

Aprendizagem de máquina na determinação de parâmetros de resistência de filitos brandos

Machine learning in the determination of soft phyllite strength parameters

Aprendizaje automático en la determinación de parámetros de resistencia de filita blanda

Recebido: 24/12/2022 | Revisado: 04/01/2023 | Aceitado: 05/01/2023 | Publicado: 11/01/2023

Lívia Aparecida Gonçalves Pinto

ORCID: <https://orcid.org/0000-0003-1517-6634>

Universidade Federal de Ouro Preto, Brasil

E-mail: livia.pinto@aluno.ufop.edu.br

José Margarida da Silva

ORCID: <https://orcid.org/0000-0001-5695-7213>

Universidade Federal de Ouro Preto, Brasil

E-mail: jms@ufop.edu.br

Resumo

Aspectos geológico-geotécnicos devem ser levados em consideração desde os estudos de exploração geológica, em empreendimentos mineiros. Alguns acidentes ocorridos em minas, nas últimas décadas, poderiam ser evitados, caso as condições geológico-geotécnicas do maciço fossem compreendidas. Ainda existe grande dificuldade em se classificar alguns tipos de rochas, sobretudo as rochas consideradas brandas, por meio dos sistemas de classificação geomecânica conhecidos. A grande maioria das classificações existentes foram desenvolvidos baseadas em características de rochas duras. Para maciços rochosos pouco resistentes, é necessário adaptar os sistemas atuais ou desenvolver novos sistemas de classificação, que sejam específicos para maciços rochosos brandos praticamente contínuos. O objetivo deste artigo é propor a utilização de técnicas de Aprendizagem de Máquina para previsão de parâmetros geotécnicos de rochas brandas, especialmente filito. Foram utilizados dados históricos de resultados de ensaios geotécnicos de laboratório de rochas de minas do Quadrilátero Ferrífero, que, por meio da interação otimizada, e com auxílio de técnica de Inteligência Artificial, como a Rede Neural Artificial e Regressão Linear, sejam capazes de gerar resultados de interesse para análises de estabilidade e modelagens geotécnicas. Das técnicas utilizadas, resultados mostraram que o método de Regressão Linear se mostrou satisfatório na determinação de parâmetros de resistência de filitos brandos e com boas perspectivas de ampliação e utilização para outros parâmetros, assim como outros tipos de rochas.

Palavras-chave: Rochas brandas; Filitos; Parâmetros de resistência; Aprendizagem de máquina; Redes neurais artificiais; Regressão linear.

Abstract

Geological-geotechnical aspects must be taken into account since geological exploration studies in mining projects. Some accidents that occurred in mines in recent decades could be avoided if the geological and geotechnical conditions of the rock mass were understood. There is still great difficulty in classifying some types of rocks, especially rocks considered soft, through known geomechanical classification systems. The vast majority of existing classifications were developed based on hard rock characteristics. For rock masses with little strength, it is necessary to adapt current systems or develop new classification systems, which are specific for practically continuous soft rock masses. The objective of this article is to propose the use of Machine Learning techniques to predict geotechnical parameters of soft rocks, especially phyllite. Were used historical data from the results of geotechnical laboratory stress measures campaign of rocks from mines in the Iron Quadrangle are used, which, through optimized interaction, and with the aid of Artificial Intelligence techniques, such as the Artificial Neural Network and Linear Regression, are capable of generating results of interest for stability analysis and geotechnical modeling. Of the techniques used, results showed that the Linear Regression method was satisfactory in determining the strength parameters of soft phyllites and with good prospects for expansion and use for other parameters, as well as other types of rocks.

Keywords: Soft rocks; Phyllites; Strength parameters; Machine learning; Artificial neural networks; Linear regression.

Resumen

Los aspectos geológicos-geotécnicos deben ser tomados en cuenta a partir de los estudios de exploración geológica en proyectos mineros. Algunos accidentes ocurridos en minas en las últimas décadas podrían evitarse si se entendieran las condiciones geológicas y geotécnicas del macizo. Todavía existe una gran dificultad para clasificar algunos tipos de rocas, especialmente rocas consideradas blandas, a través de sistemas de clasificación geomecánicos conocidos. La

gran mayoría de las clasificaciones existentes se desarrollaron con base en las características de las rocas duras. Para macizos rocosos con poca resistencia es necesario adaptar los sistemas actuales o desarrollar nuevos sistemas de clasificación, que sean específicos para macizos rocosos blandos prácticamente continuos. El objetivo de este artículo es proponer el uso de técnicas de Machine Learning para predecir parámetros geotécnicos de rocas blandas, especialmente filita. Fueron usados datos históricos de los resultados de los ensayos de laboratorio geotécnico de rocas de las minas del Cuadrángulo de Hierro, que mediante una interacción optimizada y con la ayuda de técnicas de Inteligencia Artificial, como la Red Neuronal Artificial y la Regresión Lineal, son capaces de generar resultados de interés para análisis de estabilidad y modelado geotécnico. De las técnicas utilizadas, los resultados mostraron que el método de Regresión Lineal fue satisfactorio en la determinación de los parámetros de resistencia de las filitas blandas y con buenas perspectivas de expansión y uso para otros parámetros, así como para otros tipos de rocas.

Palabras clave: Rocas blandas; Filitas; Parámetros de resistencia; Aprendizaje automático; Redes neuronales artificiales; Regresión lineal.

1. Introdução

Este artigo descreve trabalho de pesquisa de Pinto (2022) sobre determinação de parâmetros de resistência de filitos brandos com uso de aprendizagem de máquina.

Boas práticas da mineração, desenvolvidas ao longo de décadas de atividade, recomendam que aspectos geológico-geotécnicos sejam levados em consideração desde os estudos de exploração geológica. Muitos investimentos de recursos poderiam ter sido minimizados ou evitados caso houvesse conhecimento prévio satisfatório das características geomecânicas do maciço rochoso que compõe a mina.

Existe um grande grau de incerteza associado à avaliação das propriedades geotécnicas de maciços rochosos. Isso se torna ainda mais incerto devido aos complexos processos geológicos envolvidos e às dificuldades inerentes à caracterização geomecânica.

A avaliação de parâmetros geomecânicos é muitas vezes realizada por meio de testes in situ e de laboratório, juntamente com a aplicação de metodologias empíricas, tais como os sistemas de classificação Geomecânica.

Dos inúmeros sistemas de classificação geomecânica desenvolvidos, muitos envolvem a quantificação de dados empíricos dos parâmetros da rocha. Alguns são amplamente utilizados pela comunidade técnico-científica.

