



ISSN: 2447-3359

REVISTA DE GEOCIÊNCIAS DO NORDESTE

Northeast Geosciences Journal

v. 10, n° 2 (2024)

<https://doi.org/10.21680/2447-3359.2024v10n2ID35178>



Uma abordagem alternativa à previsão do comportamento cisalhante de descontinuidades rochosas utilizando redes neurais de funções de base radial

An Alternative Approach for Estimating the Shear Behavior of Rock Discontinuities by Using Radial Basis Function Neural Networks

Wana Maria de Souza¹; Silvrano Adonias Dantas Neto²; Guilherme de Alencar Barreto³

¹ Universidade Federal do Ceará, Campus Pici, Departamento de Engenharia Hidráulica e Ambiental, Fortaleza/CE, Brasil. E-mail: wanasouza@alu.ufc.br

ORCID: <https://orcid.org/0000-0002-1269-6661>

² Universidade Federal do Ceará, Campus Pici, Departamento de Engenharia Hidráulica e Ambiental, Fortaleza/CE, Brasil. E-mail: silvrano@ufc.br

ORCID: <https://orcid.org/0000-0002-9951-4938>

³ Universidade Federal do Ceará, Campus Pici, Departamento de Engenharia de Teleinformática, Fortaleza/CE, Brasil. E-mail: gbarreto@ufc.br

ORCID: <https://orcid.org/0000-0002-7002-1216>

Resumo: Este artigo tem como objetivo apresentar modelos de predição da tensão cisalhante e dilatação em descontinuidades rochosas por meio de redes neurais artificiais que empregam funções de base radial. Para tanto, foi utilizado um banco de dados obtido de 116 ensaios de cisalhamento direto em grande escala realizados em diferentes tipos de descontinuidades e condições de contorno. As variáveis de entrada dos modelos propostos são a rigidez normal externa, a tensão normal inicial, a rugosidade da descontinuidade, a resistência uniaxial da rocha intacta, a espessura do preenchimento, o ângulo de atrito do material de preenchimento, quando houver, o ângulo de atrito básico e o deslocamento cisalhante imposto na descontinuidade. Os resultados mostraram que as redes RBF são capazes de estimar de forma satisfatória o comportamento cisalhante das descontinuidades rochosas uma vez que foram obtidos coeficientes de determinação superiores a 0,98 nas fases de treinamento e teste. Além disto, nas análises de desempenho dos modelos observou-se que eles são capazes de representar de forma coerente a influência das variáveis de entrada no comportamento cisalhante das descontinuidades rochosas. Logo, pode-se concluir que os modelos obtidos se apresentam como ferramentas úteis e simples para a previsão do comportamento cisalhante de descontinuidades rochosas.

Palavras-chave: Redes Neurais Artificiais; Funções de Base Radial; Descontinuidades Rochosas.

Abstract: This paper aims to present predicting models for the shear stress and dilation in rock discontinuities by using artificial neural networks with radial basis functions. These models were developed based on a database obtained from 116 large-scale direct shear tests carried out on different types of discontinuities and boundary conditions. The input variables of the proposed models are the external normal stiffness, the initial normal stress, the roughness of the discontinuity, the uniaxial compressive strength of the intact rock, the thickness and the friction angle of existing infill material, the basic friction angle and the shear displacement imposed on the rock discontinuity. The results have shown that the RBF networks are capable of satisfactorily estimating the shear behavior of rock discontinuities, once coefficients of determination greater than 0.98 were obtained in the training and testing phases. In addition, the performance analyses of the models have shown that they are capable of representing the influence of the input variables on the shear behavior of rock discontinuities. It can therefore be concluded that the models obtained are useful and simple tools for predicting the shear behavior of rock discontinuities.

Keywords: Neural Network Artificial; Radial Basis Function; Rock Discontinuities.

Recebido: 25/01/2024; Aceito: 17/06/2024; Publicado: 22/07/2024.

1. Introdução

Ao longo das últimas décadas tem havido um grande esforço no desenvolvimento de modelos de previsão do comportamento mecânico dos maciços rochosos que levem em consideração de forma realista a influência dos principais parâmetros que governam o mecanismo de cisalhamento nestas estruturas rochosas. Neste sentido, diversos modelos analíticos foram propostos com base em ensaios de cisalhamento direto em grande escala realizados em diferentes tipos de descontinuidades e condições de contorno, podendo-se citar as propostas de Barton (1973, 1976), Ladanyi e Archambault (1969), Barton e Choubey (1977), Skinas, Bandis e Demiris (1990), Indraratna e Haque (2000), Indraratna, Oliveira e Brown (2010), dentre outros. Os resultados obtidos nestes estudos indicaram que o comportamento cisalhante das descontinuidades rochosas é governado pelos seguintes fatores: material de preenchimento, rugosidade, condições de contorno impostas, bem como das características da rocha intacta.

Apesar de representarem de forma satisfatória o comportamento cisalhante das descontinuidades rochosas para as condições em que foram desenvolvidos, os diversos modelos analíticos existentes apresentam inúmeras limitações, dadas as dificuldades de obtenção dos parâmetros necessários à sua aplicação (DANTAS NETO et al., 2017; LEITE et al., 2019a; MATOS, 2018). Desta forma, observa-se a necessidade de se empregar métodos alternativos que permitam a previsão do comportamento cisalhante das descontinuidades rochosas de forma prática e simples, mas que levem em consideração todas as suas variáveis governantes. Neste sentido, pode-se citar as redes neurais artificiais (RNA), que têm apresentado bom desempenho na resolução de problemas complexos, multivariados e não-lineares, com utilização cada vez mais frequente na Engenharia Geotécnica. Na Mecânica das Rochas, inúmeros trabalhos demonstram a capacidade destas ferramentas na previsão de parâmetros (MAJDI; REZAEI, 2013; SAYADI et al., 2013; ZHOU et al., 2020).

No que tange ao comportamento cisalhante de descontinuidades rochosas podem ser citados os trabalhos de Dantas Neto et al. (2017), Leite et al. (2019a) e Leite et al. (2019b) que utilizaram no desenvolvimento dos modelos de previsão os perceptrons multicamadas (MLP). Os resultados obtidos por tais autores mostraram que os modelos neurais têm fornecido resultados mais próximos aos dados experimentais do que as estimativas feitas pelos modelos analíticos. Entretanto, como os MLP apresentam arquiteturas complexas e são projetados para realizar uma aproximação global do mapeamento entrada-saída, com todos os parâmetros sendo computados ao mesmo tempo, exige-se um esforço computacional elevado resultando em um processo de aprendizado mais lento se comparado ao obtido com outros tipos de RNA (SOARES; TEIVE, 2015; FERREIRA, 2020).

Neste contexto, as redes do tipo função de base radial (RBF) apresentam-se como uma alternativa às ferramentas aplicadas para estimar o comportamento cisalhante das descontinuidades rochosas dada a sua capacidade de lidar adequadamente com problemas não lineares com uma única camada oculta, possibilitando o processo de treinamento (ajustes dos parâmetros da rede), cujo esforço computacional é significativamente menor quando comparado a outros tipos de redes neurais artificiais, principalmente os MLP, conforme destacado por Gan, Peng e Chen (2012), Ferreira (2020) e Souza, Batista e Silva (2021).

Em relação ao esforço computacional menos intensivo apresentado pela RBF, tem-se que para um dado vetor de entrada, tipicamente, apenas alguns neurônios ocultos apresentarão ativações significantes, o que torna seu treinamento mais rápido, diferentemente da Perceptron Multicamadas (MLP), que apresenta um padrão de conectividade mais complexo, uma vez que é baseada em múltiplas camadas de neurônios. Além disso, o processo de estimação dos parâmetros (pesos e limiares) é sequencial, necessitando de várias passadas por todas as amostras do conjunto de treinamento. Isto por sua vez, exige um elevado esforço computacional decorrente da necessidade de retropropagação do erro, resultando em uma curva de aprendizado de convergência lenta quando comparada à rede RBF (VIEIRA; LEMOS; LING, 2003; BISHOP, 1997; HA YKIN, 2009). Esta rede divide seu treinamento em duas fases bem distintas e de rápida execução, não utilizando o treinamento por várias épocas quando comparada à rede MLP. Ademais, a rede RBF tem apenas dois hiperparâmetros, isto é, o número de neurônios ocultos e a largura comum das funções de base gaussiana. Já a rede MLP requer a especificação de vários hiperparâmetros, tais como número de camadas ocultas, número de neurônios em cada camada oculta, a taxa de aprendizagem, o fator de momento e o número de épocas de treinamento. Em relação à sua aplicação, diversos autores destacaram o potencial das redes RBF na predição de parâmetros geotécnicos (QIN et al., 2018; MENDES, 2021; SAYADI et al., 2013).

