

Previsão do comportamento filtrante de geotêxteis em solos internamente instáveis utilizando rede neural artificial e métodos de regressão multivariada

Katherine Mirella Flores Bellido

Estudante, Universidade de Brasília, Brasília, Brasil, katherine.mirella.flores@gmail.com

Ennio Marques Palmeira

Professor, Universidade de Brasília, Brasília, Brasil, palmeira@unb.br

Francisco Evangelista

Professor, Universidade de Brasília, Brasília, Brasil, fejr@unb.br

RESUMO: O uso de filtros geotêxteis em atividades de engenharia geotécnica e proteção ambiental tem sido crescente nas últimas décadas devido às vantagens na execução de empreendimentos e na preservação ambiental, reduzindo o uso de materiais naturais como areia e brita. No entanto, preocupações sobre seu desempenho a longo prazo, como a redução de permeabilidade e colmatagem, persistem. O comportamento do filtro é influenciado por diversas condições, especialmente o tipo de solo, sobretudo em solos internamente instáveis, onde a sufusão pode comprometer o desempenho do filtro. Portanto, é necessário buscar métodos alternativos de previsão de comportamento sob tais condições. Este artigo propõe o uso de Rede Neural Artificial (RNA) para prever a permeabilidade do sistema solo-geotêxtil com base em 352 resultados obtidos em pesquisas. Foi utilizada uma arquitetura de Perceptron Multicamada (PMC) para configurar o modelo e adotou-se o algoritmo de Retropropagação (RP). Além disso, foi realizada regressão multivariada (RM) para estimar a permeabilidade e correlacionar as propriedades do solo com as do filtro. A acurácia dos métodos RNA e RM foi comparada por meio de erros estatísticos. O potencial desses métodos para prever o desempenho de sistemas solo-filtro geotêxtil em condições internamente instável mostrou-se satisfatório.

PALAVRAS-CHAVE: Rede Neural Artificial (RNA), Geotêxtil, Solos instáveis, Regressão Multivariada (RM)

ABSTRACT: The use of geotextile filters in geotechnical engineering and environmental protection activities has been increasing in recent decades due to the advantages in project execution and environmental preservation, reducing the use of natural materials such as sand and gravel. However, concerns about their long-term performance, such as reduced permeability and clogging, persist. The behavior of the filter is influenced by various conditions, especially soil type, particularly in internally unstable soils, where suffusion can compromise filter performance. Therefore, it is necessary to seek alternative methods for predicting behavior under such conditions. This article proposes the use of Artificial Neural Network (ANN) to predict the permeability of the soil-geotextile system based on 352 research results. A Multilayer Perceptron (MLP) architecture was used to configure the model, and the Backpropagation (BP) algorithm was adopted. In addition, multivariate regression (MR) was performed to estimate permeability and correlate soil properties with those of the filter. The accuracy of the ANN and MR methods was compared using statistical errors. The potential of these methods to predict the performance of soil-geotextile filter systems under internally unstable conditions proved satisfactory.

KEYWORDS: Artificial Neural Network (ANN), Geotextile, Unstable Soils, Multivariate Regression (MR)

1 INTRODUÇÃO

O uso de filtros geotêxteis em atividades de engenharia geotécnica e proteção ambiental tem sido crescente ao longo das últimas décadas devido às várias vantagens que sua utilização apresenta. Isso ocorre tanto durante a execução de um empreendimento, com maior facilidade no transporte e instalação, quanto nos aspectos ambientais, ao evitar ou reduzir o uso de materiais naturais como areia e brita, favorecendo a conservação do meio ambiente. Assim, tais filtros oferecem vantagens econômicas e ambientais, pois segundo Frischknecht et al. (2012), um filtro geotêxtil reduz o impacto ambiental em mais de 80% em comparação com os filtros de areia. No entanto, a sua aplicação em projetos maiores e complexos ainda apresenta certos obstáculos, sendo importante entender melhor o seu desempenho a longo prazo sob condições que possam causar um mau desempenho (Palmeira, 2018).

De forma geral, o sistema solo/filtro geotêxtil, na sua condição estável, deve atender aos critérios de retenção, permeabilidade, anticolidação e sobrevivência e durabilidade. Ao garantir o cumprimento desses critérios, a probabilidade do filtro geotêxtil apresentar problemas no seu desempenho ao longo da sua vida útil é muito baixa (Khan et al., 2022; Palmeira, 2018).