Um dos objetivos das classificações geomecânicas de maciços rochosos é definir parâmetros geotécnicos que possam ser utilizados nas análises de estabilidade de escavações. Em se tratando de rochas brandas, algumas classificações não são indicadas, e outras são limitadas quanto a sua utilização

Este estudo mostra uma ferramenta computacional para obtenção de parâmetros geotécnicos em rochas brandas, que são obtidos por meio de aprendizagem de máquina, em que os dados de entrada são informações de ensaios de caracterização geotécnica. Para treinar os modelos, foram utilizados dados de ensaios de rochas brandas do Quadrilátero Ferrífero, especificamente, de filitos presentes em minas a céu aberto de minério de ferro.

A determinação de parâmetros de resistência de maciços rochosos, por meio de aprendizagem de máquina, favorece a redução de custos de obtenção dos dados e agilidade nos processos de análises. Este artigo compara a metodologia convencional com a nova metodologia, com a utilização de técnicas de aprendizagem de máquina e analisa a aplicabilidade de tais técnicas para prever parâmetros de resistência, principalmente quando não há meios indiretos satisfatórios para se prever o comportamento de rochas brandas.

2. Fundamentos

A avaliação das propriedades geotécnicas de um maciço rochoso inclui o conhecimento das propriedades da rocha intacta, da ocorrência e natureza das descontinuidades, da extensão e do grau de alteração e da posição espacial das descontinuidades no maciço.

Investigações de campo detalhadas são fundamentais para a identificação de características do maciço rochoso, tais como plano de estratificação, juntas, falhas, dentre outras descontinuidades.

Do ponto de vista mecânico convém distinguir escavações em rochas duras e em rochas brandas. As escavações em rochas duras pressupõem maciços relativamente resistentes em presença de tensões induzidas. Nas escavações em rochas brandas, eventuais instabilidades são mais abrangentes e mais generalizadas. As rupturas por cisalhamento ou tração progredem, gradualmente, além do contorno escavado, podendo atingir volumes expressivos

Rochas brandas são, em geral, rochas de baixa resistência, possuem grande porosidade, cimentação deficiente, ou são suscetíveis ao intemperismo. Podem conter minerais argilosos expansivos e/ou intercamadas fracas. Os limites de resistência do que pode ser considerado rocha branda é algo variável, mas geralmente se considera que o limite de resistência à compressão uniaxial, entre rocha branda e dura, é de cerca de 25 MPa.

Maciços rochosos são considerados brandos não apenas pela baixa resistência da rocha intacta, mas também rochas duras com características estruturais de baixa resistência. O termo “rochas brandas” segundo a ISRM, compreende rochas cujos graus de resistência variam. Escavações em rochas brandas podem ter comportamentos que vão desde aqueles associados a solos rígidos àqueles parcialmente controladas por estruturas.

As rochas brandas fazem parte do grupo das rochas, que devido ao seu comportamento geotécnico, constituem uma fase intermédia entre os solos (coesivos) e rochas duras. Quando expostas à água e às mudanças climáticas, ocorre perda de resistência, que não é reversível em condições normais, enquanto em solos coesivos é possível devido a alterações no teor de umidade.

Maciços de complexa evolução geológico-estrutural e de baixa resistência são de difícil caracterização, tal a variedade de fatores que interferem no seu comportamento geomecânico (Pinheiro, 2014). É fundamental a obtenção de informações diretas dos aspectos geomecânicos do local em estudo, e a extrapolação de dados de outros locais não é o mais adequado (Souza et al, 2020). Testes de resistência são, em geral, caros e os parâmetros são muitas vezes inferidos indiretamente. Os ensaios de laboratório são relevantes apenas para um pequeno volume de rocha e, conseqüentemente, é necessário realizar um número considerável de ensaios para caracterizar a variabilidade dos parâmetros geomecânicos, mesmo que muito esforço seja feito na obtenção de amostras representativas.

As técnicas de perfuração convencionais dificilmente fornecem bons testemunhos de sondagem em rochas brandas de baixa resistência, assim como informações suficientes sobre os preenchimentos de descontinuidade e permeabilidade do maciço. As amostras de testemunho podem ser danificadas por águas subterrâneas, atrito de perfuração ou vibração durante a sondagem (Kanji, 2014; Tao et al, 2020). A investigação de rochas brandas é muito difícil porque falta um programa de testes padronizado.

À medida que o empreendimento mineiro for sendo implantado é necessária a atualização, bem como a obtenção de novos dados geotécnicos, para que diminuam as incertezas relativas ao projeto inicial de escavações. Pinheiro (2014) atenta para a importância da periodicidade e atualização dos levantamentos geotécnicos além do nível de detalhamento. Taludes escavados em rochas brandas estão sujeitos a processos de alteração mais acelerados que dependem do grau de fraturamento, da permeabilidade do maciço e do tempo de exposição.

As rochas brandas podem ser consideradas como rochas complexas e de deformação plástica significativa em um dado ambiente (Manchao & Xiaoming, 2020). A interação mecânica entre camadas mais rígidas e mais deformáveis controla a redistribuição de tensões e, conseqüentemente, a condição de estabilidade no interior do maciço.

Rochas brandas podem apresentar comportamentos indesejáveis. Dessa forma, são adotados parâmetros conservadores, para garantir bastante segurança, mas muitas vezes contra a economia (Kanji, 2014). Embora exista uma grande variedade de rochas brandas no Brasil, pouco se conhece sobre seu comportamento geomecânico. Pesquisas realizadas

consideram a subdivisão dos materiais que se enquadram nas categorias ISRM ‘fraco’ e ‘muito fraco’ da forma apresentada no Quadro 1, segundo Franca et al (2018).

Quadro 1 - Faixas de resistência de rochas brandas

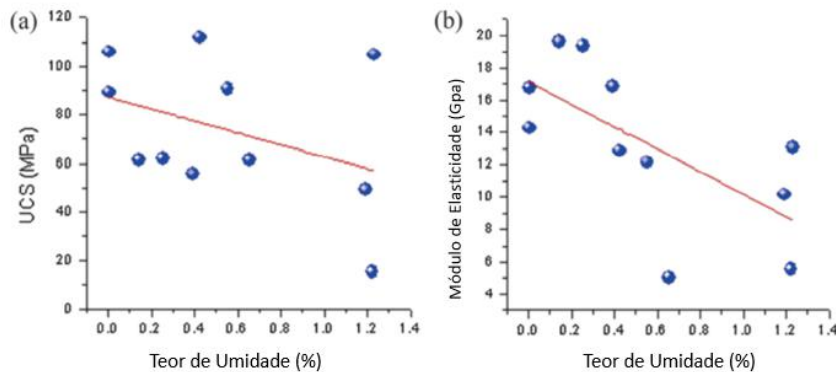
Rochas fracas (R2)	R2+	Rochas moles de alta resistência: com resistência variando de 8 a 25 MPa (semelhante ao concreto comum) ou superior.
	R2-	Rochas moles de baixa resistência: com resistência variando de 5 a 8 MPa.
Rochas muito fracas (R1)	R1+	Rochas muito moles: com resistência variando de 1 a 5 MPa.
	R1-	Rochas extremamente moles, com resistência variando de 0,25 a 1 MPa, aproximando-se das resistências do solo.

