XXII Congresso Brasileiro de Mecânica dos Solos e Engenharia Geotécnica
XI Simpósio Brasileiro de Engenheiros Geotécnicos Jovens
24 a 28 de agosto de 2026 – Brasília/DF

DOI: 10.47094/COBRAMSEG2026.2/4

Análises probabilísticas de estabilidade de taludes grampeados utilizando campos aleatórios baseados em aprendizado profundo

Lucas de Jesus Souza
Mestrando em Eng. Geotécnica, Escola Politécnica – Universidade de São Paulo (USP), São Paulo, Brasil, lsouza.pmo@usp.br

Adrian Torrico Siacara
Professor em Eng. Civil – Geotécnica, Escola Politécnica – Universidade de São Paulo (USP), São Paulo, Brasil, adrian.torrico@usp.br

RESUMO: A estabilidade de taludes é um tema central na engenharia geotécnica, especialmente em obras como barragens, cortes rodoviários e escavações. Fatores como heterogeneidade do solo, condições hidráulicas e incertezas nas propriedades mecânicas tornam essencial o uso de abordagens probabilísticas para uma avaliação mais realista do risco de falha. A variabilidade espacial das propriedades do solo exerce influência significativa na estabilidade de taludes e deve ser considerada para uma representação mais fiel do comportamento geotécnico. Neste contexto, este trabalho propõe uma metodologia probabilística para análise da estabilidade de taludes grampeados, integrando modelagem de campos aleatórios e técnicas de aprendizado profundo. O objetivo é investigar a influência da discretização da variabilidade espacial na estimativa da probabilidade de falha (P_f). Para isso, campos aleatórios dos parâmetros geotécnicos são gerados por meio de duas abordagens distintas: a expansão de Karhunen–Loève (KLE) e o método Estimativa Linear Ótima de Expansão (EOLE). Esses campos são utilizados como entrada para uma Rede Neural Convolucional (CNN), responsável por aprender padrões espaciais das propriedades do solo e estimar o fator de segurança (*FoS*). Com base nas previsões da rede, são realizadas Simulações de Monte Carlo (MCS) para estimar a probabilidade de falha do sistema. A metodologia proposta apresenta potencial para reduzir o custo computacional de análises probabilísticas em problemas de estabilidade de taludes.

PALAVRAS-CHAVE: Variabilidade Espacial do Solo, Karhunen-Loève Expasion, Expansion Optimal Linear Estimation, Análises Probabilísticas.

ABSTRACT: Slope stability is a central topic in geotechnical engineering, particularly in structures such as dams, road cuts, and excavations. Factors such as soil heterogeneity, hydraulic conditions, and uncertainties in mechanical properties make the use of probabilistic approaches essential for a more realistic assessment of failure risk. The spatial variability of soil properties has a significant influence on slope stability and must be considered to achieve a more realistic representation of geotechnical behavior. In this context, this study proposes a probabilistic methodology for the stability analysis of soil-nailed slopes, integrating random field modeling and deep learning techniques. The objective is to investigate the influence of spatial variability discretization on the estimation of the probability of failure (P_f). For this purpose, random fields of geotechnical parameters are generated using two distinct approaches: the Karhunen–Loève Expansion (KLE) and the Expansion Optimal Linear Estimation (EOLE) method. These fields are used as input to a Convolutional Neural Network (CNN), responsible for learning spatial patterns of soil properties and estimating the slope factor of safety (*FoS*). Based on the network predictions, Monte Carlo Simulations (MCS) are performed to estimate the probability of failure of the system. The proposed methodology shows potential to reduce the computational cost of probabilistic analyses in slope stability problems.

KEYWORDS: Spatial Variability, Karhunen-Loève Expansion, Expansion Optimal Linear Estimation, Probabilistic Analysis.