Com o aumento da utilização de geotêxteis, inúmeros estudos foram realizados para entender a interação entre o solo, fluidos e filtros geotêxteis e garantir os critérios mencionados acima. Porém, certos aspectos ainda exigem investigações abrangentes para compreender melhor o desempenho desses filtros. Um estudo realizado por Qureshi et al. (1990) apresenta resultados nos quais obteve-se redução significativa do coeficiente de permeabilidade do sistema solo-geotêxtil, para um solo internamente instável, e sugere que as reduções foram causadas pela impregnação dos vazios do geotêxtil por partículas do solo em contato. Outro estudo realizado por Koerner & Koerner (2015) apresentou as possíveis falhas que levaram a um comportamento inadequado do sistema solo/geotêxtil. Entre essas falhas, encontra-se o contato entre o filtro com solos atípicos, especialmente solos internamente instáveis, os quais são solos de graduação ampla que se caracterizam por ter uma curva granulométrica com concavidade voltada para cima ou solos mal graduados (gap grapped). Estes tipos de solos podem sofrer sufusão, com consequências danosas para o desempenho do filtro, reduzindo a permeabilidade do sistema solo/geotêxtil (Chang & Zhang, 2013; Koerner & Koerner, 2015; Palmeira, 2018). Diante do exposto, a procura por métodos alternativos para prever o comportamento do sistema solo-geotêxtil sob tais condições torna-se importante para a engenharia geotécnica.

Com o crescente uso de ferramentas avançadas computacionais, o uso de inteligência artificial (IA) vem se tornando bem-sucedido nos diferentes setores da engenharia geotécnica, devido a sua eficácia na análise de previsões de relações não lineares. Trata-se de uma solução para elaboração de modelos de previsão mais precisos em comparação com o uso de métodos tradicionais. Entre os métodos de IA utilizados, as Redes Neurais Artificiais (RNA) parecem ser as mais amplamente utilizadas e preferidas, compreendendo 52% dos estudos revisados (Baghbani et al., 2022).

Por outro lado, o uso de análises de regressão multivariada vem apresentando, também, previsões acuradas devido a sua capacidade de aproximar e expressar de forma matemática a relação entre os parâmetros envolvidos, sendo capaz de gerar modelos de fácil interpretação em problemas geotécnicos nos quais existem relações mais complexas entre as variáveis envolvidas.

O presente artigo visa utilizar os métodos apresentados acima para estimar a permeabilidade de um conjunto solo/geotêxtil e correlacionar as propriedades do solo a ser estudado (internamente instável) e as propriedades do filtro, com a finalidade de obter uma previsão mais acurada do desempenho do geotêxtil. Foram considerados um total de 352 dados de entrada (permeabilidade final do sistema solo/geotêxtil) e 7 parâmetros que influenciam para cada permeabilidade registrada. O objetivo desta investigação é avaliar o desempenho do algoritmo de treinamento de Retropropagação (RP) da Rede Neural Artificial (RNA) e definir a metodologia de regressão multivariada para futuros trabalhos.

2 METODOLOGIA

Apresentam-se os conceitos e dados a serem adotados nas metodologias aplicadas para as análises de previsão de permeabilidade do geotêxtil.

2.1 Rede Neural Artificial (RNA)

De acordo com Fausset (1994), uma RNA tem três componentes principais: o neurônio, a arquitetura da rede e a regra de aprendizagem. O neurônio, o componente mais básico da rede, é o elemento que compõe as camadas e está conectado a outros por meio de conexões (sinapses). Estas conexões possuem informações que podem ajudar na solução. Já a arquitetura da rede estabelece o número de neurônios, as conexões presentes entre eles e as disposições deles; e, por último, a regra define os algoritmos que serão utilizados para analisar o problema.

As redes multicamadas (PMC) são uma das arquiteturas mais utilizadas para previsão de resultados. Este tipo organiza os neurônios em camadas, com camadas intermediárias (hidden layers) entre os dados de entrada (input) e o dado de interesse ou saída (output).

