

UNIVERSIDADE DE SÃO PAULO
ESCOLA POLITÉCNICA

Isa Helena Massumi Dias Kotsubo

Análise de problemas de estabilidade em uma mina subterrânea de ouro brasileira
utilizando redes neurais artificiais

São Paulo

2019

UNIVERSIDADE DE SÃO PAULO
ESCOLA POLITÉCNICA

Isa Helena Massumi Dias Kotsubo

Análise de problemas de estabilidade em uma mina subterrânea de ouro brasileira
utilizando redes neurais artificiais

Trabalho de formatura apresentado ao
departamento de Engenharia de Minas da
Escola Politécnica da Universidade de São
Paulo, sob orientação do Professor Doutor
Eduardo César Sansone para obtenção do
título de Bacharel em Engenharia de Minas

São Paulo

2019

0991612

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.

TF-2019
K848a



Escola Politécnica - EPMI



31700002868

Catálogo-na-publicação

Kotsubo, Isa

Análise de problemas de estabilidade em uma mina subterrânea de ouro brasileira utilizando redes neurais artificiais / I. Kotsubo -- São Paulo, 2019.
41 p.

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

1.Mineração Subterrânea 2.Parâmetros Geomecânicos 3.Reconhecimento de Padrões 4.Aprendizado Automatizado 5.Estatística Computacional
I.Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Minas e de Petróleo II.t.

8669219

AGRADECIMENTOS

Ao meu orientador Professor Doutor Eduardo César Sansone por toda orientação e auxílio durante esta pesquisa.

À empresa AngloGold Ashanti Córrego do Sítio de Mineração Ltda. pela disponibilização dos dados utilizados nesta pesquisa.

Aos professores do Departamento de Engenharia de Minas e de Petróleo pela dedicação e grande papel em minha formação como Engenheira de Minas.

Aos meus amigos e meu namorado que me acompanharam e auxiliaram durante toda minha graduação.

Aos meus pais por todo empenho e educação que me trouxe até aqui e por todo o incentivo que me deram ao longo dos anos. À minha família por todo apoio dado.

RESUMO

A demanda por ouro no mundo é alta, assim como seu valor. Entretanto este metal é encontrado em teores cada vez mais baixos e sua extração é realizada em escavações cada vez mais profundas. A mina Cuiabá, em Minas Gerais é um exemplo de uma mina subterrânea de ouro e será objeto de estudo desta pesquisa. Minas subterrâneas podem apresentar problemas de estabilidade em suas escavações, o que pode comprometer a operação e a segurança da mina. A pesquisa tem como objetivo relacionar parâmetros característicos do maciço rochoso a o aparecimento de capelamento (*Buckling*) e quebra mecânica (*Breakout*) na mina Cuiabá (MG) de modo que seja possível prevê-los através de uma rede neural artificial. Com base nos dados colhidos em 197 pontos de rampas que interligam níveis da mina realizaram-se análises estatísticas com um intervalo de confiança de 95% para determinar quais parâmetros poderiam ser utilizados para a discriminação de ruptura ou não do maciço rochoso, nesta pesquisa chamada de parâmetros disjuntos. A partir dos parâmetros disjuntos encontrados foram construídos classificadores com base em redes neurais artificiais, que foram treinados com dados de 167 pontos da mina. O desempenho dos classificadores foi testado com dados de outros 30 pontos da mina. Para avaliar o poder de discriminação dos classificadores utilizou-se a curva ROC e a matriz de confusão. Com base nesses resultados e na acurácia do treinamento, conclui-se que o classificador que melhor prediz a possibilidade de ruptura do maciço rochoso é que utiliza os parâmetros RMR e profundidade (Z).

Palavras-chaves: Mineração Subterrânea. Parâmetros Geomecânicos. Reconhecimento de Padrões. Aprendizado Automatizado. Estatística Computacional.

ABSTRACT

The demand for gold in the world is high, as is its value. However, this metal is found in ever lower percentage and its extraction is performed in deeper and deeper excavations. The Cuiabá mine in Minas Gerais is an example of an underground gold mine and will be the subject of this research. Underground mines can present stability problems in their excavations, which can compromise mine operation and safety. The research aims to relate characteristic parameters of the rocky massif to the appearance of buckling and breakout in the Cuiabá mine (MG) so that it can be predicted through an artificial neural network. Based on data collected from 197 ramp points that interconnect mine levels, statistical analyzes were performed with a 95% confidence interval to determine which parameters could be used to discriminate whether or not the rock massif rupture was described, in this research called by disjoint parameters. From the disjoint parameters found were built classifiers based on artificial neural networks, which were trained with data from 167 points of the mine. The performance of the classifiers was tested with data from another 30 points in the mine. To assess the discriminating power of the classifiers, the ROC curve and the confusion matrix were used. Based on these results and training accuracy, it can be concluded that the classifier that best predicts the possibility of rock mass rupture is the RMR and depth (Z) parameters.

Keywords: Underground mining. Geotechnical parameters. Pattern recognition. Automated learning. Computational Statistics.

Lista de Tabelas

Tabela 1 - Métodos de Classificação Geomecânica	16
Tabela 2 - Classes do RMR	17
Tabela 3 - Classificação dos parâmetros de acordo com o intervalo de confiança ...	33
Tabela 4 - Resultado dos classificadores com um parâmetro	34
Tabela 5 - Resultados dos classificadores com dois parâmetros	36
Tabela 6 - Resultado do classificador com três parâmetros	37

Lista de Ilustrações

Figura 1 - Mecanismo de ruptura do tipo flexão composta ou capelamento.	12
Figura 2 - Ocorrência de Buckling em furo realizado em uma rocha foliada na Mina de Cuiabá (MG).....	13
Figura 3 -Breakout em furo de sondagem.....	14
Figura 4 - <i>Breakout</i> gerado na parede de um poço sujeito a tensões horizontais máxima e mínima	14
Figura 5 - Problemas de quebra mecânica – Breakout	15
Figura 6 – Rede Neural	19
Figura 7 – Representação de uma neurônio artificial	20
Figura 8- Tipos de função de transferência	22
Figura 9 - Arquitetura de uma rede neural artificial	23
Figura 10 – Rede neural com uma única camada.....	23
Figura 11 – Rede neural multicamadas.....	24
Figura 12 - Modelo da Matriz de Confusão	26
Figura 13 – Eficiência do classificador medida pela curva ROC de acordo com sua forma.....	27
Figura 14 - Corpos mineralizados na Mina Cuiabá	29
Figura 15 - Histograma do parâmetro RMR (a), do parâmetro Q (b), do maior vão da rampa (c) e profundidade do ponto (d).....	31
Figura 16- Boxplot do parâmetro RMR (a), do parâmetro Q (b), do maior vão da rampa (c) e profundidade do ponto (d).....	32
Figura 17 - Gráfico do Classificador (Q).....	34
Figura 18 - Curvas ROC para a discriminação da classificação binária do Q (0 – Não ruptuta, 1- Ruptura).....	35
Figura 19 - Matriz de Confusão para o Conjunto de Teste (Q)	35
Figura 20 - Função do classificador RMR & Z.....	36
Figura 21 - Curva ROC do classificador RMR & Z (0 – Não ruptuta, 1- Ruptura).	37
Figura 22 - Matriz de confusão do classificaor RMR & Z	37
Figura 23 - Curva ROC do classificador RMR & Q & Z (0 – Não ruptuta, 1- Ruptura)	38
Figura 24 - Matriz de confusão do classificaor RMR & Q & Z	38

