

ارتقاء بازدهی پروژه حفاری: پیش‌بینی و ارزیابی عملکرد ماشین رودهدر مبتنی بر هوش مصنوعی

مقاله پژوهشی

هادی فتاحی^{۱*}؛ فاطمه جیریایی^۲

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

۲- دانشجو؛ دانشکده‌ی مهندسی علوم زمین، دانشگاه صنعتی اراک، Iron.azar2@gmail.com

دریافت دست‌نوشته: ۱۴۰۲/۰۱/۲۸؛ پذیرش دست‌نوشته: ۱۴۰۳/۰۵/۰۸

شماره صفحات: ۳۱۹ تا ۳۳۰

شناسه دیجیتال (DOI): 10.22044/tuse.2024.12970.1476

چکیده

رودهدر به عنوان یک حفار مکانیکی فضاهای زیرزمینی، اهمیت بالایی در پروژه‌های عمرانی و معدنی دارد و بررسی اقتصادی یک پروژه حفاری به شدت وابسته به پیش‌بینی عملکرد رودهدر است. نرخ خالص حفاری رودهدر یک معیار مهم در ارزیابی عملکرد آن به حساب می‌آید که از طریق روش‌های مختلفی می‌توان به تخمین آن پرداخت. در این تحقیق با استفاده از روش‌های هوش مصنوعی ماشین بردار پشتیبان (SVM)، شبکه عصبی مصنوعی (ANN)، نزدیک‌ترین همسایگی (KNN)، جنگل تصادفی (RF) و رگرسیون خطی (LR)، مدل‌هایی به منظور پیش‌بینی عملکرد رودهدر ایجاد شد و دقت و مطلوبیت آن‌ها با هم مقایسه شد. متغیرهای ورودی در این مدل‌ها، شاخص کیفی سنگ (RQD) و مقادیر بازگشت چکش اشمیت R_1 ، R_2 و R_3 می‌باشند و مدل‌سازی‌ها در نرم‌افزار داده کاوی Orange انجام شده است. نتایج مدل‌سازی‌ها نشان می‌دهد که مدل ماشین بردار پشتیبان با $R^2=0.847$ و $RMSE=0.1120$ از عملکرد قابل قبولی برای پیش‌بینی نرخ حفاری یا به عبارتی پیش‌بینی عملکرد ماشین رودهدر در حفاری تونل برخوردار است.

واژگان کلیدی

نرخ خالص حفاری
عملکرد ماشین رودهدر
روش‌های هوش مصنوعی
نرم افزار داده کاوی Orange

۱- مقدمه

اشاره کرد. ماشین رودهدر نسبت به روش‌های سنتی و دستگاه‌های دیگر دارای مزایایی است نظیر: هزینه‌ی اولیه و سرمایه‌گذاری پایین، بالابودن سطح ایمنی کار با آن، نداشتن اثرات مخرب لرزش انفجار، اغتشاشات، تخریب و کاهش نیاز به تهویه (در مقایسه با روش چالزنی-انفجار)، انعطاف‌پذیری بالای حفاری، توانایی حفر مقاطع با پروفیل‌های مختلف و در نهایت داشتن سرعت بالای نرخ حفاری. همچنین ماشین

امروزه حفاری مکانیزه فضاهای زیرزمینی و تونل‌ها در پروژه‌های عمرانی و معدنی، به دلیل ارتقاء بهره‌وری و اثربخشی از اهمیت بالایی برخوردار است. در این زمینه دستگاه‌های مختلفی برای حفر مکانیزه فضاهای زیرزمینی و تونل‌ها در اختیار است که از آن جمله می‌توان به چکش ضربه‌ای، (TBM) Tunnel Boring Machine و رودهدرها

* استان مرکزی؛ اراک؛ خیابان دانشگاه؛ دانشگاه صنعتی اراک؛ ساختمان شهید زین الدین؛ دانشکده مهندسی علوم زمین؛ گروه مهندسی ژئومکانیک؛ کدپستی: ۳۸۴۸۱۷۷۵۸۴؛ شماره‌ی تلفن: ۰۸۶-۳۳۴۰۰۷۹۳

محوره (*UCS: Uniaxial Compressive Strength*) و شاخص کیفی سنگ (*RQD: Rock Quality Designation*) به عنوان ورودی مدل‌ها در نظر گرفته شده است (*Avunduk, et al., 2014*). ابراهیم‌آبادی و همکاران (۲۰۱۵) تحقیقی انجام دادند که در آن روش شبکه عصبی مصنوعی را به کار گرفتند و عملکرد حفاری با رودهدر را با این روش پیش‌بینی کردند (*Ebrahimabadi, et al., 2015*). فتاحی (۲۰۱۷) به ارزیابی سیستم استنتاج تطبیقی فازی-عصبی و همچنین روش ترکیبی شبکه عصبی مصنوعی با الگوریتم‌های ازدحام ذرات و ژنتیک در تخمین عملکرد رودهدر پرداخت (*Fattahi, 2017*). قاسمی (۲۰۱۷) یک مدل جدید برای پیش‌بینی عملکرد رودهدر ارائه داد و در آن از تحلیل رگرسیون چندمتغیره غیر خطی بهره برد. در این مقاله پایگاه داده‌ای شامل نمونه‌های حفاری یک معدن ذغال سنگ در ایران به کار گرفته شده است (*Ghasemi, 2017*). در تحقیقی دیگر فریدونبه و همکاران (۲۰۱۷) با کمک روش‌های (*GP (Genetic Programing)*) و (*GEP (Gene Expression Programing)*) به پیش‌بینی عملکرد رودهدر پرداختند و در آن از پایگاه داده‌های مربوط به عملکرد دستگاه و برخی از پارامترهای ژئومکانیکی سازند سنگ در پروژه‌های معدن ذغال سنگ طبرس استفاده کردند (*Faradonbeh et al., 2017*). سکر و اوکاک (۲۰۱۹) تعدادی از روش‌های یادگیری ماشین نظیر جنگل تصادفی، *GP*، رگرسیون خطی، رگرسیون لجستیک و روش (*MLP (Multi-Layer Perceptron)*) را برای پیش‌بینی عملکرد رودهدر به کار بستند (*Seker & Ocak, 2019*). جوناک و همکاران (۲۰۲۰)، برای پیش‌بینی بار روی ابزار برش ماشین حفاری *TBM* از روش شبکه عصبی پرسپترون با ساختار چندلایه استفاده کردند. آن‌ها معتقدند بار وارده در انتخاب توان ماشین حفاری و کنترل فرآیند استخراج مؤثر بوده و به کمک این پیش‌بینی می‌توان برای طراحی و نگهداری ابزار برش و زمان تعویض آن‌ها برنامه‌ریزی کرد (*Jonak, et al., 2020*). گائو و همکاران (۲۰۲۱) برای ارزیابی عملکرد *TBM* یک مدل پیش‌بینی نرخ نفوذ، مبتنی بر شبکه عصبی (*LSTM (long Short-Term Memory)*) ایجاد کردند. برای تأیید عملکرد مدل پیشنهادی، پارامترهای ماشین، پارامترهای توده سنگ و داده‌های بررسی