Assim sendo, este artigo tem por objetivo apresentar modelos desenvolvidos com redes neurais do tipo função de base radial para a previsão do comportamento cisalhante das descontinuidades rochosas em função das suas variáveis governantes, quais sejam, o deslocamento cisalhante, as condições de contorno representadas pela tensão normal inicial e rigidez normal de contorno e as características das descontinuidades, como rugosidade, ângulo de atrito básico, resistência à compressão uniaxial da rocha intacta, razão t/a para o preenchimento, e ângulo de atrito interno do material

de preenchimento, quando for o caso. Neste caso, o uso das redes RBF visa aproveitar a sua capacidade de modelagem de fenômenos complexos e não lineares de forma mais simples, com menor tempo computacional e melhor desempenho que aqueles obtidos com outros tipos de RNA.

2. Redes Neurais de Funções de Base Radial (RBF)

Uma RNA é formada por um conjunto de neurônios artificiais distribuídos em múltiplas camadas ligadas entre si por conexões sinápticas cuja função é transmitir os sinais da camada de entrada até a camada de saída, sendo as respostas dos neurônios artificiais dadas por funções de ativações, podendo-se citar as funções linear, sigmoideal, tangente hiperbólica, dentre outras (HAYKIN, 2009). Considerando as principais vantagens das RNA, destaca-se a capacidade de aproximação universal de funções que é usada para estabelecer relações entrada-saída por meio de um processo de aprendizado baseado em dados. Uma vez sendo submetida a um processo de treinamento adequado, a rede apresenta uma capacidade de generalizar o conhecimento sobre o fenômeno modelado permitindo a realização de previsões para padrões de entrada diferentes daqueles utilizados durante o ajuste dos parâmetros da rede (GETAHUN; SHITOTE; ABIERO GARIY, 2018).

Existem diferentes tipos de RNA, cada uma com arquiteturas e algoritmos de aprendizagem próprios (TURCATO, 2015). Dentre elas, pode-se citar o perceptron simples que se caracteriza como a arquitetura mais simples de uma RNA e seu processamento ocorre em uma única camada, cujos neurônios são ativados por funções não-lineares (HAYKIN, 2009). Pode-se mencionar também, os perceptrons multicamadas (MLP) que podem ser considerados uma extensão do perceptron simples, com capacidade de interpolar problemas não-lineares e mais complexos, devido à presença de uma ou mais camadas de neurônios ocultos. Em geral, as redes MLP são as mais utilizadas na Geotecnia, como destacado por Erzin, Rao e Singh (2008), provavelmente devido à sua capacidade de permitir a modelagem de fenômenos multivariados não-lineares e complexos em função da utilização de um maior número de camadas e neurônios ocultos não-lineares.

As redes neurais que utilizam funções de base radial (RBF) também apresentam uma estrutura na qual as informações são propagadas da camada de entrada para a camada de saída, porém, sem laços de realimentação (SOUZA; BATISTA; SILVA, 2021). De forma distinta dos demais tipos de redes neurais, uma RBF utiliza funções de base radial como função de ativação dos neurônios da camada oculta que se caracterizam como funções não-lineares (KAWASE, 2015). Entretanto, a ligação entre os neurônios da camada oculta e da camada de saída é feita por meio de neurônios lineares fazendo com que tais redes apresentem uma estrutura e um processo de aprendizagem mais simples que aquele empregados nos MLP. Dentre os diversos tipos de funções de base radial estão as funções lineares, cúbicas, gaussianas, e multiquadrática, multiquadrática inversa (MENDES, 2021).

De modo geral, uma rede RBF pode ser empregada em praticamente todo tipo de problema tratado por um MLP (CHAOWANAWATEE; HEEDNACRAM, 2012). Por ter uma estrutura topológica simples, treinamento rápido, boa generalização e uma saída ativada por uma função linear, a rede RBF torna-se uma alternativa competitiva às redes MLP na modelagem de problemas em engenharia (NASERI; TATAR; SHOKROLLAHI, 2016).

De acordo com Haykin (2009), a estrutura básica de uma rede RBF contempla três camadas: a primeira camada se refere à entrada da RNA, constituída pelos nós nos quais são alimentadas as informações oriundas das variáveis de entrada e que serão propagadas até a camada oculta; a segunda camada da rede é camada oculta, na qual é feita uma transformação não-linear do espaço de entrada por meio de funções de bases radiais para a ativação dos seus neurônios constituintes; e a camada de saída que retorna a resposta da RNA, por meio de uma transformação linear do espaço de alta dimensão da camada oculta para o espaço de (usualmente) baixa dimensão dada em função do problema modelado.

Na Figura 1 é mostrada a representação esquemática da estrutura de uma rede RBF na qual x corresponde ao vetor de entrada de dimensão n ; φ_i se refere à i -ésima função de ativação de base radial cujo valor aumenta com a diminuição da distância do vetor de entrada x em relação a um ponto central denominado de centro (μ_i) que define a posição da função de base radial no espaço de entrada.

Cada neurônio oculto é centrado em uma coordenada particular do espaço multidimensional de entrada. Desse modo, cada uma destas coordenadas caracteriza-se por definir o centro de uma região de maior aglomeração de pontos, ou *cluster*, do espaço de dados de entrada. Assim, os centros das funções de base radial são determinados como parte do processo de aprendizagem e sua quantidade bem como posição devem contemplar um conjunto representativo da amostra de dados (NEVES; CARVALHO, 2010). O parâmetro ω_i corresponde ao peso sináptico que conectam o i -ésimo neurônio oculto (ou equivalentemente, a i -ésima função de base) à saída y por meio da transformação linear mencionada anteriormente, representado a resposta da rede ao vetor de entrada x .

Conforme Soares e Teive (2015) e Souza, Batista e Silva (2021), a função de base radial comumente utilizada para os neurônios da camada oculta diz respeito a função gaussiana que é dada por:

$$\varphi(x, \mu_i) = \exp\left(-\frac{\|x - \mu_i\|^2}{2\sigma^2}\right) \quad (1)$$

Em que $\|x - \mu_i\|$ é a distância euclidiana do vetor de entrada (x) e o vetor μ_i que é o centro da i -ésima função de base radial. Já o parâmetro σ representa a largura (raio da função de base radial), também denominado *spread* no algoritmo newrb, mede o espalhamento dos dados representados pela função de base radial gaussiana.

Conforme Heshmati et al. (2009), as redes RBF com função de base radial gaussiana são aproximadores universais, ou seja, são capazes de aproximar mapeamentos entrada-saída não-lineares com um bom grau de precisão. Em relação à camada de saída, a resposta da rede RBF é calculada como uma combinação linear de todas as saídas das funções de base radial. Logo, a resposta da RNA (y) é representada pela soma das saídas das n funções gaussianas ponderadas por seus pesos sinápticos (ω_i) e pelos seus respectivos limiares (ω_0), como mostrado na seguinte equação:

$$y(x) = \sum_{i=1}^n \omega_i \varphi(x, \mu_i) + \omega_0 \quad (2)$$

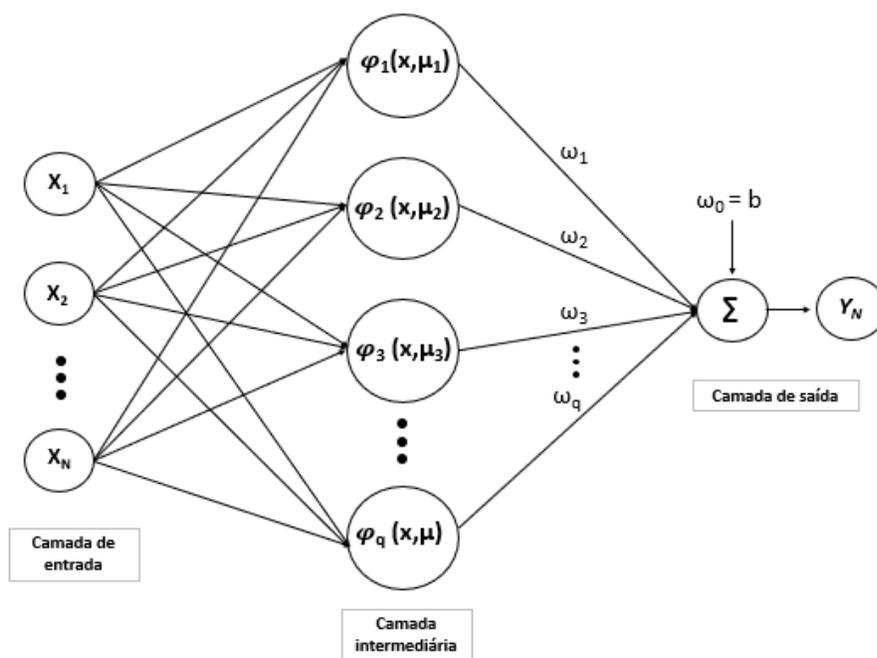


Figura 1 – Estrutura de uma RBF.

Fonte: Haykin (2009).

3. Materiais e métodos

3.1. Definição das variáveis de entrada

De uma forma geral, observa-se que as condições de contorno atuantes em uma descontinuidade rochosa, as suas características de rugosidade, presença de preenchimento e seus parâmetros de resistência, propriedades da rocha intacta e nível de deslocamento cisalhante são os principais fatores que governam o comportamento cisalhante das descontinuidades em maciços rochosos (INDRARATNA; OLIVEIRA; BROWN, 2010; OLIVEIRA; INDRARATNA, 2010; PAPALIANGAS et al., 1993; SKINAS; BANDIS; DEMIRIS, 1990).

