



Imam Khomeini International University
Vol. 10, No. 2, Summer 2025



نشریه مهندسی منابع معدنی
Journal of Mineral Resources Engineering
(JMRE)

Research Paper

Application of Reinforcement Machine Learning Models in Predicting Penetration Rate of Rotary Blast Holes

Mirzehi Kalateh Kazemi M.¹, Fayyazi A.², Dehghani H.^{3*}

1- M.Sc, Dept. of Mining Engineering, Tarbiat Modares University, Tehran, Iran

2- Ph.D Student, Dept. of Mining Engineering, Tarbiat Modares University, Tehran, Iran

3- Associate Professor, Dept. of Mining Engineering, University of Hamedan, Hamedan, Iran

Received: 02 Jun. 2024

Accepted: 27 Nov. 2024

Abstract: Drilling with the help of a rotary drilling machine is an important tool for exploration and extraction in mines. On the other hand, estimating the costs and efficiency of the rotary drilling machine is a fundamental step in the design of mining and construction projects. Drilling Penetration Rate (PR) is a suitable indicator for estimating the costs and efficiency of rotary drilling rigs. Therefore, achieving the optimal amount of PR in the rotary drilling machine will reduce costs and increase the efficiency of the rotary drilling machine. For this purpose, in this article, one of the enhanced Machine Learning (ML) methods that combines Light Gradient Boosting (LGB) and Random Forest (RF) with Meta-Heuristic algorithms (MH), including Grey Wolf Optimizer (GWO) and Harris hawk (HHO), has been done to estimate PR. In order to validate the developed models, the models were implemented on the collected data sets. The dataset, including 7 independent input variables, was used. The independent input variables are drilling Diameter in inches (D), rotational speed in Revolutions Per Minute (RPM), Weight On Bit (WOB), Uniaxial Compressive Strength (UCS) of rock in megapascals, Tensile (T) strength of rock in terms of megapascals, the Joints Spacing (JS) in the ground in centimeters, and the relative accuracy of the Joints in Degrees (JD). The obtained results show that the RF-GWO method ($R^2 = 0.987$ and $RMSE = 3.059$) is more accurate than LGB-GWO (0.912 and 8.045), LGB-HHO (0.917 and 7.831), and RF-HHO (0.912 and 8.044) in training data. Also, sensitivity analysis studies indicate that RPM and JD parameters have the most and least effect on the PR of the rotary drilling machine, respectively.

Keywords: Penetration rate drilling, Light Gradient Boosting (LGB), Random Forest (RF), Grey Wolf Optimizer (GWO), Harris Hawk Optimization (HHO).

How to cite this article

Mirzehi Kalateh Kazemi, M., Fayyazi, A., and Dehghani, H. (2025). "Application of reinforcement machine learning models in predicting penetration rate of rotary blast holes". Journal of Mineral Resources Engineering, 10(2): 91-115.

DOI: 10.30479/jmre.2025.20456.1696

*Corresponding Author Email: dehghani@hut.ac.ir

COPYRIGHTS



©2025 by the authors. Published by Imam Khomeini International University.

This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0) (<https://creativecommons.org/licenses/by/4.0/>)

INTRODUCTION

Predicting drilling machine efficiency in mining is crucial for optimizing costs and operations, with rate of penetration being a key factor influenced by various variables. Machine learning techniques, including Artificial Neural Networks and others, can enhance penetration rate management, improving drilling performance and reducing costs [1,2]. Darbor et al. assessed rotary drilling machine penetration rates using Non-Linear Multiple Regression and Multi-Layer Perceptron models, finding that the MLP-ANN model outperforms NLMR in accuracy [3]. Additionally, Zhou et al. introduced a new optimization method for geological drilling, utilizing fuzzy C-means clustering and support vector regression to enhance operational efficiency [4].

Numerous studies have aimed to create a unified model for accurately estimating the rate of penetration (PR) in drilling, utilizing both analytical and data-driven techniques, but often lacking generalizability. Sharifinasab et al. introduced a deep learning approach using Generative Adversarial Networks (GANs) to improve PR predictions, while other researchers implemented data mining and optimization algorithms to enhance prediction accuracy further [5,6].

The research aims to enhance Tunnel Boring Machine (TBM) performance predictions by developing six hybrid models utilizing various optimization algorithms, with a focus on improving accuracy and minimizing risks in tunneling projects. The LSTM-GWO model demonstrated superior results in predicting TBM penetration rates, highlighting the importance of input parameters in influencing performance outcomes [7,8].

METHODS

Two machine learning methods, LGB and RF, were enhanced by GWO and HHO algorithms to create four models for estimating the rotary drilling machine's penetration rate, while Astarita et al. demonstrated the effectiveness of a GWO-ML model over a baseline model in a case study in Calabria, Italy [9].

According to what has been said regarding optimization algorithms, Figure 1 illustrates the flowchart of the model.




Figure 1. Flowchart of the model

FINDINGS AND ARGUMENT

To enhance the estimation of PR, the dataset was categorized into two groups: training and testing. The previously mentioned models were executed using Python software to ascertain the most effective model. Ultimately, R^2 and RMSE metrics were utilized to determine the leading model. Following this, the estimation results of each model were analyzed and compared. Additionally, a sensitivity analysis method was applied to identify which parameter had the most significant influence on PR.

Given that the optimization relied on two machine learning algorithms, LGB and RF, each was further

refined using two metaheuristic algorithms, GWO and HHO. The optimization results revealed that the correlation between the measured and estimated values of RF-GWO was significantly stronger than that of the other algorithms. Consequently, the recommended approach for optimizing the prediction of the penetration rate in rotary drilling of explosive boreholes is the RF-GWO model. More information regarding the machine learning algorithms is provided below.

The sensitivity analysis results of the model, illustrated as a bar chart in ascending to descending order in Figure 2, show that the angular velocity of the rotary drilling machine has the greatest impact on PR-DM, while the relative orientation of the fractures has the least. The minimal significance of the relative orientation of fractures allows us to disregard its influence on PR-DM.




Figure 2. Results of PR sensitivity analysis

CONCLUSIONS

Rotary drilling rigs play a vital role in the mining sector, making the efficiency of these machines a key factor in the planning of mining projects. Research indicates that the Performance Ratio (PR) is an effective measure for assessing the efficiency of rotary drilling equipment, and optimizing this ratio is essential for achieving desired outcomes. To estimate PR, advanced machine learning techniques such as LightGBM (LGB) and Random Forest (RF), combined with metaheuristic algorithms like Grey Wolf Optimization (GWO) and Harris Hawks Optimization (HHO), were utilized. The models developed were tested on a dataset that was previously gathered to ensure their reliability. Results revealed that the RF-GWO method yielded the highest accuracy ($R^2 = 0.987$ and $RMSE = 3.059$) compared to LGB-GWO (0.912 and 8.045), LGB-HHO (0.917 and 7.831), and RF-HHO (0.912 and 8.044) methods when evaluated with test data. Furthermore, sensitivity analysis indicated that the parameters Revolutions Per Minute (RPM) and Jack Depth (JD) significantly influence the PR of the rotary drilling machine, with RPM having the greatest effect and JD the least.

REFERENCES

- [1] Mirzeshi-Kalate-Kazemi, M., Nabavi, Z., and Armaghani, D. J. (2024). "A novel hybrid XGBoost methodology in predicting Penetration rate of rotary based on rock-mass and material pPRerties". *Arabian Journal for Science and Engineering*, 49: 5225-5241. DOI: <https://doi.org/10.1007/s13369-023-08360-0>.
- [2] Najjarpour, M., Jalalifar, H., and Norouzi-Apourvari, S. (2022). "Half a century experience in rate of penetration management: Application of machine learning methods and optimization algorithms - A review". *Journal of Petroleum Science and Engineering*, 208: 109575. DOI: <https://doi.org/10.1016/j.petrol.2021.109575>.
- [3] Darbor, M., Faramarzi, L., and Sharifzadeh, M. (2019). "Performance assessment of rotary drilling using non-linear multiple regression analysis and multilayer perceptron neural network". *Bull Eng Geol Environ*, 78: 1501-1513. DOI:

<https://doi.org/10.1007/s10064-017-11923>.

- [4] Zhou, Y., Chen, X., Wu, M., and Cao, W. (2023). "A novel optimization method for geological drilling vertical well". Journal of Information Sciences, 634: 550-563. DOI: <https://doi.org/10.1016/j.ins.2023.03.082>.
- [5] Sharifinasab, M. H., Emami-Niri, M., and Masroor, M. (2023). "Developing GAN-boosted Artificial Neural Networks to model the rate of drilling bit penetration". Journal of Applied Soft Computing, 136: 110067. DOI: <https://doi.org/10.1016/j.asoc.2023.110067>.
- [6] Shaygan, K., and Jamshidi, S. (2023) "Prediction of rate of penetration in directional drilling using data mining techniques". Journal of Geoenergy Science and Engineering, 221: 111293. DOI: <https://doi.org/10.1016/j.petrol.2022.111293>.
- [7] Mirjalili, S. A., Mirjalili, S. M., and Lewis, A. (2014). "Grey Wolf Optimizer". Journal of Advances in Engineering Software, 69: 46-61. DOI: <http://dx.doi.org/10.1016/j.advengsoft.2013.12.007>.
- [8] Mahmoodzadeh, A., Nejati, H. R., Mohammadi, M., Ibrahim, H. H., Rashidi, S., and Rashid, T. A. (2022). "Forecasting tunnel boring machine penetration rate using LSTM deep neural network optimized by grey wolf optimization algorithm". Journal of Expert Systems with Applications, 209: 118303. DOI: <https://doi.org/10.1016/j.eswa.2022.118303>.
- [9] Astarita, V., Haghshenas, S. S., Guido, G., and Vitale, A. (2023). "Developing new hybrid grey wolf optimization-based artificial neural network for predicting road crash severity". Transportation Engineering, 12: 100164. DOI: <https://doi.org/10.1016/j.treng.2023.100164>.



