

MODELO DE REDE NEURAL ARTIFICIAL PARA PREVISÃO DO COMPORTAMENTO CISALHANTE DE DESCONTINUIDADES ROCHOSAS

Ana R. S. Leite

Silvrano A. Dantas Neto

Matheus C. Albino

ana.leite@ifce.edu.br

silvrano@ufc.br

matheus-cavalcante@hotmail.com

Departamento de Engenharia Hidráulica e Ambiental

Universidade Federal do Ceará

R. Prof. Armando Farias, 713, 60020-181, Fortaleza/CE, Brasil

Abstract. The artificial intelligence (AI) has been widely used in engineering due to its capacity to interpret and process complex information. One of these AI technologies is the artificial neural network (ANN) which is based on the functioning of the human central nervous system and its ability to learn and recognize patterns. This work aims to present an ANN model capable of predicting the shear strength of rock discontinuities. The shear strength of rock discontinuity is one of the most important factors governing the mechanical behavior of rock mass whose definition sometimes requires expensive laboratory procedures not always available. Moreover, the existing analytical models have several limitations regarding not consider all the variables which influence the shear strength of rock joints or needing shear testes. Therefore, nine ANN architectures were tested considering the following inputs: the normal boundary stiffness, the ratio between infill thickness and asperity amplitude, the initial normal stress, the joint roughness coefficient, uniaxial rock compressive strength, infill friction angle, and the horizontal displacement. As outputs the shear strength and dilation of rock discontinuities. The architecture with the best performance is the 7-20-10-2 and with 500,000 iterations with a correlation of 99% for training data and 96% in the validation data. The results show a nice fitting for the ANN model output data with experimental data. As the analytical models made so far for infilled joints are only capable of predicting the peak shear strength, the ANN comes with a handful tool for predicting shear strength with velocity and low cost.

Keywords: Artificial neural network, Shear behavior, Rock discontinuities

1 Introdução

As descontinuidades apresentam um papel fundamental na estabilidade de maciços rochosos. Pelas descontinuidades possuem uma natureza anisotrópica, variabilidade de composição e disposição, não-linearidade no comportamento, apresentando ou não preenchimento, serem encontradas sob diferentes condições de contorno, há uma dificuldade intrínseca na previsão de seu comportamento cisalhante. Tal preocupação gerou pesquisas como as de Patton [1], Barton [2], [3], [4], Barton e Choubey [5], Barton e Bandis [6], Benmokrane e Bavilliv [7], Skinas *et al.* [8], Papaliangas *et al.* [9], Haque [10], Indraratna e Haque [11], Indraratna *et al.* [12], Fasce *et al.* [13], Indraratna *et al.* [14], [15], Karakus *et al.* [16], Mehrishal *et al.* [17], Dantas Neto *et al.* [18] Shrivastava e Rao [19], etc.

Há limitações e dificuldades nos modelos analíticos criados até o momento, pois se não são bastante simplificados, levando em consideração apenas poucas variáveis para previsão do comportamento, necessitam para seu uso parâmetros que só podem ser obtidos a partir de ensaios como de cisalhamento direto, que se torna uma complicação maior principalmente ao se tratar do uso no dia-a-dia da engenharia que muitas vezes precisa de respostas rápidas para progressão dos trabalhos.

Devido às restrições citadas, modelos de Redes Neurais Artificiais (RNA), Fuzzy e Neuro-Fuzzy foram desenvolvidos com bons resultados para previsão do comportamento cisalhante de descontinuidades limpas como apresentados nos trabalhos de Dantas Neto *et al.* [18], [20] Matos *et al.* [21], [22]. Tais modelos apresentavam como resultado a previsão da tensão cisalhante e a dilatação de descontinuidades a partir de parâmetros de entrada que podem ser obtidos em uma investigação geotécnica sem necessidade de ensaios em laboratório.

Tendo em vista as dificuldades existentes nos modelos analíticos até o momento, e levando em consideração os bons resultados da aplicação da inteligência artificial (IA) para previsão do comportamento cisalhante das descontinuidades limpas, o presente trabalho trata do desenvolvimento de um modelo de RNA para previsão da tensão cisalhante e dilatação de descontinuidades preenchidas e não preenchidas sob carga normal constante (CNL) ou rigidez normal constante (CNS).

2 Resistência cisalhante das descontinuidades

As descontinuidades (juntas, falhas, fissuras, foliações, etc.) são reconhecidas como os planos com maior tendência para a ocorrência de falhas em maciços rochosos Bucher [23], Jaeger [24], Patton [1], Barton [4], [25], Bandis *et al.* [26], Maksimovic [27], Hencher e Richards [28], Singh e Basu [29]. A anisotropia característica desses planos faz com que as equações da mecânica do contínuo não possam ser aplicadas e por ser um material natural, sujeito às variabilidades das intempéries, compositivas e relacionadas às condições de contorno possíveis, torna ainda mais complexa sua previsão.

Há muito procura-se a melhor forma para se quantificar as características cisalhantes dessas por meio de formulações empíricas, correlações com dados experimentais, modelagens computacionais, entre outros. O primeiro modelo para previsão da tensão de pico (τ_p) foi o modelo de Patton [1], Eq. (1), leva em consideração a tensão normal aplicada (σ_n) e as características referentes à rugosidade que são o ângulo de atrito básico interno da rocha (ϕ_b) e o ângulo de inclinação do plano de falha relacionado à direção da força cisalhante (i). Esse modelo, apesar de relativamente simples em relação à sua aplicação, previsão somente da tensão de pico, sob CNL e para juntas limpas, foi usado como base para modelos complexos e reconhecidos na atualidade como de Indraratna *et al.* [12], [14], [30], [31], [32], Oliveira *et al.* [33], Shrivastava e Rao [19].

$$\tau_p = \sigma_n \tan(\phi_b + i). \quad (1)$$

Dentre outros, posteriormente com uma boa aceitação da comunidade científica, houveram os modelos de Barton [34] e Barton e Choubey [35] descritos na Eq. (2) e Eq. (3), respectivamente. Esses modelos são empíricos como o de Patton [1], propostos com a mesma limitação de somente prever tensão de pico, sob CNL, para descontinuidades limpas. Sua particularidade vem da inserção dos parâmetros correspondentes ao coeficiente de rugosidade da junta (JRC), que pode ser obtido pela comparação visual da rugosidade da descontinuidade com perfis propostos por Barton e Choubey [35], e a resistência efetiva à compressão da junta (JCS), que pode obtida localmente com auxílio de um

esclerômetro, mas caso a superfície não esteja úmida, pode ser substituída pela resistência à compressão uniaxial da rocha. A diferença entre ambas se deu porque, segundo os autores, os ângulos de atrito geralmente tabelados na literatura eram na realidade baseados na resistência residual.

$$\frac{\tau}{\sigma'_n} = \tan \left[JRC \cdot \log \left(\frac{JCS}{\sigma'_n} \right) + \phi_b \right]. \quad (2)$$

$$\frac{\tau}{\sigma'_n} = \tan \left[JRC \cdot \log \left(\frac{JCS}{\sigma'_n} \right) + \phi_r \right]. \quad (3)$$

Alguns modelos propostos trouxeram à tona a complexidade de lidar com a rugosidade para composição do comportamento cisalhante. Foi verificada melhor correlação da tensão de pico quando em vez de avaliada de forma usual, visual, bidimensional a rugosidade por meio do JRC, a rugosidade fosse quantificada a partir de um valor equivalente obtido após o escaneamento da superfície, considerando então sua morfologia tridimensional como proposto nos trabalhos de Grasselli [36], [37], Tian *et al.* [38] e apresentado a seguir na Fig. 1, sendo esses nas condições básicas dos modelos apresentados anteriormente.

