



APLICAÇÃO DO ALGORITMO DE REDES NEURAIS NA AVALIAÇÃO DA RESISTÊNCIA NÃO DRENADA DE RESÍDUO DE BAUXITA

GUILHERME HENRIQUE DA SILVA PINTO | Engenheiro Geotécnico – Pimenta de Ávila

HUGO ASSIS BRANDÃO | Coordenador do Comitê Técnico e Núcleo de Inovação – Pimenta de Ávila

TATIANA BARRETO SANTOS | Professora Adjunta – Universidade Federal de Ouro Preto

RESUMO

A determinação da resistência não drenada de rejeitos é essencial na Engenharia Geotécnica, tendo em vista que tal parâmetro é utilizado para avaliar as condições de estabilidade de estruturas de contenção de rejeitos. Muitas metodologias, empíricas e/ou analíticas, foram desenvolvidas para a estimativa deste parâmetro baseado em correlações para solos naturais utilizando o ensaio de piezocone (CPTu). Entretanto, tais metodologias podem apresentar valores inconsistentes se aplicadas a materiais manufaturados como rejeitos. No presente trabalho, os autores aplicaram o algoritmo de Redes Neurais Artificiais (RNAs) para determinar a resistência não drenada de pico de um rejeito de bauxita baseado em dados de CPTu. Os resultados mostraram a aplicabilidade do método RNAs, sendo obtidos resultados mais acurados e menos dispersos do que a metodologia via N_{kt} .

ABSTRACT

Definition of tailings undrained shear strength is essential in geotechnical engineering since this parameter is used to evaluate the stability conditions of tailings storage facilities. Several analytical and/or empirical methods have been developed to estimate this parameter based on correlations defined for soils using the piezocone teste (CPTu). However, these methodologies could lead to inconsistent results if directly applied to manufactured materials such as tailings. In this paper, the authors used Artificial Neural Network (ANN) to determine the undrained shear strength of a bauxite tailing based on CPTu data. The results have shown the applicability of the ANN method to obtaining more accurate and less dispersive results than the conventional methodology based on N_{kt} .

1. INTRODUÇÃO

A correta determinação de parâmetros como resistência e deformabilidade dos rejeitos é de suma importância na Engenharia Geotécnica, visto que eles impactam diretamente na avaliação da condição de estabilidade de estruturas de contenção. Casos recentes de ruptura de barragens de rejeito, como Kolóntar (Hungria) em 2010 [1], Mount Polley (Canadá) em 2014 [2], Fundão (Brasil) em 2015 [3], e B1 Córrego do Feijão (Brasil) em 2019 [4], mostram a necessidade do melhor entendimento de tais parâmetros. Além disso, o Padrão Global da Indústria para Gestão de Rejeitos destaca em seu princípio II a importância da caracterização dos rejeitos na gestão da segurança das estruturas de contenção, em todas as fases de vida do empreendimento [5].

Para a caracterização geotécnica de rejeitos de mineração e determinação de parâmetros de resistência e deformabilidade, comumente são realizados ensaios de campo e ensaios de laboratório [6]. No que tange aos ensaios de campo, dentre as formas comerciais largamente empregadas para a avaliação da resistência não drenada destacam-se o ensaio de cone/piezocone (CPT/CPTu) e o ensaio de palheta (*Field Vane Shear Test – VST*) [7].

Normalizado pela norma americana ASTM D5778 [8], o ensaio CPTu tem princípio de realização simples. O ensaio consiste na cravação de uma ponteira cônica (com 60° no ápice) com velocidade padronizada de $2,0 \pm 0,5$ cm/s, sendo registradas leituras a cada 2 cm ou 5 cm, em média. Comumente, a seção transversal do cone mede 10 cm², seguido por uma luva de atrito lateral de área transversal de 150 cm² e um sensor de medição de poropressão localizado atrás do cone (posição u_2). O ensaio CPTu fornece três medidas independentes: (i) a resistência de ponta (q_c), que representa a resistência do solo à cravação do cone; (ii) o atrito lateral (f_s), que representa a aderência do solo à luva de atrito durante a cravação; e (iii) a poropressão gerada durante a cravação (u), que é usualmente medida atrás do cone (u_2), conforme as boas práticas internacionais [9].