1 INTRODUÇÃO

A análise de estabilidade de taludes constitui um dos problemas clássicos da engenharia geotécnica, sendo fundamental para a segurança de infraestruturas e para a mitigação de riscos associados a escorregamentos. Tradicionalmente, essas análises são conduzidas por meio de abordagens determinísticas, nas quais os parâmetros geotécnicos são representados por valores únicos considerados representativos do maciço de solo. Entretanto, solos naturais apresentam significativa variabilidade espacial em suas propriedades físicas e mecânicas, resultante de processos geológicos como sedimentação, intemperismo e história de tensões. Essa heterogeneidade pode influenciar diretamente os mecanismos de ruptura e a estimativa do fator de segurança (FoS), tornando necessária a incorporação explícita dessas incertezas nas análises (Jiang et al., 2022).

Nesse contexto, métodos probabilísticos baseados na teoria de campos aleatórios têm sido amplamente empregados para representar a variabilidade espacial das propriedades do solo em análises de estabilidade de taludes. A aplicação dessas abordagens envolve a discretização do campo aleatório em um conjunto finito de variáveis aleatórias, sendo a expansão de Karhunen–Loève (KLE) e o método Expansion Optimal Linear Estimation (EOLE) duas das estratégias mais utilizadas para essa finalidade. Entretanto, a realização de análises probabilísticas por meio de técnicas como a simulação de Monte Carlo (MCS) geralmente requer um grande número de avaliações do modelo determinístico, resultando em elevado custo computacional (Siacara et al., 2024).

Com o objetivo de reduzir esse custo computacional, modelos substitutos baseados em aprendizado de máquina têm sido propostos na literatura recente (Huang et al., 2025; Jiang et al., 2023; Mert et al., 2025; Wang et al., 2024). Entre essas abordagens, as redes neurais convolucionais (CNN) têm demonstrado elevada capacidade para capturar padrões espaciais presentes em campos aleatórios de propriedades geotécnicas e aproximar a resposta estrutural do sistema. Nesse contexto, o presente trabalho propõe uma metodologia probabilística para análise de estabilidade de taludes grampeados que integra modelagem de variabilidade espacial do solo e técnicas de aprendizado profundo. A abordagem investiga o impacto de diferentes estratégias de discretização de campos aleatórios – especificamente os métodos KLE e EOLE – na estimativa da probabilidade de falha, avaliando simultaneamente sua eficiência computacional e consistência dos resultados obtidos.

2 MATERIAIS E MÉTODOS

2.1 Representação da variabilidade espacial do solo

As propriedades geotécnicas dos solos apresentam variações naturais no espaço devido a processos geológicos, deposicionais e ambientais. Essas variações resultam em incertezas significativas nos parâmetros utilizados em análises geotécnicas, como resistência ao cisalhamento e peso específico. De acordo com Phoon & Kulhawy (1999), a variabilidade observada nos parâmetros do solo resulta da combinação de três fontes principais de incerteza: variabilidade inerente do solo, erro de medição e incerteza associada à transformação de resultados de ensaios em propriedades de projeto.

Nesse contexto, uma propriedade geotécnica $\xi(z)$ pode ser representada como a soma de uma tendência determinística e uma componente aleatória associada à variabilidade espacial conforme apresentado na Eq. (1).

$$\xi(z) = t(z) + w(z) \tag{1}$$

Onde $t(z)$ representa a tendência média do perfil do solo e $w(z)$ corresponde à componente aleatória que descreve as flutuações espaciais da propriedade analisada (K.-K. Phoon & Kulhawy, 1999).

Essa formulação permite caracterizar estatisticamente o campo aleatório por meio de parâmetros como média, desvio padrão e função de autocorrelação espacial, possibilitando a geração de diferentes realizações do meio geotécnico com propriedades estatísticas equivalentes.

2.2 Função de autocorrelação espacial

Segundo Huang et al. (2025), para representar a dependência estatística entre propriedades do solo em diferentes posições do domínio espacial, é necessário definir uma função de autocorrelação espacial. Essa função descreve o grau de similaridade entre os valores de uma propriedade geotécnica em dois pontos distintos do maciço de solo.

