

پیش بینی عملکرد ماشین حفار بازویی در حفر تونل با استفاده از الگوریتم کرم شب تاب و الگوریتم مبتنی بر آموزش و یادگیری - مطالعه موردی

پژوهشی

هادی فتاحی^{۱*}؛ حسین قائدی^۲؛ فرشاد ملک محمودی^۳

۱- دانشیار؛ دانشکده مهندسی علوم زمین، دانشگاه صنعتی اراک، h.fattahi@arakut.ac.ir

۲- دانشجو؛ دانشکده مهندسی علوم زمین، دانشگاه صنعتی اراک، hossein.ghaedi74@yahoo.com

۳- دانشجو؛ دانشکده مهندسی علوم زمین، دانشگاه صنعتی اراک، farshad.malekmahmoodi@gmail.com

دریافت دست نوشته: ۱۴۰۰/۰۵/۰۲؛ پذیرش دست نوشته: ۱۴۰۰/۱۰/۰۵

شماره صفحات: ۳۵ تا ۵۰

شناسه دیجیتال (DOI): 10.22044/tuse.2021.11010.1423

واژگان کلیدی	چکیده
ماشین حفار بازویی الگوریتم مبتنی بر آموزش-یادگیری الگوریتم کرم شب تاب مقادیر واجهشی چکش اشمیت	ماشین حفار بازویی از آن دسته از ماشین‌هایی هستند که قابلیت حفاری بالایی در سنگ‌هایی با مقاومت کم تا متوسط را دارا می‌باشند. از این رو به طور گسترده در حفاریات زیرزمینی مورد استفاده قرار می‌گیرد. تخمین عملکرد ماشین حفار بازویی یکی از موضوعات اصلی و مهم در تخمین تقریبی زمان اتمام پروژه و همچنین هزینه‌های پروژه به حساب می‌آید. به همین منظور هدف از نگارش این مقاله، پیشنهاد مدل‌های پیش‌بینی هوشمند برای تخمین عملکرد ماشین حفار بازویی بوسیله دو روش هوشمند الگوریتم کرم شب تاب (FA) و الگوریتم مبتنی بر آموزش و یادگیری (TLBO) و با استفاده از یک پایگاه داده (یک مطالعه موردی) است. در این مدل‌ها از مقادیر واجهشی چکش اشمیت و شاخص کیفیت توده سنگ (RQD) به عنوان پارامترهای ورودی و از نرخ برش ماشین حفار بازویی به عنوان پارامتر خروجی استفاده شده است. در پایان برای ارزیابی دقت مدل‌ها و مدل‌سازی از شاخص‌های ضریب همبستگی مربع (R^2)، شمول واریانس (VAF)، جذر میانگین خطای مربع (RMSE) و میانگین خطای مربع (MSE) استفاده شده است. با توجه به نتایج بدست آمده در این مقاله و همچنین اعتبارسنجی مدل ایجاد شده، مقادیر پیش‌بینی عملکرد ماشین حفار بازویی توسط الگوریتم‌های بهینه‌سازی مبتنی بر آموزش و یادگیری و کرم شب تاب با مقادیر واقعی بسیار نزدیک بوده و از خطای کمی برخوردار است؛ بنابراین از مدل ایجاد شده می‌توان برای عملکرد ماشین حفار بازویی در شرایط زمین‌شناسی مشابه دیگر استفاده کرد.

۱- پیش‌گفتار

آتشکاری، امکان اجرای انواع مسیرها با قوس‌های مختلف، انعطاف پذیری عملیاتی، حفر تونل‌های متقاطع و دسترسی کامل به سینه کار اشاره کرد. چنین مزایایی به همراه پیشرفت‌های اخیر در عملکرد دستگاه و قابلیت اعتماد بالاتر ماشین‌ها موجب شده است تا معدنکارانی که از سیستم‌های مکانیزه بهره می‌برند بخش عمده و بیشتری از بازار تولیدات معدنی را به خود اختصاص دهند. یکی از مسائل مهم در

از مزایای استفاده ماشین‌های حفار بازویی در حفر تونل‌ها می‌توان به نداشتن محدودیت در قطر تونل، حفر تونل‌هایی با مقاطع دلخواه، حفاری در سنگ‌هایی با مقاومت نرم تا متوسط ($\sigma_c < 100 MPa$)، حفاری با صدمه کم به دیواره، نیاز به نگهداری و تهویه کم‌تر نسبت به روش چالزنی-


مقیاس زغال سنگ پیشنهاد دادند. ابراهیم‌آبادی و گشتاسبی (Ebrahimabadi, et al., 2011) همچنین روشی را برای پیش‌بینی عملکرد ماشین حفار بازویی براساس شاخص تردی توده‌سنگ پیشنهاد دادند. ابراهیم‌آبادی و همکاران (Ebrahimabadi, et al., 2012) در تحقیقی مدل‌های جداگانه‌ای برای شرایط مختلف زمین و شرایط ماشین حفار بازویی ارائه دادند. یزدانی چمزینی و حاجی یخچالی (Abdolreza & Siamak, 2013) مدلی با استفاده از خواص توده‌سنگ را برای پیش‌بینی عملکرد ماشین حفار بازویی ارائه دادند. یزدانی و همکاران در بررسی‌های خود مدل جدیدی را بر اساس خصوصیات توده‌سنگ برای پیش‌بینی عملکرد ماشین حفار بازویی ارائه کردند. در تحقیق دیگر ابراهیم‌آبادی و عظیمی‌پور یک مدل عملکرد ماشین حفار بازویی تنها براساس شاخص کیفیت توده‌سنگ (RQD) و مقاومت فشاری تک محوره (UCS) را مورد بررسی قرار دادند. (Ebrahimabadi, et al., 2015) اُزفیرات و همکاران (Ozfirat et al., 2017) در تحقیقی به پیش‌بینی عملکرد ماشین حفار بازویی بر مبنای عواملی همچون قدرت ماشین، وزن ماشین، نسبت قدرت به وزن، شاخص نرخ حفاری، مقاومت فشرده‌گی تک محوری و درجه‌بندی جرم سنگ بر عملکرد ماشین حفار بازویی پرداختند. در تحقیقی دیگر کهرمان و همکاران (Kahraman, et al., 2019) مطالعه‌ای بر روی پیش‌بینی عملکرد ماشین حفار بازویی با استفاده از روش‌های تست آسان مانند مقاومت کششی برزیلی، مقاومت بار نقطه‌ای، چگالی و تخلخل انجام دادند. اورین و همکاران (Averin, et al., 2019) مدلی را برای ارزیابی کارایی ماشین حفار بازویی براساس روش‌های تجربی و شاخص مقاومت سنگ معادل ارائه دادند. سو و آککان (Su & Akkas, 2020) تجزیه و تحلیل نرخ سایش، انرژی ویژه، نرخ پیشروی و مصرف ابزار برش را مورد بحث قرار دادند. نتایج نشان داد که نوع متالوژی، موقعیت‌های انتخاب و دیگر شرایط محیطی بر مکانیسم فرسایش تأثیر می‌گذارند. در نهایت، دو مدل مختلف برای تخمین مصرف برش در سنگ‌های ماسه‌ای و سنگ آهک براساس داده‌های واقعی بدست آمده از ناحیه زغالی پیشنهاد دادند. ژانگ و همکاران (Zhang, et al., 2021) پژوهشی در قالب تأثیر پارامترهای حرکتی بر روی

حفاری‌های مکانیزه بررسی‌های امکان‌سنجی، تعیین هزینه‌های پروژه و زمان بندی آن است که نیازمند تعیین دقیق و صحیح عملکرد دستگاه و بهره‌وری آن است. عملکرد ماشین حفار بازویی به طور کلی متأثر از نوع دستگاه حفار بازویی (سیستم برش طبلکی یا سیستم برش مخروطی)، شرایط زمین‌شناسی، ژئوتکنیکی و روش اجرا یا فرآیند انجام عملیات است. به همین خاطر پیش‌بینی عملکرد این دستگاه‌ها، اثر مستقیمی بر افزایش میزان تولید و سرعت بخشیدن به آن و نهایتاً سوددهی پروژه‌ها خواهد داشت.