SUMÁRIO

1. INTRODUÇÃO	10
1.1 OBJETIVO	11
2. REVISÃO DA LITERATURA.....	12
2.1. PROBLEMAS DE ESTABILIDADE DOS MACIÇOS ROCHOSOS	12
2.1.1. Capelamento (<i>Buckling</i>).....	12
2.1.2. Quebra Mecânica (<i>Breakout</i>)	13
2.2. CLASSIFICAÇÃO GEOMECÂNICA DE MACIÇOS ROCHOSOS	15
2.2.1. Classificação RMR de Bieniawski	16
2.2.2. Classificação Q de Barton	17
2.3. REDES NEURAIS.....	18
2.3.1. Rede Neural Biológica.....	18
2.3.2. Rede Neural Artificial	19
2.3.3. Arquitetura	22
2.3.4. Aprendizado Em Redes Neurais.....	24
2.4. ANÁLISE DA EFICIÊNCIA DOS CLASSIFICADORES.....	25
2.4.1 Matriz De Confusão	25
2.4.2 Curva ROC (<i>Receiver Operating Charateristic Curve</i>).....	26
3. MATERIAIS E MÉTODOS.....	28
3.1. MINA CUIABÁ.....	28
3.1.1. Método de Lavra	28
3.1.2. Aspectos Gerais da Mina	28
3.2. METODOLOGIA	29
3.2.1 Materiais	29
3.2.2 Métodos	29
4. RESULTADOS E DISCUSSÃO	31

4.1. ANÁLISE DA INDEPENDÊNCIA DAS VARIÁVEIS.....	32
4.2. CLASSIFICAÇÃO DOS DADOS	33
4.2.1. Classificação com um parâmetro.....	33
4.2.2. Classificação com dois parâmetros.....	36
4.2.3. Classificação com três parâmetros	37
5. CONCLUSÕES	39
REFERÊNCIAS.....	40

1. INTRODUÇÃO

Segundo Mathias Heider, no Brasil encontram-se 76 minas subterrâneas em operação. O mineral mais explorado nessas minas é o ouro, totalizando 22 das minas subterrâneas em atividade. Em função do ouro ser encontrado em teores cada vez mais baixos e de seu valor e sua demanda serem altos, tem se mostrado necessária a realização de escavações cada vez mais profundas para a sua produção.

Apesar da mineração subterrânea ser consideravelmente mais cara que a lavra a céu aberto, de acordo com o valor de mercado do mineral de interesse, justifica-se o maior gasto na lavra, como é o caso do ouro. Um exemplo de uma Mina subterrânea de ouro é a Mina Cuiabá, em Sarabá-MG, objeto de estudo deste trabalho.

O conhecimento das características mecânicas do maciço rochoso, das tensões *in situ* e da condição de estabilidade do maciço rochoso onde o mineral é lavrado, é de essencial importância para uma mina subterrânea. Esses fatores se relacionam não somente à viabilidade do empreendimento mineiro, mas a partir destes são dimensionadas as escavações e o sistema de suporte a ser empregado. Com avaliações mais realistas sobre estas características pode-se diminuir o custo da lavra e o risco de acidentes (Gouvea, 2016).

Na operação de uma mina subterrânea são realizadas constantes análises a fim de avaliar o comportamento do maciço rochoso de uma forma generalizada. Entretanto o simples trabalho de caracterização de campo não informa a relação entre os parâmetros característicos do maciço rochoso e os problemas de estabilidade que uma mina pode apresentar. Este conhecimento só é obtido através de análises que correlacionem os parâmetros geomecânicos e o comportamento resultante do maciço rochoso (D' Alessandro, 2007).

As técnicas relacionadas ao aprendizado de máquina (do inglês *machine learning*) podem permitir, a partir de dados conhecidos sobre o maciço rochoso, identificar quais são os parâmetros de maior importância, ou seja, de maior contribuição para a ocorrência de problemas de estabilidade. Estas técnicas podem permitir também prever se ocorrerá ou não um problema de estabilidade, de acordo com os parâmetros do maciço rochoso, em uma nova região da mina a ser lavrada.

O entendimento de como cada parâmetro contribui para a ocorrência de problemas de estabilidade em uma mina subterrânea pode ter enorme valor para empresa, uma vez que permite antecipar problemas relacionados à estabilidade.

Essa antecipação pode evitar acidentes e uma possível necessidade de paralização da operação, direcionando os responsáveis pelo planejamento de lavra na prevenção de problemas de estabilidade, permitindo atuar em soluções que se relacionem aos parâmetros de maior importância.

1.1 OBJETIVO

O objetivo deste trabalho é aplicar técnicas de aprendizado de máquina que permitam empregar os parâmetros característicos do maciço na identificação de possíveis problemas de estabilidade, em vias subterrâneas de uma mina de ouro brasileira.

2. REVISÃO DA LITERATURA

2.1. PROBLEMAS DE ESTABILIDADE DOS MACIÇOS ROCHOSOS


2.1.1. Capelamento (*Buckling*)

Rochas foliadas quando são submetidas a grande tensão, podem apresentar o problema de instabilidade estrutural denominado flexão composta ou capelamento (*buckling*). Este fenômeno é caracterizado pelo deslocamento de finas camadas de rocha paralelas às paredes da escavação.

Este mecanismo de instabilidade ocorre predominantemente em rochas metamórficas (filitos, micas-xisto) ou em rochas sedimentares finamente estratificadas (silitos, arenitos e rochas evaporíticas) (Pimenta, 2017).

Na Figura 1 a seguir é apresentado o mecanismo de ruptura do capelamento ou flexão composta.

Figura 1 - Mecanismo de ruptura do tipo flexão composta ou capelamento.



Fonte: Gouvea (2019)

Devido a alta tensão horizontal ocorre o cisalhamento entre os planos do maciço rochoso, em seguida a rocha perde confinamento e ocorre a ruptura por tração da rocha. A ruptura é condicionada pelas propriedades mecânicas dos planos de foliação (estruturas paralelas a escavação), a magnitude da tensão que a rocha é submetida e o ângulo entre os planos de foliação e a parede (Gouvea, 2019).

A Figura 2 apresenta a ocorrência do *Buckling* em um dos furos de sondagem na mina Cuiabá.

Figura 2 - Ocorrência de *Buckling* em furo realizado em uma rocha foliada na Mina de Cuiabá (MG)



Fonte: Pimenta (2017)

A apresentação do *buckling* em um maciço rochoso pode ser o início da propagação de fraturas maiores que comprometam a estabilidade das escavações (Pimenta, 2017).

2.1.2. Quebra Mecânica (*Breakout*)


A ruptura por meio do fenômeno do *breackout* ou quebra mecânica se constitui em uma forma indireta de calculo das tensões *in situ*. Ocorre como resultado da concentração de tensão ao redor de um furo de sondagem circular, que sob a atuação de um campo de tensão, rompe por deformação inelástica. O *breakout* produz uma geometria elíptica em decorrência das quebras ocorridas nas paredes (Trópia, 2013).

As zonas de *breakout* formam-se em decorrência da ruptura das paredes da escavação por conta da concentração de tensões.

Segundo Trópia (2013) o processo se desenvolve em cinco estágios. O primeiro, dito "Início" ocorrem microfissuras no entorno da escavação aglomeradas na zona de tensão máxima. Em seguida há a "Dilatação" em que devido a tensão maior, as microfissuras são abertas e ocorrem separação das fatias de rocha. O próximo estágio, o "Fatiamento", tem este nome em decorrência do fatiamento por cisalhamento devido à fragilização entre a parede e a microfissura. O "Desprendimento da camada" em que ocorre a transferência da concentração das

camadas para a próxima fatia e a atual apresenta rompimento. A “Estabilização” ocorre com a formação de um “V”, que pode ser visto na Figura 3, cessando o fatiamento e promovendo o confinamento de microfissuras.


Figura 3 -Breakout em furo de sondagem



Fonte: Trópia (2013)

Segundo Haimson e Lee (2004) as orientações das tensões principais no entorno de um poço vertical pode ser identificada pela orientação do *breakout*. Por isso, este se manifesta em zonas diametralmente opostas ao longo da direção da tensão horizontal mínima.