Considerando dois pontos localizados nas coordenadas (x_i, y_i) e (x_j, y_j), a autocorrelação espacial pode ser expressa em função da distância entre esses pontos. Uma forma amplamente utilizada na literatura geotécnica é a função de autocorrelação exponencial bidimensional, definida pela Eq. 2.

$$\rho(\tau_x, \tau_y) = exp\left[\left(-\frac{\tau_x}{\delta_h}\right)^2 - \left(-\frac{\tau_y}{\delta_v}\right)^2\right] \quad (2)$$

Onde: τ_x e τ_y representam as distâncias horizontais e verticais entre os pontos analisados; δ_h e δ_v correspondem aos comprimentos de correlação horizontal e vertical do campo aleatório. Os comprimentos de correlação representam a escala espacial da variabilidade do solo, indicando a distância ao longo da qual as propriedades geotécnicas permanecem estatisticamente correlacionadas (Zhang et al., 2025).

2.3 Expansão de Karhunen-Loève

A expansão de Karhunen–Loève (KLE) constitui um dos métodos mais utilizados para a discretização de campos aleatórios. De acordo com Siacara, Beck, et al. (2024), esse método baseia-se na decomposição espectral da função de covariância do campo aleatório, permitindo representar o campo como uma série de funções determinísticas ortogonais ponderadas por variáveis aleatórias não correlacionadas. Considerando um campo aleatório $H(x, \theta)$ definido em um domínio D, com média $\mu(x)$ e função de covariância $C(x_1, x_2)$. A expansão de Karhunen-Loève pode ser escrita como definido na Eq. 3.

$$H(x, \theta) = \mu(x) + \sum_{i=1}^{\infty} \sqrt{\lambda_i}\, \xi_i(\theta)\, \varphi_i(x) \quad (3)$$

Onde: λ_i são os autovalores da função de covariância; $\varphi_i(x)$ são as autofunções ortogonais associadas; $\xi_i(\theta)$ são variáveis aleatórias não correlacionadas de média zero e variância unitária. Os autovalores e autofunções são obtidos pela solução da equação integral apresentada na Eq. 4.

$$\int_D C(x_1, x_2)\varphi_1(x_2)\, dx_2 = \lambda_1 \varphi_1(x_1) \quad (4)$$

Na prática, a expansão é truncada após *M* termos, resultando na aproximação proposta na Eq. 5.

$$H(x, \theta) \approx \mu(x) + \sum_{i=1}^{M} \sqrt{\lambda_i}\, \xi_i(\theta)\, \varphi_i(x) \quad (5)$$

A escolha do número de termos *M* depende da quantidade de variância do campo capturada pela expansão, sendo frequentemente utilizada a razão de energia baseada na soma dos autovalores.

2.4 Estimativa Linear Ótima de Expansão

O método Estimativa Linear Ótima de Expansão (EOLE) constitui uma alternativa para a discretização de campos aleatórios baseada na decomposição espectral da matriz de covariância definida em um conjunto finito de pontos do domínio. Inicialmente, considera-se um conjunto de pontos discretos $X = \{x_i\}$ pertecentes ao domínio do campo aleatório. A aproximação do campo pode ser expressa por meio do meio do método de estimação linear ótima (OLE), conforme Eq. 6.

$$H(x) = a(x) + \sum_{i=1}^{n} b_i(x)\, y_i \quad (6)$$

Onde: $y_i = H(x_i)$ representam os valores do campo nos pontos nodais. Os coeficientes são obtidos minimizando a variância do erro da aproximação, sujeita à condição de não viés, conforme a Eq. 7.

$$\min Var[H(x) - \tilde{H}(x)] \tag{7}$$

A partir da decomposição espectral da matriz de covariância C_{YY}, o campo aleatório pode ser representado por uma expansão igual a apresentada na Eq. 8.

