

Inteligência artificial na mineração: Principais aplicações**Artificial intelligence in mining: Main applications****Leandro de Vilhena Costa¹****Jonatas Franco Campos da Mata²****Paulo Elias Carneiro Pereira³****Ricardo Alves da Silva⁴**

444

Resumo: A Inteligência Artificial (IA) está transformando a indústria da mineração, proporcionando melhorias significativas em eficiência, segurança, sustentabilidade e tomada de decisões. A capacidade da IA de processar grandes volumes de dados, identificar padrões e tomar decisões rápidas e precisas está impulsionando a inovação e melhorando a forma como as operações são realizadas. A aplicação dessas tecnologias avançadas têm o potencial de impulsionar a indústria de mineração para um futuro mais inteligente e responsável. Portanto, dentro desse contexto, o presente trabalho ocupa-se em elencar as principais áreas operacionais da Engenharia de Minas, que são: Pesquisa Mineral, Perfuração e Desmonte de Rocha, Transporte e Carregamento, as três fases supracitadas corroboram para um bom planejamento de lavra, o qual deve ser elaborado com o máximo de segurança financeira e operacional, uma vez que erros operacionais resultam em ônus para a empresa. Com a intenção de minimizar esses erros, o setor de mineração vem procurando implementar novas tecnologias que sejam capazes de otimizar as fases operacionais da mineração sem, necessariamente, ampliar seus custos. É dentro desse ambiente, ou seja, da otimização das operações mineiras, que entra a IA, e mais precisamente o Aprendizado de Máquina, sendo este último responsável pelo grande avanço das implementações tecnológicas no setor da mineração. Sendo assim, o objetivo maior desse artigo é mostrar o avanço tecnológico alcançado pelo setor da mineração, por meio do advento da IA.

¹ Engenheiro de Minas. Doutor em Engenharia Mineral pela Universidade Federal de Ouro Preto. Professor do Curso de Engenharia de Minas da Universidade Federal de Catalão. E- mail: leandro_vilhena@ufcat.edu.br

² Engenheiro de Minas. Doutor em Tecnologia Mineral pela Universidade Federal de Minas Gerais. Professor do Curso de Engenharia de Minas da Universidade Federal dos Vales do Jequitinhonha e Mucuri. E- mail: jonatas.mata@ufvjm.edu.br

³ Engenheiro de Minas. Mestre em Modelagem e Otimização pela Universidade Federal de Goiás. Professor do Curso de Engenharia de Minas da Universidade Federal de Catalão. E- mail: paulo_elias_carneiro@ufcat.edu.br

⁴ Engenheiro de Minas. Doutor em Ciência da Computação pela Universidade Federal de Pernambuco. Professor do Curso de Engenharia de Minas da Universidade Federal dos Vales do Jequitinhonha e Mucuri. E- mail: ricardo.silva@ufjvm.edu.br

Recebido em 29/10/2023**Aprovado em: 24/11/2023****Sistema de Avaliação: Double Blind Review**

Palavras-chave: Inteligência Artificial, Indústria da Mineração, Aprendizado de Máquina.

Abstract: Artificial Intelligence (AI) is transforming the mining industry, providing significant improvements in efficiency, safety, sustainability and decision-making. AI's ability to process large volumes of data, identify patterns and make fast, accurate decisions is driving innovation and improving the way operations are carried out. The application of these advanced technologies has the potential to propel the mining industry towards a smarter, more responsible future. Therefore, within this context, the present work is concerned with listing the main operational areas of Mining Engineering, which are: Mineral Research, Drilling and Rock Dismantling, Transport and Loading, the three phases mentioned above contribute to good mining planning, which must be prepared with maximum financial and operational security, since operational errors result in costs for the company. With the intention of minimizing these errors, the mining sector has been seeking to implement new technologies that are capable of optimizing the operational phases of mining without necessarily increasing costs. It is within this environment, that is, the optimization of mining operations, that AI, and more precisely Machine Learning, comes into play, the latter being responsible for the great advancement of technological implementations in the mining sector. Therefore, the main objective of this article is to show the technological advancement achieved by the mining sector, through the advent of AI.

Keywords: Artificial Intelligence, Mining Industry, Machine Learning.

1 Introdução

A inteligência artificial (IA) tem percorrido um extenso caminho desde sua concepção na década de 1950. Segundo Schunck (2023) a inteligência artificial se tornou uma parte integral de nossas vidas, graças ao surgimento de tecnologias como reconhecimento facial, carros autônomos, assistentes de voz, chatbots, automação industrial, algoritmos em mídias sociais e aprendizado de máquinas. A IA é uma ferramenta com a capacidade de solucionar problemas complexos e executar tarefas repetitivas, sendo amplamente empregada em empresas de praticamente todos os setores, com foco especial nos campos de tecnologia, finanças, saúde e transporte, sempre visando aprimorar processos e produtos. Na década de 1980, a aplicação da IA na mineração continuou a evoluir, com o uso de sistemas especialistas e o aprimoramento de técnicas de análise de dados geológicos.

