



CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS

UNIDADE ARAXÁ

LUÍSA PAULA CASTRO MARIANO

**ANÁLISE E PREDIÇÃO DE VIBRAÇÕES EM DESMONTES DE ROCHAS COM
EXPLOSIVOS APLICANDO REDES NEURAIAS ARTIFICIAIS E *RANDOM FOREST***

ARAXÁ - MG

2025

LUÍSA PAULA CASTRO MARIANO

**ANÁLISE E PREDIÇÃO DE VIBRAÇÕES EM DESMONTES DE ROCHAS COM
EXPLOSIVOS APLICANDO REDES NEURAIAS ARTIFICIAIS E *RANDOM FOREST***

Trabalho de Conclusão de Curso apresentado no curso de graduação em Engenharia de Minas do Centro Federal de Educação Tecnológica de Minas Gerais, campus Araxá, como requisito parcial para obtenção do título de bacharel em Engenharia de Minas.

Orientador: Guilherme Alzamora Mendonça

Co-orientador: Adilson César Melo de Paula

“Desistir... eu já pensei seriamente nisso, mas nunca me levei realmente a sério; é que tem mais chão nos meus olhos do que o cansaço nas minhas pernas, mais esperança nos meus passos, do que tristeza nos meus ombros, mais estrada no meu coração do que o medo na minha cabeça.”

Cora Carolina.

AGRADECIMENTO

Agradeço à Deus, fonte de infinita sabedoria e amor, e à Nossa Senhora Aparecida, minha intercessora, por serem minha força e esperança nos momentos de dúvida, sempre me guiando, iluminando para superar todos os desafios e protegendo em todos esses anos de estrada.

Aos meus pais, Mauro e Nina, por todo o esforço e incentivo na realização dos meus sonhos. Por todo amor, confiança e educação direcionados à mim por toda a vida, devo à vocês tudo que sou e todo que um dia ainda serei. E ao meu irmão, Felipe por ser meu exemplo de dedicação e comprometimento profissional.

Ao meu orientador, Prof. Me. Guilherme Alzamora Mendonça, sem sua orientação nada disso seria possível. Agradeço por todas as oportunidades de crescimento pessoal, profissional e intelectual por meio de seus conselhos, por toda paciência, apoio e pelo incentivo durante todo esse tempo. E ao meu coorientador, Engenheiro Especialista Adilson César Melo de Paula, por ser exemplo de profissional a seguir e por me proporcionar a oportunidade de vivenciar essa área de tamanha importância e descobrir minha paixão pela lavra e pelo desmonte de rochas. Tenham a certeza de que sempre serei grata à vocês e me lembrarei de sua importância para a minha construção profissional.

Aos meus familiares, especialmente à minha avó Maria e à minha madrinha Dorinha, por serem minha base, pelo apoio incondicional, pela torcida, por suas orações para que eu alcançasse mais essa conquista e por se fazerem presentes mesmo com a distância.

Ao Arthur, por ser sinônimo de amor, amizade, cumplicidade, calma e motivação frente às dificuldades enfrentadas durante essa caminhada.

Aos meus amigos de longa data Anna Júlia, Artur, Gabriel, Giovanna, Júnia, Karina e Luísa pela amizade incondicional em todos os momentos.

À Gerência de Operação de Mina da Mineração Usiminas por todo o conhecimento compartilhado e por contribuírem para minha formação profissional e pessoal durante meu tempo de estágio.

Aos docentes do Centro Federal de Educação Tecnológica de Minas Gerais – Campus Araxá, pela acolhida, por sua dedicação e por me presentear com ensinamentos para além do currículo.

Aos amigos que essa caminhada me presenteou, por todos os desafios compartilhados e incríveis memórias desse tempo aqui vivido.

E agradeço ao CEFET-MG campus Araxá, pelo ensino de qualidade e o comprometimento com formação de grandes profissionais.

RESUMO

A atividade minerária envolve várias etapas interdependentes: extração, transporte, beneficiamento e comercialização do minério, sendo a eficiência em cada uma dessas fases crucial para o sucesso geral da atividade. A fase de extração inclui o processo de desmonte de rochas, que é especialmente desafiador em locais onde estão presentes materiais mais compactos e com alta resistência. Para possibilitar a fragmentação em cenários como este, faz-se necessário a utilização de explosivos. No entanto, essa técnica envolve uma série de variáveis que devem ser rigorosamente controladas e dentre elas se destacam a geração de vibrações, que representam um dos principais desafios associados ao desmonte de rochas, que, se não forem adequadamente controladas, podem provocar danos às edificações, estruturas naturais e ao próprio meio ambiente. O trabalho enfatiza a importância da implementação de novas tecnologias e técnicas que permitam a continuidade da mineração sem causar impactos negativos às estruturas circunvizinhas. Nesse contexto, o estudo destaca a aplicação de algoritmos de aprendizado de máquina, como redes neurais artificiais e *random forest*, no monitoramento e previsão das vibrações causadas pelos desmontes. Os resultados alcançados demonstraram um potencial promissor, com as RNAs e o *random forest* atingindo, respectivamente, $R^2=79,03$ e $95,65$ na regressão. O estudo também avaliou o desempenho dos modelos em termos de erro absoluto médio (MAE). O *random forest* apresentou um MAE de 0,84, indicando uma maior precisão em comparação com as redes neurais artificiais, que atingiram um MAE de 1,72. Os resultados deste afirmam a viabilidade e o potencial dessas tecnologias como ferramentas que podem auxiliar na tomada de decisão estratégica para alcançar operações mais eficientes e seguras.

Palavras-chave: desmonte de rochas com explosivos, vibrações, *machine learning*, redes neurais artificiais, *random forest*.

ABSTRACT

Mining activity involves several interdependent steps: extraction, haulage, processing, and commercialization of the ore, with efficiency in each of these phases crucial for the overall success of the activity. The extraction phase includes the rock blasting process, which is especially challenging in locations where more compact materials with high resistance are present. To enable fragmentation in scenarios like this, the use of explosives is necessary. However, this technique involves a series of variables that must be rigorously controlled, and among them, the generation of vibrations stands out, which represents one of the main challenges associated with rock blasting, which, if not properly controlled, can cause damage to buildings, natural structures, and the environment itself. The academic work emphasizes the importance of implementing new technologies and techniques that allow the continuation of mining without causing negative impacts to the surrounding structures. In this context, the study highlights the application of machine learning algorithms, such as artificial neural networks and random forest, in monitoring and predicting the vibrations caused by blasting. The results achieved demonstrated promising potential, with ANNs and random forest achieving $R^2=79.03$ and 95.65 , respectively, in the regression. The study also evaluated the performance of the models in terms of mean absolute error (MAE). The random forest presented an MAE of 0.84 , indicating greater accuracy compared to artificial neural networks, which reached an MAE of 1.72 . The results herein confirm the feasibility and potential of these technologies as tools that can assist in strategic decision-making to achieve more efficient and safer operations.

Keywords: rock blasting, vibrations, machine learning, artificial neural networks, random forest.

LISTA DE SÍMBOLOS E ABREVIATURAS

R^2 - Coeficiente de correlação

MAE – Erro médio Absoluto

RMSE – Raiz do erro quadrático médio

VoD – Velocidade de Detonação

GPa – Giga Pascal

ANFO - *Ammonium Nitrate and Fuel Oil*

PPV – Velocidade de pico da partícula

Hz – Hertz

RNA – Rede artificial Neural

LISTA DE FIGURAS

Figura 1: Ciclo de operações minerais para a exploração de uma jazida.	17
Figura 2: Fases de um empreendimento mineiro.	18
Figura 3: Densidade, energia de detonação e potência por volume de misturas tipo emulsão/ANFO em função da emulsão.....	25
Figura 4: Ilustração do processo de fragmentação.	27
Figura 5: Propagação das ondas de choque.....	28
Figura 6: Reflexão das ondas de choque.....	29
Figura 7: Extensão das fraturas pela ação dos gases.....	29
Figura 8: Fragmentação por flexão.	30
Figura 9: Fragmentação por colisão.....	31
Figura 10: Terminologias utilizadas no desmonte de rochas em bancadas.	32
Figura 11: Tipos a de vibrações no terreno.....	34
Figura 12: Tipos de onda propagadas no terreno.	36
Figura 13: Representação gráfica dos limites de velocidade de vibração de partícula.....	37
Figura 14: Estrutura de uma rede neural artificial.....	40
Figura 15: Exemplo de árvore de decisão.....	42
Figura 16: Gráfico de regressão à partir da rede neural artificial.....	51
Figura 17: Gráfico de Regressão à partir da floresta aleatória.	52
Figura 18: Gráfico de dispersão de resíduos à partir do algoritmo de floresta aleatória.....	52
Figura 19:Histograma de resíduos à partir do algoritmo de floresta aleatória.	53
Figura 20:Gráfico de resíduos à partir do algoritmo de rede neural artificial.	54
Figura 21: Histograma de resíduos à partir do algoritmo de rede neural artificial.	55

LISTA DE TABELAS

Tabela 1: Limites de velocidade de vibração de partícula de pico por faixa de frequências.....	37
Tabela 2: Arquitetura das camadas ocultas da RNA.....	46
Tabela 3: Análise descritiva do banco de dados.	50
Tabela 4: Resultados das métricas de desempenho.....	56

SUMÁRIO

1.	INTRODUÇÃO	13
2.	OBJETIVOS	15
2.1.	Objetivo Geral	15
2.2.	Objetivos Específicos	15
3.	REFERENCIAL TEÓRICO	16
3.1.	Operações Mineiras	16
3.2.	Perfuração e desmonte	18
3.3.	Explosivos	20
3.3.1.	Principais propriedades dos explosivos	20
3.3.1.1.	Velocidade de Detonação (VoD)	21
3.3.1.2.	Energia ou força	21
3.3.1.3.	Densidade	22
3.3.1.4.	Sensibilidade	22
3.3.1.5.	Resistência à água	23
3.3.2.	Principais tipos de explosivos.....	23
3.3.2.1.	Emulsão.....	24
3.3.2.2.	ANFO.....	24
3.4.	Fragmentação e detonação.....	26
3.5.1	Mecanismos de ruptura presentes na detonação.....	27
3.5.1.1	Propagação das ondas de choque	28
3.5.1.2	Reflexão das ondas	28
3.5.1.3	Tensão exercida pelos gases	29
3.5.1.4	Colisão de fragmentos.....	30
3.6	Plano de fogo	31
3.7.1.	Diâmetro do furo.....	32

3.7.2. Profundidade do furo.....	32
3.7.3. Afastamento	33
3.7.4. Espaçamento	33
3.7.5. Tampão	33
3.7.6. Razão de carga.....	34
3.7 Vibrações	34
3.8 NBR 9653.....	36
3.9 <i>Machine Learning</i>	38
3.10 Redes neurais Artificiais	39
3.11 <i>Random Forest</i>	42
3.12 Validação.....	43
4. METODOLOGIA.....	45
4.1. Redes Neurais.....	46
4.2. <i>Random Forest</i>	48
5. RESULTADOS E DISCUSSÃO.....	50
5.1. Análise Descritiva	50
5.2. Algoritmos de Regressão	51
6. CONCLUSÃO.....	57
7. REFERÊNCIAS BIBLIOGRÁFICAS	58
APÊNDICE.....	62

1. INTRODUÇÃO

A mineração é um dos setores base do desenvolvimento econômico de diversos países. Com o Brasil não é diferente, a importância da atividade é destacada no país desde o período colonial, onde a extração de minérios foi responsável por parte da ocupação territorial, geração de riquezas e equilíbrio econômico para os países da Europa. Com isso, a atenção do mercado estrangeiro a partir daquela época se virou para os solos brasileiros.

Além da influência histórica, é possível verificar a presença da atividade minerária por toda parte ao observar o espaço em que se vive. Isso se dá pelo fato da mineração ser base para o desenvolvimento de outros setores da indústria através do fornecimento de matéria-prima. E é justamente essa relação com outras indústrias que torna a atividade uma das principais fontes de emprego tanto de forma direta através de suas próprias atividades de lavra e beneficiamento de minérios, quanto indiretamente através da relação de fornecimento de matéria-prima.

As etapas dessa atividade são a extração, o transporte do material, o beneficiamento, e por fim, a comercialização do minério. Todo o processo precisa estar em harmonia e fluir de maneira positiva individualmente, já que são interdependentes, isso a fim de se obter um bom resultado ao final da cadeia de produção.

Na fase de extração do bem mineral, se encontra a atividade de desmonte de rochas. E em minerações que contam com a presença de materiais mais compactos, com dureza e resistência superior aos materiais que permitem apenas a execução de desmonte mecânico, faz-se necessário o uso de explosivos para que o desmonte de rochas ocorra adequadamente. Processo esse que dispõe de diversas variáveis para controlar o seu desempenho e impactos, como tipo de explosivo, razão de carga, malha de perfuração, tempo de retardo, controle de vibrações, ruído e ultra lançamento de fragmentos de rocha.

O não controle desses parâmetros pode gerar impedimentos operacionais que, por sua vez, se não remediados poderão acarretar em uma paralisação total ou parcial de frentes de lavra estratégicas para a produção. Um controle extremamente importante para a operação de desmonte é a geração de vibrações que a depender

de sua magnitude pode causar danos no maciço rochoso, ou ainda em estruturas externas no entorno do empreendimento como trincas e desestabilização de casas, prédios, construções ou até mesmo estruturas naturais como as cavidades preservadas legalmente. Logo, para que não haja impactos negativos para todo o processo de mineração, faz-se necessário a aplicação de novas tecnologias que permitam a continuidade de desmontes nessas áreas e que preservem essas estruturas.

A utilização de algoritmos que permitem analisar e antecipar o comportamento das detonações na frente de lavra é uma abordagem que potencializa a otimização desse processo, podendo gerar maior eficiência e controle das vibrações. Com a aplicação prática do *Machine Learning* usando redes neurais artificiais e *random forest* para a análise de dados de desmontes e interpretações dos parâmetros, vê-se a possibilidade de otimizar a tomada de decisões de forma a obter resultados mais satisfatórios e que estejam dentro dos limites de vibrações determinados para a realização de desmontes controlados mantendo assim, a integridade das estruturas no entorno. Tendo isto em vista, este projeto tem por finalidade avaliar a aplicação dessas duas ferramentas de aprendizado de máquina na previsão de vibrações induzidas por desmontes de rocha para a obtenção de um algoritmo que auxilie na tomada de decisões estratégicas. Serão utilizados dados de desmontes reais incluindo dados de projeto e informações de monitoramento com o objetivo de construir modelos preditivos capazes de estimar com precisão, possibilitando o planejamento de desmontes mais eficientes e seguros.

2. OBJETIVOS

2.1. Objetivo Geral

Desenvolver algoritmos que auxiliem na tomada de decisões estratégicas relacionadas aos desmontes de rochas com explosivos, visando o controle efetivo das vibrações geradas, de forma a minimizar impactos ambientais, garantir a segurança das operações e otimizar os processos de mineração.