$$\tilde{H}(x,\theta) = \mu(x) + \sum_{i=1}^{M} \sqrt{\lambda_i}\, \xi_i(\theta)\varphi_i(x) \tag{8}$$

Onde: λ_i e φ_i correspondem aos autovalores e autovetores da matriz de covariância C_{YY}; ξ_i são variáveis aleatórias independentes de média zero e variância unitária. Substituindo essa decomposição na formulação de estimação linear ótima, obtém-se a representação final do campo aleatório aproximado Eq. 9.

$$\tilde{H}(x,\theta) = \mu(x) + \sum_{i=1}^{M} \xi_i(\theta)\sqrt{\lambda_i}\ \varphi_i^T C_{HY} \tag{9}$$

Onde C_{HY} representa o vetor de covariâncias entre o ponto x e os pontos nodais utilizados na discretização.

2.5 Redes Neurais Convolucionais (CNNs)

Nos últimos anos, técnicas de aprendizado de máquina têm sido utilizadas como modelos substitutos (surrogate models) para reduzir o custo computacional de análises probabilíticas considerando a variabilidade espacial do solo. Entre essas técnicas, as Redes Neurais Convolucionais (Convolutional Neural Networks – CNN) têm demonstrado elevada capacidade para lidar com dados espaciais de alta dimensionalidade, como aqueles provenientes da discretização de campos aleatórios (Huang et al., 2025; Jiang et al., 2023; Mert et al., 2025).

De maneira geral, uma arquitetura típica de CNN é composta por diferentes tipos de camadas, incluindo camadas convolucionais, responsáveis pela extração de características espaciais; camadas de ativação, que introduzem não linearidade ao modelo; camadas de pooling, que reduzem a dimensionalidade dos dados e preservam as características mais relevantes; e camadas totalmente conectadas, responsáveis por mapear as características extraídas para a variável de saída do modelo (Jiang et al., 2023; Qu et al., 2026).

Durante o processo de treinamento, a rede neural aprende a relação entre os padrões espaciais presentes nos campos aleatórios e a resposta do sistema representada pelo FoS. Uma vez treinado, o modelo baseado em CNN pode ser utilizado como um modelo substituto eficiente, permitindo estimar rapidamente o FoS para novas realizações dos campos aleatórios sem a necessidade de executar repetidamente o modelo numérico de estabilidade (Qu et al., 2026).

2.6 Função de desempenho

A P_f do talude foi definida com base na função de desempenho associada ao *FoS*. Em problemas de estabilidade de taludes, essa função pode ser expressa como apresentado na Eq. 10.

$$G_{(x)} = FoS_{(x)} - 1 \tag{10}$$

Onde: $FoS_{(x)}$ representa o fator de segurança obtido para um conjunto de variáveis aleatórias (x). A condição de falha ocorre quando $G_{(x)} \leq 0$, ou seja, quando o *FoS* é menor ou igual a 1. Dessa forma, a P_f corresponde à probabilidade de ocorrência desse evento no espaço das variáveis aleatórias.

3 IMPLEMENTAÇÃO DA METODOLOGIA PROPOSTA

Após a definição dos fundamentos teóricos apresentados na seção anterior, a metodologia proposta é implementada por meio de uma sequência de etapas computacionais que integram a modelagem da variabilidade espacial do solo, análises determinísticas de estabilidade e o uso de uma rede neural

convolucional como modelo substituto. O fluxo geral do procedimento adotado neste estudo é apresentado na Figura 1, e as etapas são descritas a seguir.