Assim sendo, para o desenvolvimento dos modelos de previsão do comportamento cisalhante foram adotados como variáveis de entrada: a rigidez normal de contorno (k_n), a relação entre a espessura do preenchimento e a altura da

aspereza (t/a), a tensão normal inicial (σ_{n0}), o coeficiente de rugosidade da descontinuidade (JRC), a resistência à compressão uniaxial da rocha intacta (σ_c), o ângulo de atrito básico (ϕ_b), o ângulo de atrito do preenchimento (ϕ_{fill}) e o deslocamento cisalhante (δ_h). Como variáveis de saída dos modelos propostos têm-se a tensão de cisalhamento (τ_s) e a dilatância (δ_v) como parâmetros representativos do comportamento cisalhante das descontinuidades rochosas.

3.2. Banco de dados

Os dados utilizados para o desenvolvimento dos modelos neuronais propostos foram obtidos a partir dos resultados de 116 ensaios de cisalhamento direto em grande escala apresentados nos trabalhos de Benmokrane e Ballivy (1989), Skinas, Bandis e Demiris (1990), Papaliangas et al. (1993), Haque (1999), Indraratna e Haque (2000), Oliveira (2009), Indraratna, Oliveira e Brown (2010), Mehrishal et al. (2016) e Shrivastava e Rao (2017).

A referida base de dados apresenta um total de 2098 exemplos entrada-saída. Destes, 58% correspondem a resultados obtidos em ensaios realizados sob condições de rigidez normal constante (CNS) e 42% realizados sob condições de carregamento normal constante (CNL). Além disto, são contempladas tanto as descontinuidades rochosas com preenchimento (55%), como sem preenchimento (45%).

Os dados utilizados no desenvolvimento dos modelos abrangem ainda resultados de ensaios realizados em descontinuidades pouco a muito rugosas, como também formadas por rochas brandas a muito resistentes. A Tabela 1 apresenta as medidas de dispersão e tendência central para os valores das variáveis de entrada e saída constituintes do bando de dados utilizado para a elaboração dos modelos neuronais propostos.

Tabela 1 – Estatística descritiva das variáveis constituintes do banco de dados.

Parâmetros	Mínimo	Máximo	Média	Mediana	Desvio Padrão
k_n (Kpa/mm)	0,00	7515,00	266,06	90,96	601,99
t/a	0,00	2,00	0,51	0,00	0,68
σ_{n0} (MPa)	0,05	46,50	2,02	0,56	5,77
JRC	2,00	20,00	9,19	8,00	4,75
σ_c (MPa)	3,50	150,00	21,05	12,00	30,66
ϕ_b (Graus)	30,00	37,50	33,99	35,00	3,44
ϕ_{fill} (Graus)	0,00	35,50	14,62	0,00	15,98
δ_h (mm)	0,01	26,00	8,03	7,00	5,81
τ_s (MPa)	0,01	6,68	0,86	0,61	0,84
δ_v (mm)	-2,43	4,97	0,39	0,20	0,83

Fonte: Autores (2024).

3.3. Treinamento e teste dos modelos RBF

De acordo com Souza, Batista e Silva (2021), o treinamento da rede consiste na alteração dos pesos sinápticos e limiares existentes de acordo com um algoritmo específico. Neste artigo, o ajuste dos pesos sinápticos das redes RBF propostas foi feito utilizando o algoritmo *newrb*¹, desenvolvido por Hagan, Demuth e Beale (1996) e disponível no *Neural Network Toolbox*.

Mota et al. (2011) ressaltam que na fase de teste são utilizados padrões de entrada não utilizados no treinamento e é nessa etapa que o desempenho alcançado pela rede RBF é efetivamente medido por meio de uma probabilidade de acerto do modelo desenvolvido, ou seja, a correlação entre os dados reais e os dados calculados. Uma vez treinada e testada, a rede neural permite a validação dos modelos, que no presente trabalho, foi feita avaliando-se a capacidade dos modelos desenvolvidos em representar de forma o comportamento dos parâmetros modelados, conforme os trabalhos de Dantas Neto et al. (2017), Leite et al. (2019a), Leite et al. (2019b) e Dantas Neto et al. (2022).

Para o desenvolvimento dos modelos de predição propostos, foi construído um código-fonte no ambiente MATLAB (*MATrix LABoratory*) versão 13a utilizado nas fases de treinamento, teste e validação, cuja rotina de funcionamento é ilustrada na Figura 2.

Inicialmente, tem-se o carregamento e leitura dos padrões de entrada e saída. Tais dados devem estar dispostos em linhas e em um único arquivo de extensão *.dat*. Possetti (2009) ressalva que podem ser implementadas, por exemplo,

¹ <https://www.mathworks.com/help/deeplearning/ref/newrb.html>

técnicas de normalização ao conjunto de dados a serem modelados com uso das RBF, de modo a tornar o processo de treinamento mais eficiente. Desse modo, os dados utilizados nas fases de treinamento e teste foram normalizados entre 0 e 1.

A etapa seguinte consiste na definição dos dados a serem utilizados nas fases de treinamento e teste de forma aleatória. Nesse trabalho, foram utilizados 80% dos dados experimentais disponíveis para a fase de treinamento e 20% para a fase de teste obtidos de forma aleatória no conjunto de dados disponível, conforme sugerido por Turcato (2015).

Em seguida, são definidos os parâmetros de ajuste requeridos pelo algoritmo, sendo eles a abertura da função de base radial (σ) e o erro médio quadrático (MSE). Neste trabalho foram utilizados para σ um valor igual a 0,5 e dez valores para o erro médio quadrático variando de 0,0001 a 0,001 de modo a poder se avaliar de forma satisfatória a influência do valor de MSE na capacidade de generalização dos modelos (DIAS, 2005).

Os centros das funções de base radial são definidos por meio de técnicas de agrupamento de forma que a distância euclidiana entre cada centro e os vetores de entrada existentes no conjunto de treinamento seja a menor possível. Os centros das funções de base radial representam os pesos sinápticos entre a camada de entrada e a camada intermediária da rede RBF. Uma vez obtidos, seus valores são utilizados para o cálculo das funções de base radial que representam os neurônios da camada intermediária de acordo com a Equação 1 apresentada anteriormente. A ativação dos neurônios de saída é feita por meio de uma combinação linear dos valores das funções de base radial obtidas.

De acordo com o algoritmo *newrb* proposto por Hagan, Demuth e Beale (1996), os neurônios da camada de saída são calculados para cada exemplo existente no conjunto de treinamento e seu valor é comparado ao valor experimental correspondente gerando um erro médio quadrático. Após o cálculo é identificado o vetor de entrada para o qual este erro médio quadrático foi o máximo entre os calculados, e caso este valor seja superior ao valor estipulado para o MSE no processo de treinamento, um novo neurônio é adicionado e as funções radiais da camada oculta são ajustadas novamente. Este processo ocorre iterativamente e o treinamento é encerrado quando o valor estipulado para o erro médio quadrático, (MSE), denominado *goal*, é alcançado ou o número máximo de neurônios é inserido (equivalente ao número de exemplos no conjunto de treinamento).

Após as iterações feitas durante o processo de treinamento, é calculado no código-fonte o desempenho estatístico nas fases de treinamento e teste considerando-se 50 simulações diferentes nas quais são utilizados dados de entrada-saída aleatoriamente escolhidos. Esse desempenho é avaliado pela média, desvio padrão, valores máximos e mínimos e a mediana dos coeficientes de determinação.

A última etapa do processo de modelagem consiste no armazenamento da topologia da rede RBF que apresentar o melhor desempenho, considerando a maior média geométrica dos coeficientes de determinação do conjunto de teste para as variáveis de saída modeladas. A rede armazenada permite a validação dos modelos, para tanto, faz-se necessário inserir um arquivo com extensão *.dat* com dados que não foram utilizados nas etapas anteriores.

