COBRAMSEG 2026

ANAIS DO

XXII CONGRESSO BRASILEIRO DE MECÂNICA DOS SOLOS E ENGENHARIA GEOTÉCNICA

XI SIMPÓSIO BRASILEIRO DE JOVENS GEOTÉCNICOS

Eixo Temático:

Big Data e Inteligência Artificial em Geotecnica

ABMS | Associação Brasileira de Mecânica dos Solos e Engenharia Geotécnica

ABMS | Associação Brasileira de Mecânica dos Solos e Engenharia Geotécnica
Centro-Oeste
Núcleo Regional

COBRAMSEG 2026

ANAIS DO

XXII CONGRESSO BRASILEIRO DE MECÂNICA DOS SOLOS E ENGENHARIA GEOTÉCNICA

XI SIMPÓSIO BRASILEIRO DE JOVENS GEOTÉCNICOS

Eixo Temático:

Big Data e Inteligência Artificial em Geotecnica

ABMS Associação Brasileira de Mecânica dos Solos e Engenharia Geotécnica

ABMS Associação Brasileira de Mecânica dos Solos e Engenharia Geotécnica
Centro-Oeste
Núcleo Regional

Editora Omnis Scientia

Anais do XXII Congresso Brasileiro de Mecânica dos Solos e Engenharia Geotécnica – COBRAMSEG 2026

Eixo Temático:

Big Data e Inteligência Artificial em Geotecnica

Volume 1

1ª Edição

RECIFE - PE

2026

Patrocínio Diamante

VALE

Patrocínio Rubi

CZM FOUNDATION EQUIPMENT

Patrocínio Esmeralda

SETE ENGENHARIA

INCOPRE PRÉ-FABRICADOS DE CONCRETO

srk

REDE Sondagens Geotécnicas

Patrocínio Água Marinha

Incotep Sistemas de Ancoragem

Solotrat

SHEIKAN ANCOR-JET FIBRAS

MACCAFERRI

belgo arames

ArcelorMittal

GERDAU O futuro se molda

owntec

geo|soluções

FOA Engenharia e Pré-Fabricados

HUESKER Ideen. Ingenieure. Innovationen.

Terra Dril

Patrocínio Turmalina



















Patrocínio Opala























































Patrocínio Safira









Divulgação

Realização

Apoio

Organização

Comissão Organizadora dos Anais

André Luís Brasil Cavalcante

Márcia Maria dos Anjos Mascarenha

Michéle Dal Toé Casagrande

José Wilson dos Santos Ferreira

Talita Caroline Miranda

Mario René Rivera Osorto

Comissão Organizadora do Evento

André Luís Brasil Cavalcante (Presidente)

Maurício Martines Sales

Flávio Ornelas

Cristiano Zandoná dos Santos

Paulo da Venda Oliveira

Marcos Massao Futai

José Wilson dos Santos Ferreira

Márcia Maria dos Anjos Mascarenha

Michéle Dal Toé Casagrande

Comissão Geojovem

José Wilson dos Santos Ferreira (Presidente)

Lídia Bruna Teles Gonzaga

Mateus Teixeira Crippa

Mario René Rivera Osorto

Zharry Ribeiro Bueno

Comissão Científica

Márcia Maria dos Anjos Mascarenha (Presidente)

Michéle Dal Toé Casagrande (Vice-presidente)

Alexandre Duarte Gusmão

Andrelisa Santos de Jesus

André Pacheco de Assis

Bernadete Ragoni Danziger

Breno Padovezi Rocha

Carlos Alberto Lauro Vargas

Ennio Marques Palmeira

Gilson De Farias Neves Gitirana Jr

José Allan Carvalho Maia

José Camapum de Carvalho

José Fernando Thomé Jucá

Kátia Vanessa Bicalho

Marta Pereira da Luz

Luan Ozelim

Luis Edmundo Prado de Campos

Magnos Baroni

João Paulo Silva de Freitas

Marcos Massao Futai

Maria Das Graças Gardoni Almeida

Maria Eugenia Gimenez Boscov

Marina Bellaver Corte

Paulo José Rocha de Albuquerque

Sandro Lemos Machado

Tácio Mauro Pereira de Campos

Terezinha de Jesus Espósito

Comissão Financeira

Cristiano Zandoná dos Santos

Comissão Consultiva

André Pacheco de Assis

Ennio Marques Palmeira

José Camapum de Carvalho

Comitê Assessor de Congresso (CAC)

Gustavo Simões

Paulo Albuquerque

Vitor Pereira Faro

ABMS — Diretoria Nacional

Roberto Quental Coutinho (Presidente)

Bernadete Ragoni Danziger (Vice-Presidente)

Robson Palha Saramago (Secretário Geral)

Marcos Massao Futai (Diretor Financeiro)

Petrucio Santos Junior (Diretor de Comunicação)

Mauricio Ehrlich (Diretor de Relações Institucionais)

Jairo Pascoal Júnior (Diretor de Normas Técnicas)

Felipe Gobbi Silveira (Diretor AD HOC)

Max Gabriel Timo Barbosa (Diretor AD HOC)

Luiz Antonio Bressani (Diretor AD HOC)

Magnos Baroni (Diretor AD HOC)

ABMS — NRCO

Maurício Martines Sales (Presidente)

Marta Pereira da Luz (Vice-Presidente)

Luiz Carlos de Figueiredo (Secretário Geral)

Cristiano Zandoná dos Santos (Diretor Financeiro)

Thiago Lopes dos Santos (Diretor Eventos Técnicos)

José Wilson dos Santos Ferreira (Diretor GeoJovem Ad hoc)

Editora

Editor-Chefe

Dr. Daniel Luís Viana Cruz

Conselho Editorial

Dr. Amâncio António de Sousa Carvalho – ESS-UTAD – Portugal

Dr. Cássio Brancaleone – UFFS – Brasil

Dr. Marcelo Luiz Bezerra da Silva – UEPa – Brasil

Dra. Pauliana Valéria Machado Galvão – UPE – Brasil

Dr. Plínio Pereira Gomes Júnior – UFRPE – Brasil

Dr. Walter Santos Evangelista Júnior – UFRPE – Brasil

Dr. Wendel José Teles Pontes – UFPE – Brasil

Assistente Editorial

Thialla Larangeira Amorim

Imagem de Capa

Canva

Edição de Arte

Vileide Vitória Larangeira Amorim

Nhatallia Laranjeira Amorim

Revisão

Os autores

Este trabalho está licenciado com uma Licença Creative Commons – Atribuição - Não Comercial - Sem Derivações 4.0 Internacional.