برآورد و تخمین عملکرد ماشین حفار بازویی یک کار بسیار پیچیده است. با این وجود بدلیل اهمیت زیاد موضوع، مطالعاتی برای یافتن رابطه معنی‌داری بین عملکرد ماشین حفار بازویی با سایر پارامترهای مؤثر بر روی آن، انجام شده که در ادامه به مهمترین آنها اشاره خواهد شد. سندبک و داگلاس (Douglas, 1985; Sandbak, 1985) یک سیستم طبقه‌بندی سنگی پیشنهاد کردند که می‌تواند برای پیش‌بینی تغییرات نرخ پیشروی و عملکرد ماشین حفار بازویی در معدن مس *San Manuel* در یک شیب نزدیک به ۱۱ درجه به کار رود. بیلگین و سیریک (Bilgin, et al., 1988) یک مدل عملکرد ماشین حفار بازویی براساس شاخص کیفیت توده‌سنگ (RQD) و مقاومت فشاری تک محوره (UCS) ارائه کردند. کوپور و اوزدمیر (Copur, et al., 1998) از داده‌های جمع‌آوری شده از یک ماشین حفار بازویی در دانشکده معدن کلرادو برای پیش‌بینی عملکرد ماشین حفار بازویی براساس سه عامل وزن ماشین حفار بازویی، قدرت کاترهد و شاخص نرخ نفوذ ماشین حفار بازویی استفاده کردند. بیلگین و دینکر (Bilgin, et al., 2004) برخی از عوامل زمین‌شناسی و ژئوتکنیکی مؤثر بر عملکرد ماشین حفار بازویی را در یک تونل مورد مطالعه قرار دادند. اوکاک و بیلگین (Ocak & Bilgin, 2010) مقایسه‌ای در مورد عملکرد ماشین حفار بازویی با عملکرد چکش ضربه‌ای و روش چالزنی- انفجار، در حفاری تونل‌های ایستگاه مترو استانبول انجام دادند و دریافتند که استفاده از ماشین حفار بازویی در محیط شهری، دارای عملکرد بهتری از دو روش دیگر است. ابراهیم‌آبادی و گشتاسبی (Ebrahimabadi, et al., 2011) مدل‌های پیش‌بینی را برای عملکرد برش ماشین حفار بازویی در

۲-۱- الگوریتم TLBO

الگوریتم بهینه‌سازی TLBO در سال ۲۰۱۲ توسط راتو و همکاران (Rao, et al., 2012) ارائه شده که مشابه سایر روش‌های بهینه‌سازی برگرفته از طبیعت و مبتنی بر جمعیت است و بر تأثیر یک معلم بر روی یادگیری دانش‌آموزان در کلاس درس اشاره دارد. الگوریتم TLBO از توانایی یادگیری دانش‌آموزان در کلاس درس و آموزش معلم کلاس به دانش‌آموزان برای ارتقاء سطح تحصیلی کلاس بهره می‌برد. معلم و دانش‌آموزان دو عنصر اصلی الگوریتم TLBO هستند. با توجه به شکل ۱، در یک تکرار i معلم (T_i) تلاش می‌کند، سطح علمی دانش‌آموزان را افزایش دهد و به سطح علمی خود سوق دهد، که این تلاش را می‌توان با بهبود میانگین دانش‌آموزان از مقدار (M_i) به مقدار (M_{i+1}) در تکرار بعد نشان داد. از آنجا که دانش‌آموزان در تکرار اول سطحشان با آموزش معلم افزایش می‌یابد؛ لذا در این روش برای تکرار بعدی، معلم جدیدی گزینش می‌شود تا آموزش‌های بعدی را به دانش‌آموزان برای پیشبرد روند آموزش ارائه دهد. این معلم جدید در تکرار جدید ($i+1$) از بین دانش‌آموزان در تکرار جدید به صورت گزینش بین بهترین عضو (T_{i+1}) انتخاب می‌شود.



شکل ۱- توزیع نمرات دانش‌آموزان در دو تکرار متوالی

در این الگوریتم، ابتدا یک جمعیت اولیه با تعداد جمعیت N_p و تعداد متغیر طراحی N_v برابر تعداد المان‌های سازه تعیین می‌شود. اگر این جمعیت به صورت ماتریسی در نظر گرفته شود، جمعیت کلاس، مطابق با رابطه ۱ ماتریسی با N_p سطر و N_v ستون است این جمعیت تعریف می‌شود. همانطور که گفته شد، این الگوریتم رامی‌توان به دو بخش مرحله آموزش و مرحله یادگیری تقسیم کرد که به هر یک از آن‌ها پرداخته می‌شود.

عملکرد برش ماشین حفار بازویی ارائه دادند. آنها با استفاده از مصرف انرژی مخصوص برش و میانگین مصرف ابزار برش به عنوان شاخص، اثرات عمق برش، سرعت و فاصله برش بعدی بر روی عملکرد برش را مورد بحث قرار دادند. اوزسن و همکاران (Özşen, et al., 2021) تحقیقی تحت عنوان تخمین انرژی ویژه و ارزیابی عملکرد ماشین حفار بازویی با استفاده از ویژگی‌های سنگ و شاخص کار بوند ارائه دادند که در آن با استفاده از نتایج تست‌های مکانیک‌سنگی به یک راه‌حل واحد برای تخمین انرژی ویژه دست یافتند.

اگرچه تلاش‌های قبلی ارزشمند هستند، اما تمامی مطالعات عنوان شده از روش‌های تجربی و رگرسیونی استفاده کردند که در روش‌های تجربی به دلیل یکسان نبودن شرایط زمین و سنگ و خطای بالای روش‌های رگرسیونی (خطی/غیرخطی) نمی‌توان از رابطه ایجاد شده در مطالعات دیگر با اطمینان استفاده کرد. عبارتی دیگر موضوع روش‌های رگرسیونی به دلیل پایین بودن دقت مدل ساخته شده از واقعیت مسئله دور بوده و نمی‌توان به عنوان یک رابطه مطمئن از آن یاد کرد؛ بنابراین با پیشرفت علم رایانه و برنامه‌نویسی روش‌های توسعه‌یافته مانند روش‌های هوشمند، می‌توانند با موفقیت رفتار خطی و غیر خطی نهفته در داده‌ها را پیدا کنند و از رابطه ایجاد شده توسط این روش‌ها می‌توان با دقت بسیار بالایی در تمامی مطالعات دیگر استفاده کرد. هدف از نگارش این مقاله، کاربرد روش‌های هوشمند برای ارزیابی عملکرد ماشین حفار بازویی با استفاده از دو الگوریتم بهینه‌سازی مبتنی بر آموزش و یادگیری (TLBO) و الگوریتم کرم شب‌تاب (FA) است. در این مدل‌ها، مقادیر واجهشی چکش اشمیت و شاخص کیفیت توده سنگ (RQD) به عنوان پارامترهای ورودی و نرخ برش ماشین حفار بازویی به عنوان پارامتر خروجی استفاده می‌شود. برای نشان دادن قابلیت این روش‌ها از داده‌های تونل‌های فاضلاب استانبول ترکیه استفاده شده است.