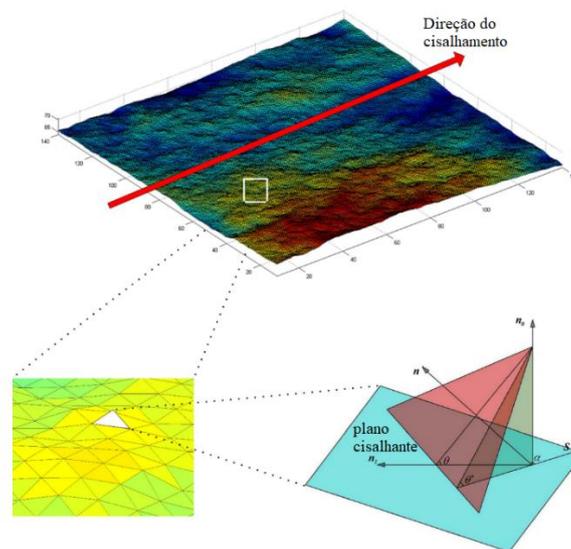


Figura 1 – Reconstrução da junta após escaneamento por elementos triangulares. Fonte: Tian *et al.* [38].

Apesar de comum os blocos sob CNL, essa muitas vezes não é a realidade dos blocos encontrados *in loco*. Para esses blocos, seja por motivo de necessidade de consideração de uso de tirantes ou mesmo pelo condição dos blocos no entorno, havia a necessidade da consideração dos mesmos sob uma determinada rigidez semelhante à de uma mola (k_n), como apresentado na Fig. 2, ou seja, sob a condição de contorno de CNS (Benmokrane e Ballivy [7], Skinas *et al.* [8], Saeb e Amadei [39]). Observa-se que a descontinuidade está submetida a uma tensão de cisalhamento (τ_h) e a uma tensão normal (σ_n) em seu plano e, ao longo do deslocamento horizontal (δ_h), ocorre também um deslocamento vertical (δ_v) por conta das asperezas. Este deslocamento será restringido pela rigidez normal constante representada, fazendo com que ocorra uma variação da tensão normal ($\Delta\sigma_n$) no plano da descontinuidade e, conseqüentemente, podendo gerar um aumento na tensão cisalhante.

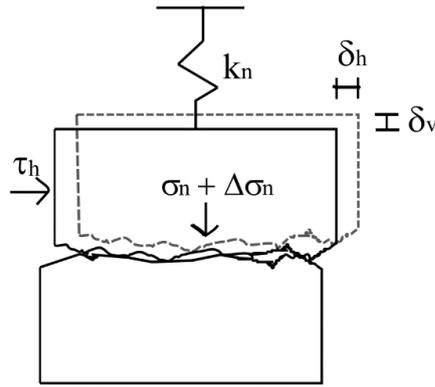


Figura 2. Descontinuidade sendo submetida ao cisalhamento direto sob CNS.

Saeb e Amadei [39] desenvolveram um modelo matemático e um modelo gráfico capazes de prever o comportamento cisalhante e dilatante acopladamente para as descontinuidades não preenchidas sob CNS, contudo tal modelo necessitava obrigatoriamente do ensaio de cisalhamento direto da amostra sob CNS. Seguidamente trabalhos como os de Indraratna *et al.* [40], Haque [10], Indraratna e Haque [11], Indraratna *et al.* [14] focaram na modelagem do mesmo comportamento. A Eq. (4) do modelo Indraratna *et al.* [40] calcula a tensão cisalhante de pico sob CNS. Onde A é a área superficial e β é a característica da área correspondente a degradação da junta, i_0 é o ângulo das asperezas inicial da descontinuidade e δ_v a dilatância que se precisaria ter para aplicação da fórmula.

$$\left(\frac{\tau_p}{\sigma_n}\right)_{CNS} = \tan \left[\Phi_b + i_0 \left(1 - \frac{\sigma_{n0} + \frac{k_n \delta_v}{A}}{\sigma_c} \right)^\beta \right]. \quad (4)$$

Haque [10] propôs para prever a dilatância de descontinuidades não preenchidas a Eq. (5), uma série de Fourier para caracterizar o comportamento cisalhantes de descontinuidades. Onde: a_0 , a_n e b_n são coeficientes da série de Fourier; n é o número de harmônicos e T o período da série. Tais incógnitas podem ser determinadas a partir da interpolação com resultado da dilatância proveniente do ensaio de cisalhamento direto seguindo as recomendações do autor.

$$\delta_v(\delta_h) = \frac{a_0}{2} + \sum_{n=1}^{\infty} \left[a_n \cos\left(\frac{2\pi n \delta_h}{T}\right) + b_n \sin\left(\frac{2\pi n \delta_h}{T}\right) \right]. \quad (5)$$

Haque [10] propôs então a Eq. (6) para a previsão da tensão cisalhante para dado deslocamento horizontal necessário tal que i_h é o ângulo da dilatância no deslocamento horizontal δ_h .

$$\tau_{(h)} = (\sigma_{n0} + \Delta\sigma_{n,h}) \tan(\sigma_{n0} + i_o) = \left(\sigma_{n0} + \frac{k_n \delta_v(\delta_h)}{A} \right) \left[\frac{\tan(\phi_b) + \tan(i_o)}{1 - \tan(\phi_b) \tan(i_h)} \right]. \quad (6)$$

Os modelos de Haque [10] e o modelo posteriormente melhorado proposto por Indraratna *et al.* [41] (acrescentado o dano das aspereza quando sob CNS), apesar de levar em consideração fatores importantes, como a variação da tensão com o deslocamento e a possível variação da tensão cisalhante da descontinuidade devido à quebra de suas rugosidades, possui como dificuldade a obtenção dos parâmetros para série de Fourier, assim como a necessidade de dados de laboratório salientado por Indraratna *et al.* [12], Indraratna *et al.* [42] e Oliveira e Indraratna [43]. Dantas Neto *et al.* [18] ressalta que outra dificuldade do modelo refere-se ao fato de que os dados laboratoriais só poderão ser fidedignos aos do campo se as condições de contorno disponíveis forem as mesmas.