O conteúdo abordado nos artigos, seus dados em sua forma, correção e confiabilidade são de responsabilidade exclusiva dos autores.

Dados Internacionais de Catalogação na Publicação (CIP)
Lumos Assessoria Editorial

C749
Congresso Brasileiro de Mecânica dos Solos e Engenharia Geotécnica (22. : 2026 : Brasília, DF).
Anais do XXII Congresso Brasileiro de Mecânica dos Solos e Engenharia Geotécnica (COBRAMSEG) : big data e inteligência artificial em geotecnica [recurso eletrônico] / coordenador André Luís Brasil Cavalcante ... [et al.]. — 1. ed. — Recife : Omnis Scientia, 2026.
Dados eletrônicos (pdf).

Inclui bibliografia.
ISBN 978-65-284-0678-4
DOI: 10.47094/COBRAMSEG2026.2

1. Engenharia civil (Geotecnia). 2. Mecânica do solo. 3. Ciência do solo. 4. Solos – Conservação. I. Cavalcante, André Luís Brasil.

CDD23: 624.15136

I-3010261/1

Bibliotecária: Priscila Pena Machado – CRB-7/6971

Editora Omnis Scientia

Av. República do Líbano, nº 251, Sala 2205, Torre A,

Bairro Pina, CEP 51.110-160, Recife-PE.

Telefone: +55 87 99920-5762

editoraomnisscientia.com.br

contato@editoraomnisscientia.com.br



Prefácio

O XXII Congresso Brasileiro de Mecânica dos Solos e Engenharia Geotécnica – COBRAMSEG 2026, realizado em Brasília, representa mais um importante capítulo na trajetória da Geotecnia brasileira. Promovido pela Associação Brasileira de Mecânica dos Solos e Engenharia Geotécnica (ABMS), o Congresso reafirma sua vocação histórica como o principal espaço nacional de encontro entre pesquisadores, profissionais, estudantes, empresas, instituições públicas e demais atores envolvidos no desenvolvimento da Engenharia Geotécnica no País.

Nesta edição, o tema **"Geotecnia e Mudanças Climáticas: Infraestruturas e Cidades Resilientes"** traduz um dos grandes desafios do nosso tempo. Eventos extremos cada vez mais frequentes, alterações nos regimes de precipitação, movimentos de massa, inundações, erosões e outros processos associados às mudanças ambientais evidenciam a necessidade de repensarmos a forma como concebemos, projetamos, construímos, monitoramos e mantemos nossas infraestruturas e cidades.

Nesse contexto, a Engenharia Geotécnica assume uma responsabilidade ainda maior. Mais do que responder às emergências, somos chamados a antecipar riscos, desenvolver soluções inovadoras, incorporar novas tecnologias e contribuir para a construção de uma sociedade mais segura e resiliente. **A Geotecnia precisa estar presente antes da emergência.**

O COBRAMSEG 2026 foi concebido exatamente com esse espírito: promover o encontro entre conhecimento científico, experiência profissional, inovação tecnológica e os grandes desafios da sociedade. A diversidade e a qualidade dos trabalhos reunidos nestes Anais demonstram a vitalidade da comunidade geotécnica brasileira e sua capacidade de produzir conhecimento relevante nas diferentes áreas da Mecânica dos Solos, Mecânica das Rochas e Engenharia Geotécnica.

Os artigos aqui publicados constituem uma importante representação do conhecimento produzido e aplicado em universidades, centros de pesquisa, empresas, órgãos públicos e instituições de todo o País. Abrangem desde temas clássicos da Geotecnia até abordagens emergentes relacionadas à sustentabilidade, mudanças climáticas, transformação digital, inteligência artificial, instrumentação e monitoramento, gestão de riscos, novos materiais e metodologias de projeto e análise.

Além da apresentação dos trabalhos técnicos, a programação científica do COBRAMSEG 2026 foi enriquecida por conferências, palestras especiais, painéis, mesas-redondas, sessões técnicas, atividades destinadas aos jovens geotécnicos e eventos integrados, proporcionando diferentes oportunidades de intercâmbio entre gerações, instituições e áreas de atuação. Esse ambiente de diálogo constitui uma das maiores riquezas do Congresso e reforça a importância da colaboração para o avanço da nossa profissão.

Brasília, cidade concebida a partir de uma visão de futuro, ofereceu um cenário particularmente simbólico para esta edição. Em um momento em que discutimos resiliência, sustentabilidade e adaptação às mudanças climáticas, reunir a comunidade geotécnica na capital brasileira também nos convida a refletir sobre nossa responsabilidade na construção das infraestruturas e das cidades que

desejamos deixar para as próximas gerações.

A Comissão Organizadora manifesta seu profundo agradecimento aos autores que confiaram seus trabalhos ao Congresso, aos revisores pela criteriosa avaliação das contribuições, aos palestrantes, moderadores e coordenadores de sessões, às Comissões Técnicas da ABMS, às instituições parceiras, às empresas patrocinadoras e expositoras, às equipes de apoio e a todos aqueles que dedicaram tempo, conhecimento e trabalho para tornar possível a realização do COBRAMSEG 2026.

