KARYERLARDA YUK OQIMINING VAQT BO‘YICHA O‘ZGARISHINI SUN’IY INTELLEKT ASOSIDA PROGNOZLASH

Raximjonov Javohir Jahongir o‘g’li
Olmaliq davlat texnika instituti
E-mail: javohirraximjonov77@gmail.com
https://doi.org/10.5281/zenodo.22861909

Annotatsiya. Mazkur maqolada karyerlarda avtotransport vositalari orqali tashiladigan yuk oqimining vaqt bo‘yicha o‘zgarishini sun’iy intellekt texnologiyalari asosida prognozlash masalasi tadqiq etilgan. Karyer transport tizimida yuk oqimining hajmi doimiy bo‘lmay, qazib olish hajmi, yuklash texnikasining unumdorligi, avtotransport vositalari soni, yo‘l uzunligi, harakat tezligi, tirbandlik, ob-havo sharoiti, texnik nosozliklar va smena rejimiga bog‘liq ravishda o‘zgarib turadi. Shu sababli an’anaviy statistik prognozlash usullaridan tashqari mashinali o‘qitish va chuqur o‘rganish algoritmlaridan foydalanish muhim ahamiyat kasb etadi. Tadqiqotda karyer yuk oqimini vaqt qatori sifatida ifodalash, ma’lumotlarni shakllantirish, xususiyatlarni tanlash, LSTM neyron tarmog‘i, Random Forest va XGBoost modellaridan foydalanish hamda prognoz natijalarini MAE, RMSE va MAPE mezonlari asosida baholash metodikasi taklif etiladi. Taklif etilayotgan yondashuv karyer transportini oldindan rejalashtirish, avtotransport vositalarini optimal taqsimlash va ishlab chiqarish jarayonining uzluksizligini ta’minlashga xizmat qiladi.

Kalit so‘zlar: karyer, yuk oqimi, avtotransport, sun’iy intellekt, mashinali o‘qitish, LSTM, Random Forest, XGBoost, vaqt qatori, prognozlash, transport oqimi, raqamli konchilik.

Аннотация. В данной статье рассматривается вопрос прогнозирования зависящих от времени изменений потока грузов, перевозимых транспортными средствами в карьерах, с использованием технологий искусственного интеллекта. В системе транспортировки грузов в карьерах объем грузопотока не постоянен, а варьируется в зависимости от объема добычи, производительности погрузочной техники, количества транспортных средств, протяженности дороги, скорости движения, загруженности дорог, погодных условий, технических неисправностей и режима работы. Поэтому, помимо традиционных статистических методов прогнозирования, большое значение имеет использование алгоритмов машинного обучения и глубокого обучения. В исследовании предлагается методология представления потока грузов в карьере в виде временного ряда, формирования данных, выбора признаков, использования нейронных сетей LSTM, моделей Random Forest и XGBoost, а также оценки результатов прогнозирования на основе критериев MAE, RMSE и MAPE. Предложенный подход позволяет планировать транспортировку в карьере заранее, оптимально распределять транспортные средства и обеспечивать непрерывность производственного процесса.

Ключевые слова: карьер, грузопоток, автомобильный транспорт, искусственный интеллект, машинное обучение, LSTM, случайный лес, XGBoost, временные ряды, прогнозирование, транспортный поток, цифровая добыча полезных ископаемых.

Abstract. This article investigates the issue of forecasting temporal variations in the flow of cargo transported by vehicles in open-pit mines using artificial intelligence technologies. Cargo flow volume in mine transport systems is not constant; it fluctuates based on extraction volume, loading equipment productivity, the number of vehicles, haulage distance, travel speed, traffic congestion, weather conditions, technical breakdowns, and shift schedules. Consequently, alongside traditional statistical forecasting methods, the use of machine learning and deep learning algorithms is of significant importance. The study proposes a methodology that involves representing mine cargo flow as a time series, data preparation, feature selection, the application of LSTM neural networks, Random Forest, and XGBoost models, and the evaluation of forecast results using MAE, RMSE, and MAPE metrics. The proposed approach facilitates the advance planning of mine transport, optimal vehicle allocation, and the assurance of continuity in the production process.

Key words: open-pit mine, cargo flow, transport, artificial intelligence, machine learning, LSTM, Random Forest, XGBoost, time series, forecasting, traffic flow, digital mining.