Saindo da proposta analítica convencional para previsão do comportamento cisalhante e visando utilizar a IA para previsão dos resultados, os modelos neuronais e de neuro-fuzzy de Dantas Neto *et al.* [18], Matos [44]; Matos *et al.* [21], [22] apresentam-se com resultados satisfatórios para previsão da resistência cisalhante de descontinuidades limpas, requerendo como dados de entrada parâmetros que não precisam de ensaios laboratoriais para se obter. Contudo tais modelos não levam em consideração a presença de um possível preenchimento da descontinuidade, que se apresenta frequentemente na mecânica das rochas.

Tendo em vista a constante e importante presença do preenchimento nas descontinuidades, diversos

trabalhos foram feitos para a compreensão da variabilidade das características cisalhantes com a variação do tipo de preenchimento e sua espessura. Os estudos apontaram a existência de uma forte influência da razão entre a espessura do preenchimento e a amplitude da rugosidade da descontinuidade (t/a) e a diminuição não-linear da resistência ao cisalhamento (chegando a diminuir mais que 60%), de tal forma que quanto maior o t/a , menor a resistência ao cisalhamento até chegar em um ponto crítico, (t/a_{crit}), onde o aumento da espessura não mais influenciaria na tensão cisalhante uma vez que a mesma já se encontraria constante e de mesmo valor que a resistência ao cisalhamento do preenchimento unicamente. Horn e Deere [45], Goodman [46], Barton [2], Richard [47], Oliveira et al. [33], Papaliangas, et al. [9], [48], [49], Indraratna et al. [50], Shrivastava e Rao [19].

Papaliangas *et al.* [49] propôs uma fórmula empírica para o coeficiente de fricção para encontrar o cisalhamento no pico, como exposta na Eq. (7), onde μ_{max} é o coeficiente de fricção para descontinuidade limpa, μ_{min} é o mínimo para o sistema e c e m são constantes experimentais. O autor propõe o valor de c para o modelo de 1 para preenchimentos argilosos e 1,5 para granulares e o m como um variante do comportamento cisalhante da rocha com o preenchimento. A tensão cisalhante será dado pelo μ pela relação $\mu = \tau/\sigma$.

$$\mu = \mu_{min} + (\mu_{max} - \mu_{min}) \left[1 - \frac{1}{c} \left(\frac{t}{a} \right) \right]^m \quad (7)$$

Indraratna et al. [50] propuseram para a tensão de pico a Eq. (8), onde h_{tp} e i_{hp} são o deslocamento horizontal e dilatância no pico e a_0 e a_1 são coeficientes relacionados à série de Fourier.

$$\tau_p (in\ filled) = \left[\sigma_{n0} + \frac{k_n}{A} \left(\frac{a_0}{2} + a_1 \cos \frac{2\pi h_{tp}}{T} \right) \right] \left[\frac{\tan(\phi_b) + \tan(i_0)}{1 - \tan(\phi_b) \tan(i_{hp})} \right] - \sigma_{n0} \frac{t/a}{\left(\frac{t}{a} \right) + \beta} \quad (8)$$

Devido à dificuldade de se trabalhar com a Eq. (8) por necessitar de coeficientes de Fourier e ser necessário encontrar os dados do deslocamento no pico e as variáveis hiperbólicas referente ao preenchimento, Indraratna *et al.* [12] propuseram um novo modelo para calcular a tensão de pico de descontinuidades preenchidas sob CNS. Quando a espessura do preenchimento não tiver alcançado o (t/a_{crit}), a equação proposta seria a Eq. (9) apresentada abaixo, e para (t/a_{crit}) em diante, a resistência ao cisalhamento se daria somente pela resistência do preenchimento em si. Oliveira *et al.* [33] sugeriu alterações para a Eq. (9), referente à parcela da equação da resistência do preenchimento, como exposto na Eq. (10). Nesta alteração que houve maior conectividade com seus dados experimentais, em vez da parcela $\tan(\phi_b + i)$, inclui-se a parcela referente ao balanço energético.

$$\frac{\tau_p (fill) - c'_{fill}}{\sigma_n} = \tan(\phi_b + i) \times \left(1 - \frac{t/a}{t/a_{cr}} \right)^\alpha + \tan\phi_{fill} \times \left(\frac{2}{1 + \frac{t/a_{cr}}{t/a}} \right)^\beta \quad (9)$$

$$\frac{\tau_p (fill) - c'_{fill}}{\sigma_n} = \left\{ \frac{[\tan(\phi_b) + \tan(i_0)]}{[1 - \tan(\phi_b) \times \tan(i_{tp}(limpa)])} \right\} \times \left(1 - \frac{t/a}{t/a_{cr}} \right)^\alpha + \tan\phi_{fill} \times \left(\frac{2}{1 + \frac{t/a_{cr}}{t/a}} \right)^\beta \quad (10)$$

Indraratna *et al.* [30], [31], [14] fizeram modelos semelhantes, mas contando com o pré-adensamento do preenchimento. Indraratna *et al.* [32], fez modelos semelhantes também ao da Eq. (9) mas contando com o grau de saturação do preenchimento.

Shrivastava e Rao [19] propuseram uma equação para previsão da tensão de pico para descontinuidades sob CNL ou CNS, para diferentes t/a e rugosidades. O modelo do autor é a seguir apresentado na Eq. (11) onde a e b são constantes e a pode ser aproximado para o valor de 1 e b varia de 0 à 0,36 para k_n de 0 à 8 kN/mm e x e y são coeficientes dependentes da tabela apresentada em seu trabalho.

$$\tau_p = (a\sigma_n + b) \tan \left[\phi_b + x \ln \left(\frac{a\sigma_n + b}{\sigma_c} + y \right) \times i \right] \quad (11)$$

Percebe-se então que ao visar a previsão do comportamento cisalhante por uma equação analítica convencional, principalmente em descontinuidades preenchidas sob CNS, por exemplo, há uma complexidade muito grande envolvida na aplicação das formulações existentes. Tais complicações se dão principalmente devido aos modelos requererem dados experimentais de ensaios de laboratório que possuem um tempo, custo e transporte envolvido. Em contra partida os modelos de IA acima citados

Modelo de rede neural artificial para previsão do comportamento cisalhante de descontinuidades rochosas

possuíram boa correlação com dados que podem ser obtidos em campo. Têm-se então o uso de RNA uma ferramenta promissora para previsão descontinuidades preenchidas e não preenchidas sob CNL e CNS.