Fonte: Franca et al (2018).

Em maciços constituídos por rochas brandas, as características de resistência da rocha matriz exercem maiores influências na geração de um plano de fraqueza que governa o mecanismo de ruptura. Silva (2010) observou, nas áreas de rochas mais alteradas, menos duráveis e resistentes, mesmo na presença de estruturas geológicas com cinemática favorável à ocorrência de rupturas definidas pelas mesmas, rupturas típicas de solos, como a circular.

Ensaio de compressão axial em rochas brandas hidratadas realizados por Zhang (2020). Demonstraram que, com o aumento do teor de umidade, a resistência da rocha tende a diminuir. A análise de correlação entre resistência à compressão uniaxial (UCS) e módulo de elasticidade mostra que ambos tendem a diminuir com o aumento do teor de umidade (Figura 1).

Figura 1 - Relação entre teor de umidade, resistência à compressão (a) e módulo de elasticidade (b) em amostras de rochas brandas.



Fonte: Zhang (2020).

Em termos de hidrogeologia, as diferenças principais nas características das rochas brandas em comparação com as rochas duras que são normalmente encontradas em áreas de mineração, são: (i) geralmente exibem porosidade primária mais alta do que a maioria das unidades de rochas duras; (ii) muitas rochas brandas são de baixa permeabilidade, tornando-as mais difíceis de drenar e, portanto, despressurizar do que formações rochosas duras; (iii) são, por definição, materiais mais macios; (iv) devido à sua natureza de grão fino, muitas vezes há um volume considerável de água retida nas rochas brandas após a despressurização. O contraste entre as propriedades hidráulicas das juntas e fraturas e as propriedades hidráulicas da matriz rochosa tende a ser menor em rochas brandas. No entanto, as discontinuidades ainda podem formar caminhos preferenciais de fluxo de água subterrânea através das rochas (Beale, 2018).

2.1 Classificações Geomecânicas

Sistemas de classificação geomecânica envolvem atribuição de pontos para observações das condições do maciço

rochoso (Silva, 1997). Dos sistemas desenvolvidos, muitos envolvem a quantificação de dados empíricos dos parâmetros da rocha. Alguns são amplamente utilizados pela comunidade técnico-científica, e fornecem subsídios confiáveis para estabelecer estimativas preliminares do comportamento de escavações subterrâneas em maciços rochosos.

A classificação geomecânica deve ser precedida de observação criteriosa quanto aos mecanismos que poderão deflagrar ruptura no maciço. Deve estar bem compreendido se a ruptura pode se dar pela rocha intacta, pela descontinuidade ou pelo maciço rochoso.

A classificação básica de maciço rochoso utiliza geralmente outros critérios, além de simples classificação litológica. Somodi et al., (2021) ponderam que os parâmetros de classificação devem refletir condições reais e considerar seus efeitos na estabilidade da escavação proposta. Para fins de projeto, os parâmetros de resistência ao cisalhamento são frequentemente selecionados em vez de determinados.

De forma geral, classificações geomecânicas fornecem, em função da classe do maciço, indicativos do vão máximo sem suporte (distância máxima à frente da escavação que pode permanecer sem suporte), do tempo de autossuporte e da estrutura mais adequada de sustentação. Permitem previsão do tipo necessário para cada setor das escavações e em qual quantidade, mas, por considerarem um dado conjunto de parâmetros, devem ser usadas em conjunto com análises de campo e interpretações geológicas, entre outras ferramentas.

O conhecimento das propriedades de resistência por ensaios *in situ* é de grande relevância, mas as dificuldades associadas à amostragem e execução dos mesmos impossibilitam sua utilização, levando ao emprego de métodos indiretos, como as classificações geomecânicas (Santos et al., 2017). Desta forma, a avaliação da condição dos maciços rochosos, por meio da quantificação de sua qualidade, constitui fase preliminar aos estudos de análise de estabilidade, permitindo as estimativas dos parâmetros de resistência dos maciços rochosos e descontinuidades, parâmetros de entrada utilizados nos modelos numéricos (Santos, 2021). Embora existam várias classificações de maciços rochosos, nenhuma delas prevaleceu sobre a outra e, normalmente, o uso de mais de uma classificação é altamente recomendado (Somodi et al., 2021).

Com intuito de compreender o comportamento do maciço rochoso no aprofundamento da mina subterrânea Pilar (Mineração Caraíba) no semiárido baiano, foi realizada caracterização Geomecânica, em que foram utilizados testemunhos de sondagens e mapeamento de galerias, com preenchimento de uma planilha de campo e posteriormente alimentando uma planilha eletrônica. A partir do qual pôde ser gerado modelo geomecânico 3D, com auxílio de software específico (Freitas, 2016).

Souza (2019) utilizou classificações geomecânicas para projetos de cavas operacionais e finais em uma mina de ouro em Goiás. Stephenson & Sandy (2021) propuseram diretrizes para projeto e suporte de emboques subterrâneos. Os autores recomendam que uma investigação detalhada do local seja conduzida usando métodos aceitos pela indústria. Berdard et al. (2016) compararam dados obtidos por meio da classificação RMR com a resistência mínima de aderência de parafusos em testes de arrancamento, na mina de ouro de Nevada, EUA.

Nos últimos anos as técnicas de machine learning têm sido usadas com sucesso para modelar problemas de engenharia geotécnica. As limitações e dificuldades de realização de testes em rochas, especificamente em rochas de camadas finas, altamente fraturadas, altamente porosas e fracas, bem como o fato de serem destrutivos, caros e demorados, levam ao seu desenvolvimento. Santos (2021) utilizou técnica de aprendizagem de máquina para prever a classificação geomecânica de maciços rochosos, testando modelos treinados tanto por aprendizagem supervisionada (descrita no item 3.1). Quanto não supervisionada. Oliveira Filho e Bicalho (2018) utilizaram redes neurais artificiais para estimativa de propriedades geotécnicas de solos argilosos. Nola (2015) utilizou as RNAs para avaliação de dados geológico-geotécnicos e previsão de movimentos gravitacionais de massa em Ouro Preto, MG.