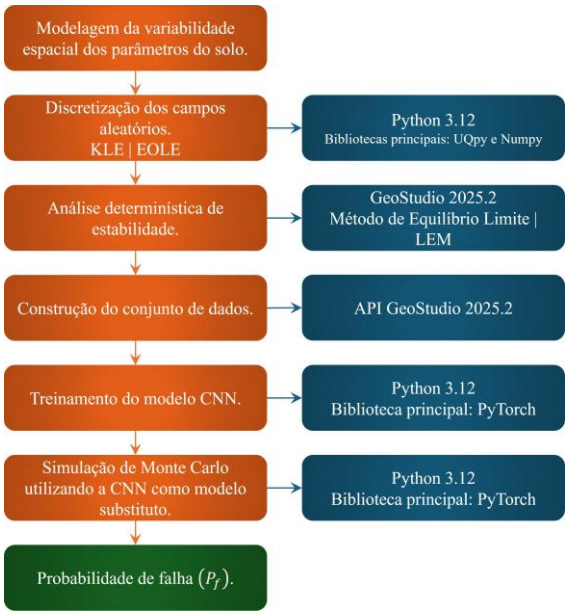


Figura 1. Estrutura metodológica para previsão do *FoS* em taludes com variabilidade espacial do solo utilizando redes neurais convolucionais.

Etapa 1: *Modelagem da variabilidade espacial.* Inicialmente são definidas as características estatísticas dos parâmetros geotécnicos considerados na análise, incluindo média, coeficiente de variação, e distribuição de probabilidade. Também é estabelecida a estrutura de correlação espacial das propriedades do solo, representada pelos comprimentos de correlação que descrevem a escala de flutuação do campo aleatório. A partir dessas informações, a variabilidade espacial do maciço de solo é representada por meio da teoria de campos aleatórios.
Etapa 2: *Discretização dos campos aleatórios.* Na segunda etapa, os campos aleatórios contínuos são discretizados em um número finito de variáveis aleatórias. Neste estudo são utilizados dois métodos de discretização: KLE e EOLE. Ambos permitem representar a variabilidade espacial das propriedades do solo preservando suas principais características estatísticas.
Etapa 3: *Analálises de estabilidade.* As realizações dos campos aleatórios são então associados ao modelo numérico do talude, permitindo a distribuição espacial das propriedades do solo em cada simulação. Para cada realização gerada é realiazada uma análise determinística de estabilidade, obtendo-se o correspondente FoS. As análises são conduzidas no software GeoStudido 2025.2, utilizando o método de equilíbrio limite (LEM).
Etapa 4: *Treinamento do modelo CNN.* O conjunto de dados obtido é utilizado para treinar uma rede neural convolucional (CNN) responsável por aproximar a relação entre a distribuição espacial das propriedades do solo e o FoS do talude. Antes do treinamento, os dados passam por um processo de pré-processamento e são divididos em conjuntos de treinamento e validação.
Etapa 5: *Simulação de Monte Carlo utilizando o CNN.* Após o treinamento, o CNN passa a atuar como um modelo substituto na criação do RF para o modelo determinístico de estabilidade. Nesse estágio, novas realizações de campos aleatórios são geradas e utilizadas como entrada para o CNN, que fornece rapidamente as estimativas correspondentes do FoS. Com base nessas previsões, é realizada uma simulação de Monte Carlo para estimar a probabilidade de falha do talude.

4 ESTUDO DE CASO

Para avaliar a aplicabilidade da metodologia proposta, foi considerado um modelo bidimensionalde talude grampeado. O talude possui 6 m de altura e 3 m de comprimento, sendo composto por duas camadas de solo com diferentes propriedades geotécnicas. O material que compõe o corpo do talude, denominado Material 2,

apresenta menor resistência ao cisalhamento, enquanto o solo de fundação, denominado Material 1, apresenta propriedades mecânicas mais competentes (Fig. 2).