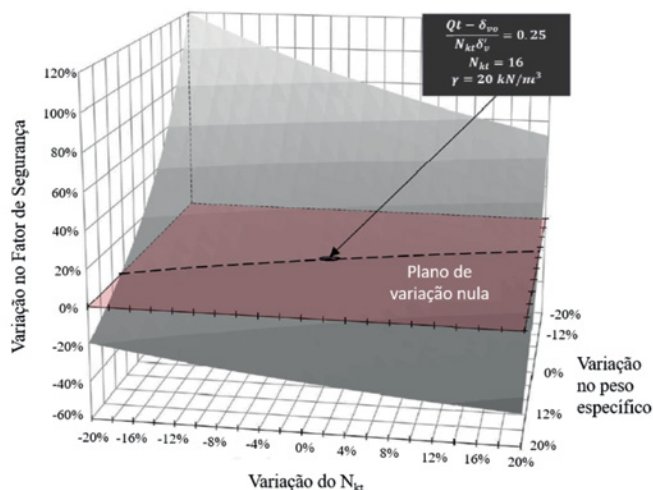
A determinação da resistência não drenada (S_u) com base em ensaios CPTu pode ser realizada com base numa equação que correlaciona as variáveis medidas pelo cone e o fator de capacidade de carga N_{kt} , como apresentado na Equação 1 [10], onde q_t é a resistência total do cone, obtida pela Equação 2, σ_{v0} é a tensão vertical total, e “a” é a correção do cone devido às áreas desiguais.

$$S_u = \frac{q_t - \sigma_{v0}}{N_{kt}} \quad (1)$$

$$q_t = q_c * (1 - a) * u_2 \quad (2)$$

Para a determinação do N_{kt} , muitos pesquisadores propuseram formulações empíricas e/ou analíticas, calibradas para as condições

de cada material estudado. Entretanto, conforme apresentado por Herza *et al.* [11], a depender das variações do peso específico do material (utilizado no cálculo da tensão vertical total) e no N_{kt} , o Fator de Segurança (F.S.) de uma estrutura pode variar entre -60% a +120%, conforme apresentado na Figura 1. Certamente, essa variação poderia levar a uma caracterização errônea da estabilidade de uma estrutura.



Escala do fator de segurança




Figura 1 - Variação do F.S. devido a variação de N_{kt} e σ_{v0} (Adaptado de [11])

Uma forma comum de determinar o N_{kt} é a utilização de ensaios de palheta para a calibração da Equação 1 com os dados do CPTu. Nesse processo, o valor de N_{kt} é ajustado de forma que o perfil de resistência obtido pelo CPTu seja similar ao do VST. Tal ensaio de campo tem objetivo de determinar a resistência ao cisalhamento não drenada de depósitos de argilas saturadas ou com elevado grau de saturação, não sendo aplicável em materiais areno-siltosos ou solos não plásticos [7]. Normalizado pela NBR 10.905 [12], o ensaio consiste na rotação de um conjunto de palhetas cruciformes cravadas em profundidades pré-definidas com velocidade controlada de $6,0 \pm 0,6$ °/min, de forma a não dissipar as poropressões geradas. Por meio da medição do torque aplicado, determina-se a resistência não drenada do material, seja ela na condição indeformada (resistência de pico) ou na condição amolgada (resistência à grandes deformações), aplicando a Equação 3, sendo T o torque máximo medido e D o diâmetro da palheta [13].

$$S_u = 0,86 \left(\frac{T}{\pi * D^3} \right) \quad (3)$$

Com o aumento da capacidade computacional e da quantidade de dados disponíveis, a aplicação de técnicas de aprendizado de máquina tem se tornado uma alternativa à utilização de formulações empíricas para determinação de parâmetros, como a resistência não drenada. Para determinação da resistência não drenada, o trabalho desenvolvido por Sivrikaya [14] utilizou o algoritmo de Redes Neurais Artificiais – RNAs (*Artificial Neural Networks - ANN*), usando como dados de entrada os Limites de Atterberg, o N-SPT do ensaio SPT, e o teor de umidade para predição da resistência não drenada de um solo argiloso natural medido por ensaios triaxiais do tipo UU (não confinado com cisalhamento não drenado) [14]. Apesar da resistência não drenada ser função da tensão efetiva, isto é, do confinamento ao qual o solo está submetido [9], o trabalho apresentado por Sivrikaya [14] demonstra a aplicabilidade das RNAs, obtendo R^2 superior a 0,75.