2.2. Objetivos Específicos

- Realizar o tratamento do banco de dados, garantindo a consistência, qualidade e precisão dos resultados.
- Realizar uma análise descritiva do banco de dados, à partir de parâmetros estatísticos.
- Desenvolver e implementar os modelos preditivos aplicando rede neural artificial e *random forest*, utilizando as variáveis do banco de dados como parâmetros de entrada.
- Validar a performance dos modelos construídos por meio de métricas, como R^2 , erro absoluto médio e raiz do erro quadrático médio, garantindo a confiabilidade dos resultados para controle de vibração.

3. REFERENCIAL TEÓRICO

3.1. Operações Mineiras

Segundo o Art. 36 do Código de Mineração, a lavra se trata de um conjunto de operações coordenadas objetivando o aproveitamento industrial da jazida, desde a extração das substâncias minerais úteis que contiver, até o beneficiamento. Porém é importante ressaltar que, antes do início da lavra propriamente dita ou de maneira simultânea à essa fase faz-se necessário o desenvolvimento mineiro, o qual possui como principal objetivo prover acesso à jazida, possibilitando a entrada de pessoal, equipamentos, energia, a saída do minério e estéril produzidos, assim possibilitando que a lavra ocorra de forma otimizada.

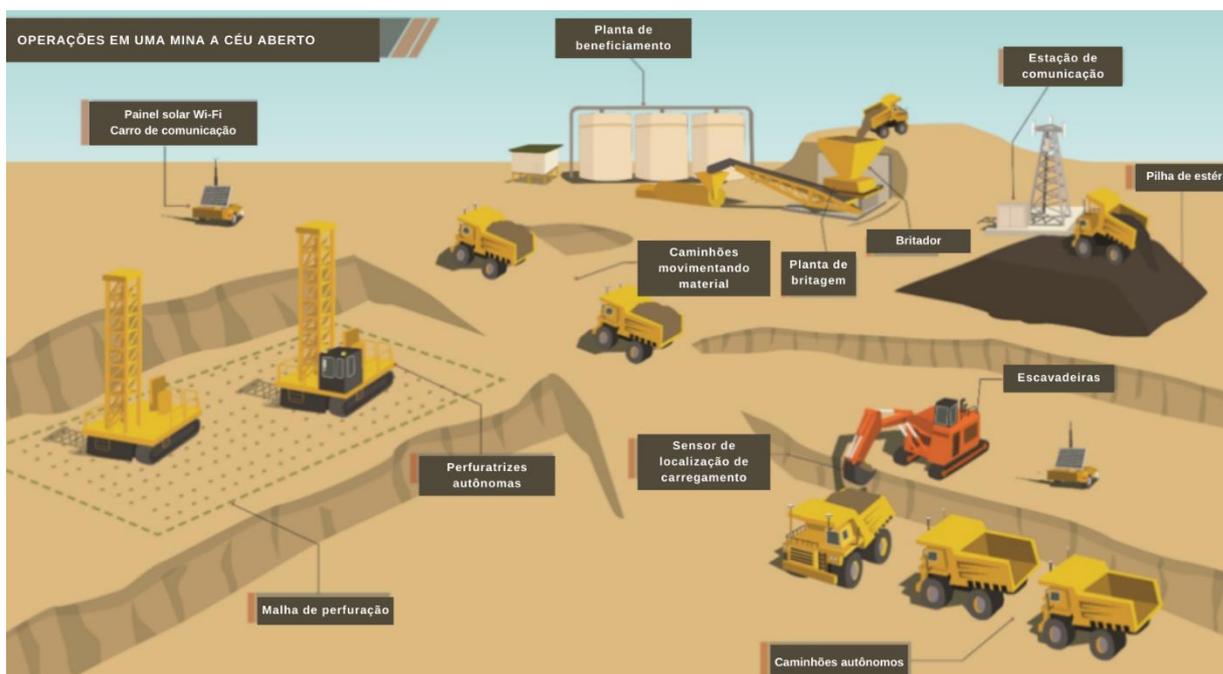
As operações de lavra em mina à céu aberto, comumente, ocorrem de maneira cíclica e se dividem em quatro etapas distintas porém, interdependentes, sendo elas a perfuração, o desmonte, o carregamento e o transporte do material, ilustradas na Figura 1.

A perfuração pode ocorrer através de diferentes métodos classificados em perfuração percussiva, perfuração rotativa, perfuração rotopercussiva e perfuração térmica. Todos esses métodos empregam perfuratrizes, cuja escolha é determinada considerando a perfurabilidade da rocha.

O desmonte pode ser executado por meios mecânicos ou pirotécnicos, ou seja, com o uso de explosivos. A escolha da técnica mais eficaz requer o conhecimento das propriedades geomecânicas da rocha, como por exemplo a resistência.

Já as operações de carregamento e transporte são realizadas com o objetivo de movimentar o material obtido por meio do processo de desmonte do maciço até a usina de beneficiamento ou até o pátio de estocagem com o uso de equipamentos como pás-carregadeiras ou escavadeiras e caminhões (DNPM, 2004).

Figura 1: Ciclo de operações minerais para a exploração de uma jazida.



Fonte: Adaptado de *The inteligente miner*.

Conforme Dutra (2014) destaca, o desenvolvimento de um empreendimento mineiro é um processo complexo que envolve diversas etapas, desde a identificação de ocorrências minerais com interesse econômico até a recuperação ambiental da área após o término da exploração. Como delineado por Hartman e Mutmanský (2002), bem como por Herrmann (2006), o ciclo de vida de um projeto de mineração é composto por três fases distintas, cada uma com suas atividades específicas:

- **Pré-Mineração:** essa fase inicial concentra-se na pesquisa e avaliação do potencial mineral de uma área, com o objetivo de determinar a existência de depósitos minerais de interesse econômico, assim como estimar sua dimensão e teor, e avaliar a viabilidade de sua exploração. As atividades incluem prospecção, exploração e estudos de viabilidade técnico-econômica.
- **Mineração:** compreende o desenvolvimento e a exploração da mina. O desenvolvimento envolve a construção da infraestrutura necessária, como acessos, plantas de beneficiamento e instalações de apoio. E a exploração consiste na extração do minério, utilizando métodos de lavra a céu aberto ou subterrânea, de acordo com as características do depósito mineral.

- Pós-Mineração: essa fase finaliza o ciclo de vida da mina, com a recuperação e reabilitação da área minerada. A recuperação visa minimizar os impactos ambientais da atividade, estabilizando taludes, revegetando áreas degradadas e monitorando a qualidade da água e do solo. A reabilitação busca reintegrar a área ao seu uso original ou a um novo uso, de acordo com o plano de fechamento da mina.

É importante ressaltar que essas fases são interligadas e interdependentes, e o sucesso de cada uma delas individualmente é essencial para o sucesso do projeto como um todo. A Figura 2 detalha as atividades específicas de cada fase, permitindo uma melhor compreensão do ciclo de vida de um projeto de mineração.

Figura 2: Fases de um empreendimento mineiro.

FASE	PROCEDIMENTOS	TEMPO
PRÉ-MINERAÇÃO		
PROSPECÇÃO (Depósito Mineral)	Procura do minério: a) Métodos de Prospecção Diretos: físicos, geológicos; Indiretos: geofísicos e geoquímicos. b) Localização favorável (mapas, literatura, minas antigas); c) No ar: fotografia aérea, satélite; d) Na superfície: geofísica e geologia; e) Anomalias locais, análises, avaliação.	1 – 3 anos
EXPLORAÇÃO (Corpo Mineral)	Definição do valor e extensão do minério: a) Amostra (perfuração ou escavação), ensaios e testes; b) Estimativa da tonelagem e teor; c) Avaliação econômica do depósito. Avaliação de mercado para tomada de decisão.	2 – 5 anos
MINERAÇÃO		
DESENVOLVIMENTO (Perspectivas)	Abertura do depósito mineral para produção: a) Aquisição ou locação de direitos minerários, se não houver sido realizado na fase anterior; b) Classificação dos impactos ambientais; c) Decapamento da área; d) Construção dos acessos, sistemas de transporte; e) Construção de instalações.	2 – 5 anos
LAVRA (Mina)	Produção de minério em larga escala: a) Fatores para escolha do método: geológico, econômico, ambiental, social e de segurança; b) Tipos de métodos de mineração: Em superfície: <i>Open Pit, Open Cast</i> etc. Em profundidade: <i>Room and Pillar, Block Caving</i> etc. c) Monitorizar custos e recuperação econômica	3 – 10 anos
PÓS-MINERAÇÃO		
RECUPERAÇÃO	Restauração da área: a) Remoção da planta e edificações; b) Recuperação dos resíduos e refugos; c) Trabalhos de recuperação da área degradada.	1 – 10 anos

Fonte: Hartman e Mutmanský, 2002.

3.2. Perfuração e desmonte

Conforme apresentado anteriormente, a etapa de fragmentação da rocha pode ocorrer de duas formas. Nos casos em que a rocha apresenta baixa resistência, o material denominado friável, é escavado utilizando a própria força mecânica de equipamentos como as escavadeiras, pás-carregadeiras ou tratores, o que se mostra

suficiente para a desagregação do insumo mineral. Já para rochas duras e compactas as quais apresentam alta resistência a aplicação de explosivos torna-se necessária, e a fragmentação se dá pela liberação de energia causada pela detonação dos explosivos, reduzindo a rocha em fragmentos menores, possibilitando as etapas subsequentes de escavação, transporte e britagem.

A perfuração de rochas é uma etapa fundamental e intrínseca ao processo de desmonte de rochas com explosivos. De acordo com Jimeno (2003), sua finalidade primordial é realizar aberturas, denominadas furos de detonação, no maciço rochoso, com geometria e distribuição adequadas, para alocar as cargas explosivas e os acessórios de detonação. A preparação do maciço pela detonação é uma das etapas que possui grande influência na eficiência da mina e de uma planta de beneficiamento de minérios.

Para realizar a fragmentação da rocha com o uso de explosivos, primeiramente são executadas as aberturas de furos na formação rochosa, onde a localização e as dimensões desses furos são cuidadosamente planejados e executados com base no plano de fogo. Uma vez concluída a perfuração, é realizado o carregamento com o material explosivo e acessórios, preparando a área para a detonação. O explosivo inserido nos furos abertos na rocha e detonado seguindo uma sequência já preestabelecida, possui a função de romper, fragmentar e deslocar uma porção delimitada de rocha.

No entanto, a utilização de explosivos na atividade de desmonte acarreta impactos ambientais e podem causar certo desconforto para populações que se encontram no entorno de onde ocorrem as operações. Conforme apontado por Neto (2004), entre os principais impactos estão: a geração de vibrações no solo, ultralançamentos, sobrepressão atmosférica, a liberação de partículas na atmosfera e o aumento dos níveis de ruído.

As vibrações são produtos das ondas sísmicas geradas pelas detonações, que se propagam pelo solo e, se não controladas podem causar danos estruturais em edifícios, casas, barragens e até mesmo formações geológicas sensíveis. Os ultralançamentos são projeções de blocos rochosos a grandes distâncias devido à força da explosão, colocando em risco pessoas, equipamentos, estruturas e o meio ambiente. A pressão acústica por sua vez se trata da variação da pressão do ar

percebida pelo ouvido humano, uma vez que as detonações causam níveis de ruídos intensos podem causar incômodos e em casos mais extremos algum dano físico.

Dessa forma, a mitigação desses efeitos constituem uma prática crucial que deve permear o planejamento e a execução dos trabalhos de desmonte.

3.3. Explosivos

Devido ao arranjo mineralógico dos minerais, algumas rochas possuem dureza elevada inviabilizando sua retirada através dos equipamentos de lavra, tornando os explosivos uma solução para cenários como esse.

Segundo Jimeno (1990) e Crosby (1998), explosivos são substâncias ou misturas, em qualquer estado físico, que ao serem submetidas a causas térmicas ou mecânicas (calor, impacto, atrito, etc.) se transformam de forma total ou parcial em gases, liberando uma elevada quantidade de energia em um curto espaço de tempo, gerando altas pressões e temperaturas, sendo utilizada para fragmentar o maciço em direção a face livre. Essa energia é liberada através do processo de detonação do explosivo que se inicia por meio da energia de ativação ou seja, da energia mínima necessária para iniciar o explosivo.

Concomitante à evolução das técnicas de mineração e métodos de lavra, os explosivos têm passado por um notável desenvolvimento tecnológico desde a década de 1940. Esse avanço tem se ocupado principalmente em aumentar a segurança durante o transporte e manuseio do produto, otimizar a fragmentação da rocha, garantir uma maior resistência à água e reduzir o custo por volume de rocha desmontado.

3.3.1. Principais propriedades dos explosivos

A seleção do explosivo adequado para uma determinada operação desprende de um conhecimento aprofundado sobre as propriedades que o caracterizam. Tais características, ligadas intrinsecamente à sua composição química, ditam seu desempenho em diferentes cenários. No contexto do desmonte de rochas, as propriedades dos explosivos que possuem maior relevância destacadas por Jimeno et al. (1994), são:

3.3.1.1. Velocidade de Detonação (VoD)

É a velocidade em que a onda gerada pela detonação se propaga através do explosivo. É um dos parâmetros mais importantes para a avaliação da performance de um explosivo (Olofsson, 1990). De acordo com Cameron et. al, 1990, essa é uma propriedade que varia entre os produtos a depender de suas composições, densidade, tipo de rocha, grau de confinamento, diâmetro do explosivo e tamanho das partículas que compõem seus ingredientes. A variação da VoD nos explosivos comerciais ocorre entre 1500 e 7600 m/s, e observa-se que quanto maior essa velocidade, maior a capacidade explosiva.

O parâmetro chamado diâmetro crítico, que determina o menor diâmetro para que ocorra o processo de detonação, está diretamente relacionado à VoD. Em diâmetros reduzidos, independente da velocidade da onda de choque ser alta ou não, o processo de detonação não se sustenta (Tamrock, 1984). E segundo Borg (1995), diâmetros maiores apresentam altas velocidades de detonação. Esta mesma relação é vista em relação ao confinamento, onde a VoD de um explosivo confinado é maior do que o não confinado.

3.3.1.2. Energia ou força

A força se refere à quantidade de energia liberada pela detonação do explosivo para produzir um efeito mecânico. A avaliação dessa força é fundamental a segurança e a eficiência das operações de desmontes de rocha, tanto em mineração quanto em construção civil. Países e regiões podem adotar critérios e metodologias distintas para realizar essa avaliação, e o que dificulta a comparação direta entre os explosivos. Entretanto, apesar de não existir um padrão global único para comparar força entre explosivos, existem diversas normas e metodologias que são amplamente utilizadas internacionalmente como as normas da União Europeia (UE) e dos Estados Unidos da América (EUA).

