

**ISMAEL DA SILVEIRA CAVALCANTE**

**PREVISÃO DA OCORRÊNCIA DE INSTABILIDADE EM RAMPAS  
DE UMA MINA SUBTERRÂNEA BRASILEIRA POR MEIO DE  
TÉCNICAS DE APRENDIZADO DE MÁQUINA**

**São Paulo**

**2021**

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

### Catálogo-na-publicação

Cavalcante, Ismael  
PREVISÃO DA OCORRÊNCIA DE INSTABILIDADE EM  
RAMPAS DE UMA MINA SUBTERRÂNEA BRASILEIRA POR MEIO  
DE TÉCNICAS DE APRENDIZADO DE MÁQUINA / I. Cavalcante --  
São Paulo, 2021.

57 p.

Trabalho de Formatura - Escola Politécnica da Universidade  
de São Paulo. Departamento de Engenharia de Minas e de  
Petróleo.

1.Lavra Subterrânea 2.Classificação de Maciços Rochosos  
3.Estabilidade 4.Aprendizado de Máquina I. Universidade de São Paulo.  
Escola Politécnica. Departamento de Engenharia de Minas e de Petróleo  
II.t.

**ISMAEL DA SILVEIRA CAVALCANTE**

**PREVISÃO DA OCORRÊNCIA DE INSTABILIDADE EM RAMPAS  
DE UMA MINA SUBTERRÂNEA BRASILEIRA POR MEIO DE  
TÉCNICAS DE APRENDIZADO DE MÁQUINA**

Trabalho de conclusão do curso de  
graduação em Engenharia de Minas do  
Departamento de Engenharia de Minas e de  
Petróleo da Escola Politécnica da  
Universidade de São Paulo.

Orientador: Prof. Dr. Eduardo Cesar Sansone

**São Paulo**

**2021**

## **AGRADECIMENTOS**

Agradeço primeiramente a Deus pela minha vida e por ter me dado a oportunidade de concluir o curso de Engenharia de Minas da Escola Politécnica da USP. A Raquel que sempre esteve ao meu lado e por sua dedicação em me ajudar. A minha família cujo apoio foi incondicional nas minhas decisões e no meu aprendizado.

Agradeço ao meu orientador Professor Dr. Eduardo Cesar Sansone que sempre ministra as suas aulas com muita didática e me auxiliou no meu TCC com muita paciência e dedicação.

Agradeço também a todos os meus colegas que me ajudaram nas atividades realizadas, principalmente ao meu irmão Israel que sempre esteve ao meu lado, literalmente, nas aulas.

## RESUMO

Os projetos de Engenharia relacionados a taludes, fundações, túneis, poços, cavernas e painéis de lavra, entre outros, são realizados em maciços rochosos que com frequência são heterogêneos e estão submetidos a tensões que podem causar deformações nas escavações ou mesmo levar à sua ruptura. Desta forma, as técnicas que provêm da Estatística e da Ciência de Dados são ferramentas úteis à análise das obras em rocha. Esta pesquisa tem como objetivo aplicar técnicas de aprendizado de máquina (Redes Neurais Artificiais, Redes Bayesianas, Máquinas de Vetores de Suporte e Regressão Logística) na previsão da ocorrência de instabilidade em rampas de uma mina subterrânea brasileira. A metodologia empregada se baseou na análise de dados relativos a RQD, RMR, Q, Largura, Altura e Cota levantados pela equipe de Geomecânica da mina em 10 rampas, para um total de 199 pontos. Inicialmente foram selecionados os melhores indicadores da ocorrência de instabilidade nas rampas, por meio da análise das distribuições de frequências e de testes de hipótese para a igualdade entre as médias de cada parâmetro a um nível de confiança de 95%, comparando os pontos estáveis e os pontos com instabilidade. Os parâmetros selecionados foram: RQD, RMR, Q e Cota. Foi também identificado que a associação entre Cota e RMR se constitui no melhor indicador da ocorrência de instabilidade. Na sequência foi realizado o treinamento de classificadores segundo as técnicas de aprendizado de máquina: Redes Neurais Artificiais, Redes Bayesianas, Máquinas de Vetores de Suporte e Regressão Logística. A análise das matrizes de confusão dos classificadores para um conjunto de teste permitiu o cálculo da acurácia e da precisão da previsão das condições de estabilidade e de instabilidade nas rampas. O classificador Rede Bayesiana foi considerado o mais adequado por apresentar uma boa acurácia e uma precisão de 100% para a previsão da condição de estabilidade. O classificador selecionado poderá ser usado pelas equipes de projeto e de lavra da mina como uma ferramenta auxiliar na indicação na possibilidade da ocorrência de instabilidade em pontos de novas rampas na mina com alta eficiência na previsão da condição de estabilidade.

Palavras-Chave: Lavra Subterrânea, Classificação de Maciços Rochosos, Estabilidade, Aprendizado de Máquina.

## **ABSTRACT**

Engineering projects related to slopes, foundations, tunnels, wells, caves and mining panels, among others, are carried out in rock masses that are often heterogeneous and are occurring at stresses that can cause deformations in the excavations or even lead to their rupture. In this way, the techniques that come from Statistics and Data Science are useful tools for the analysis of rock works. This research aims to apply Machine Learning Techniques (Artificial Neural Networks, Bayesian Networks, Support Vector Machines and Logistic Regression) to predict the occurrence of instability in slopes of a Brazilian underground mine. The methodology used was based on the analysis of data relating to RQD, RMR, Q, Width, Height and Dimension collected by the mine's Geomechanics team in 10 ramps, for a total of 199 points. Initially, the best indicators of the occurrence of instability on the slopes were selected, through the analysis of frequency distributions and hypothesis tests for equality between the means of each parameter at a confidence level of 95%, comparing the stable points and the points with instability. The selected parameters were: RQD, RMR, Q and Quota. It was also identified that the association between Cota and RMR constitutes the best indicator of the occurrence of instability. Next, classifiers were trained according to machine learning techniques: Artificial Neural Networks, Bayesian Networks, Support Vector Machines and Logistic Regression. An analysis of the classifiers' confusion matrices for a standard test set to calculate the accuracy and precision of the prediction of stability and instability conditions in the slopes. The Bayesian Network classifier was considered the most suitable for presenting good accuracy and 100% precision for predicting the stability condition. The selected classifier can be used by the mine's project and mining teams as an auxiliary tool in indicating the possibility of instability occurring at points of new mine slopes with high efficiency in predicting the stability condition.

**Keywords:** Underground Mine, Classification of Rocky Masses, Stability, Machine Learning.

## SUMÁRIO

<b>1. INTRODUÇÃO .....</b>	<b>12</b>
1.1 OBJETIVO .....	13
<b>2. REVISÃO DA LITERATURA .....</b>	<b>14</b>
2.1 PARAMETROS CARACTERÍSTICOS DO COMPORTAMENTO MECÂNICO DAS ROCHAS .....	14
2.1.1. Resistência à compressão uniaxial .....	14
2.1.2. Resistência à tração.....	15
2.2 MACIÇO ROCHOSO.....	16
2.3. CLASSIFICAÇÕES DE MACIÇOS ROCHOSOS.....	18
2.3.1. Rock Quality Designation Index (RQD) .....	18
2.3.2. Rock Mass Rating (RMR) .....	20
2.3.3 Q System.....	21
2.4 TÉCNICAS DE APRENDIZADO DE MÁQUINA .....	23
2.4.1. Redes neurais artificiais .....	23
2.4.2. Redes Bayesianas.....	24
2.4.3. Máquinas de vetores de suporte.....	25
2.4.4. Regressão logística .....	27
2.5. ANÁLISE DO DESEMPENHO DE CLASSIFICADORES NO APRENDIZADO DE MÁQUINA.....	28
2.5.1. Matriz de confusão .....	28
2.5.2. Acurácia e Precisão .....	29
<b>3. MATERIAIS E MÉTODOS.....</b>	<b>31</b>
3.1. MATERIAIS UTILIZADOS .....	31
3.2. METODOLOGIA EMPREGADA.....	33
<b>4. RESULTADOS E DISCUSSÃO.....</b>	<b>35</b>

4.1 SELEÇÃO DOS MELHORES INDICADORES DA OCORRÊNCIA DE INSTABILIDADE.....	35
<b>4.1.1. RQD .....</b>	<b>35</b>
4.1.2 RMR.....	36
4.1.3 Índice Q .....	37
4.1.4. Largura .....	38
4.1.5. Altura.....	39
4.1.6. Cota.....	40
4.2. SELEÇÃO DA ASSOCIAÇÃO ENTRE 2 VARIÁVEIS COMO MELHOR INDICADOR DA OCORRÊNCIA DE INSTABILIDADE NAS RAMPAS.....	42
<b>4.2.1 Associação Cota x RQD .....</b>	<b>42</b>
<b>4.2.2 Associação Cota x Q .....</b>	<b>43</b>
<b>4.2.3 Associação Cota x RMR .....</b>	<b>43</b>
4.3. TREINAMENTO DOS CLASSIFICADORES .....	44
<b>4.3.1. Classificador Rede Neural Artificial.....</b>	<b>45</b>
<b>4.3.2. Classificador Redes Bayesianas.....</b>	<b>46</b>
<b>4.3.3. Classificador Máquina de Vetores de Suporte .....</b>	<b>48</b>
<b>4.3.4. Classificador Regressão Logística .....</b>	<b>50</b>
<b>5. CONCLUSÃO.....</b>	<b>54</b>
<b>REFERÊNCIAS.....</b>	<b>55</b>



## LISTA DE FIGURAS

Figura 1 – Aplicação de uma força de compressão na direção perpendicular (A) e paralela (B) à estrutura da rocha .....	14
Figura 2 - Ensaio de compressão uniaxial.....	15
Figura 3 - Ensaio de tração.....	15
Figura 4 - Ensaio de tração indireta (ensaio brasileiro) .....	16
Figura 5 – Exemplo de maciço rochoso com suas descontinuidades .....	17
Figura 6 - Características das descontinuidades .....	17
Figura 7 - Recomendações de suporte a partir do RQD para um túnel com 6 m de largura .....	19
Figura 8 – Parâmetros da classificação RMR.....	21
Figura 9 - Categorias de suporte recomendadas pelo Q System .....	22
Figura 10 – Neurônio biológico.....	23
Figura 11 – Exemplo de Rede neural artificial.....	24
Figura 12 – Grafos acíclico (A) e direcional (B) .....	25
Figura 13 – Possíveis hiperplanos de separação para um conjunto de dados com 2 classes .....	26
Figura 14 - Melhor hiperplano de separação.....	27
Figura 15 - Função logística.....	28
Figura 16 - Matriz de confusão 2x2 .....	29
Figura 17 - Representação gráfica das rampas com os tipos de rochas presentes nos pontos amostrados.....	32
Figura 18 - Pontos de instabilidade nas rampas de A até J .....	33
Figura 19 – Distribuição de frequências para o RQD .....	35
Figura 20 - Distribuição de frequências para o RMR .....	36
Figura 21 - Distribuição de frequências para o índice Q .....	37
Figura 22 – Distribuição de frequências para a Largura .....	38
Figura 23 – Distribuição de frequências para a Altura .....	39
Figura 24 – Distribuição de frequências para a Cota.....	40
Figura 25 - Associação RQD X Cota.....	42
Figura 26 – Associação Cota x Q .....	43
Figura 27 - Associação Cota x RMR .....	44
Figura 28 – Classificador Redes Neurais Artificiais e conjunto de dados de teste .....	45