As RNAs remetem ao funcionamento de neurônios biológicos, sendo inspirado no funcionamento do cérebro humano [14]. A Figura 2 exemplifica a arquitetura de uma RNAs, sendo a calibração do modelo obtida pela variação dos pesos, da quantidade dos neurônios e de camadas, de forma a obter o modelo que melhor descreva a variável estudada (*output*) [14].

Abu-Farsakh e Mojumder também aplicaram o algoritmo de RNAs para avaliação da resistência não drenada [15]. Os autores utilizaram os dados de ensaios de CPTu e os Limites de Atterberg para a predição de S_u de diferentes solos naturais argilosos com base em ensaios triaxiais UU [15]. Dentre os principais resultados obtidos pelos autores, a metodologia utilizando RNAs apresentou desempenho superior à metodologia tradicional que utiliza o fator N_{kt} , como apresentado na Figura 3.

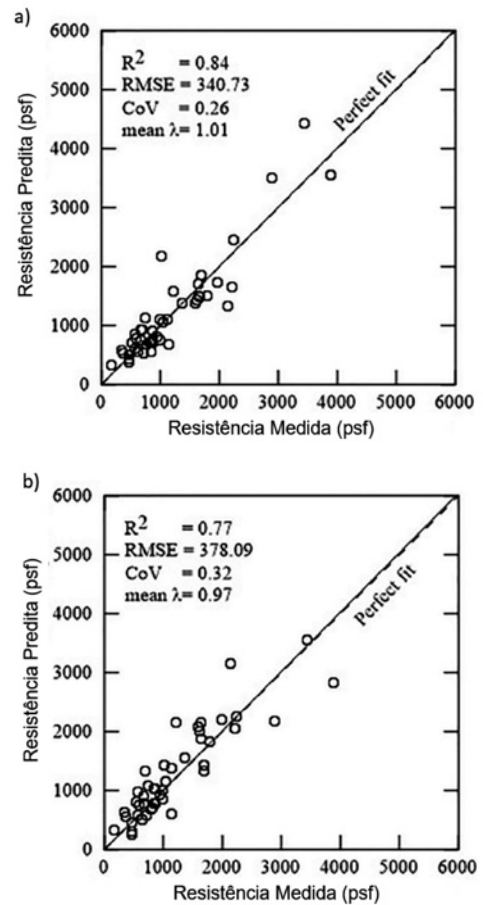


Figura 3 - Aplicação da RNA: a) Resultados obtidos pela RNA; e b) Resultado obtido com a aplicação do N_{kt} . (Adaptado de [15])