Os acidentes na mineração segundo Zonta (2023), em 2016, superaram até três vezes a média nacional. Considerando que segurança é uma das regras de ouro adotadas na mineração, fica evidente a importância do uso da inteligência artificial para sanar essas questões.

Ainda, a utilização de IA no setor mineral pode fornecer garantia quanto aos recursos disponíveis e suporte técnico para a execução das atividades de forma sustentável, promovendo um crescimento sustentável da sociedade e da economia (GAO et al., 2023).

Neste trabalho é apresentada uma revisão das aplicações de IA na indústria mineral, explorando o emprego da IA na operação de mina, exploração mineral, planejamento de mina, perfuração e desmonte de rochas, e segurança de mina.

As análises realizadas poderão fornecer suporte para entender a forma como a IA vem sendo empregada em diversas atividades e/ou etapas de um projeto de mineração, o que será útil para a disseminação da IA em diversos projetos mineiros.

2 Metodologia

O trabalho consistiu de pesquisa acerca das aplicações de IA na indústria mineral. Foram realizadas pesquisas em diversas bases de dados de periódicos, livros, dissertações e teses. Não foram consideradas restrições quanto ao ano da publicação, com o propósito de abranger uma maior variedade de aplicações.

A análise da utilização da IA na mineração abrangeu as seguintes etapas e/ou atividades: (1) Operação de mina; (2) perfuração e desmonte de rochas; (3) exploração mineral e planejamento de mina, e; (4) segurança de mina.

3 Resultados e Discussões

Nesta seção estão abordadas as aplicações de IA na mineração, cujos tópicos estão agrupados de acordo com as áreas analisadas. Serão abordadas as principais aplicações da inteligência artificial na mineração nas áreas de Exploração Mineral e Planejamento de Mina, Perfuração e Desmonte de Rochas, Operação de Mina e Segurança.

3.1 Exploração Mineral e Planejamento de Mina

No que se refere à etapa de exploração mineral, a qual abrange a prospecção e a pesquisa mineral, diversas abordagens baseadas em métodos de aprendizado de máquina têm sido desenvolvidas. Com relação à prospecção mineral, Zou et al. (2022) utilizaram o método de Florestas Aleatórias (FA) e um algoritmo de rede neural profunda (RNP) para diferenciar

zircões de rochas ígneas associadas à ocorrência de depósitos de cobre pórfiro daquelas não mineralizadas. O modelo obtido foi capaz de identificar a ocorrência de mineralização de cobre pórfiro com uma taxa de acertos média de 90 %, e com baixa ocorrência de falsos positivos, independentemente do contexto geotectônico.

Baseando-se também em uma abordagem de RNP, Li, Chen e Xiang (2020) utilizaram o algoritmo AlexNet, uma Rede Neural Convolucional (RNC), para prever a ocorrência de depósitos de manganês na região de Hunan e Guizhou, China.

A partir da otimização dos hiperparâmetros do modelo, foi possível obter uma taxa de acertos de 86,21%. A aplicação do modelo para predição de ocorrências de mineralização de manganês na área permitiu identificar cinco alvos com elevada probabilidade de ocorrência de mineralização, o que poderá guiar futuras campanhas de amostragem.

Combinando análise fractal e RNC, Fu et al. (2023) estudaram a ocorrência de ouro da área de Qixia, China, onde há um elevado número de depósitos polimetálicos de ouro. Os modelos utilizaram informações de anomalias geoquímicas de ouro em sedimentos de corrente, distribuição espacial de ocorrências de ouro, mapas de estruturas controladoras da mineralização aurífera, e dados de alteração de rochas. A combinação das duas técnicas permitiu a identificação de cinco alvos potenciais para investigação detalhada.

Com o propósito de identificar alvos potenciais no cinturão metalogênico de Qin-hang, Gao et al. (2023) propuseram a utilização do modelo de RNP baseado na Estrutura de Atenção a Características de Multiescala (EACM), o qual poderia apresentar melhores resultados com dados geológicos escassos. Apesar da quantidade limitada de informações, o modelo proposto foi capaz de identificar 100 % dos depósitos já conhecidos na área. A partir do mapa de previsão de potenciais alvos foi possível estabelecer 15 alvos para pesquisa.