Cabe destacar alguns tipos de redes neurais: Hopfield Network, Backpropagation Network (BPN), ART Network (Adaptive Resonance Theory) e General Method of Data Handling (GMDH). A rede Backpropagation é uma das mais utilizadas para modelos de previsão e caracteriza-se por ser composta de uma camada de entrada (dados disponíveis), uma camada de saída (variável de interesse) e por uma ou mais camadas ocultas para análise não linear (Chao et al., 2021). Esse algoritmo funciona por meio de processos iterativos (épocas), onde as camadas intermediárias e de saída recebem e analisam cada resultado das entradas anteriores (X_i) afetadas por pesos sinápticos (w_i) e bias (θ_o), e posteriormente processadas através de uma função de ativação, conforme a Equação 1:

$$y = f\left(\sum_{i=1}^n X_i w_i + \theta_o\right) \quad (1)$$

A função de ativação tem como finalidade aproximar os valores de saída em função dos valores de entrada (inputs). Na Figura 1 apresenta-se o fluxograma da aplicação da metodologia.

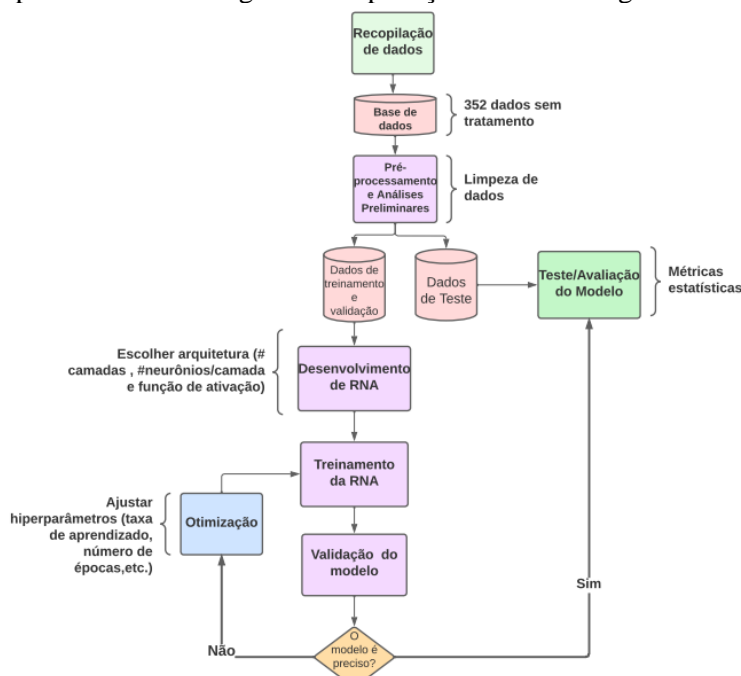


Figura 1. Fluxograma da metodologia de RNA

2.2 Regressão Multivarida (MRM)

A análise multivariada é frequentemente utilizada em estudos de engenharia geotécnica, onde é necessário compreender as interações entre diferentes propriedades do solo, como resistência, permeabilidade, densidade, entre outras. Essa análise pode ser aplicada em diferentes contextos, como projetos de fundações, estabilidade de taludes, comportamento de aterros, entre outros.

A técnica de Regressão Linear Múltipla (técnica de dependência) foi aplicada em trabalhos de geotecnia (Habibi et al., 2014; Khanlari et al., 2012; Pinto, 2023; A. E. M. Santos, 2021; Tiryaki, 2008; Williams & Ojuri, 2021). Este tipo de análise é uma técnica estatística usada para entender a relação entre uma variável dependente e diversas variáveis independentes. Seu objetivo é usar os valores conhecidos das variáveis independentes para prever os valores da variável dependente escolhida. Cada variável independente é ponderada durante o processo de análise de regressão para garantir uma previsão eficaz baseada no conjunto delas. Esses pesos representam a contribuição relativa de cada variável independente para a previsão final, mas interpretar sua influência pode ser desafiador quando há correlação entre as variáveis independentes. A combinação ponderada das variáveis independentes forma a variável estatística de regressão, também chamada de equação ou modelo de regressão. Esse modelo (Equação 2) representa uma variável estatística fundamental nas técnicas multivariadas (Charnet et al., 2008).

$$Y = \beta_0 + \beta_1x_1 + \beta_2x_2 + \dots + +\beta_px_p + \epsilon \quad (2)$$

Onde Y é a variável dependente ou variável que se deseja prever; β_p são variáveis independentes; β_0 é o intercepto; β_p é o coeficiente de regressão parciais; e ϵ , é o erro.