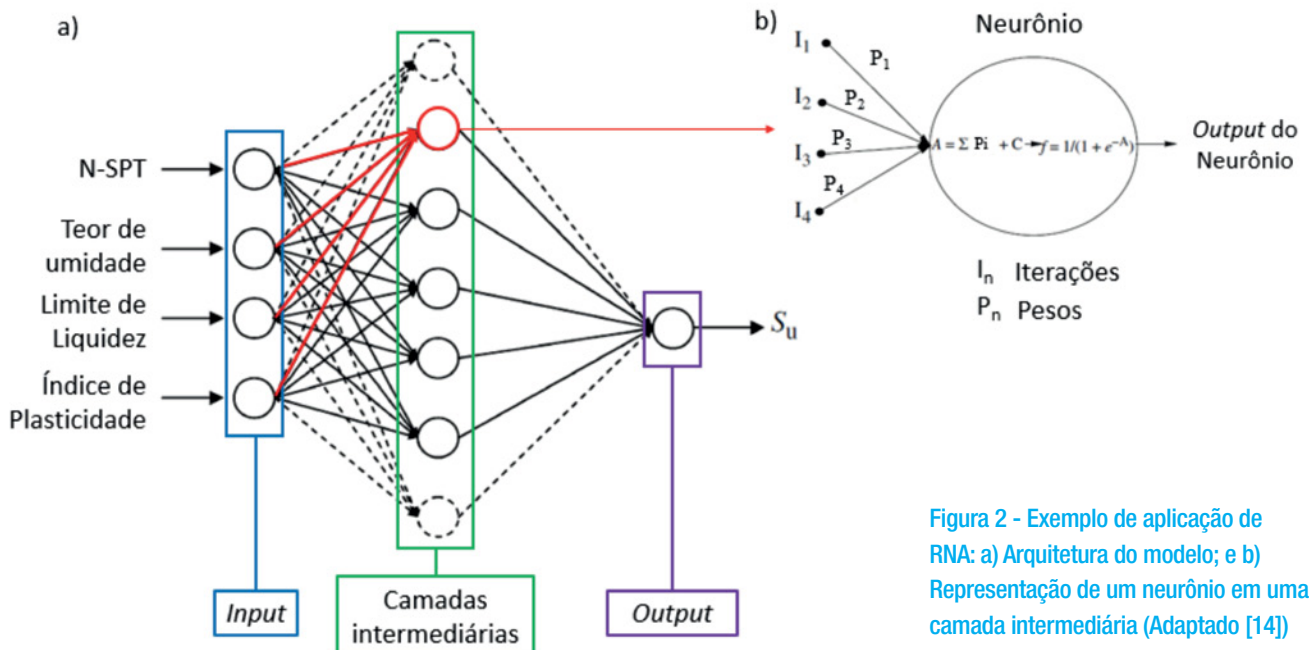


Figura 2 - Exemplo de aplicação de RNA: a) Arquitetura do modelo; e b) Representação de um neurônio em uma camada intermediária (Adaptado [14])

Cabe destacar que até o momento não foram encontradas referências de aplicação da técnica de RNAs para predição da resistência não drenada de rejeitos por meio de ensaios de campo. Mediante o exposto, o objetivo deste estudo é aplicar a técnica de Redes Neurais Artificiais na predição da resistência não drenada de pico de um rejeito de bauxita com base nas variáveis medidas pelo cone (variáveis independentes, *input* da RNA) e nos dados do ensaio de palheta (variável dependente, *output* da RNA). Os resultados obtidos serão comparados com a resistência não drenada obtida por meio da Equação 1.

2. METODOLOGIA

2.1 BANCO DE DADOS

Para o desenvolvimento do estudo, foi utilizado um banco de dados com 11 (onze) pares de verticais de ensaios CPTu e ensaios de palheta associados. Os ensaios foram executados em um depósito de rejeito de bauxita classificado como um material silto-argiloso com a porcentagem de silte variando entre 60% e 80%, sendo o restante de material de granulometria argila e percentual desprezível de areia. Além disso, o rejeito apresenta uma densidade relativa dos grãos de 3,10 ($G_s = 3,10$), sendo um valor típico para rejeitos de bauxita [16].

Os ensaios de CPTu foram filtrados para considerar as mesmas profundidades dos ensaios de palheta associados. Os dados foram tratados sendo os *outliers* multivariados removidos [17]. Sequencialmente, a técnica de Bartlett [18] foi aplicada para verificar a aplicabilidade de técnicas de redes neurais artificiais.

Dessa forma, em linhas gerais, para a elaboração das RNAs foram utilizadas como variáveis independentes àquelas medidas pelo ensaio de CPTu (q_c , f_s e u_2) para determinar a resistência não drenada de pico obtida pelo ensaio de palheta (variável dependente).

2.2 SUBSAMPLING E PADRONIZAÇÃO

O banco total é composto de 84 medições em profundidade, limitados aos ensaios de palheta realizados a cada metro, visto que o ensaio de CPTu forneceu medidas a cada 5 cm. O banco de dados foi dividido em treino e teste. A amostra de treino foi utilizada para gerar o modelo preditor por meio de RNAs e calibrar o N_{kt} . A amostra de teste foi utilizada com vistas a avaliar o desempenho do modelo e comparar com o resultado da Equação 1. Após a retirada dos *outliers* multivariados, foi adotada uma razão de 70% para treino (54 medições) e 30% para teste (16 medições).

Tendo em vista a diferença de magnitude da medição das variáveis de independentes (q_c , f_s e u_2), tais valores foram padronizados utilizando a Equação 4.

$$\text{Medida padronizada} = \left(\frac{\text{medida} - \text{média das medidas}}{\text{desvio padrão das medidas}} \right) \quad (4)$$