Agradecemos especialmente à **Associação Brasileira de Mecânica dos Solos e Engenharia Geotécnica – ABMS**, cuja história se confunde com o próprio desenvolvimento da Geotecnia brasileira e cuja atuação continua sendo fundamental para aproximar academia e prática profissional, formar novas gerações e projetar internacionalmente a Engenharia Geotécnica produzida no Brasil.

Aos participantes, nosso reconhecimento por transformarem o Congresso em um verdadeiro espaço de encontro, aprendizado e construção coletiva.

Esperamos que estes Anais ultrapassem os limites temporais do evento e permaneçam como registro do conhecimento, das ideias e das inquietações que mobilizaram a comunidade geotécnica brasileira em 2026. Que os trabalhos aqui reunidos inspirem novas pesquisas, projetos, soluções e parcerias e contribuam para uma Engenharia Geotécnica cada vez mais inovadora, sustentável e comprometida com a sociedade.

Que o COBRAMSEG 2026 seja lembrado não apenas pelo conhecimento que compartilhamos, mas também pelas conexões que construímos e pela visão de futuro que reafirmamos juntos.

André Luís Brasil Cavalcante
Presidente do COBRAMSEG 2026

Sumário

ANÁLISE DE CONFIABILIDADE DE TALUDES AFETADOS PELO CLIMA COM SOLOS ESPACIALMENTE VARIÁVEIS USANDO MODELOS SUBSTITUTOS COM APRENDIZADO ATIVO.....19

ANÁLISE DE RECALQUES PRIMÁRIOS E SECUNDÁRIOS EM SOLOS COMPRESSÍVEIS UTILIZANDO DADOS GERADOS POR INTELIGÊNCIA ARTIFICIAL.....27

ANÁLISE E MONITORAMENTO DE ATERROS FERROVIÁRIOS INSTRUMENTADOS UTILIZANDO TÉCNICAS DE BUSINESS INTELLIGENCE.....35

ANÁLISES PROBABILÍSTICAS DE ESTABILIDADE DE TALUDES GRAMPEADOS UTILIZANDO CAMPOS ALEATÓRIOS BASEADOS EM APRENDIZADO PROFUNDO.....43

ANN-BASED PREDICTION OF SLOPE STABILITY USING A DIMENSIONLESS FORMULATION FOR HOMOGENEOUS DRY SLOPES.....51

APLICAÇÕES E EFICÁCIA DAS ANÁLISES DE CORRELAÇÃO ESTATÍSTICA NA CARACTERIZAÇÃO DE PROPRIEDADES GEOTÉCNICAS: UMA REVISÃO SISTEMÁTICA.....59

AUTOMAÇÃO DA EXTRAÇÃO DE DADOS GEOTÉCNICOS HISTÓRICOS COM *DOCUMENT INTELLIGENCE* E OCR AVANÇADO.....67

AVALIAÇÃO DA PERFORMANCE DE DIFERENTES MODELOS DE INTELIGÊNCIA ARTIFICIAL GENERATIVA NA RESOLUÇÃO DE PROBLEMAS DE CÁLCULO NA MECÂNICA DOS SOLOS.....75

AVALIAÇÃO DO DESEMPENHO DE REDE NEURAL TREINADA COM DADOS SINTÉTICOS APLICADA À ESTABILIDADE GEOTÉCNICA.....83

BIM GEOTÉCNICO: REVISÃO SISTEMÁTICA.....89

DA CONVERSA À SIMULAÇÃO: MODELAGEM NUMÉRICA GEOTÉCNICA MEDIADA POR MODELOS DE LINGUAGEM DE LARGA ESCALA (LLMS).....97

DETECÇÃO E MENSURAÇÃO DE DANOS EM PAVIMENTOS ASFÁLTICOS COM YOLOV11: UM ESTUDO EM RODOVIAS BRASILEIRAS.....105

ESTATÍSTICA APLICADA À INTEGRAÇÃO DE MONITORAMENTO AUTOMATIZADO E INSPEÇÃO GEOTÉCNICA EM BARRAGENS.....113

FUNDAÇÃO INTELIGENTE: UM CHATBOT ESPECIALIZADO PARA APOIO TÉCNICO EM ENGENHARIA CIVIL.....122

GERENCIAMENTO DIGITAL DE TAILINGS STORAGE FACILITIES.....130

INTEGRAÇÃO DE BUSINESS INTELLIGENCE, INTELIGÊNCIA ARTIFICIAL E COMPUTAÇÃO EM NUVEM NO MAPEAMENTO DE SOLOS COLAPSÍVEIS E EXPANSIVOS DO BRASIL.....138

INTEGRAÇÃO DE CAMPOS ESTOCÁSTICOS E APRENDIZADO DE MÁQUINA PARA PREVISÃO DE CONDIÇÕES CRÍTICAS EM ATERROS FERROVIÁRIOS LATERÍTICOS AMAZÔNICOS.....146

METODOLOGIA PARA AVALIAÇÃO DA ADERÊNCIA DE DISTRIBUIÇÕES ACUMULADAS EM PARÂMETROS GEOTÉCNICOS UTILIZANDO SOFTWARE R.....154

MODELAGEM PREDITIVA DA DEFORMAÇÃO PERMANENTE DE SUBLEITOS DE SOLOS TROPICAIS ATRAVÉS DE REGRESSÃO POLINOMIAL EVOLUCIONÁRIA ORIENTADA POR SENSIBILIDADE.....161

MODELO CONSTITUTIVO BASEADO EM REDES NEURAIS ARTIFICIAIS PARA AREIAS REFORÇADAS COM FIBRAS POLIMÉRICAS.....169

MODELO NEURAL PARA PREVISÃO DA CAPACIDADE DE CARGA DE ESTACAS PRÉ-MOLDADAS DE CONCRETO.....176

OTIMIZAÇÃO DA INTERPRETAÇÃO DE ENSAIOS CPTU COM MODELO DE APRENDIZADO DE MÁQUINA: UMA PROVA DE CONCEITO.....184

PANORAMA DA UTILIZAÇÃO DA INTELIGÊNCIA ARTIFICIAL NA GESTÃO DE RISCO DE MOVIMENTO DE MASSA: UMA ANÁLISE BIBLIOMÉTRICA COM FOCO EM APLICAÇÕES GEOTÉCNICAS E AMBIENTAIS.....192