A implantação de métodos capazes de fornecer previsões confiáveis em condições de pouca disponibilidade de informações também foi tratada por Carranza e Laborte (2014), os quais propuseram a utilização de um modelo de FA para prever a ocorrência de depósitos de cobre pórfiro na área de Abra, Filipinas.

A partir da utilização de 10 variáveis preditoras, algumas com valores ausentes, foi possível estabelecer um mapa de probabilidade de ocorrência de depósitos.

Para obter uma quantidade suficiente de dados para treinamento de uma RNC em um estudo de prospecção de depósitos de ouro, Yang et al. (2022) propuseram a implantação de um algoritmo de aumento de dados (AD). As informações geológicas foram utilizadas para a

geração de possíveis amostras, as quais foram também alimentadas em três redes neurais: LeNet, AlexNet e VggNet.

Os resultados mostraram que o modelo obtido pela LeNet forneceu os melhores resultados, com uma taxa de acertos de 91,38%, além de prever com sucesso 81,38% dos depósitos de ouro conhecidos dentro de 18,6% da área de estudo. Desta forma, mesmo em condições de pouca disponibilidade de informações, foi possível estabelecer alvos potenciais com alta taxa de acertos.

Pesquisas também têm sido desenvolvidas no que se refere à aplicação de aprendizado de máquina para a estimativa de teores. Kaplan e Topal (2020) propuseram a utilização de uma abordagem constituída por dois modelos, um baseado em uma rede de k-vizinhos próximos (kVP) e outro baseado em uma Rede Neural *Feed-Forward* (RNFF).

O modelo kVP foi utilizado na primeira fase para a estimativa dos tipos de rocha e alterações nos locais não amostrados, resultando no modelo geológico, o qual foi a base para a estimativa dos teores de ouro a partir da RNFF. Os resultados obtidos foram promissores, o que demonstra que a abordagem poderia ser utilizada para estimativa de teores.

Uma RNFF de múltiplas camadas foi utilizada por Tsae, Adachi e Kawamura (2023) para estimar teores de cobre baseando-se em informações de litologia, alteração, coordenadas espaciais (X, Y e Z) e parâmetros das sondagens (direção e inclinação).

As estimativas obtidas pela RNFF foram comparadas com outros modelos de aprendizado de máquina: regressão linear, kVP, FA, *light gradient boosting machine*, e regressor de árvore extra. Os resultados mostraram que a abordagem proposta foi superior a todos os demais modelos testados, atingindo um coeficiente de correlação de 0,765.

Uma investigação acerca da aplicação de RNFF de múltiplas camadas foi feita também por Jafrasteh, Fathianpour e Suárez (2018), os quais aplicaram uma rede *multilayer perceptron* (MLP) para a estimativa de teores de cobre em um depósito de cobre pórfiro.

A RNFF foi comparada com dois métodos de aprendizado de máquina (FA e processo Gaussiano) e com dois métodos geoestatísticos (Krigagem Ordinária e Krigagem Indicadora). Os resultados mostraram que o método do processo Gaussiano apresentou os melhores resultados, seguido pela Krigagem Indicadora.

Aplicações de aprendizado de máquina no planejamento de mina também têm sido objeto de estudo nas últimas décadas. Para facilitar o manuseio de dados geológicos em aplicações de aprendizado de máquina no *software* VulcanTM, Kapageridis e Triantafyllou (2011) desenvolveram uma interface de redes neurais denominada LavaNet, capaz de realizar

tarefas inerentes ao planejamento de mina a partir de informações de modelos de blocos e de furos de sondagem. Conforme Kapageridis e Triantafyllou (2011), o ambiente possui suporte para os seguintes métodos: Rede de Funções de Bases Radiais (RFBR), *Perceptrons* de Múltiplas Camadas (PMC) e Mapas Auto Organizáveis (MAO).

Com o propósito de reduzir das diferenças entre modelos utilizados para os planejamentos de mina de longo e de curto prazos, Olmos-de-Aguilera, Campos e Risso (2023) efetuaram um estudo comparativo entre três RNPs: RNFF, RNC de uma dimensão, e modelo de memória de curto e longo prazo (*Long Short-Term Memory* – LSTM).

Os modelos foram utilizados para a estimativa de teores de cobre. Os resultados obtidos após a otimização dos hiperparâmetros dos modelos mostraram que houve uma redução dos erros de estimativa, em que o modelo baseado em LSTM forneceu o melhor resultado, com uma redução do Erro Quadrático Médio (EQM) de 39,99%, seguido pela RNC de uma dimensão (36,99%) e pela RNFF (20,63 %).

Uma metodologia baseada em RNC foi desenvolvida por Choros et al. (2022) para diferenciar o minério de estéril na operação de mina. Imagens hiperespectrais foram obtidas de um protótipo de sistema de escaneamento constituído de câmeras espectrais e um sistema de posicionamento.