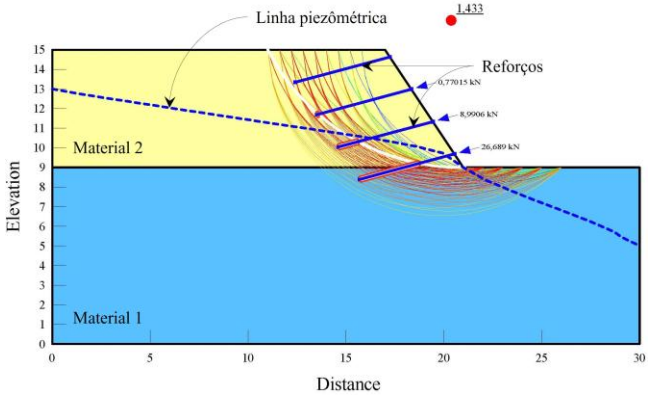


Figura 2. Geometria do modelo de talude grampeado utilizado no estudo de caso.

O sistema de reforço do talude é constituído por quatro grampos, com comprimento de 5 m e resistência ao arrancamento de 40,50 kPa. A estabilidade do talude foi avaliada por meio do LEM utilizando o método de Morgenstern-Price, implementado no software GeoStudio (GEO-SLOPE, 2025).

Para considerar o efeito das pressões neutras no maciço de solo, foi realizada previamente uma análise de fluxo em regime permanente. Nessa análise foram aplicadas condições de carga hidráulica a montante e a jusante do modelo, permitindo a determinação do campo de pressões neutras utilizado posteriormente nas análises de estabilidade.

Para cada material, os parâmetros de resistência ao cisalhamento coesão efetiva (c') e ângulo de atrito efetivo (φ') foram modelados como campos aleatórios. Por outro lado, o peso específico (γ'), a condutividade hidráulica (Ks) e a resistência ao arrancamento dos reforços (τ) foram considerados como variáveis aleatórias espacialmente uniformes, representando incertezas globais associadas a esses parâmetros. Os parâmetros estatísticos adotados, incluindo média (μ), coeficiente de variação (*COV*) e distribuição de probabilidade Lognormal (LN), são apresentados na Tabela 1.

Tabela 1. Parâmetros probabilísticos adotados.

Material	Parâmetros	μ	*COV (%)*	Distribuição Probabilística	*Lx (m)*	*Ly (m)*
Material 2	c' (kPa)	5,00	40	*LN*	30,00	3,00
	φ' (°)	24,00	30	*LN*		
	γ' (kN/m³)	16,00	7	*LN*		
	Ks (m/s)	$1{,}00 \times 10^{-3}$	80	*LN*		
Material 1	c' (kPa)	10,00	40	*LN*	30,00	3,00
	φ' (°)	26,00	30	*LN*		
	γ' (kN/m³)	18,00	7	*LN*		
	Ks (m/s)	$3{,}00 \times 10^{-3}$	80	*LN*		
Reforços	τ (kPa)	40,50	30	*LN*	-	-

No presente estudo, foi considerada uma correlação (ρ) negativa de -0,50 entre os parâmetros de resistência c' e φ' de cada material, porém, não existe correlação entre camadas. A variabilidade espacial foi representada por campos aleatórios lognormais com comprimentos de correlação horizontal de 30 m e vertical de 3 m, os dois materiais receberam os mesmos comprimentos de correlação.

5 RESULTADOS E DISCUSSÃO

A Figura 3 apresenta exemplos de realizações dos campos aleatórios gerados pelos métodos KLE e EOLE para os parâmetros de resistência do solo. Observa-se que ambos os métodos são capazes de reproduzir padrões espaciais consistentes com os comprimentos de correlação adotados. Essa representação ilustra a forma como a variabilidade espacial é incorporada nas análises de estabilidade.

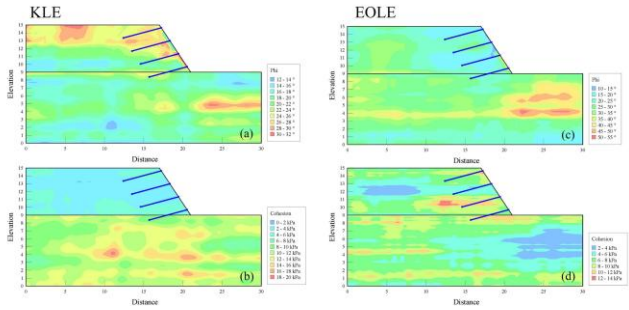


Figura 3. Realização de campos aleatórios. (a - c) ângulo de atrito efetivo; (b - d) coesão efetiva.