PREVISÃO BASEADA EM MACHINE LEARNING DE RESISTÊNCIA NÃO DRENADA (SU) A PARTIR DE ENSAIOS DSS PARA APLICAÇÕES OFFSHORE.....200

PREVISÃO DA VARIAÇÃO DE TEMPERATURA DO SOLO EM SISTEMA GSHP VERTICAL USANDO REDES NEURAIS ARTIFICIAIS (RNA).....208

PREVISÃO DA VELOCIDADE DE ONDA DE CISALHAMENTO EM ARGILAS MARINHAS UTILIZANDO MACHINE LEARNING COM DADOS DE SCPT E BENDER ELEMENT.....216

PRIORIZAÇÃO DE RISCOS EM PILHAS DE MINERAÇÃO: UMA ABORDAGEM INTEGRADA DE ESTATÍSTICA E INTELIGÊNCIA COMPUTACIONAL SOBRE DADOS FMEA.....224

SISTEMA WEB INTERATIVO PARA BANCO DE DADOS MCT: FERRAMENTA DE APOIO À CARACTERIZAÇÃO DE SOLOS TROPICAIS.....232

TRANSFORMAÇÃO DIGITAL NA MINERAÇÃO: APLICAÇÃO DA MICROSOFT POWER PLATFORM NA GESTÃO DE PROJEÇÕES FINANCEIRAS E MEDIÇÕES DE GEOTECNIA E GEOLOGIA.....237

USO DE ANN PARA PREDIÇÃO DE MÓDULO DE RESILIÊNCIA.....245

USO DE IA COMO FERRAMENTA DE SUPORTE À DECISÃO EM SUPRIMENTOS EM EMPRESA DE FUNDAÇÕES.....253

UTILIZAÇÃO DE RADAR DE ABERTURA SINTÉTICA INTERFEROMÉTRICO (INSAR) COMO AUXÍLIO AO MONITORAMENTO DE TALUDES EM ZONAS DE INSTABILIDADE GEOLÓGICO-GEOTÉCNICA NO MUNICÍPIO DE ILHÉUS - BAHIA – BRASIL.....261

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/COBRAMSEG2026.2/1

Análise de Confiabilidade de Taludes Afetados pelo Clima com Solos Espacialmente Variáveis Usando Modelos Substitutos com Aprendizado Ativo

Adrian Torrico Siacara
Professor, Departamento de Engenharia de Estruturas e Geotécnica, Escola Politécnica da Universidade de São Paulo, São Paulo, Brasil, adrian.torrico@usp.br

Xiangfeng Guo
Escola de Ciências e Engenharia Marinha, Universidade de Tecnologia do Sul da China, China, xfguo18@scut.edu.cn

André Teófilo Beck
Professor, Departamento de Engenharia de Estruturas, Escola de Engenharia de São Carlos da Universidade de São Paulo, São Paulo, Brasil, adrian.torrico@usp.br

RESUMO: Fatores climáticos, como precipitação, umidade relativa, evapotranspiração e temperatura, influenciam diretamente a estabilidade de taludes de terra, podendo representar riscos à infraestrutura e à segurança pública. Este estudo propõe um arcabouço probabilístico para avaliar a estabilidade de taludes sob a influência de variáveis climáticas. A metodologia é estruturada em cinco etapas: definição do problema, desenvolvimento do modelo numérico, análise determinística e duas etapas de análise probabilística considerando variáveis aleatórias (RVs) e campos aleatórios (RFs). As análises determinísticas utilizam o Método dos Elementos Finitos (FEM) e o Método do Equilíbrio Limite (LEM), enquanto as análises probabilísticas são realizadas por meio do Método de confiabilidade de primeira ordem (FORM) e do modelo Caos Polinomial-Kriging Adaptativo (A-PCK). O método é aplicado a um talude em Belo Horizonte, Brasil, com base em 33 anos de dados climáticos, com foco no período crítico de 150 dias caracterizado por intensas variações climáticas e do nível freático. A partir das abordagens determinística, RV e RF, propõe-se uma tabela de critérios de níveis de estabilidade para apoiar o monitoramento e a modelagem de taludes em condições climáticas dinâmicas.

PALAVRAS-CHAVE: Análise de confiabilidade; talude de solo; clima; modelo substituto; aprendizagem ativa.

ABSTRACT: Climate-related factors such as rainfall, relative humidity, evapotranspiration, and temperature directly influence the stability of earth slopes, potentially posing risks to infrastructure and public safety. This study proposes a probabilistic framework to evaluate slope stability under climatic influences. The methodology is structured in five steps: problem definition, numerical model development, deterministic analysis, and two probabilistic stages considering random variables (RVs) and random fields (RFs). Deterministic analyses are performed using the Finite Element Method (FEM) and the Limit Equilibrium Method (LEM), while probabilistic assessments apply reliability techniques such as the First-Order Reliability Method (FORM) and the Adaptive Polynomial Chaos-Kriging (A-PCK) model. The framework is applied to an earth slope in Belo Horizonte, Brazil, using 33 years of climate data, focusing on a critical 150-day period characterized by strong climatic and groundwater fluctuations. Based on deterministic, RV, and RF approaches, a stability level criteria table is proposed to support slope monitoring and modeling under dynamic climate conditions.

KEYWORDS: Reliability analysis; earth slope; climate; surrogate model; active learning.