۲- روش تحقیق

در این مقاله از الگوریتم‌های بهینه‌سازی TLBO و کرم شب‌تاب برای پیش‌بینی عملکرد ماشین حفار بازویی در حفر تونل استفاده شده است.

$$M(j) = \frac{\sum_{k=1}^N \frac{X^k(j)}{F^k}}{\sum_{k=1}^N \frac{1}{F^k}} \quad (5)$$

در رابطه فوق، Fk بیانگر دانش آموز k ام می‌باشد.

۲-۱-۲- مرحله یادگیری

این مرحله، قسمت دوم فرآیند بهینه‌سازی $TLBO$ را تشکیل می‌دهد که در آن دانش‌آموزان سطح دانش و اطلاعاتشان را بالاتر می‌برند. هر دانش‌آموز به صورت تصادفی با سایر دانش‌آموزان ارتباط برقرار کرده و در صورتی که سطح یکی از آن‌ها بالاتر باشد مطالبی را به دیگری می‌آموزد تا سطح آن افزایش یابد این فرآیند با روابط ۶ و ۷ بیان می‌شود (Rao, et al., 2011).


$$IF \ f(x_i) < f(x_j) \quad (6)$$

$$x_{new,i} = x_{old,i} + r_i(x_{old,i} - x_j)$$

$$ELSE \ IF \ f(x_i) > f(x_j) \quad (7)$$

$$x_{new,i} = x_{old,i} + r_i(x_j - x_{old,i})$$

که در آن اندیس i از یک تا تعداد کل اعضا تغییر می‌کند، $x_{old,i}$ یک عضو قدیمی است که تاکنون از تعامل با سایر دانش‌آموزان چیزی فرا نگرفته است، r_i یک عدد تصادفی بین $[0, 1]$ است، x_j دانش‌آموزی است که به صورت تصادفی و با شرط $i \neq j$ انتخاب شده است، $f(x_i)$ و $f(x_j)$ مقادیر تابع هدف برای x_i و x_j هستند و $x_{new,i}$ عضو جدیدی است که تنها در صورتی که از عضو قدیمی بهتر باشد پذیرفته خواهد شد. مطابق با روابط ۶ و ۷، شکل ۲، مرحله آموزش را دو حالت بالا بودن نمرات و سطح دانش‌آموز در حال یادگیری و آموزش‌دهنده را نشان می‌دهد.



حالت اول: اگر نمرات آموزش گیرنده از آموزش دهنده بدتر باشد.

حالت دوم: اگر نمرات آموزش گیرنده از آموزش دهنده بهتر باشد.

شکل ۲- مقایسه شرایط آموزش گیرنده و آموزش‌دهنده

$$\begin{bmatrix} X_{1,1} & X_{1,1} & \dots & X_{1,N_v-1} & X_{1,N_v} \\ X_{2,1} & X_{1,1} & \dots & X_{2,N_v-1} & X_{2,N_v} \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ X_{N_p-1,1} & X_{N_p-1,2} & \dots & X_{N_p-1,N_v-1} & X_{N_p-1,N_v} \\ X_{N_p,1} & X_{N_p,2} & \dots & X_{N_p,N_v-1} & X_{N_p,N_v} \end{bmatrix} \quad (1)$$

۲-۱-۱- مرحله آموزش

در این مرحله از بین جمعیت ساخته شده عضوی که بهترین مقدار (کمترین مقدار پاسخ برای وزن) را می‌دهد به عنوان معلم انتخاب شده و سپس رابطه ۲ به هر یک از اعضا اعمال می‌شود (Rao, et al., 2011).

$$X_{new,N_v}^k(j) = X_{old,N_v}^k \pm \Delta(j) \quad (2)$$

که در آن، X^k نشان‌دهنده متغیر طراحی z ام برای طراحی k ام، X_{new,N_v} مقدار متغیر طراحی جدید (سطح مقطع المان) برای دانش‌آموز N_v و X_{old,N_v} مقدار متغیر طراحی برای دانش‌آموز N_v از تکرار قبل است. پارامتر $\Delta(j)$ به عنوان گام حرکت و اختلاف بین معلم و میانگین کلاس است که باید به گونه‌ای انتخاب شود که دانش‌آموزان را به سمت معلم انتقال دهد. پارامتر $\Delta(j)$ از رابطه (۳) محاسبه می‌شود.

$$\Delta(j) = T_F + r |M(j) - T(j)| \quad (3)$$

مطابق با رابطه ۳، $M(j)$ مقدار میانگین کلاس، T_F ضریب آموزش، $T(j)$ بیانگر معلم و r عدد تصادفی بین ۰ و ۱ است (Rao et al., 2011). از آنجایی که الگوریتم $TLBO$ یک فرآیند مبتنی بر تکرار است، در انتهای هر مرحله آموزش، نقش معلم با یکی از بهترین دانش‌آموزان جایگزین می‌شود. محاسبه میانگین برای نشان دادن مقیاس جستجو بسیار مهم است. در الگوریتم $TLBO$ فرمول ارائه شده توسط راتو برای محاسبه میانگین به صورت رابطه (۴) است.

$$M(j) = \frac{1}{N} \sum_{k=1}^N X^k(j) \quad (4)$$

از آنجا که N اندازه جمعیت است، در $TLBO$ وزن میانگین مبتنی بر سازگاری تک‌تک مقادیر فرض شده است. سازگاری مبتنی بر میانگین به صورت رابطه (۵) تعریف می‌شود.

و فرموله کردن جذابیت حشرات است؛ همچنین شدت نور در فاصله معین r از منبع نور، از قانون مجذور معکوس پیروی می‌کند. گفته می‌شود که شدت نور I با افزایش فاصله کاهش پیدا می‌کند. نور می‌تواند به عنوان تابع هدف فرموله شده و به عنوان یک الگوریتم بهینه‌سازی جدید معرفی شود. درخشندگی کرم‌های شب‌تاب توسط مقدار تابع هدف تعیین می‌شود. برای مسئله بهینه‌سازی، شدت نور می‌تواند به سادگی توسط مقدار تابع هدف تعیین می‌شود. میزان جذابیت کرم شب‌تاب نسبی است و به شدت نور دیده شده توسط کرم‌های مجاور بستگی دارد. جذابیت کرم‌های شب‌تاب توسط رابطه ۸ محاسبه می‌شود.

$$B(r) = B_0 e^{-\gamma r^2} \quad (8)$$

که در آن B_0 بیانگر میزان جذابیت کرم درخشان‌تر با دامنه تغییرات $[0, 1]$ ، γ بیانگر ضریب جذب با تغییرات $0, \infty$ ، $[0]$ و r بیانگر فاصله حشره نام از حشره نام است. رابطه ۹ معادله r_{ij} را نشان می‌دهد.

$$r_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (9)$$

حرکت حشره نام به سمت حشره نام از رابطه ۱۰ محاسبه می‌شود.

$$x_i = x_i + B_0 e^{-\gamma r} (x_j - x_i) + \alpha(\text{rand} - 0.5) \quad (10)$$

در رابطه ۱۰ جمله اول نشان‌دهنده موقعیت فعلی کرم شب‌تاب i ، جمله دوم فرآیند جذب و جمله سوم، جمله تصادفی‌ساز است که توسط پارامتر تصادفی‌ساز α این کار انجام می‌گردد. rand یک عدد تصادفی است که با استفاده از توزیع یکنواخت بین $[0, 1]$ به دست می‌آید.