3.3.1.3. Densidade

É definida como o peso específico de um explosivo comumente expresso em g/cm^3 , variando em torno de 0,6 a $1,6 \text{ g/cm}^3$, entretanto cada tipo de explosivo possui uma densidade ótima no que se refere a performance final dos mesmos. A densidade é um fator crucial a se considerar para definir a quantidade de explosivo necessária para obter a fragmentação desejada. Portanto, em cenários em que há a presença de água no fundo do furo, o mais indicado é utilizar explosivos com densidade superior a $1,1 \text{ g/cm}^3$. Isso se deve ao fato de a presença de sólidos suspensos na água elevar sua densidade para além de 1 g/cm^3 , o que pode fazer com que explosivos menos densos flutuem, prejudicando o preenchimento correto dos furos (Candia, 2006).

A energia liberada por um explosivo possui relação direta com sua densidade, o que significa que explosivos de alta densidade fornecem mais energia por volume do que aqueles de baixa densidade. Por existir essa correlação justifica-se, em muitos casos, a aplicação dos mais densos no fundo dos furos onde se faz necessário uma maior concentração de energia. Cumpre ressaltar que a pressão hidrostática inerente à coluna de explosivo, já induz naturalmente um aumento da densidade na parte inferior, sendo justificável a prática do adensamento artificial somente quando a natural não é suficiente para a eficácia do desmonte.

A densidade também possui influência na sensibilidade de um explosivo e um conceito de importância relacionado a isso é denominado densidade de morte (“*Dead packed*”). Esse termo refere-se a densidade limite de um explosivo para que o mesmo apresente um bom desempenho. Quando um explosivo possui uma baixa densidade, pode iniciar só pelo cordel detonante. Em contrapartida, uma alta densidade pode reduzir a sua sensibilidade, tornando-o insensível ou até mesmo impossibilitando a iniciação.

3.3.1.4. Sensibilidade

A sensibilidade é entendida como a mínima energia requerida para que o explosivo seja iniciado de forma eficiente, além da capacidade da reação se propagar pela extensão da coluna (ICI, 1989). Explosivos que possuem baixa sensibilidade

como o ANFO, requerem o uso de cargas iniciadoras e em certos casos o uso de reforçadores para garantir a velocidade de detonação na coluna.

Na indústria de explosivos, as fontes de iniciação primárias são classificadas de acordo com o acrônimo F.I.S.H., que compreende:

- *Friction* (Fricção): se refere ao atrito entre as superfícies;
- *Impact* (Impacto): se trata da colisão entre superfícies, gerando aumento de pressão e temperatura;
- *Static* (Estática): iniciação por descarga eletrostática;
- *Head* (Calor): ignição por meio de fontes de calor como fogo, decomposição, compressão adiabática, calor radiante e atrito prolongado.

Dentre os principais parâmetros que influenciam a sensibilidade de um explosivo de acordo com ICI (1989) têm-se: presença de água, densidade, temperaturas extremas e o uso de diâmetros inadequados.

3.3.1.5. Resistência à água

Essa característica diz sobre a capacidade do explosivo de manter suas propriedades explosivas e sua funcionalidade de maneira eficaz mesmo quando exposto à umidade ou submerso em água. É essencial em operações onde há a ocorrência de ambientes aquosos ou úmidos e é comumente expressa em termos do tempo em que o produto pode permanecer submerso sem perder sua eficácia. Explosivos que possuem baixa resistência à água podem ter seu desempenho comprometido ao absorverem umidade, tendo como exemplo os explosivos à base de nitrato de amônio podendo não detonar adequadamente quando molhados.

3.3.2. Principais tipos de explosivos

No dinâmico cenário da mineração e construção civil, a escolha adequada do explosivo é um fator decisivo para o sucesso das operações de desmonte. Dentre a vasta gama de opções disponíveis no mercado, o ANFO e a emulsão se destacam.

3.3.2.1. Emulsão

As emulsões são caracterizadas pela dispersão de minúsculas partículas de sais oxidantes, como nitrato de amônia, sódio e cálcio, dispersas em uma matriz coloidal de óleo diesel ou outro hidrocarboneto contendo também alumínio em pó e água. De acordo com Alonso, Gomez e Herbert (2013), suas principais características são a alta velocidade de detonação, entre 4.500 e 5.500 m/s; densidade próxima à 1,15 g/cm³ e alta resistência à água. Sendo esta última justificada pela presença de hidrocarbonetos em sua composição.

3.3.2.2. ANFO

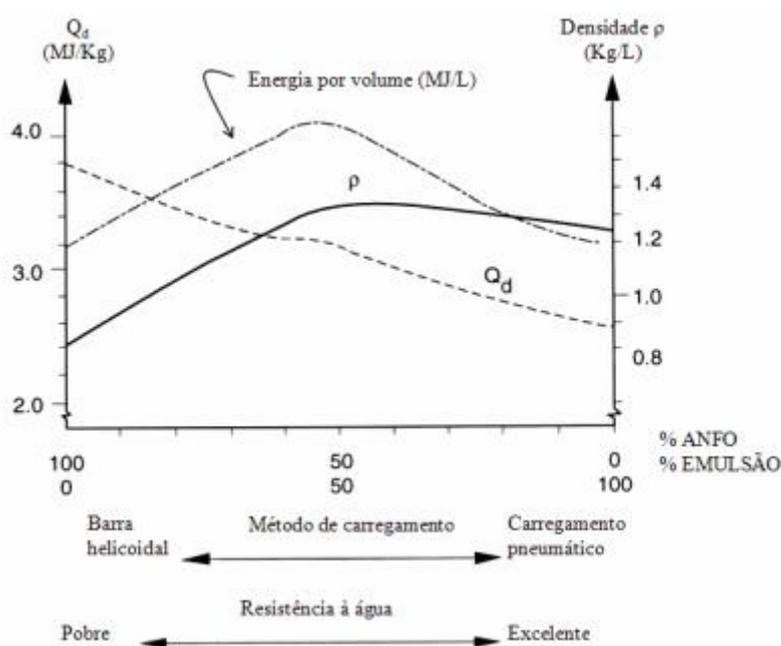
O ANFO, *Ammonium Nitrate and Fuel Oil*, é conhecido há mais de um século como um produto explosivo de custo reduzido e de alta segurança sendo, segundo Olofsson (1990), o explosivo civil mais utilizado no mundo. O produto se trata de uma mistura de 5,5% de nitrato de amônio e 94,5% de um óleo combustível, onde o nitrato atua como um comburente, fornecendo o oxigênio necessário à reação, enquanto o diesel atua como um combustível ou redutor na composição. Possui baixa densidade, em torno de 0,8 g/cm³, potência média, velocidade de detonação entre 2000 e 3000 m/s e apresenta baixa resistência à água. Com fórmula química NH₄NO₃, consiste em aproximadamente 60% de oxigênio em peso, 33% de nitrogênio e 7% de hidrogênio. Por se tratar de um sal, é facilmente dissolvido pela água sendo necessário recobri-lo com uma fina camada de talco ou zeolita para evitar a absorção da umidade do ar e consequente perda de eficiência na detonação. (Konya, 1996^a).

Diferentemente da pólvora, o ANFO não foi um produto descoberto por meio de uma detonação acidental, mas sim um produto fortemente pesquisado. É um explosivo bastante estável, fácil fabricação, de baixo custo porém possui uma certa complexidade em seu controle, pois muitos fatores afetam seu desempenho. A utilização do ANFO na indústria mineral foi viabilizada somente no início da década de 1950, com o desenvolvimento de técnicas de fabricação de nitrato de amônio em formatos adequados, como pequenas partículas esféricas ou grânulos.

3.3.2.3. Explosivos blendados

Para melhorar o desempenho das emulsões explosivas, são adicionados grânulos de nitrato de amônio que intensificam a mistura oxidante-combustível, ao passo que reduz a fluidez do explosivo. A emulsão confere resistência à água e um aumento da densidade, enquanto o ANFO reduz o custo e apresenta melhora a geração de gases. A adição desse granulado faz com que a energia por unidade de volume diminua, como ilustrado na Figura 3.

Figura 3: Densidade, energia de detonação e potência por volume de misturas tipo emulsão/ANFO em função da emulsão.



Fonte: Persson et. al, 1994.

Este tipo de explosivo é encontrado em diferentes proporções de emulsão/ANFO, porém sempre com a emulsão em maior quantidade, sendo comumente encontrados com as relações de 60/40, 70/30, 80/20 e 90/10. A escolha da proporção ideal depende da necessidade de resistência à água, das condições geológicas do maciço, do custo e da fragmentação desejada.

Este produto combina o baixo custo com um alto valor energético, e devido à sua maior densidade e velocidade de detonação em comparação ao ANFO, possui um poder de ruptura superior.

3.3.2.4. Plasma

O Plasma se trata de um produto não explosivo composto pela mistura dos sais metálicos de rápida expansão: nitrato de sódio, óxido de alumínio, escamas ferrosas, magnésio e óxido de cobre. Essa tecnologia utiliza do princípio do 4º estado da matéria para fragmentar a rocha por meio do diferencial de temperatura e da expansão dos gases resultantes, sendo comercializada em cápsulas. O Plasma gera mínimas vibrações e níveis reduzidos de ruído, minimizando o impacto em estruturas adjacentes e no meio ambiente.

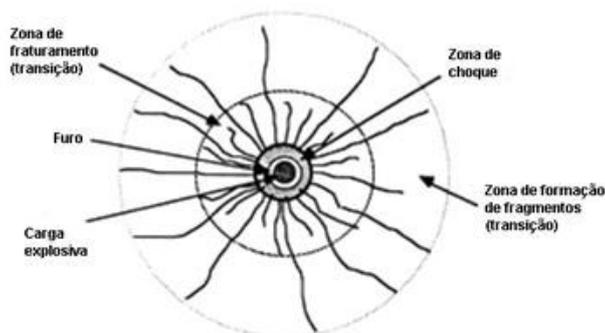
3.4. Fragmentação e detonação

A obtenção de uma fragmentação eficiente requer o desenvolvimento de um projeto técnico bem elaborado, uma execução precisa e um monitoramento rigoroso do desmonte. O projeto deve buscar a máxima conformidade com as condições reais de campo e seu sucesso está ligado de forma intrínseca ao conhecimento detalhado das características geomecânicas do maciço rochoso e à análise de históricos operacionais de planos de fogo precedentes. A execução demanda aderência estrita ao planejamento, o que pode ser alcançado com a aplicação de softwares especializados que permitem identificar divergências em tempo real e implementar correções imediatas. Já o monitoramento contínuo é indispensável para validar os resultados obtidos ou detectar eventuais falhas operacionais e promover medidas corretivas que otimizem a eficiência do processo.

Uma fragmentação ineficiente pode gerar blocos maiores que o planejado (*oversize*) ou de granulometria reduzida, influenciando diretamente na eficiência da produção. Nos casos em que os fragmentos são muito grandes e dificultam as etapas de escavação, transporte e processamento, devem ser considerados como um indicativo de ineficiência do desmonte. Scott et al. (1996), aponta duas soluções possíveis para essa situação: ou se aceita a ineficiência como parte do processo, ou se realiza novamente a fragmentação desses blocos por desmonte hidráulico ou desmonte secundário. Contudo, o desmonte secundário é um procedimento mais

lento, oneroso e difícil quando comparado ao desmonte primário. A Figura 4 ilustra esse processo de fragmentação à partir da carga explosiva presente no furo.

Figura 4: Ilustração do processo de fragmentação.



Fonte: Essen et al, 2003.

A detonação necessita de um estímulo para iniciar e os fornecedores dessa energia inicial são os sistemas de iniciação, que por serem suficientemente energéticos conseguem romper a estabilidade do explosivo através da geração de ondas de choque que ao atingi-los resultam na reação química dos seus compostos iniciando o processo de detonação. Por definição, a detonação se trata de uma reação exotérmica de decomposição com participação do oxigênio presente no explosivo. Esse processo segue ocorrendo ao longo do explosivo até que seja atingido sua velocidade de detonação e à partir de um certo momento, o estímulo inicial já não influencia mais na reação e sim a auto propagação do explosivo que é responsável por dar continuidade ao processo até que toda a carga explosiva ao longo do furo detone.

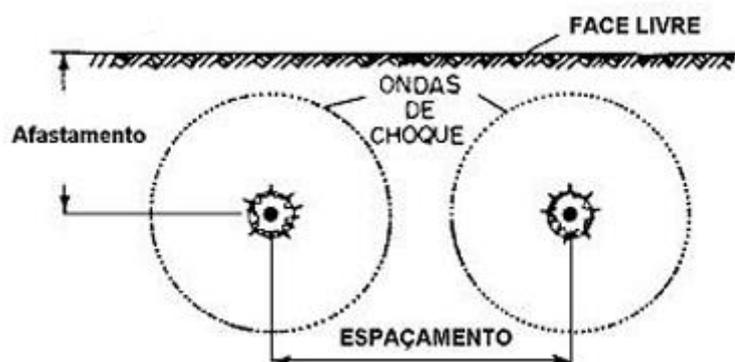
3.5.1 Mecanismos de ruptura presentes na detonação

Para que a detonação seja bem sucedida os mecanismos de ruptura devem ocorrer no processo sendo eles: a propagação das ondas de choque, a reflexão de ondas, tensão exercida pelos gases e a colisão de fragmentos.

3.5.1.1 Propagação das ondas de choque

Após a detonação da carga explosiva confinada, a sua massa é convertida em gases que se expandem rapidamente ocupando o furo. Esse processo que ocorre a alta temperatura e pressão induz a propagação de uma onda de choque que atua na parede do furo (Figura 5). Essa onda compressiva, que atinge valores de até 50 GPa, ao exceder a resistência à compressão da rocha circundante resulta em microfraturamentos num raio de até 8 vezes o diâmetro da carga, a depender da competência do maciço e da energia do explosivo (HAGAN,1979).

Figura 5: Propagação das ondas de choque.



Fonte: Silva, 2013

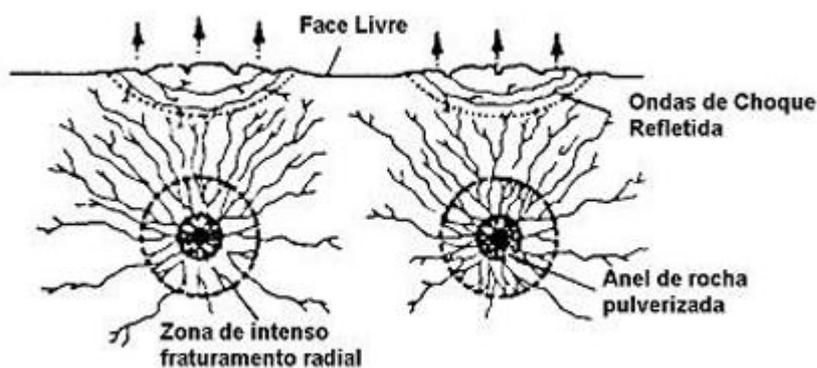
A presença de fraturas naturais em rochas exerce uma influência significativa na propagação de rachaduras durante as detonações. A extensão do dano e a direção das fraturas são fortemente influenciadas pela interação da onda de choque com as descontinuidades preexistentes. Quando um furo de detonação intercepta longitudinalmente fraturas existentes, estas são prontamente abertas pela passagem da onda de choque. Por outro lado, a abertura dessas fraturas preexistentes alivia a tensão em outras direções, limitando o desenvolvimento de rachaduras radiais que normalmente se propagariam a partir do furo (Jimeno et. al, 1994).