1 INTRODUÇÃO

O rápido crescimento populacional em regiões tropicais tem impulsionado a expansão urbana desordenada para áreas montanhosas e de maior risco geotécnico (Li et al., 2018; Yan et al., 2015). Esse processo aumenta a impermeabilização do solo, reduz a capacidade de drenagem natural e eleva a probabilidade de instabilidade de taludes, gerando riscos significativos para a infraestrutura e para a segurança pública. Eventos climáticos extremos, como chuvas intensas e períodos prolongados de seca, têm se tornado mais frequentes e imprevisíveis devido às mudanças climáticas, intensificando ainda mais esses desafios (Nunes et al., 2022). Em países tropicais e subtropicais, incluindo Brasil, China e Singapura, deslizamentos de terra induzidos por precipitação representam uma ameaça recorrente, afetando áreas urbanas e rurais (Albino et al., 2020; A. T. Siacara, Napa-García, et al., 2024).

Embora a precipitação seja tradicionalmente considerada nas análises de estabilidade, outras variáveis climáticas, como umidade relativa, evapotranspiração e temperatura, também podem impactar significativamente o comportamento hidrogeotécnico dos taludes. Essas variáveis afetam o nível do lençol freático e a pressão intersticial da água no solo, aumentando o risco de falha mesmo em taludes projetados de acordo com normas vigentes. Entretanto, análises convencionais geralmente desconsideram essas influências, resultando em avaliações incompletas ou conservadoras da segurança do talude.

Métodos determinísticos, baseados no cálculo do fator de segurança, são amplamente utilizados na engenharia geotécnica , mas apresentam limitações quando se trata de incertezas nos parâmetros do solo e na variabilidade climática (Duncan et al., 2014; Li et al., 2018). Nesse contexto, abordagens probabilísticas oferecem uma alternativa mais robusta, permitindo a modelagem de variabilidade por meio de variáveis aleatórias e campos aleatórios. Essas técnicas possibilitam estimar a probabilidade de falha e fornecer uma avaliação mais realista da confiabilidade do talude, apoiando decisões baseadas em risco e estratégias de monitoramento adaptativo (Guo et al., 2021; Lu et al., 2025; A. T. Siacara, Beck, et al., 2024).

Este estudo propõe um arcabouço probabilístico para a avaliação da estabilidade de taludes sob condições climáticas variáveis, combinando análises determinísticas e probabilísticas. A metodologia inclui a definição do problema, o desenvolvimento de modelos numéricos, análises determinísticas e avaliações probabilísticas considerando variáveis aleatórias e campos aleatórios. O framework é aplicado a um talude em Belo Horizonte, Brasil, considerando precipitação, umidade relativa, evapotranspiração, temperatura e incertezas geotécnicas relevantes. Os resultados permitem uma compreensão mais abrangente do comportamento do talude sob influências climáticas e fornecem subsídios para estratégias de monitoramento, planejamento e gestão de riscos (Adrian Torrico Siacara et al., 2026).

2 FUNDAMENTO TEORICO

2.1 Modelo Numérico

Para avaliar a influência climática na infiltração de solos não saturados, foram realizadas simulações usando o Seep/W (GeoStudio, 2024a), baseadas na equação de Richards (Richards, 1931) e nas equações de van Genuchten (Van Genuchten, 1980). A sucção do solo, que aumenta a resistência ao cisalhamento (Vanapalli et al., 1996), foi considerada no cálculo da estabilidade do talude utilizando o software Slope/W (GeoStudio, 2024b). A interação solo-atmosfera incluiu precipitação, escoamento e evaporação real, simulada pelo modelo de Wilson et al. (Wilson et al., 1997), limitada pela disponibilidade de água no solo. Esse modelo permite analisar de forma integrada os efeitos de variáveis climáticas sobre o fluxo de água e a estabilidade do solo (Albino et al., 2020; Nunes et al., 2022; Wilson et al., 1997).

2.2 Modelagem de Incerteza com Variáveis Aleatórias (RV) e Campos Aleatórios (RF)

Na engenharia geotécnica, incertezas das propriedades do solo podem ser tratadas por variáveis aleatórias (RV), assumindo homogeneidade espacial, ou por campos aleatórios (RF), que capturam a variabilidade espacial. RFs são discretizados em RVs independentes usando a Expansão de Karhunen–Loève (KLE) e podem ser transformados em distribuições lognormais. Essa abordagem permite avaliar de forma mais realista a confiabilidade de taludes em solos heterogêneos (A. T. Siacara et al., 2022; A. T. Siacara, Guo, et al., 2024).

2.3 Análise de Confiabilidade

A análise de confiabilidade estima a probabilidade de falha P_f de um sistema considerando incertezas, usando métodos como FORM e SS. O modelo Caos Polinomial-Kriging Adaptativo (A-PCK) combina PCK com aprendizado ativo, permitindo estimar P_f de forma eficiente. O modelo é iterativamente atualizado selecionando novos pontos próximos à superfície de falha e interrompendo quando P_f se estabiliza, oferecendo precisão e economia computacional em problemas geotécnicos. Para detalhes e formulações matemáticas é necessária a consulta em bibliografia especializada (Beck, 2019; Melchers & Beck, 2018).

3 FORMULAÇÃO DO PROBLEMA

3.1 Geometria do Problema e Variáveis Consideradas

As análises consideraram dados climáticos de Belo Horizonte, Brasil, região subtropical úmida, abrangendo 33 anos (1990–2022) de precipitação diária, umidade relativa, evapotranspiração e temperatura (INMET, 2025). Foram destacados anos extremos, como 2019 (seco) e 2020 (extremamente úmido), e um período crítico de 150 dias na transição entre esses anos foi selecionado para capturar os efeitos de variações climáticas extremas. As condições climáticas são apresentadas na Figura 1 (b).

O talude investigado possui 20 m de altura, inclinação de 26,57° (2H:1V), dividido em dois segmentos de 10 m separados por um berma de 3 m e com distância horizontal de 17 m até a infraestrutura adjacente. O nível do lençol freático varia durante o período crítico, refletindo as mudanças climáticas, com condições de drenagem superficial mantidas na análise. O talude é ilustrado na Figura 1 (a).