رودهدر قابلیت حفاری سنگ با مقاومت پایین تا متوسط را دارد، بخصوص برای معادنی که استخراج انتخابی دارند گزینه بسیار مناسبی است (*Salsani, et al., 2014*). بطور کلی در ارتقاء سطح عملکرد انواع حفاری، پارامترهای مختلفی دخیل هستند که عبارتند از: نوع حفاری، خصوصیات توده سنگ، ابزار حفاری، پارامترهای ماشین، اندازه و شکل دانه‌ها، مؤلفه‌های عملیاتی، هندسه‌ی حفاری و مهارت‌های اپراتور (*Iphar, 2012*).

پیش‌بینی عملکرد رودهدر و تخمین معیارهای مختلف آن مانند نرخ حفاری آنی (*ICR: Instantaneous Cutting Rate*) و نرخ حفاری عملیاتی (*OCR: Operational Cutting Rate*)، به دلیل تأثیری که بر زمان انجام پروژه، برآورد هزینه‌ی آن و برنامه‌ریزی‌ها دارد اهمیت ویژه‌ای دارد و از طریق روش‌های مختلف محاسبه می‌شود (*Abdolreza & Siamak, 2013*). مدل‌های تجربی تا حدودی این پیش‌بینی‌ها را انجام می‌دهند اما قادر به شناسایی و درک ساختار و روابط پیچیده در مجموعه داده‌ها نیستند. روش‌های هوش محاسباتی به علت قابلیت بالایی که در مدل‌سازی داده‌ها و تعریف روابط بین آن‌ها داشته‌اند، می‌توانند جایگزین مدل‌های تجربی شوند و با سرعت و دقت بالایی متغیر هدف را تخمین زده و پیش‌بینی کنند. امروزه محققین در پی تلاش برای اثبات توانایی روش‌های هوش محاسباتی در پیش‌بینی و ساخت مدل‌های کارآمد هستند که به برخی از مهمترین مطالعاتی که در این زمینه انجام شده اشاره خواهد شد. سلسانی و همکاران (۲۰۱۴) برای پیش‌بینی عملکرد رودهدر به مقایسه‌ی دو مدل شبکه عصبی مصنوعی (*ANN: Artificial Neural Network*) و رگرسیون چند متغیره پرداختند. آن‌ها نشان دادند مدل شبکه عصبی مصنوعی از دقت بالاتری در پیش‌بینی عملکرد رودهدر برخوردار است. همچنین تحلیل حساسیتی انجام دادند و متغیر مقاومت فشاری محدود نشده را به عنوان مؤثرترین متغیر معرفی کردند (*Salsani, et al., 2014*). آوندوک و همکاران (۲۰۱۴) یک بار به روش تجربی و بار دیگر با استفاده از روش شبکه عصبی مصنوعی، نرخ حفاری آنی را پیش‌بینی کردند و ثابت کردن مدل شبکه عصبی مصنوعی با دقت بسیار بالاتری پیش‌بینی را انجام می‌دهد. در این پژوهش متغیرهای مقاومت فشاری تک

که بردارهای ورودی به یک فضای چند بعدی انتقال داده می‌شوند، سپس ابر صفحه‌ای ایجاد می‌شود که بردارهای ورودی را با بیشترین فاصله از هم جدا کند. در فضای با ابعاد زیاد، برای رفع مشکل انجام عملیات از یک تابع کرنل استفاده می‌شود و مشکل چند بعدی و غیر خطی بودن حل می‌شود (Fattahi & Babanouri, 2017). هدف این روش تابعی است که یک مسئله کمینه‌سازی را تعریف کند و وزن پارامترها و ارباب تابع را طوری انتخاب کند که بهترین انطباق را بر داده‌ها داشته باشد. به طور کلی تابع به صورت رابطه‌ی ۱ تعریف می‌شود (Yu & Kim, 2012).

$$f(x, w) = w^T x + b \quad (1)$$

که در آن x متغیر ورودی با n بعد، بردار w وزن پارامترها، b ارباب تابع و $f(x, w)$ مقدار نظیر متغیر هدف است. برای محاسبه‌ی w و b تابع بهینه‌سازی در رابطه‌ی ۲ تعریف می‌شود.

$$R(C) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^L L_{\varepsilon}(y_i \cdot f_i(x, w)) \quad (2)$$

که در آن C پارامتری ثابت برای ایجاد تعادل و L_{ε} تابع وپنیک است (Vapnik, 2013).

۲-۲- شبکه عصبی مصنوعی (ANN)

روش شبکه عصبی مصنوعی شامل پردازشگرهایی به نام نرون است و با الگوبری از نرون‌های مغز انسان تلاش می‌کند تا با شناخت روابط ذاتی بین داده‌ها، رابطه‌ی بین داده‌های ورودی و خروجی ایجاد کند (Fattahi & Bazdar, 2017). این عملیات از لایه‌های مختلفی تشکیل می‌شود. لایه‌ها یا لایه‌های مخفی اطلاعات دریافت شده از لایه‌ی ورودی را پردازش کرده و در اختیار لایه‌ی خروجی قرار می‌دهد. شبکه با دریافت داده‌های آموزشی وارد مرحله‌ی یادگیری می‌شود و زمانی به پایان می‌رسد که وزن‌های ارتباطی بین لایه‌ها طوری انتخاب شود که اختلاف بین مقدار پیش‌بینی شده و مقدار واقعی در حد قابل قبول باشد. این شبکه آماده به‌کارگیری برای شبیه‌سازی خروجی‌های متناسب با مجموعه‌ی جدید داده‌ها است (Mashrei, 2012).