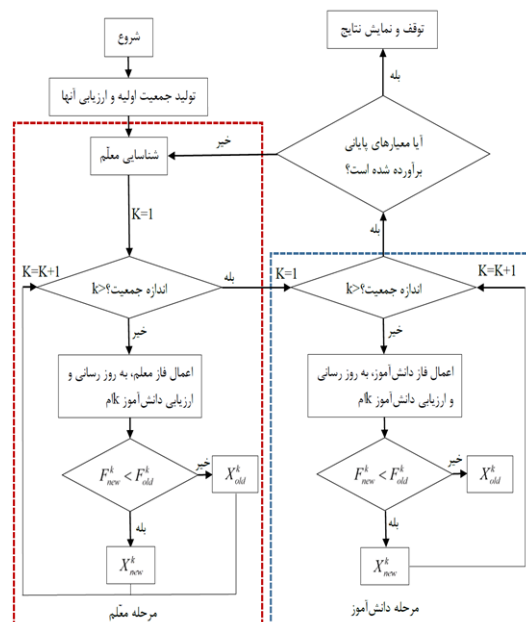
مرال اجرای این الگوریتم به صورت زیر است (Yang, 2013):

گام ۱: تعریف توابع هدف و محدودیت‌ها و همچنین تعیین تعداد تکرار (یا شرط توقف).

گام ۲: بارگذاری جمعیت n کرم شب‌تاب به صورت یکنواخت در فضای مساله (از تکرار دوم بر اساس درخشندگی کرم‌ها جمعین به سمت بهترین جواب (جواب غالب مرحله قبل g') حرکت می‌کند).

گام ۳: تبدیل موقعیت‌های تصادفی هر کرم به موقعیت شدنی با اعمال محدودیت‌های پیش‌نیازی حاکم بین فعالیت‌ها (این عمل با به کارگیری الگوریتم ابتکاری معرفی شده انجام می‌شود)، جواب‌های تصادفی ایجاد شده به کمک

در حالت کلی، مطابق با توضیحات گفته شده در مرحله یادگیری و آموزش شکل ۳، روند الگوریتم TLBO را نشان می‌دهد.



شکل ۳- روند کلی الگوریتم TLBO

۲-۲- الگوریتم کرم شب‌تاب (FA)

الگوریتم FA از الگوریتم‌های برگرفته از طبیعت است که رفتار اجتماعی کرم‌های شب‌تاب را شبیه‌سازی می‌کند. این الگوریتم توسط یانگ در سال ۲۰۰۸ بر مبنای رفتار و الگوهای چشمک زن کرم‌های شب‌تاب ارائه شد (Yang, 2008). اساس این الگوریتم بر این مبناست که کرم‌های شب‌تاب نورهایی تولید می‌کنند که الگوی نوری هر کدام با دیگری متفاوت است. کرم‌های شب‌تاب از این نورها به دو منظور پروسه جذب جفت‌ها و دیگر به منظور شکار استفاده می‌کنند. میزان این نور رابطه مستقیم با جذابیت کرم شب‌تاب دارد. با در نظر گرفتن میزان نور هر کرم به عنوان مقدار تابع هدف، می‌توان رفتار کرم‌های شب‌تاب را به صورت یک الگوریتم بهینه‌سازی مدل کرد؛ همچنین این نورها می‌توانند به عنوان یک سازو کار محافظتی برای کرم‌های شب‌تاب باشند. نورهای با آهنگ منظم، نرخ تابیدن نور و میزان فاصله زمانی که بین سیگنال‌های نور وجود دارند، سبب جذب کرم شب‌تاب، تغییرات شدت نور روشنایی

۳- پایگاه داده‌ها

مجموعه داده‌ها در این مطالعه شامل متغیرهای ورودی (مقادیر واجهشی چکش اشمیت و RQD) و متغیر خروجی (نرخ برش خالص ماشین حفار بازویی برای هر منطقه) است که بخشی از داده‌های مورد استفاده در این مطالعه در جدول ۱، نشان داده شده است. این داده‌ها قبلاً در طول ساخت تونل برای سیستم فاضلاب استانبول ترکیه ثبت شده‌اند (*Goktan & Gunes, 2005; Shahriar, 1988*). مقادیر واجهشی چکش اشمیت از ۳۵ منطقه سنگی مختلف همراه با نرخ برش خالص ماشین حفار بازویی برای هر منطقه بدست آمده است. مقادیر واجهشی چکش اشمیت با چکش نوع N انجام شده است. برای بدست آوردن مقادیر واجهشی چکش اشمیت سه روش انجام شده است:

- روش اول برای بدست آوردن مقادیر R_1 در هر نقطه آزمایش ۱۵ تا ۲۰ مقادیر واجهشی پیوسته اندازه‌گیری شدند و مقادیر پایین‌تر از مقدار میانگین حذف شدند.
- روش دوم برای بدست آوردن مقادیر R_2 انتخاب مقدار واجهشی بیشینه از پنج ضربه پیوسته در یک نقطه و حذف مقادیر باقیمانده (*Poole & Farmer, 1980*).
- روش سوم برای بدست آوردن مقادیر R_3 مقدار واجهشی بیشینه از ده ضربه پیوسته را در یک نقطه انتخاب کرده و مقادیر باقیمانده حذف می‌شود (*Hucka, 1965*).

۴- تخمین عملکرد ماشین حفار بازویی با

استفاده از الگوریتم‌های FA و TLBO

همانطور که قبلاً گفته شد، پیش‌بینی عملکرد ماشین حفار بازویی عامل بسیار مهم در تخمین زمان پایان پروژه و هزینه‌های مربوط به حفاری است؛ بنابراین ساخت یک مدل دقیق به منظور پیش‌بینی عملکرد ماشین حفار بازویی یکی از مهمترین مباحث در پروژه‌های تونلسازی است. به همین منظور، در این بخش برای تخمین نرخ برش ماشین حفار بازویی از الگوریتم‌های FA و TLBO استفاده شده است. در این مدل‌سازی از مقادیر واجهشی چکش اشمیت (R_3, R_2, R_1)

این الگوریتم به یک جواب شدنی براساس روابط پیش‌نیازی تبدیل می‌شوند.

گام ۴: بررسی مجدد شدنی بودن موقعیت‌های خروجی گام ۳، جواب‌های غیرموجه (نشدنی) در این گام از مجموعه جواب‌ها حذف می‌شوند.

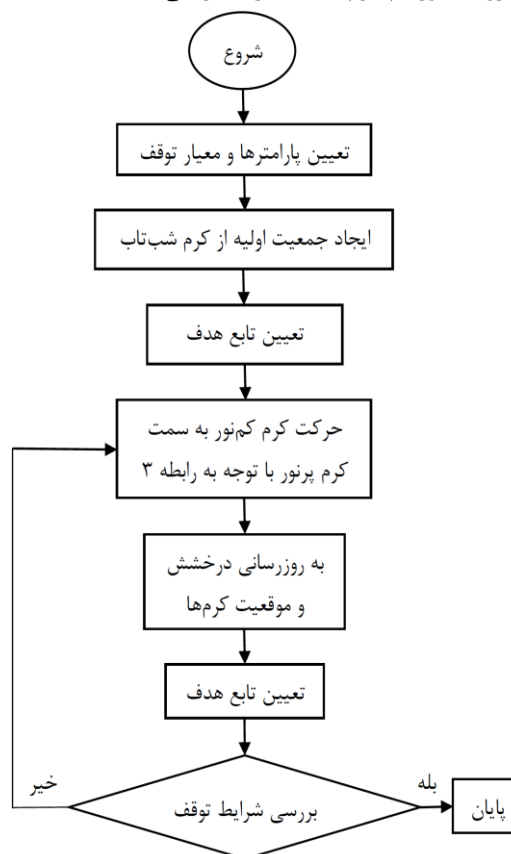
گام ۵: محاسبه مقدار توابع هدف یا درخشندگی برای هر کرم، مقایسه آن با یکدیگر و تعیین g_i . در صورتی که یک جواب غالب در بین جواب‌های این تکرار وجود نداشته باشد.