Este modelo deve ser avaliado por meio de diferentes critérios para garantir sua eficiência, entre eles: significância, linearidade, homoscedasticidade dos resíduos e normalidade dos resíduos (Charnet et al., 2008). No caso de a variável dependente não seguir uma distribuição normal, devem ser adotadas técnicas que ajustem a distribuição de dados para uma normal (Habibi et al., 2014). É importante destacar que os dados nem sempre apresentam propriedades de linearidade, sendo necessário adotar Métodos de Regressão Não-Linear como modelo logarítmico, de potência, entre outros. Vários trabalhos na área da geotecnia adotaram esses métodos (Habibi et al., 2014; Khanlari et al., 2012; Mohammadi et al., 2022; Tiryaki, 2008). Na Figura 2, apresenta-se o fluxograma com aplicação da metodologia de regressão multivariada.

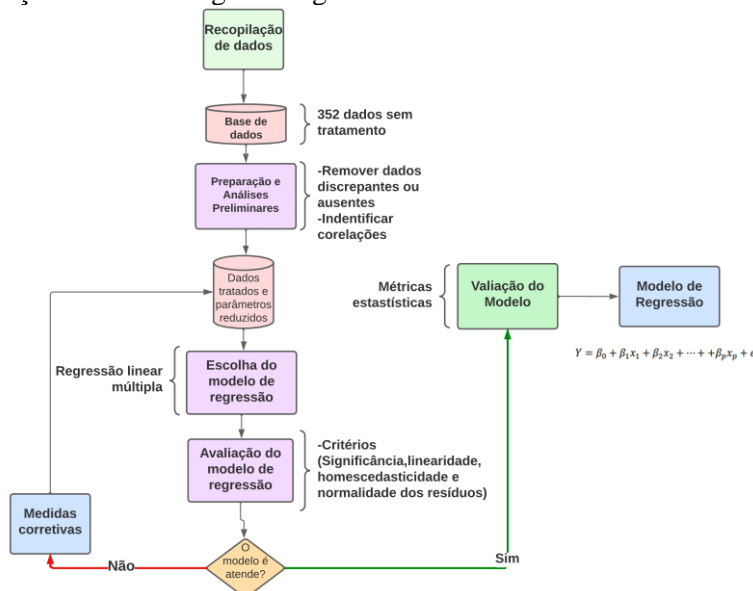


Figura 2. Fluxograma da metodologia de MR.

3 ANÁLISES DE DADOS

Os dados de entrada (*input*) e os valores de permeabilidade final do sistema foram definidos com base nos resultados obtidos de investigações anteriores realizadas por diferentes autores. Foram coletadas 352 amostras, que incluem parâmetros que influenciam na permeabilidade do sistema solo/geotêxtil. A Tabela 1 de Parâmetros e variáveis de interesse apresenta os dados estatísticos dos parâmetros de entrada utilizados. Cabe destacar que o tipo de geotêxtil foi atribuído um valor de 0 ou 1, sendo 1 quando o geotêxtil é do tipo tecido ou não tecido quando for utilizado, respectivamente.

Tabela 1. Parâmetros e variáveis de interesse.

Tipo de parâmetros/ Variáveis	Parâmetros
Parâmetros de Entrada (<i>Input</i>)/Independentes	Tipo de Geotêxtil (WG/NWG); D_{10} ; D_{15} ; D_{30} ; D_{50} ; D_{60} ; D_{85} ; C_c ; C_u ; T_{GT} ; M_A ; FOS; LS; i_{sys} ; σ_v , k_{sys-o}
Parâmetros de Saída (<i>Output</i>)/Dependentes	k_{sys}

WG=Woven geotextile, WG=Nowoven geotextile, D_{xx} =Diâmetro de partícula do solo base para xx% de passagem, C_c : C=coef. de curvatura C_u =coef. de uniformidade, T_{GT} =espessura do geotêxtil, M_A =gramatura do geotêxtil, FOS= abertura de filtração do geotêxtil, LS=espessura do corpo de prova; i_{sys} = gradiente hidráulico do sistema (solo-geotêxtil), σ_v =tensão vertical, k_{sys-o} = Coeficiente de permeabilidade inicial do sistema solo- geotêxtil, k_{sys} = Coeficiente e permeabilidade final do sistema solo- geotêxtil.