Figura 29 - Matriz de confusão do classificador Rede Neural Artificial .....	46
Figura 30 - Classificador de Redes Bayesianas e conjunto de dados de teste.....	47
Figura 31 - Matriz de confusão do classificador Rede Bayesiana.....	48
Figura 32 - Classificador Máquina de Vetores de Suporte e conjunto de dados de teste	49
Figura 33 – Matriz de confusão do classificador Máquina de Vetores de Suporte .....	50
Figura 34 – Classificador Regressão Logística e conjunto de dados de teste .....	51
Figura 35 – Matriz de confusão do classificador Regressão Logística.....	52

## LISTA DE TABELAS

Tabela 1 - Qualidade do maciço rochoso em função do RQD .....	19
Tabela 2 - Tipos de rochas identificadas nas rampas (classificação adotada pela empresa .....)	31
Tabela 3 - Tipos de rochas nas rampas de A até J .....	32
Tabela 4 – Estatísticas para os parâmetros levantados .....	33
Tabela 5 - Estatísticas para o RQD .....	36
Tabela 6 - Estatística RMR .....	37
Tabela 7 - Estatísticas para o índice Q .....	38
Tabela 8 - Estatísticas para a Largura .....	39
Tabela 9 - Estatísticas para a Altura .....	40
Tabela 10 - Estatísticas para a Cota .....	41
Tabela 11 – Resumo dos testes de hipóteses .....	41
Tabela 12 – Acurácia e precisão dos classificadores para o conjunto de dados de teste	52

## 1. INTRODUÇÃO

A realização de obras em rocha é uma atividade que teve origem nos primórdios de nossa civilização e em razão de sua grande importância tem ganhado cada vez mais destaque em nossos dias. Estas obras estão relacionadas principalmente a atividades de mineração, construção civil e produção de petróleo.

As obras em rocha podem ser realizadas em superfície, como as cavas de minas a céu aberto, os cortes para a passagem de estradas; e em subterrâneo, como as minas subterrâneas, os túneis e os poços de petróleo. De modo geral, os projetos de Engenharia envolvendo este tipo de atividade podem ser agrupados nas seguintes categorias: taludes, fundações, túneis, poços, cavernas, painéis de lavra, obras de produção de energia geotérmica e armazenamento de rejeitos radioativos, entre outros (HARTMAN e MUTMANSKY, 2002).

O projeto destas obras deve ser realizado de modo a permitir que estas desempenhem sua função com eficiência e ao mesmo tempo proporcionem segurança para a operação e para os usuários. Para tanto, se torna importante aplicar os conceitos da Mecânica das Rochas, a área tecnológica que tem como finalidade estudar as propriedades e o comportamento das Rochas e dos Maciços Rochosos quando estes sofrem a ação de tensões (HARRISON e HUDSON, 2000).

Os maciços rochosos estão sempre submetidos a tensões que podem causar deformações ou mesmo levar à sua ruptura. A origem destas tensões pode ser atribuída a causas naturais ou induzida pela realização de obras de Engenharia. As primeiras são aquelas que atuam nas rochas em razão de algum fator condicionante anterior, como o efeito gravitacional ou os esforços tectônicos atuantes na crosta terrestre. Enquanto as segundas estão associadas às perturbações no meio provocadas pelas próprias escavações (HOEK, 2007).

As tensões naturais gravitacionais apresentam componentes que se orientam segundo as direções vertical e horizontal, mas a presença de outros tipos de esforços pode mudar esta configuração. Estas tensões atuando sobre as escavações, tanto em superfície quanto em profundidade, provocam deformações, sendo a relação entre estas, ditada pelo particular comportamento mecânico da rocha escavada (BRADY e BROWN, 1993).

Uma característica particular do projeto de obras em rocha, e que acrescenta um grande complicador em uma comparação com o projeto de outros tipos de obras, é a

grande variabilidade natural das rochas e das estruturas presentes em um maciço rochoso. Isto se dá em virtude da diversidade de processos que se manifestam na evolução geológica da crosta terrestre e produzem como resultado uma distribuição complexa de materiais com características mecânicas diversas, variáveis e anisotrópicas, além da presença de descontinuidades distribuídas de forma muitas vezes caótica (HOEK, 2007).

Desta forma, a caracterização e a determinação dos parâmetros mecânicos das rochas presentes na região da obra, se tornam tarefas difíceis e que tendem a apresentar resultados com grande incerteza associada (CAO, WANG e LI, 2016).

Tal fato introduz a necessidade da realização de análises estatísticas quando do projeto das obras em rocha. Simulações estatísticas permitem a avaliação da influência da variabilidade dos dados de entrada sobre resultados como a distribuição das tensões e deformações na periferia das escavações, bem como, a ocorrência de instabilidade, ruptura e o colapso estrutural (CAO, WANG e LI, 2016).

As técnicas de aprendizado de máquina provêm da Estatística e da Ciência de Dados e se constituem em uma coleção de métodos que permitem identificar correlações e padrões em problemas multivariados, como são os problemas do projeto de obras em rocha. Neste sentido, estes métodos têm despertado grande interesse nos últimos anos e estão sendo cada vez mais aplicados nesta área.

## 1.1 OBJETIVO

A pesquisa tem como objetivo aplicar técnicas de aprendizado de máquina (Redes Neurais Artificiais, Redes Bayesianas, Máquinas de Vetores de Suporte e Regressão Logística) na previsão da ocorrência de instabilidade em rampas de uma mina subterrânea brasileira.

## 2. REVISÃO DA LITERATURA

### 2.1 PARAMETROS CARACTERÍSTICOS DO COMPORTAMENTO MECÂNICO DAS ROCHAS


#### 2.1.1. Resistência à compressão uniaxial

A resistência à compressão uniaxial é determinada através de um ensaio onde é aplicada uma tensão compressiva sobre uma amostra do material rochoso. O objetivo é identificar a tensão máxima que a rocha suporta antes de ocorrer a ruptura. Uma das suas grandes aplicações está nas classificações de maciços rochosos (SAAR, 2013).

A resistência da rocha está relacionada a diversos fatores característicos do maciço rochoso, por exemplo: direção da força de compressão em relação à estrutura da rocha, estado de alteração da rocha, anisotropia, microfissuras, porosidade e dimensões dos grãos minerais (SAAR, 2013).

A anisotropia da rocha e a direção da força aplicada na compressão, seja paralela ou perpendicular ao bandamento, pode condicionar o valor da resistência à compressão uniaxial, como mostra a figura 1.

Figura 1 – Aplicação de uma força de compressão na direção perpendicular (A) e paralela (B) à estrutura da rocha



Fonte: SAAR (2013)

O ensaio de compressão uniaxial é realizado em uma amostra de rocha cilíndrica que é colocada em uma prensa que aplica esforços de compressão. Assim, a amostra fica submetida a uma tensão de compressão  $\sigma_c$ , resultado de uma força normal  $N$  aplicada sobre a área da base  $A$ , como mostra a figura 2 (CHIOSSI, 2013).

$$\sigma_c = \frac{N}{A} \quad (1)$$

Figura 2 - Ensaio de compressão uniaxial



Fonte: CHIOSSI (2013)

### 2.1.2. Resistência à tração

A resistência a tração é uma medida da tensão aplicada de modo a tracionar a rocha até a sua ruptura. As rochas não suportam grandes esforços de tração pois normalmente possuem fraturas preexistentes e também poros que facilitam a ruptura da rocha (CHIOSSI, 2013).

A determinação da resistência a tração segue o mesmo raciocínio da resistência a compressão, como mostra a figura 3, onde a resistência a tração  $\sigma_T$  será dada por (CHIOSSI, 2013):

$$\sigma_T = \frac{N}{A} \quad (2)$$

Figura 3 - Ensaio de tração



Fonte: CHIOSSI (2013)

Outra forma de determinar a resistência a tração da rocha é usando o ensaio de tração indireta, conhecido como ensaio brasileiro. A amostra de teste tem a forma de um disco, com proporção entre espessura e diâmetro de 0,5. Aplica-se uma força de compressão na direção do diâmetro e a ruptura ocorre no centro e avança no sentido dos pontos de carregamento. A resistência a tração  $\sigma_T$  é dada por (NAGARATNAM, SANJAY e BRAJA, 2013):

$$\sigma_T = \frac{2P}{\pi dt} \quad (3)$$

Onde:


$P$  – Carga na ruptura

$d$  – diâmetro da amostra

$t$  – espessura da amostra

A figura 4 mostra o ensaio para a determinação da resistência a tração de forma indireta (Nagaratnam et al. 2013).

Figura 4 - Ensaio de tração indireta (ensaio brasileiro)



Fonte: (Nagaratnam et al. 2013)


## 2.2 MACIÇO ROCHOSO

Maciço rochoso pode ser definido como a associação entre a rocha (material rochoso) e as descontinuidades (juntas, planos de acamamento, superfícies de clivagem, xistosidades etc.) geradas pelos processos geológicos que atuaram em certa região da crosta terrestre (BRADY e BROWN, 1993).

A figura 5 mostra à esquerda um exemplo de maciço rochoso com seu padrão de faturamento que é representado de forma esquemática à direita.



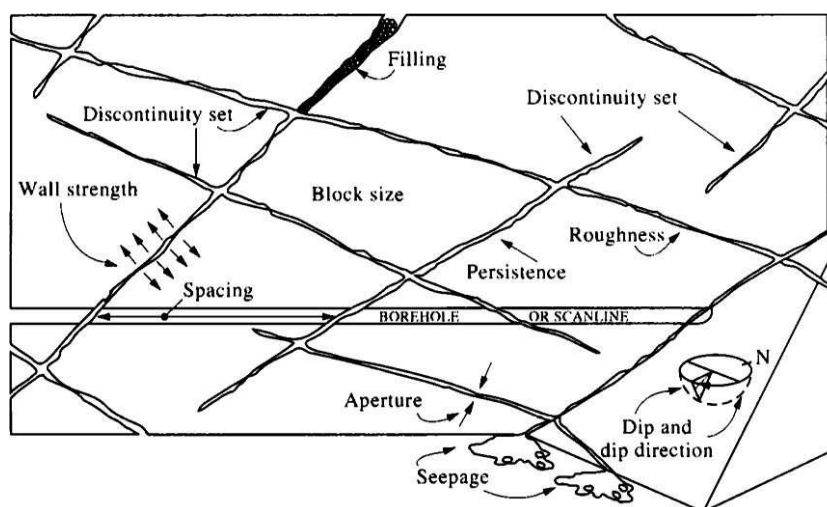
Figura 5 – Exemplo de maciço rochoso com suas descontinuidades



Fonte: Adaptado de BRADY e BROWN (1993)

As principais características das descontinuidades são: orientação, número de famílias, espaçamento, persistência, tamanho de bloco, rugosidade, resistência das paredes, abertura, preenchimento e infiltração de água, como mostra a figura 6. Estas características devem ser levantadas no campo por meio de procedimentos padronizados. Estas informações serão dados de entrada das classificações de maciços rochosos.

Figura 6 - Características das descontinuidades



Fonte: BRADY e BROWN (1993)

## 2.3. CLASSIFICAÇÕES DE MACIÇOS ROCHOSOS

As classificações de maciços rochosos são métodos empregados no projeto de obras em rocha que se baseiam na caracterização de campo e na utilização da experiência acumulada a partir da observação de projetos bem ou mal sucedidos (BIENIAWSKI, 1989).