3.5.1.2 Reflexão das ondas

Quando a onda de compressão se propaga através da rocha e atinge uma superfície livre, como a face de um talude ou de uma escavação, parte dessa energia

é refletida de volta (Figura 6), transformando a compressão em tensão de tração. Essa tensão de tração, ao retornar ao ponto de origem da detonação e excede a capacidade da rocha de resistir a esse tipo de força, resulta na fragmentação.

Figura 6: Reflexão das ondas de choque.

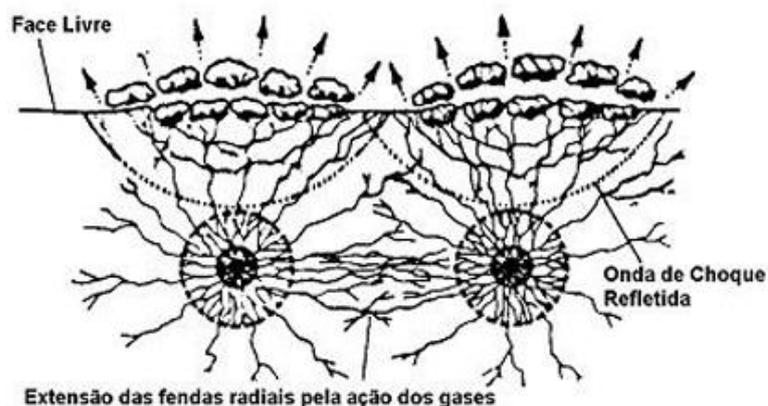


Fonte: Silva, 2013.

3.5.1.3 Tensão exercida pelos gases

Após a onda de compressão gerar as primeiras rachaduras na rocha, os gases resultantes da detonação se expandem e penetram nessas fraturas causando a extensão das mesmas (Figura 7), sob a influência da concentração de tensão em suas extremidades.

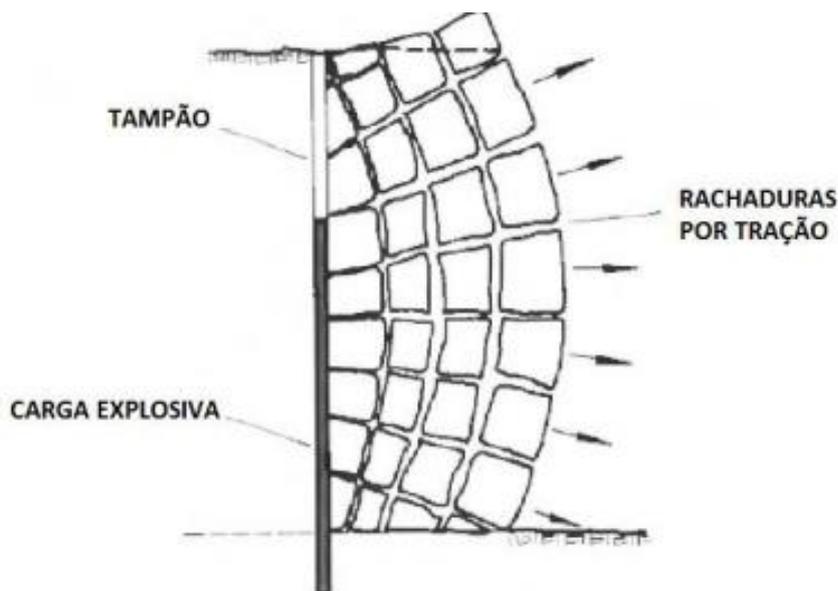
Figura 7: Extensão das fraturas pela ação dos gases.



Fonte: Silva, 2013.

Essa pressão dos gases não apenas alarga as descontinuidades existentes, mas também leva à fragmentação da rocha por flexão. Isso ocorre porque a rocha à frente da carga explosiva faz com que a coluna de rocha se comporte como uma viga, com um ponto fixo na base do furo e outro na área do tampão, como apresentado na Figura 8 (Jimeno et. al, 1994).

Figura 8: Fragmentação por flexão.

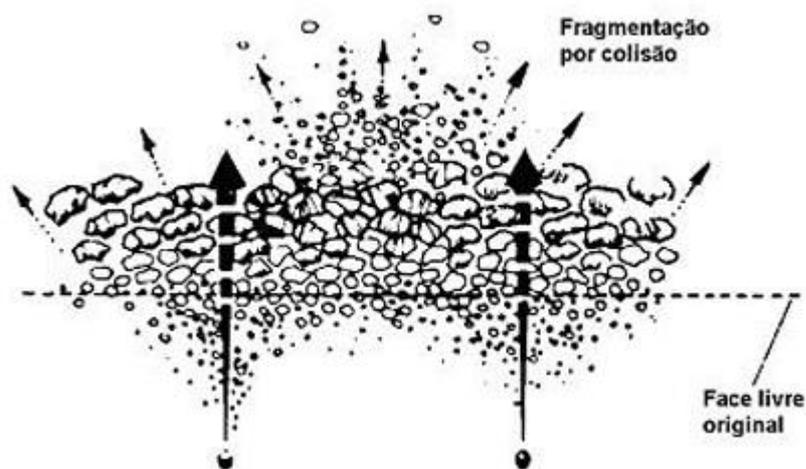


Fonte: Jimeno et. al, 1994.

3.5.1.4 Colisão de fragmentos

A etapa final da fragmentação da rocha ocorre durante a projeção dos fragmentos, quando estes colidem entre si ou com o solo, representada na Figura 9. No entanto, a maior parte da fragmentação já ocorreu devido à ação das ondas de compressão e tração, bem como à expansão dos gases. Portanto, a fragmentação por colisão tem um papel secundário no processo geral de quebra da rocha.

Figura 9: Fragmentação por colisão.



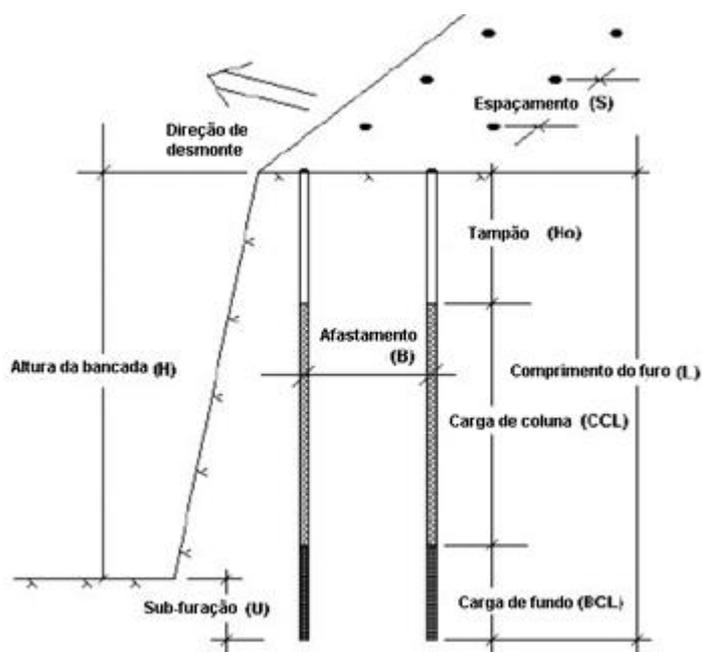
Fonte: Silva, 2013

3.6 Plano de fogo

Uma ferramenta imprescindível para se obter uma melhor qualidade da fragmentação da rocha e controle da energia liberada no processo é o plano de fogo, que se trata de um documento que conterá todas as informações sobre a detonação, algumas delas estão representadas na Figura 10.

Tradicionalmente, o dimensionamento do plano de fogo tem se baseado em abordagens empíricas, fundamentadas na experiência prática e em conhecimentos técnicos acumulados ao longo do tempo. No entanto, com o avanço da tecnologia e a crescente disponibilidade de dados, novas metodologias, como o uso de softwares de modelagem e simulação, têm sido incorporadas ao processo de planejamento, permitindo uma análise mais precisa e otimizada dos parâmetros envolvidos.

Figura 10: Terminologias utilizadas no desmonte de rochas em bancadas.



Fonte: Bergman, 2005.

3.7.1. Diâmetro do furo

É determinado de acordo com sua finalidade, custo, produção horária desejada e com o tipo de explosivo que irá alocar. Este parâmetro é definido pelo porte dos equipamentos de lavra e de importância ressaltar que possui influência nas vibrações causadas ao terreno. Essa influência se deve, principalmente, à quantidade de explosivo que pode ser acomodada no furo e à forma como a energia da detonação é liberada.

3.7.2. Profundidade do furo

A profundidade do furo varia de acordo com a altura da bancada. Não é exatamente igual, pois é recomendado que se faça uma subfuração, ou seja, ultrapassar o plano da bancada para evitar a formação de repé. (Ricardo, 1990)

3.7.3. Afastamento

Trata-se da distância entre a linha de furo e a face livre do talude. É uma variável muito crítica que, quando muito pequeno possui relação com a geração excessiva de ruído, quando muito excessivo contribui para ultra lançamentos e altos níveis de vibração no terreno. Um afastamento adequado permite que a energia da detonação seja utilizada de forma eficiente, fragmentando a rocha no tamanho desejado para facilitar o carregamento, transporte e britagem. A definição do afastamento ideal depende de diversos fatores como o tipo de rocha, tamanho desejado dos blocos e as condições do local que ocorrerá a detonação.

3.7.4. Espaçamento

É a distância entre dois furos consecutivos de uma mesma linha. Se muito pequeno produzirá matacões à frente da linha de furos e se muito excessivo pode gerar problemas com repés e uma frente muito irregular.

3.7.5. Tampão

Segundo Jimeno (2013), o tampão é a parte do furo preenchida com material inerte acima da carga explosiva na qual visa reter e confinar os gases provenientes da detonação. O autor destaca que um tampão insuficiente ou sua ausência pode resultar no escape de gases para a atmosfera, gerando uma explosão de ar e projeção de fragmentos, comumente conhecidos como ultra lançamentos, representando um sério risco à segurança. Em contrapartida, um tampão excessivo também possui consequências negativas, como o aumento dos níveis de vibração, a redução do inchamento da pilha e o lançamento de uma grande quantidade de pedregulhos à partir da parte superior da bancada.

3.7.6. Razão de carga

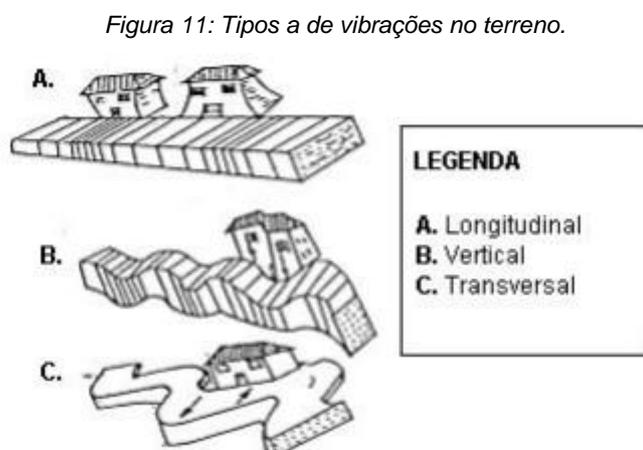
A razão de carga, normalmente expressa em kg de explosivo por metro cúbico de rocha - kg/m^3 , indica a quantidade de explosivo utilizada para fragmentar um determinado volume de rocha. Ela é calculada dividindo-se a massa total de explosivos utilizados em um desmonte pelo volume total de rocha fragmentada.

Esse parâmetro quando inadequado, afeta a qualidade da fragmentação, propicia a geração de vibrações e ruídos, oferece riscos à segurança ao causar ultra lançamentos e impacta nos custos dos desmontes.

3.7 Vibrações

Um dos impactos de grande relevância que resulta de um desmonte de rochas com a utilização de explosivos são as vibrações no terreno, que podem comprometer a estabilidade geotécnica de estruturas da região próxima à mina e gerar desconforto à comunidades circunvizinhas. Segundo Dinnis Da Gama (1998), apenas 5 a 15% da energia liberada pelo explosivo é utilizada na fragmentação da rocha, o que resulta na maior parte da energia sendo dissipada na forma de efeitos colaterais no ambiente, resultando em vibração no terreno ou na pressão acústica.

As vibrações no terreno podem ocorrer de três maneiras distintas: longitudinal, vertical ou transversal, apresentadas na Figura 10.



Fonte: Adaptado de Dhekne, 2015.

Dhekne (2015) afirma que, embora seja impossível evitar por completo as vibrações no terreno, os desmontes podem ser planejados visando minimizar seus efeitos e mantê-los sob um maior controle. O conhecimento dos parâmetros de um desmonte de rochas com o uso de explosivos é crucial para que seja possível otimizar o plano de fogo e minimizar esses impactos negativos em áreas adjacentes uma vez que, cada parâmetro influencia diretamente na intensidade e na propagação das ondas no solo.

As ondas sísmicas propagadas no terreno são divididas em ondas volumétricas, aquelas transmitidas no interior da rocha, e as ondas superficiais, transmitidas na superfície terrestre.

As ondas volumétricas são subdivididas em dois tipos principais, de acordo com a direção de vibração das partículas em relação à direção de propagação da onda:

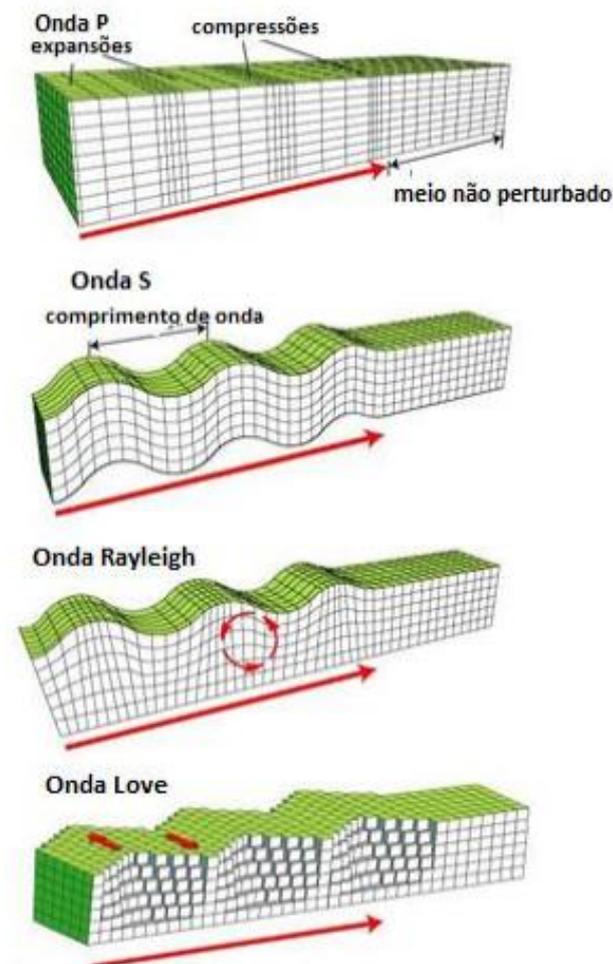
- Ondas P (primárias): são as ondas mais rápidas, se propagam na direção longitudinal e realizam compressão no terreno. As partículas do meio vibram na mesma direção em que a onda se propaga, comprimindo e expandindo o material.
- Ondas S (secundárias): são mais lentas comparadas à ondas P, também denominadas transversais ou cisalhantes. As partículas vibram perpendicularmente à direção de propagação da onda, fazendo com que o material se deforme lateralmente.