5.1 Desempenho do modelo substituto baseado em CNN

A Figura 4 apresenta a comparação entre os valores de FoS obtidos nas análises determinísticas utilizando o LEM e os valores previstos pela CNN. Observa-se uma forte correlação entre os valores previstos e os valores obtidos nas análises determinísticas. Para o conjunto de dados analisado, o modelo apresentou coeficiente de determinação $R^2 = 0{,}9534$ para o caso associado ao método KLE e $R^2 = 0{,}953$ para o caso associado ao método EOLE, indicando que mais de 95 % da variabilidade dos resultados é explicada pelo modelo substituto.

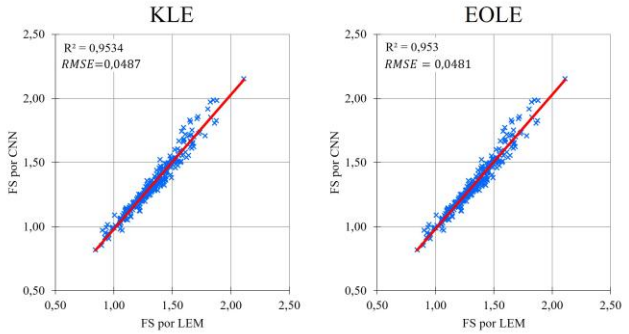


Figura 4. Desempenho do modelo CNN na previsão do fator de segurança.

Além disso, os valores de RMSE (Root Mean Square Error) obtidos foram 0,0487 para o modelo baseado em KLE e 0,0481 para o modelo baseado em EOLE. Considerando que os fatores de segurança obtidos variam aproximadamente entre 0,8 e 2,1, os erros observados correspondem a aproximadamente 2-3 % do intervalo de valores analisados, o que demonstra a elevada precisão do modelo substituto.

5.2 Análise de confiabilidade

A P_f do talude foi estimada por meio de simulações de Monte Carlo utilizando a CNN como modelo substituto, considerando 50.000 simulações para cada método de discretização. Para o método KLE, foi obtido $P_f = 1{,}612 \times 10^{-2}$ com $\beta = 2{,}141$, enquanto para o método EOLE foi obtido $P_f = 1{,}614 \times 10^{-2}$ com $\beta = 2{,}141$, indicando resultados praticamente idênticos entre as duas abordagens, conforme apresentado na Tabela 2. Os intervalos de confiança de 95 % também apresentaram sobreposição significativa, confirmando a consistência estatística das estimativas. Entretanto, diferenças relevantes foram observadas em termos de custo computacional. O método baseado em KLE apresentou tempo total de processamento de aproximadamente 37 minutos, enquanto o método EOLE apresentou tempo de aproximadamente 4 minutos, representando uma redução superior a 85 %. Essa diferença está associada ao fato de que a expansão de Karhunen–Loève requer a decomposição espectral da matriz de covariância espacial do campo aleatório, cuja dimensão cresce com o número de pontos da malha. Em problemas bidimensionais com malhas relativamente densas, essa operação envolve procedimentos de álgebra linear computacionalmente custosos. Em contraste, o método EOLE usa

um número menor de pontos de expansão e operadores já calculados, permitindo gerar realizações do campo aleatório com operações matriciais mais simples.

Tabela 2. Resultados da análise de confiabilidade.