Amostras coletadas de uma mina de ouro foram analisadas para obter teores de ouro e escaneadas por câmeras espectrais. As informações obtidas foram utilizadas para criar um banco de dados rotulado, o qual foi alimentado em um modelo de RNC.

Os resultados encontrados mostraram que o modelo foi capaz de diferenciar minério de estéril a partir de imagens da bancada a ser lavrada com boa taxa de acertos. Apesar da necessidade de realização de estudos adicionais (CHOROS et al., 2022), há evidências de que o método possa ser utilizado para auxiliar na escavação reduzindo a diluição.


3.2 Perfuração e Desmonte de Rochas

Segundo Gama (1998), usualmente as metodologias que efetuam o desmonte de rochas por meio de perfuração e aplicação de explosivos são mais eficazes e baratas para fragmentar as rochas do que os métodos mecânicos. Entretanto, a eficiência energética é muito baixa. Sabe-se que, aproximadamente, entre 85 % e 95 % da energia liberada é perdida para o ambiente, acarretando os seguintes impactos indesejáveis: vibrações do terreno, fraturamento da formação rochosa remanescente, ultra-lançamento de blocos, geração de particulados e ruídos acima do

permitido. Torres et al. (2018) observam serem frequentes as reclamações de pessoas das comunidades do entorno das minerações, em função de pressão acústica excessiva, vibrações estruturais de casas e prédios e, por vezes, danos à propriedade privada.

Uma alternativa para o monitoramento das vibrações ocorridas em desmontes de rochas e seu consequente controle é a utilização das Redes Neurais Artificiais (RNA). Esta tecnologia é uma das subáreas da Inteligência Artificial, sendo capaz de processar informações de modo semelhante aos neurônios presentes no cérebro (COSTA, 2019). McCulloch e Pitts (1943) desenvolveram a modelagem matemática utilizada pelas RNAs, reproduzindo a capacidade de aprendizado do cérebro humano (Figura 1).

Figure 1 -Representação do neurônio artificial de forma análoga ao neurônio humano



Fonte: Souza (2020)

Cruz (2022) propôs uma metodologia para previsão e controle das vibrações utilizando RNAs. Para isso, foram instalados sismógrafos em diversos locais da mina de minério de ferro Conceição da empresa VALE S.A. em Itabira - MG, além de barragens de rejeito e pontos situados na comunidade externa. Efetuou-se um amplo levantamento de dados de vibração. Este banco de dados permitiu o treinamento de redes neurais, que trouxeram previsões assertivas de vibrações causadas pelos desmontes de rochas. A manipulação dos parâmetros operacionais durante a etapa do plano de fogo permitiu a definição de limites seguros para as operações, reduzindo-se assim as vibrações e danos às estruturas geotécnicas, além de minimizar os

incômodos à comunidades do entorno. A Figura 2 exibe alguns sismógrafos utilizados neste trabalho.

Figure 2 - Sismógrafos utilizados para análise de vibrações de desmorte por explosivos



Fonte: TORRES, COSTA e SOUSA (2021)

O Índice de Blastabilidade ou Blastability Index (BI) é um fator que mede a resistência da rocha no desmorte por explosivos. A avaliação do BI depende de parâmetros de projeto do desmorte, como: características do explosivo, tipo e dimensões da malha de perfuração, densidade e grau de fraturamento da rocha, dentre outros (Khorzoughi, 2013). Moomivand e Vandyousefi (2020) caracterizaram o BI através de Inteligência Artificial, utilizando redes neurais. Azimi et al. (2010), por sua vez, aplicou modelos fuzzy para prever a *blastability*, modelando e solucionando aspectos geomecânicos do maciço rochoso.

3.3 Operação de Mina

3.3.1 Caminhões Autônomos

Segundo Agricola *et al* 1950, os processos de mineração modernos envolvem a prospecção de corpos de minério, a análise do potencial de lucro de uma mina proposta, a extração dos materiais desejados e a recuperação ou restauração final da área lavrada após o fechamento da mina. As operações mineiras podem criar um impacto ambiental negativo, tanto durante a atividade mineira como após o encerramento da mina. Portanto, dentro desse contexto, a tecnologia da informação vem ganhando um espaço bastante significativo no setor da mineração.

A mineração desempenha um papel importante na economia mundial. Com a procura de zero vítimas e a entrada numa era de escassez de trabalhadores qualificados nos países desenvolvidos, estimou-se que até 2020, 50 % das principais empresas mineiras na Austrália, na Europa e nas Américas estariam utilizando os produtos autônomos, e algumas minas decidiram adotar totalmente equipamentos de mineração autônomos.