Kirish. Karyerlarda foydali qazilmalarni qazib olish va tashish jarayoni ko‘plab o‘zaro bog‘liq texnologik operatsiyalardan tashkil topadi. Qazib olish, yuklash, tashish va tushirish jarayonlarining o‘zaro muvofiqligi umumiy ishlab chiqarish samaradorligiga bevosita ta’sir ko‘rsatadi. Ayniqsa, avtotransport vositalari yordamida yuk tashiladigan karyerlarda yuk oqimining vaqt bo‘yicha o‘zgarishi transport tizimini boshqarishning muhim masalalaridan biridir. Karyerdagi yuk oqimini faqat o‘rtacha sutkalik yoki smenalik qiymat orqali baholash yetarli emas. Chunki bir smena davomida yuk oqimi sezilarli darajada o‘zgarishi mumkin. Masalan, yuklagichning vaqtincha to‘xtashi, avtotransport vositalarining navbatda qolishi, yo‘lning yomonlashuvi, ob-havo sharoitining o‘zgarishi yoki texnik nosozliklar transport oqimining kamayishiga olib keladi. Aksincha, yuklash punktlarining unumdorligi oshishi yoki transport vositalarining samarali taqsimlanishi yuk oqimining ko‘payishiga sabab bo‘ladi. Zamonaviy konchilikda sensorlar, GPS, bort diagnostikasi, telemetriya va dispetcherlik tizimlaridan katta hajmdagi ma’lumotlar shakllanmoqda. Ushbu ma’lumotlar sun’iy intellekt algoritmlari yordamida tahlil qilinsa, kelajakdagi yuk oqimini oldindan baholash imkoniyati paydo bo‘ladi. 2026-yilda e’lon qilingan tizimli sharhda konchilikdagi vaqt qatorlari prognozlash tadqiqotlarida LSTM, GRU, attention va Transformer kabi modellar, shuningdek, transport va haulage jarayonlari asosiy qo‘llanish yo‘nalishlaridan biri ekani qayd etilgan [1]. Ochiq karyerlarda yuk tashish unumdorligini mashinali o‘qitish asosida prognozlash bo‘yicha tadqiqotlarda katta hajmdagi ma’lumotlar va IoT texnologiyalaridan foydalanish imkoniyatlari ham ko‘rsatilgan [2]. Shu nuqtayi nazardan, karyerlarda yuk oqimining vaqt bo‘yicha o‘zgarishini oldindan prognozlash transport vositalarini optimal taqsimlash, ishlab chiqarish rejasini aniqlashtirish va transport xarajatlarini kamaytirish uchun muhim ilmiy-amaliy masala hisoblanadi.

Adabiyotlar tahlili. Karyer transport tizimlarini sun’iy intellekt asosida takomillashtirish so‘nggi yillarda konchilik muhandisligining istiqbolli yo‘nalishlaridan biriga aylandi. Tadqiqotlarda mashinali o‘qitish algoritmlari qazib olish, yuklash, tashish, ishlab chiqarish rejalashtirish va transport vositalarini boshqarish jarayonlarida qo‘llanilmoqda. Choi

va hammualliflar ochiq karyerlarda yuk tashuvchi avtotransport tizimining unumdorligini Big Data va mashinali o‘qitish asosida optimallashtirishni tadqiq qilgan. Tadqiqotda ore production prognozi uchun SVM, BPNN va Random Forest kabi modellar taqqoslangan [2].

Ochiq karyerlar bo‘yicha mashinali o‘qitish tadqiqotlarini tizimli ko‘rib chiqishda ML algoritmlarining burg‘ilash, portlatish, qazib olish, haulage va qayta ishlash bosqichlarida qo‘llanilishi tahlil qilingan. Mualliflar mashinali o‘qitish va simulyatsiyani birlashtirishni kelajakdagi muhim yo‘nalishlardan biri sifatida ko‘rsatadi [3]. Ochiq karyerda ruda ishlab chiqarishini yuk tashuvchi avtomobillar asosida prognozlash uchun chuqur neyron tarmoqlardan foydalanilgan tadqiqotda modelning kirish parametrlari sifatida transport vositalari faoliyati va operatsion vaqt ko‘rsatkichlari olingan [4].