2.3 MÉTRICAS DE AVALIAÇÃO DOS MODELOS

Os modelos foram avaliados com base nas métricas de erro: (i) Erro Médio Absoluto (*Mean Absolute Error* – MAE); (ii) Erro Médio Absoluto ao Quadrado (MSE); e (iii) Coeficiente de Determinação (R^2), como apresentado nas Equações 5 a 7, sendo n o número de medições, y_i o valor real, \hat{y} o valor médio e \hat{y} o valor predito.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5)$$

$$MAE = \frac{1}{n} * \sum_{i=1}^n |y_i - \hat{y}_i| \quad (6)$$

$$MSE = \frac{1}{n} * \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (7)$$

2.4 REDES NEURAIS

A rede neural foi construída com três camadas, sendo uma camada para a entrada dos dados, uma camada intermediária e uma camada para os dados de saída, com estrutura similar à apresentada por [14]. A determinação do número de neurônios da camada intermediária foi obtida por variações do número de neurônios objetivando minimizar o R^2 (Equação 5). A modelagem do algoritmo de redes neurais foi realizada em linguagem de programação Python [19].

3. DISCUSSÃO DOS RESULTADOS

A Figura 4 apresenta os resultados em profundidade das medidas obtidas pelo ensaio de CPTu, compatibilizado com a resistência não drenada obtida por meio do ensaio de palheta. Como pode ser observado, os dados de resistência de ponta e poropressão são diretamente proporcionais à profundidade, assim como à resistência não drenada.

Aplicando-se o teste de Bartlett foi obtido um p-valor de $1,76 \times 10^{-178}$ com 4 graus de liberdade (número de variáveis) e uma estatística χ^2 igual a 9,48, utilizando um nível de significância

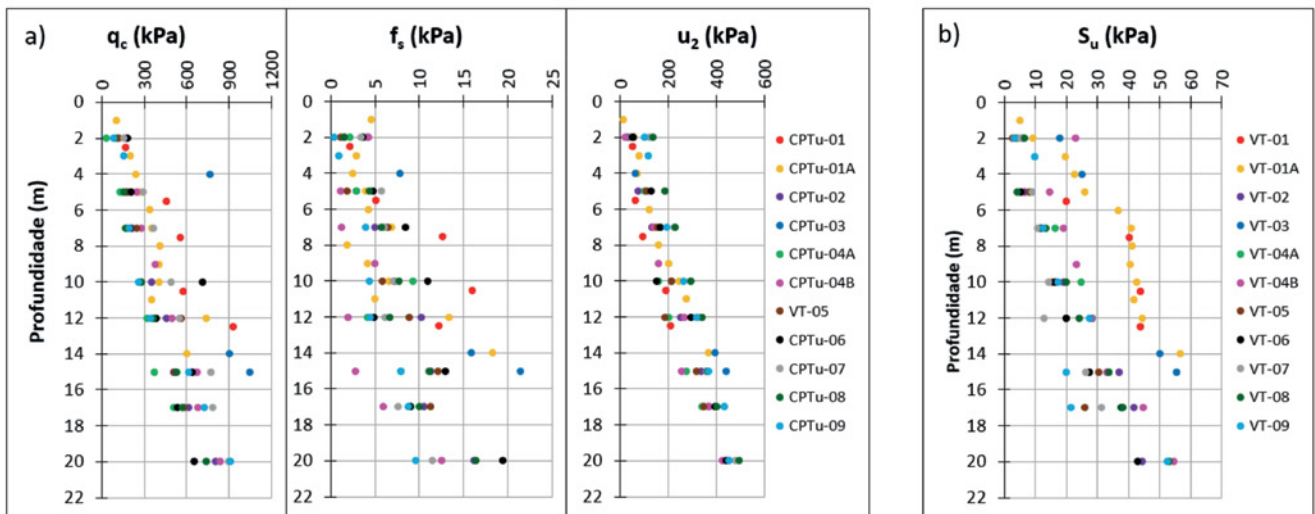


Figura 4 – Resultados dos ensaios de campo: a) CPTu; e b) Vane

de 5% (intervalo de confiança de 95%). Dessa forma, como o p-valor é menor que o nível de significância adotado para o teste de hipótese ($1,76 \times 10^{-178} \ll 0,005$), a técnica de redes neurais pode ser aplicada.

Sequencialmente, aplicando-se a técnica de remoção de outlier multivariado, foi obtido o banco final a ser utilizado na modelagem. Aplicando-se a Equação 1, no banco treino (70% do banco sem outliers multivariados), foi obtido um valor de N_{kt} aproximadamente igual à 11, como apresentado na Figura 6.