گام ۶: تولید بردار وزن تصادفی با مجموع یک برای هر کرم شب‌تاب.

گام ۷: تعیین g_i براساس وزن‌ها و مقادیر توابع هدف هر کرم شب‌تاب.

گام ۸: تعیین جواب‌های غیرمغلوب و انتقال آن‌ها به تکرار بعدی.

گام ۹: تکرار گام‌های ۲ تا ۸ تا رسیدن به شرط توقف. شکل ۴، روند الگوریتم کرم شب‌تاب را نشان می‌دهد.



شکل ۴- چارت کلی الگوریتم FA

و کیفیت توده‌سنگ (RQD) برای تخمین نرخ برش ماشین حفار بازویی استفاده شده است.

جدول ۱- بخشی از داده‌های مورد استفاده در این مطالعه (Goktan & Gunes, 2005; Shahriar, 1988)

منطقه	شرح ساختار سنگ	پارامترهای ورودی				پارامتر خروجی
		RQD	R ₁	R ₂	R ₃	نرخ برش (m ³ /h)
۱	گلسنگ	۰	۲۹	۳۱	۳۲	۲۵
۲	شیل	۰	۳۵	۳۵	۴۳	۲۰/۴
۳	شیل	۲۳	۳۷	۳۴	۴۴	۲۰/۴
۴	گلسنگ	۰	۳۸	۳۶	۴۵	۱۶/۲
۵	شیل-اسلیت	۱۹	۳۸	۳۶	۴۶	۲۰/۳
۶	شیل	۱۹	۳۱	۳۰	۳۴	۲۳
۷	ماسه سنگ	۰	۴۸	۴۵	۴۹	۲۳
۸	شیل همراه با رس دستی	۲۳	۳۷	۳۵	۳۸	۱۹/۶
۹	شیل همراه با رس دستی	۱۹	۳۸	۴۱	۴۵	۱۸/۴
۱۰	شیل	۳۳	۴۷	۴۵	۵۰	۲۱/۴

تخمین نرخ برش ماشین حفار بازویی به صورت زیر به دست آمده است:

$$NCR = (20 \times RQD^{-0.6266}) + (7.4236 \times R_1^{-1}) \times (20 \times R_2^{-0.5438}) \times (R_3^{0.2211}) \quad (12)$$

$$NCR = (-0.0038 \times RQD^{0.870}) + (7.6871 \times R_1^{-0.831}) \times (10 \times R_2^{0.6212}) \times (R_3^{-0.1337}) \quad (13)$$

لازم به ذکر است که روابط پیش‌بینی بالا، به پارامترهای تنظیم اولیه الگوریتم‌های بهینه‌سازی FA و $TLBO$ که به روش سعی و خطا تعیین می‌شوند، وابسته هستند. جدول ۲ و جدول ۳، مقادیر پارامترهای تنظیم الگوریتم‌های FA و $TLBO$ را نشان می‌دهند.

جدول ۲- پارامترهای تنظیم شده برای اجرای الگوریتم

مقدار	پارامترها
۲۰۰۰	ماکزیمم تعداد تکرار
۳۰	تعداد کرم شب‌تاب
۱	ضریب جذب نور
۰/۲	مقدار اولیه ضریب جذابیت
۰/۲	ضریب جهش
۰/۹۹	نسبت میرایی ضریب جهش

در روش‌های الگوریتم‌های بهینه‌سازی هوشمند، داده‌های ورودی به طور تصادفی به دو دسته داده‌های آموزش و آزمون تقسیم می‌شوند. با استفاده از مجموعه داده‌های آموزش، ضرایب بهینه روابط پیش‌بینی بدست می‌آید. سپس با استفاده از مجموعه داده‌های آزمون روابط بدست آمده توسط این الگوریتم‌ها مورد ارزیابی قرار می‌گیرند. به همین دلیل در این مقاله، ۸۰ درصد مجموعه داده‌ها (۲۸ داده) به عنوان داده‌های آموزش و ۲۰ درصد مجموعه داده‌ها برای ارزیابی صحت و دقت مدل‌ها استفاده شده است. در این مطالعه، در محیط $MATLAB$ ، پیش‌بینی نرخ برش ماشین حفار بازویی با استفاده از الگوریتم‌های بهینه‌سازی FA و $TLBO$ بر روی معادله رگرسیونی غیرخطی زیر انجام شد:

$$NCR = (w_1 \times RQD^{w_2}) + (w_3 \times R_1^{w_4}) \times (w_5 \times R_2^{w_6}) \times (R_3^{w_7}) \quad (11)$$

که در آن، w_i عوامل وزن‌دهی متناظر برای پارامترهای ورودی هستند که مقدار بهینه آن‌ها توسط الگوریتم‌های بهینه‌سازی در نرم‌افزار $MATLAB$ بدست می‌آیند.

مطابق با رابطه ۱۱، روابط پیش‌بینی و ضرایب بهینه بدست آمده توسط دو الگوریتم $TLBO$ و FA جهت

پیش‌بینی عملکرد ماشین حفار بازویی در حفر تونل با استفاده از الگوریتم کرم شب‌تاب و ... هادی فتاحی و ... ص ۳۵-۵۰

بدست آمده (روابط ۱۲ و ۱۳) از الگوریتم‌های بهینه‌سازی *FA* و *TLBO* در دو حالت آموزش و آزمون در جدول ۴، نشان داده شده است.

$$R^2 = 1 - \frac{\sum_{k=1}^n (Y_{mea} - Y_{pre})^2}{\sum_{k=1}^n Y_{mea}^2 - \frac{\sum_{i=1}^n Y_{pre}^2}{n}} \quad (14)$$

$$VAF = \left[1 - \frac{\text{var}(Y_{mea} - Y_{pre})}{\text{var}(Y_{mea})} \right] \quad (15)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_{mea} - Y_{pre})^2} \quad (16)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_{mea} - Y_{pre})^2 \quad (17)$$

همچنین همبستگی بین نرخ برش اندازه‌گیری شده و پیش‌بینی برای داده‌های آزمون توسط دو الگوریتم در شکل ۵ تا شکل ۸، نشان داده شده است. مطابق با نتایج به دست آمده از جدول ۴ و شکل ۵ تا شکل ۸، مدل‌های بدست آمده توسط الگوریتم‌های *FA* و *TLBO* دارای دقت قابل قبولی در پیش‌بینی عملکرد ماشین حفار بازویی هستند. برش ماشین حفار بازویی توسط مدل‌های *FA* و *TLBO* و مقادیر اندازه‌گیری شده برای ۳۵ مجموعه داده در مراحل آموزش (۲۸ داده) و آزمون (۷ داده) در شکل ۹ تا شکل ۱۲، نشان داده شده است.