Este estudo incorpora as incertezas de oito parâmetros de entrada relacionados ao talude em uma análise de confiabilidade. Esses parâmetros incluem cinco propriedades relacionadas ao escoamento de água e três parâmetros relacionados à estabilidade. Especificamente, eles são: dois parâmetros de ajuste de Van Genuchten da curva de retenção de água do solo (a, n), os conteúdos volumétricos de água saturado e residual (θ_s e θ_r), o parâmetro de condutividade hidráulica saturada (k_s), o peso específico do solo (γ), a coesão efetiva do solo (c') e o ângulo de atrito efetivo do solo (ϕ'). Todos são tratados como variáveis aleatórias (RVs) com distribuições lognormal ou uniforme, com média, coeficiente de variação e limites baseados na literatura. Uma correlação negativa de $\rho_{c'-\phi'} =$ -0.5 é adotada entre c' e o ϕ' (Javankhoshdel & Bathurst, 2015; Sivakumar Babu & Srivastava, 2007). As propriedades são apresentadas na Tabela 1.

Todos os oito parâmetros são tratados como variáveis aleatórias (RVs) e assumidos como seguindo uma distribuição lognormal (LN) ou uniforme (U). A escolha dessas distribuições ajuda a evitar valores fisicamente irreais para as propriedades geotécnicas. Os valores médios (μ), os coeficientes de variação (COV) e os valores mínimos e máximos dessas RVs estão apresentados na Tabela 1, sendo obtidos a partir da literatura relevante (Guo et al., 2019; A.T. Siacara, Napa-García, et al., 2020). Para o modelo de campos aleatórios (RF), apenas os parâmetros mais influentes identificados na análise de sensibilidade são tratados como RFs. A variabilidade espacial é representada por comprimentos de autocorrelação horizontal de 40 m e vertical de 2 m. As curvas resultantes de conteúdo volumétrico de água e condutividade hidráulica mostram a influência da variabilidade dos parâmetros do solo.

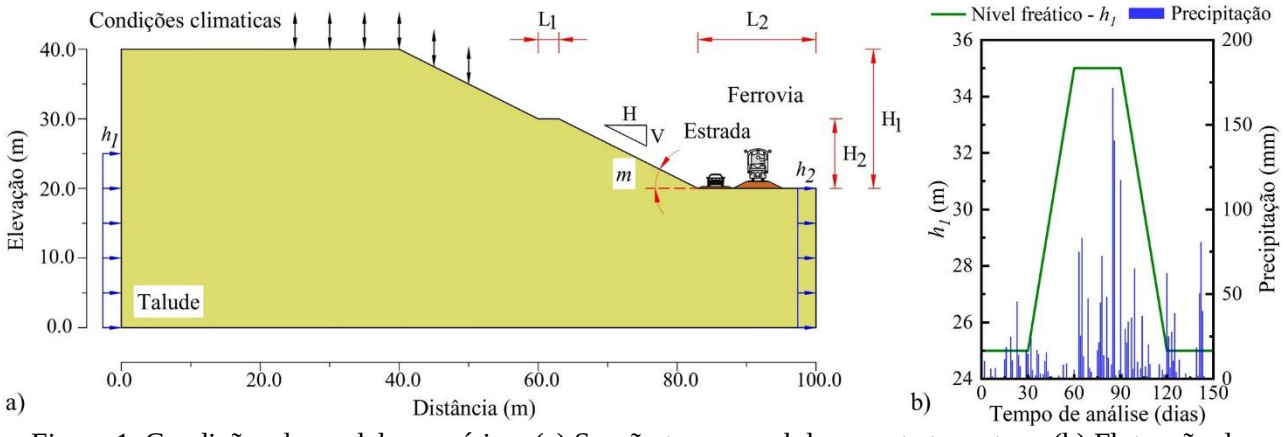


Figura 1. Condições do modelo numérico: (a) Secção transversal da encosta terrestre e (b) Flutuação da superfície da água subterrânea.

Tabela 1. Propriedades de Entrada dos Materiais.

Material	Parâmetro	Média (μ)	COV (%)	Distribuição (PD)	Valor Mínimo	Valor Máximo
Fluxo	k_s (m/s)	$5{,}63 \times 10^{-5}$	100	*LN*	–	–
	θ_s (m³/m³)	0,54	–	*U*	0,45	0,63
	θ_r (m³/m³)	0,17	–	*U*	0,09	0,26
	a (kPa)	8,06	–	*U*	1,61	14,51
	n	1,76	–	*U*	1,32	2,20
Estabilidade	c' (kPa)	8,0	50	*LN*	–	–
	ϕ' (°)	28,0	30	*LN*	–	–
	γ (kN/m³)	18,0	11	*LN*	–	–

3.2 Desarrolho do Modelo Numérico

O modelo numérico foi desenvolvido utilizando o Método dos Elementos Finitos (FEM) no software SEEP/W para o fluxo de água e o Método do Equilíbrio Limite (LEM) no software SLOPE/W para a estabilidade do talude, considerando três abordagens: determinística, RV e RF. O domínio foi discretizado com malha triangular, refinada em regiões críticas, e a análise começou com um escoamento estacionário para determinar a pressão de poros inicial. Em seguida, realizou-se escoamento transitório ao longo de 150 dias, considerando variações climáticas diárias, e a estabilidade do talude foi avaliada a cada passo de tempo usando o método de Morgenstern e Price, determinando a superfície crítica e o fator de segurança (FoS).