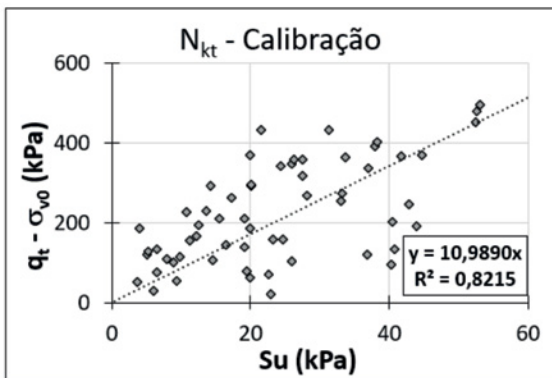
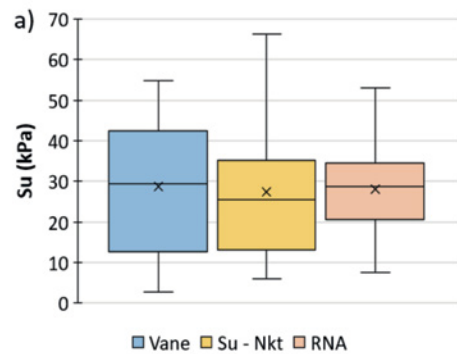


Figura 6 – Calibração do N_{kt}

Com base no processo de calibração do modelo de RNAs (otimização do R^2), foram adotados 6 neurônios para a camada intermediária. Após a calibração do modelo empírico e do modelo obtido por meio de rede neural, o banco de teste foi utilizado para a avaliação dos modelos gerados. A Figura 7a apresenta os boxplots e a Figura 7b demonstra o resumo estatístico dos

resultados da resistência não drenada do rejeito de bauxita obtidos pela RNA, N_{kt} igual a 11, em comparação com os valores medidos pelo ensaio de palheta. Como pode ser observado, o modelo de RNA apresentou menor dispersão do que os valores obtidos via N_{kt} e obtidos pelo ensaio de palheta.



b)

| Legenda | Vane | $S_u - N_{kt}$ | RNA |
|----------|-------|----------------|-------|
| Cor | | | |
| Máx. | 54,69 | 66,26 | 52,94 |
| Q75 | 42,34 | 35,22 | 34,53 |
| Mediana | 29,39 | 25,39 | 28,75 |
| Média | 28,79 | 27,49 | 28,16 |
| Q25 | 12,65 | 13,11 | 20,48 |
| Min. | 2,68 | 6,03 | 7,47 |
| σ | 16,95 | 18,15 | 13,50 |
| C.V. | 58,9% | 66,0% | 47,9% |

Figura 7 – Resultados obtidos: a) boxplot; e b) resumo estatístico de S_u

Os modelos foram avaliados de acordo com as métricas MAE, MSE e R^2 . Com base nos resultados apresentados na Figura 8, observa-se que o modelo de RNAs apresentou o menor valor de MAE e MSE, indicando uma menor dispersão dos valores de resistência não drenada preditos em relação aos medidos quando comparado com os valores obtidos via N_{kt} .