جدول ۳- پارامترهای تنظیم شده برای اجرای الگوریتم *TLBO*

مقدار	پارامترها
۲۰۰۰	ماکزیمم تعداد تکرار
۵۰	اندازه جمعیت


۵- اعتبارسنجی مدل‌ها

برای ارزیابی عملکرد مدل‌های بدست آمده توسط الگوریتم‌های *FA* و *TLBO*، چندین شاخص آماری شامل ضریب همبستگی مربع (R^2)، شمول واریانس (*VAF*)، جذر میانگین خطای مربع (*RMSE*) و میانگین خطای مربع (*MSE*) استفاده شده است. در این روابط N تعداد نمونه‌ها، Y_{pre} و Y_{mea} به ترتیب مقادیر اندازه‌گیری شده و پیش‌بینی شده هستند. به منظور برآورد درست روابط بدست آمده، هرچقدر مقدار *MSE* و *RMSE* به عدد صفر، R^2 به عدد ۱ و *VAF* به عدد ۱۰۰ نزدیکتر شوند، مدل در پیش‌بینی موفق‌تر عمل کرده است. روابط مربوط به شاخص‌های R^2 ، *VAF*، *RMSE* و *MSE* را می‌توان به ترتیب بصورت روابط ۱۴ تا ۱۷ تعریف کرد (Fattahi, 2020; Fattahi & Babanouri, 2017; Fattahi & Bazdar, 2017; Fattahi & Moradi, 2017; Karimpouli & Fattahi, 2018).

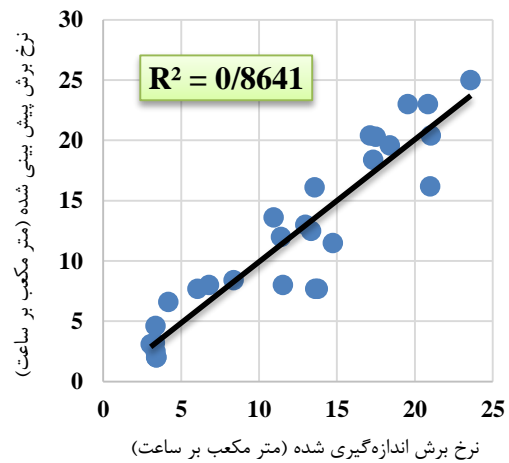
مقادیر شاخص‌های بالا برای مدل‌های پیش‌بینی

جدول ۴- اعتبارسنجی روابط پیش‌بینی با استفاده از الگوریتم‌های بهینه‌سازی *FA* و *TLBO*


MSE	R^2	VAF	RMSE	شرح	نوع الگوریتم
۰/۰۴۴۵۳۴	۰/۸۶۴۱	۸۳/۹۵	۰/۲۱۱۰	آموزش	الگوریتم <i>FA</i>
۰/۰۰۰۰۰۱۳۱۸	۰/۹۲۵۳	۹۲/۶۸	۰/۰۰۱۱	آزمون	
۰/۰۰۰۰۱۰۰۰۶	۰/۸۹۲۵	۸۸/۹۷	۰/۰۰۳۲	آموزش	الگوریتم <i>TLBO</i>
۰/۰۰۰۰۰۷۸۹۸	۰/۹۱۵۴	۹۱/۷۵	۰/۰۰۲۸	آزمون	




شکل ۷- همبستگی بین نرخ برش اندازه‌گیری شده و پیش‌بینی برای داده‌های آزمایش توسط الگوریتم TLBO



شکل ۵- همبستگی بین نرخ برش ماشین حفار بازویی اندازه‌گیری شده و پیش‌بینی برای داده‌های آموزش توسط الگوریتم FA

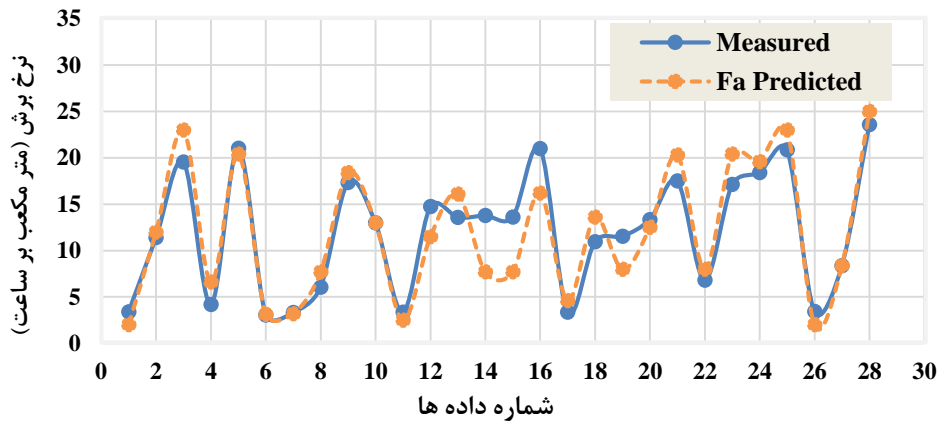


شکل ۸- همبستگی بین نرخ برش ماشین حفار بازویی اندازه‌گیری شده و پیش‌بینی برای داده‌های آزمون توسط الگوریتم TLBO




شکل ۶- همبستگی بین نرخ برش اندازه‌گیری شده و پیش‌بینی برای داده‌های آزمون توسط الگوریتم FA

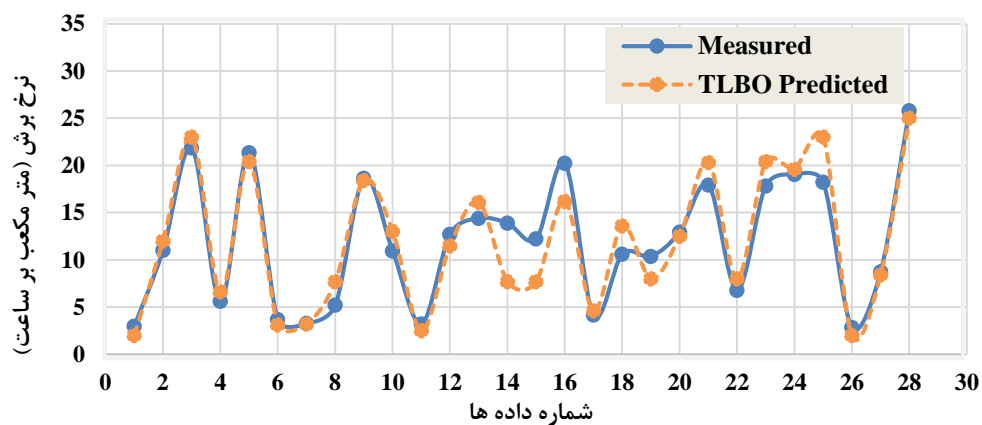
پیش‌بینی عملکرد ماشین حفار بازویی در حفر تونل با استفاده از الگوریتم کرم شب‌تاب و ... هادی فتاحی و ... ص ۳۵-۵۰



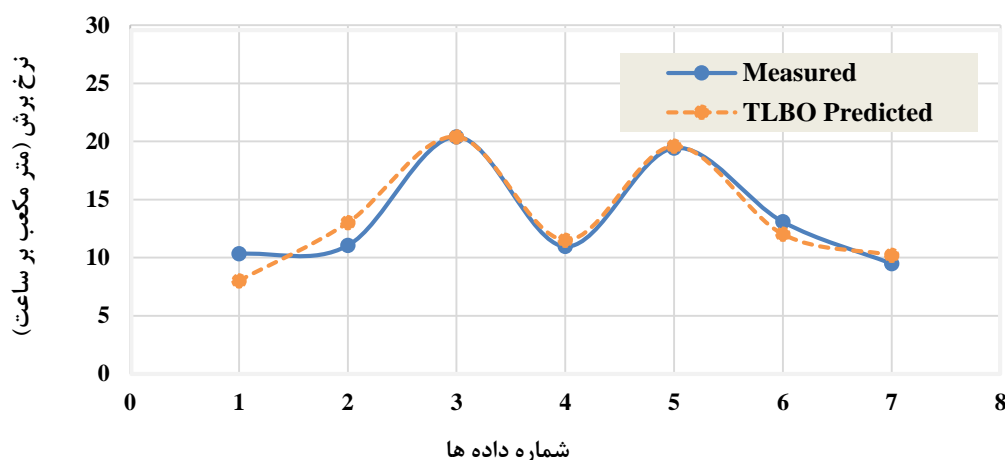
شکل ۹- مقایسه بین نرخ برش ماشین حفار بازویی اندازه‌گیری شده و پیش‌بینی شده برای داده‌های آموزش توسط الگوریتم FA