Figura 4 - *Breakout* gerado na parede de um poço sujeito a tensões horizontais máxima e mínima



Fonte: Amadei e Stephansson (1997)

Em 2005, na mina Cuiabá (MG) escavou-se um poço de ventilação, e após sua conclusão surgiram rupturas contínuas em suas paredes. Como a escavação era circular e as rupturas diametralmente opostas, estas foram consideradas rupturas por quebra mecânica, ou *breakout*. (Trópia, 2013)

Figura 5 - Problemas de quebra mecânica – Breakout



Fonte: Trópia (2013)

2.2. CLASSIFICAÇÃO GEOMECÂNICA DE MACIÇOS ROCHOSOS

Os sistemas de classificação geomecânica de maciços rochosos têm como objetivo caracterizar a condição de estabilidade do maciço rochoso de interesse. Este tipo de classificação é importante pois em uma escavação subterrânea utiliza-se o maciço rochoso como principal material estrutural, sendo necessário conhecer suas características e seu comportamento quando há perturbações em seu estado natural.

A classificação geomecânica também é utilizada para projetar sistemas de suporte adequados, selecionar a geometria das seções de escavação e auxiliar o plano de desmonte. Assim o maciço rochoso pode ser individualizado em regiões com características mecânicas mais ou menos uniformes (Nogoseke, 2009).

Para a identificação dos parâmetros geomecânicos é realizada uma caracterização mecânica em laboratório de amostras recolhidas em sondagem e um estudo das descontinuidades da rocha por meio de observações e ensaios *in situ* (Gouvea, 2016).

Os primeiros estudos de classificações geomecânicas de maciços rochosos são da década de 1940. As mais antigas possuíam um caráter mais qualitativo e foram

concebidas pensando em escavações subterrâneas. Com o passar dos anos assumiram um caráter quantitativo sua utilização foi estendida para taludes e fundações (Nogosoke, 2009)

De acordo com Bieniawski (1989) os principais objetivos de classificar um maciço rochoso são: identificar os parâmetros mais significativos para o seu comportamento mecânico, realizar a divisão do maciço rochoso em grupos com comportamento mecânico similar, obtenção de parâmetros quantitativos e diretrizes para um projeto de engenharia, fornecer uma base comum para comunicação efetiva entre os envolvidos com geomecânica, relacionar as experiências obtidas em um local com as encontradas em outro, e fornecer uma base sólida para compreender as características geomecânicas do maciço rochoso.

Na Tabela 1 apresentam-se as principais classificações geomecânicas, seus autores, origem e aplicações. Nesta pesquisa, as principais classificações utilizadas serão a de Bieniawski (1973) e de Barton (1974).

Tabela 1 - Métodos de Classificação Geomecânica

Classificação	Autor (Data)	Origem	Aplicações Originais
Carga de rocha	Terzaghi (1946)	EUA	Túneis com suportes metálicos
Tempo de autosustentação	Lauffer (1958)	Áustria	Túneis
RQD	Deere et al. (1967)	EUA	Descrição de testemunhos e túneis
RSR	Wickham et al. (1972)	EUA	Túneis com suportes metálicos
Sistema RMR	Bieniawski (1973)	África do Sul	Túneis e minas
Sistema Q	Barton et al. (1974)	Noruega	Túneis e cavidades amplas

Fonte: Adaptado de Castro (2016)

2.2.1. Classificação RMR de Bieniawski

Em 1973, Bieniawski publicou uma classificação de maciços rochosos chamada Rock Mass Rating ou apenas RMR. Ao longo dos anos o sistema RMR sofreu revisões (1974, 1975, 1976 e 1989), mas os princípios básicos se mantiveram

constantes. Inicialmente desenvolvida apenas para obras subterrâneas posteriormente, surgiram aplicações na análise da estabilidade de taludes (Castro, 2004).

A classificação RMR utiliza seis parâmetros que, segundo Bieniawski, contribuem mais significativamente para o comportamento mecânico do maciço rochoso. Para cada um dos parâmetros é atribuído um peso. A somatória dos pesos constitui um índice que corresponde a cinco classes de qualidade propostas pelo autor. Os seis parâmetros são: resistência a compressão uniaxial da rocha intacta ou índice de compressão puntiforme, RQD ("*Rock Quality Designation*") , espaçamento entre as descontinuidades, condição das descontinuidades, influência da água subterrânea e orientação das descontinuidades.

Para a determinação dos pesos de cada parâmetro, Bieniawski propôs tabelas, onde os pesos variam de acordo com o valor dos parâmetros determinados a partir de furos de sondagem ou da caracterização de campo.

De acordo com o valor total do RMR obtido, o maciço rochoso pode ser classificado em: Muito bom, Bom, Razoável, Fraco e Muito fraco, conforme a Tabela 2 a seguir.

Tabela 2 - Classes do RMR

Somatório (RMR)	100 - 81	80 - 61	40 - 21	40 - 21	< 21
Classe	I	II	III	IV	V
Qualidade do maciço rochoso	Muito bom	Bom	Razoável	Fraco	Muito Fraco

Fonte: Adaptado de Bieniawski (1989)

O valor do índice RMR se correlaciona ao tempo médio de auto-sustentação (período em que deve-se colocar suporte na estrutura sob pena de colapso total) para túneis não revestidos. O RMR também fornece orientações quanto às características da seção de escavação e quanto aos métodos de suporte mais adequados.

2.2.2. Classificação Q de Barton

A classificação Q de Barton, também conhecida como *Rock Mass Quality*, foi proposta em 1974 após a observação de mais de 200 casos de obras em rocha. O índice é baseado na análise de 6 fatores que, segundo o autor, são relevantes para

caracterizar o comportamento mecânico do maciço rochoso (Nogoseke, 2009). É calculado a partir a Fórmula 1:

$$Q = \frac{RQD}{J_n} \times \frac{J_r}{J_a} \times \frac{J_w}{SRF} \quad (1)$$

Onde:

RQD = Designação de Qualidade da rocha ("Rock Quality Designation")

J_n = Índice de influência do nº de famílias das descontinuidades

J_r = Índice de influência da rugosidade das fraturas

J_a = Índice de influência do grau de alteração das fraturas

J_w = Índice de influência da água subterrânea

SRF = (Stress Reduction Factor) = Índice que considera o estado de tensões no entorno da escavação

De acordo com o valor do índice Q são propostas recomendações em relação ao tipo de suporte necessário para garantir a estabilidade de maciços rochosos em túneis.

2.3. REDES NEURAIS

2.3.1. Rede Neural Biológica


O cérebro humano desempenha funções de reconhecimento de padrões, controle motor, percepção, etc. Este é composto por cerca de 100 bilhões de neurônios que são conectados entre si por meio de sinapses. (Kandell, 1998)

O neurônio é uma célula nervosa e é considerada a unidade básica do sistema nervoso, é capaz de gerar sinais elétricos que permitem a transmissão de informações por longos percursos. Possui três funções básicas: receber sinais (ou informações), integrar sinais de entrada (para determinar se esta informação deve ser repassada adiante ou não) e comunicar sinais a células alvo (outros neurônios, músculos ou glândulas) (Kandell, 1998).

Estas funções são refletidas na anatomia do neurônio, que é dividida em dendritos, soma (corpo celular) e axônio. Os dois primeiros possuem a função de receber e processar informações. Os sinais (ou informações) recebidos podem ser inibidos ou não por meio do potencial de membrana. Nesta parte do neurônio é tomada a decisão se o sinal é relevante para ser transmitido, caso seja, é conduzido até o axônio e é transmitido para a próxima célula por meio da sinapse. O sinal é transmitido sempre que o potencial da membrana for superior a um determinado limiar (*threshold*) (Kandell, 1998).

A sinapse é o local onde as informações são transmitidas do neurônio pré-sináptico para o pós-sináptico (célula alvo). Na maioria das sinapses a informação é transmitida por neurotransmissores, que são mensageiros químicos. Na Figura 6 observa-se o esquema de um neurônio e sua anatomia.