زمین‌شناسی از تونل انتقال آب یک مطالعه‌ی موردی برای تشکیل یک مجموعه داده جمع‌آوری شده است (Gao, et al., 2021). از آنجا که رودهدر نوع بازویی، نمی‌تواند نوسانات سرعت حفاری را با تغییرات سختی سنگ و ذغال سنگ منطبق کند، لی و همکاران (۲۰۲۲)، یک استراتژی کنترلی برای نوسانات سرعت حفاری پیشنهاد دادند. در این استراتژی از شبکه‌ی عصبی PSO-BP (Particle Swarm Optimization-Back Propagation) برای ساخت شناساگر بار حفاری بمنظور تنظیم نوسانات سرعت حفاری رودهدر استفاده کردند (Li, et al., 2022).

هدف از این تحقیق ساخت مدل‌های هوشمند برای پیش‌بینی عملکرد رودهدر در نرم‌افزار قدرتمند داده‌کاوی Orange برای برآوردن این هدف است. در مدل‌سازی‌ها از روش‌های ماشین بردار پشتیبان (SVM: Support Vector Machine)، شبکه عصبی مصنوعی (ANN)، نزدیک‌ترین همسایگی (KNN: K-fold Nearest Neighbor) جنگل تصادفی (RF: Random Forest) و رگرسیون خطی (LR: Linear Regression) استفاده شده و عملکرد آن‌ها با هم مقایسه شده است. مجموعه داده‌های به‌کار گرفته شده مربوط به داده‌های جمع‌آوری شده در حین ساخت تونل سیستم فاضلاب شهر استانبول است و شامل چهار متغیر ورودی شاخص کیفی سنگ و مقادیر بازگشت چکش اشمیت R_1 ، R_2 و R_3 و متغیر خروجی نرخ خالص حفاری (Q) ماشین رودهدر می‌باشد.

۲- روش‌های هوش مصنوعی بکار گرفته شده

۲-۱- ماشین بردار پشتیبان (SVM)

یکی از قوی‌ترین الگوریتم‌های یادگیری ماشین، بی‌شک روش ماشین بردار پشتیبان است که در دو حوزه‌ی طبقه‌بندی و رگرسیون از آن استفاده می‌شود. این روش براساس تئوری آموزش آماری و از نوع نظارت شده استوار است (Fattahi & Babanouri, 2017) نوع روش رگرسیون بردار پشتیبان که برای تخمین یک تابع، به منظور نگاشت یک عدد به داده‌های ورودی، مورد استفاده قرار می‌گیرد، بین داده‌های ورودی و مقدار متغیر هدف با کمینه سازی ریسک ساختاری ارتباط برقرار می‌کند. به این ترتیب

طور تصادفی ساخته می‌شود و در آن روش کیسه‌گذاری به‌کار گرفته می‌شود. جنگل تصادفی چندین درخت تصمیم می‌سازد و آن‌ها را با هم ادغام می‌کند تا پیش‌بینی‌های صحیح‌تر و پایدارتری به دست آیند. سپس از نتایج حاصل از تمام درخت‌های تصمیم میانگین‌گیری می‌شود. در این روش از دو عامل میانگین‌کاهشی دقت و میانگین‌کاهشی جینی برای تعیین اهمیت و تأثیرگذاری هر یک از متغیرها استفاده می‌شود (Nicodemus, 2011).

۳- معرفی نرم‌افزار داده‌کاوی Orange

نرم‌افزار Orange یک ابزار بسیار قوی در علم داده‌کاوی و از نوع منبع باز است که برای اهداف طبقه‌بندی، رگرسیون و انواع تجزیه و تحلیل آماری داده‌ها و ساخت مدل مورد استفاده قرار می‌گیرد. انجام هرگونه عملیات در این نرم‌افزار به صورت بصری بوده و کاملاً قابل فهم است و می‌توان با کمک این ابزار قدرتمند، انواع تحلیل‌های هوشمند را با سرعت بالا انجام داد. نرم‌افزار Orange قابلیت تحلیل چندین مجموعه داده به طور هم‌زمان در یک صفحه کار را دارا می‌باشد و این امر کار مقایسه را برای کاربر آسان می‌کند. بعلاوه این نرم‌افزار دارای یک سایت پشتیبانی قوی (www.orangedatamining.com) می‌باشد که درمورد تمام گزینه‌ها و روش‌ها موجود در آن اطلاعات مفیدی را در اختیار کاربر می‌گذارد.

۴- مطالعه‌ی موردی

عملکرد رودهدر، تخمین نرخ حفاری یا تولید این دستگاه در واحد زمان است و توسط واحدهای (m^3/hr) و (ft^3/hr) بیان می‌شود. نرخ حفاری معمولاً به دو شکل OCR و ICR تعریف می‌شود. در صورتی که زمان‌های توقف حین عملیات حفاری در محاسبه‌ی نرخ حفاری دخالت داده نشود، به آن نرخ حفاری آنی یا ICR می‌گویند. اما در صورتی که همان زمان‌های تأخیر و افت کار نیز در محاسبه‌ی نرخ حفاری در نظر گرفته شود به آن نرخ حفاری عملیاتی گفته می‌شود. تاکنون روابطی برای تخمین نرخ حفاری آنی رودهدر ارائه شده است. بیلگین و همکاران (۱۹۸۸) رابطه‌ای براساس مقاومت فشاری سنگ و شاخص کیفی سنگ معرفی کردند که در رابطه‌ی ۵ بیان شده است (Bilgin, et al., 1997).