As ondas superficiais também são divididas em dois tipos, sendo eles:

- Ondas Love: as partículas do solo se movem horizontalmente, perpendicularmente à direção de propagação da onda.
- Ondas Rayleigh: esse tipo de onda se move em órbitas elípticas verticais, com movimento para trás na parte superior da elipse e para frente na parte inferior.

As quatro ondas estão representadas esquematicamente na Figura 12, onde é possível visualizar como elas se movem e a reação do solo perante sua ação.

Figura 12: Tipos de onda propagadas no terreno.



Fonte: ScienceLearn, 2016

A importância de se conhecer a velocidade das ondas compressoriais em diferentes tipos de rochas, reside na sua aplicação na análise de desmontes de rochas com explosivos. A comparação dessas velocidades com dados coletados em campo permite estimar o módulo dinâmico de Young do maciço rochoso em questão, possibilitando a previsão do seu comportamento sob carregamentos dinâmicos específicos (Silveira, 2017).

3.8 NBR 9653

A NBR 9653:2005 define os valores máximos para a pressão acústica e a vibrações com a finalidade de reduzir os riscos inerentes ao desmonte de rochas com

explosivos. Estabelecendo critérios e diretrizes para avaliar e controlar os efeitos de vibrações e ruídos provenientes de detonações, com foco na proteção da população e do meio ambiente. A avaliação de riscos de danos causados por vibrações do terreno exige uma análise cuidadosa da magnitude e da frequência das vibrações das partículas.

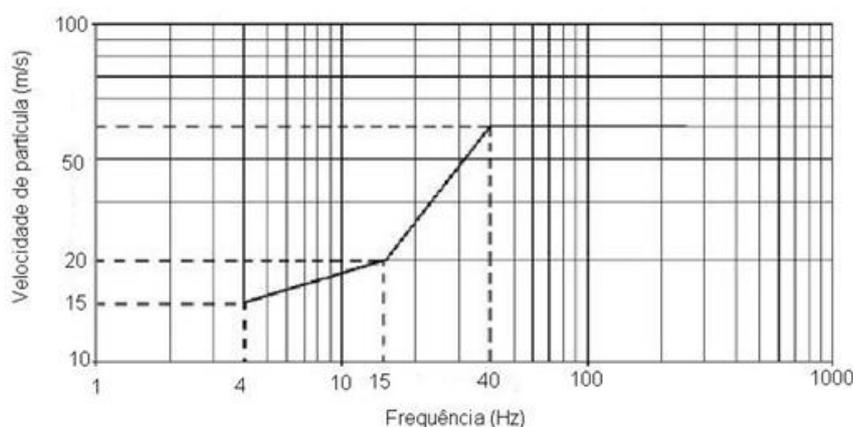
A magnitude da vibração, geralmente medida em termos de velocidade de pico da partícula (PPV), indica a intensidade da vibração. Quanto maior a PPV, maior a energia de vibração e, conseqüentemente, maior o risco de danos. Enquanto que a frequência, medida em Hertz (Hz), indica o número de ciclos vibratórios por segundo. Diferentes estruturas e materiais possuem diferentes sensibilidades a diferentes frequências de vibração. Os limites de velocidade de vibração de partícula de pico, que indicam o ponto em que podem ocorrer danos induzidos por vibrações no terreno, são apresentados de forma numérica na Tabela 1 e visualmente na Figura 13.

Tabela 1: Limites de velocidade de vibração de partícula de pico por faixa de frequências.

Faixa de Frequência	Limite de Velocidade de vibração de partícula de pico
4 Hz a 15 Hz	Iniciando em 15 mm/s aumenta linearmente até 20 mm/s
15 Hz a 40 Hz	Acima de 20 mm/s aumenta linearmente até 50 mm/s
Acima de 40 Hz	50 mm/s
NOTA -Para valores de frequência abaixo de 4 Hz deve ser utilizado como limite o critério de deslocamento de partícula de pico de no máximo 0,6 mm (de zero a pico)	

Fonte: ABNT, 2005

Figura 13: Representação gráfica dos limites de velocidade de vibração de partícula.



Fonte: ABNT, 2005.

Langefors e Kihlström (1978), ao estabelecerem seu critério de danos em edifícios, destacam a importância da relação entre a frequência natural da construção e a frequência da vibração a que ela será exposta. Essa relação é um fator chave para determinar a ocorrência de danos. Os autores também observam que os danos podem ser causados por alongamento, cisalhamento e torção, deformações que podem ser intensificadas por tensões estáticas preexistentes na estrutura. Isso implica a necessidade de critérios de avaliação mais rigorosos, levando em conta também o estado de conservação do edifício.

De acordo com a Norma Técnica D7.013 da CETESB, que trata dos critérios para desconforto humano, aponta que a velocidade máxima de vibração da partícula (V_p) resultante de detonações com explosivos não deve exceder 4,2 mm/s fora da área do empreendimento.

3.9 Machine Learning

O *Machine Learning* ou aprendizado de máquina, é um subconjunto da inteligência artificial em que de forma autônoma um sistema aprende e aperfeiçoa continuamente seu desempenho aplicando redes neurais e *deep learning*, sem ter sido programado necessariamente com esse objetivo, ao receber grandes quantidades de dados.

A cada dia mais, a taxa de geração de dados no mundo acelera. Sendo um enorme desafio analisar todos eles sem o auxílio de uma ferramenta de *machine learning*. Sua aplicação reside em diversas atividades, entre elas estão:

- Automatização de tarefas: como análise de dados, reconhecimento de padrões, tradução de idiomas entre outras atividades repetitivas.
- *Insights* para a tomada de decisões: à partir da identificação de anomalias, tendências e padrões o *machine learning* pode auxiliar a tomada de decisões mais estratégicas.
- Personalização de experiências: amplamente empregado em áreas de e-commerce e marketing para a personalização de produtos e serviços.

- Otimização de processos: ao analisar dados e identificar gargalos, o modelo é capaz de otimizar processos, reduzir custos e aumentar a eficiência em diversas áreas.

3.10 Regressão

De acordo com Soto (2013), a regressão é um método que visa modelar a relação entre variáveis dependentes e independentes, buscando compreender como as variáveis independentes influenciam a dependente por meio de ferramentas estatísticas utilizadas para criar um modelo que descreva essa relação.

As técnicas de regressão se utilizam dessas correlações entre as variáveis para prever valores futuros com base no dados disponíveis. A escolha do algoritmo de regressão adequado irá depender das características dos dados e também do problema a ser solucionado. É crucial avaliar o desempenho do modelo utilizando métricas como o erro absoluto médio (MAE), o erro quadrático médio (MSE), a raiz do erro quadrático médio (RMSE) e o coeficiente de correlação (R^2).

Comumente, os passos realizados para aplicar uma regressão são:

- Pré-processamento: tratamento dos dados, como a remoção de *outliers* e padronização dos valores.
- Seleção de modelo: seleção do modelo de regressão a ser utilizado.
- Treinamento: ajuste do modelo aos dados de entrada.
- Avaliação: aplicação de métricas de desempenho para avaliar a performance do modelo.

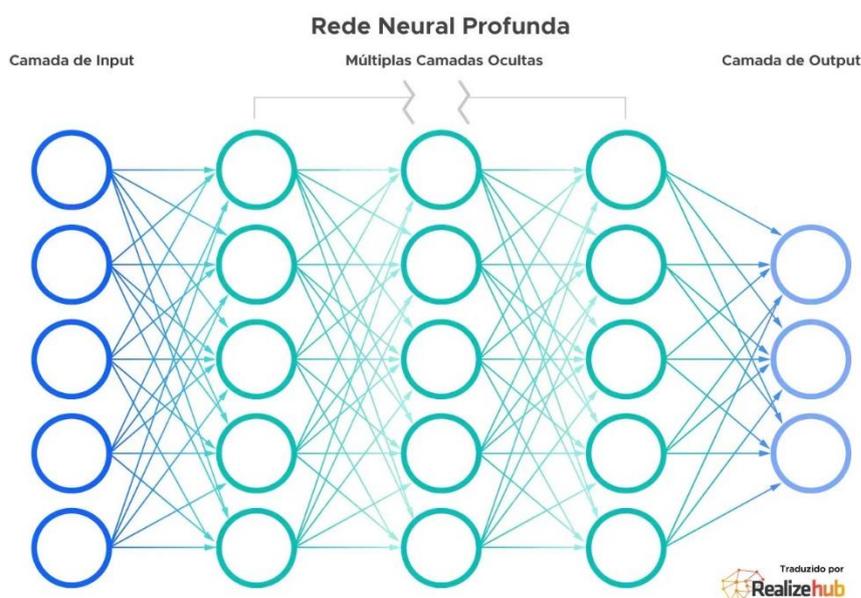
3.11 Redes neurais Artificiais

Grande parte das tecnologias desenvolvidas pelo homem advém da observação da natureza, com as redes neurais não é diferente. A história das redes neurais artificiais remonta à década de 1940, quando o neurofisiologista McCulloch e o matemático Walter Pitts publicaram um artigo intitulado “*Logical Calculus of the Ideas Immanent in Nervous Activity*”. Embora os modelos originais fossem simples, eles estabeleceram os fundamentos para o desenvolvimento das complexas redes

neurais aplicadas atualmente. As RNAs são técnicas computacionais que apresentam um modelo matemático inspirado no funcionamento da estrutura neural de um cérebro humano e o processo de aprendizagem, onde elas criam sistemas adaptativos usados pelos computadores para aprender com os erros e aprimorar de maneira contínua. Elas são compostas por unidades denominadas neurônios artificiais que enviam dados entre si, fazendo com que a informação seja compartilhada por meio da rede. Uma RNA se organiza em camadas (Figura 14) sendo elas:

- Camada de *input* ou camada de entrada: é a primeira camada da rede, por meio de onde os dados são inseridos no sistema.
- Camadas ocultas: se localizam entre as camadas de entrada e saída e se ocupam de realizar os cálculos complexos, possibilitando o aprendizado da máquina em relação à padrões e relações presentes nos dados. A quantidade dessas camadas depende da complexidade do problema.
- Camada de *Output* ou camada de saída: esta camada gera a saída da rede, que pode ser um valor numérico (previsão), uma categoria (classificação) ou uma decisão, com base nos dados de entrada processados e nos padrões aprendidos.

Figura 14: Estrutura de uma rede neural artificial.



Fonte: Realize Hub.

As redes neurais operam em duas fases principais: aprendizado e teste. A fase de aprendizado, se trata de um processo iterativo onde as conexões geradas no modelo estão associadas a pesos que armazenam o conhecimento adquirido e são utilizados para ponderar a entrada recebida por cada neurônio da rede. Essa etapa funciona da seguinte maneira:

- Preparação dos dados: os dados de treinamento são divididos em um conjunto de entradas, são os que a rede receberá, e um conjunto de saídas desejadas, que são os resultados corretos para esses *inputs*.
- Inicialização dos pesos: de forma aleatória as conexões entre os neurônios recebem seus pesos.
- Alimentação da rede: a rede é alimentada pelos *inputs*, gerando uma saída correspondente.
- Cálculo do erro: o modelo calcula por meio de métricas o erro entre a saída da rede e a saída desejada.
- Ajuste dos pesos: analisando a etapa anterior, um algoritmo de otimização ajusta os pesos com o objetivo de minimizar esse erro calculado.
- Repetição: repete-se os passos alimentação da rede, cálculo do erro e ajuste dos pesos várias vezes, até que o erro seja suficientemente pequeno ou um número máximo de iterações seja atingido.

Após o treinamento, a rede é testada para avaliar a sua capacidade de generalização, ou seja o seu desempenho em fazer previsões precisas em dados não vistos durante o treinamento. Essa etapa segue a seguinte lógica:

- Preparação dos dados: aqui os dados são divididos da mesma forma que os dados de treinamento, em um conjunto de entrada e outro de saída.
- Alimentação da rede: as entradas dos dados de teste são alimentadas na rede e geram saídas correspondentes.
- Avaliação de desempenho: utilizando métricas como precisão, acurácia e *recall* se avalia a performance da rede ao comparar as saídas geradas com as saídas desejadas.

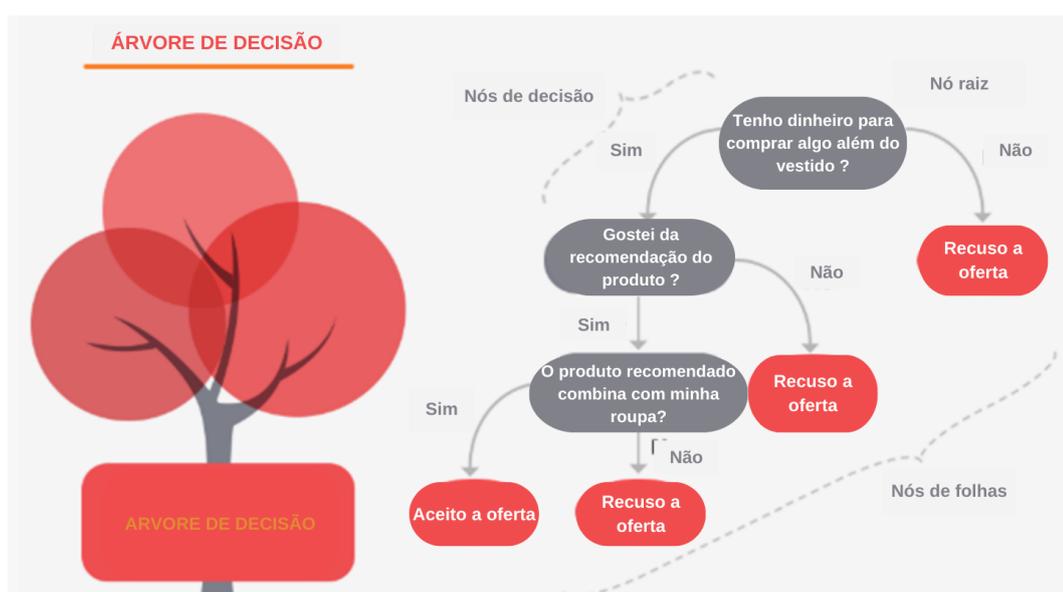
Importante ressaltar que a qualidade do banco de dados é fundamental para o desempenho do modelo. Dados enviesados ou ruidosos podem afetar o aprendizado da máquina e levar a resultados imprecisos.