Figura 6 – Rede Neural



Fonte: Khan Academy

2.3.2. Rede Neural Artificial


A tentativa de simular matematicamente a rede neural do cérebro humano levou às propostas da rede neural artificial (RNA). O primeiro trabalho publicado sobre a RNA é de 1940, realizado pelo neurofisiologista Warren McCulloch e pelo matemático Walter Pitts. Neste artigo, descreveram o princípio de funcionamento de um neurônio matemático e modelaram uma rede neural simples com circuitos elétricos, com base

em um algoritmo denominado lógica de limiar. A partir deste trabalho as pesquisas sobre redes neurais foram divididas em uma frente voltada para os processos biológicos do cérebro e outra para a aplicação em inteligência artificial. A inspiração na rede neural biológica serve para modelar como o processo de aprendizado e resolução de sistemas complexos acontece no cérebro humano.

A rede neural artificial pode ser definida como uma estrutura de processamento (rede), que possui capacidade de realizar cálculos em paralelo para processar dados e representar o conhecimento. É composta por unidades conectadas (neurônio artificial). Cada unidade apresenta um comportamento específico quanto a entrada ou saída de informações.

Assim como no modelo biológico, a RNA recebe sinais de entrada e o processo que acontece na sinapse é representado por um peso associado, que indica sua influência na unidade de saída. Então é feita uma soma ponderada (função soma) dos sinais recebidos que gera um nível de atividade específico. Caso o nível de atividade exceda um certo limite (*threshold*) a unidade produz uma resposta de saída (função de ativação) (Zambiasi, 2008). A Figura 7 mostra a representação de um neurônio artificial.

Figura 7 – Representação de uma neurônio artificial



Fonte: Tafner (1996)

O peso é um atributo de grande importância em uma rede neural artificial. É geralmente representado pela letra w (*weight*), que significa peso em inglês, e representa o grau de importância da entrada em relação ao neurônio. O valor é

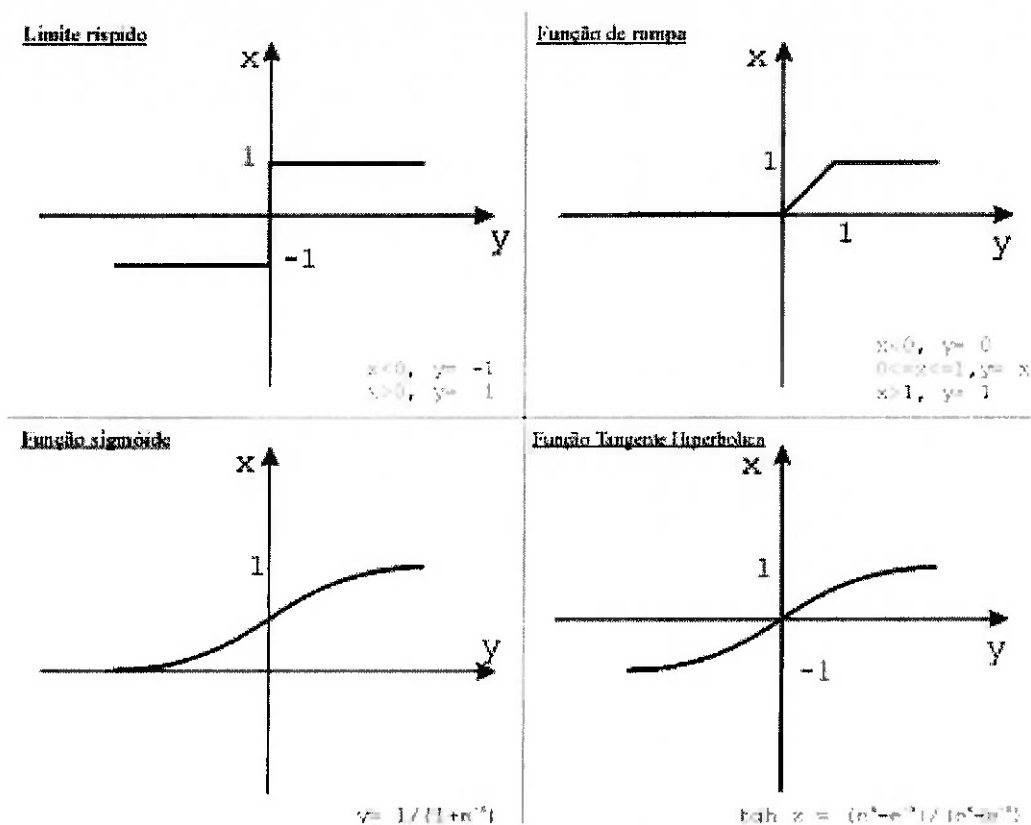
alterado de acordo com a intensidade de sua entrada, mudando o valor representativo para a rede. Este processo é denominado de aprendizagem. Dessa forma a rede entende que quanto menos uma dada entrada for estimulada, esta terá um peso menos significativo na saída. O contrário ocorre se a entrada for mais estimulada. Matematicamente os pesos são vistos como um vetor de valores para um neurônio e como uma matriz de pesos para um conjunto de neurônios (Tafner 1996).

O sinal de excitação enviado para o neurônio é o resultado da soma do produto dos pesos pelos respectivos sinais de entrada. O próximo passo que o neurônio realiza é comparar o valor da soma com o limiar. Esse processo é realizado por uma função de ativação ou limiar lógico.

Esta função atua dentro do próprio neurônio e é responsável pela decisão de ativar ou não o neurônio de acordo com os resultados da soma ponderada das entradas. O valor de saída só é produzido após a chamada da função de ativação e segue pela função transferência.

A função ativação dita se a RNA terá efeito sobre o neurônio seguinte, introduzindo um componente não linear nas redes neurais, fazendo com que sejam capazes de reproduzir mais do que relações lineares entre variáveis dependentes e independentes (Kovács, 1998). A função de ativação pode ser de diversos tipos como apresentado na Figura 8.

Figura 8- Tipos de função de transferência




Fonte: Kovács (1996)

2.3.3. Arquitetura

Assim como em redes neurais biológicas, o conjunto de vários neurônios artificiais formam redes neurais artificiais. A seguir, na Figura 9 pode-se observar a arquitetura básica de uma rede neural artificial.

Figura 9 - Arquitetura de uma rede neural artificial




Fonte: Zambiasi (2008)

A maneira como os neurônios artificiais são agrupados é um fator importante para que as informações sejam processadas de maneira dinâmica e interativa. As RNAs podem ter uma ou mais camadas, sendo a quantidade de camadas relacionada à quantidade de "nós" que existe entre a de entrada e a de saída (Zambiasi, 2008).

As redes que possuem apenas uma camada são utilizadas para resolução de problemas linearmente separados. A Figura 10 esquematiza esta arquitetura.


Figura 10 – Rede neural com uma única camada



Fonte: Zambiasi (2008)

As redes neurais multicamadas possuem uma ou mais camadas escondidas (*hidden* ou ocultas). O número de camadas entre a camada de entrada e a de saída é variável e muda de acordo com a necessidade do arquiteto da rede. As camadas ocultas são constituídas por neurônios que recebem dados, mas seus *outputs* são passados para outros neurônios. A arquitetura desse tipo de rede neural é apresentada na Figura 11.

Figura 11 – Rede neural multicamadas



Fonte: Zambiasi (2008)

2.3.4. Aprendizado Em Redes Neurais

Uma RNA pode aprender por exemplos, desse modo ser ajustada a intensidade de suas conexões de acordo com a saída esperada. O aprendizado em uma rede neural pode ser feito de duas formas: aprendizado supervisionado e não supervisionado. A tarefa do algoritmo de aprendizagem consiste em ajustar os parâmetros de uma RNA para que esta possa aprender um determinado padrão. O primeiro passo para a resolução de um problema a partir de uma RNA é o processo de aprendizagem, que consiste na rede procurar e extrair padrões a partir do reconhecimento dos dados fornecidos a ela, modelando uma representação própria das informações dadas (Zambiasi, 2008).

2.3.4.1. Aprendizado Supervisionado

No aprendizado supervisionado a rede neural é treinada antes de ser utilizada. O treinamento da rede consiste em apresentar dados de entrada e os dados de saída correspondentes. Assim os dados de saída da rede neural são comparados com os dados de saída esperados (Ortega, 2008).