بکارگیری مدل‌های یادگیری ماشین تقویتی در پیش‌بینی نرخ نفوذ حفاری دورانی چال‌های انفجاری

محمد میرزهی کلاته کاظمی^۱، عارف فیاضی^۲، حسام دهقانی^{۳*}

۱- کارشناسی ارشد، گروه مهندسی معدن، دانشکده فنی و مهندسی، دانشگاه تربیت مدرس، تهران

۲- دانشجوی دکتری، گروه مهندسی معدن، دانشکده فنی و مهندسی، دانشگاه تربیت مدرس، تهران

۳- دانشیار، گروه مهندسی معدن، دانشکده مهندسی معدن و مواد، دانشگاه صنعتی همدان، همدان

پذیرش: ۱۴۰۳/۰۹/۰۷

دریافت: ۱۴۰۳/۰۳/۱۳

چکیده

حفاری به کمک دستگاه حفاری دورانی ابزار مهمی برای اکتشاف و استخراج در معادن است. از طرفی برآورد هزینه‌ها و کارایی دستگاه حفاری دورانی، یک گام اساسی در طراحی پروژه‌های معدنی و عمرانی است. نرخ نفوذ حفاری (PR)، شاخص مناسبی برای برآورد هزینه‌ها و کارایی دستگاه حفاری دورانی به شمار می‌رود. بنابراین بهینه‌سازی PR در دستگاه حفاری دورانی، سبب کاهش هزینه‌ها و افزایش کارایی دستگاه حفاری دورانی می‌شود. بدین منظور در این مقاله، از روش‌های تقویت شده یادگیری ماشین (ML) که با ترکیب تقویت گرادیان سبک (LGB) و جنگل تصادفی (RF) با الگوریتم‌های فراابتکاری (MH) شامل گرگ خاکستری (GWO) و شاهین هریس (HHO) صورت گرفته است، برای تخمین PR اقدام می‌شود. در راستای اعتبارسنجی مدل‌های توسعه داده شده، مدل‌ها بر روی مجموعه داده‌های جمع‌آوری شده پیاده‌سازی شده‌اند. مجموعه داده شامل ۷ متغیر مستقل ورودی شامل قطر حفار بر حسب اینچ (D)، سرعت دورانی بر حسب دور بر دقیقه (RPM)، وزن روی سرتمه (WOB)، مقاومت فشاری تک‌محوره سنگ بر حسب مگاپاسکال (UCS)، مقاومت کششی سنگ بر حسب مگاپاسکال (T)، فاصله‌داری درزه‌ها در زمین بر حسب سانتی‌متر (JS) و راستی نسبی درزه‌ها بر حسب درجه (JD)، استفاده گردید. نتایج به دست آمده نشان می‌دهد که روش RF-GWO ($R^2 = 0.987$ و $RMSE = 3.059$) دقت بیشتری نسبت به روش‌های LGB-GWO (۰.۹۱۲ و ۸.۰۴۵)، LGB-HHO (۰.۹۱۷ و ۷.۸۳۱) و RF-HHO (۰.۹۱۲ و ۸.۰۴۴) در داده‌های آزمایشی دارد. همچنین، مطالعات آنالیز حساسیت مشخص می‌کند که پارامترهای RPM و JD به ترتیب بیشترین و کمترین تاثیر را بر PR دستگاه حفاری دورانی دارند.

کلمات کلیدی

نرخ نفوذ حفاری، یادگیری ماشین، تقویت گرادیان سبک (LGB)، جنگل تصادفی (RF)، گرگ خاکستری (GWO)، شاهین هریس (HHO).

استناد به این مقاله

میرزهی کلاته کاظمی، م.، فیاضی، ع.، دهقانی، ح.؛ ۱۴۰۴؛ "بکارگیری مدل‌های یادگیری ماشین تقویتی در پیش‌بینی نرخ نفوذ حفاری دورانی چال‌های انفجاری". نشریه مهندسی منابع معدنی، دوره دهم، شماره ۲، ص ۹۱-۱۱۵.

DOI: 10.30479/jmre.2025.20456.1696



حق مؤلف © نویسندگان

ناشر: دانشگاه بین‌المللی امام خمینی (ره)

*نویسنده مسئول و عهده دار مکاتبات Email: dehghani@hut.ac.ir

۱- مقدمه

درک توانایی پیش‌بینی کارایی دستگاه‌های حفاری برای عملیات معدنی اهمیت بسیاری دارد. نرخ نفوذ که میزان پیشروی و کارایی دستگاه حفاری را مشخص می‌کند، بر تمام عملیاتی معدنی، از برنامه‌ریزی تا اقتصاد عملیات معدنی تاثیر می‌گذارد. نرخ نفوذ حفاری دورانی همچنین در کاهش هزینه‌های حفاری معدن نقش دارد. این نرخ، نشان می‌دهد که چگونه عوامل مختلفی بر سرعت حفاری در معدن تاثیر می‌گذارند. در عملیات معدنی، انتخاب دستگاه‌ها و تجهیزات و همچنین قیمت نهایی محصول، بر اساس تخمین‌های نرخ نفوذ انجام می‌شود که اگر دقیق نباشد، ممکن است ریسک‌آفرین باشد. معادلات نرخ حفاری هم در تخمین هزینه‌های کلی حفاری کمک می‌کنند و با استفاده از آن‌ها می‌توان نوع دستگاه را انتخاب کرد. عوامل زیادی مانند ویژگی‌های سنگ و مشخصات دستگاه حفاری، بر نرخ نفوذ تاثیر می‌گذارند. با این حال، شرایط زمین‌شناسی و ویژگی‌های سنگ که توسط انسان قابل کنترل نیستند هم مهم هستند [۱].

از آنجایی که مدیریت نرخ نفوذ حفاری (PR) موضوعی مهم در عملیات حفاری است و در مطالعات مختلف مورد توجه قرار گرفته است، بنابراین بهینه‌سازی متغیرهای موثر در PR از طریق یادگیری ماشین (ML)^۲، یک روش کاربردی برای مدیریت PR است. با توجه به اهمیت مدیریت PR در عملیات حفاری، چالش اصلی در این زمینه بهینه‌سازی متغیرهای موثر بر PR است. این موضوع نه تنها بر کارایی و هزینه‌های عملیات حفاری تاثیر می‌گذارد، بلکه به افزایش ایمنی و کاهش زمان پروژه‌ها نیز کمک می‌کند.

یادگیری ماشین (ML) به عنوان یک ابزار پیشرفته، قابلیت تحلیل داده‌های پیچیده و شناسایی الگوهای موثر در PR را دارد. با استفاده از الگوریتم‌های ML، می‌توان به شناسایی عوامل کلیدی که بر نرخ نفوذ تاثیر می‌گذارند، پرداخته و بهینه‌سازی‌های لازم را انجام داد. این رویکرد به بهبود عملکرد حفاری، کاهش هزینه‌ها و افزایش بهره‌وری در پروژه‌های حفاری منجر می‌شود، بنابراین توجه به بهینه‌سازی PR از طریق یادگیری ماشین نه تنها یک ضرورت بلکه یک فرصت برای ارتقاء کیفیت و کارایی در صنعت حفاری به شمار می‌آید. روش‌های مختلف ML و الگوریتم‌های فراابتکاری (MH)^۳ مانند شبکه‌های عصبی مصنوعی (ANNs)^۴ ساده و بهینه، ماشین‌های برداری پشتیبان (SVM)^۵، منطق فازی

(FL)^۶ و سیستم استنتاج عصبی فازی تطبیقی (ANFIS)^۷ به این منظور استفاده شده است. نجاریور^۸ و همکاران، برخی از مطالعات انجام شده با استفاده از این روش‌ها را به عنوان رویکرد اصلی مدیریت PR، برای دستیابی به درک بهتر این مفهوم در نظر گرفته و مزایای اقتصادی و همچنین ظرفیت‌های تحقیقاتی آن را مورد بررسی قرار دادند. نتایج مطالعات نشان می‌دهد که ANN‌ها محبوب‌ترین روش ML در مدیریت PR بودند. این در حالی بود که ANN‌های ساده از این نظر بر انواع اصلاح شده برتری دارند. با این حال، ANN‌های اصلاح شده از نظر دقت پیش‌بینی بهتر از ANN‌های ساده هستند، اما از آنجایی که ANN‌ها در عملکرد پیش‌بینی دقیق نقص دارند؛ در عوض، سایر رویکردهای ML مدیریت، PR مانند رگرسیون خطی (LR)^۹، جنگل تصادفی (RF)^{۱۰} و روش تقویت گرادیان (GBM)^{۱۱} این کاستی را جبران کرده و کارایی و کاربردی بودن خود را به اثبات رسانده‌اند [۲]. داربر^{۱۲} و همکاران، نرخ نفوذ (PR)^{۱۳} یک ماشین حفاری دورانی را با استفاده از دو تکنیک مدل‌سازی توسعه‌یافته، یعنی مدل‌های رگرسیون چندگانه غیرخطی (NLMR)^{۱۴} و شبکه‌های عصبی پرسپترون-مصنوعی چندلایه (MLP-ANN)^{۱۵} مورد ارزیابی قرار دادند. برای این منظور از داده‌های میدانی و تجربی مطالعات موردی مختلف استفاده شد. چندین شاخص عملکرد، از جمله ضریب تعیین (R^2)، شمول واریانس^{۱۶} (VAF)^{۱۷} و ریشه میانگین مربعات خطا (RMSE)^{۱۸}، برای بررسی ظرفیت پیش‌بینی مدل‌های توسعه‌یافته مورد ارزیابی قرار گرفتند. با در نظر گرفتن ورودی‌های متعدد در مدل‌های مختلف NLMR، عوامل موثر بر PR شامل تردی، شاخص تعیین کیفیت سنگ (RQD)^{۱۹}، آب‌محتوی و شاخص ناهمسانگردی است. نتایج تحلیل چند متغیره مدل‌های توسعه‌یافته نشان داد که مدل MLP-ANN پیش‌بینی عملکرد دقیق‌تری را نسبت به مدل NLMR برای مجموعه داده‌های آموزشی و آزمایشی نشان می‌دهد. علاوه بر این، آنالیز حساسیت نشان داد که RQD و آب‌محتوی تاثیر قابل توجهی بر PR دارند. مدل‌های ارایه شده به وسیله آن‌ها را می‌توان با موفقیت برای پیش‌بینی PR در سنگ‌هایی با ویژگی‌های مشابه به کار برد [۱]. حفاری زمین‌شناسی ابزار مهمی برای اکتشاف زمین است. به دلیل غیرخطی بودن رابطه بین متغیرها و اثر متقابل متغیرهای موثر بر حفاری، حفاری زمین‌شناسی با راندمان و ایمنی پایین همراه بوده و پیش‌بینی دقیق حالت‌های حفاری دشوار است. علاوه بر این، مسیر چاه عمودی باید از خط شاقول پیروی