So‘nggi tadqiqotlarda yuk tashish tizimlarining vaqt ko‘rsatkichlarini LSTM va boshqa chuqur o‘rganish algoritmlari orqali prognozlashga ham katta e’tibor qaratilmoqda. Masalan, ochiq karyer yuk avtomobillarining harakat vaqtini prognozlashda LSTM va TabTransformer kombinatsiyasidan foydalanilib, modelga transport vositasi, yuklash punkti, material turi, yo‘l sifati va ob-havo kabi omillar kiritilgan [5]. Bundan tashqari, yuk tashuvchi transport vositalarining harakat vaqtini Stacking ansamblli o‘qitish orqali prognozlash tadqiqotlari transport vositalarini intellektual dispetcherlashtirish uchun aniq prognozlarning ahamiyatini ko‘rsatadi [6]. Adabiyotlar tahlili shuni ko‘rsatadiki, mavjud tadqiqotlarning katta qismi yuk avtomobillarining harakat vaqti yoki ishlab chiqarish unumdorligini prognozlashga qaratilgan. Biroq karyerning umumiy yuk oqimining vaqt bo‘yicha dinamikasini transport, texnologik va tashqi omillarni birgalikda hisobga olgan holda prognozlash masalasi alohida tadqiqot yo‘nalishi sifatida qaralishi mumkin.

Tadqiqot metodologiyasi. Tadqiqotning asosiy maqsadi karyerda ma’lum vaqt oralig‘idan keyingi yuk oqimini sun’iy intellekt yordamida prognozlashning matematik va algoritmik modelini ishlab chiqishdan iborat.

Tadqiqotning obyekti — karyer transport tizimidagi yuk oqimi.

Tadqiqot predmeti — yuk oqimining vaqt bo‘yicha o‘zgarishiga ta’sir qiluvchi omillar va ularni sun’iy intellekt yordamida prognozlash algoritmlari.

Tadqiqotda quyidagi usullardan foydalanish taklif etiladi: vaqt qatorlari tahlili, korrelyatsion tahlil, statistik ma’lumotlarni qayta ishlash, Random Forest, XGBoost, LSTM neyron tarmog‘I, gibrid mashinali o‘qitish, MAE, RMSE va MAPE orqali model aniqligini baholash.

Karyer yuk oqimining asosiy vaqt qatori quyidagicha ifodalanadi:

$$Q_t = \frac{M_t}{\Delta t}$$

bu yerda:

Q_t — t vaqt oralig‘idagi yuk oqimi, t/soat;

M_t — mazkur vaqt oralig‘ida tashilgan yuk massasi, tonna;

Δt — vaqt oralig‘i.

Masalan, bir soat davomida 4200 tonna material tashilgan bo‘lsa:

$$Q_t=\frac{4200}{1}=4200\ t/soat$$

Keyingi davr uchun prognoz qiymati:

$$\widehat{Q}_{t+h}=f(Q_t,Q_{t-1},..,X_t)$$

ko‘rinishida aniqlanadi.

Bu yerda:

$\widehat{Q}_{t+h}$— h qadamdan keyingi prognoz yuk oqimi;

Q_t— joriy yuk oqimi;

X_t— tashqi va ichki omillar to‘plami.

Yuk oqimiga ta’sir etuvchi omillar. Karyerdagi yuk oqimi bir nechta omillarning kompleks ta’siri ostida shakllanadi.

Omil	Belgilanishi	Yuk oqimiga ta’siri
Avtotransport soni	N_t	Yuqori
Yuklash texnikasi unumdorligi	P_l	Yuqori
Yuk avtomobilining yuk ko‘tarish qobiliyati	C_t	Yuqori
Sikl vaqti	T_c	Yuqori
Yo‘l uzunligi	L	O‘rta–yuqori
Harakat tezligi	V	Yuqori
Tirbandlik darajasi	K_q	Yuqori
Yo‘l texnik holati	R	O‘rta
Ob-havo	W	O‘rta–yuqori
Texnik nosozliklar	F	Yuqori
Smena vaqti	S	O‘rta
Yuklash/tushirishdagi kutish	T_q	Yuqori

Shunday qilib, yuk oqimini faqat tarixiy $Q_t$qiymatlariga asoslanib prognozlashdan ko‘ra, ko‘p omilli modeldan foydalanish maqsadga muvofiq.

Sun’iy intellekt asosida prognozlash modeli. Tadqiqotda uch bosqichli prognozlash tizimini taklif qilish mumkin.

1-bosqich. Ma’lumotlarni yig’ish. Ma’lumotlar quyidagi manbalardan olinadi:

GPS → IoT → bort diagnostikasi → dispetcherlik tizimi → ishlab chiqarish ma’lumotlari → ob-havo ma’lumotlari.