Conforme explicado na Figura 1, é necessário realizar uma divisão dos dados para validar o modelo da RNA. Portanto, os dados são divididos em dois grupos para duas fases distintas: a fase de treinamento e a fase de teste. Na fase de treinamento, o objetivo é permitir que a rede neural aprenda, estabelecendo os pesos sinápticos necessários. Por outro lado, na fase de teste, o propósito é validar o modelo e determinar se a rede neural prevê corretamente o resultado desejado. Neste artigo, 70% dos dados totais foram alocados para a fase de treinamento, enquanto os restantes 30% foram reservados para a fase de teste.

4 RESULTADOS E DISCUSSÃO

Foi adotado para este trabalho uma arquitetura de RNA composta por 7 neurônios de entrada (D_{50} ; D_{60} ; C_u ; T_{GT} ; M_A ; FOS/ D_{30} e k_{sys-o}), 2 camadas intermediárias (*hidden layers*) e uma neurônio de saída (k_{sys-o}). Na Figura 3, se apresenta o gráfico de correlação entre os valores de coeficiente permeabilidade final (K_{sys}) recopilados da literatura (valores observados) e os valores previstos pela rede neural para fase de treinamento e de teste, respectivamente.




Figura 3. Correlação dos valores observados e os valores previstos pela RNA nas duas fases (Treinamento e Teste)

Na Tabela 2, estão apresentados os valores do erro MSE (erro quadrático médio), MAPE (erro percentual médio absoluto) e R^2 (coeficiente de determinação). É importante ressaltar que, para os erro MSE, valores

mais próximos de 0 indicam melhor desempenho do modelo. Já para o R^2 , valores próximos a 1 representam melhor funcionalidade do modelo.

Tabela 2. Valores de erros estatísticos para a rede neural com 7 inputs.

Erro/Fase	7 inputs
R^2 treinamento	0.89
R^2 teste	0.94
MSE treinamento	0.364
MSE teste	0.316
MAPE treinamento	7.93%
MAPE teste	8.26%

De acordo com a Tabela 2, os valores de R^2 para treinamento e teste foram de 0,89 e 0,94, respectivamente. Isso sugere que o modelo demonstrou um bom desempenho em termos de previsão. Quanto aos erros, tanto os valores de treinamento quanto os de teste exibem um bom ajuste, com o valor de MSE próximo de zero. Além disso, para a análise do erro percentual absoluto, ambas as fases apresentam valores inferiores a 10%, indicando uma boa previsão precisa proporcionada pelo modelo de RNA adotado.

5 CONCLUSÕES

Este estudo investigou a eficácia de uma Rede Neural Artificial com algoritmo de treinamento RP na previsão do comportamento do geotêxtil em contato com solos internamente instáveis, utilizando os valores de permeabilidade do sistema solo-geotêxtil. Os resultados destacam que o modelo da RNA proporciona boas previsões dos valores de permeabilidade encontrados na literatura, como evidenciado pela precisão em relação aos erros de correlação estatística. Isso sugere que o modelo desenvolvido pode ser uma ferramenta confiável de previsão. Entretanto, é importante ressaltar que o modelo é válido somente para parâmetros de entrada dentro das faixas predefinidas e para solos com comportamento internamente instável. Além disso, este estudo serve como base para futuras investigações sobre o uso de outros métodos de previsão do comportamento do geotêxtil, como métodos de regressão multivariada.

AGRADECIMENTOS

Em agradecimento ao Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq pelo apoio financeiro para o desenvolvimento do artigo.