کند. ژو^{۲۰} و همکاران، روش بهینه‌سازی جدیدی برای حل این مساله پیشنهاد کردند. در این روش، ابتدا شرایط کاری با روش خوشه‌بندی C-means فازی شناسایی شده و پس از آن محدوده‌های تنظیم مربوط به متغیرهای عملیاتی برای بهینه‌سازی اصلاح می‌شوند. در همین حال، رگرسیون بردار پشتیبان و الگوریتم خفاش ترکیبی برای ساخت مدل‌های قابل اعتماد برای حجم گودال گل‌گذاری (MPV)^{۲۱} و PR استفاده می‌شوند [۳].

هدف، دستیابی به یک مدل واحد برای تخمین PR با دقت بالا، موضوع مطالعات بسیاری بوده است. برای این منظور، از روش‌های تحلیلی و تکنیک‌های مبتنی بر داده استفاده شد. با این حال، علی‌رغم اثربخشی جزئی، این روش‌ها برای ایجاد مدل‌های کلی کفایت مطلوبی نداشتند. شریفی‌نسب^{۲۲} و همکاران، بر اساس مفاهیم یادگیری عمیق (DL)^{۲۳}، یک رویکرد نوآورانه ایجاد کردند که مدل‌های عمومی و تقویت شده را تولید کرده که قادر به تخمین دقیق‌تر PRها در مقایسه با سایر تکنیک‌ها هستند. یکی از اجزای حیاتی این رویکرد، استفاده از ساختار ANN عمیق معروف به شبکه مولد متخاصم (GAN)^{۲۴} است. ساختار GAN با ANNهای رگرسیون (پیش‌بینی کننده) ترکیب شده تا عملکرد آن‌ها را هنگام تخمین متغیر هدف افزایش دهد [۴].

PR، سرعت و زمان حفاری را حین انجام عملیات حفاری در چاه‌های نفت و گاز نشان می‌دهد. یک مدل پیش‌بینی کننده PR را به پارامترهای تاثیرگذار آن پیوند می‌دهد. این مدل، برای بهینه‌سازی PR جهت به حداقل رساندن هزینه‌های حفاری ضروری است. شایگان^{۲۵} و جمشیدی^{۲۶}، یک رویکرد داده‌کاوی جامع را با استفاده از جعبه‌ابزار پایتون برای بهبود پیش‌بینی PR در چاه‌های جهت‌دار اجرا کردند که به اندازه چاه‌های عمودی (با توجه به کم‌بودن وزن چاه روی سرمته (WOB)^{۲۷} و انتقال برش مورد توجه قرار نگرفته است. روش‌های پیش‌پردازش داده‌ها، متشکل از امتیاز Z^{۲۸} (ZS) اصلاح شده و ساوتسکی-گولی^{۲۹} (SG)، برای حذف داده‌های پرت و کاهش داده‌های تصادفی در مجموعه داده ورودی استفاده شد. MLP-ANN و مدل‌های رگرسیون RF، به طور نسبی برای پیش‌بینی PR مورد استفاده قرار گرفتند و معماری آن‌ها با تنظیم فراپارامترهای مدل‌ها طراحی گردید [۵]. میرجلیلی^{۳۰} و همکاران، یک الگوریتم MH جدید به نام بهینه‌ساز گرگ خاکستری (GWO)^{۳۱} با الهام گرفتن از گرگ‌های خاکستری پیشنهاد کردند. نتایج توسط یک مطالعه

مقایسه‌ای با بهینه‌سازی ازدحام ذرات (PSO)^{۳۲}، الگوریتم جستجوی گرانشی (GSA)^{۳۳}، تکاملی تفاضلی (DE)^{۳۴}، برنامه‌ریزی تکاملی (EP)^{۳۵} و تکامل استراتژی (ES)^{۳۶} تایید شدند. یافته‌ها نشان دادند که الگوریتم GWO نتایج بسیار رقابتی را در مقایسه با این الگوریتم‌های MH معروف نامبرده شده ارائه می‌دهند [۶]. پیش‌بینی مطمئن و دقیق عملکرد TBM به حداقل رساندن خطرات مربوط به هزینه‌های سرمایه‌گذاری بالا و برنامه‌ریزی پروژه‌های تونل‌سازی کمک می‌کند. هدف این تحقیق توسعه شش مدل ترکیبی تقویت شدید گرادیان (XGB)^{۳۷} است که با الگوریتم‌های GWO، PSO، بهینه‌سازی عنکبوت اجتماعی (SSO)^{۳۸}، الگوریتم کسینوسی سینوسی (SCA)^{۳۹}، بهینه‌سازی چندوجهی (MVO)^{۴۰} و بهینه‌سازی شعله پروانه (MFO)^{۴۱} برای پیش‌بینی نرخ نفوذ TBM (TBM-PR) بهینه شده‌اند [۷]. دستیابی به یک برآورد دقیق و قابل اعتماد از عملکرد ماشین حفاری تونل (TBM)^{۴۲}، خطرات مربوط به هزینه‌های سرمایه‌گذاری بالا و برنامه‌ریزی ساخت تونل را کاهش می‌دهد. محمودزاده^{۴۳} و همکاران، یک مدل ترکیبی حافظه بلند و کوتاه‌مدت (LSTM)^{۴۴} که با GWO تقویت شده است را برای پیش‌بینی نرخ نفوذ TBM (TBM-PR) ایجاد کردند. آن‌ها، ۱۱۲۵ مجموعه داده شامل شش پارامتر ورودی در نظر گرفتند. برای از بین بردن بیش‌برازش، از تکنیک کنار گذاشتن بخشی از داده‌ها (DPRout) استفاده شد. اثر طول سری‌های زمانی ورودی بر عملکرد مدل مورد مطالعه قرار گرفت. نتایج TBM-PR مدل LSTM-GWO با برخی دیگر از مدل‌های ML مانند LSTM مقایسه شد. نتایج با استفاده از RMSE، MAPE و ضریب همبستگی (R^2) مورد ارزیابی قرار گرفت. در نهایت، مدل LSTM-GWO دقیق‌ترین نتایج را تولید کرد (آزمون: $R^2=0.9795$; $RMSE=0.004$; $MAPE=0.009$ ٪). آزمون اثر متقابل نشان داد که پارامترهای ورودی طبقه‌بندی شکست سنگ و مقاومت فشاری تک محوره به ترتیب کمترین و بیشترین تاثیر را بر TBM-PR داشتند [۸].

با توجه به اهمیت تخمین دقیق PR-DR در عملیات معدنکاری و چالش‌برانگیز بودن جمع‌آوری داده‌های مربوطه، این مطالعه بر روی پیش‌بینی PR-DR با مقایسه دو روش یادگیری ماشین تحت عنوان تقویت گرادیان سبک (LGB)^{۴۵} و RF تقویت شده با دو الگوریتم MH به طور جداگانه تحت عنوان GWO و بهینه‌سازی شاهین‌های هریس (HHO)^{۴۶} انجام گرفت.

منجر می‌شود.

حساسیت به شرایط محیطی: فرض بر این است که شرایط محیطی (مانند دما و فشار) تاثیر قابل توجهی بر نرخ نفوذ دارند و تغییرات آن‌ها به تغییراتی در PR منجر می‌شود. استفاده از الگوریتم‌های فراابتکاری در پیش‌بینی PR به بهبود دقت پیش‌بینی‌ها و مدیریت بهتر عملیات حفاری کمک می‌کند.

۱-۳- محدودیت‌های پژوهش و مطالعات آتی

مدل‌های توسعه‌یافته در حوزه پیش‌بینی نرخ نفوذ حفاری دورانی چال‌های انفجاری، به رغم پیشرفت‌های قابل توجهی که داشته‌اند، محدودیت‌ها و چالش‌هایی در پیاده‌سازی عملی دارند. این محدودیت‌ها و چالش‌ها شامل موارد زیر می‌شوند:

۱. محدودیت‌های اصلی مدل‌ها:

دقت داده‌ها: کیفیت و دقت داده‌های ورودی به مدل‌ها ممکن است متفاوت باشد. داده‌های نادرست یا ناقص می‌توانند به پیش‌بینی‌های نادرست منجر شوند.

ساده‌سازی مدل: بسیاری از مدل‌ها برای قابلیت استفاده باید پیچیدگی‌های واقعی را ساده کنند. این ساده‌سازی ممکن است باعث از بین رفتن اطلاعات مهم در روند تصمیم‌گیری شود.

عدم انعطاف‌پذیری: برخی از مدل‌ها ممکن است قادر به سازگاری با شرایط خاص زمین‌شناسی یا عملیاتی نباشند، که ممکن است تاثیر منفی بر نتایج داشته باشد.

۲. چالش‌های پیاده‌سازی در پروژه‌های واقعی:

تطبیق با شرایط واقعی: در محیط واقعی، شرایط زمین‌شناسی، جوی و فنی ممکن است به طور مداوم تغییر کنند و این تغییرات به تنظیمات مستمر در مدل‌ها نیاز دارد. هزینه و زمان: استفاده از مدل‌های پیشرفته ممکن است به آموزش و تجهیزات خاصی نیاز داشته باشد که ممکن است هزینه‌ها و زمان اجرای پروژه را افزایش دهد.