3. Materiais e Métodos

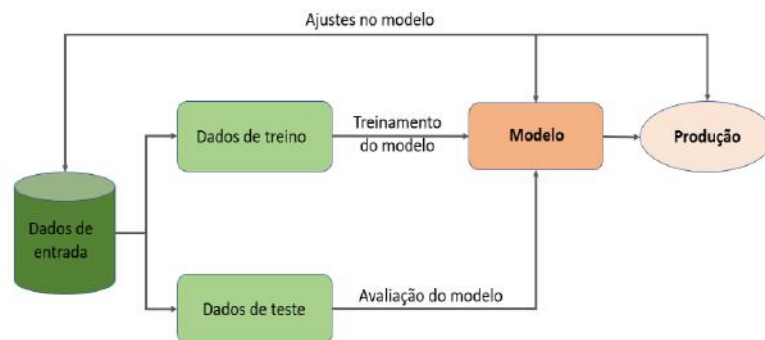
3.1 Recursos computacionais e aprendizagem de máquina em geotecnia

A atividade de campo para obtenção dos parâmetros geotécnicos que serão utilizados para a classificação geomecânica de maciços rochosos requer a utilização de planilhas, independentemente do método de classificação escolhido. Inúmeras são as opções de planilhas eletrônicas, muito embora, em alguns casos, a utilização delas em campo requer o uso de redes de conectividade, o que muitas vezes não está disponível.

Dentre alternativas computacionais de uso comercial ou livres estão disponíveis: Kundu et al. (2020) propõem de maneira prática e objetiva a obtenção de valores de RMR por meio da inserção dos parâmetros obtidos em campo; planilha em formato Excel foi desenvolvida por Palmstron (1995), atualmente na quarta versão (Palmstron, 2020); Pinheiro (2013) também produziu uma ferramenta computacional, sem que seja necessário recorrer às tabelas físicas ou eletrônicas de preenchimento manual.

A tentativa de reproduzir nas máquinas o mesmo processo de aprendizagem dos seres humanos é chamado de machine learning ou aprendizagem de máquina, que se utiliza de algoritmos, que nada mais são do que operações matemáticas e estatísticas, com a finalidade de reproduzir tarefas e otimizar processos. O aprendizado de máquina é definido como o campo de estudo que dá aos computadores a capacidade de aprender sem serem explicitamente programados, ensinando máquinas a lidar com dados com mais eficiência (Mahesh, 2019). O fluxo de trabalho dos algoritmos de aprendizado de máquina supervisionado é fornecido na Figura 2.

Figura 2 - Fluxo de trabalho – algoritmo de aprendizagem supervisionada.



Fonte: Modificado de Mahesh (2019).

Com a abundância de conjuntos de dados disponíveis, a demanda por aprendizagem de máquina vem aumentando. Um fator importante é que para que a aprendizagem de máquina seja viável, é fundamental a existência de dados históricos sobre o modelo que se deseja prever.


A aprendizagem dita supervisionada ocorre quando um algoritmo é treinado sobre um conjunto de dados históricos contendo entradas e saídas e sendo capaz de gerar previsões a partir de dados novos. Dentre as diversas técnicas de aprendizagem supervisionada, podemos citar a regressão linear, utilizada nesse trabalho. A regressão linear é usada com valores continuamente variáveis, como no caso em que o preço de o produto e a quantidade de consumo são variáveis contínuas, o que significa que elas podem ter um número infinito de valores possíveis.

As Redes neurais (RNAs) ou Redes Neurais Artificiais (artificial neural network – ANN) são uma série de algoritmos para reconhecimento de relacionamentos em um conjunto de dados por meio de um processo que imita a forma como o cérebro humano funciona. Nesse sentido, redes neurais referem-se a sistemas de neurônios, de natureza orgânica ou artificial.

Uma rede neural artificial funciona em três camadas. A camada de entrada recebe os dados de entrada (muito parecido

com o que fazem os dendritos, no neurônio biológico). A camada oculta processa a entrada (como soma e axônio). Finalmente, a camada de saída envia o resultado (como os terminais dendríticos). Uma rede neural artificial é composta por várias unidades de processamento, cujo funcionamento é bastante simples. Essas unidades, geralmente, são conectadas por canais de comunicação que estão associados a determinado peso.

Figura 3 - Organização em camadas



Fonte: ICMC (2022).

3.2 Contexto geológico-geomorfológico e geoestrutural – origem das amostras

As amostras utilizadas neste estudo são provenientes de filitos do Quadrilátero Ferrífero. O filito é uma rocha abundante em todo o Quadrilátero e como está sempre associada à formação ferrífera, desta forma, invariavelmente está exposta nas frentes de lavra de minério de ferro. De forma geral, a idade das rochas estudadas é proterozóica (Alkmim & Marshak, 1998).

Os filitos da base de dados deste estudo são provenientes de Formações Geológicas diversas. Neste trabalho, não se procurou distinguir qual a formação geológica a que cada amostra pertence, nem há este detalhamento das fontes de dados coletadas.

O Quadrilátero ferrífero é definido por estruturas sinformais localizadas nas suas bordas. As megaestruturas são compostas por rochas do Supergrupo Minas, as quais encontram-se topograficamente mais elevadas em relação ao embasamento granítico – gnáissico e ao Supergrupo Rio das Velhas. São encontrados: xistos, quartzitos, filitos, itabiritos, dolomitos, depósitos lacustres, sedimentos aluvionares, depósitos de tálus, colúvios e coberturas lateríticas (canga).

Os filitos são encontrados nos fundos de vales ou no sopé de encostas, são muitas vezes altamente suscetíveis à erosão e escorregamentos, frequentemente controlados pelas estruturas da rocha. Filitos são rochas metamórficas que ocorrem em zonas que sofreram baixo metamorfismo e com elevado teor de metais alcalinos. Possuem granulometria fina, constituída principalmente de caulinita, mica muscovita (sericita) e quartzo (CPRM, 2005).