Uma “classificação” é construída a partir da compilação de um banco de dados composto das características de obras acompanhadas durante suas fases de concepção, execução e operação, reunindo informações sobre: características da rocha intacta ou sã, características das descontinuidades, tensões *in situ*, presença de água no maciço rochoso, tipo de obra (por exemplo: túnel, talude, painel de lavra etc.) e características geométricas da obra (BIENIAWSKI, 1989).

Os resultados finais de uma classificação de maciços rochosos são o enquadramento do maciço rochoso em estudo segundo classes predefinidas e também a apresentação de orientações para a realização do projeto, especialmente quanto aos sistemas de suporte e segurança a serem utilizados (BIENIAWSKI, 1989).

As classificações de maciços rochosos são úteis nos estágios preliminares de um projeto de mineração, quando são conhecidas poucas informações sobre o maciço rochoso. São ainda mais importantes nas operações rotineiras da mina, pois permitem introduzir rapidamente correções sobre o projeto inicial em função da variabilidade dos maciços rochosos (BIENIAWSKI, 1989).

Como os vários sistemas de classificação enfatizam diferentes parâmetros, recomenda-se a utilização de mais de um deles. O uso das classificações de maciços rochosos não deve substituir as metodologias de projeto mais elaboradas, deve sim, complementá-las.

Ao longo das últimas décadas foram propostas diversas classificações, tais como: classificação de Terzaghi, Rock Quality Designation index (RQD), Rock Structure Rating (RSR), Rock Mass Rating (RMR) e Sistema Q, entre outras (BIENIAWSKI, 1989).

### 2.3.1. Rock Quality Designation Index (RQD)

A classificação foi proposta visando estimar a qualidade dos maciços rochosos a partir da análise de testemunhos de sondagem. É baseada em um único índice chamado RQD (BIENIAWSKI, 1989).

O RQD é definido como a porcentagem do comprimento total dos fragmentos maiores que 10 cm ou 4” em relação ao comprimento total do testemunho de sondagem com diâmetro pelo menos igual a 54,7 mm.

O cálculo do RQD pode ser feito segundo a equação 4 (BIENIAWSKI, 1989):

$$RQD = \frac{\sum \text{Comprimento dos fragmentos} > 10 \text{ cm}}{\text{Comprimento total do testemunho}} \times 100 \quad (4)$$

A qualidade da rocha pode ser inferida a partir do RQD de acordo com a Tabela 1.

Tabela 1 - Qualidade do maciço rochoso em função do RQD

RQD (%)	Qualidade do maciço rochoso
< 25	Muito pobre
25 - 50	Pobre
50 - 75	Média
75 - 90	Boa
90 - 100	Excelente

Fonte: Adaptado de BIENIAWSKI (1989)

A classificação RQD fornece recomendações sobre a necessidade de suporte em túneis de acordo com a figura 7.

Figura 7 - Recomendações de suporte a partir do RQD para um túnel com 6 m de largura

	No Support or Local Bolts	Pattern Bolts	Steel Ribs
Deere et al. (1970)	RQD 75–100	RQD 50–75 (1.5–1.8-m spacing) RQD 25–50 (0.9–1.5-m spacing)	RQD 50–75 (light ribs on 1.5–1.8-m spacing as alternative to bolts) RQD 25–50 (light to medium ribs on 0.9–1.5-m spacing as alternative to bolts) RQD 0–25 (medium to heavy circular ribs on 0.6–0.9-m spacing)
Cecil (1970)	RQD 82–100	RQD 52–82 (alternatively, 40–60-mm shotcrete)	RQD 0–52 (ribs or reinforced shotcrete)
Merritt (1972)	RQD 72–100	RQD 23–72 (1.2–1.8-m spacing)	RQD 0–23

Fonte: BIENIAWSKI (1989)

### 2.3.2. Rock Mass Rating (RMR)

O Rock Mass Rating é um método de classificação geomecânica proposto por Bieniawski e que ao longo do tempo foi recebendo aprimoramentos e atualizações com o objetivo de ampliar a sua aplicabilidade, os parâmetros utilizados na classificação RMR são (BIENIAWSKI, 1989):

- Resistência à compressão uniaxial do material rochoso ( $A_1$ ).
- Valor do índice RQD ( $A_2$ ).
- Espaçamento das descontinuidades ( $A_3$ ).
- Condição das descontinuidades ( $A_4$ ).
- Condição da presença de água ( $A_5$ ).
- Orientação das descontinuidades ( $B$ ).

O valor do índice RMR é a soma dos parâmetros:

$$RMR = A_1 + A_2 + A_3 + A_4 + A_5 + B \quad (5)$$

Os valores dos parâmetros são obtidos a partir da figura 8.

A classificação RMR foi desenvolvida inicialmente a partir de dados de obras civis, mas posteriormente sofreu adaptações para se adequar a outros tipos de obras, como as de mineração (BIENIAWSKI, 1989).

Figura 8 – Parâmetros da classificação RMR

A. CLASSIFICATION PARAMETERS AND THEIR RATINGS								
Parameter			Range of values					
1	Strength of intact rock material	Point-load strength index	>10 MPa	4 - 10 MPa	2 - 4 MPa	1 - 2 MPa	For this low range - uniaxial compressive test is preferred	
		Uniaxial comp. strength	>250 MPa	100 - 250 MPa	50 - 100 MPa	25 - 50 MPa	5 - 25 MPa	1 - 5 MPa
	Rating		15	12	7	4	2	1
2	Drill core Quality <i>RQD</i>		90% - 100%	75% - 90%	50% - 75%	25% - 50%	< 25%	
	Rating		20	17	13	8	3	
3	Spacing of discontinuities		> 2 m	0.6 - 2 m	200 - 600 mm	60 - 200 mm	< 60 mm	
	Rating		20	15	10	8	5	
4	Condition of discontinuities (See E)		Very rough surfaces Not continuous No separation Unweathered wall rock	Slightly rough surfaces Separation < 1 mm Slightly weathered walls	Slightly rough surfaces Separation < 1 mm Highly weathered walls	Slickensided surfaces or Gouge < 5 mm thick or Separation 1-5 mm Continuous	Soft gouge > 5 mm thick or Separation > 5 mm Continuous	
	Rating		30	25	20	10	0	
5	Ground water	Inflow per 10 m tunnel length (l/m)	None	< 10	10 - 25	25 - 125	> 125	
		(Joint water press)/(Major principal $\sigma$ )	0	< 0.1	0.1 - 0.2	0.2 - 0.5	> 0.5	
		General conditions	Completely dry	Damp	Wet	Dripping	Flowing	
	Rating		15	10	7	4	0	
B. RATING ADJUSTMENT FOR DISCONTINUITY ORIENTATIONS (See F)								
Strike and dip orientations			Very favourable	Favourable	Fair	Unfavourable	Very Unfavourable	
Ratings	Tunnels & mines		0	-2	-5	-10	-12	
	Foundations		0	-2	-7	-15	-25	
	Slopes		0	-5	-25	-50		
C. ROCK MASS CLASSES DETERMINED FROM TOTAL RATINGS								
Rating			100 - 81	80 - 61	60 - 41	40 - 21	< 21	
Class number			I	II	III	IV	V	
Description			Very good rock	Good rock	Fair rock	Poor rock	Very poor rock	
D. MEANING OF ROCK CLASSES								
Class number			I	II	III	IV	V	
Average stand-up time			20 yrs for 15 m span	1 year for 10 m span	1 week for 5 m span	10 hrs for 2.5 m span	30 min for 1 m span	
Cohesion of rock mass (kPa)			> 400	300 - 400	200 - 300	100 - 200	< 100	
Friction angle of rock mass (deg)			> 45	35 - 45	25 - 35	15 - 25	< 15	
E. GUIDELINES FOR CLASSIFICATION OF DISCONTINUITY conditions								
Discontinuity length persistence)			< 1 m	1 - 3 m	3 - 10 m	10 - 20 m	> 20 m	
Rating			6	4	2	1	0	
Separation/aperture)			None	< 0.1 mm	0.1 - 1.0 mm	1 - 5 mm	> 5 mm	
Rating			6	5	4	1	0	
Roughness			Very rough	Rough	Slightly rough	Smooth	Slickensided	
Rating			6	5	3	1	0	
Infilling (gouge)			None	Hard filling < 5 mm	Hard filling > 5 mm	Soft filling < 5 mm	Soft filling > 5 mm	
Rating			6	4	2	2	0	
Weathering			Unweathered	Slightly weathered	Moderately weathered	Highly weathered	Decomposed	
Ratings			6	5	3	1	0	
F. EFFECT OF DISCONTINUITY STRIKE AND DIP ORIENTATION IN TUNNELLING**								
Strike perpendicular to tunnel axis					Strike parallel to tunnel axis			
Drive with dip - Dip 45 - 90°			Drive with dip - Dip 20 - 45°		Dip 45 - 90°		Dip 20 - 45°	
Very favourable			Favourable		Very unfavourable		Fair	
Drive against dip - Dip 45-90°			Drive against dip - Dip 20-45°		Dip 0-20 - Irrespective of strike°			
Fair			Unfavourable		Fair			

Fonte: BIENIAWSKI (1989)

### 2.3.3 Q - System

Q - System foi desenvolvido no NGI (Norwegian Geotechnical Institute) por Nick Barton com base em uma grande amostragem realizada em obras de escavação subterrânea. É possível, a partir das características do maciço rochoso, determinar o índice Q através de seis parâmetros (BIENIAWSKI, 1989):

- Índice RQD.
- Número de famílias de juntas ( $J_n$ ).
- Rugosidade da descontinuidade mais desfavorável ( $J_r$ ).
- Grau de alteração ou enchimento da descontinuidade mais fraca ( $J_a$ ).
- Fluxo de água ( $J_w$ ).
- Condições de tensão (SRF – Stress Reduction Factor).