پذیرش توسط پرسنل: اگر کارکنان و پیمانکاران نسبت به روش‌های جدید یا مدل‌های تحلیلی آموزش کافی نداشته باشند، ممکن است از آن‌ها به طور موثری استفاده نشود.

۳. چگونگی رفع این چالش‌ها:

آموزش و بهبود مهارت‌ها: برگزاری دوره‌های آموزشی و کارگاه‌های عملی به ارتقاء مهارت‌های ضروری و آشنایی پرسنل با مدل‌ها کمک می‌کند.

در ادامه نیز، به موضوعات مراحل تدوین مدل، فرض‌های مدل، محدودیت‌های پژوهش و مطالعات آتی، الگوریتم‌های بهینه‌سازی، جمع‌آوری و آنالیز داده‌ها، یافته‌ها و نتیجه‌گیری مقاله اشاره خواهد شد.

۱-۱- مراحل تدوین مدل

مراحل تدوین مدل شامل موارد زیر است:

جمع‌آوری داده‌ها: داده‌های مربوط به عملیات حفاری شامل PR، نوع سنگ، شرایط حفاری و پارامترهای عملیاتی جمع‌آوری می‌شود.

تعیین متغیرهای ورودی: شناسایی متغیرهای مستقل که بر PR تاثیر می‌گذارند. این متغیرها شامل عواملی مانند نوع مته، وزن مته، فشار و کف مایع حفاری هستند.

انتخاب الگوریتم فراابتکاری: انتخاب الگوریتم مناسب بر اساس نوع داده‌ها و پیچیدگی مدل. برای مثال، در صورتی که داده‌ها غیرخطی باشند، الگوریتم‌هایی مانند تدریس مرزی یا الگوریتم ژنتیک انتخاب می‌شوند.

توسعه تابع هدف: ایجاد یک تابع هدف که ممکن است به حداقل رساندن خطا بین پیش‌بینی و ارزش واقعی PR باشد.

بهینه‌سازی مدل: استفاده از الگوریتم فراابتکاری برای بهینه‌سازی پارامترهای مدل. این الگوریتم‌ها به جستجوی فضای پارامترها پرداخته و سعی در پیدا کردن بهترین ترکیب برای پیش‌بینی PR دارند.

اعتبارسنجی: اعتبارسنجی مدل با استفاده از داده‌های تست و مقایسه نتایج پیش‌بینی شده با داده‌های واقعی.


۱-۲- فرض‌های مدل

فرض‌های مدل شامل موارد زیر است:

خطی بودن یا غیرخطی بودن روابط: فرض بر این است که بین PR و متغیرهای ورودی رابطه خاصی وجود دارد که ممکن است خطی یا غیرخطی باشد.

داده‌های مستقل و تصادفی: فرض بر این است که داده‌های مورد استفاده مستقل و از یک توزیع تصادفی پیروی می‌کنند. تاثیر متغیرها قابل سنجش است: فرض می‌شود که همه متغیرهای انتخاب شده تاثیر قابل اندازه‌گیری و معنی‌داری بر PR دارند.

عدم حضور هم‌خطی: فرض بر عدم وجود هم‌خطی شدید بین متغیرهای ورودی است که به عدم دقت در پیش‌بینی



شکل ۱: طبقه‌بندی الگوریتم‌های بهینه‌سازی [۱۲]

۲-۱- تقویت گرادیان سبک (LGB)

این روش یادگیری ماشین که یک الگوریتم محبوب توسعه داده شده توسط مایکروسافت است؛ برای مسایل رتبه‌بندی و طبقه‌بندی استفاده می‌شود. ساختار آن نیز بر اساس مدل‌های درخت تصمیم است. LGB، با سرعت تمرین و نتایج پیش‌بینی دقیق متمایز می‌شود. این به دلیل افزودن یک روش انتخاب خودکار ویژگی و همچنین تمرکز بر تقویت نمونه‌هایی با گرادیان بیشتر است [۱۱]. LGB همچنین، یک استراتژی رشد مبتنی بر برگ را اتخاذ کرده که برگ بهینه را با بیشترین تقسیم سود (به طور کلی بیشترین مقدار داده) از میان همه برگ‌های جاری می‌یابد (شکل ۲) [۱۲].

LGB، یک چارچوب برای یادگیری مبتنی بر درخت است که از روش‌های تقویت گرادیان استفاده می‌کند. در رابطه ۱، فرمول‌های کلیدی این الگوریتم به زبان ریاضی آورده شده است [۱۲].

(۱)

$$\tilde{V}_j(d) = \frac{1}{n} \left(\frac{\left(\sum_{x_i \in A_l} g_i + \frac{1-a}{b} \sum_{x_i \in B_l} g_i \right)^2}{n_l'(d)} + \frac{\left(\sum_{x_i \in A_r} g_i + \frac{1-a}{b} \sum_{x_i \in B_r} g_i \right)^2}{n_r'(d)} \right)$$

که در آن:

V : تابع کلی خسارت

توسعه مدل‌های تطبیقی: ایجاد مدل‌هایی که قابلیت انعطاف‌پذیری بیشتری دارند و می‌توانند به راحتی با شرایط متغیر انطباق پیدا کنند.

استفاده از داده‌های به‌روز: جمع‌آوری و به کارگیری داده‌های به‌روز و متنوع بهبود دقت مدل‌ها و پیش‌بینی‌ها را به همراه دارد.

۴. تاثیر محدودیت‌ها بر قابلیت استفاده:

کاهش اعتماد به مدل‌ها: اگر محدودیت‌ها و چالش‌ها به خوبی شناسایی و رفع نشوند، ممکن است اعتماد به مدل‌ها در تصمیم‌گیری‌های عملیاتی کاهش یابد.

تاثیر بر بهره‌وری: در صورت عدم توانایی مدل‌ها در درک شرایط واقعی، این ممکن است به تصمیمات غیربهینه و کاهش بهره‌وری پروژه‌های حفاری منجر شود.

به طور کلی، برای مقابله با این چالش‌ها و محدودیت‌ها باید توجه خاصی به به‌روزرسانی مدل‌ها، آموزش پرسنل و جمع‌آوری داده‌های معتبر و منتخب صورت گیرد.

۲-۲ الگوریتم‌های بهینه‌سازی

همان‌طور که گفته شد، برای تخمین نرخ نفوذ دستگاه حفاری دورانی (دستگاه حفاری دورانی)^{۴۷}، از دو روش یادگیری ماشین (LGB و RF) تقویت‌شده با دو الگوریتم MH به طور جداگانه (GWO و HHO) استفاده شد، بنابراین به طور کلی ۴ مدل مستقل ML تقویت شده با الگوریتم MH (LGB-MH، GWO، LGB-HHO، RF-GWO و FR-HHO) تدوین گردید.

آستاریتا^{۴۸} و همکاران، دو تکنیک یادگیری ماشین یعنی شبکه عصبی مصنوعی (ANN)^{۴۹} و الگوریتم GWO با چندین معیار عملکرد برای ارزیابی الگوریتم GWO بر پایه یکی از انواع ML (GWO-ML) استفاده کردند. برای این منظور، عواملی را که بر سطح پاسخ تاثیر می‌گذاشتند، در نظر گرفتند. مطالعه موردی آن‌ها در شهر کالابریا در جنوب ایتالیا انجام شد. هنگام مقایسه مدل پیشنهادی GWO-ML با مدل ML پایه، یافته‌ها به وضوح برتری مدل GWO-ML پیشنهادی را نشان داد [۹].

برای انجام عملیات بهینه‌سازی کارآمد، به درک درستی از نحوه طبقه‌بندی الگوریتم‌های بهینه‌سازی نیاز است. به این منظور، قلم‌باز^{۵۰} و همکاران، یک طبقه‌بندی کلی از الگوریتم‌های بهینه‌سازی مطابق شکل ۱ ارائه دادند [۱۰].

N: تعداد نمونه‌های آموزشی

کسر اول: تابع خسارت (مانند میانگین مربعات خطا برای رگرسیون)

کسر دوم: عبارت منظم‌کننده برای کنترل پیچیدگی مدل است.

در فرمول بالا تابع هدف (تابع کلی خسارت) محاسبه شده و برای هر شاخه بعدی این عمل تکرار می‌شود [۱۲].

۲-۲- جنگل تصادفی (RF)

RF را می‌توان در مسایل رگرسیون و طبقه‌بندی و همچنین مسایل ML خوشه‌بندی بدون نظارت و تشخیص موارد دور از دسترس مطابق شکل ۳ استفاده کرد [۱۳].


RF، یک تکنیک طبقه‌بندی غیرخطی است که از گروهی از DTها تشکیل شده و چندین DT را برای پیش‌بینی‌های دقیق‌تر ادغام می‌کند. هر مدل DT زمانی استفاده می‌شود که به تنهایی مورد استفاده قرار گیرد. این الگوریتم، تصادفی

نامیده می‌شود، زیرا پیش‌بینی‌کننده‌ها به طور تصادفی در یک زمان آموزش انتخاب می‌شوند. علاوه بر این، آن را جنگل می‌نامند، زیرا برای تصمیم‌گیری نتیجه درختان متعدد است. مزیت اصلی RF در مقایسه با DT این است که تعداد زیاد مدل‌های درختی نامرتب که به عنوان یک واحد کار کرده، همیشه از مدل‌های درختی منفرد بهتر عمل می‌کنند [۱۴].

برای انتخاب یک ویژگی برای طبقه‌بندی بولین^{۵۱}، نیاز به دانستن این موضوع است که آن طبقه‌بندی چقدر خالص یا ناخالص خواهد بود و این ویژگی به عنوان گره ریشه انتخاب خواهد شد که کمترین ناخالصی یا به عبارت دیگر، کمترین شاخص جینی^{۵۲} را دارد. یک طبقه‌بندی خالص به معنی دریافت "بله" یا "خیر" است. شاخص جینی طبق رابطه ۲ نوشته می‌شود [۱۴].