Método	N simulações	Pf	β	IC95%	Tempo (min)
KLE	50.000	$1{,}612 \times 10^{-2}$	2,141	$[1{,}505 \times 10^{-2}; 1{,}726 \times 10^{-2}]$	37
EOLE	50.000	$1{,}614 \times 10^{-2}$	2,141	$[1{,}507 \times 10^{-2}; 1{,}728 \times 10^{-2}]$	4

6 CONCLUSÕES

Este trabalho apresentou uma abordagem probabilística para análise de estabilidade de taludes grampeados considerando a variabilidade espacial das propriedades do solo e o uso de uma rede neural convolucional como modelo substituto. Os métodos de discretização de campos aleatórios KLE e EOLE foram avaliados quanto à sua influência na estimativa da probabilidade de falha. Os resultados indicaram que ambos os métodos produziram estimativas praticamente idênticas de probabilidade de falha ($\approx 1{,}61 \times 10^{-2}$) e índice de confiabilidade ($\approx 2{,}14$). Entretanto, diferenças significativas foram observadas em termos de custo computacional, com o método EOLE apresentando redução superior a 80% no tempo de processamento. A abordagem proposta demonstra o potencial do uso de modelos substitutos baseados em aprendizado profundo para viabilizar análises de confiabilidade em problemas geotécnicos complexos.

REFERÊNCIAS BIBLIOGRÁFICAS

GEO-SLOPE International Ltd, 2025. Stability Modeling with GeoStudio. GEO-SLOPE International Ltd., Calgary, Canada.

Huang, N., Han, Y., Xie, W., Hu, R., Peng, H., Song, G., Wu, M., Zhu, M., Wei, H., & Liang, M. (2025). An innovative and efficient approach for slope reliability analysis: Machine learning based surrogate modeling with advanced attention mechanisms. *Engineering Geology*, *354*. https://doi.org/10.1016/j.enggeo.2025.108194

Jiang, S. H., Huang, J., Griffiths, D. V., & Deng, Z. P. (2022). Advances in reliability and risk analyses of slopes in spatially variable soils: A state-of-the-art review. *Computers and Geotechnics*, *141*. https://doi.org/10.1016/j.compgeo.2021.104498

Jiang, S. H., Zhu, G. Y., Wang, Z. Z., Huang, Z. T., & Huang, J. (2023). Data augmentation for CNN-based probabilistic slope stability analysis in spatially variable soils. *Computers and Geotechnics*, *160*. https://doi.org/10.1016/j.compgeo.2023.105501

Mert, A. C., Guo, X., Shen, Z., Pan, H., & Dias, D. (2025). A reliability-based framework for offshore monopile design using CPT data and deep learning enhanced adaptive metamodeling. *Ocean Engineering*, *342*, 122952. https://doi.org/10.1016/j.oceaneng.2025.122952

Phoon, K.-K., & Kulhawy, F. H. (1999). *Characterization of geotechnical variability*. www.nrcresearchpress.com

Qu, C., Liu, Y., Guo, H., & Liu, L. (2026). Probabilistic analysis of stress effects on an unsaturated soil slope stability using convolutional neural networks and Bayesian optimisation. *Engineering Geology*, *361*. https://doi.org/10.1016/j.enggeo.2025.108511

Siacara, A. T., Beck, A. T., & Ji, J. (2024). Impact of Random Field Simulations on FEM-Based Earth Slope Reliability. *Geotechnical and Geological Engineering*, *42*(8), 7873–7891. https://doi.org/10.1007/s10706-024-02956-5

Siacara, A. T., Guo, X., & Beck, A. T. (2024). Probabilistic analysis of shallow foundation on earth slope using an active learning surrogate-centered procedure. *Computers and Geotechnics*, *175*. https://doi.org/10.1016/j.compgeo.2024.106659

Wang, Z. Z., Zhang, J., & Huang, H. (2024). Interpreting random fields through the U-Net architecture for failure mechanism and deformation predictions of geosystems. *Geoscience Frontiers*, *15*(1). https://doi.org/10.1016/j.gsf.2023.101720

Zhang, Q., Zhang, H., & Wang, L. (2025). Influence of characteristics of geotechnical parameter random field on slope stability. *Structures*, *81*. https://doi.org/10.1016/j.istruc.2025.110445