O conhecimento do comportamento mecânico do filito é complexo, devido à dificuldade de se retirar amostras intactas e de se preparar amostras adequadas à realização de testes mecânicos, uma vez que se constitui em um material com elevada suscetibilidade à alteração intempérica, apresentando, com frequência, estágio avançado de decomposição, além de frequente baixa resistência, mesmo nos materiais mais são (Carvalho, 2019). A dificuldade envolvida na identificação macroscópica dos graus de intemperismo devido à textura muito fina da rocha, bem como as heterogeneidades microestruturais são prováveis causas da variabilidade observada nas propriedades do filito. Mudanças na porosidade e na distribuição do tamanho dos poros na frente de intemperismo não apresentaram linearidade, assim como as variações de resistência. (Leão et al. 2019).

3.3 Interface gráfica para parâmetros de resistência por meio de caracterização geomecânica - Protótipo

Nessa fase, inicialmente foi construído um protótipo de interface gráfica, onde o usuário pode inserir os dados de entrada, tais como os obtidos em campo durante a caracterização geomecânica, e a partir desses dados, pode apresentar, por meio de um campo de saída, a classe geomecânica do maciço pelo método RMR clássico (Bieniawski, 1989), seguido dos parâmetros geotécnicos de resistência da rocha. Esta tarefa permite organizar, por meio de uma única tela, todos os dados de entrada e saída necessários. Após o processamento das informações, o aplicativo lança um resultado que é apresentado em uma tela, de interface amigável.

Esses dados foram disponibilizados por meio de ícones, representados por faixas de valores (ranges) onde é possível o usuário selecionar o que melhor se adequa ao material que está sendo analisado. Durante a construção deste protótipo, foram utilizados conceitos de programação da linguagem orientada a objetos Pascal.

Os valores foram inseridos nos botões para acionamento automático pelo usuário. Cada atributo é acionado por um botão, sendo um de cada vez, e o resultado apresentado num campo específico (Figura 4).

A partir do conceito de programação utilizado, objetivou-se desenvolver uma aplicação que fosse possível obter, além dos parâmetros de resistência para rochas duras, para rochas brandas. Devido à dificuldade em se trabalhar nesta primeira aplicação com os métodos de machine learning, como Redes Neurais Artificiais e Regressão Linear, optou-se por utilizar uma segunda linguagem de programação em que fosse possível tanto o processamento quanto a apresentação dos resultados obtidos por aprendizagem de máquina.

Figura 4 - Protótipo da interface do usuário para classificação por RMR

Fonte: Autores.

3.4 Elaboração do modelo de machine learning para previsão de parâmetros de resistência de fíltos

A linguagem de programação escolhida para realização da análise exploratória e tratamento dos dados, assim como os testes dos modelos de RNA e de Regressão Linear, foi a linguagem R®. O R é uma linguagem de programação além de um ambiente para cálculos matemáticos, estatísticos e geração de gráficos.

3.5 Obtenção e análise exploratória dos dados de ensaios de filitos

Os dados utilizados para o treinamento da rede neural foram extraídos de publicações de ensaios geotécnicos de 70 amostras de filito de diferentes minas do Quadrilátero Ferrífero. A partir da reunião das informações de interesse em um banco de dados consolidado, procedeu-se com a análise exploratória, seguida do tratamento dos dados. Os testes nos modelos de machine learning foram com dois grupos: um de 32 amostras e 6 variáveis, outro de 27 amostras e 11 variáveis.

4. Resultados e Discussão

Inúmeros testes de modelos preditivos foram realizados utilizando-se aprendizagem de máquina por Redes Neurais e Regressão Linear. Pinto (2022) apresenta a descrição detalhada das etapas de exploração dos dados e tratamento, assim como os testes dos modelos preditivos, tanto de Regressão Linear, quanto Redes Neuras.

Durante a análise exploratória dos dados, entre as variáveis do primeiro grupo testado (densidade real dos grãos, peso específico seco, porosidade, índice de vazios, coesão e ângulo de atrito), foi observado moderada a forte correlação linear (considerando coeficiente de correlação linear - Quadro 2).

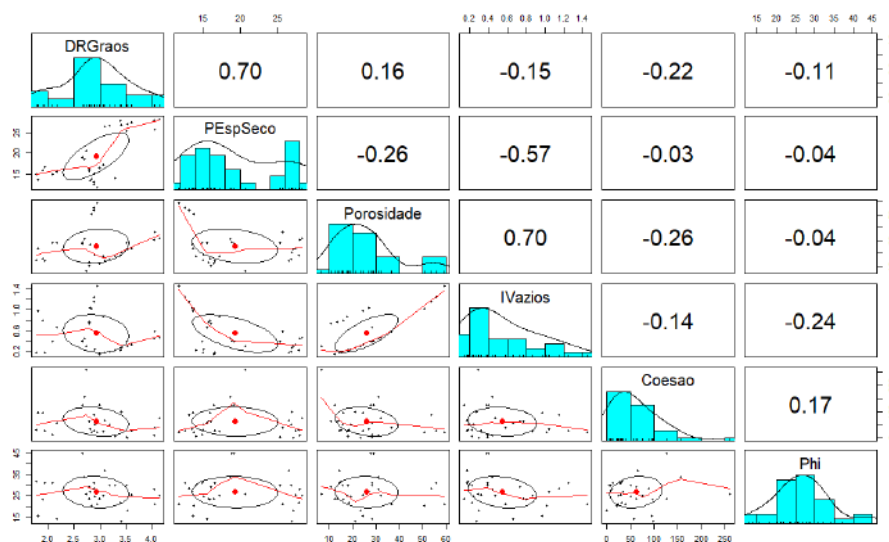
Quadro 2 - Coeficiente de Correlação Linear.

Coeficiente de correlação linear de Pearson	
$0 < r_{jk} < 0,30$	Fraca correlação linear
$0,30 < r_{jk} < 0,60$	Moderada correlação linear
$0,60 < r_{jk} < 0,90$	Forte correlação linear
$0,90 < r_{jk} < 1,00$	Correlação linear muito forte

Fonte: Hinkle (2003).

Conforme observado na Figura 5, a correlação entre os pares de variáveis densidade real dos grãos e peso específico seco, porosidade e índice de vazios, obtiveram índices de correlação de 70%, o que configura uma forte correlação linear.