O índice Q é definido como:

$$Q = \underbrace{\frac{RQD}{J_n}}_{A_1} \times \underbrace{\frac{J_r}{J_a}}_{A_2} \times \underbrace{\frac{J_w}{SRF}}_{A_3} \quad (6)$$

Onde cada quociente possui o seguinte conceito físico:

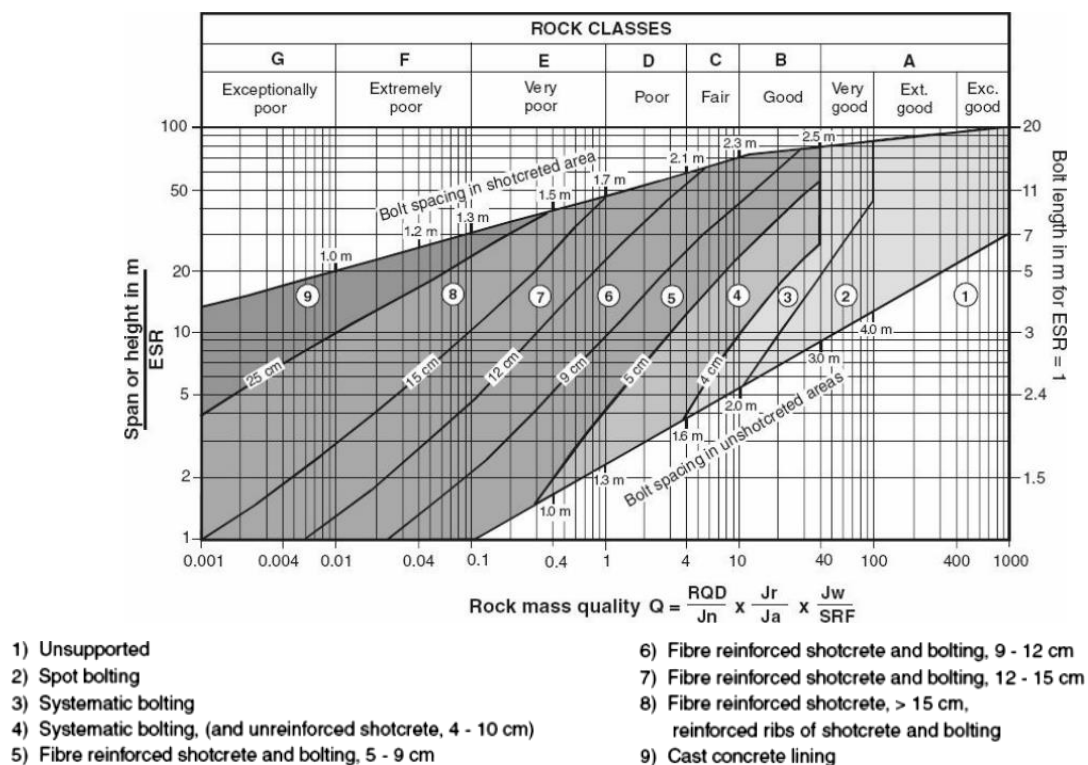
$A_1$  – Medida do tamanho de blocos.

$A_2$  – Tensões de cisalhamento entre os blocos.

$A_3$  – Tensões ativas na região analisada.

Com base no valor do índice Q, foi proposto um ábaco onde a partir da qualidade da rocha são recomendadas categorias de suporte para cada tipo de maciço rochoso. A figura 9 exibe as recomendações de suporte.

Figura 9 - Categorias de suporte recomendadas pelo Q System



Fonte: BIENIAWSKI (1989)

## 2.4 TÉCNICAS DE APRENDIZADO DE MÁQUINA


As técnicas de aprendizado de máquina tiveram sua origem na Estatística e na Ciência de Dados e relacionam-se ao campo da Inteligência Artificial. As técnicas possuem aplicação nos processos em que se tem como objetivo utilizar o conhecimento contido em bases de dados para resolver problemas. De uma forma simples, essas técnicas visam prever características sobre novas entradas com base em exemplos previamente classificados (ALVES, 2020).

As técnicas a serem abordadas nesta pesquisa são: redes neurais artificiais, redes bayesianas, máquinas de vetores de suporte e regressão logística.

### 2.4.1. Redes neurais artificiais

As redes neurais artificiais (RNA) são sistemas que usam o mesmo conceito do sistema de neurônios que constitui o cérebro humano (ALVES, 2020). A rede nervosa cerebral é formada por axônios e dendritos que tem a função de cabos de transmissão de impulsos nervosos e pelo corpo celular que atua no processamento e transmissão de informações, como pode ser visto na figura 10 (CÉLULAS NERVOSAS, 2008).

Figura 10 – Neurônio biológico




Fonte: CÉLULAS NERVOSAS (2008)

Reproduzindo o pressuposto biológico, as redes neurais artificiais recebem os dados, processam as informações e fornecem resultados para um problema apresentado. Os neurônios são a unidade do sistema nervoso biológico e os *Perceptrons* são da rede neural artificial (ASSIS, 2009).

Na figura 11 a RNA recebe as informações ( $x_1$ ,  $x_2$ ,  $x_3$  e  $x_4$ ), os dados são processados pelos *Perceptrons* e fornecem os resultados ( $y_1$ ,  $y_2$  e  $y_3$ ) (ASSIS, 2009).



Figura 11 – Exemplo de Rede neural artificial



Fonte: KINAST (2019)

As Redes Neurais artificiais possuem capacidade de generalização e para isso podem ser usados três tipos principais de estratégias de aprendizado (KINAST, 2019):

- **Aprendizado supervisionado:** onde são fornecidos dados rotulados e o algoritmo gradativamente introduz modificações para processar o conjunto de dados de entrada de forma a fornecer o resultado almejado;
- **Aprendizado não supervisionado:** onde não se tem um conjunto de dados rotulados disponível para o aprendizado. O resultado é obtido através da minimização de uma função de custo e
- **Aprendizado reforçado:** onde a rede neural artificial aprende pelo reforço dos resultados positivos e pela inibição dos resultados negativos.


#### 2.4.2. Redes Bayesianas

Redes Bayesianas são a representação matemática de grafos das probabilidades de ocorrência de eventos *a priori* e *a posteriori*, onde os vértices são as variáveis aleatórias e as arestas são as relações de dependência (AUGUSTO, 2020).

Os grafos podem ser definidos como um conjunto de objetos onde uma variável anterior se relaciona a uma variável posterior. Existem dois tipos de grafos: o grafo direcionado em que as relações entre as arestas acontecem em direções específicas e o grafo acíclico, ou seja, aquele que não possui ciclos, como mostra a figura 12 (AUGUSTO, 2020)



Figura 12 – Grafos acíclico (A) e direcional (B)



Fonte: BRENO (2018)

O teorema de Bayes descreve a probabilidade condicional associada a um evento que já ocorreu, de ocorrer novamente. Esta é chamada de informação *a priori* (AUGUSTO, 2020).

A partir das probabilidades *a priori* e dos novos dados recebidos, obtém-se a probabilidade *a posteriori* que é a probabilidade resultante (AUGUSTO, 2020).


Uma Rede Bayesiana é definida como um par ordenado (S, P), onde S é a estrutura da rede (nós e arestas) e P é o conjunto de distribuições de probabilidade  $p(x_i | pa(x_i))$ , sendo ( $pa(x_i)$ ) as probabilidades associadas aos nós resultantes dos  $x_i$  (AUGUSTO, 2020).

### 2.4.3. Máquinas de vetores de suporte

A Máquina de Vetores de Suporte (SVM) é um algoritmo de aprendizagem de máquina aplicável a problemas de classificação e regressão (REMIGIO, 2020).

Uma SVM tem como função encontrar os limites que separam as classes contidas nos conjuntos de dados que sejam linearmente separáveis. Os limites de separação entre as classes são chamados de hiperplanos, assim esse método busca o melhor hiperplano para um determinado conjunto de dados que seja linearmente separável. A figura 13 ilustra os possíveis hiperplanos de separação para um conjunto de dados com 2 classes (pontos + e pontos -) (REMIGIO, 2020):


Figura 13 – Possíveis hiperplanos de separação para um conjunto de dados com 2 classes



Fonte: REMIGIO, (2020)

O melhor hiperplano será o que se encontra no ponto médio entre os dois grupos. Os pontos apresentam características de simetria quando ocorre a classificação, onde o ponto mais próximo de cada classe está a uma distância “d” do hiperplano que minimiza os erros de classificação. Os pontos mais próximos ao hiperplano são chamados de vetores de suporte e a distância entre os vetores de suporte e o hiperplano é denominada margem, como mostrado na figura 14 (REMIGIO, 2020).

Figura 14 - Melhor hiperplano de separação




Fonte: REMIGIO, (2020)

#### 2.4.4. Regressão logística

A Regressão Logística é uma técnica de modelagem usada para variáveis binárias (0 ou 1). É um algoritmo de classificação que tem vantagens sobre a regressão linear, pois os dados não precisam estar normalmente distribuídos (quando a sua média, mediana e moda são iguais) e nem linearmente distribuídos. A técnica também não exige a necessidade de relação linear entre a variável resposta e a variável explicativa (YUKIO, 2018).

O objetivo dessa técnica é fornecer uma probabilidade como saída que substitua a regressão linear para o caso de variáveis binárias. A função logística é representada como uma curva em forma de S, como mostrado na figura 15 (YUKIO, 2018).

Figura 15 - Função logística



Fonte: YUKIO (2018)

Como a variável dependente na Regressão Logística assume dois valores, 0 quando é identificada como negação e 1 para afirmação, a probabilidade fica restrita ao intervalo entre esses dois valores. Quando a variável independente assume valores mais baixos, a probabilidade se aproxima de 0 e quando assume valores próximos de 1, a probabilidade aumenta (Fernandes et al. 2020).

## 2.5. ANÁLISE DO DESEMPENHO DE CLASSIFICADORES NO APRENDIZADO DE MÁQUINA

### 2.5.1. Matriz de confusão

A matriz de confusão é um dos métodos mais usados para representar o desempenho de um classificador. É estruturada como uma matriz  $n \times n$ , onde o valor de  $n$  se relaciona ao número de classes a classificar. A matriz de confusão compara os valores reais e os valores previstos por um modelo e permite a análise dos acertos e dos erros cometidos pelo classificador. Por exemplo, para um classificador binário tem-se uma matriz de confusão  $2 \times 2$ , como mostrado na figura 16 (Wagh et al. 2021) :

Figura 16 - Matriz de confusão 2x2

		Actual Values	
		1	0
Predicted Values	1	TP	FP
	0	FN	TN

Fonte: Wagh et al. (2021)

Essa matriz compara os valores reais e os valores previstos identificando 4 situações possíveis: verdadeiro positivo (TP), verdadeiro negativo (TN), falso positivo (FP) e falso negativo (FN) (Wagh et al. 2021).

- Verdadeiro Positivo (TP): É o caso em que os valores positivos reais são iguais aos previstos, mostrando que o modelo foi previsto corretamente em relação aos valores positivos (1).
- Verdadeiro Negativo (TN): É o caso em que os valores negativos reais são iguais aos previstos, mostrando que o modelo foi previsto corretamente em relação aos valores negativos (0).
- Falso Positivo (FP): É o caso em que o classificador prevê incorretamente um valor negativo real (0), como um valor positivo (1).
- Falso Negativo (FN): É o caso em que o classificador prevê incorretamente um valor positivo real (1), como um valor negativo (0).

### 2.5.2. Acurácia e Precisão

Medidas de desempenho de um classificador podem ser obtidas a partir da matriz de confusão na forma dos parâmetros: acurácia e precisão (Wagh et al. 2021).

Acurácia é a medida da proporção de previsões corretas que o classificador fez considerando os valores reais e previstos. É representada matematicamente por (Wagh et al. 2021):

$$Acurácia = \frac{TP+TN}{TP+TN+FP+FN} \quad (7)$$

Precisão é a medida da proporção de valores positivos (1) previstos corretamente. A confiabilidade do modelo é inferida a partir da precisão (Wagh et al. 2021):

$$Precisão = \frac{TP}{TP+FP} \quad (8)$$

### 3. MATERIAIS E MÉTODOS

#### 3.1. MATERIAIS UTILIZADOS

A pesquisa foi desenvolvida com base em dados obtidos em uma mina subterrânea brasileira que utiliza o método de lavra por corte a céu aberto e possui rampas que interligam os seus painéis de lavra. As análises foram feitas sobre as rampas da mina.

A equipe do setor de Geomecânica da mina realizou uma campanha de coleta de informações e de realização de ensaios mecânicos em 10 rampas para um total de 199 pontos. Foram identificados 9 tipos litológicos ao longo destas 10 rampas. As tabelas 2 e 3 mostram informações detalhadas quanto aos tipos litológicos presentes, bem como a sua distribuição.