(۲)

$$Gini\ Index = 1 - \sum_{i=1}^n (P_i)^2 = 1 - [(P_+)^2 - (P_-)^2]$$



Leaf-wise tree growth

شکل ۲: مثالی از LGB [۱۴]



شکل ۳: مثالی از RF [۱۴]

که در آن:

$$D_m^{\rightarrow} = |C^{\rightarrow} \cdot X^{\rightarrow}(t) - X^{\rightarrow}(t)| \quad (3)$$


 P^+ : احتمال یک طبقه‌بندی مثبت

$$X_m^{\rightarrow}(t+1) = X_p^{\rightarrow}(t) - A^{\rightarrow} \cdot D^{\rightarrow} \quad (4)$$



 P^- : احتمال یک طبقه‌بندی منفی است.

۲-۳- گرگ خاکستری (GWO)

الگوریتم GWO سلسله مراتب و تعامل اجتماعی گرگ‌های خاکستری در طبیعت را تقلید می‌کند. در یک سری از گرگ‌ها، انواع مختلفی از اعضا وجود دارند که با توجه به سطح تسلط طبقه‌بندی شده که شامل α ، β ، δ و ω می‌شود. غالب‌ترین گرگ α بوده و قدرت سلطه و رهبری از α به ω کاهش می‌یابد [۱۵]. شکل ۴، سلسله مراتب زندگی اجتماعی گرگ‌های خاکستری در طبیعت را نشان می‌دهد [۱۶]. این مکانیسم، با تقسیم جمعیت گرگ‌ها از راه‌حل‌های کاندید برای حل یک مساله بهینه‌سازی معین به چهار کلاس تقسیم‌بندی می‌شود. این فرآیند بهینه‌سازی در شکل ۵ برای به‌روزرسانی موقعیت گرگ‌ها نشان داده شده است. همان‌طور که در این شکل مشاهده می‌شود، سه راه حل بهینه به ترتیب به صورت α ، β و δ در نظر گرفته می‌شوند. بقیه راه‌حل‌ها در گروه گرگ‌های ω قرار می‌گیرند [۱۷]. برای پیاده‌سازی این روش، باید قبل از تغییر راه‌حل‌ها، سلسله مراتب را در هر تکرار، طبق روابط ۳ تا ۶ به‌روز کرد. پس از این به‌روزرسانی، موقعیت راه‌حل‌ها نیز با استفاده از رابطه ۷ به‌روز می‌شود [۱۸-۲۰].



شکل ۴: سلسله مراتب زندگی اجتماعی گرگ‌های خاکستری در طبیعت [۱۸]



شکل ۵: به‌روزرسانی موقعیت در GWO [۱۹]

که در این روابط:

m : سلسه مراتب گرگ‌های خاکستری (به ترتیب ۱ تا ۳)

t : موقعیت فعلی

X : بردار موقعیت گرگ‌های خاکستری

A و C : بردارهای تغییر موقعیت

D : بردار موقعیت جدید گرگ‌های خاکستری

A : بردار تغییر موقعیت وابسته به موقعیت فعلی و تعداد

تکرارها

r_1 و r_2 : بردارهای فاصله با اندازه تصادفی در بازه $[0-1]$

است.

بدین ترتیب، موقعیت گرگ‌ها در هر تکرار به موقعیت

شکار (پاسخ مورد نظر) نزدیک‌تر می‌شود.

۲-۴- بهینه‌سازی شاهین‌های هریس (HHO)

برای یافتن و آنالیز ضریب هوشی در پس راه‌های

نوآورانه دستیابی به جواب بهینه توسط شیوه‌های تغذیه

پرندگان، رویکردی توسط لوئیس لوفور^{۵۳} پیشنهاد شد [۲۱].

شاهین‌ها به عنوان بزرگترین پرندگان باهوش در حیات وحش

شناخته می‌شوند. شاهین هریس با نام علمی "parabuteo"


"unicinctus" در برزیل، اروپای غربی و در جنوب غربی ایالات

متحدہ وجود دارد. با توجه به اقدامات شکار حمایتی غیرقابل

تقلید، شاهین‌های هریس در شکار سرآمد بوده و می‌توانند

به عنوان شکارچیان سازگار باهوش شناخته شوند. معمولاً شکارچیان دیگر بدون همراه حمله کرده، متوجه شکار شده و شکار را می‌ربایند، اما شاهین‌های هریس با همکاری با سایر گونه‌هایی که در یک گروه زندگی می‌کنند، به جستجوی غذا می‌پردازند. گروهی از این شکارچیان صحرا در هنگام حمله به طعمه پنهان، مهارت‌های برق‌آسای شگفت انگیزی را در یافتن، احاطه کردن، شکار کردن طعمه از خود نشان می‌دهند [۲۲].

مطابق شکل ۶، در این الگوریتم بهینه‌سازی، دسته‌ای از شاهین‌ها که سعی در تعقیب هدف خود دارند به عنوان جمعیت اولیه در نظر گرفته می‌شوند [۲۱]. هدف را می‌توان به عنوان راه‌حل برای مشکل تعریف کرد. شاهین‌ها جهت‌های مختلفی را برای تعقیب هدف با استفاده از حرکت غافلگیرانه انتخاب می‌کنند. در ابتدا، هدف می‌تواند توسط رهبر گروه مورد حمله قرار گیرد. میزان موفقیت رهبر در تعقیب به رفتار فراری و ماهیت پرانرژی هدف بستگی دارد. اکنون دیگر اعضای گروه می‌توانند تاکتیک‌های تعویض را برای گرفتن هدف دنبال کنند. با گنج کردن و تحریک کردن هدف، شاهین‌های گروه می‌توانند آن را با استراتژی‌های همکاری دنبال کنند. در الگوریتم HHO، راه‌حل‌های کاندید پرندگان هستند و راه‌حل هدف پیش‌بینی می‌شود. اکتشاف و بهره‌برداری دو مرحله اصلی بوده در حالی که شاهین‌ها یا راه‌حل‌های کاندید در حال



شکل ۶: الگوریتم HHO [۲۴]

یافتن هدف یا راه‌حل بهینه هستند. فرمول تابع هدف این الگوریتم، طبق رابطه ۸ است [۲۳].

$$h = y_{prey}(T) - e|Ky_{prey}(T) - y(T)| \quad (8)$$

که در آن:

h : موقعیت متوسط شاهین‌ها

$y_{prey}(T)$: موقعیت هر شاهین در تکرار t

N : تعداد کل شاهین‌ها است.

علاوه بر موارد یاد شده، توضیحاتی در خصوص عملگرهای محاسباتی مورد استفاده در مدل که شامل R^2 و RMSE است، برای مقایسه مدل‌ها داده شد.

۲-۵- عملگرهای محاسباتی

ضریب تعیین (R^2)، یک ابزار آماری برای تعیین شدت رابطه یک متغیر کمی با متغیر کمی دیگر است. این ضریب، یکی از معیارهای مورد استفاده در تعیین همبستگی متغیرها است [۲۴]. R^2 که برابر با توان دوم ضریب همبستگی است؛ تنها شدت رابطه را نشان داده و مقدار آن بین صفر و ۱ است. مقدار R^2 ، همواره کوچکتر یا مساوی ضریب همبستگی خواهد شد. همین امر سبب می‌شود که استفاده از R^2 ، در انتخاب سخت‌گیرانه مدل مطلوب کمک‌کننده باشد. در صورتی که رابطه‌ای بین متغیرها وجود نداشته باشد، مقدار این ضریب

برابر صفر خواهد بود [۲۵].

ریشه دوم مجموع مربعات خطاها (RMSE)، یک عملگر محاسباتی بوده که تفاوت میان مقدار اندازه‌گیری و مقدار پیش‌بینی شده به وسیله مدل را نشان داده و هیچ‌گاه مقدار آن منفی نخواهد بود. در صورتی که مقدار مجموع مربعات خطاها (MSE) بین صفر و یک باشد؛ مقدار RMSE که ریشه دوم MSE بوده، بزرگ‌تر خواهد شد. همین امر سبب می‌شود که در مقادیر خطای بین صفر و یک، استفاده از RMSE به جای MSE، در انتخاب سخت‌گیرانه مدل مطلوب کمک‌کننده باشد [۲۶].


مطابق آنچه که در خصوص الگوریتم‌های بهینه‌سازی گفته شد، شکل ۷ فلوچارت مدل را به تصویر می‌کشد.

۳- جمع‌آوری و آنالیز داده‌ها

در این بخش به توصیف مطالعه موردی داده‌های جمع‌آوری شده و نیز آمار توصیفی این داده‌ها به تفکیک پرداخته شد.

۳-۱- مطالعه موردی (معدن مس سرچشمه)

معدن مس سرچشمه که در قسمت مرکزی رشته‌کوه زاگرس اطراف شهرستان رفسنجان قرار داشته؛ یکی از معروف‌ترین معادن جهان محسوب می‌شود. این معدن، بزرگ‌ترین معدن مس ایران بوده که ذخیره زمین‌شناسی آن



شکل ۷: فلوچارت مدل

است، مورد استفاده قرار گرفتند. در جدول ۱، خلاصه‌ای از آمار توصیفی متغیرها شامل حد پایین و بالا، میانگین و انحراف معیار متغیرها که به ترتیب با ^{55}Max ، ^{54}Min و $^{56}\text{Std.Dev.}$ نشان داده شده‌اند، آمده است.