A quantidade de dados para o treinamento deve ser suficientemente grande para conter as informações necessárias para que a rede aprenda as relações importantes

presentes nos dados. Esta etapa permite que a rede tenha os pesos corretos para representar o padrão desejado.

Após o treinamento é necessário testar como a rede se comporta com dados que ainda não foram apresentados a ela. Caso os dados de saída não sejam razoáveis, é necessário realizar um novo treinamento.

2.3.4.2. Aprendizado Não Supervisionado

Neste tipo de aprendizado a rede deve ser capaz de aprender sem a necessidade de um conjunto de treinamento. Não há suporte para que fontes externas interfiram no aprendizado da máquina. De acordo com os sinais de entrada a rede adapta as tendências para as suas necessidades (Ortega,2008).

Esta deve possuir características que determinam se o aprendizado converge ou não para o caminho certo.

2.4. ANÁLISE DA EFICIÊNCIA DOS CLASSIFICADORES

Nesta pesquisa as RNAs serão na classificação de dados, assim é necessária uma medida para a caracterização da eficiência dos classificadores produzidos. A avaliação do desempenho de classificadores com resposta binária pode ser feita por meio da matriz de Confusão e da curva ROC (Receiver Operating Characteristic Curve), descritas na sequência.

2.4.1 Matriz De Confusão

A matriz de confusão é uma ferramenta importante para medir a habilidade de discriminação de modelos, ou seja a discriminação entre eventos e não eventos. A utilização deste método de determinação de eficiência, permite uma análise visual do desempenho de um classificador (Chagas, 2009).

A matriz de confusão mostra a relação entre as classes previstas por um classificador para um conjunto de dados e a classe real a que os dados pertencem. Desta maneira os resultados são divididos em quatro classes distintas.

1. Verdadeiro Positivo (VP): ocorre quando um dado é previsto em uma classe (0 no caso binário) e o dado real pertence à mesma classe (0)

2. Falso Positivo (FP): quando o classificador prevê o dado em uma classe (0) e o dado real pertence à classe (1).
3. Falso Negativo (FN): caso em que o classificador prevê o dado na classe (1) e o dado real pertence à classe (0).
4. Verdadeiro Negativo (VN): caso em que o classificador prevê um dado na classe (1) e este é igual ao dado real (1)

As colunas da matriz correspondem aos dados previstos pelo classificador e as linhas correspondem aos dados verdadeiros. A disposição da matriz é demonstrada a Figura 12.

Figura 12 - Modelo da Matriz de Confusão

		Valor Previsto	
		0	1
Valor Observado	0	VP	FN
	1	FP	VN

Fonte: Elaboração própria

2.4.2 Curva ROC (*Receiver Operating Characteristic Curve*)


A curva ROC é utilizada para demonstrar quão bem o modelo pode discriminar entre 2 classificações (entre 1 e 0 para o binário). Possui dois parâmetros principais: taxa de verdadeiros positivo e taxa de falsos negativo.

A taxa de verdadeiros positivo, também chamada de *recall* ou sensibilidade, é dada por todos os dados classificados como verdadeiro positivo e verdadeiro negativo. Assim como a taxa de falsos negativo, também conhecida como “1- especificidade”, é dado pelos falsos positivos e falsos negativos (Glenn, 2019).

Associada à curva ROC está a curva de não discriminação do classificador. Caso a curva ROC seja igual a esta, pode considerar-se a predição como aleatória, uma vez que em uma classificação binária há 50% de chance de acerto.

A capacidade de discriminação do classificador de acordo com o formato da curva é apresentado abaixo.

Figura 13 – Eficiência do classificador medida pela curva ROC de acordo com sua forma



Fonte: Glenn (2019)

3. MATERIAIS E MÉTODOS

3.1. MINA CUIABÁ

A mina subterrânea Cuiabá está localizada na cidade de Sabará, em Minas Gerais, no Quadrilátero Ferrífero. A unidade operacional é composta pela mina subterrânea (Mina Cuiabá) e uma planta de beneficiamento (Planta Ouro). A mina subterrânea hoje possui mais de 1000 m de profundidade. Assim como em outras minas, como a Mina Velha, pertencente a antiga mineradora Morro Velho. O estado das tensões *in situ* e a estabilidade do maciço rochoso são fatores fundamentais para a viabilidade da mineração, por isso para a continuidade dos trabalhos de extração em profundidade na Mina Cuiabá é de grande importância o conhecimento do comportamento geomecânico do maciço rochoso. (Trópia, 2013)

3.1.1. Método de Lavra

A mina Cuiabá (MG) é lavrada pelo método de corte e aterro (*cut and fill*). O método consiste no preenchimento dos vazios deixados pela escavação do minério por estéril ou material de baixo valor antes de se realizar uma nova escavação.

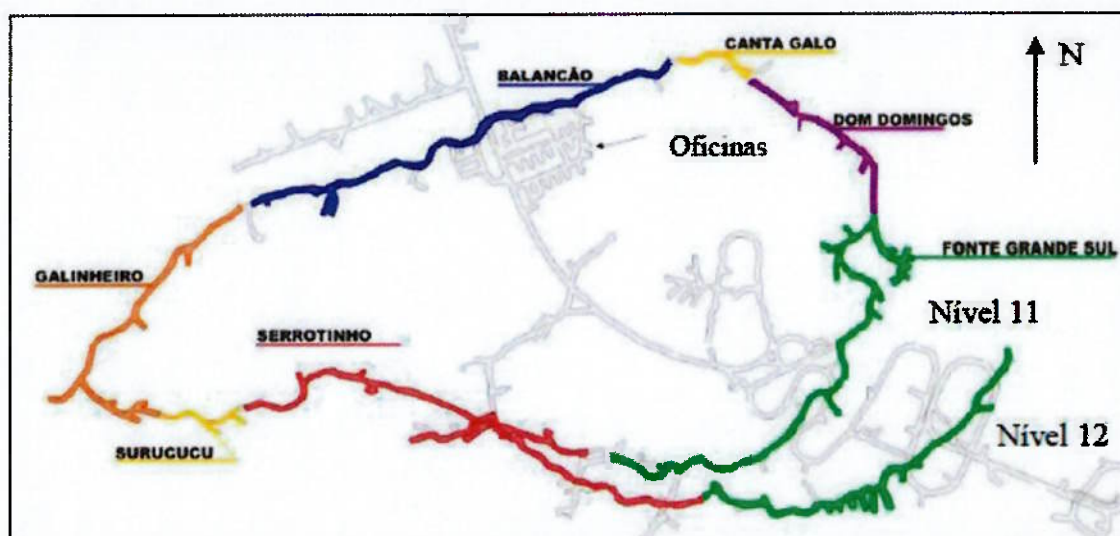
Este método permite lidar com a variação da qualidade do minério, fornecendo teor e recuperação aceitáveis. No caso da Mina Cuiabá o material do enchimento é o rejeito do beneficiamento (*backfill*).

3.1.2. Aspectos Gerais da Mina

A Mina Cuiabá (MG) opera com painéis com lavra da altura vertical de 66 m até o nível 9, de 44 m do nível 9 ao nível 11, e a partir do nível 11 a altura do painel para o corpo Grande Sul é de 33 m e para o Serratinho de 60 m segundo Trópia (2013).

Os corpos mineralizados e lavradas na mina são o Balancão, Galinheiro, Fonte Grande Sul e Serratinho, como é mostrado na Figura 14 a seguir.

Figura 14 - Corpos mineralizados na Mina Cuiabá



Fonte: Trópia (2013)

3.2. METODOLOGIA

3.2.1 Materiais

Para a realização desta pesquisa foi utilizado o programa Stdisk para a realização das análises estatísticas das variáveis, a determinação do histograma e do *boxplot*.

A construção do classificador com base em uma rede neural foi realizada a partir do programa Mathematica.

3.2.2 Métodos

As rampas de acesso aos painéis de lavra da Mina Cuiabá (MG) têm apresentado problemas de ruptura em suas paredes e tetos.