3 Redes neurais artificiais

Os modelos de redes neurais artificiais são importantes ferramentas dentro do sistema de aprendizado de máquinas utilizados para resolver problemas da engenharia que exista necessidade de previsão de comportamento a partir de fenômenos previamente estudados. Esta ferramenta é baseada no cérebro humano, em suas redes neurais especificamente, de tal forma à ser possível o reconhecimento de padrões a partir do princípio e aprendizado com erro. O Sistema de multicamadas utilizado nesse trabalho é descrito e formalmente apresentado por Haykin [51], cujas equações no neurônio k são apresentadas abaixo pelas Eq. (12), Eq. (13), Eq. (14), sendo representado simplificadamente na Fig. 3. O modelo é composto por uma função contínua não-linear, por uma camada inicial das variáveis de entrada, uma ou mais camadas intermediárias escondidas e uma camada de saída que representa as respostas do modelo ao comportamento requerido. O mesmo segue um loop finito, sendo nesse trabalho delimitado pelo número de interações, buscando a minimização do erro entre as variáveis de saída informadas nos dados de treinamento com os calculados na RNA fazendo variações de bias e pesos sinápticos.

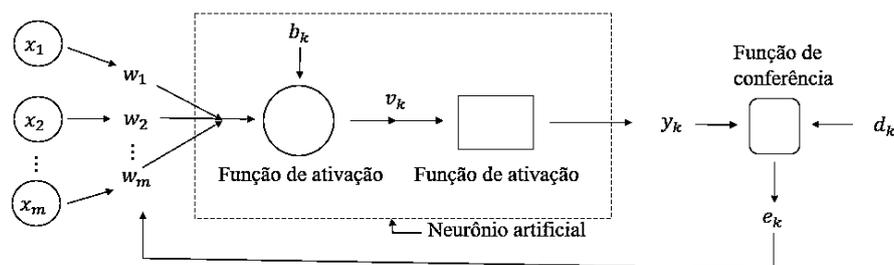


Figura 3. Representação de uma RNA com loop fechado de feedback. Fonte: Haykin [51].

$$u_k = \sum w_{km} x_m = \{w\}^T \{x\}. \quad (12)$$

$$v_k = u_k + b_k = \{w\}^T \{x\} + b_k. \quad (13)$$

$$y_k = f(v_k) = f(\{w\}^T \{x\} + b_k). \quad (14)$$

Onde: x_m = variáveis de entrada; w_m = pesos sinápticos; v_k = campo local induzido; u_k = saída do combinador linear; b_k = bias; y_k = resultado saída do neurônio; d_k = resultado esperado; e_k = erro de saída do neurônio.

O composição estrutural de uma RNA pode ser feita de diferentes maneiras denominadas arquiteturas. A classe escolhida para esse trabalho foi do perceptron de multicamadas onde a variação ocorre em número de camadas intermediárias ocultas e no número de neurônios em cada uma, mesma usada em Dantas Neto *et al.* [18], [20]. A Fig. 4 a seguir demonstra um exemplo de perceptron com duas camadas intermediárias. Arranjos diferentes da disposição dessas camadas alteram a forma da rede neural interpretar o problema.

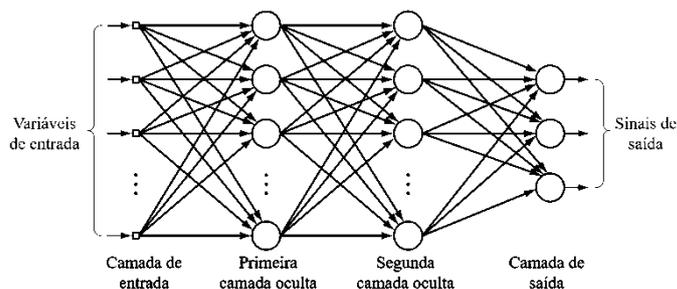


Figura 4. Exemplo de uma arquitetura de perceptron de duas camadas. Fonte: modificada de Haykin [51].

É importante salientar que a RNA tem sido usada na geotecnia e mecânica das rochas em si por diversos autores, como Jalalifar *et al.* [52], Amancio [53], Dantas Neto *et al.* [54], Sayadi *et al.* [55], Moshrefii, *et al.* [56], assim como o trabalho já realizado visando a resistência ao cisalhamento de juntas limpas de Dantas Neto *et al.* [18].

4 Desenvolvimento da RNA

A seguir é exposto como se deu a seleção das variáveis de entrada e saída, fontes utilizadas, forma de seleção de resultados e particularidades da RNA.

4.1 Dados de entrada

Inicialmente 104 ensaios de cisalhamento direto tiveram 1852 pontos selecionados de Indraratna *et al.* [11], Haque [10], Indraratna *et al.* [57], Skinas *et al.* [8], Oliveira [33], Benmokrane e Ballivy [7], Mehrishal *et al.* [17], Shrivastava e Rao [19]. Desses pontos, 60% são de juntas com preenchimento e 67% do total para ensaio sobre CNS. As juntas obtidas são juntas naturais e idealizadas.

Procurou-se definir como dados de entrada aqueles apontados na literatura como importantes para a descrição do comportamento cisalhante de descontinuidade com ou sem preenchimento, assim como dados que fossem de fácil obtenção numa investigação geotécnica local. As variáveis de entrada escolhidas portanto foram:

- x_1 = rigidez da mola (k_n), em kN/mm;
- x_2 = a razão entre espessura do preenchimento pela altura da aspereza (t/a);
- x_3 = tensão normal inicial (σ_{no}), em MPa;
- x_4 = JRC;
- x_5 = tensão de compressão da rocha (σ_c), em MPa;
- x_6 = ângulo de atrito do preenchimento (ϕ_{fill}), em graus;
- x_7 = deslocamento horizontal (δ_h), em mm.

Como variáveis de saídas estão a tensão de cisalhamento (τ), em kPa e por ser um parâmetro importante para resistência do cisalhamento junto à CNS, a dilatância (δ_v), em mm. A Eq. (15) apresenta a RNA de uma forma genérica onde g representa a arquitetura, os pesos sinápticos e bias da rede neural. A seguir, na Tabela 1, os valores máximos e mínimos dos dados da literatura utilizados no trabalho.

$$\tau, \delta_v = g(k_n, t/a, \sigma_{no}, JRC, \sigma_c, \phi_{fill}, \delta_h) \quad (15)$$

Tabela 1. Valores máximos e mínimos utilizados para treinamento e validação das RNA.

| | k_n kN/mm | t/a | σ_{no} MPa | JRC | σ_c MPa | ϕ_{fill} ° | δ_h ° | T kPa | δ_v mm |
|-----|----------------|-------|----------------------|-----|-------------------|--------------------|-----------------|----------|------------------|
| Min | 0 | 0 | 0,05 | 2 | 11,8 | 0 | 0,02 | 45 | -1,284 |
| Max | 7515 | 2 | 46,5 | 20 | 150 | 35,5 | 26 | 6680 | 4,974 |

4.2 Treinamento e validação da RNA

A rede neural foi treinada em nove arquiteturas diferentes, como as expostas a seguir, o primeiro número representa o número de variáveis de entrada, os intermediários, as camadas ocultas da rede neural e o final, os valores das variáveis de saída que são a tensão cisalhante e a dilatância. Essas arquiteturas foram: 7-30-2; 7-20-2; 7-15-2; 7-10-2; 7-30-15-2; 7-30-10-2; 7-30-15-5-2; 7-20-10-5-2. Todas as arquiteturas foram treinadas em cinco números de gerações distintas: 100.000, 200.000, 300.000, 500.000 e 1.000.000.