شکل ۱۰- مقایسه بین نرخ برش ماشین حفار بازویی اندازه‌گیری شده و پیش‌بینی شده برای داده‌های آزمون توسط الگوریتم FA



شکل ۱۱- مقایسه بین نرخ برش ماشین حفار بازویی اندازه‌گیری شده و پیش‌بینی شده برای داده‌های آموزش توسط الگوریتم TLBO



شکل ۱۲- مقایسه بین نرخ برش ماشین حفار بازویی اندازه‌گیری شده و پیش‌بینی شده برای داده‌های آزمون توسط الگوریتم TLBO

تجربی قادر به تشخیص ساختارهای پیچیده دخیل در مجموعه داده‌ها نیستند. در این تحقیق از دو روش هوشمند به نام‌های الگوریتم TLBO و الگوریتم FA برای تخمین عملکرد ماشین حفار بازویی استفاده شده است. به منظور اعتبارسنجی روابط بدست آمده، از شاخص‌های ضریب همبستگی مربع (R^2)، شمول واریانس (VAF)، جذر میانگین خطای مربع (RMSE) و میانگین خطای مربع (MSE) برای هر یک از الگوریتم‌ها برای دو مجموعه داده آموزش و مجموعه داده آزمون استفاده شد. مطابق با نتایج بدست آمده، مشخص شد که مدل‌های پیش‌بینی حاصل شده (روابط ۱۲ و ۱۳) به دلیل پایین بودن خطا و نزدیک بودن به مقدار اندازه‌گیری شده می‌تواند به عنوان روابط مناسب برای تخمین عملکرد ماشین حفار بازویی در حفر تونل مدنظر استفاده کرد. با توجه به عدم قطعیت در پارامترهای زمین‌شناسی، تابع حالت حدی ایجاد شده این متودولوژی می‌تواند قابل تعمیم برای منطقه مشابه باشد و با داشتن مقادیر هر یک از ورودی‌های مدل می‌توان عملکرد ماشین حفاری ماشین حفار بازویی را در همان منطقه بدست آورد؛ همچنین با توجه به نتایج به دست آمده از این مقاله می‌توان دریافت که الگوریتم‌های بهینه‌سازی FA و TLBO توانایی بالایی برای حل مسائل پیچیده در سایر موضوعات تونلسازی را دارند.

مطابق با شکل ۹ تا شکل ۱۲، اعتبارسنجی مدل‌های پیش‌بینی بدست آمده بوسیله‌ی الگوریتم‌های FA و TLBO در شرایط قابل قبولی به لحاظ دقت پیش‌بینی قرار دارند؛ بنابراین می‌توان به این نتیجه رسید که نتایج نرخ برش ماشین حفار بازویی در حالت واقعی با نتایج پیش‌بینی شده توسط الگوریتم‌ها تقریباً به هم نزدیک بوده که این نشان‌دهنده آن است که مدل‌های بدست آمده از دقت قابل قبولی برای پیش‌بینی عملکرد ماشین حفار بازویی در حفر تونل مدنظر برخوردار است.

۶- نتیجه‌گیری

تخمین و برآورد عملکرد حفاری ماشین حفار بازویی برای هر سازند زمین‌شناسی یکی از اصلی‌ترین نگرانی‌ها در تعیین جنبه‌های اقتصادی یک عملیات مکانیزه استخراج و یا تونل‌زنی است. تجزیه و تحلیل عملکرد ماشین حفار بازویی نقش مهمی در تخمین هزینه مورد نیاز و زمان تکمیل پروژه‌های زیرزمینی دارند؛ بنابراین، برآورد صحیح عملکرد ماشین حفار بازویی نقش قابل توجهی در برنامه‌ریزی مؤثر پروژه حفاری دارد. در این زمینه، مطالعات زیادی برای یافتن رابطه معنی‌داری بین عملکرد ماشین حفار بازویی با سایر پارامترهای مؤثر آن انجام شده است. اگرچه تلاش‌های قبلی ارزشمند هستند، اما این مدل‌های

۷- منابع

- Abdolreza, Y.-C., & Siamak, H. Y. (2013). A new model to predict roadheader performance using rock mass properties. *Journal of Coal Science and Engineering (China)*, 19(1), 51-56 .
- Averin, E., Zhabin, A., Polyakov, A., Linnik, Y., & Linnik, V. (2019). Preliminary Assessment of Roadheaders Efficiency Based on Empirical Methods and Index of Equivalent Rock Strength. *Mining of Mineral Deposits*. 2019. T. 13. № 3. C. 113, 118 .
- Bilgin, N., Dincer, T., Copur, H., & Erdogan, M. (2004). Some geological and geotechnical factors affecting the performance of a roadheader in an inclined tunnel. *Tunnelling and Underground Space Technology*, 19(6), 629-636 .
- Bilgin, N., Seyrek, T., Erding, E., & Shahriar, K. (1990). Roadheaders plean valuable tips for Istanbul metro. *Tunnels & tunnelling*, 22(10), 29-32 .
- Bilgin, N., Seyrek, T., & Shahriar, K. (1988). Roadheader performance in Istanbul. Golden Horn clean-up contributes valuable data. *Tunnels & tunnelling*, 20(6), 41-44 .
- Copur, H., Ozdemir, L., & Rostami, J. (1998). Roadheader applications in mining and tunneling industries. *PREPRINTS-SOCIETY OF MINING ENGINEERS OF AIME* .
- Douglas, W. (1985). ROADHEADERS OPEN NEW HORIZONS AT SAN-MANUEL. *E&MJ-ENGINEERING AND MINING JOURNAL*, 186(8), 22-25 .
- Ebrahimabadi, A., Azimipour, M & ,Bahreini, A. (2015). Prediction of roadheaders' performance using artificial neural network approaches (MLP and KOSFM). *Journal of Rock Mechanics and Geotechnical Engineering*, 7(5), 573-583 .
- Ebrahimabadi, A., Goshtasbi, K., Shahriar, K., & Cheraghi Seifabad, M. (2011). A model to predict the performance of roadheaders based on the Rock Mass Brittleness Index. *Journal of the Southern African institute of Mining and Metallurgy*, 111(5), 355-364 .
- Ebrahimabadi, A., Goshtasbi, K., Shahriar, K., & Seifabad, M .C. (2012). A universal model to predict roadheaders' cutting performance. *Archives of Mining Sciences*, 57 .
- Fattahi, H. (2020). A New Method for Forecasting Uniaxial Compressive Strength of Weak Rocks. *Journal of Mining and Environment*, 11(2), 505-515 .
- Fattahi, H., & Babanouri, N. (2017). Predicting tensile strength of rocks from physical properties based on support vector regression optimized by cultural algorithm. *Journal of Mining and Environment*, 8(3), 467-474 .
- Fattahi, H., & Bazdar, H. (2017). Applying improved artificial neural network models to evaluate drilling rate index. *Tunnelling and Underground Space Technology*, 70, 114-124 .
- Fattahi, H., & Moradi, A. (2017). Risk Assessment and Estimation of TBM Penetration Rate Using RES-Based Model. *Geotechnical and Geological Engineering*, 35(1), 365-376 .