Devido ao fato das redes neurais artificiais serem aptas a resolver problemas de natureza geral, tais como aproximação, classificação, categorização, previsão, entre outros, a gama de áreas onde ela pode ser aplicada é vasto (Braga, 2007). Dentre suas áreas de aplicação pode-se citar a visão computacional, mecanismos de predição ou recomendação, reconhecimento por voz e processamento de linguagem natural. E devido a esta abrangência, possui casos de uso em diversos setores como: diagnóstico médico feito pela classificação de imagens, previsões de variáveis a serem controladas, previsões financeiras.

3.12 *Random Forest*

O *Random Forest*, ou floresta aleatória, é um algoritmo de *machine learning* que usa vários subconjuntos de dados de treinamento para construir uma série de árvores de decisão (que compõem a floresta), que de forma resumida se trata de uma estrutura de dados que representa uma sequência de decisões e suas consequências, como representado no exemplo da Figura 15.

Figura 15: Exemplo de árvore de decisão.



Fonte: Adaptado de Blog Somos Tera.

Após a construção, o sistema faz uso das árvores para realizar previsões em novos *inputs*, e então combina as previsões individuais de cada uma formando uma floresta de decisões, que aumenta a precisão do conjunto de saída. O algoritmo possui a seguinte estrutura básica:

- Seleção das amostras: seleciona de forma aleatória algumas amostras dos dados de treinamento.
- Definição da raiz: o modelo realiza cálculos utilizando as amostras para definir qual variável será a raiz.
- Definição dos nós: após definida a raiz, o algoritmo avança para os próximos nós, alocando duas ou mais variáveis e excluindo aquelas aplicadas no nó anterior. Esse processo se repete sucessivamente até o último nó. Sequente à formação da primeira árvore, inicia-se a construção das demais.
- Previsão de novos valores: ao final, cada árvore terá seu resultado, possibilitando que o modelo faça a previsão. Em casos de regressão, ele costuma apresentar a média dos valores previstos como o resultado final, enquanto que para as classificações, o resultado é o que apareceu com mais frequência.

Há um ponto ideal em que a capacidade do modelo em generalizar bem os dados ainda não vistos e fazer previsões precisas é otimizado. Essa otimização da eficácia pode ser alcançada por meio de técnicas como a validação cruzada, regularização e curvas de aprendizado.

3.13 Validação

A validação se trata de um processo sistemático crucial para assegurar que um modelo, sistema ou produto não apenas atenda aos requisitos estabelecidos, mas também opere de forma confiável e eficaz em um cenário real. Na ciência de dados, as metodologias de validação desempenham um papel fundamental para avaliar o desempenho de modelos estatísticos e de aprendizado de máquina, garantindo a precisão e confiabilidade dos resultados obtidos por meio da análise de dados.

Dentre as diversas metodologias existentes, a mais adequada dependerá do contexto e dos tipos de dados a serem trabalhados. Entre as mais comuns estão a validação cruzada e a validação externa.

A validação cruzada divide o conjunto de dados em múltiplos subconjuntos, também denominados *folds*. Permitindo que o modelo seja treinado em uma parte dos dados e testado em outra. A validação cruzada *K-fold* é um exemplo dessa técnica e o método aplicado na metodologia deste trabalho, no qual os dados são divididos em k subconjuntos, alguns para treino e outros para teste do modelo. Esse processo de treino-teste é repetido até que cada *fold* seja utilizado como conjunto de teste uma vez.

A validação externa, por sua vez, faz uso de dados completamente novo daqueles aplicadas no modelo para treiná-lo e verificar a eficácia alcançada. Sendo eficaz em revelar vieses presentes nos dados de treino que não foram identificados anteriormente por outras validações.

4. METODOLOGIA

O código de programação foi implementado utilizando a linguagem Python no ambiente interativo de desenvolvimento Jupyter Notebook, uma aplicação web de código aberto. Durante o desenvolvimento, foram empregadas as seguintes bibliotecas especializadas para atender às necessidades específicas de cada parte do projeto:

- Pandas: esta biblioteca permite a manipulação eficiente dos dados, incluindo tratamento, limpeza e análise estatística destes.
- Numpy: oferece um conjunto de ferramentas computacionais numéricas e se trata de um pacote destinado a realizar operações em arrays multidimensionais.
- Matplotlib: é uma biblioteca de visualização de dados e plotagem gráfica para linguagem de programação Python, amplamente utilizada.
- Seaborn: também é uma ferramenta de visualização de dados porém seaborn simplifica algumas configurações de temas que são mais complexas no matplotlib.
- Scikit-learn: desenvolvida especificamente para a aplicação prática de machine learning. Neste projeto, foi utilizada para normalização dos dados, para o modelo de regressão, para a validação cruzada e para as métricas de avaliação.

Antes de entrar com o banco no modelo, procedeu-se com uma etapa de análise e tratamento, que compreendeu a remoção de *outliers* por inspeção visual seguida da identificação e exclusão de registros das variáveis que não apresentaram nenhuma variabilidade. Este último cenário citado foi observado para as variáveis independentes “Altura do furo” e “Afastamento”.

O banco de dados é composto por 72 amostras referentes à uma mina de ferro localizada no Quadrilátero Ferrífero, cada uma contendo a variável dependente “Vibração” e as seguintes variáveis independentes: “Diâmetro do furo”, “Quantidade de furos”, “Espaçamento”, “Tampão”, “Carga máxima”, “Explosivo” e “Distância do desmonte ao ponto monitorado”.

Feito isso, iniciou-se a preparação dos algoritmos de regressão. Em ambos os códigos foram implementados as etapas de normalização dos dados, divisão treino-teste e análise à partir dos gráficos de regressão linear, gráficos de dispersão de resíduos e histogramas.

Em um primeiro momento, foi realizada uma análise descritiva dos dados empregando estatísticas como média, mediana, desvio padrão, valores mínimos e máximos, além dos quartis para cada uma das variáveis que compõe o banco.

4.1. Redes Neurais

Após a importação das bibliotecas requeridas para o ambiente, os dados foram carregados à partir de um arquivo Excel. Subsequente, realizou-se a divisão entre a variável dependente (Vibração) das variáveis independentes ou preditoras. Após isso, aplicou-se uma técnica de normalização dos dados onde os valores foram escalonados, apresentando média 0 e desvio padrão 1. Essa etapa de pré-processamento é crucial para otimizar o desempenho das funções de ativação, assegurando maior eficiência no processo de aprendizado da máquina.

Na sequência é definida a arquitetura das camadas ocultas da rede neural utilizando uma lista onde cada tupla se refere a uma camada com as distintas configurações apresentadas na Tabela 2.

Tabela 2: Arquitetura das camadas ocultas da RNA.

Nº de camadas	Nº de neurônios por camada
1	7
2	7
1	14
2	14
1	21
2	21
1	28
2	28

Fonte: Autoral, 2025.

Foram adotadas 1 ou 2 camadas de entrada, cada uma delas com o número de neurônios igual aos múltiplos do número de variáveis preditoras, que neste caso

são 7. Esses diferentes modelos de camadas ocultas serão testados visando identificar qual a arquitetura que fornece a melhor performance no problema de modelagem.

Ademais, é definida a lista que especifica as funções de ativação que possuem um papel crucial na rede neural pois são as responsáveis por introduzirem a não-linearidade no modelo, permitindo que o mesmo trabalhe relações mais complexas nos dados. Nesta lista, têm-se três funções: '*Identify*', que aplica uma função linear retornando os valores de *input*; '*tahn*', que produz saídas no intervalo de -1 à 1 utilizando uma tangente hiperbólica; e '*reLU*', que retorna o valor do *input* se for positivo e o valor 0 se for negativo, sendo essa uma função amplamente aplicada devida a sua eficiência.

Com as informações levantadas até aqui, um modelo de regressão neural com um número máximo de 5000 iterações foi criado e o código realizou testes com diferentes combinações de camadas e funções de ativação, avaliando seu desempenho em cada uma dessas combinações através das métricas estatísticas: R^2 , MAE e RMSE em uma validação cruzada utilizando *KFold*. Neste cenário, os dados são divididos em quatro partes, onde em cada iteração o modelo utiliza três *folds* para treinar e com o 4º ele realiza o teste, repetindo o processo para cada um dos quatro *folds* até que cada parte tenha sido aplicada como um conjunto de teste uma vez. Para a garantia de que a divisão dos dados será consistente em cada execução e que os dados sejam embaralhados antes de cada divisão, foi definida uma semente aleatória fixa igual a 100. Isso assegura que a aleatoriedade seja controlada, permitindo reproduzir os resultados e evitando vieses nos experimentos.

O modelo armazena as combinações de parâmetros testadas e suas respectivas métricas de desempenho e a busca pelo cenário ótimo é iniciada pela seleção da combinação que apresenta o maior valor médio de R^2 . Em seguida, o modelo é novamente treinado, porém agora, utilizando a arquitetura otimizada identificada na etapa anterior. Com o modelo treinado sob a melhor configuração encontrada, são geradas previsões para as variáveis independentes. Ao fim, as métricas de avaliação são replicadas sobre as previsões e os valores reais para quantificar a performance do modelo com o melhor cenário.

Na etapa seguinte, realiza-se o cálculo dos resíduos, os quais correspondem à diferença entre os valores reais e os valores ajustados, ou seja, os valores preditos pelo modelo de regressão. Esses resíduos são importantes para avaliar a qualidade do ajuste do modelo, pois representam os erros de predição encontrados. Com base nesses valores, são construídos o gráfico de dispersão e o histograma dos resíduos, que permitem visualizar a distribuição e o padrão dos erros. A análise visual por meio de gráficos se faz necessária pois possibilita a identificação de problemas como *outliers* e a heterocedasticidade dos dados.

Concluindo a análise, um gráfico de regressão é construído, confrontando os valores reais de vibração com as predições do modelo otimizado. O destaque dado ao valor de R^2 permite interpretar a relação existente entre os dados.

4.2. *Random Forest*

Após a importação do conjunto de dados e a aplicação do processo de normalização assim como na rede neural, determinou-se uma faixa de valores para o número de árvores individuais a serem consideradas na construção do modelo. Este intervalo compreende valores entre 5 e 245 com incrementos de 5 unidades, resultando na sequência de valores 5, 10, 15, ... até alcançar 245 árvores. Ademais, estabeleceram-se os critérios de divisão dos nós, sendo eles o erro quadrático médio (MSE) e o erro absoluto médio (MAE), os responsáveis por definir como a árvore de decisão escolhe atributo para dividir os dados em cada nó. Para a avaliação do modelo de regressão mantém-se a análise do coeficiente de determinação R^2 .

Inicia-se então o treinamento, onde para cada combinação de critério e árvore, um modelo de regressão é treinado e testado para prever os valores de vibração. Após cada etapa de treino-teste, o R^2 é calculado e armazenado para fins de avaliação e comparação quanto ao desempenho do modelo para a previsão. À partir desses testes determina-se a melhor combinação de parâmetros para cada critério e, em seguida, o melhor cenário global alcançado.

O modelo de regressão, agora configurado com os hiperparâmetros ótimos identificados na etapa anterior é novamente treinado e avaliado em um conjunto de

teste. As métricas de avaliação são aplicadas, quantificando a performance do modelo, confrontando os valores reais observados com as previsões geradas.

Foi realizada a validação cruzada por meio do método *K-Fold*, seguindo o mesmo formato aplicado na RNA, aplicando 4 *folds* no total e uma semente aleatória fixa no valor de 100. O código imprime as métricas R^2 para cada *fold*, média e desvio padrão obtidas na validação.

Para concluir a análise, foram construídos gráficos no mesmo formato aplicado na RNA para possibilitar a visualização dos resultados obtidos à partir da análise de resíduos e da regressão linear.

5. RESULTADOS E DISCUSSÃO

5.1. Análise Descritiva

No contexto da modelagem de regressão, a análise descritiva (Tabela 3) auxilia na compreensão das relações entre as variáveis independentes e dependente, permitindo avaliar a adequação dos dados ao modelo proposto e também, identificar alterações necessárias.

Tabela 3: Análise descritiva do banco de dados.

	Vibração (mm/s)	Diâmetro (m)	Furos (unid)	Espaçamento (m)	Tampão (m)	Q máxima (Kg)	Explosivo	Distância (m)
Unidades	71	71	71	71	71	71	71	71
Média	6.180	146.064	199.986	4.507	2.890	46.169	2.775	445.756
Desvio Padrão	5.701	0.119	38.287	0.504	0.739	14.711	0.566	255.325
Mínimo	0.192	146.050	150.000	4.000	2.250	29.000	1.000	54.933
25%	2.518	146.050	180.000	4.000	2.300	35.000	3.000	248.613
50%	4.592	146.050	197.000	5.000	2.500	35.000	3.000	391.577
75%	7.696	146.050	200.000	5.000	4.000	60.000	3.000	635.544
Máximo	25.956	147.050	317.000	5.000	4.000	65.000	3.000	1046.984

Fonte: Autoral.

As variáveis analisadas apresentaram os seguintes valores médios: vibração apresentou uma média de 6,18 mm/s; o diâmetro 146,06 milímetros; os furos 199,98 unidades; o espaçamento 4,51 metros; o tampão médio igual a 2,89 metros; a carga máxima 46,17 Kg e a distância igual a 445,76 metros.

A análise estatística dos dados revela que a variável “Distância” apresenta o maior desvio padrão, atingindo o valor de 255,32. Esse resultado era esperado, visto que esta representa as distâncias entre a operação de detonação e os pontos de monitoramento sismográficos.

Essa variabilidade nas distâncias entre o desmonte e os pontos de monitoramento foi uma prática adotada com o objetivo de se obter uma compreensão mais abrangente do alcance e intensidade das vibrações geradas pela detonação. A diversificação dos pontos de monitoramento, possibilita traçar um perfil mais assertivo

da propagação das vibrações na região circundante, o que leva a uma análise mais precisa dos impactos e da necessidade de medidas de controle.