4 RESULTADOS

4.1 Resultados Determinísticos

A estabilidade do talude foi avaliada considerando FoSs sob condições transientes, focando em variações climáticas. Valores determinísticos recomendados para este modo de falha foram adotados da literatura (ABNT-NBR 11682, 2016; Duncan et al., 2014; FHWA, 2006). Ao longo da simulação, o FoS variou entre 1,26 e 1,55, indicando condições estáveis, com o FoS crítico FoS_{cr} =1,26 em tempo critico $t_{cr} = 87$ dias. As superfícies de deslizamento crítica apresentam pequenas variações ao longo do tempo, corroborando estudos anteriores (A. T. Siacara, Napa-García, et al., 2024; A.T. Siacara, Beck, et al., 2020), que mostram que oscilações moderadas de poropressão (PWP) pouco alteram as superfícies, mas grandes oscilações, como em escoamentos rápidos, podem provocar mudanças significativas. A análise evidencia forte correlação entre FoS, PWP e precipitação, destacando a influência das condições climáticas no comportamento do talude, conforme ilustrado na Figura 2.

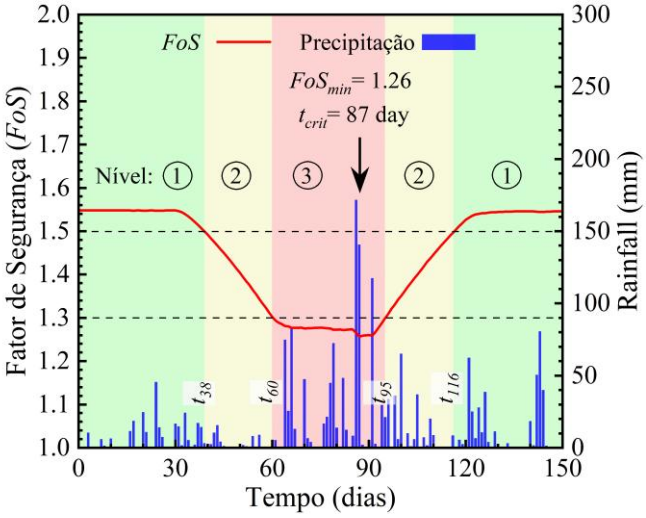


Figura 2. Resultados determinísticos.

4.2 Resultados RV

O estudo considera o escorregamento do talude como o principal modo de falha, com a função de desempenho definida como $g(\boldsymbol{X}) = FoS - 1.0$. Nesse critério, o talude falha quando o FoS é menor que 1, permitindo quantificar probabilisticamente a confiabilidade do sistema sob condições incertas.

A análise de confiabilidade foi realizada usando FORM e A-PCK/SS, considerando as variáveis como RVs. No método A-PCK/SS, o modelo substituto PCK foi utilizado, o método SS para estimar a P_f, a função de aprendizado baseada no número de desvio U, e critério de parada baseado na estabilidade de P_f. A análise foi conduzida ao longo do período transitório de 150 dias com passo diário ($\Delta t = 1$ dia).

Os resultados mostram que o A-PCK/SS é mais eficiente, requerendo menos de 50 chamadas ao modelo numérico, com COV de P_f abaixo de 3%. O β segue a mesma tendência do FoS, permitindo definir níveis probabilísticos de estabilidade:

- Nível 1 – Aceitável ($\beta \geq 1{,}5$): condições seguras, monitoramento padrão;
- Nível 2 – Atenção ($1{,}0 < \beta < 1{,}5$): condição potencialmente instável, requer atenção;
- Nível 3 – Crítico ($\beta \leq 1{,}0$): situação crítica, recomenda-se abordagem com RF para capturar variabilidade espacial do solo.

Esses níveis foram aplicados ao talude estudado, evidenciando períodos críticos e períodos seguros ao longo do intervalo de análise, Figura 3.

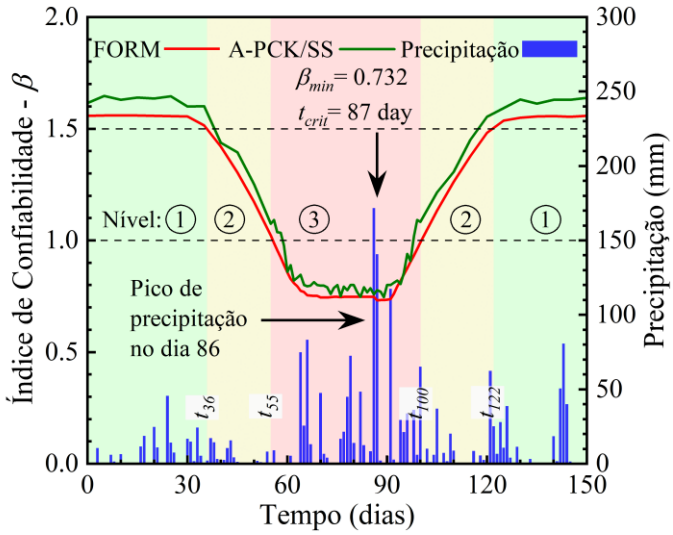


Figura 3. Resultados RV do método FORM e A-PCK/SS.

4.3 Resultados RF

Neste passo, a confiabilidade do talude foi avaliada incorporando a variabilidade espacial do solo por meio do método RF combinado com A-PCK/SS, enquanto os demais parâmetros foram tratados como RVs. Três variáveis críticas—c', ϕ' e k_s—foram modeladas como campos aleatórios, capturando a variação espacial ao longo do talude e ao longo do período crítico de 150 dias. Apesar do aumento no custo computacional e no número de avaliações da função de desempenho ($N_{call} < 190$), a análise apresentou COV do P_f inferior a 5%, mostrando robustez nos resultados. Comparado ao método RV, o RF forneceu índices de confiabilidade β mais altos (ou probabilidades de falha menores), sugerindo que considerar a variabilidade espacial reduz o conservadorismo típico dos modelos RV e permite avaliações mais realistas. As avaliações de segurança do talude em termos probabilísticos de RF são apresentadas na Figura 4. O processo de aprendizado ativo exigiu mais amostras de treinamento para atingir o critério de parada, refletindo a complexidade adicional do modelo RF, mas resultando em uma avaliação mais precisa da confiabilidade do talude sob efeitos climáticos.