از آنجا که ضریب همبستگی پیرسون (R)، نوع رابطه معکوس (منفی) یا مستقیم (مثبت) و نیز شدت رابطه متغیرها را نشان می‌دهد؛ مقدار این ضریب بین -1 تا 1 بوده و در صورتی که رابطه‌ای بین متغیرها وجود نداشته باشد، مقدار آن برابر صفر خواهد بود [۲۷]. شکل ۹، همبستگی پارامترهای مختلف مدل را نشان می‌دهد. همان‌طور که از شکل مشخص است، راستای نسبی درزه‌ها و سرعت زاویه‌ای دستگاه حفاری دورانی به ترتیب کمترین و بیشترین همبستگی را با نرخ نفوذ دستگاه حفاری دورانی دارند. همچنین، در جدول ۲ خلاصه‌ای از معیارهای R^2 و RMSE مدل آورده شده است.


۴- یافته‌ها

برای تخمین بهینه PR، داده‌ها به دو دسته آموزشی^{۵۷} و آزمایشی^{۵۸} تقسیم شدند. مدل‌های عنوان شده در نرم‌افزار پایتون^{۵۹} برای تعیین مدل بهینه، پیاده‌سازی شده‌اند. در نهایت،

بیش از ۱ میلیارد تن سنگ حاوی گوگرد است. عیار متوسط این ذخیره حدوداً ۰٫۷ درصد تخمین زده شده است. این معدن، بر روی کمربند جهانی مس (گسترش از شمال غرب به جنوب شرق به شکل بیضوی) قرار گرفته است. کانه‌زایی این محدوده پورفیری و سنگ آن از نوع گرانودیوریت است. تشکیل سنگ‌های این ناحیه به حدود ۲۵ میلیون سال پیش برمی‌گردد. شکل ۸، موقعیت جغرافیایی و به کارگیری روش حفاری دورانی چال‌های انفجاری معدن مس سرچشمه را به تصویر می‌کشد.

۳-۲- آمار توصیفی

در مدل‌های تقویتی پژوهش حاضر، ۷ متغیر مستقل ورودی که شامل قطر حفار بر حسب اینچ (D)، سرعت دورانی بر حسب دور بر دقیقه (RPM)، وزن روی سرمته (WOB)، مقاومت فشاری تک‌محوره سنگ بر حسب مگاپاسکال (UCS)، مقاومت کششی سنگ بر حسب مگاپاسکال (T)، فاصله‌داری درزه‌ها در زمین بر حسب سانتی‌متر (JS) و راستی نسبی درزه‌ها بر حسب درجه (JD)، برای تخمین PR بر حسب سانتی‌متر بر دقیقه دستگاه حفاری دورانی (PR)



شکل ۸: موقعیت جغرافیایی و به کارگیری روش حفاری دورانی چال‌های انفجاری معدن مس سرچشمه


از معیارهای R^2 و RMSE به منظور مشخص کردن برترین مدل استفاده گردید. در ادامه، نتایج تخمین هریک از مدل‌ها، شرح داده شده و در انتها با یکدیگر مقایسه شدند. از طرفی، در راستای تعیین پارامتر بیشترین تاثیر بر PR یک روش آنالیز حساسیت به کار گرفته شد.

جدول ۱: خلاصه آمار توصیفی متغیرها

متغیرها	D (inch)	RPM	WOB (PSI)	UCS (MPa)	T (MPa)	JS (cm)	JD (deg)	PR (cm/min)
Max	۸٫۵	۲۴	۷۷٫۲۷	۵۰	۶	۵	۱۰	۸
Min	۹٫۸۸	۱۷۷	۱۷۵۰	۲۲۶	۲۸	۱۱۵	۹۰	۱۰۰
Mean	۹٫۲۷	۸۵٫۹۵	۹۶۱٫۵۱	۱۵۷٫۹۳	۱۹٫۸۱	۴۱٫۷۷	۳۶٫۰۳	۴۰٫۳۶
Std.Dev.	۰٫۵۸	۴۰٫۹۴	۳۶۰٫۵۱	۴۵٫۹۲	۵٫۷۷	۲۸٫۳۰	۱۶٫۰۹	۲۴٫۶۰

 جدول ۲: خلاصه نتایج معیارهای R^2 و RMSE برای مدل‌های بهینه‌سازی

ویژگی‌ها	Type	LGB-GWO	LGB-HHO	RF-GWO	RF-HHO
R^2	train	۰٫۹۶۴۲	۰٫۹۶۲۳	۰٫۹۹۴۰	۰٫۹۶۳۷
	test	۰٫۹۱۲۲	۰٫۹۱۶۸	۰٫۹۸۷۳	۰٫۹۱۲۲
RMSE	train	۴٫۴۶۶۴	۴٫۵۸۲۶	۱٫۸۲۷۹	۴٫۴۹۷۵
	test	۸٫۰۴۴۴	۷٫۸۳۱۰	۳٫۰۵۹۴	۸٫۰۴۵۶



شکل ۹: همبستگی پارامترهای مدل


الگوریتم‌های ML پرداخته شده است.

۴-۱- تقویت گرادیان سبک (LGB)


نتایج حاصل از بهینه‌سازی LGB-GWO و LGB-HHO در قالب گراف‌هایی با خطوط آبی (مقادیر اندازه‌گیری‌شده) و خطوط نارنجی (مقادیر تخمینی) برای داده‌های آموزشی و آزمایشی به ترتیب در شکل‌های ۱۰ و ۱۱ نشان داده شدند. همان‌طور که از شکل‌ها مشخص است، گراف‌های مربوط به مقادیر اندازه‌گیری‌شده و تخمینی این مدل‌ها با هم همبستگی یکسانی دارند.

با توجه به اینکه بهینه‌سازی بر پایه دو الگوریتم ML، شامل LGB و RF انجام شده بود؛ هر کدام از آن‌ها نیز به وسیله دو الگوریتم MH شامل GWO و HHO تقویت شدند.

طبق یافته‌های به دست آمده از بهینه‌سازی، مقادیر اندازه‌گیری‌شده و تخمینی RF-GWO نسبت به سایر الگوریتم‌ها، با هم همبستگی بسیار بالاتری دارند. از این رو، الگوریتم پیشنهادی برای بهینه‌سازی پیش‌بینی نرخ نفوذ حفاری دورانی چال‌های انفجاری، مدل RF-GWO توصیه می‌شود. در ادامه نیز، به جزئیات بیشتر در خصوص



شکل ۱۰: گراف‌های آموزشی حاصل از بهینه‌سازی سمت بالا (LGB-GWO) و سمت پایین (LGB-HHO)



شکل ۱۱: گراف‌های آزمایشی حاصل از بهینه‌سازی سمت بالا (LGB-GWO) و سمت پایین (LGB-HHO)

۲-۴- جنگل تصادفی (RF)

آزمایشی به ترتیب در شکل‌های ۱۲ و ۱۳ نشان داده شدند. همان‌طور که از شکل‌ها مشخص است، گراف‌های مربوط به مقادیر اندازه‌گیری شده و تخمینی RF-GWO نسبت به سایر الگوریتم‌ها، با هم همبستگی بسیار بالاتری دارند.


نتایج حاصل از بهینه‌سازی RF-GWO و RF-HHO در قالب گراف‌هایی با خطوط آبی (مقادیر اندازه‌گیری شده) و خطوط نارنجی (مقادیر تخمینی) برای داده‌های آموزشی و

۳-۴- مقایسه مدل‌های بهینه‌سازی


برای مقایسه الگوریتم‌های ML با الگوریتم‌های کلاسیک که استفاده از آن‌ها در گذشته مرسوم بوده است؛ هر کدام از الگوریتم‌ها به صورت جداگانه تشریح شده و در نهایت با هم مقایسه می‌شوند.

الگوریتم‌های کلاسیک شامل الگوریتم‌های جستجوی محلی، برنامه‌ریزی پویا و الگوریتم‌های مبتنی بر گراف هستند. این الگوریتم‌ها معمولاً برای حل مسایل خاص طراحی شده‌اند و به صورت دقیق و با استفاده از قوانین مشخص عمل می‌کنند. این الگوریتم‌ها معمولاً در مسایل با اندازه کوچک تا متوسط کارایی

خوبی دارند، اما با افزایش اندازه گراف، زمان محاسباتی آن‌ها به شدت افزایش می‌یابد، بنابراین این الگوریتم‌ها معمولاً برای مسایل خاص بهینه‌سازی طراحی شده‌اند و ممکن است در مواجهه با تغییرات در داده‌ها یا شرایط جدید عملکرد خوبی نداشته باشند. از طرف دیگر، الگوریتم‌های DL و ML تقویت شده با MH، می‌توانند از داده‌های بزرگ و پیچیده یاد بگیرند و به تدریج بهینه‌سازی کنند. آن‌ها می‌توانند الگوهای پیچیده را شناسایی کرده و به صورت خودکار بهبود یابند. این الگوریتم‌ها معمولاً قابلیت تعمیم به مسایل جدید را دارند و می‌توانند در شرایط مختلف به خوبی عمل کنند.



شکل ۱۲: گراف‌های آموزشی حاصل از بهینه‌سازی سمت بالا (RF-GWO) و سمت پایین (RF-HHO)



شکل ۱۳: گراف‌های آزمایشی حاصل از بهینه‌سازی سمت بالا (RF-GWO) و سمت پایین (RF-HHO)

روش‌های LGB و RF هر دو از روش‌های محبوب در ML هستند، اما تفاوت‌های قابل توجهی در نحوه عملکرد و کاربردهای آن‌ها وجود دارد. روش LGB به صورت تدریجی و مرحله‌ای عمل می‌کند. در هر مرحله، یک مدل جدید به مدل‌های قبلی اضافه می‌شود تا خطاهای مدل‌های قبلی را اصلاح کند. این فرآیند به بهبود دقت مدل کمک می‌کند. LGB

از این رو، می‌توان نتیجه گرفت در حالی که الگوریتم‌های کلاسیک برای مسایل خاص و با اندازه کوچک مناسب هستند، روش‌های ML تقویت شده با MH به دلیل قابلیت یادگیری و بهبود مستمر، به ویژه در مسایل پیچیده و با داده‌های بزرگ، می‌توانند گزینه بهتری باشند. انتخاب بین این دو روش بستگی به نوع مساله، اندازه داده‌ها و نیاز به انعطاف‌پذیری دارد.