O treinamento e validação das redes neurais foram feitos a partir do software QNET2000. Na metodologia em questão, os dados de entrada foram normalizados pelo próprio programa com valores de 0 à 1. A técnica utilizada pelo programa para encontrar a RNA ótima é a do *backpropagation*, Schmidhuber [58], onde a cada interação é calculada a diferença entre o valor gerado pela RNA e o valor alvo do treinamento e esse erro é retropropagado pela rede variando os pesos sinápticos e bias de cada nó, sendo as atualizações utilizadas na geração seguinte buscando a contínua minimização do erro. A função de ativação escolhida para a função de todos os neurônios é sigmoide, descrita pela Eq. (16).

$$f(x) = \frac{1}{1+e^{-x}} \quad (16)$$

Sobre os dados de treinamento foram usadas uma taxa de aprendizagem mínima de 0,001 e máxima de 0,1, um começo de interação da taxa de aprendizado no valor de 1.000, e um *momentum* (α) de 0,8. Foram usados 80% dos ensaios para treinamento e 20% foram os ensaios escolhidos aleatoriamente para validação. O critério para definição da melhor RNA foi escolhido, por fim, como a de maior valor de correlação dos valores de validação.

Foram obtidas, também, as contribuições das variáveis, assim como suas variâncias, buscando compreender de que forma o programa estava interpretando a importância delas para a tensão cisalhante e para a dilatância.

5 Resultados e discussão

A seguir, são apresentados os resultados advindos da pesquisa, havendo discussão a respeito das questões inerentes ao modelo, como a RNA escolhida e os dados de saída quando comparados com os dados experimentais.

5.1 Rede escolhida

Os melhores resultados de correlação para os dados de validação foram dados para o número maior de interações, sendo esse 500.000. Foi observado que o número maior de interações aumentaria a porcentagem, contudo esse aumento traria uma tendência à não capacidade de generalização da RNA, por esse motivo limitou-se a esse valor, valor intermediário entre os trabalhos de Dantas Neto *et al.* [18] e [20]. A melhor rede foi a 7-20-10-2 com correlação de treinamento de 99% e de validação de 96%.

Da contribuição das variáveis, a Tabela 2 apresenta as contribuições para a tensão cisalhante e para a dilatância da rede escolhida. Para a tensão cisalhante, apresentam-se o k_n , σ_{no} , JRC e σ_c como variáveis de maior relevância, sendo a soma delas igual à 80%. Sobre a dilatância, observa-se uma contribuição mais equilibrada entre as variáveis, apontando-se com uma relevância acentuada de t/a e diminuição considerável de σ_{no} quando comparado seu efeito na tensão cisalhante.

Tabela 2. Contribuição percentual de cada variável para previsão do cisalhamento e da dilatação para rede 7-20-10-2 com 500.000 interações.

| | k_n | t/a | σ_{no} | JRC | σ_c | ϕ_{fill} | δ_h |
|------------|-------|-------|---------------|-----|------------|---------------|------------|
| T | 10% | 8% | 32% | 22% | 16% | 6% | 6% |
| δ_v | 14% | 17% | 13% | 23% | 7% | 9% | 16% |

5.2 Comparações de gráficos: pontos reais e gerados pela RNA

A seguir, a Fig. 5 apresenta os gráficos comparando os dados obtidos pela literatura e os dados oriundos da RNA de arquitetura 7-20-10-2 com 500.000 de interações de Indraratna *et al.* [11] e Haque [10]. Na mesma figura, têm-se os gráficos de exemplos em CNL de juntas não preenchidas mudando-se os valores da tensão normal inicial e o JRC. Para a Fig. 5-a, pode-se observar a boa compreensão do modelo neuronal para a variação da tensão normal inicial e para o JRC, em sua forma não-linear, em que o modelo compreende que quanto maior a tensão normal, maior a cisalhante, como esperado pela literatura e mesma coisa para JRC. Na Fig. 5-b, referente à comparação entre a dilatação experimental com os resultados de saída RNA, nota-se uma boa compreensão do comportamento.

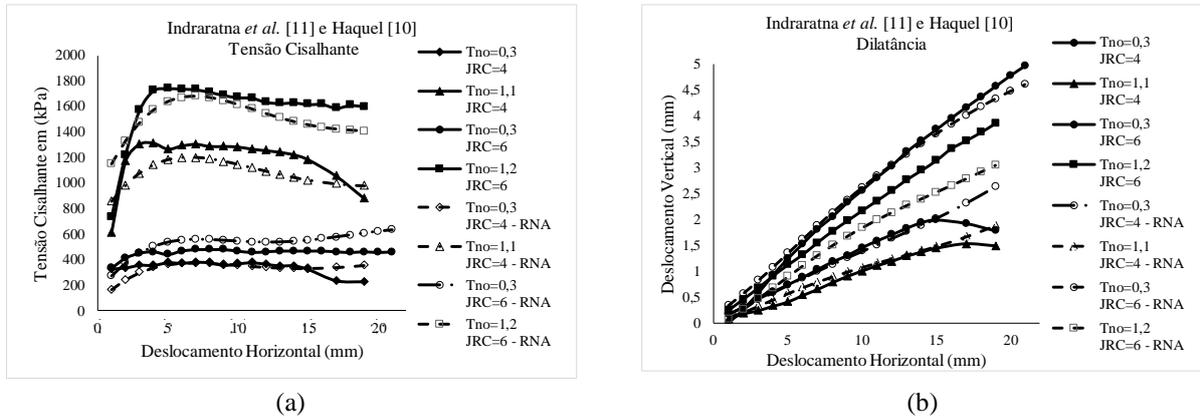


Figura 5. Comparação dos resultados do ensaio de cisalhamento direto obtido pela literatura a valores obtidos pela RNA 7-20-10-2. (a) Tensão cisalhante Indraratna *et al.* [11] e Haque [10] (b) Dilatância Indraratna *et al.* [11] e Haque [10].