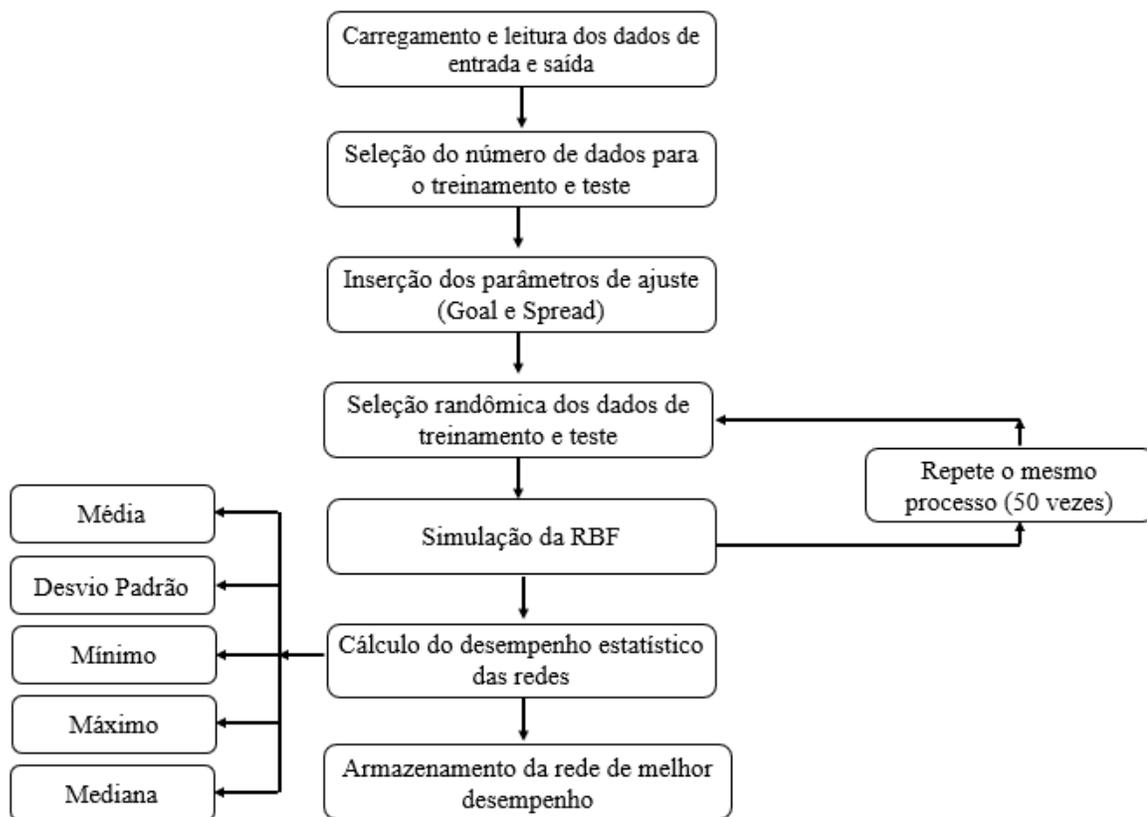


Figura 2 – Rotina do código-fonte.
Fonte: Autores (2024).

3.4 Etapa de validação e seleção do modelo de previsão

Após o desenvolvimento de todos os modelos, foi realizada uma análise de modo a selecionar como modelos aptos à validação aqueles que apresentarem coeficientes de determinação (R^2) superiores a 0,95 e a raiz dos erros médios quadráticos (RMSE) mais próximos a zero nas fases de treinamento e teste. Os menores valores RMSE, sugerem um modelo de melhor ajuste, tendo em vista indicar um menor erro entre os dados reais e os calculados pela RBF, que em termos estatísticos, indicam um modelo de bom ajuste.

A validação consiste na avaliação dos modelos no que tange à sua capacidade de representar de forma satisfatória a influência das variáveis de entrada nos valores previstos para a tensão cisalhante e dilatância em descontinuidades rochosas hipotéticas de forma semelhante ao que foi feito nos trabalhos de Dantas Neto et al. (2017), Leite et al. (2019a), Leite et al. (2019b) e Dantas Neto et al. (2022). A seleção do modelo de previsão do comportamento cisalhante das descontinuidades rochosas foi então feita utilizando-se como critério final o melhor desempenho na fase de validação.

4. Resultados e discussão

A Tabela 2 apresenta os valores dos coeficientes de determinação (R^2) e o RMSE obtidos durante as fases de treinamento e teste dos modelos RBF propostos para a previsão do comportamento cisalhante das descontinuidades rochosas representados pela tensão de cisalhamento e pela a dilatância.

Tabela 2 – Coeficientes de determinação e RMSE dos conjuntos de treinamento e teste da tensão cisalhante e dilatância.

Configurações			Tensão cisalhante				Dilatância			
Modelos	Goal	Arquitetura	Treinamento		Teste		Treinamento		Teste	
			R ²	RMSE	R ²	RMSE	R ²	RMSE	R ²	RMSE
M1	0,0002	8-242-2	0,984	0,0153	0,9872	0,0157	0,9872	0,0127	0,9840	0,0141
M2	0,0003	8-129-2	0,9760	0,0189	0,9828	0,0185	0,9798	0,0184	0,9800	0,0178
M3	0,0004	8-103-2	0,9686	0,0217	0,9787	0,0205	0,9719	0,0182	0,9742	0,0203
M4	0,0005	8-87-2	0,9632	0,0235	0,9748	0,0223	0,9624	0,0210	0,9669	0,0230
M5	0,0006	8-76-2	0,9593	0,0247	0,9709	0,0240	0,9528	0,0235	0,9638	0,0241
M6	0,0007	8-72-2	0,9566	0,0255	0,9687	0,0248	0,9374	0,0271	0,9507	0,0280
M7	0,0008	8-64-2	0,9552	0,0266	0,9643	0,0244	0,9285	0,0297	0,9347	0,0301
M8	0,0009	8-51-2	0,9419	0,0295	0,9579	0,0288	0,9214	0,0304	0,9399	0,0311
M9	0,0001	8-49-2	0,9388	0,0313	0,9480	0,0286	0,9193	0,0320	0,9280	0,0299

Fonte: Autores (2024).

Os resultados mostram que ao considerar um *goal* muito baixo ocorre o *overfitting*, que é quando um modelo estatístico se ajusta muito bem ao conjunto de dados anteriormente observados, mas se mostra ineficaz para prever novos resultados, portanto, fazendo com que o modelo construído com *goal* de 0,0001 fosse descartado. Conforme o critério estabelecido, os modelos M1, M2, M3, M4 e M5, que apresentam R² superiores a 0,95 e RMSE próximos de 0 nas fases de treinamento e teste, foram escolhidos como aptos para o processo de validação. Para tanto, foram utilizadas descontinuidades hipotéticas com o intuito de averiguar se os mesmos eram capazes de expressar a influência das variáveis que governam o comportamento cisalhante de descontinuidades rochosas preenchidas e não preenchidas, sob condições CNL e CNS. Tais descontinuidades tem como variáveis constantes $\sigma_c = 12$ MPa, $JRC = 5$, $\phi_b = 37,5^\circ$, e de modo a verificar a influência do preenchimento utilizou-se um σ_{fill} de $35,5^\circ$ e distintos valores de t/a (0; 0,6; 1,0 e 1,4).

Os resultados obtidos na fase de validação indicam que o modelo M1 foi o que melhor representou a influência das variáveis de entrada no comportamento cisalhante das descontinuidades rochosas. Observa-se que os resultados fornecidos pela RBF foram coerentes, e conforme esperado, houve o aumento da tensão cisalhante (Figuras 3a e 4a) bem como a diminuição da dilatação (Figura 3b e 4b) com o aumento da rigidez normal de contorno e da tensão normal inicial, respectivamente.

Observa-se ainda que para elevados níveis de tensão normal inicial, tem-se uma diminuição acentuada da dilatância (Figura 4b). Isto ocorre devido a degradação das asperezas da descontinuidade sem preenchimento, conforme mostrado nos resultados experimentais apresentados por Indraratna e Haque (2000), Indraratna, Oliveira e Brown (2010), Oliveira, Indraratna e Nemeick (2009) e Oliveira e Indraratna (2010) indicando a capacidade do modelo em entender tal fenômeno.

De modo a avaliar o comportamento do modelo com a mudança da rugosidade, foram assumidos valores de JRC de 5 e 10 para descontinuidade hipotética sem preenchimento, sob CNS (560 kPa/mm). As Figuras 5a e 5b mostram o aumento tanto da tensão cisalhante como da dilatância com a rugosidade representada pelo valor de JRC, conforme o esperado.