Har bir transport vositasi bo‘yicha quyidagi parametrlar shakllantiriladi:

$$X_t=[N,V,T_c,L,Q_l,K_q,W,R,F]$$

2-bosqich. Ma’lumotlarni tayyorlash. Ma’lumotlarda mavjud bo‘lishi mumkin bo‘lgan: bo‘sh qiymatlar, takroriy yozuvlar, keskin anomal qiymatlar, sensor xatolari, vaqt belgilaridagi nomuvofiqliklar aniqlanadi va qayta ishlanadi.

So‘ngra parametrlar normalizatsiya qilinadi:

$$X'=\frac{X-X_{min}}{X_{max}-X_{min}}$$

3-bosqich. Prognozlash. Prognozlash uchun uchta modelni parallel sinovdan o‘tkazish mumkin:

Random Forest → XGBoost → LSTM

Keyinchalik eng yuqori aniqlikni ko‘rsatgan model yoki gibrid model ishlab chiqarish tizimiga integratsiya qilinadi.

Lstm modeli asosida yuk oqimini prognozlash. Karyer yuk oqimi vaqt bo‘yicha ketma-ket shakllanadigan ma’lumot bo‘lganligi sababli LSTM modeli ushbu masala uchun istiqbolli algoritmlardan biridir. LSTM tarmog‘i oldingi vaqt oralig‘idagi ma’lumotlarni saqlash orqali kelajakdagi qiymatni prognozlash imkonini beradi.

Umumiy ko‘rinishda:

$$\widehat{Q}_{t+1}=LSTM(Q_t,Q_{t-1},\ldots,Q_{t-k+1}X_t)$$

Bu yerda k— model foydalanadigan vaqt oynasi.

Masalan, model oxirgi 6 soatdagi ma’lumotlardan foydalanib, keyingi 1 soat uchun yuk oqimini prognoz qilishi mumkin:

$$[Q_{t-5},Q_{t-4},Q_{t-3},Q_{t-2},Q_{t-1},Q_t]\rightarrow\widehat{Q}_{t+1}$$

Agar 24 soatlik prognoz talab qilinsa, model bir necha bosqichli prognozlash rejimida ishlashi mumkin. Xgboost va random forest modellaridan foydalanish. LSTM bilan bir qatorda daraxtlarga asoslangan algoritmlardan foydalanish modelning turli omillar ta’sirini aniqlash imkoniyatini oshiradi.

XGBoost modeli:

$$\widehat{Q}_t=\sum_{m=1}^{M} f_m\,(X_t)$$

ko‘rinishida ifodalanadi.

Random Forest esa bir nechta qaror daraxtlari natijasini birlashtiradi.

Ushbu modellar quyidagi holatlarda ayniqsa foydali: yuk oqimining keskin o‘zgarishi, yo‘l sharoitining o‘zgarishi, transport vositalari sonining o‘zgarishi, texnik nosozliklar, ob-havo ta’siri, yuklash punktlaridagi navbatlar. Choi va hammualliflar tomonidan ochiq karyerlardagi haulage tizimi uchun mashinali o‘qitish usullari qo‘llanilgan va turli ML modellarining ishlab chiqarish prognozidagi imkoniyatlari taqqoslangan [2].

Gibrid sun’iy intellekt modeli. Tadqiqot uchun quyidagi gibrid modelni taklif qilish mumkin:

$$Hybrid=\alpha LSTM+\beta XGBoost+\gamma RF$$

bu yerda:

$LSTM$— vaqt qatori komponenti;

$XGBoost$— nolinear omillarni aniqlash komponenti;

RF— ko‘p omilli klassifikatsiya va regressiya komponenti;

α,β,γ— modellar og‘irlik koeffitsiyentlari.

Og‘irliklar validation to‘plamidagi prognoz xatosiga qarab aniqlanishi mumkin. Bunday gibrid yondashuvning afzalligi shundaki, LSTM vaqt bo‘yicha bog‘liqlikni, XGBoost va Random Forest esa tashqi omillarning nolinear ta’sirini modellashtiradi.

Tadqiqot natijalari va muhokama. Ushbu tadqiqotning amaliy qismi real karyer ma'lumotlari mavjud bo'lganda tarixiy GPS, transport, yuklash va ishlab chiqarish ma'lumotlari asosida bajarilishi lozim. Quyidagi jadvaldagi raqamlar maqola metodikasini namoyish etish uchun shartli modellashtirish qiymatlari bo'lib, real karyer tajribasi natijasi sifatida talqin qilinmasligi kerak.