۲-۳- نزدیک‌ترین همسایگی (KNN)

این روش نیز برای دو هدف طبقه‌بندی و رگرسیون مورد استفاده قرار می‌گیرد. KNN تخمین متغیر مجهول را براساس بیشترین شباهت داده‌ها با داده‌های معلوم که در نزدیکی آن‌ها قرار دارند انجام می‌دهد. این مدل ابتدا در پی یافتن روش و رابطه‌ای برای محاسبه‌ی فاصله‌ی بین داده‌های مورد آزمایش و داده‌های تعلیم است و معمولاً برای تعیین این فاصله طبق رابطه‌ی ۳ از فاصله‌ی اقلیدسی استفاده می‌شود.

$$d(X, Y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (3)$$

که در آن x داده‌های تعلیم و y داده‌های مورد آزمایش با تعداد پارامتر مشخص است. پس از آن داده‌های تعلیم براساس فاصله‌ی آن‌ها به صورت صعودی مرتب شده و از نظر تشابه به داده‌ی مورد نظر ارزش‌گذاری می‌شوند. به تعداد K مورد از داده‌ها انتخاب شده و در تخمین متغیر هدف از آن‌ها استفاده می‌شود. بنابراین تعیین تعداد همسایه‌ها (K) یکی از مؤثرترین مراحل این روش است که با سعی و خطا انجام می‌شود (Wu & Kumar, 2009).

۲-۴- رگرسیون خطی (LR)

رگرسیون خطی چند متغیره همانند سایر روش‌ها به دنبال یافتن ارتباطی بین متغیرهای مستقل و متغیر وابسته است. ارتباط خطی بین متغیرهای x_1, x_2, \dots, x_n و متغیر y به صورت رابطه‌ی ۴ تعریف می‌شود.


$$y = a_0 + a_1x_1 + a_2x_2 + \dots + a_nx_n + e \quad (4)$$

که در آن ضرایب رگرسیون a_1, a_2, \dots, a_n و e خطا است. مهم انتخاب ضریب مناسب برای به حداقل رساندن اختلاف مقدار واقعی و پیش‌بینی شده است که از طریق روش‌های مختلف صورت می‌گیرد. مانند روش‌های احتمالی، کمترین مربعات، گرادیان کاهشی تصادفی و کمترین قدرمطلق‌ها (Weisberg, 2005).

۲-۵- جنگل تصادفی (RF)

جنگل تصادفی نوعی الگوریتم یادگیری ماشین و از نوع نظارت شده است و برای دسته‌بندی و رگرسیون از آن استفاده می‌شود. در این روش گروه‌هایی از درخت تصمیم به

همان سطح است. بنابراین هرچه سطح، سخت‌تر باشد، فاصله‌ی برگشت نیز بیشتر است. این چکش‌ها در سطوح مختلفی از انرژی ضربه‌ای طراحی می‌شوند که نوع N و L بیشتر برای آزمایش سنگ و بتن استفاده می‌شود و نوع N دارای انرژی ضربه‌ای ۳ برابر بیشتر از نوع L است (Goktan & Gunes, 2005). تاکنون روش‌های مختلفی برای ثبت مقادیر سختی از مقادیر بازگشت چکش اشمیت ارائه شده است. این روش‌ها براساس دو رویکرد تک ضربه‌ای و ضربات مداوم بر یک نقطه است. در روش اول (R_1) در هر نقطه ۱۵ تا ۲۰ ضربه‌ی مداوم ایجاد می‌شود. سپس اعداد بازگشتی که مقادیر بسیار پایینی دارند با استفاده از معیار Chauvenet مشخص شده و در محاسبه‌ی مقدار میانگین، از محاسبات حذف می‌شوند. در روش دوم (R_2) از ۵ ضربه‌ی مداوم در یک نقطه، عدد حداکثر بازگشت انتخاب شده و سایر مقادیر حذف می‌شوند. در روش سوم (R_3) نیز از ۱۰ ضربه‌ی مداوم در یک نقطه، عدد حداکثر بازگشت انتخاب شده و مابقی مقادیر حذف می‌شوند که در این مقاله از هر سه مقدار R_1 ، R_2 و R_3 بعنوان ورودی مدل‌ها استفاده شده است (شکل ۱).



شکل ۱- نمایشی از چکش اشمیت و مقادیر R_1 ، R_2 و R_3

آزمایشات با چکش اشمیت نوع Proceq N انجام شده است. در هر تشکیلات سنگی ۳ مقدار R_1 ، R_2 و R_3 اندازه گیری می‌شود. گکتان و گنس (۲۰۰۵) توسط همین داده‌ها یک روش آزمون جدید برای چکش اشمیت ارائه دادند که براساس روش ضربات مداوم، سه مقدار بازگشت چکش اشمیت را محاسبه کردند. آن‌ها نشان دادند این مقادیر، سختی کلی سنگ را بهتر نمایش می‌دهند و در پیش‌بینی عملکرد رودهدر مؤثر هستند. جدول ۱، مشخصات آماری متغیرهای ورودی و خروجی را نشان می‌دهد. همچنین در

$$ICR = 0.28 \times P \times (0.974)^{RMCI} \quad (5)$$

$$RMCI = \sigma_c \times (RQD/100)^{2/3}$$

که در آن ICR نرخ حفاری آبی سنگ (m^3/hr)، P توان کله حفار (اسب بخار)، $RMCI$ شاخص قابلیت حفاری توده سنگ، σ_c مقاومت فشاری تک محوره (MPa) و شاخص کیفی توده سنگ (%) است. همچنین یکی دیگر از روش‌های رایج برای پیش‌بینی میزان نرخ حفاری در ماشین‌های حفاری، استفاده از توان حفاری، انرژی ویژه به دست آمده از آزمون‌های حفاری در مقیاس واقعی و نسبت انتقال انرژی از کله حفار به سنگ طبق رابطه‌ی ۶ است (Rostami, et al., 1995).

$$ICR = k \frac{P}{SE_{opt}} \quad (6)$$

که در آن P توان حفاری دستگاه (kW)، SE_{opt} انرژی ویژه مطلوب (KWh/m^3) و k ضریب انتقال انرژی متناسب با حفار مکانیکی مورد استفاده است.