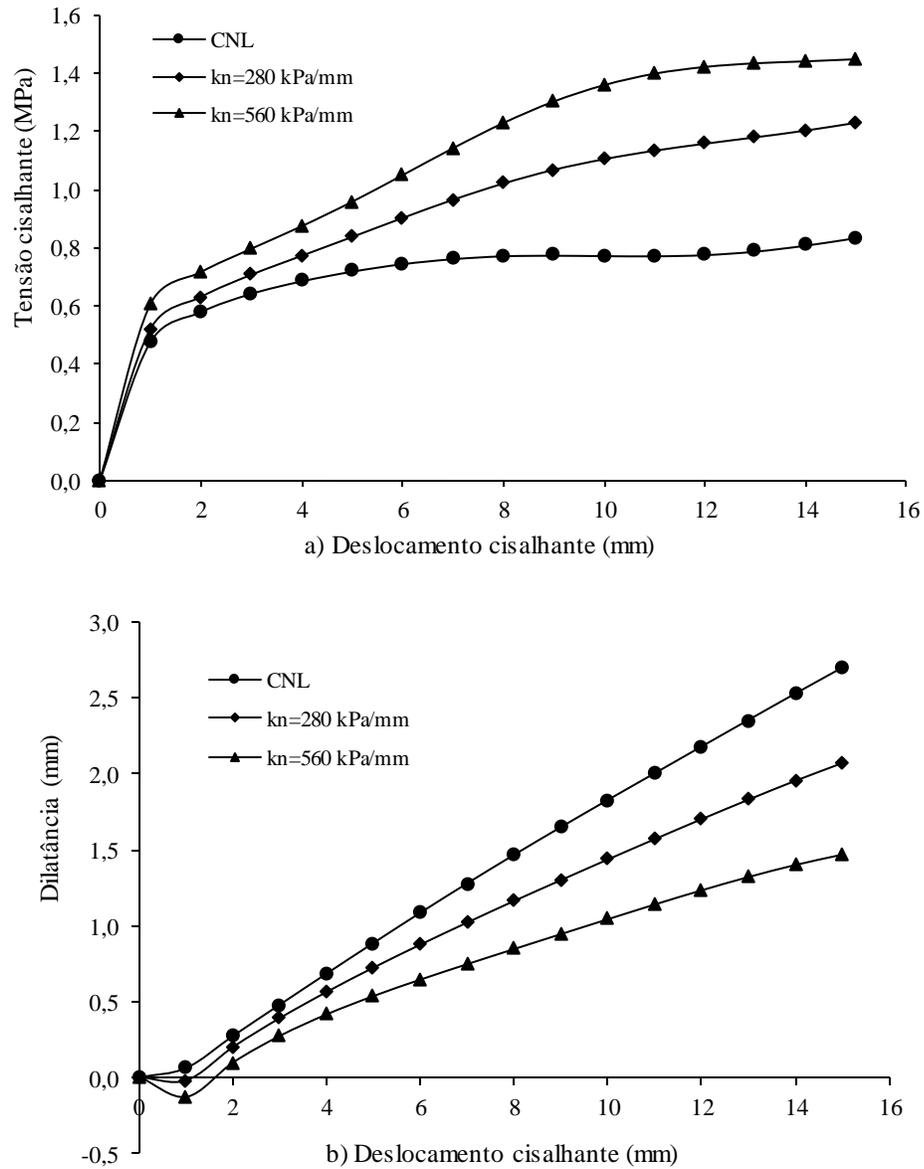


Figura 3 – Influência da rigidez normal na tensão cisalhante (a) e dilatância (b) ($\sigma_{no} = 0,5 \text{ MPa}$, $t/a = 0$).
 Fonte: Autores (2024).

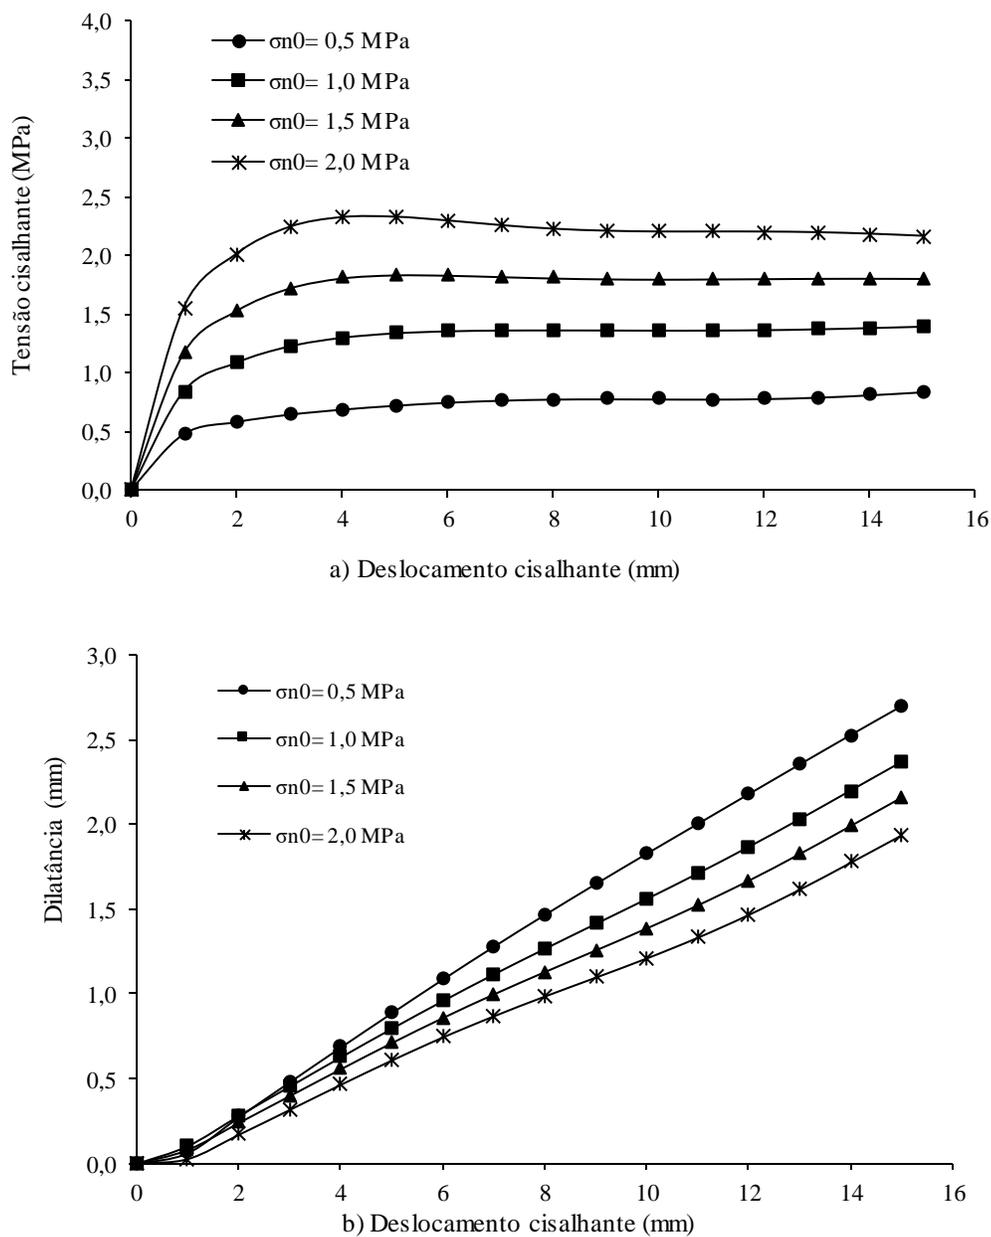


Figura 4 – Influência da tensão normal inicial na tensão cisalhante (a) e dilatância (b) ($kn = 0$ kPa/mm e $t/a = 0$).
 Fonte: Autores (2024).

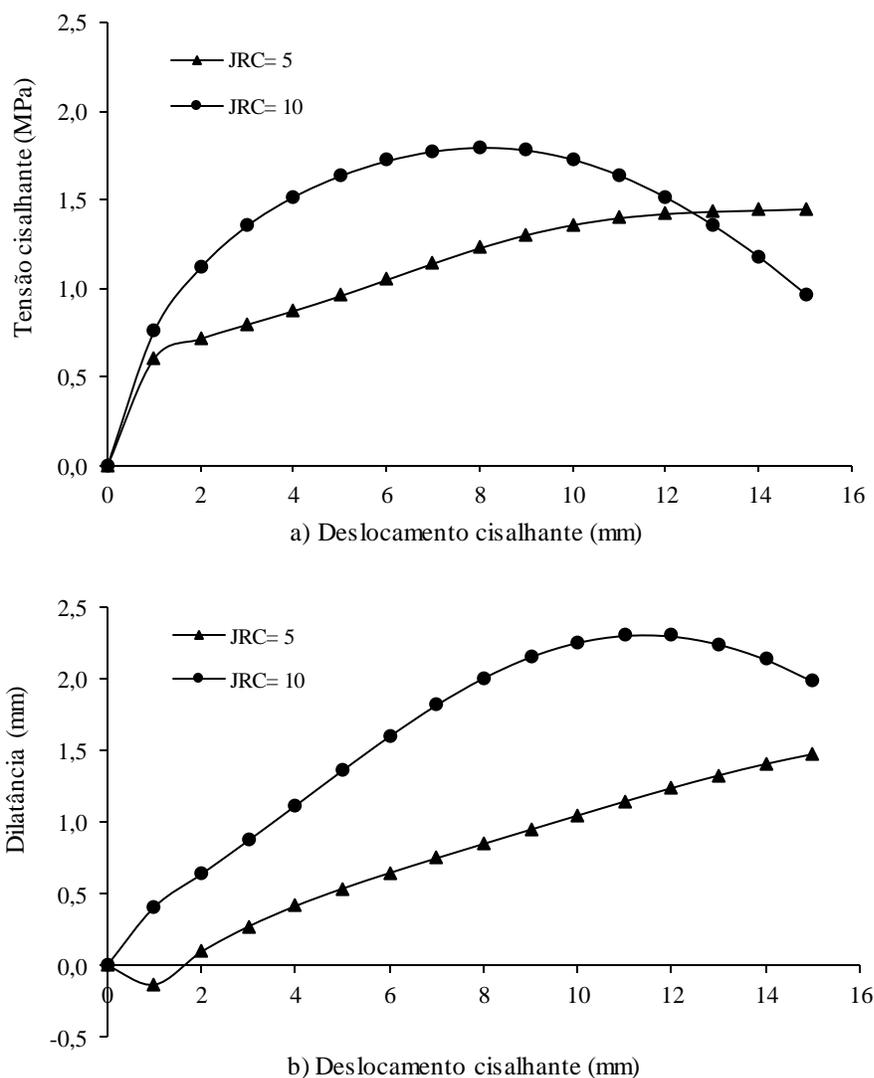


Figura 5 – Influência da rugosidade na tensão cisalhante (a) e dilatação (b) ($kn=560$ kPa/mm, $\sigma_{no}=0,5$ MPa e $t/a=0$)
Fonte: Autores (2024).