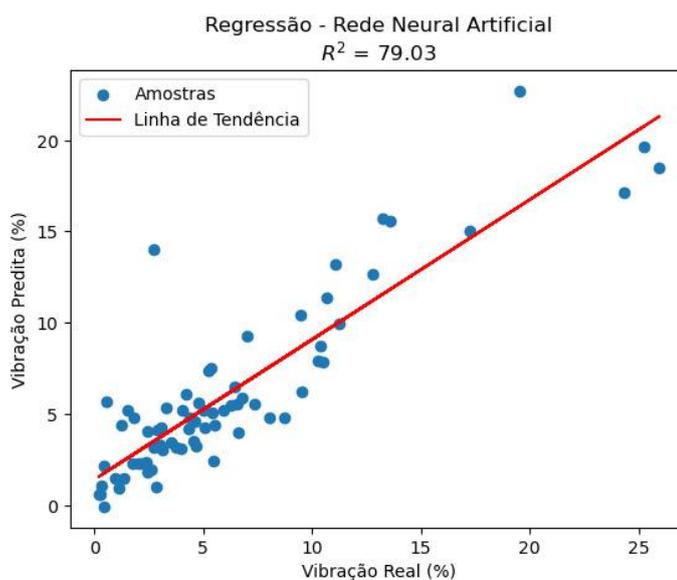
O baixo desvio padrão observado no diâmetro do furo, igual a 0,12, indica uma pequena variabilidade dos dados. Embora, essa constância nos diâmetros do furo seja desejável em algumas situações, como garantir a padronização do processo e a qualidade do desmonte, ela também representa um desafio significativo para a modelagem, comprometendo a capacidade de generalização do modelo para novos dados e também dificultando a identificação de padrões gerais.

5.2. Algoritmos de Regressão

As Figuras 16 e 17 apresentam os gráficos de regressão para os dois modelos aplicados, onde destaca-se um bom ajuste dos dados a linha de tendência. O valor de R^2 igual a 0.7903 para o algoritmo de rede neural (**Erro! Fonte de referência não encontrada.**), indica uma boa correlação entre os valores preditos e os valores reais. Entretanto, ao comparar os dois gráficos de regressão é possível avaliar que o desempenho do algoritmo de floresta aleatória, apresentado na

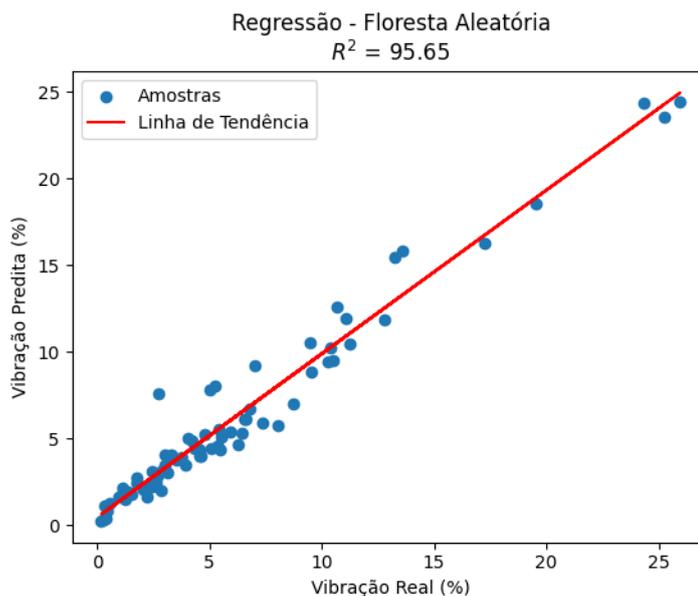
Figura 17, foi o que melhor se ajustou aos dados, alcançando um coeficiente de correlação igual à 95,65%. O fato do banco de dados utilizado ser relativamente pequeno, pode ter dificultado o treinamento da rede neural artificial e ter favorecido a performance do algoritmo *random forest*.

Figura 16: Gráfico de regressão à partir da rede neural artificial.



Fonte: Autoral, 2025.

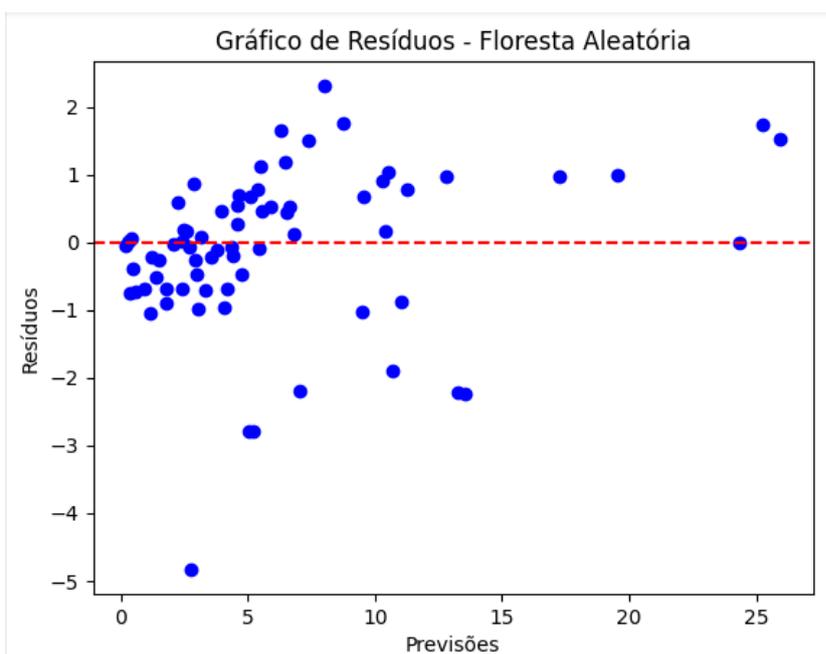
Figura 17: Gráfico de Regressão à partir da floresta aleatória.



Fonte Autoral, 2025.

O gráfico de dispersão ao plotar os resíduos em relação aos valores reais da variável alvo “vibração” à partir do algoritmo de floresta aleatória, apresenta a variação desses erros em um intervalo de -4,9 à 2,3. Em geral, os resíduos devem se distribuir de forma aleatória, o que é observado na Figura 18.

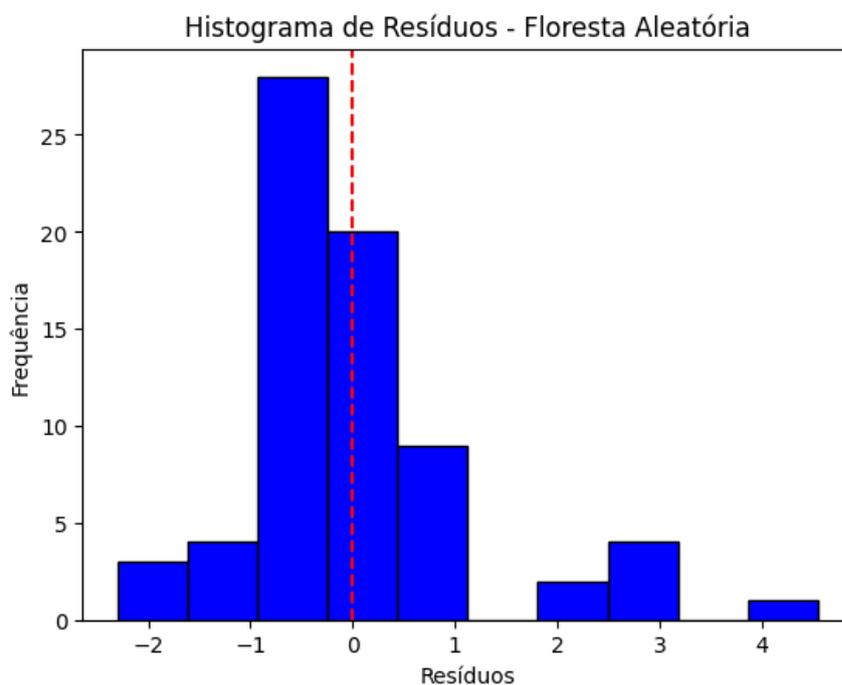
Figura 18: Gráfico de dispersão de resíduos à partir do algoritmo de floresta aleatória.



Fonte: Autoral

Ao analisar o histograma (Figura 19) em conjunto ao gráfico de dispersão, destaca-se uma maior ocorrência de resíduos negativos, o que indica que o modelo tende a ser menos conservador em suas previsões acerca das vibrações. Um modelo menos conservador pode permitir maior variabilidade nos erros desde que a previsão geral seja útil, aceitando um nível maior de incerteza.

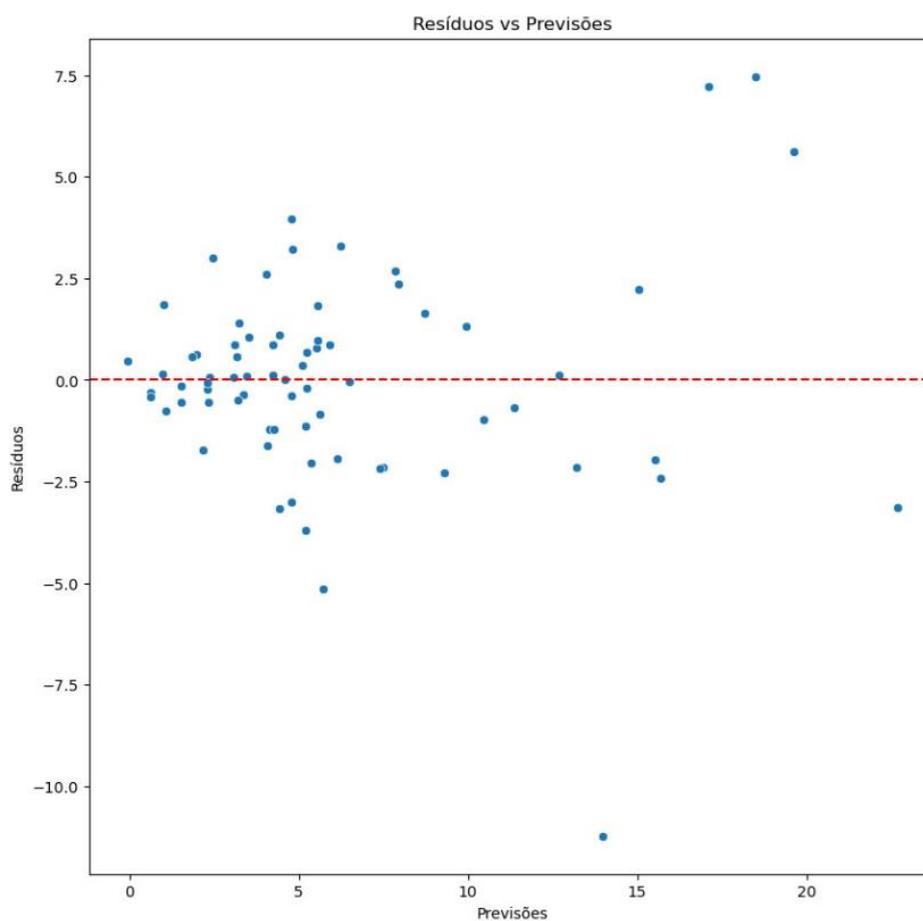
Figura 19: Histograma de resíduos à partir do algoritmo de floresta aleatória.



Fonte: Autoral.

Já no gráfico de dispersão dos resíduos à partir do algoritmo de redes neurais artificiais, apresentado na Figura 20, o intervalo identificado é maior, partindo de -10,5 à 7,5. É possível observar uma aleatoriedade ainda maior na distribuição dos erros em relação ao 0, tal distribuição sugere a ausência de viés no modelo, com erros independentes, demonstrando que as previsões não apresentam uma tendência sistemática de superestimar ou subestimar os valores observados.

Figura 20: Gráfico de resíduos à partir do algoritmo de rede neural artificial.

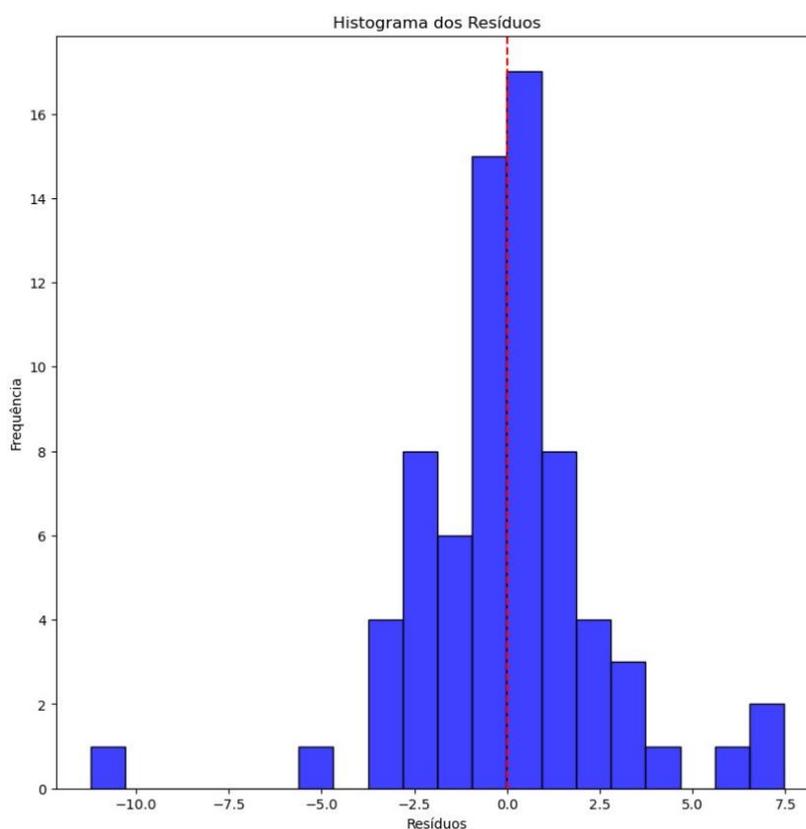


Fonte: Autoral.

O histograma a partir do algoritmo de rede neural artificial, Figura 21, apresenta uma distribuição normal e uma maior frequência de dados positivos, indicando que esse modelo está prevendo mais vibrações que o real adotando uma postura conservadora diferentemente do algoritmo à partir da floresta aleatória.

Ao considerar um cenário em que há risco de segurança na operação, aplicar um modelo mais conservador se torna o mais indicado uma vez que assim, é possível estabelecer limites de segurança mais rígidos e reduzir a probabilidade de ocorrer eventos indesejados, como danos estruturais, garantindo a integridade da operação e a segurança dos trabalhadores.

Figura 21: Histograma de resíduos à partir do algoritmo de rede neural artificial.



Fonte: Autoral.

Os resultados da avaliação do modelo de regressão utilizando redes neurais artificiais e *random forest* encontram-se sumarizados na **Erro! Fonte de referência não encontrada.**, onde são apresentadas as métricas de desempenho.

Com base nos resultados obtidos, é possível observar que o algoritmo *random forest* alcançou uma melhor performance não só no coeficiente de correlação mas

também, apresentou menores erros de previsão quando comparado a rede neural artificial.

Tabela 4: Resultados das métricas de desempenho.

Métricas	Rede Neural Artificial	Random Forest
R ²	79.0278	95.6455
MAE	1.7254	0.8441
MSE	6.7197	1.3952
RMSE	2.5922	1.1812

Fonte: Autoral.