Tabela 2 - Tipos de rochas identificadas nas rampas (classificação adotada pela empresa)

Tipo de Rocha	Denominação	Pontos
I	Carbonato-sericita-clorita-quartzo xisto - Man	14
II	CL Xisto	6
III	Clorita-tremolita-plagioclásio-epidoto-quartzo-carbonato xisto - Manx	8
IV	Grafita Xisto	8
V	Manx	1
VI	Sericita-plagioclásio-quartzo-carbonato xisto - X2Cl	21
VII	Sericita-plagioclásio-quartzo-carbonato xisto - X2Cl/Manx	138
VIII	Sericita-plagioclásio-quartzo-carbonato xisto sulfetado - X2Cl/XS	2
IX	Sericita-plagioclásio-quartzo-carbonato xisto- X2Cl/Manx	1
Total		199

Fonte: Arquivo pessoal

A distribuição do tipo de rocha nas 10 rampas de A até J é mostrada na tabela 3:


Tabela 3 - Tipos de rochas nas rampas de A até J

Rampa	Rocha									Pontos
	I	II	III	IV	V	VI	VII	VIII	IX	
A	1		4			22	2			29
B	8					10				18
C	5					10				15
D						15			1	16
E			4			12				16
F		6			21					27
G				8						8
H						21				21
I						13		1		14
J						35				35
Total	14	6	8	8	21	138	2	1	1	199

Fonte: Arquivo pessoal

A figura 17 é uma representação gráfica da tabela 3, com as 10 rampas, os 199 pontos caracterizados e os 9 tipos de rochas presentes ao longo das rampas. Assim é possível observar que as rampas têm uma presença maior do tipo de rocha Sericita-plagioclásio-quartzo-carbonato xisto - X2CI/ MANX (VI).

Figura 17 - Representação gráfica das rampas com os tipos de rochas presentes nos pontos amostrados




Fonte: Arquivo pessoal

A figura 18 exibe os pontos onde foram identificadas instabilidades. Para o resultado 0, o local é estável e para o resultado 1, ocorre instabilidade.



Figura 18 - Pontos de instabilidade nas rampas de A até J



Fonte: Arquivo pessoal

Segundo o corpo técnico da mina, as instabilidades observadas estão essencialmente relacionadas às tensões atuantes que causam grandes deformações, deslocamentos e rupturas localizadas.

Para os 199 pontos caracterizados na campanha de amostragem, são apresentadas as estatísticas: média, mediana, desvio padrão, mínimo e máximo para os seguintes parâmetros: RQD, RMR, Q, Largura, Altura e Cota (altura acima do nível do mar), mostrados na tabela 4.

Tabela 4 – Estatísticas para os parâmetros levantados

Estatística	Parâmetros					
	RQD (%)	RMR	Q	Largura (m)	Altura (m)	Cota (m)
Média	84,54	66,64	2,39	5,55	4,83	318,91
Mediana	85,00	66,00	2,00	5,47	4,80	296,00
Desvio-Padrão	7,82	4,40	1,59	0,60	0,50	106,65
Mínimo	70,00	56,00	0,13	4,19	3,74	149,00
Máximo	95,00	81,00	9,10	8,66	6,50	521,00

Fonte: Arquivo pessoal

### 3.2.MÉTODOLOGIA EMPREGADA

A pesquisa foi desenvolvida utilizando as ferramentas: planilha eletrônica Microsoft Excel e o programa Wolfram Mathematica.

A metodologia empregada consistiu em inicialmente reduzir a dimensionalidade do problema, a partir da seleção das variáveis mais adequadas para a previsão da ocorrência de instabilidade nas rampas da mina subterrânea em estudo; para a posterior

construção de classificadores visando a previsão da ocorrência de instabilidades em novas escavações da mina.

O resultado da pesquisa será um classificador que possa ser empregado como uma ferramenta auxiliar de trabalho pelas equipes de projeto, planejamento e de execução da lavra da mina.

A sequência de atividades está dividida em três etapas:

1) Seleção das variáveis individuais com potencial para a indicação da possibilidade de ocorrência de instabilidade, por meio da análise das distribuições de frequências e de testes de hipótese para a igualdade entre as médias de cada parâmetro a um nível de confiança de 95% ( $H_0$  = As médias para o parâmetro são iguais e  $H_1$  = As médias para o parâmetro são diferentes), comparando os pontos estáveis e os pontos com instabilidade.

2) Seleção da associação entre duas variáveis com melhor potencial para a previsão da ocorrência de instabilidade, por meio da análise de gráficos que associam duas variáveis e definem regiões de estabilidade e instabilidade.

3) Construção de classificadores que utilizam os métodos de aprendizado de máquina: Redes Neurais Artificiais, Rede Bayesianas, Máquinas de Vetores de Suporte e Regressão Logística; e identificação do classificador que fornece melhores resultados. O processo de aprendizado dos classificadores será realizado dividindo o conjunto de dados total em um conjunto de treinamento e outro conjunto de teste na proporção 80 % para 20%.

## 4. RESULTADOS E DISCUSSÃO

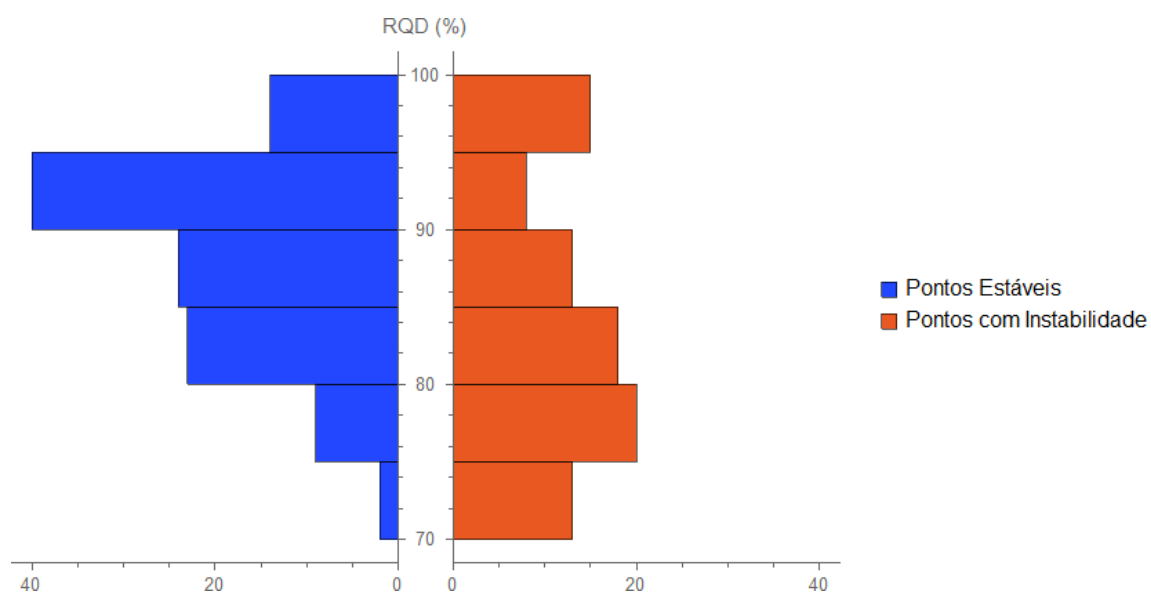
### 4.1 SELEÇÃO DOS MELHORES INDICADORES DA OCORRÊNCIA DE INSTABILIDADE

A partir das informações fornecidas pela equipe de geomecânica da mina, foi feito um tratamento dos dados visando identificar quais variáveis são melhores indicadores da ocorrência de instabilidade ao longo das rampas. As variáveis analisadas foram: RQD, RMR, Q, Altura, Largura e Cota.

#### 4.1.1. RQD

Para a variável Rock Quality Designation Index (RQD) foram construídos os gráficos de distribuição de frequências para os 199 pontos amostrados. Do lado esquerdo do gráfico estão os pontos estáveis e do lado direito, os pontos com instabilidade, como pode ser visto na figura 19.

Figura 19 – Distribuição de frequências para o RQD



Fonte: Arquivo pessoal

Dos 199 pontos amostrados, 112 pontos são estáveis e 87 pontos apresentam instabilidade. A tabela 5 apresenta as estatísticas para o RQD.

Tabela 5 - Estatísticas para o RQD

RQD	Pontos	
	Estáveis	Com Instabilidade
Média (%)	86,81	81,61
Mediana (%)	88,00	80,00
Desvio-Padrão (%)	6,53	8,36
Mínimo (%)	70,00	70,00
Máximo (%)	95,00	95,00

Fonte: Arquivo pessoal

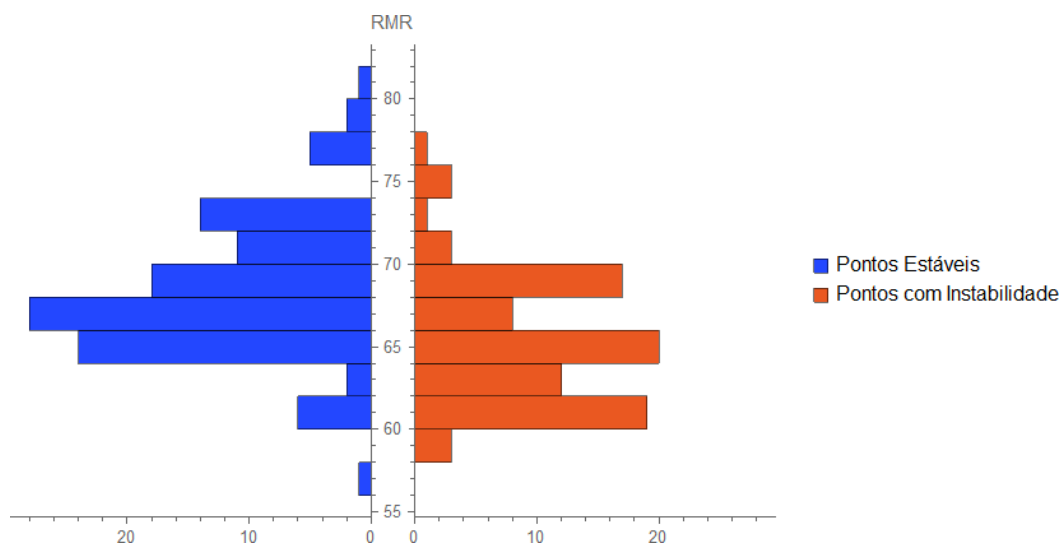
Foi realizado um teste estatístico visando verificar a hipótese de igualdade entre as médias do RQD para os pontos estáveis e para os pontos com instabilidade.

O valor obtido para o p-estatístico foi 0,000016693, o que leva a rejeição da hipótese de igualdade entre as médias a um nível de confiança de 95% e mostra que o RQD é um bom indicador da possibilidade de ocorrência de instabilidade nas rampas.

#### 4.1.2 RMR

Para a variável Rock Mass Rating (RMR) foram construídos os gráficos de distribuição de frequências para os 199 pontos amostrados. Como pode ser visto na figura 20.

Figura 20 - Distribuição de frequências para o RMR



A tabela 6 apresenta as estatísticas para o RMR.