Para as descontinuidades hipotéticas com preenchimento, foram considerados os seguintes parâmetros: $kn = 560$ kPa/mm; $\sigma_{no} = 0,5$ MPa; $\phi_{fill} = 35,5^\circ$; valores de t/a variando de 0 a 1,4; $JRC=5$; $\sigma_c = 12$ MPa e $\phi_b=37,5$. Os resultados mostrados na Figuras 7a e 7b indicam que o modelo M1 consegue representar de forma bastante satisfatória a redução da tensão cisalhante e da dilatação com o aumento da espessura do preenchimento, conforme resultados obtidos por diferentes autores, tais como Indraratna e Haque (2000), Indraratna, Oliveira e Brown (2010), Oliveira, Indraratna e Nemcick (2009), e Oliveira e Indraratna (2010).

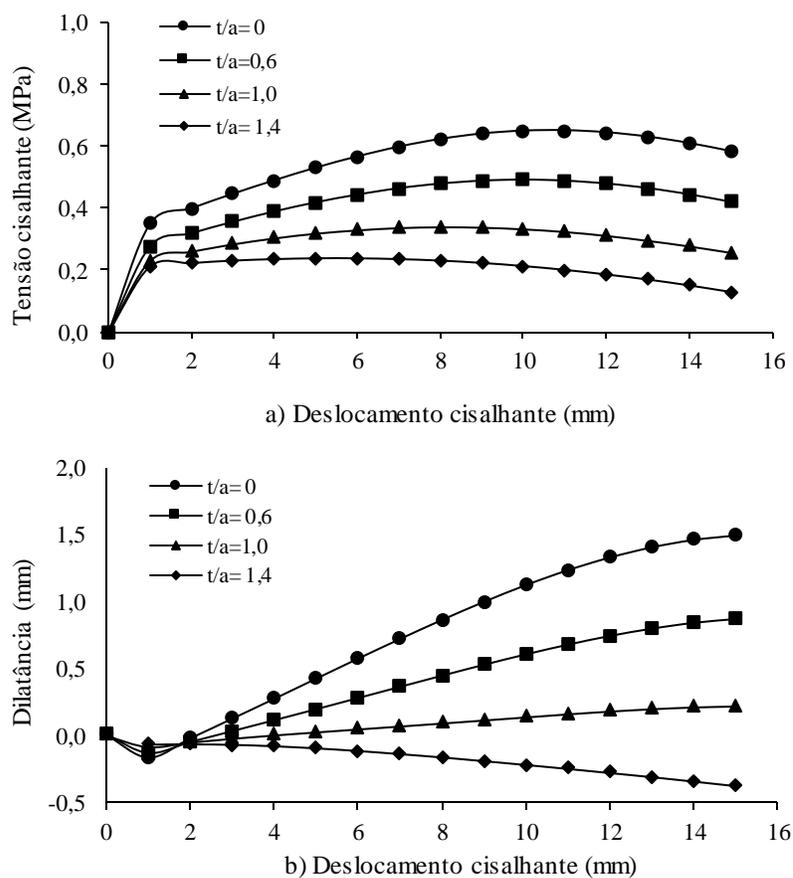


Figura 6 – Influência do preenchimento sob CNS na tensão cisalhante (a) e dilatação (b) ($k_n=560\text{ kPa/mm}$ e $\sigma_{no}=0,5\text{ MPa}$)
 Fonte: Autores (2024).

O modelo M1 apresenta uma arquitetura composta de 8 neurônios na camada de entrada, 242 neurônios na camada intermediária e 2 neurônios na camada de saída, como ilustrado na Figura 7. Os coeficientes de determinação e valores de RMSE para a tensão cisalhante e dilatação obtidos pelo referido modelo são apresentados nas Figuras 8a e 8b, respectivamente.

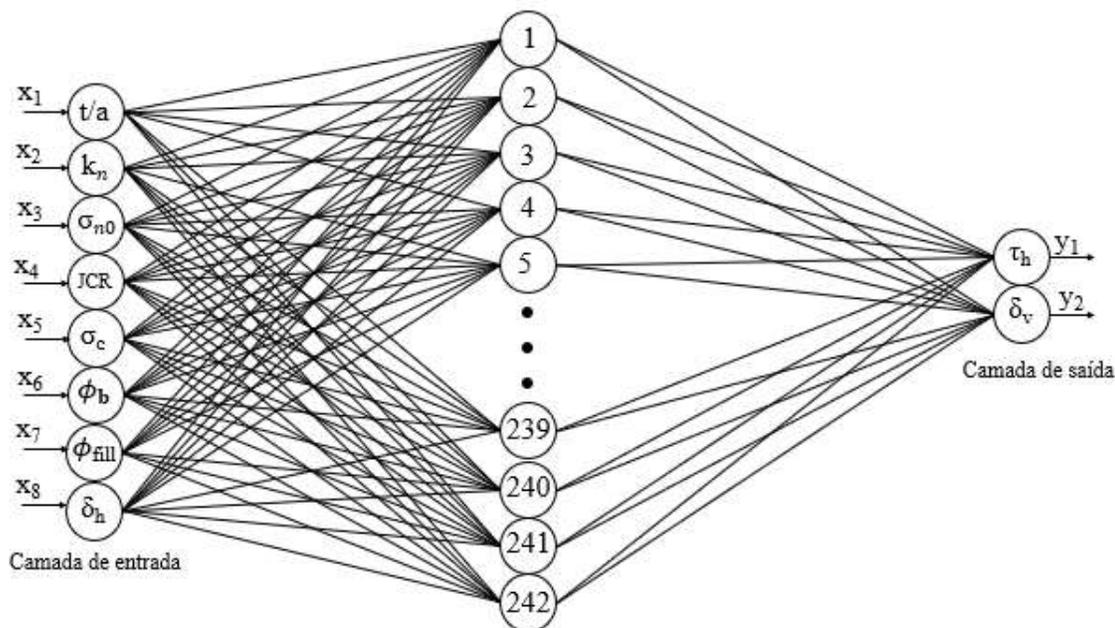


Figura 7 – Arquitetura do modelo RBF (8-242-2).
Fonte: Autores (2024).

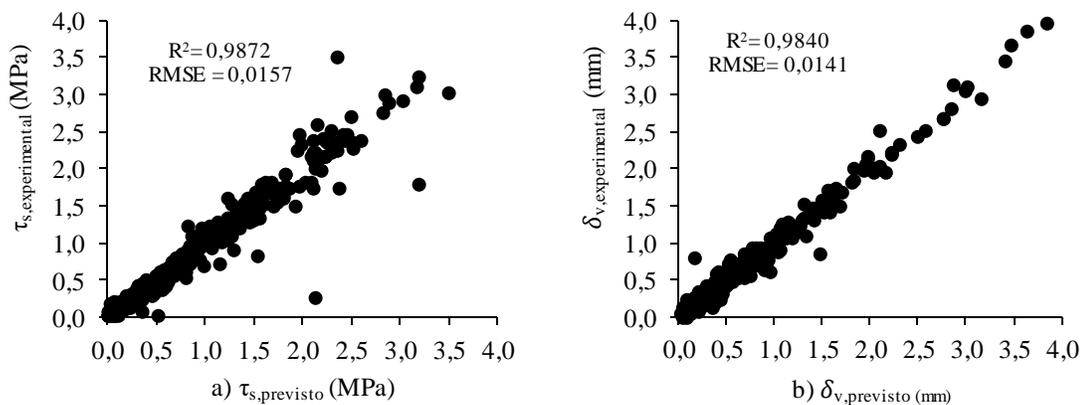


Figura 8 – Correlação entre os dados experimentais e os previstos pela rede RBF para a tensão cisalhante para os conjuntos de treinamento e teste.
Fonte: Autores (2024).

A Figura 9 apresenta a comparação entre os resultados fornecidos pelo modelo RBF, os dados experimentais e o modelo analítico de Indraratna e Haque (2000) e os modelos neurais de Dantas Neto et al. (2017) e Leite (2019) para a tensão cisalhante (a) e a dilatância (b) para uma descontinuidade rochosa sem preenchimento ensaiada sob condição de rigidez normal constante com $k_n=453$ kPa/mm, $\sigma_c=12$ MPa, $JRC=8$ e $\phi_b = 37,5^\circ$.