De acordo com Gao *et al.* 2019, a inteligência artificial, a aprendizagem automática e as tecnologias autônomas na indústria mineira começaram há mais de uma década com caminhões mineiros autônomos (AMT - *Autonomous Mining Trucks*) ou sistemas de transporte autônomos (AHS - *Autonomous Haulage Systems*). As suas aplicações tiveram um impacto bastante significativo, no que concerne às perspectivas tecnológicas, econômicas e ambientais da indústria mineira. Esse impacto é percebido, na indústria da mineração, nos seguintes aspectos:

1. Redução de custos
2. Eficiência
3. Aumento da Produtividade
4. Redução da exposição dos trabalhadores a condições perigosas
5. Produção contínua
6. Segurança aprimorada

Os caminhões de mineração autônomos (AMT) são veículos pesados que trafegam nas dependências da mineração, sem a necessidade de motorista, os quais podem perceber o ambiente e trafegar nas vias de acesso da mina sem qualquer intervenção humana. Os AMTs reduzem a vulnerabilidade ao risco de contato do equipamento com equipamentos auxiliares ou veículos manuais equipados (EMV - *Equipped Manual Vehicles*). Dentro do AMT todos os dados obtidos são compilados para que o *software* possa tomar uma decisão adequada. Calcular a velocidade máxima permitida a um equipamento próximo ou o tempo estimado para a quebra de um AMT são decisões possíveis. Determinar a localização exata de cada AMT e EMV é obrigatório para evitar acidentes. Os sistemas inteligentes que executam AMTs incluem Frontrunner para Komatsu e Command para Caterpillar. Para se comunicar, os AMTs contam com:

1. Comunicações sem fio;

2. Sistemas de prevenção/detecção de objetos;
3. Sistema de Posicionamento Global (GPS).

3.3.2 Aprendizagem de Máquina Aplicada aos Caminhões Autônomos


De acordo com Severyn et al. (2015), o maior desafio para a implementação de AMTs nas dependências da mina consiste em prevenir acidentes e tomar decisões precisas em tempo real. Portanto, para aumentar o desempenho nas operações mineiras se faz necessário, segundo Li et al. (2018), a aplicação de RNCs, sendo este um algoritmo que tem a capacidade de processar grandes volumes de dados, capaz de identificar padrões nos dados, selecionar as características (*features*) mais importantes, e efetuar previsões a partir dos padrões identificados.

453

3.3.3 Arquitetura de Uma Rede Neural Convolucional

Uma RNC consiste de uma arquitetura na qual existe uma camada de entrada, camadas ocultas e uma camada de saída. Nesse tipo de rede, as camadas ocultas incluem uma ou mais camadas que realizam convoluções. Normalmente, isso inclui uma camada que executa um produto escalar do kernel de convolução com a matriz de entrada da camada. Em outras palavras, as convoluções realizam o reconhecimento ou extração de características do objeto que será analisado, que no caso dos caminhões, são, principalmente, as imagens. A Figura 3 ilustra uma RNC típica.

Figure 3 - RNC genérica



Fonte: RAFAEL SAKURAI (2017)

3.3.4. Sistema de Despacho

Um dos problemas que a indústria da mineração lida diariamente, de acordo com Meech (2006) é como monitorar, controlar e investigar o dia a dia das operações dos equipamentos de produção, de forma a minimizar os custos operacionais. Portanto, para alcançar esse objetivo as empresas recorrem a um sistema de despacho, o qual tem a finalidade de resolver um problema que consiga alocar, de forma eficiente, os equipamentos de operação, que inclui, principalmente, os caminhões e as escavadeiras.

Dado que o sistema de despacho de uma mina está totalmente correlacionado com as operações de lavra, fica claro que implementação dos caminhões autônomos é de fundamental importância para otimizar o tempo de carregamento e transporte e com isso, evitar as perdas de produção indesejadas, além de oferecer acompanhamento do tempo de manobra, carregamento e báscula, número de viagens, distância média de transporte (DMT), produtividade e monitoramento de filas, ou seja, com a ajuda dos algoritmos de AM será factível encontrar um modelo de operacional que se ajuste às demandas de produção desejadas.

3.4 Segurança de Mina


Os acidentes na mineração segundo Zonta (2023), em 2016, superaram até três vezes a média nacional. Desde então, tem sido uma regra de ouro a segurança nas mineradoras. Diversas áreas têm adotado mecanismos e uso da inteligência artificial.

Uma das principais aplicações na segurança de mina seria a detecção de fadiga dos motoristas de caminhões fora de estrada. De acordo com o IBRAM (2022), o sistema conta com os mais avançados *softwares* de IA para detecção de fadiga do mundo, o que, além de dar segurança para os gestores da mina, gera uma mudança no comportamento dos operadores, uma vez que estes começam a entender melhor seus padrões de sono. Estimula os colaboradores a criar hábitos de dormir em determinados horários, o que permite estar mais dispostos durante o trabalho.