Tabela 6 - Estatística RMR

RMR	Pontos	
	Estáveis	Com Instabilidade
Média	67,87	65,07
Mediana	67,00	65,00
Desvio-Padrão	4,34	3,96
Mínimo	56,00	59,00
Máximo	81,00	77,00

Fonte: Arquivo pessoal


Foi realizado um teste estatístico visando verificar a hipótese de igualdade entre as médias do RMR para os pontos estáveis e para os pontos com instabilidade.

O valor obtido para o p - estatístico foi 0,00000346591, o que leva a rejeição da hipótese de igualdade entre as médias a um nível de confiança de 95% e mostra que o RMR é um bom indicador da possibilidade de ocorrência de instabilidade.

#### 4.1.3 Índice Q

Para a variável Q foram construídos os gráficos de distribuição de frequências para os 199 pontos amostrados, como pode ser visto na figura 21.

Figura 21 - Distribuição de frequências para o índice Q



Fonte: Arquivo pessoal

A tabela 7 apresenta as estatísticas para o índice Q.

Tabela 7 - Estatísticas para o índice Q

Q	Pontos	
	Estáveis	Com Instabilidade
Média	2,79	1,87
Mediana	2,52	1,67
Desvio-Padrão	1,78	1,11
Mínimo	0,21	0,13
Máximo	9,10	6,33

Fonte: arquivo pessoal

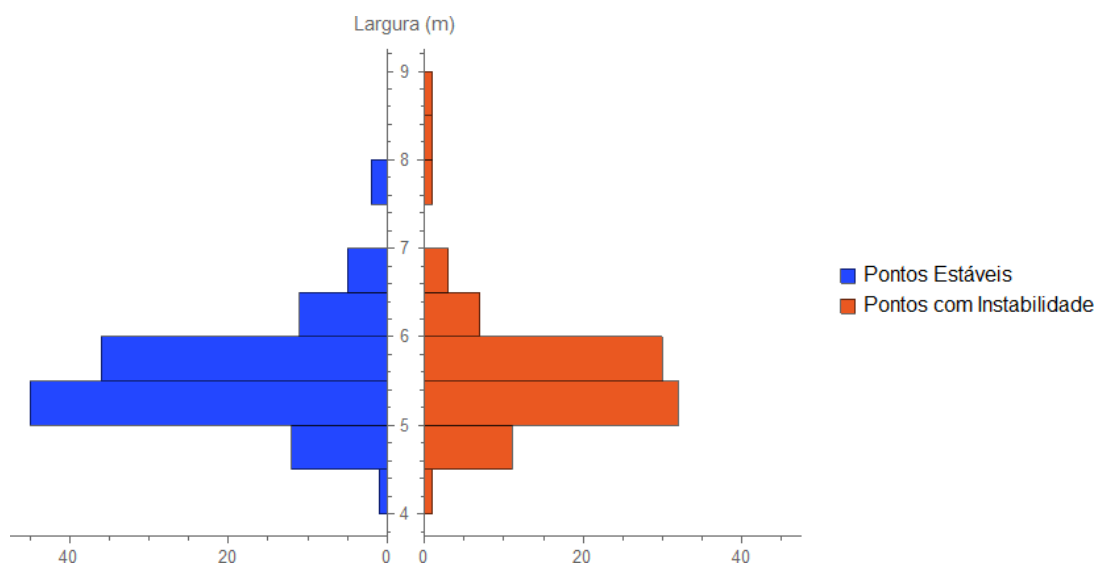
Foi realizado um teste estatístico visando verificar a hipótese de igualdade entre as médias do Q para os pontos estáveis e para os pontos com instabilidade.

O valor obtido para o p - estatístico foi 0,0000483781, o que leva a rejeição da hipótese de igualdade entre as médias a um nível de confiança de 95% e mostra que o índice Q é um bom indicador da possibilidade de ocorrência de instabilidade.

#### 4.1.4. Largura

Para a variável Largura foram construídos os gráficos de distribuição de frequências para os 199 pontos amostrados, como pode ser visto na figura 22.

Figura 22 – Distribuição de frequências para a Largura



Fonte: Arquivo pessoal

A tabela 8 apresenta as estatísticas para a Largura.

Tabela 8 - Estatísticas para a Largura

Largura	Pontos	
	Estáveis	Com Instabilidade
Média (m)	5,53	5,58
Mediana (m)	5,46	5,47
Desvio-Padrão (m)	0,53	0,68
Mínimo (m)	4,19	4,28
Máximo (m)	7,74	8,66

Fonte: Arquivo pessoal

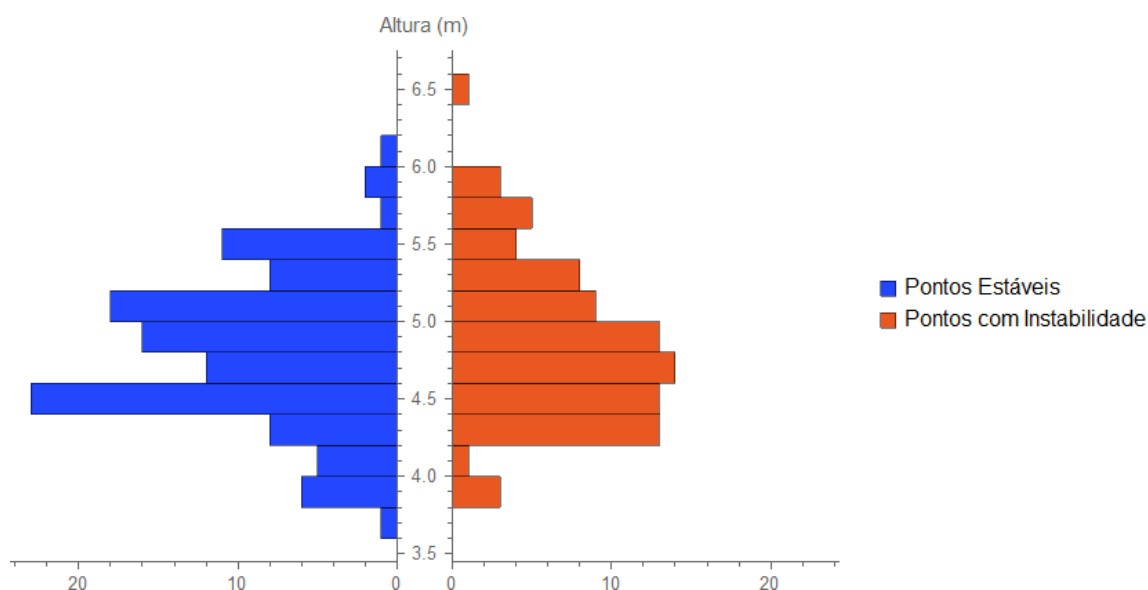
Foi realizado um teste estatístico visando verificar a hipótese de igualdade entre as médias da Largura para os pontos estáveis e para os pontos com instabilidade.

O valor obtido para o p - estatístico foi 0,634618, o que leva a aceitação da hipótese de igualdade entre as médias a um nível de confiança de 95% e mostra que a Largura não é um indicador adequado para possibilidade de ocorrência de instabilidade.

#### 4.1.5. Altura

Para a variável Altura foram construídos os gráficos de distribuição de frequências para os 199 pontos amostrados, como pode ser visto na figura 23.

Figura 23 – Distribuição de frequências para a Altura



Fonte: Arquivo pessoal

A tabela 9 apresenta as estatísticas para a Altura.

Tabela 9 - Estatísticas para a Altura

Altura	Pontos	
	Estáveis	Com Instabilidade
Média (m)	4,80	4,86
Mediana (m)	4,80	4,78
Desvio-Padrão (m)	0,49	0,51
Mínimo (m)	3,74	3,80
Máximo (m)	6,10	6,50

Fonte: Arquivo pessoal

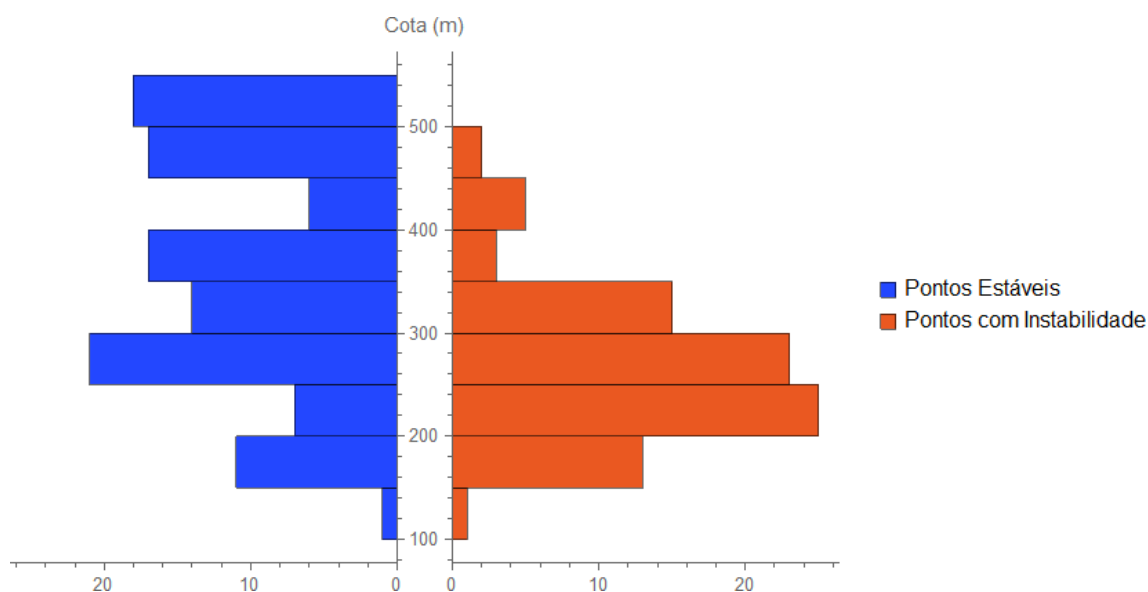
Foi realizado um teste estatístico visando verificar a hipótese de igualdade entre as médias da Altura para os pontos estáveis e para os pontos com instabilidade.

O valor obtido para o p - estatístico foi 0,444725, o que leva a aceitação da hipótese de igualdade entre as médias a um nível de confiança de 95% e mostra que a Altura não é um indicador adequado para possibilidade de ocorrência de instabilidade.

#### 4.1.6. Cota

Para a variável Cota foram construídos os gráficos de distribuição de frequências para os 199 pontos amostrados, como pode ser visto na figura 24.

Figura 24 – Distribuição de frequências para a Cota



Fonte: Arquivo pessoal



A tabela 10 apresenta as estatísticas para a Cota.

Tabela 10 - Estatísticas para a Cota

Cota	Pontos	
	Estáveis	Com Instabilidade
Média (m)	357,49	269,24
Mediana (m)	353,5	254,00
Desvio-Padrão (m)	112,44	73,19
Mínimo (m)	149,00	149,00
Máximo (m)	521,00	458,00

Fonte: Arquivo pessoal

Foi realizado um teste estatístico visando verificar a hipótese de igualdade entre as médias da Cota para os pontos estáveis e para os pontos com instabilidade.

O valor obtido para o p - estatístico foi 0,000000962301, o que leva a rejeição da hipótese de igualdade entre as médias a um nível de confiança de 95% e mostra que a Cota é um bom indicador da possibilidade de ocorrência de instabilidade.