A equipe de Mecânica das Rochas da mina levantou dados relativos às características do maciço rochoso e parâmetros geométricos de 197 pontos localizados em 10 rampas de acesso aos níveis diferentes da mina. Estes dados foram fornecidos pela Mina para a realização da pesquisa.

A partir dos dados colhidos, foram analisados o parâmetro RMR, o parâmetro Q, a profundidade do ponto e o maior vão da rampa (maior valor entre a altura e a largura).

Foram analisados o valor dos parâmetros RMR, Q, Maior Vão (m), Profundidade(m), e se apresentava ruptura ou não do maciço rochoso de 197 pontos de 10 rampas da

Mina Cuiabá. A não ruptura do maciço rochoso foi representada por '0' e a ruptura por '1'.

O primeiro passo consistiu nas análises estatísticas do RMR, Q, Maior Vão e Profundidade para avaliar a independência dos parâmetros. Com o auxílio do programa Statdisk criou-se o histograma e *boxplot* de cada parâmetro. Em seguida os dados foram divididos em com ruptura e sem ruptura. Foi analisada a diferença entre as médias de cada parâmetro nas duas situações com um teste t com um intervalo de confiança de 95%.

O segundo passo consistiu na construção de um classificador com base em uma rede neural no programa Mathematica para cada parâmetro capaz de discriminar a ruptura ou não do maciço rochoso. Os dados foram separados em dados de treinamento (167 pontos) e dados de teste (30 pontos).

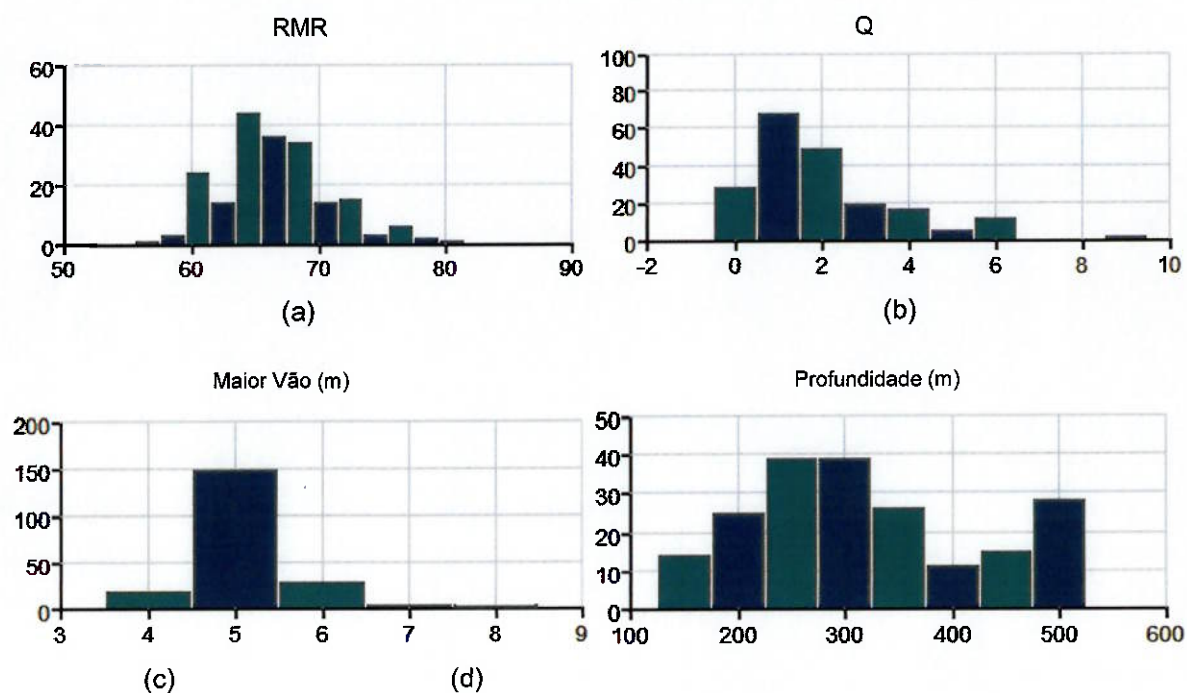
O classificador foi treinado com os 167 pontos da mina, em seguida foi testado com os 30 pontos de teste. A comparação entre o resultado de saída do classificador e os dados de teste foi realizada através da acurácia do classificador, da matriz de confusão e das curvas ROC.

O terceiro passo consistiu na construção de classificadores com mais de um parâmetro de entrada, utilizando-se do mesmo processo de construção para o classificador com um parâmetro de entrada. Foram construídos os classificadores e avaliados de acordo com sua acurácia, curva ROC e matriz de confusão.

4. RESULTADOS E DISCUSSÃO

Na Figura 15 é possível observar o histograma de cada parâmetro analisado e sua distribuição.

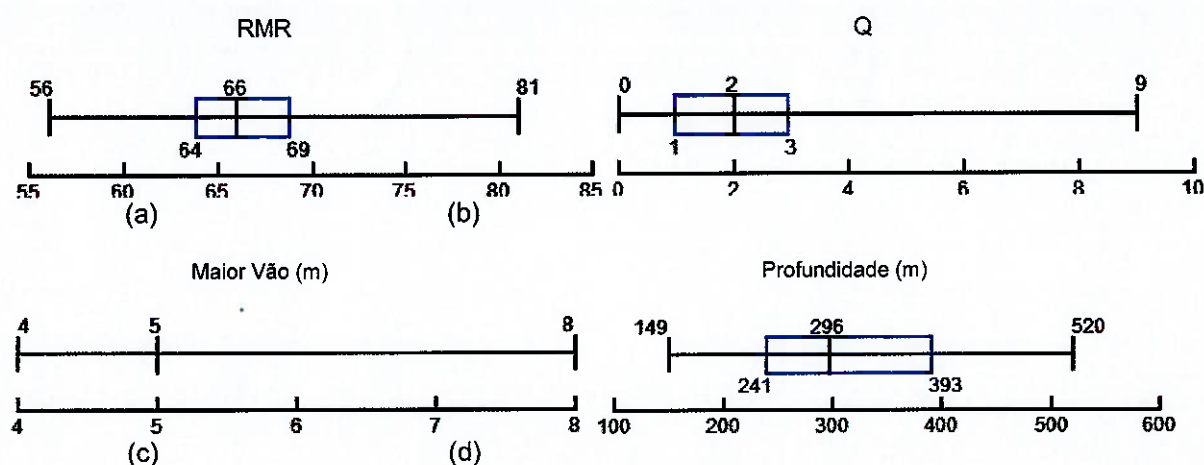
Figura 15 - Histograma do parâmetro RMR (a), do parâmetro Q (b), do maior vão da rampa (c) e profundidade do ponto (d).



Fonte: Elaboração Própria

Nota-se na Figura 16 que os histogramas dos parâmetros seguem uma distribuição normal característica. Com exceção da profundidade, a Figura 16 apresenta os Boxplot para cada parâmetro, onde se observa os valores máximo, mínimo, mediana e quartis.

Figura 16- Boxplot do parâmetro RMR (a), do parâmetro Q (b), do maior vão da rampa (c) e profundidade do ponto (d).



Fonte: Elaboração Própria

4.1. ANÁLISE DA INDEPENDÊNCIA DAS VARIÁVEIS

A análise da capacidade de discriminação das variáveis quanto à ocorrência de ruptura da rocha nas rampas da Mina Cuiabá (MG) foi feita por meio de uma análise estatística dos parâmetros geomecânicos e geométricos levantados.

Os dados com ocorrência ou não de ruptura foram separados para identificar quais parâmetros permitem distinguir a ocorrência dos problemas de estabilidade.

O método utilizado foi a determinação do intervalo de confiança para a média da variável para o RMR, Q, Profundidade (Z) e maior vão com um grau de confiança de 95%.

Os parâmetros que não apresentaram sobreposição de valores nos intervalos de confiança da média para os dados com e sem ruptura, foram denominados de "parâmetros disjuntos" por distinguirem a ocorrência ou não de problemas de estabilidade.