A empresa Usiminas adotou essa tecnologia em suas minas na região de Itatiaiuçu. Segundo IBRAM (2022), em um ano de uso não houve registro de acidentes causados por sono e fadiga entre os 114 motoristas que operam caminhões fora-de-estrada. A implementação foi bem sucedida, atingindo o número recorde de 80 mil horas. Durante o período avaliado foi registrada uma redução de 72 % na frequência de alertas de sonolência gerados por operadores de caminhões fora-de-estrada.

Uma outra aplicação seria uso de sensores de presença nos caminhões fora de estrada que detectam objetos e pessoas em seu trajeto. Conforme Zaparolli (2020), na mina de Brucutu (VALE) os caminhões são dotados de sensores desses tipos de dispositivos. Os caminhões param de se mover quando encontram obstáculos, até que o caminho esteja liberado, evitando colisões e atropelamentos. A Figura 4 mostra o funcionamento do sistema de detecção de obstáculos apresentado por Rivera (2014).

Figure 4 - Sistema de detecção de obstáculos




Fonte: Rivera (2014).

A Teleoperação de equipamentos permite que os colaboradores executem as suas atividades de maneira segura e eficiente. Um exemplo, a citar é na empresa Hydro Paragominas (PA). O trator D11 é operado de forma remota já é uma realidade, inclusive uma das primeiras experiências do tipo em uma mina de bauxita no mundo. um processo mais seguro, mais rápido e eficiente, e reduz o tempo da máquina parada, o consumo de combustível e a consequente emissão de CO₂, garantindo também maior produtividade do equipamento (MINERAÇÃO E SUSTENTABILIDADE, 2023).

Na mina subterrânea podemos citar o controle inteligente dos ventiladores (ventilação por demanda) e equipamentos operados remotamente. Nesse caso o ar é fornecido somente onde necessário em condições adequadas exigidas pela legislação.

Zaporroli (2020) menciona que o sistema de ventilação sob demanda da mina subterrânea de Vazante (MG), que explora zinco e chumbo. No sistema tradicional, os ventiladores trabalham de forma contínua, enquanto a nova tecnologia programa a ventilação de acordo com a movimentação de pessoas e máquinas dentro da mina, reduzindo o gasto de energia. O sistema de ventilação é programado, mas já tem os sensores que fazem os ajustes automaticamente da ventilação. A Figura 5 mostra um exemplo do funcionamento da ventilação por demanda.

Figure 5 - Aplicação da ventilação por demanda



Fonte: Costa (2019)

4. Considerações Finais

A Inteligência Artificial avançou muito nos últimos anos e está revolucionando a indústria da mineração, proporcionando benefícios expressivos em termos de eficiência, segurança e sustentabilidade. A capacidade da IA de processar grandes volumes de dados em tempo real, otimizar processos, prever falhas em sistemas e equipamentos, aprimorar a exploração mineral e melhorar a segurança no trabalho é inquestionável. Ela está permitindo a indústria de mineração a operar de maneira mais inteligente e eficaz, maximizando a utilização de recursos preciosos e minimizando impactos ambientais.

A utilização da IA tem melhorado significativamente as operações em diversos setores produtivos e de serviços. Neste trabalho foram apresentadas aplicações da IA no setor mineral, especificamente nas seguintes etapas e/ou áreas: Operação de Mina, Exploração Mineral e Planejamento de Mina, Perfuração e Desmonte de Rochas e Segurança de Mina.

As aplicações mais proeminentes da IA na Operação de Mina se referem ao desenvolvimento de caminhões autônomos e na melhoria dos sistemas de despacho, o que proporciona um aumento da produtividade e também melhoria da segurança das operações.

Na Exploração Mineral, a utilização da IA na detecção de anomalias, e, portanto, identificação de potenciais alvos para pesquisa detalhada, acarretará em um aumento substancial de descoberta de novos depósitos, o que poderá aumentar as reservas conhecidas de diversas *commodities*. Ainda, o uso da IA para estimativa de teores, determinação de modelos geológicos e de planos de mina mais confiáveis, proporcionará uma redução nos riscos inerentes ao projeto mineiro.

No que se refere à etapa de Perfuração e Desmonte de Rochas, o refinamento do modelo por meio de IA com o propósito de reduzir vibrações resulta em mais segurança e coopera para a sustentabilidade das operações mineiras, uma vez que reduz o dano às estruturas vizinhas. Ainda, melhora as relações entre a empresa e as comunidades vizinhas, as quais participarão dos efeitos positivos da utilização de modelos de IA para reduzir vibrações.