#### 4.1.7 Resumo das análises

A partir das análises realizadas sobre as distribuições de frequências, bem como os testes de hipótese para a igualdade entre as médias para os pontos estáveis e para os pontos com instabilidade para as variáveis RQD, RMR, Q, Largura, Altura e Cota, chegou-se à conclusão de que as variáveis que são melhores indicadores para a ocorrência de instabilidade nas rampas são: RQD, RMR, Q e Cota, como mostra a tabela 11.

Tabela 11 – Resumo dos testes de hipóteses

Variável	Valor-p	Hipótese de igualdade entre as médias: Pontos Estáveis x Pontos com Instabilidade
RQD	0,000016693	Rejeitada
RMR	0,00000346591	Rejeitada
Q	0,0000483781	Rejeitada
Largura	0,634618	Aceita
Altura	0,444725	Aceita
Cota	0,00000000962301	Rejeitada

Fonte: Arquivo pessoal

O melhor indicador para ocorrência de instabilidade nas rampas de acordo com o valor-p é a Cota, pois é a variável que apresenta o menor resultado, 0,0000000096230.

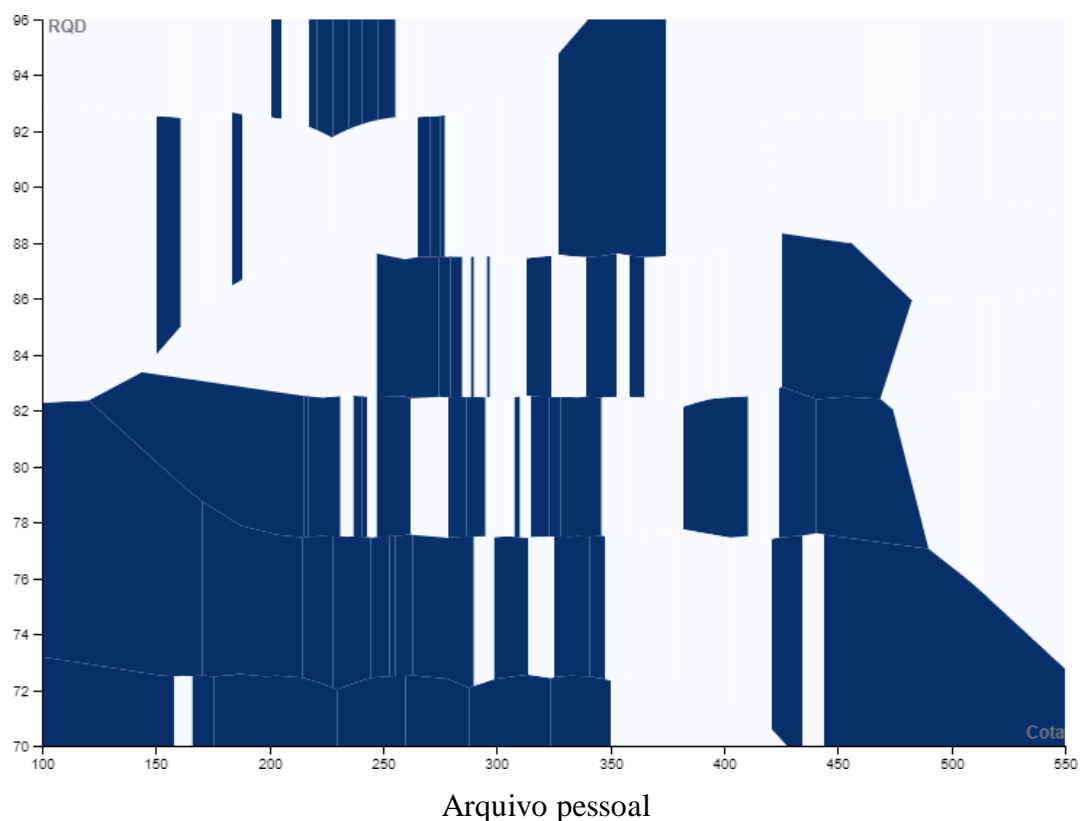
## 4.2. SELEÇÃO DA ASSOCIAÇÃO ENTRE 2 VARIÁVEIS COMO MELHOR INDICADOR DA OCORRÊNCIA DE INSTABILIDADE NAS RAMPAS

Com o objetivo de reduzir ainda mais a dimensionalidade do problema, buscou-se a seleção da associação entre 2 variáveis que se constitua em um indicador adequado da ocorrência de instabilidade nas rampas da mina. A escolha foi por associar a melhor variável identificada na etapa anterior da pesquisa, Cota, com as outras variáveis RQD, RMR e Q, pois essas variáveis também são bons indicadores da ocorrência de instabilidade. Assim foram construídos gráficos: Cota x RQD, Cota x RMR e Cota x Q apresentando a distribuição dos pontos estáveis e instáveis.

### 4.2.1 Associação Cota x RQD

A figura 25 apresenta a relação entre a Cota e o RQD. As áreas preenchidas em azul representam as regiões do gráfico onde ocorreram instabilidades e as áreas brancas são as regiões estáveis. A análise mostra que não se pode identificar uma separação bem definida entre as regiões, pois não existem limites bem marcados entre as regiões estáveis e instáveis, mostrando que essa combinação de variáveis não é adequada.

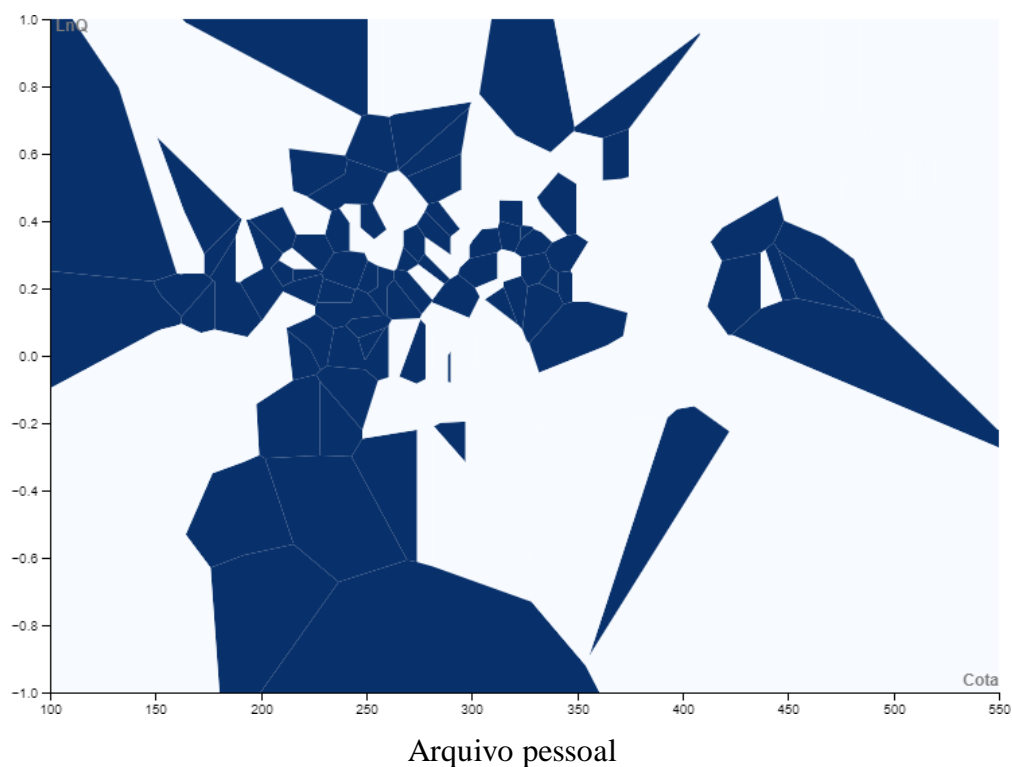
Figura 25 - Associação RQD X Cota



### 4.2.2 Associação Cota x Q

A figura 26 apresenta a relação entre a Cota e o Q. A análise mostra, como no caso anterior, que não se pode identificar uma separação bem definida entre as regiões, pois não existem limites bem marcados entre as regiões estáveis e instáveis, mostrando que essa combinação de variáveis não é adequada.


Figura 26 – Associação Cota x Q



### 4.2.3 Associação Cota x RMR

A figura 27 apresenta a relação entre a Cota e o RMR. A análise mostra que é possível identificar uma separação melhor definida entre as regiões, pois os limites são mais marcados e esta associação é considerada como adequada.

Figura 27 - Associação Cota x RMR



Fonte: Arquivo pessoal

A análise realizada indica que as variáveis Cota e RMR em associação, se configuram como os melhores indicadores da ocorrência de ruptura nas rampas da mina e estas serão as variáveis utilizadas na construção dos classificadores da próxima etapa da pesquisa.

#### 4.3. TREINAMENTO DOS CLASSIFICADORES

Os classificadores que utilizam os métodos de aprendizado de máquina: Redes Neurais Artificiais, Redes Bayesianas, Máquinas de Vetores de Suporte e Regressão Logística foram treinados utilizando 159 pontos ou 80% do número total de pontos do conjunto de dados inicial (conjunto de treinamento), sendo os outros 40 pontos ou 20%, reservados para a análise do desempenho dos classificadores (conjunto de teste).

As variáveis de entrada são o RMR e a Cota e a função do classificador é separar os pontos segundo duas classes numéricas 0 e 1 que correspondem respectivamente às situações de “estabilidade” e “instabilidade”.


Cada classificador foi configurado de forma a fornecer os melhores resultados de acordo com as características particulares de cada método de aprendizado de máquina.

### 4.3.1. Classificador Rede Neural Artificial

O classificador que utiliza o método de aprendizado de máquina de Rede Neural Artificial foi treinado no programa Wolfram Mathematica com a configuração MaxTrainingRounds = 3000 e NetworkDepth = 1.

A figura 28 mostra em azul as regiões em que o classificador prevê para a combinação RMR x Cota, a ocorrência de instabilidade, já as regiões em branco correspondem a uma previsão de estabilidade. Os pontos exibidos correspondem ao conjunto de teste, onde os pontos na cor verde são pontos estáveis e os pontos na cor vermelha, pontos com instabilidade.

Figura 28 – Classificador Redes Neurais Artificiais e conjunto de dados de teste




Fonte: Arquivo pessoal

A análise do desempenho do classificador para o conjunto de treinamento mostrou acurácia de 82%. Para o conjunto de teste, a acurácia foi de 82,5%, a precisão do classificador foi de 100% para a previsão da condição de estabilidade e de 69,6% para a previsão da condição de instabilidade.

A figura 29 mostra a matriz de confusão do classificador para o conjunto de teste, onde se pode observar que dos 24 pontos estáveis, 17 foram classificados adequadamente e dos 16 pontos onde ocorreu instabilidade, todos foram classificados de forma acertada.

Figura 29 - Matriz de confusão do classificador Rede Neural Artificial




Fonte: Arquivo pessoal

#### 4.3.2. Classificador Redes Bayesianas

O classificador que utiliza o método de aprendizado de máquina de Redes Bayesianas foi treinado no programa Wolfram Mathematica com a configuração  $\text{SmoothingParameter} = 0,1$ .

A figura 30 mostra o classificador e o conjunto de dados de teste. As características são as mesmas descritas no item anterior.