چندهدفه، کاربرد دارد.

از مطالب یاد شده می‌توان نتیجه گرفت که هر دو الگوریتم از رفتارهای طبیعی الهام گرفته و در مسایل بهینه‌سازی کاربرد دارند، اما از گونه‌های مختلفی از حیوانات استفاده می‌کنند و ممکن است در زمینه‌های خاصی عملکرد بهتری داشته باشند. به علاوه، GWO بیشتر بر روی همکاری و شکار گروهی تمرکز دارد، در حالی که HHO بر روی استراتژی‌های فردی و شکار دقیق تاکید دارد.

در نهایت نیز، از میان سایر الگوریتم‌های MH، الگوریتم‌های GWO و HHO برای بهینه‌سازی انتخاب شدند.

مدل‌های بهینه‌سازی ارایه شده در پژوهش حاضر مطابق شکل ۱۴ با هم مقایسه شدند. همان‌طور که از شکل مشخص است، گراف سبز (مربوط به مدل RF-GWO) نسبت به سایر گراف‌ها با گراف قرمز (مربوط به مقادیر واقعی PR) همبستگی دارد، بنابراین می‌توان نتیجه گرفت که مدل RF-GWO نتایج بهتری را نسبت به سه مدل بهینه‌سازی دیگر ارایه می‌دهد.

این زیربخش نشان می‌دهد که مدل‌های پیش‌بینی بهینه چگونه با استفاده از نمودار تیلور عمل می‌کنند. این نمودار ریاضی برای نشان دادن این که کدام یک از مدل‌های توسعه یافته واقعی‌تر است، استفاده می‌شود. برای ارزیابی میزان توافق بین رفتار مدل شده و مشاهده شده از RMSE، انحراف معیار و همبستگی پیرسون استفاده می‌شود. شکل ۱۵ نمودار تیلور مدل‌های این مطالعه را که برای مجموعه داده‌های آزمایشی و آموزشی تولید شده‌اند، نشان می‌دهد. بر اساس نتایج، مدل ترکیبی RF-GWO در پیش‌بینی نرخ نفوذ دقیق‌تر از سایر مدل‌های پیش‌بینی است.

یکی از روش‌های ارزیابی مدل‌های پیش‌بینی، توزیع مقادیر پیش‌بینی شده است. نمودارهای جعبه‌ای در شکل ۱۶ توابع توزیع برای نرخ‌های نفوذ پیش‌بینی و اندازه‌گیری شده را نشان می‌دهند. به دلیل توزیع احتمالی مشابه با نتایج مشاهده‌ای، روش RF-GWO عملکرد بهتری نسبت به سایر مدل‌ها داشت.


۴-۴- آنالیز حساسیت

نتایج آنالیز حساسیت مدل که به صورت نمودار میله‌ای صعودی به نزولی در شکل ۱۷ آماده است، نشان از این دارد که پارامترهای سرعت زاویه‌ای دستگاه حفاری دورانی و راستای نسبی درزه‌ها به ترتیب بیشترین و کمترین تاثیر را بر PR-DM دارند که به دلیل اهمیت بسیار پایین راستای نسبی درزه‌ها می‌توان از تاثیر آن بر PR-DM چشم‌پوشی کرد.


معمولا دقت بالاتری به ویژه در مجموعه داده‌های پیچیده و با ویژگی‌های غیرخطی نسبت به RF دارد، اما ممکن است در برابر داده‌های نویزی حساس‌تر بوده و به درستی عمل نکند. همچنین، LGB معمولا زمان بیشتری برای آموزش نیاز دارد، زیرا هر مدل جدید باید به دقت بر اساس خطاهای مدل‌های قبلی آموزش ببیند. این روش، بیشتر در مسایل پیش‌بینی و رقابتی استفاده می‌شود، جایی که دقت بالای مدل اهمیت دارد، اما در مقابل، روش RF از مجموعه‌ای از درختان تصمیم‌گیری تشکیل شده است که به صورت موازی آموزش می‌بینند. هر درخت به صورت مستقل از دیگر درختان ساخته شده و در نهایت، پیش‌بینی‌ها با استفاده از میانگین یا رای‌گیری ترکیب می‌شوند. RF، عملکرد خوبی در برابر داده‌های نویزی دارد و به خوبی از بیش‌برازش^۶ جلوگیری می‌کند. دقت آن ممکن است کمتر از LGB باشد، اما معمولا پایدارتر بوده و در داده‌های نویزی عملکرد بهتری دارد. به دلیل ساختار موازی، RF معمولا سریع‌تر از LGB آموزش می‌بیند و به راحتی بر روی داده‌های بزرگ مقیاس پیاده‌سازی می‌شود. به دلیل سادگی و کارایی، این روش در بسیاری از کاربردهای تجاری و علمی به کار می‌رود، به ویژه زمانی که نیاز به تفسیر مدل وجود دارد.

در نهایت، از میان سایر روش‌های ML، روش‌های LGB و RF برای بهینه‌سازی انتخاب شدند. در ادامه نیز، دو الگوریتم فراابتکاری GWO و HHO برای تقویت ML با هم مقایسه می‌شوند.


الگوریتم‌های فراابتکاری GWO و HHO هر دو از جمله روش‌های بهینه‌سازی الهام‌گرفته از طبیعت هستند، اما ویژگی‌ها و کاربردهای متفاوتی دارند. الگوریتم GWO بر اساس رفتار شکار و زندگی اجتماعی گرگ‌های خاکستری طراحی شده است. فرآیند جستجو در این الگوریتم به صورت تقلید از نحوه شکار و همکاری گرگ‌ها انجام می‌شود. گرگ‌ها در این الگوریتم به عنوان نمایندگان راه‌حل‌ها عمل و با استفاده از اطلاعات موجود، به سمت بهترین راه‌حل حرکت می‌کنند. این الگوریتم معمولا در مسایل بهینه‌سازی پیوسته و غیرخطی کاربرد دارد، اما در مقابل، الگوریتم HHO بر اساس رفتار شکار و پرواز شاهین‌های هریس طراحی شده است. تمرکز این الگوریتم بر روی استراتژی‌های شکار و نحوه تعامل این پرندگان با محیط و یکدیگر است. شاهین‌ها در این الگوریتم به عنوان نمایندگان راه‌حل‌ها عمل و با استفاده از تکنیک‌های جستجو، به سمت بهترین راه‌حل حرکت می‌کنند. این الگوریتم نیز در مسایل بهینه‌سازی مختلف، به ویژه در مسایل پیچیده و




شکل ۱۴: مقایسه عملکرد مدل‌های بهینه‌سازی با داده‌های واقعی



شکل ۱۵: مقایسه عملکرد مدل‌های بهینه‌سازی با داده‌های واقعی با نمودار تیلور



شکل ۱۶: مقایسه عملکرد مدل‌های بهینه‌سازی با داده‌های واقعی با نمودار باکس پلات



شکل ۱۷: نتایج آنالیز حساسیت PR

۵- نتیجه‌گیری

از آنجا که حفاری به وسیله دستگاه حفاری دورانی ابزار مهمی در صنعت معدنکاری است، بنابراین کارایی این دستگاه می‌تواند یک گام اساسی در طراحی پروژه‌های معدنی باشد. طبق یافته‌ها، PR شاخص مناسبی برای برآورد کارایی دستگاه حفاری دورانی بوده که دستیابی به مقدار بهینه آن می‌تواند این مهم را حاصل کند. به همین منظور، در پژوهش حاضر از روش‌های تقویت شده ML (LGB و RF) که با الگوریتم‌های MH شامل GWO و HHO صورت گرفته است، برای تخمین

PR استفاده شد. همچنین، برای اعتبارسنجی مدل‌های توسعه داده شده، مدل‌ها بر روی مجموعه داده‌های جمع‌آوری شده پیاده‌سازی شدند. نتایج به دست آمده نشان می‌دهد که روش پیاده‌سازی شدند. نتایج به دست آمده نشان می‌دهد که روش RF-GWO ($R^2 = 0.987$; $RMSE = 3.059$) دقت بیش‌تری نسبت به روش‌های LGB-GWO (0.912 و 0.45)، RF-HHO (0.912 و 0.44) و HHO (0.917 و 0.831) دارد. همچنین، مطالعات آنالیز حساسیت مشخص کرد که پارامترهای RPM و JD به ترتیب بیش‌ترین و کم‌ترین تاثیر را بر PR دستگاه حفاری دورانی دارند.