Os resultados mostram que para ambas as variáveis de saída, o modelo M1 se ajustou melhor aos dados experimentais que os demais modelos considerados, mostrando que as redes neurais do tipo função de base radial têm fornecidos melhores resultados que aqueles obtidos por modelos analíticos tradicionais e pelos perceptrons multicamadas.

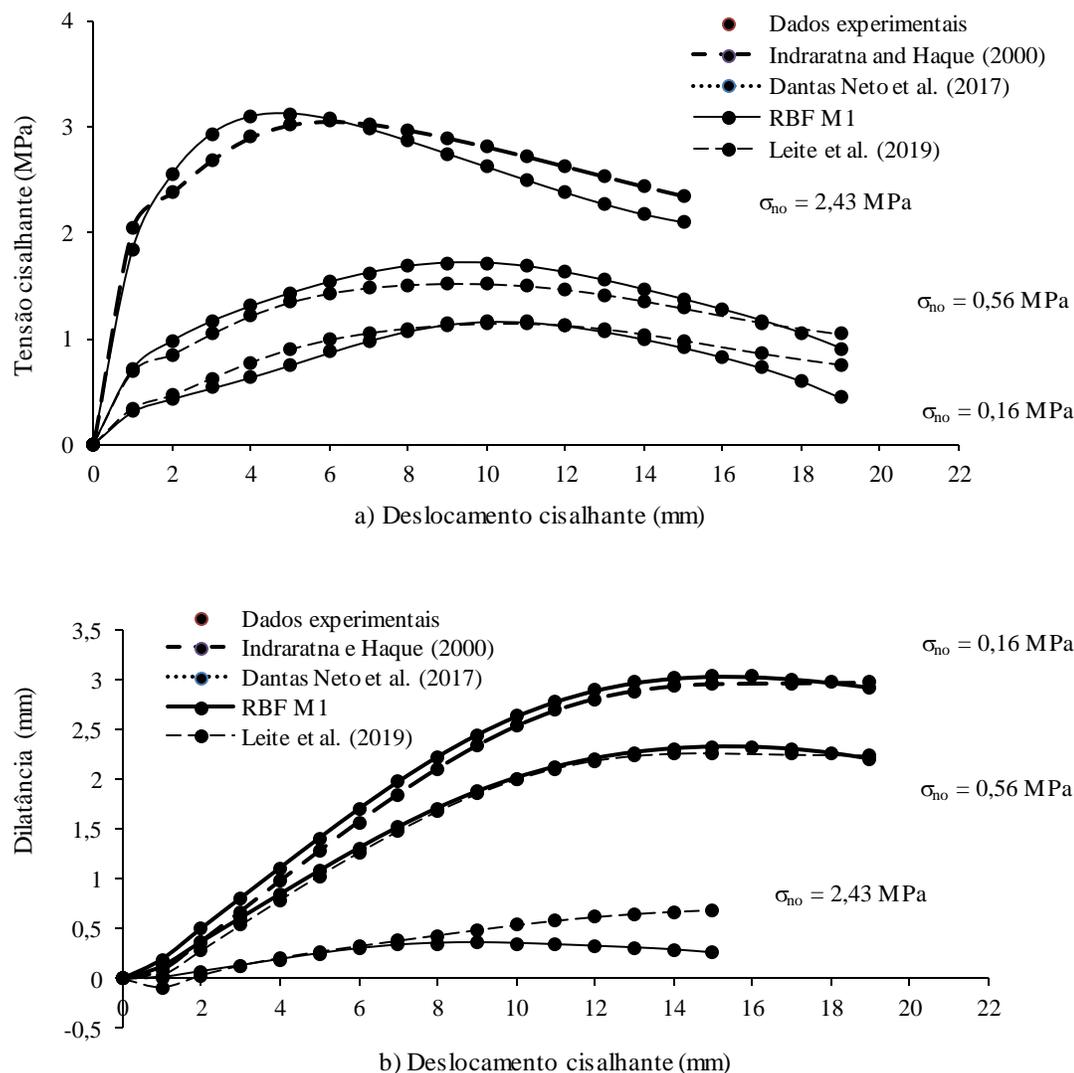


Figura 9 – Comparação entre dados experimentais e os modelos neuronais e analítico para a tensão cisalhante (a) e a dilatância (b).

Fonte: Autores (2024).

5. Conclusões

Neste trabalho foi proposta uma abordagem alternativa para a estimação do comportamento cisalhante das descontinuidades rochosas preenchidas e não preenchidas e sob condições CNL e CNS. O modelo denominado M1 foi obtido com *spread* igual a 0,5 e *goal* de 0,0002, tendo como variáveis de entrada a rigidez normal (k_n) dada em kPa/mm, tensão normal inicial (σ_{no}) em MPa, o coeficiente de rugosidade da junta (JRC), a resistência à compressão uniaxial da rocha intacta (σ_c) em MPa, o ângulo de atrito básico (ϕ_b) em graus e deslocamento cisalhante (δ_h) em mm, já as variáveis preditoras se referem a resistência ao cisalhamento (τ_s) dada em kPa e a dilatância correspondente (δ_v) em mm, apresentando uma arquitetura de 8-242-2.

Os coeficientes de determinação foram superiores a 0,98 para a tensão cisalhante e para a dilatância e os valores do RMSE foram iguais ou inferiores a 0,0157 nas fases de treinamento e teste, indicando uma excelente concordância entre os dados experimentais e os resultados obtidos pelo modelo RBF proposto. Considerando as diversas características de

descontinuidades hipotéticas de rochas preenchidas e não preenchidas, observa-se que o modelo escolhido consegue representar satisfatoriamente a influência das variáveis que governam o seu comportamento cisalhante e alguns mecanismos específicos, a exemplo da degradação da aspereza em altos níveis de tensão normal inicial.

Em relação às limitações do modelo proposto, destaca-se a necessidade de implementar um código-fonte para testar e validar os resultados, tendo em vista que a interface do software permite apenas o treinamento dos dados. Somado a isso, tem-se que o modelo proposto não considerou outros fatores importantes que vêm sendo investigados atualmente, como algumas características do material de enchimento, podendo-se citar o seu grau de compactação, o grau de saturação e a parcela coesiva da sua resistência ao cisalhamento, assim como o efeito do intemperismo nas paredes das descontinuidades rochosas. Em suma, o modelo proposto se mostra um método alternativo para a aquisição da tensão cisalhante e dilatância de forma rápida e econômica para aplicações diárias na área de Mecânica das Rochas.

Agradecimentos

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (Capes) pelo apoio financeiro e ao Centro Nacional de Processamento de Alto Desempenho (CENAPAD) da Universidade Federal do Ceará, pela licença do software MATLAB.

Referências

- Barton, N. R. The shear strength of rock and rock joints. *Int. J. Rock Mech. Min. Sci.*, v.13, n. 9, p. 255-279, 1976.
- Barton, N. R. A review of the shear strength of filled discontinuities in rock. *Norwegian Geotechnical Institute Publication*, n. 105, p. 1-38, 1973.
- Barton, N. R.; Choubey, V. The shear strength of rock joints in theory and practice. *Rock Mechanics and Rock Engineering*, v. 10, n. 1-2, p. 1-54, 1977.
- Barton, N. R.; Choubey, V. The shear strength of rock joints in theory and practice. *Rock Mechanics and Rock Engineering*, v. 10, n. 1-2, p. 1-54, 1977.
- BENMOKRANE, B.; BALLIVY, G. 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, Balke ma, Rotterdam, p. 899-906, 1989.
- CHAOWANAWATEE, K.; HEEDNACRAM, A. (2012). Implementation of cuckoo search in RBF neural network for flood forecasting, 2012. In: FOURTH INTERNATIONAL CONFERENCE ON COMPUTATIONAL INTELLIGENCE, COMMUNICATION SYSTEMS AND NETWORKS (CICSyN), IEEE, p.22-26.
- Dantas Neto, S. A.; Indraratna, B.; Oliveira, D. A. F.; Assis, P. Modelling the Shear Behaviour of Clean Rock Discontinuities Using Artificial Neural Networks. *Rock Mechanics and Rock Engineering*, v. 50, n. 7, p. 1817-1831, 2017.
- Dantas Neto, S. A.; Albino, M.C.; Leite, A.R.S.; Abreu, A. A. Development of neuro-fuzzy models for predicting shear behavior of rock joints. *Soil and Rocks*, v.45, n. 4, p. 1-13, 2022.
- Erzin, Y.; Rao, B. H.; Singh, D. N. Artificial neural network models for predicting soil resistivity. *International Journal of Thermal Sciences*, v. 47, n. 10, p. 1347-1358, 2008.
- Fernández-Navarro, F.; Hervás-Martínez, C.; Sanchezmonedero, J.; Gutiérrez, P. A. MELM-GRBF: a modified version of the extreme learning machine for generalized radial basis function neural networks. *Neurocomputing*, v. 74, p. 2502-2510, 2011.
- FERREIRA, J. A. B. *Redes neurais artificiais aplicadas em aprendizagem de trajetória em robótica móvel*. 2020. 111f. Dissertação (Mestrado). Programa de Pós-Graduação em Sistemas Mecatrônicos, Universidade de Brasília, Brasília – DF. 2020.