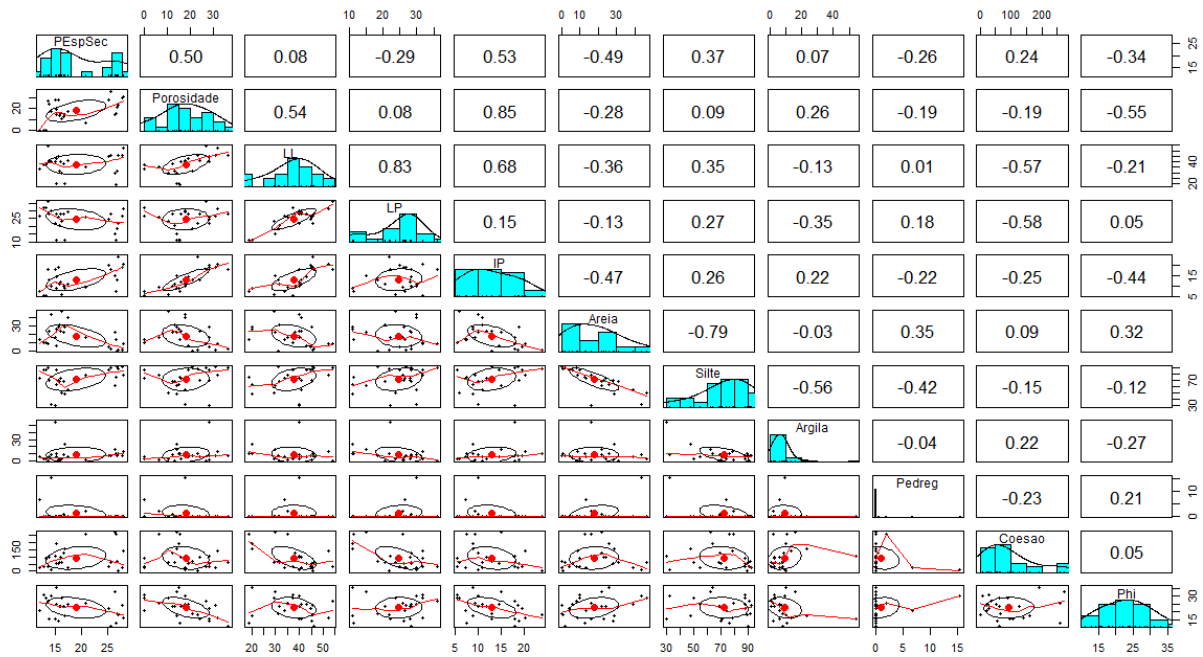
Figura 5 - Dispersão de dados e valores de correlação – primeiro conjunto de dados.



Fonte: Autores.

Na análise exploratória do segundo conjunto de dados (variáveis: peso específico seco, porosidade, limite de liquidez, limite de plasticidade, índice de plasticidade, porcentagens de areia, silte, argila, pedregulho, coesão e ângulo de atrito) foram obtidos os seguintes resultados, conforme mostram a Figura 6.

Figura 6 - Dispersão de dados e valores de correlação - segundo conjunto de dados.

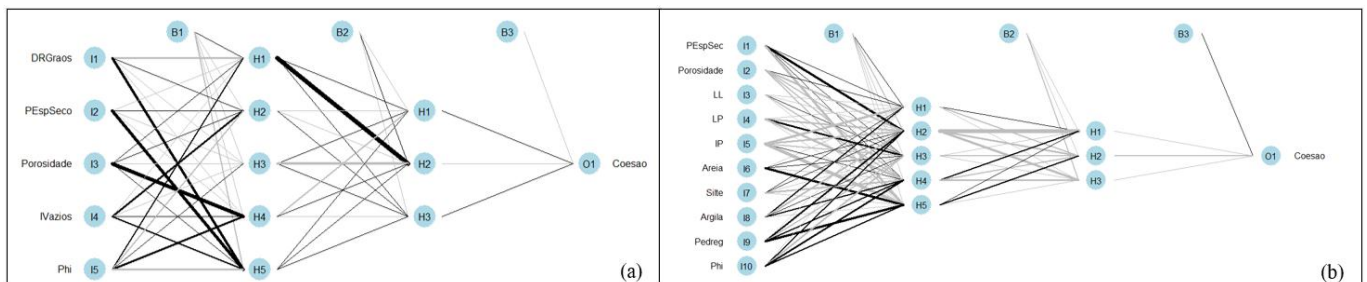


Fonte: Autores.

Os testes de *machine learning*, tanto de regressão linear quanto por redes neurais foram realizados para os dois *datasets*. O desenvolvimento completo, assim como o código em R utilizado durante a modelagem de *machine learning* pode ser acompanhado em Pinto (2022).

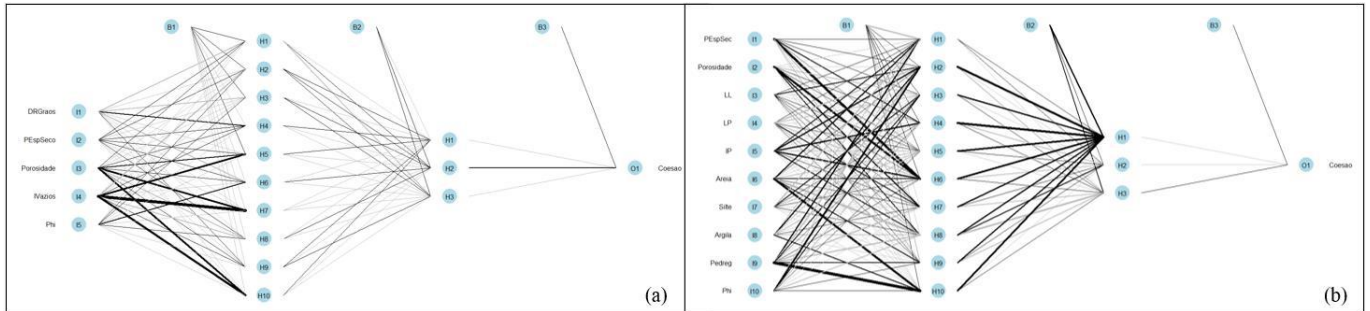
Os testes com redes neurais foram realizados em ambos *datasets*, utilizando-se inicialmente camadas internas ocultas, com 5 e 3 neurônios (Figura 7). Posteriormente foram realizados testes com 10 e 3 camadas internas ocultas (Figura 8).

Figura 7 - Testes com redes neurais, com 5 e 3 neurônios nas camadas internas ocultas, (a) primeiro conjunto de dados e (b) segundo conjunto de dados.



Fonte: Autores.

Figura 8 - Testes com redes neurais, com 10 e 3 neurônios nas camadas internas ocultas, (a) primeiro conjunto de dados e (b) segundo conjunto de dados.



Fonte: Autores.