Os parâmetros que apresentaram sobreposição nos intervalos de confiança foram denominados "parâmetros sobrepostos", não permitindo a distinção da ocorrência de ruptura da rocha com base em seus valores.

A Tabela 3 apresenta os resultados dos intervalos de confiança para cada parâmetro e sua classificação como disjunto ou sobreposto. O único parâmetro que apresentou

sobreposição de no intervalo foi o Maior Vão e por isso não foi utilizado na classificação dos dados.

Tabela 3 - Classificação dos parâmetros de acordo com o intervalo de confiança

Parâmetro	Sem Ruptura		Com Ruptura		Classificação
	Limite Inferior	Limite Superior	Limite Inferior	Limite Superior	
RMR	67,049	68,683	64,226	65,938	Disjuntos
Q	1,9923	2,1334	1,218	1,7232	Disjuntos
Profundidade (z)	253,242	285,299	335,919	378,206	Disjuntos
Maior Vão	4,984	5,1946	4,977	5,235	Sobrepostos

Fonte: Elaboração Própria

4.2. CLASSIFICAÇÃO DOS DADOS

O treinamento de uma rede neural artificial baseia-se em encontrar uma função de ativação que represente adequadamente os pontos dados. Estes são divididos em dados de aprendizagem e dados de teste.

Os dados geomecânicos e geométricos da Mina Cuiabá foram separados, 167 pontos foram utilizados para treino da rede neural artificial. Com base nesses dados a rede cria uma função que busca prever de acordo com o valor do parâmetro dado se há ou não ruptura da rocha.

Dos pontos totais, 30 foram separados para testar a acurácia da rede neural. Foram dados à rede neural artificial treinada esses pontos e foi devolvida a sua classificação.

Os dados reais de ruptura ou não ruptura da rocha foram comparados com os devolvidos pela rede neural artificial.

4.2.1. Classificação com um parâmetro

A análise da predição de ruptura do maciço rochoso foi realizada através do treinamento de uma rede neural artificial. Cada treinamento realizado relacionou um dos parâmetros - RMR, Q e maior profundidade (selecionados na etapa anterior) - com a ruptura ou não dos dados de treinamento.

A cada treinamento realizado com um parâmetro obteve-se um função que representa a classificação da rede neural artificial. A partir desta função obteve-se a

acurácia, matriz de confusão e curva ROC de cada treinamento. O resultado é apresentado na Tabela 4 se seguir.

Tabela 4 - Resultado dos classificadores com um parâmetro

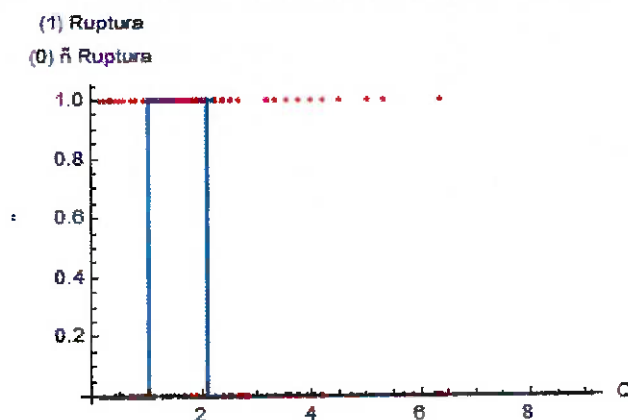
	Acurácia	Precisão - Ruptura	Precisão - Não Ruptura	Curva ROC - Ruptura	Curva ROC - Não Ruptura	Matriz de Confusão - % FP	Matriz de Confusão - % FN
R	0,73	0,63	0,90	Elevada	Média	3%	23%
Q	0,80	0,89	0,76	Média	Média	17%	3%
Z	0,73	0,85	0,69	Elevada	Elevada	23%	3%

Fonte: Elaboração Própria

O classificador com o parâmetro Q apresentou maior acurácia, portanto foi considerado o classificador com os melhores resultados para a predição de problemas de estabilidade do maciço rochoso.

A função obtida através do classificador com o parâmetro Q é representada pela Figura 17.

Figura 17 - Gráfico do Classificador (Q)




Fonte: Elaboração Própria

Observa-se pelo gráfico da função dada pela rede neural artificial que valores aproximadamente entre 1 e 2 são classificados como ruptura. Os valores de Q fora deste intervalo são classificados como não ruptura. Os valores de que Q são coerentes, rochas com menores valores de Q tendem a ser menos resistentes.

A função dada pela rede neural artificial possui uma acurácia(taxa de acerto) do treinamento de 0,8.


Para uma resposta binária, como é o caso do experimento, é importante avaliar o seu poder de discriminação. A curva ROC foi utilizada para visualizar a capacidade de discriminação e uma matriz de confusão que apresenta verdadeiros e falsos positivos e verdadeiros e falsos negativos.

Figura 18 - Curvas ROC para a discriminação da classificação binária do Q (0 – Não ruptuta, 1- Ruptura).



Fonte: Elaboração Própria

Figura 19 - Matriz de Confusão para o Conjunto de Teste (Q)



Fonte: Elaboração Própria

Pela Figura 18 nota-se que a curva ROC para a não ruptura da rocha possui uma discriminação média, enquanto para a ruptura a discriminação é maior.

Observa-se na Figura 19 que o modelo teve 1 caso de falso negativo, ou seja, que não sofreu ruptura mas o modelo o classifica como rompido, que corresponde 3% do conjunto teste. E 5 casos de falsos positivo, ou seja, pontos que sofreram ruptura,

entretanto foram classificados pelo modelo como se não tivessem rompido, representando 17% do conjunto teste.

4.2.2. Classificação com dois parâmetros

A identificação da contribuição de mais de um parâmetro simultaneamente na predição da ruptura da rocha, foi realizada através da construção de classificadores com múltiplas entradas.

Os parâmetros foram separados em pares, construindo 3 classificadores diferentes. A Tabela 7 apresenta os resultados obtidos para cada classificador com pares de parâmetros.


Tabela 5 - Resultados dos classificadores com dois parâmetros

	Acurácia	Precisão - Ruptura	Precisão - Não Ruptura	Curva ROC - Ruptura	Curva ROC - Não Ruptura	Matriz de Confusão - % FP	Matriz de Confusão - % FN
RMR & Q	0,77	0,85	0,69	Média	Média	6%	17%
RMR & Z	0,83	0,80	0,90	Alta	Alta	13%	3%
Q & Z	0,77	0,85	0,69	Baixa	Baixa	23%	3%

Fonte: Elaboração Própria

O classificador que utiliza os parâmetro RMR e z possui a maior acurácia, portanto dentre os classificadores de dois parâmetros é o melhor para a predição de problemas de estabilidade. A função dada pela rede neural artificial é representada na Figura 20.

Figura 20 - Função do classificador RMR & Z




Fonte: Elaboração Própria

De acordo com a Figura 20, as rupturas previstas pelo classificador ocorrem com um RMR abaixo de 72 e profundidade menor que 400 m.

A seguir são apresentadas a curva ROC e a matriz de confusão do classificador. A curva ROC apresentada na Figura 21 mostra um alta discriminação do classificador, tanto para o caso da ruptura da rocha quanto a não ruptura.


Figura 21 - Curva ROC do classificador RMR & Z (0 – Não ruptura, 1- Ruptura).



Fonte: Elaboração Própria

Dentre os dados do conjunto de teste, apenas 1 caso dentre 13 foi classificado como um falso negativo, representando 3% do conjunto total. A quantidade de falsos positivo foi de 4 casos, sendo 13% dos dados.

Figura 22 - Matriz de confusão do classificador RMR & Z



Fonte: Elaboração Própria

4.2.3. Classificação com três parâmetros

A análise de predição da ruptura do maciço rochoso foi agora realizada a partir da construção um classificador que utiliza os três parâmetros disjuntos simultaneamente. O resultado do classificador é dado pela Tabela 6 a seguir.