۶- مراجع

- [10] Ghalambaz, M., Jalilzadeh-Yengejeh, R., and Davami, A. H. (2021). "Building energy optimization using Grey Wolf Optimizer (GWO)". Case Studies in Thermal Engineering, 27: 101250. DOI: <https://doi.org/10.1016/j.csite.2021.101250>.
- [11] Brownlee, J. (2020). "Ensemble learning algorithms with Python: Make better predictions with bagging, boosting, and stacking". Machine Learning Mastery, Accessed 2021 Apr 26. https://machinelearningmastery.com/wp-content/uploads/2021/03/ensemble_learning_algorithms_with_python_sample.pdf.
- [12] Li, Y., Xie, Y., Yu, C., Yu, F., Jiang, B., and Khushi, M. (2017). "Feature importance recap and stacking models for forex price prediction". arXiv. DOI: <https://doi.org/10.48550/arXiv.2107.14092>.
- [13] Torky, M., Bakhiet, A., Bakrey, M., Ahmed-Adel, I., and Ahmed, I. B. S. (2023). "Recognizing Safe Drinking Water and Predicting Water Quality Index using Machine Learning Framework". International Journal of Advanced Computer Science and Applications (IJACSA), 14(1): 23-33. DOI: <https://doi.org/10.14569/IJACSA.2023.0140103>.
- [14] Mirjalili, S., Aljarah, I., Mafarja, M., Heidari, A. A., and Faris, H. (2020). "Grey Wolf Optimizer: Theory, Literature Review, and Application in Computational Fluid Dynamics Problems". In: Mirjalili, S., Song Dong, J., and Lewis, A. (Eds.), Nature-Inspired Optimizers. Studies in Computational Intelligence, Vol. 811, Springer, Cham. DOI: https://doi.org/10.1007/978-3-030-12127-3_6.
- [15] Faris, H., Aljarah, I., Al-Betar, M. A., and Mirjalili, S. (2018). "Grey wolf optimizer: a review of recent variants and applications". Neural Computing and Applications, 30: 413-435. DOI: <https://doi.org/10.1007/s00521-017-3272-5>.
- [16] Zhao, G., Wang, H., Jia, D., and Wang, Q. (2019). "Feature selection of grey wolf optimizer based on quantum computing and uncertain symmetry rough set". Symmetry, 11: 1470. DOI: <https://doi.org/10.3390/sym11121470>.
- [17] Banaie-Dezfouli, M., Nadimi-Shahraki, M. H., and Beheshti, Z. (2021). "R-GWO: Representative-based grey wolf optimizer for solving engineering problems". Applied Soft Computing, 106: 107328. DOI: <https://doi.org/10.1016/j.asoc.2021.107328>.
- [18] Yamni, M., Daoui, A., Karmouni, H., Elmalih, S., Ben-fares, A., Sayyouri, M., Qjidaa, H., Maaroufi, M., Alami, B., and Jamil, M. O. (2023). "Copyright protection of multiple CT images using Octonion Krawtchouk moments and grey Wolf optimizer". Journal of the Franklin Institute, 360: 4719-4752. DOI: <https://doi.org/10.1016/j.fri.2023.100164>.
- [1] Kazemi, M. M. K., Nabavi, Z., and Armaghani, D. J. (2024). "A novel hybrid XGBoost methodology in predicting Penetration rate of rotary based on rock-mass and material pPRerties". Arabian Journal for Science and Engineering, 49: 5225-5241. DOI: <https://doi.org/10.1007/s13369-023-08360-0>.
- [2] Najjarpour, M., Jalalifar, H., and Norouzi-Apourvari, S. (2022). "Half a century experience in rate of penetration management: Application of machine learning methods and optimization algorithms - A review". Journal of Petroleum Science and Engineering, 208: 109575. DOI: <https://doi.org/10.1016/j.petrol.2021.109575>.
- [3] Darbor, M., Faramarzi, L., and Sharifzadeh, M. (2019). "Performance assessment of rotary drilling using non-linear multiple regression analysis and multilayer perceptron neural network". Bulletin of Engineering Geology and the Environment, 78: 1501-1513. DOI: <https://doi.org/10.1007/s10064-017-1192-3>.
- [4] Sharifinasab, M. H., Emami-Niri, M., and Masroor, M. (2023). "Developing GAN-boosted Artificial Neural Networks to model the rate of drilling bit penetration". Applied Soft Computing, 136: 110067. DOI: <https://doi.org/10.1016/j.asoc.2023.110067>.
- [5] Shaygan, K., and Jamshidi, S. (2023). "Prediction of rate of penetration in directional drilling using data mining techniques". Geoenergy Science and Engineering, 221: 111293. DOI: <https://doi.org/10.1016/j.petrol.2022.111293>.
- [6] Mirjalili, S. A., Mirjalili, S. M., and Lewis, A. (2014). "Grey Wolf Optimizer". Advances in Engineering Software, 69: 46-61. DOI: <http://dx.doi.org/10.1016/j.advengsoft.2013.12.007>.
- [7] Zhou, Y., Chen, X., Wu, M., and Cao, W. (2023). "A novel optimization method for geological drilling vertical well". Information Sciences, 634: 550-563. DOI: <https://doi.org/10.1016/j.ins.2023.03.082>.
- [8] Mahmoodzadeh, A., Nejati, H. R., Mohammadi, M., Ibrahim, H. H., Rashidi, S., and Rashid, T. A. (2022). "Forecasting tunnel boring machine penetration rate using LSTM deep neural network optimized by grey wolf optimization algorithm". Expert Systems with Applications, 209: 118303. DOI: <https://doi.org/10.1016/j.eswa.2022.118303>.
- [9] Astarita, V., Haghshenas, S. S., Guido, G., and Vitale, A. (2023). "Developing new hybrid grey wolf optimization-based artificial neural network for predicting road crash severity". Transportation Engineering, 12: 100164. DOI: <https://doi.org/10.1016/j.treng.2023.100164>.

doi.org/10.1016/j.jfranklin.2023.03.008.

- ¹ Penetration Rate
- ² Machine Learning
- ³ MetaHueristic
- ⁴ Artificial Neural Networks
- ⁵ Support Vector Machines
- ⁶ Fuzzy Logic
- ⁷ Adaptive Neuro-Fuzzy Inference System
- ⁸ Najjarpour
- ⁹ Linear Regression
- ¹⁰ Random Forest
- ¹¹ Gradient Boosting Method
- ¹² Darbor
- ¹³ Rate Of Peneration
- ¹⁴ Non-Linear Multi Regression
- ¹⁵ Multilayer Perceptron–Artificial Neural Networks
- ¹⁶ آمارهای است که میزان اثر میانجی یک متغیر در رابطه میان متغیر مستقل و متغیر وابسته را تعیین می‌کند.
- ¹⁷ Variance Accounted For
- ¹⁸ Root Mean Square Error
- ¹⁹ Rock Quality Designation
- ²⁰ Zhou
- ²¹ Mud Pit Volume
- ²² Sharifinasab
- ²³ Deep Learning
- ²⁴ Generative Adversarial Network
- ²⁵ Shaygan
- ²⁶ Jamshidi
- ²⁷ Weight On the Bit
- ²⁸ Z-Score
- ²⁹ Savitzky-Golay
- ³⁰ Mirjalili
- ³¹ Grey Wolf Optimizer
- ³² Particle Swarm Optimization
- ³³ Gravitational Search Algorithm
- ³⁴ Differential Evolution
- ³⁵ Evolutionary Programming

- [19] Duan, Y., and Yu, X. (2023). "A collaboration-based hybrid GWO-SCA optimizer for engineering optimization problems". Expert Systems with Applications, 213: 119017. DOI: <https://doi.org/10.1016/j.eswa.2022.119017>.
- [20] Lefebvre, L., Whittle, P., Lascaris, E., and Finkelstein, A. (1997). "Feeding innovations and forebrain size in birds". Animal Behaviour, 53(3): 549-560. DOI: <https://doi.org/10.1006/anbe.1996.0330>.
- [21] Hariprasad, C. H., Kayalvizhi, R., and Karthik, N. (2022). "Optimization for Position and Rating of Distributed Generating units using Harris Hawk Optimization Algorithm to Reduce Power Losses". Journal of Electrical Systems, 18(2): 205.
- [22] Yu, Z., Shi, X., Zhou, J., Chen, X., and Qiu, X. (2020). "Effective Assessment of Blast-Induced Ground Vibration Using an Optimized Random Forest Model Based on a Harris Hawks Optimization Algorithm". Applied Sciences, 10: 1403. DOI: <https://doi.org/10.3390/app10041403>.
- [23] Jinyan, Y., Yongbai, S., Yanli, C., and Xiaoying, Z. (2022). "A Novel Ensemble of Arithmetic Optimization Algorithm and Harris Hawks Optimization for Solving Industrial Engineering Optimization Problems". Journal of Machines, 10(8): 602. DOI: <https://doi.org/10.3390/machines10080602>.
- [24] فیاضی، ع.، دوست محمدی، ر.؛ ۱۴۰۱؛ "بررسی استفاده از ترسیب میکروبی کلسیم کربنات در ترمیم سنگ‌های ساختمانی". نشریه مهندسی معدن، دوره ۱۷، شماره ۵۴، ص ۶۲-۴۰. DOI: <https://doi.org/10.22034/IJME.2021.141646.1841>.
- [25] Fayyazi, A., and Doostmohammadi, R. (2022). "Investigation of the Effective Parameters of Travertine Stones Healing Using Bio-Grouting". Journal of Mining Science, 58: 1069-1083. DOI: <https://doi.org/10.1134/S1062739122060217>.
- [26] Nabavi, Z., Mirzezi, M., Dehghani, H., and Ashtari, P. (2023). "A hybrid model for Backbreak prediction using XGBoost machine learning and metaheuristic algorithms in Chadormalu iron mine". Journal of Mining and Environment, 14(2): 689-712. DOI: <https://doi.org/10.22044/jme.2023.12796.2323>.
- [27] Mirzezi Kalateh Kazemi, M., Nabavi, Z., and Khandelwal, M. (2023). "Prediction of blast-induced air overpressure using a hybrid machine learning model and gene expression programming (GEP): A case study from an iron ore mine". AIMS Geosciences, 9(2): 357-381. DOI: <https://doi.org/10.3934/geosci.2023019>.

- ³⁶ Evolution Strategy
- ³⁷ Extreme Gradient Boosting
- ³⁸ Social Spider Optimization
- ³⁹ Sine Cosine Algorithm
- ⁴⁰ Multi Verse Optimization
- ⁴¹ Moth Flame Optimization
- ⁴² Tunnel Boring Machine
- ⁴³ Mahmoodzadeh
- ⁴⁴ Long Short-Term Memory
- ⁴⁵ Light Gradient Boosting
- ⁴⁶ Harris Hawks Optimizaion
- ⁴⁷ Rotary Drilling
- ⁴⁸ Astarita
- ⁴⁹ Artificial Neural Network
- ⁵⁰ Ghalambaz
- ⁵¹ Boolean
- ⁵² Gini
- ⁵³ Louis Lefebvre
- ⁵⁴ Minimum
- ⁵⁵ Maximum
- ⁵⁶ Standard Devation
- ⁵⁷ train
- ⁵⁸ test
- ⁵⁹ Python
- ⁶⁰ overfitting