A Segurança de Mina tem sido também afetada pela utilização de modelos de IA para detectar fadiga dos motoristas de caminhões fora-de-estrada, detectar colisões entre equipamentos, estabelecer sistemas de ventilação sob demanda, e condução remota de veículos. A implantação desses sistemas atua no sentido de proporcionar uma redução da probabilidade de ocorrência de acidentes e melhorar as condições de trabalho, o que significa também aumento da produtividade das operações.

À medida que a IA continua a evoluir, seu impacto positivo na mineração e na gestão de recursos minerais é inegável. Apesar dos ganhos obtidos, também é crucial considerar desafios éticos, regulatórios e de segurança à medida que a IA se torna mais presente no setor mineral.

Referências

AGRÍCOLA, GEORG; HOOVER, HERBERT. De re metallica. MBLWHOI Library. New York: Dover Publications, 1950.

CARRANZA, E. J. M.; LABORTE, A. G. Random forest predictive modeling of mineral prospectivity with a small number of prospects and data with missing values in Abra (Philippines). Computers & Geosciences, v. 74, p. 60-70, Jan. 2015. <https://doi.org/10.1016/j.cageo.2014.10.004>.

CHOROS, K. A. et al. Can Hyperspectral Imaging and Neural Network Classification Be Used for Ore Grade Discrimination at the Point of Excavation?. Sensors, v. 22, n. 7, Art. n. 2687, Mar. 2022. <https://doi.org/10.3390/s22072687>

COSTA, L. DE V.; SILVA, J. M. DA. Strategies used to control the costs of underground ventilation in some Brazilian mines. REM - International Engineering Journal, v. 73, n. 4, p. 555–560, 2020.

COSTA, J. H. R. Previsão de vibrações utilizando redes neurais artificiais no controle de desmonte de rochas. 91 p.p. Dissertação de Mestrado. Universidade Federal de Ouro Preto, 2019.

CRUZ, R. M. S. Modelagem de Desmontes de Rochas Controlados com Auxílio de Redes Neurais Artificiais - Estudo de Caso Itabira. 64 p.p. Dissertação de Mestrado. Universidade Federal de Ouro Preto, 2022.

FU, S. et al. Information Fusion and Metallogenic Prognosis of Gold Deposits in the Qixia Area, Northern Shandong Province, China. Minerals, v. 13, n. 9, Art. n. 1125, Ago. 2023. <https://doi.org/10.3390/min13091125>.

GABER et al. Autonomous Haulage Systems in the Mining Industry: Cybersecurity, Communication and Safety Issues and Challenges. Electronics, vol. 10, p. 1357, 2021.

GAMA, C. Dinis da. Ruídos e Vibrações Ligados à Utilização dos Explosivos e Equipamentos. In: 1º Seminário de Auditorias Ambientais Internas. Divisão de Minas e Pedreiras do Instituto Geológico e Mineiro, Portugal, 16p. 1998.

GAO et al. Parallel End-to-End Autonomous Mining: An IoT-Oriented Approach. IEEE Internet of Things Journal. 2019

GAO, L. et al. Intelligent Identification and Prediction Mineral Resources Deposit Based on Deep Learning. Sustainability, v. 15, n. 13, Art. n. 10269, Jun. 2023. <https://doi.org/10.3390/su151310269>

IBRAM. 2022. Mineração Usiminas obtém resultados significativos após adotar sistema de detecção de fadiga da Optalert. Disponível em: <https://ibram.org.br/noticia/mineracao-usiminas-obtem-resultados-significativos-apos-adotar-sistema-de-deteccao-de-fadiga-da-optalert/>. Acesso em: 21 out. 2023.

JAFRASTEH, B.; FATHIANPOUR, N.; SUÁREZ, A. Comparison of machine learning methods for copper ore grade estimation. Computational Geosciences, v. 22, p. 1371-1388, Out. 2018. <https://doi.org/10.1007/s10596-018-9758-0>

KAPAGERIDIS, I. K.; TRIANTAFYLLOU, A. G. LavaNet—Neural network development environment in a general mine planning package. Computers & Geosciences, v. 37, n. 4, p. 634-644, Abr. 2011. <https://doi.org/10.1016/j.cageo.2010.10.017>

KAPLAN, U. E.; TOPAL, E. A New Ore Grade Estimation Using Combine Machine Learning Algorithms. Minerals, v. 10, n. 10, Art. n. 847, Set. 2020. <https://doi.org/10.3390/min10100847>.

KHORZOUGH, M. B. Use of Measurement While Drilling Techniques for improved rock mass characterization in open-pit mines. Master Thesis. University of British Columbia. Vancouver, 2013.