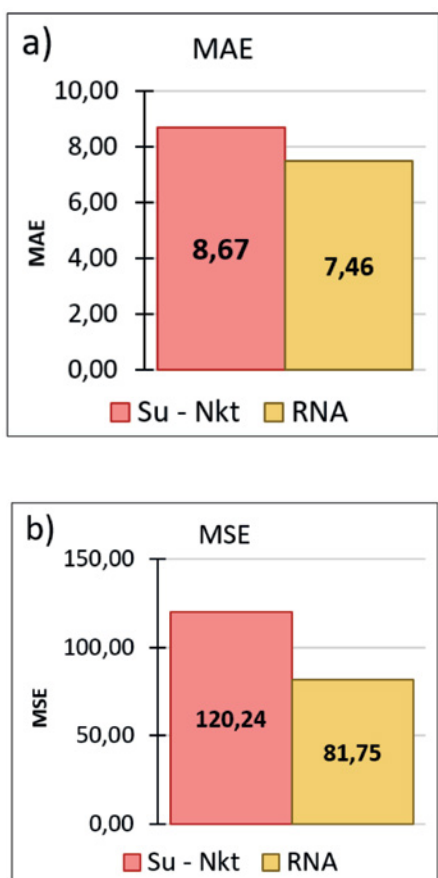


Figura 8 – Valores de MAE, MSE obtidos na modelagem

A Figura 9 apresenta a comparação dos valores medidos pelo ensaio de palheta (eixo das ordenadas) e os valores preditos pelos modelos (eixo das abscissas), sendo possível observar que o algoritmo de redes neurais obteve um R^2 superior ao modelo convencional, sendo 0,93 versus 0,89, respectivamente. Apesar da diferença dos materiais estudados, os resultados apresentados na Figura 9 se assemelham com o obtido por Abu-Farsakh e Mojumder [15], como mostrado na Figura 3, sendo o algoritmo de RNA com R^2 superior a metodologia utilizando o N_{kt} .

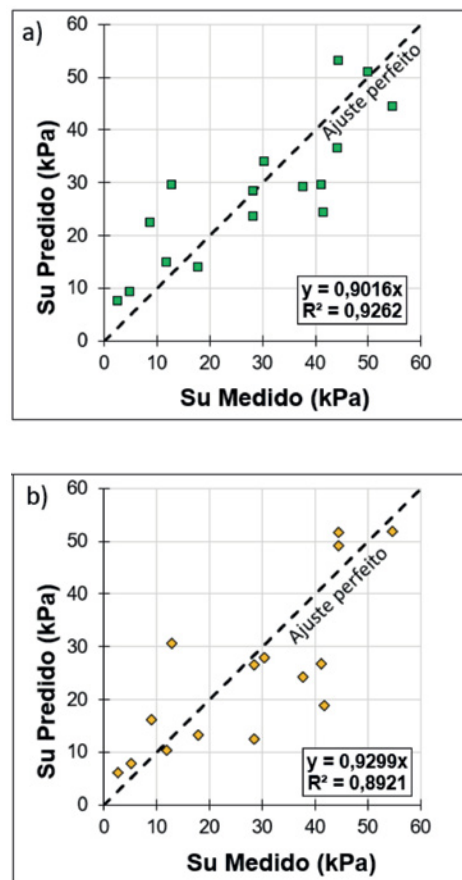


Figura 9 – Comparação dos resultados obtidos nas modelagens: a) RNA; b) N_{kt}

4. CONCLUSÕES

O algoritmo de RNAs aplicado no rejeito de bauxita em estudo obteve desempenho superior a metodologia clássica baseada no fator N_{kt} , sendo obtidos resultados com maior acurácia (maior R^2) e menor dispersão (menor MAE e MSE). Tais conclusões também foram observadas na literatura para solos naturais no trabalho de Abu-Farsakh e Mojumder [15]. Cabe destacar que a aplicação de tais técnicas possibilita a utilização de outras variáveis, como peso específico na definição da resistência não drenada, permitindo um refinamento dos resultados. Por fim, a aplicação de técnicas de ciência de dados, em especial técnicas de aprendizado de máquina, podem auxiliar na criação de modelos específicos para cada material de forma acurada, sendo essa uma alternativa à utilização de modelos empíricos.

5. PALAVRAS-CHAVE

Rejeitos de Bauxita, Redes Neurais Artificiais (RNAs), resistência não drenada, N_{kt} , CPTu.

6. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] TURI, DAVID; PUSZTAI, JOZSEF; AND NYARI, ISTVAN, (2013) "Causes and Circumstances of Red Mud Reservoir Dam Failure In 2010 at MAL Zrt Factory Site in Ajka, Hungary". International Conference on Case Histories in Geotec. Eng. 10.
- [2] JEFFERIES M; MORGENSTERN, N. R.; ZYL, D.V.; WATES, J.; (2019) "Report on NTSF Embankment Failure Cadia Valley Operations for Ashurst Australia". H356804-00000-22A-230-0001.
- [3] MORGENSTERN, N. R.; VICK, S. G. VIOTTI C. B. WATTS, B. D.; (2016) "Fundão Tailings Dam Review Panel Report on the Immediate Causes of the Failure of the Fundão Dam".
- [4] ROBERTSON P. K.; MELO L.; WILLIAMS, D. J.; WILSON, W. G. (2019) "Report of the Expert Panel on the Technical Causes of the Failure of Feijão Dam I".
- [5] GLOBAL INDUSTRY STANDARD ON TAILINGS MANAGEMENT – GISTM (2020), Global Tailings Review, International Council on Mining & Metals (ICMM), UN Environment Programme (UNEP) and Principles for Responsible Investment (PRI).
- [6] DAS, BRAJA M. (2007) "Fundamentos de Engenharia Geotécnica". 6. ed. Thomson
- [7] SCHNAID, F. (2009) "In situ testing in geomechanics: the main tests". Oxon: Taylor & Francis Group.
- [8] AMERICAN SOCIETY FOR TESTING AND MATERIALS - ASTM (2020) D5778: "Standard Test Method for Electronic Friction Cone and Piezocone Penetration Testing of Soils." West Conshohocken, PA 19428-2959.
- [9] ROBERTSON, P.K. & CABAL, K.L. (2015) "Guide to Cone Penetration Testing for Geotechnical Engineering". 6th Ed. Signal Hill, CA: Gregg Drilling & "Testing, Inc.
- [10] LUNNE, T.; ROBERTSON, P.K. & POWELL, J.J.M. (1997) Cone Penetration Testing in Geotechnical Practice". 1ª Edition. Abingdon: E & FNSpon Press.
- [11] HERZA, J; ASHLEY M.; THORP J.; (2017) "Factor of Safety? - Do we use it correctly?" In Proceedings ANCOLD.
- [12] ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. (1989) NBR 10905: Solo — Ensaio de Palheta in situ. Rio de Janeiro.
- [13] SCHNAID, F. & ODEBRECHT, E. (2012) "Ensaio de campo e suas aplicações à engenharia de fundações". São Paulo: Oficina de Textos.
- [14] SIVRIKAYA, O. (2009) "Comparison of Artificial Neural Networks models with correlative works on undrained shear strength". Eurasian Soil Sc. 42, 1487.

[15] ABU-FARSAKH, M.Y.; MOJUMDER, M.A.H. (2020) "Exploring artificial neural network to evaluate the undrained shear strength of soil from cone penetration test data." Transp. Res. Rec. J. Transp. Res. Board. 2674, 11–22.

[16] FOURIE, A; REID, D.; AYALA, J.; RUSSEL, A.; VO, T.; RAHMAN, M.; (2015) "Improvements in estimating strengths of loose sandy and silty tailings: first results from the TAILLIQ research project." Proceedings. Mine Waste and Tailings, AusIMM, Brisbane, Australia, 207-217.

[17] FILZMOSE P. (2004). "A multivariate outlier detection method." In Proceedings of the seventh international conference on computer data analysis and modeling, vol 1. Belaru-sian State University, Minsk,18–22.


[18] BARTLETT M.S., (1951) "The effect of standardization on a chi square approximation in factor analysis." Biometrika, 38:337–44.

[19] VAN ROSSUM, G., & DRAKE JR, F. L. (1995) "Python reference manual. Centrum voor Wiskunde en Informatica Amsterdam".




Guilherme Henrique da Silva PINTO

É Engenheiro Júnior na Pimenta de Ávila Consultoria. Possui graduação em Engenharia Civil pela Universidade Federal de Minas Gerais. É mestrando no programa de Pós-graduação de Engenharia Mineral da Universidade Federal de Ouro Preto. Possui experiência em interpretação de ensaios de campo e laboratório, elaboração de análises de estabilidade e interpretação de instrumentação geotécnica.



Hugo Assis BRANDÃO

É Coordenador do Comitê Técnico e Núcleo de Inovação na Pimenta de Ávila. Possui graduação em Engenharia Civil pela UFMG, Pós-graduação em Engenharia de Barragens pela PUC-MG e em Gestão de Projetos pela FGV. É mestrando no programa de Pós-graduação em Engenharia Mineral da UFOP. Possui experiência em Geotecnia, projetos de barragem de rejeito e barragens de água, pilhas de rejeito e aprendizado de máquina.



Tatiana Barreto SANTOS

É Professora Adjunta do Departamento de Engenharia de Minas da Escola de Minas da Universidade Federal de Ouro Preto e dos Programas de Pós-graduação em Engenharia Mineral (PPGEM) e Geotecnia (NUGEO). Possui graduação em Engenharia de Minas pela UFOP, e os títulos de Mestre em Engenharia Mineral pela UFOP e Doutora em Engenharia Mineral na UFOP, com período sanduíche na *University Of New South Wales* (Sydney, Austrália). Tem experiência em Geotecnia de mineração, mecânica das rochas e aprendizado de máquina.