با این وجود در این تحقیق از روش‌های هوش مصنوعی برای تخمین نرخ حفاری استفاده شده است. مجموعه داده‌هایی که برای آموزش و آزمون مدل‌ها به کارگرفته شده، مربوط به داده‌های میدانی حاصل از عملیات با رودهدر تونل سیستم فاضلاب شهر استانبول می‌باشد (Shahriar, 1988). این پایگاه داده شامل ۳۵ نمونه در تشکیلات سنگی مختلف از متغیرهای RQD و مقادیر بازگشت چکش اشمیت R_1 ، R_2 و R_3 به عنوان متغیرهای ورودی و نرخ خالص حفاری رودهدر (Q) به عنوان متغیر خروجی می‌باشد.

ارزیابی مقاومت مکانیکی سنگ یکی از مؤلفه‌های مهم در زمینه‌ی حفاری سنگ و پیش‌بینی عملکرد حفارها می‌باشد. از آنجا که آزمون مستقیم مقاومت فشاری تک محوره زمان‌بر و هزینه‌بر بوده و نیاز به آماده‌سازی بیشتری دارد، اغلب از آزمون‌های غیر مستقیم و سازگار با آزمایش میدانی مانند آزمون چکش اشمیت استفاده می‌شود. این ابزار قابل حمل، عدد بازگشت سطح مورد بررسی را اندازه‌گیری می‌کند، براین اساس که برگشت یک جرم الاستیک که بر سطح مورد آزمایش ضربه‌ای وارد می‌کند، تابعی از سختی

شکل ۲- نمودار فراوانی ایجاد شده برای متغیرهای ورودی و خروجی در نرم‌افزار Orange

ستون نمودارهای فراوانی با یک طیف رنگی همراه است که براساس Q متناظر داده‌ها ایجاد شده است. به این صورت که برای متغیر شاخص کیفی سنگ، مقادیر بالای آن در سمت راست نمودار با مقادیر پایین Q ، نظیر یکدیگر و هم‌رنگ هستند. درمورد سایر متغیرها نیز این قضیه صادق است. می‌توان گفت با افزایش مقدار متغیرهای ورودی مقدار متغیر هدف کاهش می‌یابد. در ادامه مدل‌های ماشین بردار پشتیبان، شبکه عصبی مصنوعی، نزدیک‌ترین همسایگی، جنگل تصادفی و رگرسیون خطی ایجاد شده و توسط شاخص‌های آماری مختلف همچون MAE ، $RMSE$ ، MSE و R^2 ارزیابی می‌شوند.

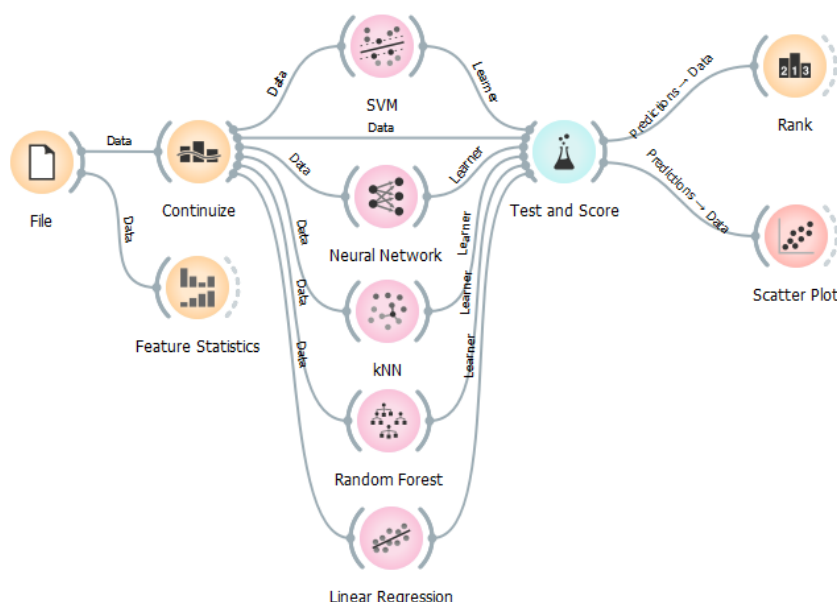

شکل ۲، نمودار فراوانی به دست آمده از نرم‌افزار نمایش داده شده است.

جدول ۱- مشخصات آماری متغیرهای ورودی و خروجی مدل‌ها

| پارامترها | حداقل | حداکثر | میانگین |
|--------------------------|-------|--------|---------|
| شاخص کیفیت سنگ (RQD) | ۰ | ۱۰۰ | ۵۳/۹۴ |
| عدد بازگشت ۱ (R_1) | ۲۹ | ۶۳ | ۴۹/۷۸ |
| عدد بازگشت ۲ (R_2) | ۳۰ | ۶۱ | ۴۷/۶۷ |
| عدد بازگشت ۳ (R_3) | ۳۲ | ۶۴ | ۵۱/۷۵ |
| نرخ خالص حفاری (Q) | ۲ | ۲۵ | ۱۱/۳۹ |

۵- تحلیل و نتایج

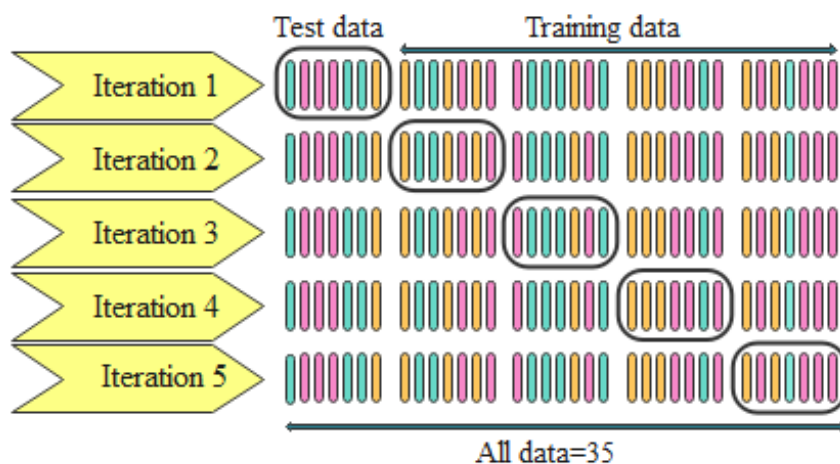
در شکل ۳، نمای ایجاد شده در نرم‌افزار Orange پس از مدل‌سازی نشان داده شده است. روند مدل‌سازی از سمت چپ صفحه شروع شده و به ترتیب مراحل مدل‌سازی را طی می‌کند. این مراحل شامل فراخوانی فایل داده‌ها، عملیات پیش‌پردازش داده‌ها، ساخت مدل‌ها، مطالعه‌ی شاخص‌های ارزیابی آن‌ها و سایر بررسی‌های آماری می‌باشد.