Jadval 1. Yuk oqimini prognozlash uchun namunaviy ma'lumotlar

Vaqt	Avtotransport soni	O'rtacha sikl, min	Yuk oqimi, t/soat
08:00	18	32	4050
09:00	20	30	4380
10:00	22	29	4720
11:00	23	28	4950
12:00	21	31	4450
13:00	19	34	4010
14:00	22	30	4600
15:00	24	27	5150

Jadvaldan ko'rinadiki, transport vositalari sonining ko'payishi har doim ham yuk oqimining proporsional ravishda oshishini anglatmaydi. Masalan, 12:00–13:00 oralig'ida sikl vaqtining ortishi natijasida yuk oqimi kamayishi mumkin. Bu holat prognoz modeliga faqat avtotransport sonini emas, balki sikl vaqti, yo'l holati, navbat, yuklash vaqti va boshqa parametrlarni ham kiritish zarurligini ko'rsatadi.

Prognoz aniqligini baholash. Model sifatini quyidagi mezonlar orqali baholash mumkin.

MAE

$$MAE=\frac{1}{n}\sum_{i=1}^{n} \mid Q_i-\widehat{Q}_i \mid$$

MAE prognoz qiymatining haqiqiy qiymatdan o'rtacha mutlaq og'ishini ko'rsatadi.

RMSE

$$RMSE=\sqrt{\frac{1}{n}\sum_{i=1}^{n}(Q_i-\widehat{Q}_i)^2}$$

RMSE katta xatolarga MAEga nisbatan kuchliroq ta'sirchan.

MAPE

$$MAPE=\frac{100}{n}\sum_{i=1}^{n}\left|\frac{Q_i-\widehat{Q}_i}{Q_i}\right|$$

MAPE prognoz xatosini foizda ifodalash imkonini beradi.

Yuk oqimining dinamik o'zgarishini aniqlash. Sun'iy intellekt modelining asosiy afzalliklaridan biri yuk oqimining nafaqat joriy holatini, balki uning kelajakdagi tendensiyasini aniqlash imkoniyatidir.

Masalan:

$$Q_{t+1}>Q_t$$

bo'lsa, yuk oqimining oshishi kutiladi.

Agar:

$$Q_{t+1} < Q_t$$

bo‘lsa, yuk oqimining kamayishi prognoz qilinadi.

Agar:

$$| Q_{t+1} - Q_t | > \delta$$

bo‘lsa, tizim yuk oqimining keskin o‘zgarishi haqida dispetcherga ogohlantirish yuborishi mumkin. Bu mexanizm karyer transportini reaktiv emas, balki proaktiv boshqarish imkonini beradi.

Tadqiqot natijalari konseptual jihatdan shuni ko‘rsatadiki, karyer yuk oqimini prognozlashda faqat tarixiy yuk hajmidan foydalanish yetarli emas. Transport vositalarining soni, sikl vaqti, yo‘l uzunligi, yo‘lning texnik holati, yuklash va tushirish punktlaridagi kutish vaqti, ob-havo hamda texnik nosozliklar birgalikda hisobga olinishi kerak. Ayniqsa, yuk oqimining vaqt qatori tabiatga ega ekanligi LSTM kabi ketma-ketliklarni o‘rganuvchi algoritmlardan foydalanishni asoslaydi. Zamonaviy tadqiqotlarda ham konchilikdagi vaqt qatorlari uchun LSTM/GRU va attention asosidagi modellar istiqbolli yo‘nalish sifatida qayd etilgan [1]. Boshqa tomondan, XGBoost va Random Forest kabi modellar tashqi omillarning yuk oqimiga ta’sirini aniqlashda foydalidir. Shu sababli gibrid model karyer transport tizimining murakkab nolinear xususiyatlarini ifodalash imkoniyatini oshirishi mumkin. Prognozlash modelini real ishlab chiqarish tizimiga joriy etishda modelning aniqligi bilan bir qatorda uning barqarorligi, tushuntiriluvchanligi, boshqa karyerlarga ko‘chiriluvchanligi va noaniqlikni baholash imkoniyati ham muhim hisoblanadi. 2026-yilgi tizimli sharhda aynan transferability, external validation va uncertainty quantification konchilikdagi vaqt qatori prognozlashning muhim muammolari sifatida ko‘rsatilgan [1].