LI, S.; CHEN, J.; XIANG, J. Applications of deep convolutional neural networks in prospecting prediction based on two-dimensional geological big data. Neural Computing and Applications, v. 32, p. 2037-2053, Abr. 2020. <https://doi.org/10.1007/s00521-019-04341-3>.

Li, T., Liu, X., Su, S. Semi-supervised text regression with conditional generative adversarial networks. 2018.

MEECH, J.A. The evolution of intelligent systems in the mining industry. In: Proceedings of Mineral Process Modeling, Simulation and Control Conference, 2006

MINERAÇÃO E SUSTENTABILIDADE. Operação remota promove mais eficiência e diversidade na Hydro Paragominas. Disponível em: <<https://revistamineracao.com.br/2023/06/19/operacao-remota-promove-mais-eficiencia-e-diversidade-na-hydro-paragominas/>>. Acesso em: 22 out. 2023

McCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, v. 5, p. 115–133, 1943.

MOOMIVAND, H.; VANDYOUSEFI, H. . Development of a new empirical fragmentation model using rock mass properties, blasthole parameters, and powder factor. *Arabian Journal of Geosciences*, 13(22). 2020.

PANG, B., LEE, L. et al. Opinion mining and sentiment analysis. In: *Foundations and Trends in Information Retrieval*, vol. 2, no. 1–2, pp. 1–135, 2008.

RAFAEL SAKURAI. Implementando a estrutura de uma Rede Neural Convolutacional utilizando o MapReduce do Spark. Disponível em: <https://www.sakurai.dev.br/cnn-mapreduce/>. Acesso em: 22 out. 2023. 2017.

RIVERA, Julio Renato. Efectos de la incorporación de tecnologías autónomas en el diseño y la planificación minera. 2014. Memoria (ingeniero civil de minas) - Universidad de Chile departamento de Ingeniería de Minas, Santiago de Chile, 2014. Disponível em: URI: <https://repositorio.uchile.cl/handle/2250/131395>. Acesso em: 19 out. 2023.

SAMORA, Hélio. O uso da Internet das Coisas no monitoramento de barragens e mineradoras. 2019. Disponível em: <https://cryptoid.com.br/criptografia-identificacao-digital-id-biometria/o-uso-da-internet-das-coisas-no-monitoramento-de-barragens-e-mineradoras/>. Acesso em: 25 jun. 2023.

SCHUNCK, Marcelo. A evolução e o potencial da inteligência artificial de impactar os negócios. 2023. Disponível em: <https://exame.com/bussola/a-evolucao-e-o-potencial-da-inteligencia-artificial-de-impactar-nos-negocios/>. Acesso em: 18 out. 2023.

SEVERYN, A. MOSCHITTI, A. Twitter sentiment analysis with deep convolutional neural networks. In: *Proceedings of the 38th International ACM SIGIR Conference on Research and Development in Information Retrieval*. ACM, 2015, pp. 959–962.

SOUZA, Calebe Paiva Gomes de. Diagnóstico de estruturas civis baseado em medidas de vibração: uma abordagem a partir de algoritmos não-adaptativos e adaptativos para treinamento

de redes neurais artificiais. 154f. Tese de Doutorado. Universidade Estadual de Campinas, 2020.

TORRES, Vidal Feliz Navarro; COSTA, João Henrique; SOUSA Rodolfo Matias. Criação de um modelo de redes neurais para previsão de vibrações. estudo de caso: Itabira. Relatório Científico ITV, Prod. Tec. ITV MI – N0043/2021, 2021.

TORRES, Vidal Félix Navarro; SILVEIRA, Leandro Geraldo Canaan; LOPES, Paulo Filipe Trindade; LIMA, Hernani Mota de. Assessing and controlling of bench blasting-induced vibrations to minimize impacts to a neighboring community. Journal of Cleaner Production, v. 187, p. 514-524, 2018.

ZAPAROLLI, Domingos. Mineração digital. 2020. Disponível em: <https://revistapesquisa.fapesp.br/mineracao-digital/>. Acesso em: 19 out. 2023.

ZONTA, Márcio. Acidentes na mineração superam em até três vezes a média nacional, mostra fundação. 2016. Disponível em: <https://www.brasildefato.com.br/2016/07/08/acidentes-na-mineracao-superam-em-ate-tres-vezes-a-media-nacional-mostra-fundacao>. Acesso em: 21 out. 2023.

ZOU, S. et al. Application of Machine Learning to Characterizing Magma Fertility in Porphyry Cu Deposits. Journal of Geophysical Research: Solid Earth, v. 127, n. 8, Art. n. e2022JB024584, Ago. 2022. <https://doi.org/10.1029/2022JB024584>.