O modelo de rede neural artificial, ao apresentar um Erro Médio Absoluto (MAE) de 1.7254, demonstra uma tendência a gerar vibrações que desviam dos valores reais nessa ordem de grandeza, aproximadamente. Ou seja, o modelo pode subestimar ou superestimar os valores em 1.7254 unidades, magnitude considerada significativa.

Os resultados obtidos com a aplicação dos algoritmos de rede neural artificial e *random forest* para a previsão de vibrações em desmontes de rocha com explosivos demonstraram um potencial promissor, destacado pelas boas respostas alcançadas na regressão em ambas as técnicas.

Visando testar a capacidade de generalização dos algoritmos, torna-se recomendável aplicá-los a outros bancos de dados, abrangendo diferentes cenários. Estes tipos de testes são cruciais para avaliar a robustez e a adaptabilidade dos modelos, verificando se eles conseguem manter o bom desempenho em situações diversas.

6. CONCLUSÃO

A monografia realizada demonstrou a viabilidade e o potencial de aplicação de técnicas de aprendizado de máquina, especificamente redes neurais artificiais e *random forest*, na análise e predição de vibrações em desmontes de rochas com explosivos. Ambas as metodologias apresentaram resultados promissores na modelagem do fenômeno vibratório, evidenciando a capacidade de capturar a complexidade inerente ao processo e estabelecer relações não lineares entre os parâmetros de entrada e a intensidade das vibrações.

Apesar do bom desempenho geral de ambos os algoritmos, o modelo *random forest* se destacou por apresentar um ajuste mais preciso aos dados observados, conforme evidenciado pelas métricas de avaliação utilizadas. Sua capacidade de lidar com um grande número de variáveis e identificar relações complexas entre elas, sem a necessidade de ajustes excessivos dos parâmetros, contribuiu para a sua melhor performance.

Os resultados obtidos neste estudo corroboram a importância da utilização de técnicas de aprendizado de máquina como ferramentas complementares aos métodos empíricos e analíticos tradicionais, oferecendo uma abordagem mais precisa e eficiente para a previsão de vibrações em desmontes de rochas. A capacidade de prever com maior precisão os níveis de vibração permite otimizar o planejamento de desmontes, reduzir custos, aumentar a segurança das operações e minimizar os impactos ambientais e estruturais.

As ferramentas de *machine learning*, como as utilizadas neste estudo, oferecem um grande potencial para aprimorar a gestão de desmontes de rocha, contribuindo para a otimização de processos, a redução de riscos e a promoção de um ambiente de trabalho mais seguro e sustentável.

7. REFERÊNCIAS BIBLIOGRÁFICAS

ALONSO, J. B.; GÓMEZ, J. C.; HERBERT, J. H. H. ***Peforación y Voladura de Rocan en Minería***. Madri: Universidad Politécnica de Madrid, 2013.

BRAGA, Antonio de Pádua; LUDERMIR, Teresa Bernarda e CARVALHO, André Carlos Ponce de Leon Ferreira de. ***Redes neurais artificiais: teoria e aplicações***. Rio de Janeiro: LTC.

BORG, O. G. ***Bulk loaded emulsion explosives technology***. Coai Magazine, Chicago, v.1 00, n.1, p.27 -33, 1995.

CAMERON, A. R.; ADAMSON, W. R. ; McKENZIE, C. K. ***Measuring the performance of commercial explosives under field conditions***. Brisbane, Australia: 1990. Fragblast 90, p.1 -11.

CANDIA, C. R. ***Escavação de rochas com furos de grande diâmetro na mineração a céu aberto***. Edição revista. São Paulo, 2006.

CETESB D7.013. ***Avaliação e monitoramento das operações de desmonte de rochas com uso de explosivo na mineração: Procedimento***. São Paulo: CETESB. 2015. 8 p.

CURI, A. ***Minas a Céu Aberto – Planejamento de Lavra***. São Paulo: Oficina de textos, 2014.

Departamento Nacional de Produção Mineral (DNPM). ***Capítulo 4: Planejamento na Mineração***. In: DNPM. Plano Diretor de Mineração para a Região Metropolitana de Curitiba. Curitiba: DNPM, 2004. p. 135-184.

Departamento Nacional de Produção Mineral (DNPM). ***A Importância Econômica da Mineração no Brasil***. Brasília: DNPM, 2011.

DHEKNE, P. Y. ***Environmental impacts of rock blasting and their mitigation***. International Journal of Chemical, Environmental & Biological Sciences. Vol. 3, 2015.

DINIS DA GAMA, C.; BERNARDO, P.A.M. **Condições Técnicas para Uso de Explosivos na Escavação de Túneis Urbanos em Maciços Rochosos**. Curso sobre Túneis em Meios Urbanos (organizado por SPG e FCT-UC) – Coimbra. 2001.

DINIS DA GAMA, C. **Ruídos e Vibrações Ligados à Utilização dos Explosivos e Equipamentos**. Comunicações do 1º Seminário de Auditorias Ambientais Internas. Divisão de Minas e Pedreiras do Instituto Geológico e Mineiro de Portugal. 1998.

DUTRA, R. Mineração – **Atividades e Responsabilidades**. Associação Paulista de Engenheiros de Minas. Ponta Grossa/PR, 2014. Disponível em: Acesso em: 10 out. 2024.

ESSEN, S.; ONEDERRA, I.; BILGIN, H.A. **Modelling the size of the crushing zone around a blast hole**. International journal of rock mechanics and mining sciences, Vol. 40, p. 485 – 495, 2003.

GAMBERINI, A. A.; NASCIMENTO, F. P.; DUARTE, J. M.; RIBEIRO, L. L.; DAMASCENO, L. A.; SILVA, M. M.; BUENO, M. i. P. P.; LEMES, R. B.; GONÇALVES, R. M. O.; SILVA, S. S. M.; ARAÚJO, S. S. S.; BRAGA, W. O. **Manual de Normalização de Trabalhos Acadêmicos**. Belo Horizonte, 2022.

GOMES, J. P. M. A. **Metodologia para Análise de Vibrações provocadas por Desmontes com Recurso a Explosivos**. Dissertação (mestrado em Engenharia de Minas de Geo-Ambiente). Portugal: Universidade do Porto, 2016.

HAGAN, T. N. **Rock Breakage by Explosives**. Acta Astronautica, Melbourne, Vol. 6, Nº 3-4, pp. 329-340, Março, 1979.

HARTMAN, H. L. et al. **Introduction to Mining**. In: Hartman, H. L. (ed.) **Mining Engineering Handbook**. 2nd ed. Littleton: Society for Mining, Metallurgy, and Exploration, Inc., 1992. pp. 3-41.

HARTMAN, H. L.; MUTMANSKY, J. M. **Introductory Mining Engineering**. 2. ed. John Wiley and Sons, 2002.

HOEK, E. **Strength of Jointed Rock Masses**. Geotechnique, Vol. 33, Nº 3, pp. 187-223, Setembro, 1983.

ICI. **Teoria de desmonte de rochas**. Rio de Janeiro, 1989, 302p.

JIMENO et al. **Manual de Perforación y Voladura de Rocas**. Madrid: Instituto Geológico y Minero de España, 1994.

JIMENO, C. L.; JIMENO, E. L.; BERMÚDEZ, P. G. **Manual de Perforación y Voladura de Rocas**. Madrid: Instituto Tecnológico Geominero de España, 2003.

KOHAVI, R. **A study of cross-validation and bootstrap for accuracy estimation and model selection**. In: International joint Conference on artificial intelligence. [S.l.: s.n.], 1995. v. 14, p. 1137–1145.

KONYA, C., J. **Priming blasting agents**. Engineering and Mining Journal, Chicago, v.196, n.11. p.41-42, 1996a.

LANGFORS, U.; KIHLLSTROM, B. **Técnica moderna de voladura de rocas**. Espartero, Espanha, 1963. 425p.

MCCARTER, M. K. et al. **Mining Exploitation**. In: Hartman, H. L. (ed.) **Mining Engineering Handbook**. 2nd ed. Littleton: Society for Mining, Metallurgy, and Exploration, Inc., 1992. pp. 1365-1451.

MENDES, M. L. **Curso de Desmonte de Rochas por Explosivos**. Disponível em: <http://fliphtml5.com/peale/jzhn/basic>. Acesso em: 15 de Jan. de 2025.

NBR 9653: 2018. **Guia para avaliação dos efeitos provocados pelo uso de explosivos nas minerações em áreas urbanas**. Rio de Janeiro. Associação Brasileira de Normas Técnicas, 2018.

OLOFSSON, S. O. **Applied Explosives Technology for Construction and Mining**. Arla: APPLEPLEX, 1998.

HUB, Realize. **O que são Redes Neurais**. [S. l.]: Realize Hub, 2022. Disponível em: <https://realizehub.com/o-que-sao-redes-neurais/>. Acesso em: 15 dez. 2024

ROCHA, S. S. **Análise comparativa dos benefícios econômicos, operacionais e ambientais do método Terrace Mining na mineração de gipsita do polo gesseiro do Araripe**. Dissertação (Mestrado) - Universidade federal de Pernambuco, Recife, 2017. Disponível em: <https://repositorio.ufpe.br/handle/123456789/26893>.

Acesso em: 13 Out. de 2024

RODRIGUES, L. A. **Otimização de desmonte de rocha: com auxílio do Software O-PITBLAST**. 2017. Centro Universitário Luterano de Palmas, 2017.

SANTOS, A. E.; FONTES, M. P. **Apostila de Lavra de Mina**. Araxá: Centro Federal de Educação Tecnológica de Minas Gerais. 2020.

SCIENCELEARN. **Seismic Wave**. Internet. Disponível em: <http://sciencelearn.org.nz/>
Acesso em: 20 Dez. 24

SILVEIRA, L. G. C. **Controle de vibrações e pressão acústica no desmonte de rochas com explosivos: estudo de caso em uma mina do Quadrilátero Ferrífero**. 2017. Dissertação (Pós- Graduação em Engenharia Mineral) - Escola de Minas da Universidade Federal de Ouro Preto, [S. l.], 2017.

SCOTT, A. **Open pit blast design: analysis and optimization**. Brisbane, Australia:, The University of Queensland, Julius Kruttschnitt Mineral Research Centre: 1996, 338p.

SILVA, Valdir C. **Desmonte de Rochas**. São Paulo, 2019.

TAMROCK. **Handbook on surface drilling and blasting**. Tampere, Finland: 1984. Tampella, 308p.

UNPINGCO, José. **Python for Probability, Statistics, and Machine Learning**. 2. ed. [S. l.]: Springer, 2019.

Verum Partners. **A importância da mineração**. Verum Partners, 2020. Disponível em: < <https://verumpartners.com.br/a-importancia-da-mineracao-no-brasil/>>. Acesso em: 19/01/2022.

APÊNDICE

Vibração (mm/s)	Diâmetro (m)	Furos (unid)	Espaçamento (m)	Tampão (m)	Q máxima (Kg)	Explosivo	Distância (m)
17.27	146.05	317	5	2.5	60	001	111.46
11.06	146.05	317	5	2.5	60	001	188.20
10.68	146.05	317	5	2.5	60	001	281.79
10.53	146.05	317	5	2.5	60	001	575.40
5.35	146.05	317	5	2.5	60	001	604.85
0.42	146.05	197	5	2.5	60	003	1046.98
0.32	146.05	197	5	2.5	60	003	799.21
2.05	146.05	197	5	2.5	60	003	658.42
5.10	146.05	197	5	2.5	60	003	433.74
1.51	146.05	197	5	2.5	60	003	319.15
4.20	146.05	197	5	2.5	60	003	240.64
4.56	146.05	250	4	4	35	003	494.62
2.43	146.05	250	4	4	35	003	438.16
1.12	146.05	250	4	4	35	003	765.48
4.40	146.05	250	4	4	35	003	365.20
10.29	146.05	200	4	2.25	29	003	192.78
0.55	146.05	200	4	2.25	29	003	296.73
5.53	146.05	200	4	2.25	29	003	391.58
3.31	146.05	200	4	2.25	29	003	319.59
6.44	146.05	200	4	2.25	29	003	253.84
4.59	147.05	200	4	2.25	29	003	380.50
4.35	146.05	200	4	2.25	29	003	410.72
6.64	146.05	200	4	2.25	29	003	430.58
3.76	146.05	200	4	2.25	29	003	521.50
6.30	146.05	200	4	2.25	29	003	308.93
12.80	146.05	200	4	2.25	29	003	54.93
1.76	146.05	200	4	2.25	29	003	612.67
6.78	146.05	187	4	4	35	003	249.99
7.37	146.05	187	4	4	35	003	284.19
3.96	146.05	187	4	4	35	003	661.03
8.03	146.05	187	4	4	35	003	374.44
2.92	146.05	187	4	4	35	003	494.62
4.07	146.05	187	4	4	35	003	322.67
1.38	146.05	150	4	4	35	003	930.52
5.22	146.05	150	4	4	35	003	132.74
3.12	146.05	150	4	4	35	003	746.82
5.02	146.05	150	4	4	35	003	308.60
2.41	146.05	150	4	4	35	003	837.37
2.75	146.05	200	5	4	35	003	208.03

4.77	146.05	200	5	4	35	003	391.80
13.27	146.05	200	5	4	35	003	176.78
25.96	146.05	200	5	4	35	003	124.05
24.33	146.05	200	5	4	35	003	150.49
5.43	146.05	200	5	4	35	003	408.69
25.25	146.05	170	5	2.8	35	002	307.25
19.54	146.05	170	5	2.8	35	002	229.81
3.55	146.05	170	5	2.8	35	002	796.10
13.57	146.05	170	5	2.8	35	002	395.21
5.47	146.05	170	5	2.8	35	002	884.49
1.79	146.05	170	5	2.8	35	002	706.62
6.54	146.05	180	5	2.3	65	003	239.76
8.75	146.05	180	5	2.3	65	003	329.30
2.60	146.05	180	5	2.3	65	003	750.67
3.00	146.05	180	5	2.3	65	003	584.50
2.85	146.05	180	5	2.3	65	003	874.91
0.30	146.05	180	5	2.3	65	003	946.92
0.19	146.05	180	5	2.3	65	003	946.12
2.44	146.05	180	5	2.3	65	003	764.22
0.45	146.05	180	5	2.3	65	003	729.43
2.21	146.05	180	5	2.3	65	003	717.14
4.64	146.05	180	5	2.3	65	003	600.52
2.71	146.05	180	5	2.3	65	003	607.45
3.05	146.05	180	5	2.3	65	003	413.33
5.91	146.05	200	4	2.5	60	003	247.24
9.53	146.05	200	4	2.5	60	003	216.18
10.38	146.05	200	4	2.5	60	003	135.18
9.48	146.05	200	4	2.5	60	003	72.45
11.26	146.05	200	4	2.5	60	003	91.98
7.02	146.05	200	4	2.5	60	003	115.36
1.23	146.05	200	4	2.5	60	003	273.51
0.94	146.05	200	4	2.5	60	003	372.58