شکل ۳- نمایی از روند انجام مدل‌سازی در نرم‌افزار Orange

اعتبارسنجی یا آزمایش). برای کاهش پراکندگی، عمل اعتبارسنجی چندین بار با افزایش‌های مختلف انجام و از نتایج اعتبارسنجی‌ها میانگین گرفته می‌شود. در اعتبارسنجی متقابل K لایه، داده‌ها به K زیرمجموعه افزایش می‌شوند (Fattahi & Shirinzade, 2022). از این K زیرمجموعه، هر بار یکی برای اعتبارسنجی و $K-1$ تای دیگر برای آموزش بکار می‌روند. این روال K بار تکرار می‌شود و همه داده‌ها دقیقاً یک بار برای آموزش و یک بار برای اعتبارسنجی بکار می‌روند. در نهایت میانگین نتیجه این K بار اعتبارسنجی به‌عنوان یک تخمین نهایی برگزیده می‌شود. در این مقاله داده‌ها به تعداد گروه‌های مشخص ($K=5$) تقسیم شدند. طریقه‌ی انتخاب داده‌ها در روش اعتبارسنجی متقابل در شکل ۴، نمایش داده شده است.

انتخاب داده‌ها به عنوان داده‌های آموزش و آزمون شامل روش‌های متنوعی است. در این تحقیق با توجه به تعداد کم داده‌ها از روش اعتبارسنجی متقابل استفاده شده است (شکل ۴). اعتبارسنجی متقابل، یک روش ارزیابی مدل‌ها است که تعیین می‌نماید نتایج یک تحلیل آماری بر روی یک مجموعه داده تا چه اندازه قابل تعمیم و مستقل از داده‌های آموزشی است. این روش به‌طور ویژه در کاربردهای پیش‌بینی، مورد استفاده قرار می‌گیرد تا مشخص شود مدل موردنظر تا چه اندازه در عمل مفید خواهد بود. به‌طور کلی یک دور از اعتبارسنجی ضربدری شامل افزایش داده‌ها به دو زیرمجموعه مکمل، انجام تحلیل بر روی یکی از آن زیرمجموعه‌ها (داده‌های آموزشی) و اعتبارسنجی تحلیل با استفاده از داده‌های مجموعه دیگر است (داده‌های



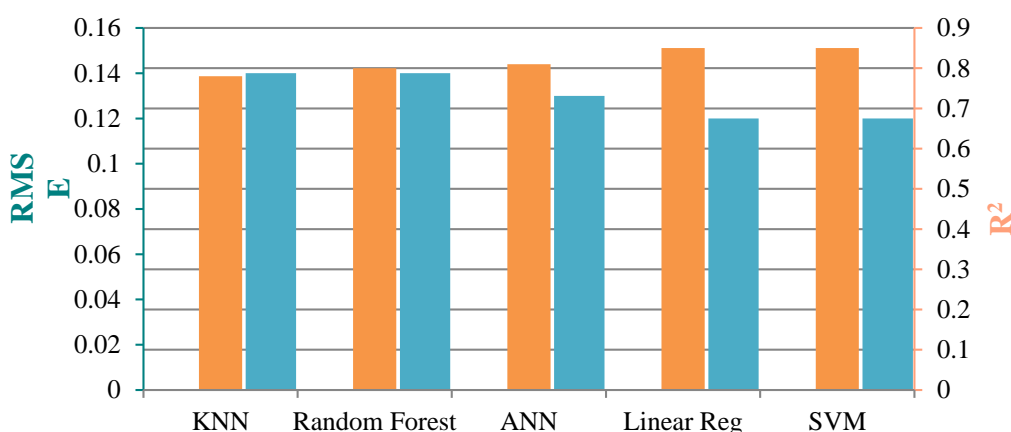
شکل ۴- نمودار روش اعتبارسنجی متقابل با افزایش داده‌ها به $K=5$ مجموع

بنابراین مقدار R^2 هرچه به یک، و خطای $RMSE$ هرچه به صفر نزدیک‌تر مدل از توانایی بالاتری برای پیش‌بینی برخوردار است. در شکل ۵، مدل ماشین بردار پشتیبان دارای R^2 بالاتر و $RMSE$ پایین‌تری نسبت به سایر مدل‌ها هستند و روش نزدیک‌ترین همسایگی نیز با R^2 پایین‌تر و بالاتر نسبت به مدل‌ها، عملکرد ضعیف‌تری دارد.

جدول ۲، مقدار شاخص‌های ارزیابی را برای مدل‌های مختلف نشان می‌دهد. همچنین در شکل ۵، R^2 و $RMSE$ به صورت نمودار ستونی نشان داده شده است. شاخص R^2 با ضریب تعیین تعدیل یافته که از توان دوم همبستگی مقادیر واقعی و پیش‌بینی شده به دست می‌آید، دقت مدل در تخمین متغیر را مشخص می‌کند. سایر شاخص‌های ذکر شده نیز به نوعی خطا در مقدار تخمینی را تعریف می‌کنند.