A métrica para avaliação de performance dos modelos por regressão linear e de redes neurais, foi o MSE (*mean squared error*), ou erro quadrático médio, com o qual é calculada a diferença entre o valor predito e o valor real e elevada ao quadrado. Desta forma, penalizam-se valores muito diferentes entre o previsto e o real. Portanto, quanto maior o valor do MSE, significa que o modelo não performou bem em relação às previsões. Os modelos de *machine learning* com o primeiro conjunto de dados obteve valores de MSE da ordem de 2.000, representando o modelo com menor erro de estimação. Os resultados comparativos dos modelos preditivos analisados, são mostrados na sequência (Figura 9 e Figura 10).

Figura 9 - Comparação entre as performances dos modelos de regressão linear (*mse.lm*) e de redes neurais (*mse.nn*) com camadas internas de 5 e 3 neurônios – (a) primeiro conjunto de dados e (b) segundo conjunto de dados.

<pre>> print(paste(mse.lm, mse.nn)) [1] "2439.04441165447 2326.07779254233"</pre>	<pre>> print(paste(mse.lm, mse.nn)) [1] "5321.90131562556 9252.46823279486"</pre>
(a)	(b)

Fonte: Autores.

Figura 10 - Comparação entre as performances dos modelos de regressão linear (*mse.lm*) e de redes neurais (*mse.nn*) com camadas internas de 10 e 3 neurônios – (a) primeiro conjunto de dados e (b) segundo conjunto de dados.

<pre>> print(paste(mse.lm, mse.nn)) [1] "5321.90131562556 58651.2522559346"</pre>	<pre>> print(paste(mse.lm, mse.nn)) [1] "3578.1139871439 11098.2486215152"</pre>
(a)	(b)

Fonte: Autores.

O *dataset* com maior erro de estimação foi o do segundo conjunto de dados, constituído por 11 variáveis e 27 amostras. Com maiores erros de estimação principalmente nos modelos de redes neurais, seja com camadas internas menores (de 5 e 3 neurônios internos) ou com camadas internas maiores (com 10 e 3 neurônios internos). Os erros de estimação em ambos os casos foram mostrados nas Figura 9 e Figura 10.

Foi possível observar que tanto os modelos por regressão linear, quanto por redes neurais, o número de amostras influencia positivamente nos resultados de previsão do parâmetro geotécnico coesão, conforme pôde ser observado nos resultados das análises pelas duas técnicas de *machine learning* aqui estudadas. Desta forma, o primeiro conjunto de dados, com 6 parâmetros de entrada (ou variáveis) e 32 amostras, obteve performance melhor que o *dataset* do segundo conjunto de

dados, com 11 variáveis e 27 amostras.

Os resultados de previsão do parâmetro geotécnico coesão, com utilização do modelo de regressão linear, com uso da *dataset* do primeiro conjunto de dados, é mostrado na Figura 11.

Figura 11 - Resultados do parâmetro geotécnico coesão previstos por regressão linear por meio do *dataset* do primeiro conjunto de dados

```
> pr.nn_
      [,1]
AE-05-FL 16.59099
AE-33-FL 99.93508
PI-BL-02 10.82153
Cctna    48.55106
CMT01B   118.31930
PIC4A    139.25349
CMT2C    20.27413
AM01CD400 35.27694
> |
```

Fonte: Autores.

Nas análises por Redes Neurais, observou-se que uma maior quantidade de neurônios nas camadas intermediárias não influencia positivamente na obtenção dos parâmetros de saída. Em nenhum dos dois *datasets* foi verificado incremento de performance quando o número de neurônios das camadas intermediárias foi aumentado

Desta forma, verificou-se que os modelos, tanto de regressão linear, quanto de redes neurais obtiveram boa performance quando utilizado *dataset* com 6 variáveis de entrada e 32 amostras e que o número de amostras influencia positivamente na performance dos modelos, embora os modelos com número de amostras menor contivessem mais variáveis de entrada para os modelos, este fator não se mostrou relevante, em comparação à quantidade de amostras.

5. Conclusões

Como conclusão, destaca-se inicialmente a importância dos métodos, tanto empíricos quanto automatizados e a integração deles visando a melhoria dos processos de caracterização e classificação geotécnica.

A estimativa de parâmetros de resistência, como coesão e ângulo de atrito, com auxílio de classificação geomecânica, pode ser facilmente obtido para estimativa de materiais resistentes, como o que foi mostrado com o protótipo do aplicativo para parâmetros de resistência pelo método RMR89. A vantagem do protótipo de aplicativo proposto, com base na linguagem de programação Pascal, se deve à simplicidade para se inserir as informações, que são selecionadas por meio de intervalos de cada parâmetro analisado.

Para obtenção da coesão em materiais brandos como os filitos analisados, o método de aprendizagem de máquina pode ser entendido como uma alternativa quando se trata de modelos com grande volume de dados históricos. No caso do modelo apresentado, embora o banco de dados tenha um tamanho reduzido, a aplicação da técnica mostrou-se adequada.

A técnica de redes neurais artificiais para a obtenção de parâmetros geotécnicos se mostrou interessante. Para tanto é necessário que se disponha de um maior número de dados de ensaios geotécnicos. O modelo de aprendizagem de máquina por regressão linear obteve uma performance melhor, quando comparado ao modelo de redes neurais artificiais, sendo este o modelo escolhido para previsão de dados de coesão geotécnica.

Foi possível identificar por meio das análises empregando-se a técnica de *machine learning*, e algoritmo de regressão linear, os parâmetros geotécnicos, gerados por meio de ensaios de caracterização, que exercem maior influência nos resultados para predição dos parâmetros de resistência de filitos.

Com isso, o desenvolvimento de alternativas que busquem a melhoria nos processos de análises de estabilidade, por meio de estimativas mais confiáveis de parâmetros de resistência, além de promover a segurança de pessoas e equipamentos das operações de lavra, auxiliam melhor o planejamento e a economia de recursos.

Análises de *machine learning* apresentam um universo de possibilidades para ser explorado e tanto a geotecnia como a mineração podem se beneficiar profundamente com os benefícios desta tecnologia.

Para trabalhos futuros com redes neurais artificiais, para além de um maior volume de dados, considera-se interessante trabalhar com dois neurônios de saída, como coesão e ângulo de atrito, no lugar de somente coesão, a fim de melhorar as previsões e auxiliar na obtenção destas informações, tendo em vista as dificuldades de se obter estes parâmetros, que hoje são somente por meio de ensaios de laboratório. Como os bancos de dados de ensaios utilizado é reduzido, não foi possível estimar valores de ângulo de atrito, somente coesão.