- Goktan, R., & Gunes, N. (2005). A comparative study of Schmidt hammer testing procedures with reference to rock cutting machine performance prediction. *International journal of rock mechanics and mining sciences* (1997), 42(3), 466-472 .
- Hucka, V. (1965). A rapid method of determining the strength of rocks in situ. *International Journal of Rock Mechanics and Mining Sciences & Geomechanics Abstracts* ,
- Kahraman, S., Aloglu, A. S., Aydin, B., & Saygin, E .(۲۰۱۹) .The needle penetration index to estimate the performance of an axial type roadheader used in a coal mine. *Geomechanics and Geophysics for Geo-Energy and Geo-Resources*, 5(1), 37-45 .
- Karimpouli, S., & Fattahi, H. (2018). Estimation of P-and S-wave impedances using Bayesian inversion and adaptive neuro-fuzzy inference system from a carbonate reservoir in Iran. *Neural Computing and Applications*, 29(11), 1059-1072 .
- Ocak, I., & Bilgin, N. (2010). Comparative studies on the performance of a roadheader ,impact hammer and drilling and blasting method in the excavation of metro station tunnels in Istanbul. *Tunnelling and Underground Space Technology*, 25(2), 181-187 .
- Ozfirat, K. M., Malli, T., Ozfirat, P. M., & Kahraman, B. (2017). The performance prediction of roadheaders with response surface analysis for underground metal mine. *Kuwait Journal of Science*, 44(2) .(
- Özşen, H., Dursun, A. E., & Aras, A. (2021). Estimation of Specific Energy and Evaluation of Roadheader Performance Using Rock Properties and Bond Work Index. *Mining, Metallurgy & Exploration*, 1-10 .
- Poole, R., & Farmer, I. (1980). Consistency and repeatability of Schmidt hammer rebound data during field testing. *International Journal of Rock Mechanics and Mining Science*, 17(3) .(
- Rao, R. V., Savsani, V. J., & Vakharia, D. (2011). Teaching–learning-based optimization: a novel method for constrained mechanical design optimization problems. *Computer-Aided Design*, 43(3), 303-315 .
- Rao, R. V., Savsani, V. J., & Vakharia, D. (2012). Teaching–learning-based optimization: an optimization method for continuous non-linear large scale problems. *Information sciences*, 183(1), 1-15 .
- Sandbak, L. A. (1985). Roadheader drift excavation and geomechanical rock classification at San Manuel, Arizona. *Proceedings of the Rapid Excavation and Tunnelling Conference*, New York ,
- Shahriar, K. (1988). *Rock cuttability and geotechnical factors affecting the penetration rates of roadheaders* PhD thesis, Istanbul Technical University .[
- Su, O., & Akkaş, M. (2020). Assessment of pick wear based on the field performance of two transverse type roadheaders: a case study from Amasra coalfield. *Bulletin of Engineering Geology and the Environment*, 79(5), 2499-2512 .
- Yang, X.-S. (2008). *Nature-inspired metaheuristic algorithms*. Luniver press .

پیش‌بینی عملکرد ماشین حفار بازویی در حفر تونل با استفاده از الگوریتم کرم شب‌تاب و ... هادی فتاحی و ... ص ۳۵-۵۰

Yang, X.-S. (2013). Multiobjective firefly algorithm for continuous optimization. *Engineering with Computers*, 29(2), 175-184 .

Zhang, D., Liu, S., & Jia, J. (2021). Influence of motion parameters on cutting performance of boom-type roadheader during the swing cutting. *Arabian Journal for Science and Engineering*, 46(5), 4387-4397 .

Prediction of the performance of roadheader in tunnel excavation using teaching-learning based optimization algorithm and firefly algorithm, A case study

H. Fattahi^{1*}; H. Ghaedi²; F. Malekmahmoudi³

1- Associate Professor; Faculty of Earth Sciences Engineering, Arak University of Technology, h.fattahi@arakut.ac.ir

2- Student; Faculty of Earth Sciences Engineering, Arak University of Technology, hossein.ghaedi74@yahoo.com

3- Student; Faculty of Earth Sciences Engineering, Arak University of Technology, farshad.malekmahmoodi@gmail.com

Received: 24 Jul 2021; Accepted: 26 Dec 2021

DOI: 10.22044/TUSE.2021.11010.1423

Keywords

Roadheader
TLBO algorithm
Firefly algorithm
Schmidt hammer rebound values
Tunnel excavation

Extended Abstract

Summary

Roadheader machine is one of those machines that have high drilling capability in rocks with low to medium strength. Hence, it is widely used in underground excavations. Estimation of the performance of roadheader machine is one of the main and important issues in estimation of project completion time as well as project costs. Therefore, the purpose of this paper is to propose intelligent forecasting models for estimation of the performance of roadheader machine in a case study by two intelligent methods, namely firefly algorithm (FA) and the Teaching-learning based optimization algorithm (TLBO). In these models, the Schmidt hammer rebound and the rock quality degree (RQD) values are used as input parameters and the cutting rate of the roadheader is used as the output parameter. Finally, to evaluate the accuracy of the models and modeling, the indices of square correlation coefficient (R^2), variance account for (VAF), root mean square error (RMSE) and mean square error (MSE) have been used. The results indicate that the two models have strong potentials to estimate roadheader performance with high degrees of accuracy and robustness.

Introduction

Roadheader is a mechanized excavation equipment used for excavating purposes in underground mining applications and civil tunnels. Based on its capabilities to cut virtually any tunnel profile, roadheaders have been steadily endorsed by civil construction contractors looking for ways to improve productivity and reduce costs. Estimation of the excavation performance of roadheader for any geological formation is one of the main concerns in determination of the economic aspects of a mechanized mining and/or tunneling operation. The performance analysis of roadheader machines plays an important role in the cost and time of underground completion, therefore, correct estimation of the roadheader performance has a key impact on the effective planning of the excavation projects. The estimation of roadheader performance is a highly complex task. Nevertheless, several researches have been conducted to find a significant relationship between the roadheader performance and other parameters influencing it. Researchers have also focused on the development of performance estimation models of roadheader machines.

Methodology and Approaches

The purpose of this paper is to propose intelligent forecasting models for estimation of the performance of roadheader machine in a case study using the FA and TLBO intelligent methods. In these two models, the values of Schmidt hammer rebound and RQD are used as input parameters and the cutting rate of the roadheader is used as the output parameter.

Results and Conclusions

Although previous efforts for development of empirical models in the investigated subject are valuable, the empirical models are not capable of distinguishing the sophisticated structures involved in a dataset. For this purpose, an attempt has been made to use modern methods such as soft computing methods, which can successfully model the linear and nonlinear behavior in the data. In this paper, the application of two intelligent methods for data analysis to estimate roadheader performance has been demonstrated. In these methods, the values of Schmidt hammer rebound and RQD have been used as the input parameters, and net cutting rates have been considered as the output parameter. In order to accurately estimate the shear strength of unsaturated soils and the performance of roadheader machines, the FA and TLBO intelligent methods have been applied. Finally, RMSE, VAF, MSE and R2 have been used to evaluate the accuracy of the prediction models. The modeling results show that the use of the above-mentioned two intelligent algorithms yields to acceptable accuracy and efficiency in estimation of the performance of roadheader machines in tunnel excavations.