Tabela 6 - Resultado do classificador com três parâmetros

	Acurácia	Precisão - Ruptura	Precisão - Não Ruptura	Curva ROC - Ruptura	Curva ROC - Não Ruptura	Matriz de Confusão - % FP	Matriz de Confusão - % FN
RMR & Q & Z	0,73	0,74	0,72	Média	Média	17%	10%

Fonte: Elaboração Própria


A seguir são apresentados a curva ROC e a matriz de confusão deste classificador. Na Figura 23 observa-se que a curva ROC possui uma discriminação média para o conjunto de testes, tanto na ruptura, quanto na não ruptura.

Figura 23 - Curva ROC do classificador RMR & Q & Z (0 – Não ruptura, 1- Ruptura)



Fonte: Elaboração Própria

Figura 24 - Matriz de confusão do classificador RMR & Q & Z



Fonte: Elaboração Própria

Pela Figura 24 observa-se para o classificador, 3 casos de falsos negativo, sendo 10% do total do conjunto, e 5 casos de falsos positivo, representando 23%.

5. CONCLUSÕES

Este trabalho teve dentre seus objetivos analisar quais parâmetros dentre RMR, Q, profundidade e maior vão possui influência na ruptura ou não da rocha da Mina Cuiabá (MG). Foi identificado que os parâmetros RMR, Q e Z possuem intervalos de confiança disjuntos em relação à ocorrência ou não da ruptura da rocha.

Para a construção dos classificadores utilizou-se os parâmetros RMR, Q e profundidade. O maior vão foi descartado pois não possuía a capacidade de discriminação suficiente entre ruptura e não ruptura.

Foram criados classificadores com um, dois e três parâmetros. O classificador que forneceu maior acurácia foi o classificador RMR & Z. Os dois parâmetros utilizados em conjunto puderam prever a ruptura da rocha com acurácia de 0,83.

Para o classificador com um parâmetro, o que obteve a maior acurácia é o com parâmetro Q. Este teve uma acurácia de 0,8 no treinamento.

Apesar de o classificador RMR & Z e o classificador Q apresentarem os melhores resultados de predição de ruptura, o classificador com três parâmetros obteve a acurácia de 0,73 no treinamento, menor valor obtido dentre os resultados.

A ruptura do maciço rochoso é um evento crítico, pois pode comprometer a operação da mina, assim como sua segurança. Por isso, apesar da acurácia do treinamento ser alta ainda é recomendado mais estudos sobre classificadores a fim de aumentá-la ainda mais.

Pelos resultados obtidos nesta pesquisa, observou-se que o classificador RMR & Z é o que melhor prediz a ruptura da rocha nas rampas de acesso aos níveis na mina Cuiabá (MG).

Conclui-se que os objetivos inicialmente propostos de aplicar o aprendizado de máquina para identificar parâmetros que possam ser associados a problemas de estabilidade do maciço rochoso da mina Cuiabá (MG) foram alcançados.

REFERÊNCIAS

- AMADEI, B.; STEPHANSSON, O. **Rock stress and its measurement**. London: Chapman and Hall, 1997.
- BARBOSA, K.J. **Avaliação Geotécnica De Lavra Subterrânea Do Corpo Serrotinho Da Mina Cuiabá Através Da Modelagem Numérica Tridimensional**, 2011. Dissertação de Mestrado – Núcleo de Engenharia Geotécnica, Universidade Federal de Ouro Preto, Ouro Preto, 2011.
- BARTON, N. et al. **Engineering classification of rock masses for the design of tunnel support**. Rock Mechanics, v.6, 1974
- BELL, F. G. **Engineering Properties of Soils and Rocks**. 4ª Edição. Malden: Blackwell Science, 2000.
- BIENIAWSKI, Z. T. **A complete manual and geologists in Mining, Civil, and Petroleum Engineering**. Engineering Rock Mass Classifications. John Wiley & Sons, New York, 1989.
- CHAGAS, C. S.; VIEIRA, C. A. O; FILHO, E.I.F.; JÚNIOR, W. de C. . Utilização de redes neurais artificiais na classificação de níveis de degradação de paisagens. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.13, n.3, p.319–327, 2009. Disponível em: < <https://www.alice.cnptia.embrapa.br/handle/doc/658048>>. Acesso em: 20/05/2019
- D'ALESSANDRO, J. R. P. . **Análise de estabilidade do maciço rochoso da Mineração Casa de Pedra**. 159 p. Dissertação (Mestrado em Engenharia Civil) Faculdade de Engenharia Civil, Arquitetura e Urbanismo, Universidade de Campinas, Campinas, SP.
- GLEN, S. ROC Curve Explained in One Picture. Apresenta explicação sobre a curva ROC. Disponível em: <<https://www.datasciencecentral.com/profiles/blogs/roc-curve-explained-in-one-picture>> Acesso em 31/08/2019

GOUVEA, A. D. V. . **Análise dos parâmetros conficionantes de problemas de estabilidade em uma mina subterrânea de ouro a partir de técnicas de reconhecimento de padrões** 2019. Dissertação (Mestrado),Escola Politécnica, Universidade de São Paulo, São Paulo

HAIMSON B.; LEE, H. **Borehole breakouts and compaction bands in two high porosity sandstones**. International Journal of Rock Mechanics & Mining Sciences, v. 41, p. 287-301, 2004.

HEIDER, M. Visão da Mineração Subterrânea no Brasil, **In the Mine**, Brasil. Disponível em: <<http://inthemine.com.br/site/wp-content/uploads/2017/04/ITM.66.Mercado.pdf>>. Acesso em: 27/05/2019

HUTCHINSON, D. J.; DIEDERICHS, M. S. Cablebolting in underground mines. Vancouver: BiTech. 1996.

IV SIMPÓSIO BRASILEIRO DE REDES NEURAI (BRAZILIAN SYMPOSIUM ON NEURAL NETWORKS), Goiania, Brazil, December 1997. **Evolutionary Design of MLP Neural Network Architectures** Proceedings SBRN'97 – International Track, pages 58-65, IEEE Computer Press.

KANDELL, E. R. **Neurociencia y conducta**. Madrid: Prentice Hall, 1998

KHAN ACADEMY , A. Rede Neural Biológica. Disponível em: <https://pt.khanacademy.org/science/biology/human-biology/neuron-nervous-system/a/overview-of-neuron-structure-and-function>. Acesso em 20/05/2019

KOVÁCS, Z.L. **Rede neurais artificiais: Fundamentos e Aplicações**. Segunda edição, Collegium Cognitivo, 1998

NOGOSEKE, E. . **Compartimentação de maciços rochosos para projetos básicos de PCH'S usando sistema RMR aplicação o projeto básico da PCH Morro Grande – RS**. 125 p. Dissertação (Mestrado em Geotecnia) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Paulo, 2009.

ORTEGA, G. V. C. **Redes Neurais na Identificação de Perdas Comerciais do Setor Elétrico**. Dissertação (Mestrado em Engenharia Elétrica) - Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2008.

PIMENTA, L. M. V. **Análise das zonas plastificadas da rampa fonte grande sul (mina Cuiabá) via modelagem numérica.** Dissertação (Mestrado) - Universidade Federal de Ouro Preto, Ouro Preto, 2017

SANSONE, E.C. **Abordagem Não Convencional Na Representação Matemática Do Comportamento Mecânico Das Rochas.** 2001. Dissertação de Doutorado – Escola Politécnica, Universidade de São Paulo, São Paulo, 2001.

TAFNER, M. A. **Reconhecimento de palavras faladas isoladas usando redes neurais artificiais.** Dissertação (Mestrado) – Universidade Federal de Santa Catarina, Santa Catarina, 1996

TRÓPIA, I. R. **Análise das tensões in situ em ambiente de lavra subterrânea – Mina Cuiabá – Sabará/MG.** 2013. Dissertação (Mestrado em Geotecnia) – Universidade Federal de Ouro Preto, Ouro Preto, 2013

ZAMBIASI, S.P. Apostila sobre redes neurais artificiais. Disponível em: https://www.gsigma.ufsc.br/~popov/aulas/rna/uteis/RNA_material_apoio.pdf. Acesso em 20/05/2019 Pg 19,22 e 23