A Fig. 6 apresenta os gráficos comparando os dados obtidos em Oliveira *et al.* [33] e os obtidos pelo modelo RNA de arquitetura 7-20-10-2 com 500.000 interações. Nas figuras (a) e (b) têm-se os gráficos dos ensaios em CNS de juntas preenchidas variando os valores de t/a . Para a Fig. 6-a, verifica-se que, além da semelhança com os dados experimentais, ocorre a compreensão da influência do aumento do t/a tanto para Fig 6-a, levando à diminuição da tensão cisalhante, como para a Fig. 6-b, com a dilatação indo de positiva com $t/a=0$ à negativa com $t/a=2$, representando a compressão do preenchimento.

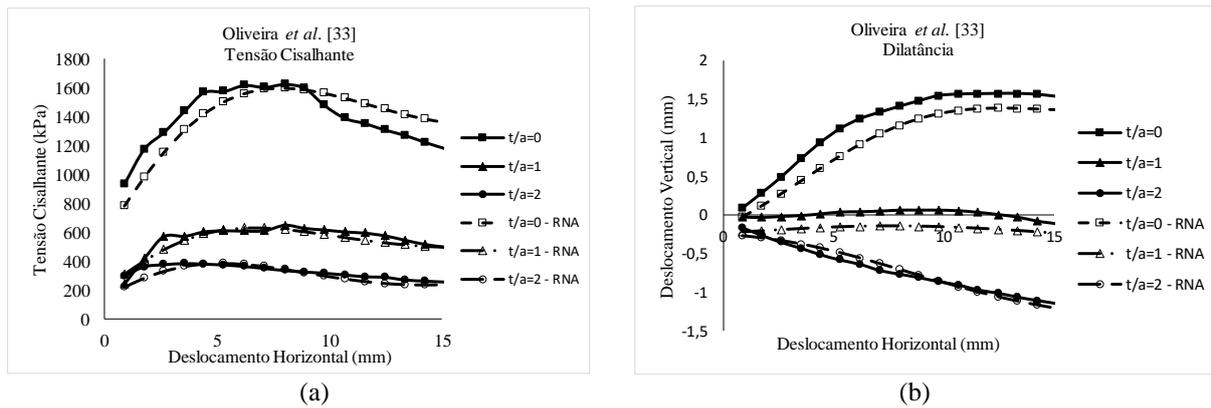


Figura 6. Comparação dos resultados do ensaio de cisalhamento direto obtido pela literatura a valores obtidos pela RNA 7-20-10-2. (a) Tensão cisalhante Oliveira *et al.* [33] (b) Dilatância Oliveira *et al.* [33].

A Fig. 7, por sua vez, apresenta os gráficos comparando os dados obtidos em Shrivastava e Rao [19] e os obtidos pelo modelo RNA de arquitetura 7-20-10-2 com 500.000 interações. Nas figuras (a) e (b) têm-se os gráficos dos ensaios em CNL de juntas preenchidas variando os valores de t/a . Para Fig. 7-a, diferentemente dos resultados obtidos nas anteriores, não há uma equivalência tão grande entre os dados experimentais e os dados do modelo RNA em termos do comportamento geral da tensão cisalhante com o deslocamento horizontal, mas há uma aproximação em termos de tensão de pico. Na Fig. 7-b há uma diferença considerável entre o comportamento de saída previsto pelo modelo RNA e os dados experimentais relevando uma compreensão não tão considerável do modelo neuronal ao problema.

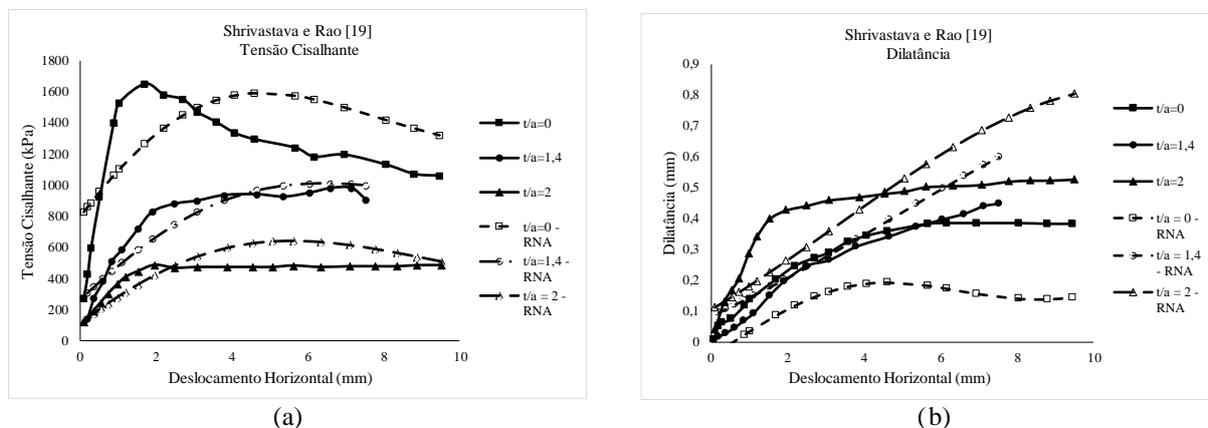


Figura 7. Comparação dos resultados do ensaio de cisalhamento direto obtido pela literatura a valores obtidos pela RNA 7-20-10-2. (a) Tensão cisalhante Shrivastava e Rao [19] (b) Dilatância Shrivastava e Rao [19].

6 CONCLUSÕES

Este trabalho trata de um modelo de RNA para a previsão do comportamento das discontinuidades dos maciços rochosos com e sem preenchimento relacionado à sua tensão cisalhante e dilatância, dado seu deslocamento horizontal. As variáveis de entrada, escolhidas tanto pela relevância que a literatura traz sobre elas em relação ao fenômeno, quanto pela facilidade de obtê-las em campo foram a rigidez da mola (kn), em kN/mm; a razão entre espessura do preenchimento pela altura da aspereza (t/a); tensão normal inicial (σ_{no}), em MPa; índice de rugosidade da rocha JRC; tensão de compressão da rocha (σ_c), em MPa; ângulo de atrito do preenchimento (ϕ_{fil}), em graus e o deslocamento horizontal (δh) em mm.

Dentro das nove arquiteturas de RNA testadas em cinco diferentes número de interações, encontrou-se a rede 7-20-10-2 com 500.000 interações como a melhor por ter maior correlação entre os dados de validação e os de saída da RNA, sendo esse valor de 96%, enquanto para os elementos utilizados para treinamento, obteve-se correlação de 99%. Fazendo um levantamento sobre a contribuição das variáveis, para a tensão cisalhante as mais relevantes foram, na sequência, σ_{no} , JRC, σ_c , apresentando a soma da contribuição delas igual à 70%. Para a dilatância, os dados de entrada tiveram contribuição semelhantes.

Comparando os dados experimentais com os de saída da RNA, no geral, observa-se uma boa compreensão do fenômeno por parte do modelo uma vez que a variação não-linear dos resultados esperada pela literatura em termos de tensão normal aplicada, variação de JRC, variação de t/a , sob CNL e CNS, foi bem representada. O modelo neuronal proposto não tem o intuito de substituir os ensaios de cisalhamento direto para previsão do comportamento cisalhante de descontinuidades com e sem preenchimento, mas para dar uma resposta aproximada aceitável em casos que um ensaio não seja disponível, mas a informação necessária.