جدول ۲- مقدار شاخص‌های ارزیابی برای مدل‌های ایجاد شده برای تخمین نرخ خالص حفاری (Q)

| مدل | MSE | RMSE | MAE | R ² |
|---------------------|-------|-------|-------|----------------|
| ماشین بردار پشتیبان | ۰/۰۱۴ | ۰/۱۲۰ | ۰/۰۸۲ | ۰/۸۴۷ |
| رگرسیون خطی | ۰/۰۱۶ | ۰/۱۲۹ | ۰/۰۸۷ | ۰/۸۴۵ |
| شبکه عصبی مصنوعی | ۰/۰۱۷ | ۰/۱۳۲ | ۰/۰۹۷ | ۰/۸۱۳ |
| جنگل تصادفی | ۰/۰۱۹ | ۰/۱۳۷ | ۰/۰۹۷ | ۰/۷۹۹ |
| نزدیک‌ترین همسایگی | ۰/۰۲ | ۰/۱۴۲ | ۰/۱۰۲ | ۰/۷۸۵ |




شکل ۵- نمودار ستونی شاخص‌های ارزیابی R^2 و $RMSE$ برای مدل‌های مختلف

چراکه مقدار شاخص R برای خط برازش شده بر روی نقاط، همبستگی بالایی را بین شاخص کیفی سنگ و Q نشان می‌دهد. این شاخص در مورد متغیر R_1 دارای مقدار پایین‌تری است.


| | # | Univar. reg. | RReliefF |
|------------------|---|--------------|----------|
| N RQD (%) | | 174.864 | 0.516 |
| N R1 | | 90.190 | 0.421 |
| N R2 | | 71.215 | 0.420 |
| N R3 | | 64.226 | 0.368 |

شکل ۶- رتبه‌بندی و اهمیت متغیرهای ورودی در نرم‌افزار Orange

بعلاوه در بحث آنالیز حساسیت، متغیرهای ورودی مختلف به یک اندازه بر روی تخمین متغیر خروجی تأثیرگذار نیستند، بلکه هر یک سهم متفاوتی در عملیات پیش‌بینی دارد. یکی از راه‌های بررسی چگونگی رفتار متغیرهای مختلف و تصمیم‌گیری در مورد آن‌ها، مطالعه‌ی تأثیرگذاری از طریق شاخص‌های مختلف و یا رسم نمودار پراکندگی دوبه‌دوی آن‌ها است. شکل ۶، نشان دهنده‌ی درجه‌ی اهمیت متغیرهای مختلف است که در آن متغیر شاخص کیفی سنگ مهم‌ترین متغیر و پس از آن R_1 از اهمیت بالایی برخوردار است. متغیر R_3 نیز کمترین اهمیت را دارد. در نمودار پراکندگی شکل ۷ و شکل ۸ نیز می‌توان دریافت شاخص کیفی سنگ دارای اهمیت بالایی است.



شکل ۷- نمودار پراکندگی دو متغیر شاخص کیفی سنگ و نرخ خالص حفاری در نرم‌افزار Orange



شکل ۸- نمودار پراکندگی دو متغیر R_1 و نرخ خالص حفاری در نرم‌افزار Orange

۶- نتیجه‌گیری

تخمین و برآورد عملکرد حفاری رودهدر برای هر سازند زمین‌شناسی یکی از اصلی‌ترین نگرانی‌ها در تعیین جنبه‌های اقتصادی یک عملیات مکانیزه استخراج و یا تونل‌زنی است. تجزیه و تحلیل عملکرد ماشین‌آلات رودهدر نقش مهمی در تخمین هزینه مورد نیاز و زمان تکمیل پروژه‌های زیرزمینی دارند. بنابراین، برآورد صحیح عملکرد رودهدر نقش قابل توجهی در برنامه‌ریزی مؤثر پروژه حفاری دارد. در این

زمینه، مطالعات زیادی برای یافتن رابطه معنی‌داری بین عملکرد رودهدر با سایر پارامترهای مؤثر آن انجام شده است. اگرچه تلاش‌های قبلی ارزشمند هستند، اما این مدل‌های تجربی قادر به تشخیص ساختارهای پیچیده دخیل در مجموعه داده‌ها نیستند. در این تحقیق از روش‌های ماشین بردار پشتیبان، شبکه عصبی مصنوعی، نزدیک‌ترین همسایگی، جنگل تصادفی و رگرسیون خطی مدل‌هایی به‌منظور پیش‌بینی عملکرد رودهدر استفاده و دقت و مطلوبیت آن‌ها با هم مقایسه شد. متغیرهای ورودی در این

نزدیک‌ترین همسایگی ضعیف‌ترین عملکرد را بین مدل‌ها برای تخمین دارد. همچنین برای تعیین متغیر مؤثر بر روند پیش‌بینی، اهمیت متغیرهای مختلف بررسی شد و مشخص شد شاخص کیفی سنگ سهم بالایی در تخمین متغیر هدف دارد و پس از آن R_1 دارای اهمیت بالایی است.

مدل‌ها، شاخص کیفی سنگ و مقادیر بازگشت چکش اشمیت R_1 ، R_2 و R_3 می‌باشند و مدل‌سازی‌ها در نرم‌افزار داده کاوی Orange انجام شد. نتایج نشان داد مدل ماشین بردار پشتیبان از دقت قابل قبولی برخوردار هستند و می‌توانند برای تخمین نرخ خالص حفاری (Q) یا پیش‌بینی عملکرد رودهدر مورد استفاده قرار گیرند. از طرفی مدل

۷- منابع

- Abdolreza, Y.-C., & Siamak, H. Y. (2013). A new model to predict roadheader performance using rock mass properties. *Journal of Coal Science Engineering*, 19(1), 51-56.
- Avunduk, E., Tumaç, D., & Atalay, A. (2014). Prediction of roadheader performance by artificial neural network. *Tunnelling Underground Space Technology*, 44, 3-9.
- Bilgin, N., Kuzu, C., Eskikaya, S., & Özdemir, L. (1997). Cutting performance of jack hammers and roadheaders in Istanbul Metro drivages. *World Tunnel Congress*.
- Ebrahimabadi, A., Azimipour, M., & Bahreini, A. (2015). Prediction of roadheaders' performance using artificial neural network approaches (MLP and KOSFM). *Journal of Rock Mechanics Geotechnical Engineering*, 7(5), 573-583.
- Faradonbeh, R. S., Salimi, A., Monjezi, M., Ebrahimabadi, A., & Moormann, C. (2017). Roadheader performance prediction using genetic programming (GP) and gene expression programming (GEP) techniques. *Environmental earth sciences*, 76(16), 1-12.
- Fattahi, H. (2016). Application of improved support vector regression model for prediction of deformation modulus of a rock mass [journal article]. *Engineering with Computers*, 32(4), 567-580. <https://doi.org/10.1007/s00366-016-0433-6>.
- Fattahi, H. (2017). Application of Soft Computing Methods for the Estimation of Roadheader Performance from Schmidt Hammer Rebound Values. *Analytical and numerical methods in mining engineering*, 6, 11-24.
- 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.
- 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., & Shirinzade, M. A. (2022). Applying different soft computing methods to predict mechanical properties of carbonate rocks based on petrographic and physical properties. *Earth Science Informatics*, 15(1), 351-368. <https://doi.org/10.1007/s12145-021-00736-w>.