Xulosa. Karyerlarda yuk oqimining vaqt bo‘yicha o‘zgarishini oldindan prognozlash transport tizimining samarali ishlashini ta’minlashda muhim ahamiyatga ega. Yuk oqimi qazib olish hajmi, avtotransport vositalari soni, yuklash texnikasi unumdorligi, sikl vaqti, yo‘l sharoiti, tirbandlik, ob-havo va texnik nosozliklar kabi ko‘plab omillar ta’sirida shakllanadi. Tadqiqotda karyer yuk oqimini sun’iy intellekt asosida prognozlashning ko‘p bosqichli modeli taklif qilindi. Model GPS, IoT, bort diagnostikasi va ishlab chiqarish tizimlaridan olingan ma’lumotlarni birlashtirishga asoslanadi. Prognozlashda LSTM, Random Forest va XGBoost algoritmlaridan foydalanish, ularning natijalarini MAE, RMSE va MAPE mezonlari orqali baholash taklif etildi. LSTM modeli yuk oqimining vaqt bo‘yicha bog‘liqligini aniqlashga, XGBoost va Random Forest esa tashqi omillarning nolinear ta’sirini hisobga olishga xizmat qiladi. Ushbu modellarni gibrid tizimga birlashtirish karyer transport tizimining kelajakdagi yuk oqimini yanada kompleks baholash imkonini beradi. Taklif etilayotgan prognozlash tizimi asosida avtotransport vositalarini oldindan taqsimlash, yuklash punktlaridagi navbatlarni kamaytirish, transport yo‘nalishlarini optimallashtirish va ishlab chiqarish rejasini dinamik ravishda tuzatish mumkin. Kelgusidagi tadqiqotlarda O‘zbekiston karyerlarining real GPS, tonnaj, sikl vaqti, yo‘l holati, ob-havo va transport vositalari bo‘yicha ma’lumotlari asosida LSTM, XGBoost, Transformer va gibrid modellarni eksperimental taqqoslash maqsadga muvofiq. Bunda modelning RMSE, MAE, MAPE va R^2 ko‘rsatkichlari bilan bir qatorda uning real ishlab chiqarish samaradorligiga ta’siri ham baholanishi lozim.

Foydalanilgan adabiyotlar

1. Choi, Y., Nguyen, H., Bui, X.-N., Nguyen-Thoi, T. Optimization of haulage-truck system performance for ore production in open-pit mines using big data and machine learning-based methods. *Resources Policy*, 2022, Vol. 76, 102522. DOI: 10.1016/j.resourpol.2021.102522.
2. Liu, S., Liu, L., Kozan, E., Corry, P., Masoud, M., Li, X. Machine learning for open-pit mining: a systematic review. *International Journal of Mining, Reclamation and Environment*, 2025, Vol. 39, No. 1, pp. 1–39. DOI: 10.1080/17480930.2024.2362579.
3. Deep Neural Network for Predicting Ore Production by Truck-Haulage Systems in Open-Pit Mines. *Applied Sciences*, 2020, Vol. 10, No. 5, 1657.
4. Prediction of open-pit mine truck travel time based on LSTM-TabTransformer. *Scientific Reports*, 2025. DOI: 10.1038/s41598-025-88543-x.
5. Underground mine truck travel time prediction based on stacking integrated learning. *Engineering Applications of Artificial Intelligence*, 2023, Vol. 120, 105873. DOI: 10.1016/j.engappai.2023.105873.
6. Zhang, L., Shan, W., Zhou, B., Yu, B. A dynamic dispatching problem for autonomous mine trucks in open-pit mines considering endogenous congestion. *Transportation Research Part C: Emerging Technologies*, 2023, Vol. 150, 104080. DOI: 10.1016/j.trc.2023.104080.
7. Deep Reinforcement Learning based real-time open-pit mining truck dispatching system. *Computers & Operations Research*, 2025, Vol. 173, 106815.
8. Noriega, R., Pourrahimian, Y. A systematic review of artificial intelligence and data-driven approaches in strategic open-pit mine planning. *Resources Policy*, 2022, 102727. DOI: 10.1016/j.resourpol.2022.102727.
9. Prediction of Ore Production in a Limestone Underground Mine by Combining Machine Learning and Discrete Event Simulation Techniques. *Minerals*, 2023, Vol. 13, No. 6, 830. DOI: 10.3390/min13060830.
10. Decision Making applied to Shift Change in Stochastic Open-pit Mining Truck Dispatching. *IFAC-PapersOnLine*, 2013, Vol. 46, No. 16, pp. 34–39. DOI: 10.3182/20130825-4-US-2038.00090.
11. Hazrathosseini, A., Moradi Afrapoli, A. Transition to intelligent fleet management systems in open pit mines: A critical review on application of reinforcement-learning-based systems. *Mining Technology*, 2024, Vol. 133, No. 1.