REFERÊNCIAS BIBLIOGRÁFICAS

Baghbani, A., Choudhury, T., Costa, S., & Reiner, J. (2022). Application of artificial intelligence in geotechnical engineering: A state-of-the-art review. Em *Earth-Science Reviews* (Vol. 228). Elsevier B.V. <https://doi.org/10.1016/j.earscirev.2022.103991>

Chang, D. S., & Zhang, L. M. (2013). Extended internal stability criteria for soils under seepage. *Soils and Foundations*, 53(4), 569–583. <https://doi.org/10.1016/j.sandf.2013.06.008>

Chao, Z., Fowmes, G., & Dassanayake, S. M. (2021). Comparative Study of Hybrid Artificial Intelligence Approaches for Predicting Peak Shear Strength Along Soil-Geocomposite Drainage Layer Interfaces. *International Journal of Geosynthetics and Ground Engineering*, 7(3). <https://doi.org/10.1007/s40891-021-00299-2>

Charnet, R., Freire, C. A. de F., Bonvino, H., & Charnet, E. M. R. (2008). *Análise de Modelos de Regressão Linear com Aplicações* (2º ed). UNICAMP.

Habibi, M. J., Mokhtari, A. R., Baghbanan, A., & Namdari, S. (2014). Prediction of permeability in dual fracture media by multivariate regression analysis. *Journal of Petroleum Science and Engineering*, 120, 194–201. <https://doi.org/10.1016/j.petrol.2014.06.016>

Khan, M. W., Dawson, A. R., & Marshall, A. M. (2022). Filtration performance of non-woven geotextiles with internally-stable and -unstable soils under dynamic loading. *Geotextiles and Geomembranes*, 50(2), 293–311. <https://doi.org/10.1016/j.geotexmem.2021.11.007>

Khanlari, G. R., Heidari, M., Momeni, A. A., & Abdilor, Y. (2012). Prediction of shear strength parameters of soils using artificial neural networks and multivariate regression methods. *Engineering Geology*, 131–132, 11–18. <https://doi.org/10.1016/j.enggeo.2011.12.006>

Koerner, R. M. (2016). *Geotextiles: From Design to Applications*. (1^o ed). Woodhead Publishing.

Koerner, R. M., & Koerner, G. R. (2015). Lessons learned from geotextile filter failures under challenging field conditions. *Geotextiles and Geomembranes*, 43(3), 272–281. <https://doi.org/10.1016/j.geotexmem.2015.01.004>

Palmeira, E. M. (2018). *Geossintéticos em geotecnia e meio ambiente* (1^o ed). Oficina de Textos.

Palmeira, E. M. (2023). Geotextile filters. From idealization to real behaviour. *12th International Conference on Geosynthetics*, 1–40.

Palmeira, E. M., Gardoni, M. G., & Bessa Da Luz, D. W. (2005). Soil-geotextile filter interaction under high stress levels in the gradient ratio test. *Geosynthetics International*, 4(12), 162–175.

Palmeira, E. M., & Trejos Galvis, H. L. (2018). Evaluation of predictions of nonwoven geotextile pore size distribution under confinement. *Geosynthetics International*, 25(2), 230–241. <https://doi.org/10.1680/jgein.18.00004>

Pinto, G. H. da S. (2023). *Proposta de modelos de predição da resistência não drenada de rejeitos de bauxita* [Dissertação de Mestrado]. Universidade Federal de Ouro Preto.

Santos, A. E. M. (2021). *Classificação de maciços rochosos por meio de técnicas de estatística multivariada e inteligência artificial* [Tese de Doutorado]. Universidade Federal de Ouro Preto.

Santos, D. (2023). *Comportamento de filtros geotêxteis em solos internamente instáveis sob confinamento* [Dissertação de Mestrado]. Universidade de Brasília.

Sardehaei, E. A., & Mehrjardi, G. T. (2020). Winter 2020 Downloaded from jeg. Em *Journal of Engineering Geology* (Vol. 13, p. 1–22).

Tiryaki, B. (2008). Predicting intact rock strength for mechanical excavation using multivariate statistics, artificial neural networks, and regression trees. *Engineering Geology*, 99(1–2), 51–60. <https://doi.org/10.1016/j.enggeo.2008.02.003>

Williams, C. G., & Ojuri, O. O. (2021). Predictive modelling of soils' hydraulic conductivity using artificial neural network and multiple linear regression. *SN Applied Sciences*, 3(2). <https://doi.org/10.1007/s42452-020-03974-7>

Zhang, R. (2006). *Efficient Sequential and Batch Learning Artificial Neural Network Methods for Classification Problems*.