- Gao, B., Wang, R., Lin, C., Guo, X., Liu, B., & Zhang, W. (2021). TBM penetration rate prediction based on the long short-term memory neural network. *Underground Space*, 6(6), 718-731.
- Ghasemi, E. (2017). Development of a site-specific regression model for assessment of road-header cutting performance of Tabas coal mine based on rock properties. *Journal of Mining Environment*, 8(4), 663-672.
- 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 mining sciences*, 42(3), 466-472.
- Iphar, M. (2012). ANN and ANFIS performance prediction models for hydraulic impact hammers. *Tunnelling Underground Space Technology*, 27(1), 23-29.
- Jonak, J., Kuric, I., DROŹDZIEL, P., Gajewski, J., & Saga, M. (2020). Prediction of load on the cutting tools in tunnel boring machines. *Acta Montanistica Slovaca*, 25(4).
- Li, F., Li, Y., Yan, C., Ma, C., Liu, C., & Suo, Q. (2022). Swing speed control strategy of fuzzy PID roadheader based on PSO-BP Algorithm. *2022 IEEE 6th Information Technology and Mechatronics Engineering Conference (ITOEC)*.
- Mashrei, M. A. (2012). Neural network and adaptive neuro-fuzzy inference system applied to civil engineering problems. *Fuzzy Inference System-Theory Applications*.
- Nicodemus, K. K. J. B. i. b. (2011). Letter to the editor: On the stability and ranking of predictors from random forest variable importance measures. 12(4), 369-373.
- Rostami, J., Ozdemir, L., & Neil, D. M. (1995). Performance prediction: a key issue in mechanical hard rock mining. *International Journal of Rock Mechanics and Mining Sciences and Geomechanics Abstracts*.
- Salsani, A., Daneshian, J., Shariati, S., Yazdani-Chamzini, A., & Taheri, M. (2014). Predicting roadheader performance by using artificial neural network. *Neural Computing Applications*, 24(7), 1823-1831.
- Seker, S. E., & Ocak, I. (2019). Performance prediction of roadheaders using ensemble machine learning techniques. *Neural Computing Applications*, 31(4), 1103.
- Shahriar, K. (1988). Rock cuttability and geotechnical factors affecting the penetration rates of roadheaders Ph D Thesis, *Istanbul Technical University*.
- Vapnik, V. (2013). The nature of statistical learning theory. *Springer Science & Business Media*.
- Weisberg, S. (2005). Applied linear regression (Vol. 528). *John Wiley & Sons*.
- Wu, X., & Kumar, V. (2009). The top ten algorithms in data mining. *CRC press*.
- Yu, H., & Kim, S. (2012). SVM Tutorial-Classification, Regression and Ranking. *Handbook of Natural computing*, 1, 479-506.

Improvement of drilling project efficiency: AI-based roadheader performance prediction and evaluation

H. Fattahi^{1*}, F. Jiryae²

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

2- MSc. Student; Department of Earth Sciences Engineering, Arak University of Technology, Iron.azar2@gmail.com

Received: 17 Apr 2023; Accepted: 29 Jul 2024

DOI: 10.22044/tuse.2024.12970.1476

Keywords

**Instantaneous (net) cutting rate
Roadheader machine performance
Artificial intelligence methods
Orange data mining software**

Extended Abstract

Summary

The economic assessment of a drilling project heavily relies on forecasting the drilling machine performance. The net cutting rate of a roadheader is a crucial parameter for performance evaluation, and it can be estimated using various methods. In this study, various models were developed to predict roadheader performance and their accuracy and desirability were compared. The models utilized artificial intelligence techniques such as support vector machine (SVM), artificial neural network (ANN), K-fold nearest neighbor (KNN), random forest (RF), and linear regression (LR). The input variables for these models were rock quality designation (RQD) and the return values of the Schmidt hammer R_1 , R_2 , and R_3 . The modeling task was conducted using the Orange data mining software.

Introduction

Mechanized drilling in civil and mining projects is of paramount importance today, as it enhances productivity and efficiency in underground spaces and tunnels. Various devices are employed for mechanized drilling, including impact hammers, tunnel boring machines (TBM), and roadheaders. Roadheader machines offer several advantages over traditional methods and other devices. Accurately, predicting roadheader performance and estimating key criteria like instantaneous cutting rate (ICR) and operational cutting rate (OCR) is vital for project scheduling, cost estimation, and planning. Several methods are employed for these calculations, but empirical models have limitations in understanding the complex data structure and relationships.

Methodology and Approaches

In this study, SVM, ANN, KNN, RF, and LR modeling techniques were used, and their performance was compared. The dataset utilized pertains to data collected during the construction of the Istanbul sewerage system tunnel. It includes four input variables: RQD and the return values of Schmidt hammer R_1 , R_2 , and R_3 , as well as the output variable, the net cutting rate (Q) of the roadheader machine. Modeling was conducted using the Orange software, which provides an intuitive and comprehensible platform for high-speed intelligent analysis.

Results and Conclusions

The results indicated that the SVM model exhibited satisfactory accuracy and could be employed to estimate the net cutting rate (Q) or predict roadheader performance. Conversely, the K-fold nearest neighbor model displayed the weakest performance in estimation. Moreover, to identify the influential variable in the prediction process, the importance of different variables was assessed. It was observed that RQD significantly contributed to the estimation of the target variable, followed by the importance of R_1 .