Agradecimentos

Os autores agradecem a FUNCAP(Fundação Cearense de Apoio ao Desenvolvimento Científico e Tecnológico) e CAPES/Proex pelo suporte financeiro para Pós-Graduação em Engenharia Civil da Universidade Federal do Ceará.

References

- [1] Patton, F. D. Multiple modes of shear failure in rock. Proc. 1st Congr. Int. Soc. Rock Mech., Lisbon, pp. 509-513, 1966.
- [2] N. R. Barton, A review of the shear strength of filled discontinuities in rock. Norwegian Geotechnical Institute Publication, n. 105, p. 1-38, 1973.
- [3] N. R. Barton. The shear strength of rock and rock joints. *Int. J. Rock Mech. Min. Sci.*, vol. 13, no. 9, pp. 255-279, 1976.
- [4] N. R. Barton, Non-linear shear strength for rock, rock joints, rockfill and interfaces. *Innov. Infrastruct. Solut.*, vol. 1, no. 1, p. 30, 2016.
- [5] N. R. Barton and V. Choubey, The shear strength of rock joints in theory and practice. *Rock Mech. Felsmechanik Mécanique des Roches*, vol. 10, no. 1-2, pp. 1-54, 1977.
- [6] N. R. Barton and S. Bandis. Effect of block size on the shear behavior of jointed rock. *23rd U.S Symp. Rock Mech.*, no. January, pp. 739-760, 1982.
- [7] B. Benmokrane and G. Ballivy. Laboratory study of shear behaviour of rock joints under constant normal stiffness conditions. *Rock Mechanics as a Guide for Efficient Utilization of Natural Resources*, Khair (ed.), Balkema, Rotterdam, pp. 899- 906, 1989.
- [8] C. A. Skinas, S. C. Bandis, C. A. Demiris, Experimental investigations and modelling of rock joint behaviour under constant stiffness. In: Barton, Stephanson (eds) *Rock joints*. Balkema Publisher, Rotterdam, p. 301-307, 1990.
- [9] T. Papaliangas, S. R. Hencher, A. C. Lumsden, and S. Manolopoulou. The effect of frictional fill thickness on the shear strength of rock discontinuities. *Int. J. Rock Mech. Min. Sci.*, vol. 30, no. 2, pp. '81-91, 1993.
- [10] A. Haque. Shear behaviour of soft rock joints under constant normal stiffness. *G{é}otechnique*, vol. 49, no. 3, p. 296, 1999.
- [11] B. Indraratna, and A. Haque, A Experimental and numerical modeling of shear behaviour of rock joints, *GeoEng 2000*, vol. 2000.
- [12] B. Indraratna, H. S. Welideniya, and E. T. Brown, A shear strength model for idealised infilled joints under constant normal stiffness, *Géotechnique*, vol. 55, no. 3, pp. 215-226, 2005.
- [13] B. I. Fasce, A. Mirzaghorbanali, D. a F. Oliveira, and W. Premadasa, Shear Behaviour of Rock Joints Under Cyclic Loading, no. 2003, pp. 1256-1261, 2012.

- [14] B. Indraratna, W. Premadasa, E. T. Brown, A. Gens, and A. Heitor. Shear strength of rock joints influenced by compacted infill. *Int. J. Rock Mech. Min. Sci.*, vol. 70, pp. 296–307, 2014.
- [15] B. Indraratna, C. Kumara, S.-P. Zhu, and S. Sloan, Mathematical Modeling and Experimental Verification of Fluid Flow through Deformable Rough Rock Joints, *Int. J. Geomech.*, vol. 15, no. 4, p. 04014065, 2015.
- [16] M. Karakus, Y. Liu, G. Zhang, and H. Tang, “A new shear strength model incorporating influence of infill materials for rock joints,” *Geomech. Geophys. Geo-Energy Geo-Resources*, vol. 2, no. 3, pp. 183–193, 2016.
- [17] S. Mehrishal, M. Sharifzadeh, K. Shahriar, and J. J. Song, “An Experimental Study on Normal Stress and Shear Rate Dependency of Basic Friction Coefficient in Dry and Wet Limestone Joints,” *Rock Mech. Rock Eng.*, vol. 49, no. 12, pp. 4607–4629, 2016.
- [18] S. A. Dantas Neto, B. Indraratna, D. A. F. Oliveira, a. P. Assis. Modelling the shear behaviour of clean rock discontinuities using artificial neural networks. *Rock Mech Rock Eng*, v. 50, p. 1817-1831, 2017.
- [19] A. K. Shrivastava and K. S. Rao, Physical Modeling of Shear Behavior of Infilled Rock Joints Under CNL and CNS Boundary Conditions. *Rock Mech. Rock Eng.*, vol. 51, no. 1, pp. 101–118, 2018.
- [20] S. A. Dantas Neto, B. Indraratna, D. A. F. Oliveira. Prediction of the Shear Behaviour of Clean Joints in Soft Rocks using Perceptron. In: Proc 7rd Congress of ISRM, Belo Horizonte, Brazil pp. 1817–1831, 2017.
- [21] Y. M. P. de Matos, S. A. Dantas Neto, and G. de A. Barreto, A Takagi-Sugeno fuzzy model for predicting the clean rock joints shear strength, *REM - Int. Eng. J.*, vol. 72, no. 2, pp. 193–198, 2019.
- [22] Y. M. P. de Matos, S. A. Dantas Neto, and G. de A. Barreto. Predicting the Shear Strength of Unfilled Rock Joints with the First-Order Takagi-Sugeno Fuzzy Approach. *Soils and Rocks*, vol. 42, no. 1, pp. 21–29, 2019.
- [23] W. H. Bucher. The Mechanical Interpretation Of Joints. *J. Geol.*, vol. XXIX, no. 1, 1921.
- [24] J. C. Jaeger. The frictional properties of joints in rock. *Geojis. pura appl.* 43, 148-158, 1959.
- [25] N. R. Barton. A relationship between joint roughness and joint shear strength. *Proc. Int. Symp. Rock Mech.*, vol. Nancy, no. March, p. Pap. I-8, 1971.
- [26] S. C. Bandis, A. C. Lumsden, and N. R. Barton, Fundamentals of rock joint deformation, *Int. J. Rock Mech. Min. Sci.*, vol. 20, no. 6, pp. 249–268, 1983.
- [27] M. Maksimovic, The Shear Strength Rock Joint Components of a Rough. *Int. J. Rock Mech. Min. Sci. Geomech. Abstr.*, vol. 33, no. 8, pp. 769–783, 1996.
- [28] S. R. Hencher and L. R. Richards, Assessing the Shear Strength of Rock Discontinuities at Laboratory and Field Scales, *Rock Mech. Rock Eng.*, vol. 48, no. 3, pp. 883–905, 2015.
- [29] H. K. Singh and A. Basu. Evaluation of existing criteria in estimating shear strength of natural rock discontinuities Evaluation of existing criteria in estimating shear strength of natural rock discontinuities. *Eng. Geol.*, vol. 232, no. July 2018, pp. 171–181, 2017.
- [30] B. Indraratna, M. Jayanathan, and E. T. Brown. Shear strength model for overconsolidated clay-infilled idealised rock joints. *Géotechnique*, vol. 58, no. 1, pp. 55–65, 2008.
- [31] B. Indraratna, D. A. F. Oliveira, and M. Jayanathan. Revised Shear Strength Model for Infilled Rock Joints Considering Overconsolidation Effect. *Proc. 1st South. Hemisph. Int. Rock Mech. Symp. SHIRMS 2008, Perth, 16-19 Sept. 2008*, no. September, pp. 16–19, 2008.
- [32] B. Indraratna, W. Premadasa, and E. T. Brown. Shear behaviour of rock joints with unsaturated infill. *Géotechnique*, vol. 3, no. 15, pp. 1356–1360, 2013.
- [33] D. A. F. Oliveira, B. Indraratna, and J. Nemicik. Critical review on shear strength models for soil-infilled joints. *Geomech. Geoengin.*, vol. 4, no. 3, pp. 237–244, 2009.
- [34] N. R. Barton, Review of a new shear-strength criterion for rock joints. *Eng. Geol.*, vol. 7, no. 4, pp. 287–332, 1973.
- [35] N. R. Barton and V. Choubey, The shear strength of rock joints in theory and practice, *Rock Mech*, vol. 10, pp. 1-54, 1977.
- [36] G. Grasselli, Shear Strength Of Rock Joints Based On Quantified Surface Description, Thesis, Univeristá di Parma, 2001.
- [37] G. Grasselli. Shear strength of Rock Joints Based on Quantified Surface Description. *Rock Mech. Rock Eng.*, vol. 39, no. 4, pp. 295–314, 2006.
- [38] Y. Tian, Q. Liu, D. Liu, Y. Kang, P. Deng, and F. He. Updates to Grasselli ’ s Peak Shear Strength