-
- Gan, M.; Peng, H.; Chen, L. A hybrid global–local optimization approach to parameter estimation of RBF-type models. *Information Sciences*, v. 197, p. 144–160, 2012.
- Getahun, M. A.; Shitote, S. M.; Abiero Gariy, Z. C. Artificial neural network based modelling approach for strength prediction of concrete incorporating agricultural and construction wastes. *Construction and Building Materials*, v. 190, n. 108, p. 517–525, 2018.
- Hagan, M.T.; Demuth, H.B.; Beale, M.H. *Neural network design*. PWS Publishing: Boston, 1996.
- HAQUE, A. *Shear Behaviour of Soft Rock Joints under Constant Normal Stiffness*. 1999. Thesis (Doctorate) - University of Wollongong. Department of Civil, Mining and Environmental Engineering. Wollongong, Austrália, 1999.
- HAYKIN, S. *Neural Networks and Learning Machines*. 3 ed, p. 1-263, New York: Prentice Hall, 2009.
- Heshmati, R. A. A.; Alavi, A. H.; Keramati, M.; Gandomi, H. A. A Radial Basis Function Neural Network Approach for Compressive Strength Prediction of Stabilized Soil. *Geotechnical Special Publication*, v. 191, n. 191, p. 147-153, 2009.
- INDRARATNA, B.; HAQUE, A. Experimental and numerical modeling of shear behaviour of rock joints, *GeoEng 2000*, 2000. CD-ROM.
- Indraratna, B.; Oliveira, D. A. F.; Brown, E. T. A Shear-Displacement Criterion for Soil-Infilled Rock Discontinuities. *Géotechnique*. v. 60, n. 8, p. 623-33, 2010.
- KAWASE, K. H. F. *Aplicação de redes neurais RBF e MLP na análise de evasão discente do curso de Sistemas de Informação da UFRRJ*. 2015. 59 f. Dissertação (Mestrado). Programa de Pós-Graduação em Modelagem Matemática e Computacional, Universidade Federal Rural do Rio de Janeiro, Seropédica-RJ, 2015.
- LADANYI, B.; ARCHAMBAULT, G. Simulation of Shear Behavior of a Jointed Rock Mass. In: ELEVENTH U.S. SYMPOSIUM ON ROCK MECHANICS: THEORY AND PRACTICE. 1969, Berkeley, *Proceedings...* Alexandria, VA: American Rock Mechanics Association Press, 1969. p. 105-125.
- LEITE, A.R.S.; DANTAS NETO, S.A.; ALBINO, M.C. Modelo de rede neural artificial para previsão do comportamento cisalhante de descontinuidades rochosas. In: XL IBERO-LATIN AMERICAN CONGRESS ON COMPUTATIONAL METHODS IN ENGINEERING (CILAMCE). Belo Horizonte, Brazil: ABMEC. p. 1-13, 2019.
- LEITE, A.R.S., DANTAS NETO, S.A., POLEMIS JUNIOR, K.; OLIVEIRA, C.M.O. Study on the shear behaviour of rock joints using different models of artificial neural networks. In: INTERNATIONAL CONGRESS ON ROCK MECHANICS AND ROCK ENGINEERING (p. 2707-2714). Salzburg, Austria: ISRM. 2019.
- MATOS, Y. M. P. *Desenvolvimento de modelos de previsão do comportamento cisalhante em descontinuidades sem preenchimento de maciços rochosos utilizando técnicas fuzzy e neuro-fuzzy*. 2018. 211 f. Dissertação (Mestrado em Engenharia Civil), Programa de Pós-Graduação em Engenharia Civil: Geotecnia, Universidade Federal do Ceará, Fortaleza - CE, 2018.
- MENDES, G. A. R. *Otimização e previsão de parâmetros para definição do comportamento cisalhante de descontinuidades rochosas por meio de métodos meta-heurísticos e redes neurais artificiais*. 2021. 119 f. Dissertação (Mestrado em Engenharia Civil), Programa de Pós-Graduação em Engenharia Civil: Geotecnia, Universidade Federal do Ceará, Fortaleza - CE, 2021.
- Mehrishal, S.; Sharifzadeh, M.; Shahriar, K.; Song, J. J. An Experimental Study on Normal Stress and Shear Rate Dependency of Basic Friction Coefficient in Dry and Wet Limestone Joints. *Rock Mech. Rock Eng.*, v. 49, n. 12, p. 4607-4629, 2016.

- MOTA, J.F.; SIQUEIRA, P. H.; SOUZA, L. V.; VITOR, A. Uma rede neural de base radial baseada em computação evolucionária. In: XXXII CILAMCE: CONGRESSO IBERO LATINO AMERICANO DE MÉTODOS COMPUTACIONAIS EM ENGENHARIA. Ouro Preto – MG, 2011.
- Naseri, S.; Tatar, A.; Shokrollahi, A. Development of an accurate method to prognosticate choke flow coefficients for natural gas flow through nozzle and orifice type chokes. *Flow Measurement and Instrumentation*, v. 48, p. 1–7, 2016.
- NEVES E CARVALHO, G.R. *Utilização de RNA RBF para previsão de quantidade de água no solo*. 2010. 73f. Monografia (Graduação). Curso de Ciência da Computação. Faculdades Integradas de Caratinga. Caratinga - MG. 2010.
- Oliveira, D. A. F.; Indraratna, B.; Nemcik, J. Critical Review on Shear Strength Models for Soil-Infilled Joints. *Geomechanics and Geoengineering*, v. 4, n. 3, p. 237-244, 2009.
- Papaliangas, T.; Hencher, S. R.; Lumsden, A. C.; Manolopoulou, S. The Effect of Frictional Fill Thickness on the Shear Strength of Rock Discontinuities. *International Journal of Rock Mechanics and Mining Sciences and Geomatics*, v. 30, n. 2, p. 81-91.1993.
- Possetti, G, R, C. *Sensor Inteligente a Fibra Ótica Para Análise da Qualidade da Gasolina Brasileira*. 2009. 115f. Dissertação (Mestrado). Pós-Graduação em Engenharia Elétrica e Informática Industrial, Universidade Tecnológica Federal do Paraná, Ponta Grossa, PR, 2009.
- Qin, Z., Chen, X.; Fu, H.; Hu, S.; Wang, J. Slope Stability Analysis Based on the Radial Basis Function Neural Network of the Cerebral Cortex. *NeuroQuantology*, v. 16, n. 5, p. 734-740, 2018.
- Majdi, A.; Rezaei, M. Prediction of unconfined compressive strength of rock surrounding a roadway using artificial neural network. *Neural Comput & Applic*, v. 23, n. 2, p. 381–389, 2013.
- Safarnejad, A.; Hormozi-Nezhad, M, R.; Abdollahi, H. Radial basis function-artificial neural network (RBF-ANN) for simultaneous fluorescent determination of cysteine enantiomers in mixtures. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, n.261, p.1-10, 2021.
- Sayadi, A.; Monjezi, M.; Talebi, N.; Khandelwal, M. A comparative study on the application of various artificial neural networks to simultaneous prediction of rock fragmentation and backbreak. *Journal of Rock Mechanics and Geotechnical Engineering* v,5, p. 318–324, 2013.
- Shrivastava, A. K.; Rao, K. S. Physical Modeling of Shear Behavior of Infilled Rock Joints Under CNL and CNS Boundary Conditions. *Rock Mech. Rock Eng.*, v. 51, n. 1, p. 101-118, 2017.
- SKINAS, C. A.; BANDIS, S. C.; DEMIRIS, C. A. Experimental Investigations and Modelling of Rock Joint Behaviour Under Constant Stiffness. In: Barton, Stephanson (eds). *Rock joints*, Balkema Publisher, Rotterdam. p. 301-307, 1990.
- Soares, D. G.; Teive, R. C. G. Estudo Comparativo entre as Redes Neurais Artificiais MLP e RBF para Previsão de Cheias em Curto Prazo. *Revista de Informática Teórica e Aplicada*, v.22, n. 2, p. 67-86, 2015.
- SOUZA, L. P.; BATISTA, P. V. C.; SILVA, P, C. L. A New Heuristic for Radius Estimation in RBF Neural Networks. In: XVIII ENCONTRO NACIONAL DE INTELIGÊNCIA ARTIFICIAL E COMPUTACIONAL. At: *Online Event*. 2021.
- TURCATO, A, C. *Desenvolvimento de uma metodologia baseada em redes neurais artificiais para a identificação de anomalias em redes de comunicação Profinet*. 115 2015. 218 f. Dissertação (Mestrado). Programa de Pós-Graduação em Engenharia Elétrica, Universidade de São Paulo, São Carlos - SP, 2015.

Zhou, J.; Bejarbaneh, B. Y.; Armaghani, D. J.; Tahir, M. Forecasting of tbm advance rate in hard rock condition based on artificial neural network and genetic programming techniques. *Bulletin of Engineering Geology and the Environment, Springer*, v. 79, n. 2, p. 2069–2084, 2020.