Figura 30 - Classificador de Redes Bayesianas e conjunto de dados de teste

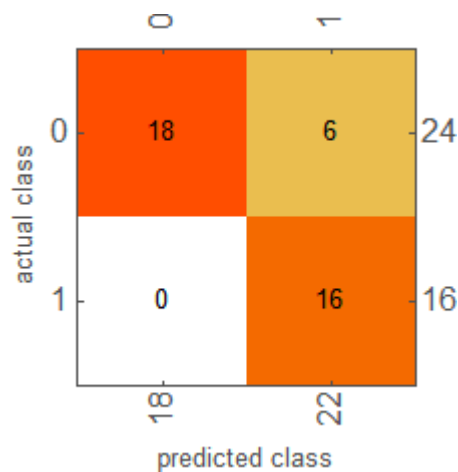


Fonte: Arquivo pessoal

A análise do desempenho do classificador para o conjunto de treinamento mostrou acurácia de 82,7%. Para o conjunto de teste, a acurácia foi de 85%, a precisão do classificador foi de 100% para a previsão da condição de estabilidade e de 72,7% para a previsão da condição de instabilidade.

A figura 31 mostra a matriz de confusão do classificador para o conjunto de teste onde se pode observar que dos 24 pontos estáveis, 18 foram classificados adequadamente e dos 16 pontos onde ocorreu instabilidade, todos foram classificados de forma acertada.

Figura 31 - Matriz de confusão do classificador Rede Bayesiana



Fonte: Arquivo pessoal


#### 4.3.3. Classificador Máquina de Vetores de Suporte

O classificador que utiliza o método de aprendizado de Máquina de Vetores de Suporte foi treinado no programa Wolfram Mathematica com a configuração `BiasParameter = 1`, `KernelType = RadialBasisFunction` e `PolynomialDegree = 3`.

A figura 32 mostra o classificador e o conjunto de dados de teste. As características são as mesmas descritas no item 4.3.1.



Figura 32 - Classificador Máquina de Vetores de Suporte e conjunto de dados de teste



Fonte: Arquivo pessoal

A análise do desempenho do classificador para o conjunto de treinamento mostrou acurácia de 84%. Para o conjunto de teste, a acurácia foi de 90%, a precisão do classificador foi de 88,5% para a previsão da condição de estabilidade e de 92,9% para a para a previsão da condição de instabilidade.

A figura 33 mostra a matriz de confusão do classificador para o conjunto de teste onde se pode observar que dos 24 pontos estáveis, 23 foram classificados adequadamente e dos 16 pontos onde ocorreu instabilidade, 13 foram classificados de forma acertada.

Figura 33 – Matriz de confusão do classificador Máquina de Vetores de Suporte




Fonte: Arquivo pessoal

#### 4.3.4. Classificador Regressão Logística

O classificador que utiliza o método de aprendizado de máquina Regressão Logística foi treinado no programa Wolfram Mathematica com a configuração `L1Regularization = 0` e `OptimizationMethod = StochasticGradientDescent`.

A figura 34 mostra o classificador e o conjunto de dados de teste. As características são as mesmas descritas no item 4.3.1.

Figura 34 – Classificador Regressão Logística e conjunto de dados de teste



Fonte: Arquivo pessoal

A análise do desempenho do classificador para o conjunto de treinamento mostrou acurácia de 79%. Para o conjunto de teste, a acurácia foi de 82,5%, a precisão do classificador foi de 90,5% para a previsão da condição de estabilidade e de 73,7% para a para a previsão da condição de instabilidade.

A figura 35 mostra a matriz de confusão do classificador para o conjunto de teste onde se pode observar que dos 24 pontos estáveis, 19 foram classificados adequadamente e dos 16 pontos onde ocorreu instabilidade, 14 foram classificados de forma acertada.

Figura 35 – Matriz de confusão do classificador Regressão Logística



Fonte: Arquivo pessoal

#### 4.3.5 Escolha do melhor classificador

A tabela 12 sumaria os resultados obtidos na análise do desempenho dos classificadores em relação ao conjunto de dados de teste.

Tabela 12 – Acurácia e precisão dos classificadores para o conjunto de dados de teste

Classificadores	Acurácia (%)	Precisão de Estabilidade (%)	Precisão de Instabilidade (%)
Rede Neural Artificial	82,50	100,00	69,60
Rede Bayesiana	85,00	100,00	72,70
Máquina de Vetores de Suporte	90,00	88,50	92,90
Regressão Logística	82,50	90,50	73,70

Fonte: Arquivo Pessoal

O Classificador Máquina de Vetores de Suportes é o que apresenta a maior acurácia com 90%, seguindo do classificador Rede Bayesiana com 85% e do classificador Rede Neural Artificial com 82,5%.

Deve ser considerado que a previsão da condição de estabilidade é o requisito mais importante para o classificador, pois um erro neste caso implica em afirmar que há uma condição de estabilidade, quando na verdade ocorre ruptura. Por sua vez, um erro na previsão da condição de instabilidade não compromete a segurança, pois significa afirmar que ocorre ruptura, quando na verdade há uma condição de estabilidade.

Desta forma, o índice de desempenho do classificador “ precisão da previsão da condição de estabilidade (0) ” será considerado como o melhor indicador para a escolha do classificador mais adequado.

Os classificadores Rede Bayesiana e Rede Neural Artificial apresentam valor de 100% para a “precisão da previsão da condição de estabilidade (0) “, mas o classificador Rede Bayesiana apresentou valores melhores para a “acurácia” e para “precisão da previsão da condição de instabilidade (1)”, assim é o classificador mais adequado.

Classificador escolhido: classificador Rede Bayesiana.

## 5. CONCLUSÃO

O objetivo desta pesquisa foi aplicar técnicas de aprendizado de máquina na previsão da ocorrência de instabilidade em rampas de uma mina subterrânea brasileira. A pesquisa foi desenvolvida a partir de dados coletados nas rampas da mina onde foram identificados 9 tipos litológicos. Assim foram identificados os pontos estáveis e com instabilidade e analisados os seguintes parâmetros: RQD, RMR, Q, Largura, Altura e Cota.

A metodologia utilizada buscou inicialmente reduzir o número de variáveis, selecionando os melhores indicadores de instabilidade nas rampas. Por meio da análise das distribuições de frequências e de testes de hipóteses para cada parâmetro a um nível de confiança de 95%, foram selecionados os parâmetros: RQD, RMR, Q e Cota.

Na sequência foi buscada a associação do melhor indicador (Cota) com os outros indicadores: Cota x RQD, Cota x RMR, Cota x Q, resultando na escolha de Cota x RMR. A partir daí construiu-se quatro classificadores utilizando de métodos de aprendizado de máquina aplicados na identificação das condições de instabilidade e estabilidade das rampas com o programa Wolfram Mathematica, resultando no método Rede Bayesiana como o que produz o melhor classificador.

O classificador selecionado poderá ser usado pelas equipes de projeto e de lavra da mina como uma ferramenta auxiliar na indicação na possibilidade da ocorrência de instabilidade em pontos de novas rampas na mina com alta eficiência na previsão da condição de estabilidade, sendo assim a favor da segurança. Ressalta-se ainda que esse classificador sempre poderá ser melhorado, pois com a escavação de novas rampas, é possível coletar novas informações e aprimorar o desempenho do classificador.

## REFERÊNCIAS

ALEXANDRE. Extração de Conhecimento em Bases de Dados por Redes Bayesianas. **DEV MEDIA**, 2006. Disponível em: <<https://www.devmedia.com.br/extracao-de-conhecimento-em-bases-de-dados-por-redes-bayesianas/2637>>.

ALVES TÔRRES FERNANDES, A. et al. leia este artigo se você quiser aprender regressão logística. **Revista de Sociologia e Política**, Recife, v. 28, n. 6, p. 20, Maio 2020.

ALVES, P. M. inteligência artificial e redes neurais. **centro de pesquisa em ciencia, tecnologia e sociedade**, 23 dez. 2020. Disponível em: <<https://www.ipea.gov.br/cts/pt/central-de-conteudo/artigos/artigos/106-inteligencia-artificial-e-redes-neurais>>.

ASSIS, P. O que são redes Neurais? **Tecmundo**, 09 18 2009. Disponível em: <<https://www.tecmundo.com.br/programacao/2754-o-que-sao-redes-neurais.htm>>.

AUGUSTO, F. Redes Bayesianas. **Medium**, 11 maio 2020. Disponível em: <<https://medium.com/oiluna/redes-bayesianas-fcf35516dedb>>.

BIENIAWSKI, Z. T. **Engineering rock mass classifications**. new york: John Wiley, 1989.

BRADY, B. H. G.; BROWN, E. T. **Rock Mechanics for underground mining**. London: Chapman & Hall, 1993.

BRENO, T. Ajuda em Grafo - matriz de adjacência direcionado e não direcionado. **GUJ**, março 2018. Disponível em: <<https://www.guj.com.br/t/ajuda-em-grafo-matriz-de-adjacencia-direcionado-e-nao-direcionado/365088>>.

CAO, Z.; WANG, Y.; LI, D. **Probabilistic Approaches for Geotechnical Site Characterization and Slope Stability Analysis**. Zhejiang: Springer, 2016.

CÉLULAS NERVOSAS. **Só Biologia**, 2008. Disponível em: <<https://www.sobiologia.com.br/conteudos/FisiologiaAnimal/nervoso2.php>>.

CHIOSSI, N. **Geologia de engenharia**. [S.l.]: oficina de textos, 2013.

FRANÇA CARVALHO, V.; CHIANN,. Scielo Brasil. **Scielo Brasil**, p. 67, 2013.

GONZALEZ, L. D. A. **Regressão Logística e suas Aplicações**. Universidade Federal do Maranhão. São Luiz, p. 46. 2018. (15).

HARRISON, J. P.; HUDSON, J. A. **Engineering rock mechanics**. London: Pergamon, 2000.

HARTMAN, H. L.; MUTMANSKY, J. M. **Introductory Mining Engineering**. 2. ed. New Delhi: John Wiley & Sons Lnc., 2002.

HOEK, E. **Practical Rock Engineering**. Vancouver: Capilano Crescent, 2007.

KINAST, P. O que são redes neurais artificiais. **Oficina da net**, 28 fev. 2019. Disponível em: <<https://www.oficinadanet.com.br/tecnologia/25007-o-que-sao-as-redes-neurais-artificiais>>.

NAGARATNAM, S.; SANJAY, K. S.; BRAJA, M. D. **Rock Mechanics an introduction**. New York: CRC Press, 2013.

REMIGIO, M. Maquina de Vetores de Suporte, 24 agosto 2020. Disponível em: <<https://medium.com/@msremigio/m%C3%A1quinas-de-vetores-de-suporte-svm-77bb114d02fc>>.

SAAR, L. C. A. **Avaliação dos "Granitos" Giallo São Francisco Real, Branco**. Rio Claro. 2013.

WAGH, S. J.; S. BHENDE, M.; D. THAKARE, A. **Fundamentals of Data Science**. Abingdon: CRC Press, 2021.

YUKIO. Regressão Logística: Conceitos Essenciais e Modelo. **ESTATSITE.COM.BR**, 29 Agosto 2018. Disponível em: <<https://estatsite.com.br/2018/08/29/regressao-logistica-conceitos-e-formula/>>.

ZANINI, A. **Regressão Logística e Redes Neurais Artificiais: Um problema de estrutura de preferência do consumidor e classificação de perfis de consumo**. Mestrado em economia Aplicada FEZ/UFJF. Juiz de Fora, p. 15. 2007.