- Model Updates to Grasselli 's Peak Shear Strength Model. *Rock Mech. Rock Eng.*, vol. 51, no. 7, pp. 2115–2133, 2019.
- [39] S. Saeb and B. Amadei. Modelling rock joints under shear and normal loading. *Int. J. Rock Mech. Min. Sci.*, vol. 29, no. 3, pp. 267–278, 1992.
- [40] B. Indraratna, A. Haque, and N. Aziz. Laboratory modelling of shear behaviour of soft joints under constant normal stiffness conditions. *Geotechnical and Geological Engineering*, , 16 17–44, 1998.
- [41] B. Indraratna, S. Thirukumar, E. T. Brown, and S. P. Zhu, Modelling the Shear Behaviour of Rock Joints with Asperity Damage Under Constant Normal Stiffness, *Rock Mech. Rock Eng.*, vol. 48, no. 1, pp. 179–195, 2014.
- [42] B. Indraratna, D. A. F. Oliveira, and E. T. Brown, International Journal of Rock Mechanics & Mining Sciences Effect of soil – infilled joints on the stability of rock wedges formed in a tunnel roof, vol. 47, pp. 739–751, 2010.
- [43] D. A. F. Oliveira and B. Indraratna, Comparison between Models of Rock Discontinuity. *J. Geotech. Geoenviron. Eng.*, 136:864-874, 2010.
- [44] Y. M. P. de Matos, Desenvolvimento de modelos de previsão do comportamento cisalhante em descontinuidades sem preenchimento de maciços rochosos utilizando técnicas fuzzy e neuro-fuzzy, Dissertação, Universidade Federal do Ceará, 2018.
- [45] H. M. Horn and D. U. Deere. Frictional Characteristics of Minerals. *Géotechnique*, vol. 12, no. 4, pp. 319–335, 1962.
- [46] R. E. Goodman, The Deformability of Joints. In: Determination of the In-Situ Modulus of Deformation of Rock. ASTM, STP 477: 174–196, 1969.
- [47] L. R. Richard, The Shear Strength of Joints in weathered rock, Thesis, University of London, 1975.
- [48] T. Papaliangas, S. Hencher, and A. C. Lumsden. Discussion of ' Laboratory testing and parameters controlling the shear strength of filled rock joints. *Géotechnique*, vol. 45, no. 1, pp. 175–183, 1995.
- [49] T. Papaliangas, A.C. Lumsden, S.R. Hencher and S. Manolopoulou. Shear strength of modelled filled rock joints. In: N.R. Barton and O. Stephansson, eds. *Rock joints: proceedings of the international conference on rock joints*, Loen. Rotterdam: Balkema, 275-282, 1990.
- [50] B. Indraratna, A. Haque, N. Aziz. Shear behaviour of idealized infilled joints under constant normal stiffness. *Géotechnique*, 49 (3), 331-355, 1990.
- [51] S. Haykin, *Neural Networks and learning machines*. 3rd ed. Pearson, 2008.
- [52] H. Jalalifar, S. Mojedifar, A. A. Sahebi, and H. Nezamabadi-pour. Application of the adaptive neuro-fuzzy inference system for prediction of a rock engineering classification system. *Comput. Geotech.*, vol. 38, no. 6, pp. 783–790, 2011.
- [53] Amancio, L. B. Previsão de recalques em fundações profundas utilizando redes neurais artificiais do tipo Perceptron. Dissertação Universidade Federal Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2013.
- [54] S. A. Dantas Neto, L. B. Amâncio, and G. Jacques. Pile Settlement Modeling with Multilayer Perceptrons. *EJGE*, pp. 4517–4528, 2014.
- [55] A. Sayadi, M. Monjezi, N. Talebi, and M. Khandelwal. A comparative study on the application of various artificial neural networks to simultaneous prediction of rock fragmentation and backbreak. *J. Rock Mech. Geotech. Eng.*, vol. 5, no. 4, pp. 318–324, 2013.
- [56] S. Moshrefii, A. Ramezanzadeh, and K. Goshtasbi, “Prediction of ultimate strength of shale using artificial neural network,” *Journal of Mining & Environment*, Vol.9, No.1, 91-105, 2018.
- [57] B. Indraratna, D. A. F. Oliveira, and e. T. Brown, “A shear-displacement criterion for soil-infilled rock discontinuities,” *Géotechnique*, vol. 60, no. 8, pp. 623–633, 2010.
- [58] J. Schmidhuber, “Deep learning in neural networks : An overview,” *Neural Networks*, vol. 61, pp. 85–117, 2015.