Contudo, a pesquisa se mostra relevante sob o ponto de vista de inovação para obtenção de parâmetros geotécnicos de coesão, que atualmente são obtidos por meio de ensaios geotécnicos caros e demorados, por análise de falhas anteriores e analogia com outros locais semelhantes.

Agradecimentos

Agradecimento ao apoio financeiro concedido pela CAPES – Coordenação de Aperfeiçoamento de Pessoal de Nível Superior.

Referências

- Beale, G. (2018). The role of Water in Slope Design for Weak Rocks. *Guidelines for Open Pit Slope Design in Weak Rocks*. D. Martin and Peter Stacey (eds.), CSIRO Publishing, Melbourne, Australia, 80-113
- Freitas, J.P.S. (2016). *Elaboração do modelo geomecânico tridimensional para a reavaliação e setorização geotécnica dos realces da Mineração Caralba*. Dissertação de Mestrado, NUGEO, Escola de Minas, Universidade Federal de Ouro Preto.
- Hinkle, D. E., Wiersma, W. & Jurs, S. G. (2003). *Applied statistics for the behavioral sciences*. Vol. 663. Houghton Mifflin College Division.
- Kanji, M. A. (2014). Critical issues in soft rocks. *Journal of Rock Mechanics and Geotechnical Engineering* 6 (2014) 186e195
- Kundu, J., Sarkar, K., Singh, A. K., & Singh, T. N. (2020). QuickRMR beta. A Rock Mass Rating calculator based on continuous functions. <https://jkundu.com/quickrmr>.
- Mahesh, B., (2019) Machine Learning Algorithms - A Review. *International Journal os Science and Research (IJSR)*. https://www.researchgate.net/publication/344717762_Machine_Learning_Algorithms_-_A_Review.
- Manchao, H. & Xiaoming, S. (2020). State Key Laboratory of Geomechanics and Deep Underground Engineering (SKL-GDUE), China University of Mining and Technology, Beijing, China. © Springer Nature Switzerland AG 7 M. Kanji et al. (eds.), *Soft Rock Mechanics and Engineering*,
- Nola, I. T. S. (2015). *Avaliação de dados geológico-geotécnicos prévios para elaboração de Carta de Eventos Perigosos de movimentos de massa gravitacionais por meio de redes neurais artificiais e probabilidade*. Dissertação de Mestrado (Geotecnia) – Escola de Engenharia de São Carlos. Universidade de São Paulo. São Carlos.
- Oliveira Filho, A. G., & Bicalho K. (2018). Aplicação de Redes Neurais Artificiais na Estimativa de Propriedades Geotécnicas de Solos Argilosos. XIX Congresso Brasileiro de Mecânica dos Solos e Engenharia Geotécnica Geotecnia e Desenvolvimento Urbano. Salvador, BA
- Palmström A. (1995). *RMI: a rock mass characterization system for rock engineering purposes*. University of Oslo, 400 p. (PhD Thesis).
- Palmström, A. (2022). RockMass.net. Geology Applied in Rock Construction. <https://rockmass.net/estimations-with-rmi/>
- Pinheiro, R. F. S. (2013). *Classificações geomecânicas mineiras para o dimensionamento de maciços rochosos: o aplicativo MGC-RocDesign/Calc*. Mestrado em Engenharia Geotécnica e Geoambiente. ISEP - Instituto Superior de Engenharia do Porto.
- Pinheiro, A. L. (2014). *Influência das descontinuidades no comportamento geomecânico e nos modos de ruptura em taludes escavados em rochas brandas*. 2014. 192 f. Tese (Doutorado em Geotecnia) - Universidade Federal de Ouro Preto, Ouro Preto.
- Pinto, L. A. G. (2022). *Determinação de parâmetros de resistência de filitos com uso de aprendizagem de máquina*. Dissertação de Mestrado em Engenharia Mineral - Universidade Federal de Ouro Preto. Escola de Minas. Departamento de Engenharia de Minas.

- Santos, T. B., Lana, M. S., Santos, A. & Silveira, L. R.C. (2017). Aplicabilidade de classificações geomecânicas para estimativa de propriedades de resistência em maciços rochosos brasileiros. *Anais da Academia Brasileira de Ciências*, 89 (2), 859-872. <https://dx.doi.org/10.1590/0001-3765201720160065>
- Santos, A. E. M. (2021). *Classificação de maciços rochosos por meio de técnicas da estatística multivariada e inteligência artificial*. Tese Doutorado em Engenharia Mineral - Universidade Federal de Ouro Preto. Escola de Minas. Departamento de Engenharia de Minas.
- Silva, C. H. C. (2010). *Comportamento geotécnico dos filitos do talude oeste da Mina Pau Branco*. Dissertação (Mestrado) - Universidade Federal de Ouro Preto. Escola de Minas. Departamento de Engenharia de Minas.
- Silva J. M. (1997). *Contribuição à Determinação da Rugosidade da Superfície de Descontinuidades Rochosas*. Dissertação de mestrado. CPGEM. Universidade de São Paulo, EPUSP.
- Somodi G., Bar N., Vasarhey B, Kovács, L., Arrieta, M., & Török, A. (2021). Correlation between the Rock Mass Quality (Q-system) method and Geological Strength Index (GSI). Correlations in Granite, Siltstone, Sandstone and Quartzite Rock Masses. *Applied Science*.
- Souza, M. M. (2019). *Estudos geotécnicos para determinação e viabilização de cavas operacionais e finais. Estudo de caso: cava Três Buracos, Goiás*. Dissertação de Mestrado, Publicação 321/2019, Departamento de Engenharia Civil, Universidade de Brasília, Brasília, DF, 83p.
- Souza, L. R., Sousa, L. R. Cuiying, Z. & Karam, K. (2020). Chapter 8 - Evaluation of Geomechanical Properties of Soft Rock Masses by Laboratory and In Situ Testing. M. Kanji et al. (eds.), *Soft Rock Mechanics and Engineering*. Springer Nature Switzerland.
- Stephenson, R. M., & Sandy, M. P. (2021). Considerations for the designs and support of underground portals. *Underground Operators Conference*. Perth, WA, 15-17 March 2021.
- Tao, Z., Zhou, C., Sousa, L. R. & Feifei, Z. (2020). Chapter 7 - Site Investigation for Soft Rock Mass. M. Kanji et al. (eds.), *Soft Rock Mechanics and Engineering*. Springer Nature Switzerland
- Zhang, N. (2020). Chapter 9 - Interaction Between Water and Soft Rocks. M. Kanji et al. (eds.), *Soft Rock Mechanics and Engineering*. Springer Nature Switzerland