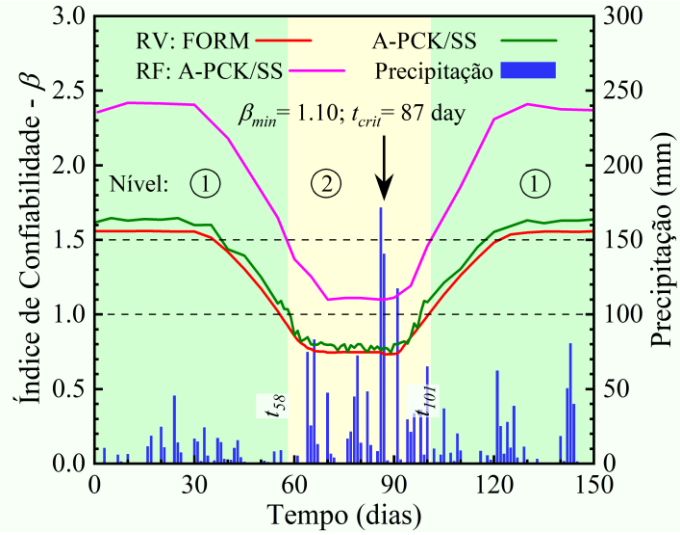


Figura 4. Resultados RF do método A-PCK/SS.

4 CONCLUSÕES

O estudo propõe uma metodologia probabilística integrada para avaliar a estabilidade de taludes sob diferentes condições climáticas (chuva, umidade, temperatura e evapotranspiração), combinando análises determinísticas e probabilísticas com variáveis e campos aleatórios, além dos métodos de confiabilidade de primeira ordem (FORM) e modelo Caos Polinomial-Kriging Adaptativo (A-PCK) combinado com a Simulação de Subconjunto (SS). A abordagem é estruturada em cinco etapas, incluindo modelagem numérica e análise de confiabilidade.

A aplicação foi realizada em um talude em Belo Horizonte, com base em 33 anos de dados climáticos e foco em um período crítico de 150 dias. Os resultados determinísticos indicaram estabilidade geral, com fator de segurança (FoS) entre 1,26 e 1,55, sendo o dia 87 o mais crítico devido a chuvas intensas e variações do nível do lençol freático. A primeira avaliação é realizada e são observados os tempos críticos.

Na análise probabilística em termos de Variáveis Aleatórias (RV), os principais parâmetros de influência foram o ângulo de atrito efetivo do solo (ϕ'), a coesão efetiva do solo (c') e a condutividade hidráulica saturada (k_s). Nesta etapa novamente é avaliado o talude e é determinado os tempos críticos. Na etapa das análises probabilísticas por Campos Aleatórios (RF), a modelagem do solo é mais realista e os resultados são menos conservadores. Nesta etapa é atualizada a avaliação da estrutura deixando-a sem estados críticos e no estado aceitável e de atenção. Em conjunto, todos os métodos confirmaram o mesmo período crítico, demonstrando a eficácia da abordagem integrada para avaliação de risco em taludes sob condições climáticas variáveis.

AGRADECIMENTOS

O segundo autor agradece o apoio financeiro da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP; Processo nº 2023/06123-9).

REFERÊNCIAS BIBLIOGRÁFICAS

ABNT-NBR 11682. (2016). *Slope stability (in Portuguese)*. Brazilian Association of Technical Standards (ABNT).

Albino, U. R., Portelinha, F. H. M., & Futai, M. M. (2020). Numerical simulation of a geotextile soil wall considering soil-atmosphere interaction. *Geosynthetics International*, 27(4), 394–413. https://doi.org/10.1680/jgein.20.00003

Beck, A. T. (2019). *Reliability and safety of structures (in portuguese)*. Elsevier Editora Ltda.

Duncan, J. M., Wright, S. G., & Brandon, T. L. (2014). *Soil Strength and Slope Stability* (2nd Editio). John Wiley & Sons Ltd.

FHWA. (2006). Soils and Foundations. Reference Manual – Volume I. National Highway Institute. *Washington DC, USA*.

GeoStudio. (2024a). Heat and Mass Transfer Modeling with GeoStudio (GEO-SLOPE). *GEO-SLOPE International Ltd, Calgary, AB, Canada T2P*. http://downloads.geo-slope.com/geostudioresources/books/10/0/Heat and Mass Transfer Modeling.pdf

GeoStudio. (2024b). Stability Modeling with GeoStudio (GEO-SLOPE). *GEO-SLOPE International Ltd, Calgary, AB, Canada T2P 0T8*. https://downloads.geo-slope.com/geostudioresources/8/0/6/books/slope modeling.pdf?v=8.0.7.6129

Guo, X., Dias, D., Carvajal, C., Peyras, L., & Breul, P. (2019). A comparative study of different reliability methods for high dimensional stochastic problems related to earth dam stability analyses. *Engineering Structures*, 188(March), 591–602. https://doi.org/10.1016/j.engstruct.2019.03.056

Guo, X., Dias, D., Carvajal, C., Peyras, L., & Breul, P. (2021). Modelling and comparison of different types of random fields: case of a real earth dam. *Engineering with Computers*, *0123456789*. https://doi.org/10.1007/s00366-021-01495-4

INMET. (2025). *Climatic Measurements in Brazil (in portuguese)*. National Institute of Meteorology (INMET), Ministry of Agriculture, Livestock and Supply. Retrieved in March 24, 2025 from www.inmet.gov.br

Javankhoshdel, S., & Bathurst, R. (2015). Influence of cross-correlation between soil parameters on probability of failure of simple cohesive and c- φ slopes. *Canadian Geotechnical Journal*, 6000(November), 1–44. https://doi.org/10.1139/cgj-2015-0109

Li, Z., Ye, W., Marence, M., & Bricker, J. (2018). Unsteady Seepage Behavior of an Earthfill Dam During Drought-Flood Cycles. *Geosciences*, 9(1), 17. https://doi.org/10.3390/geosciences9010017

Lu, M., Tao, Y., Ma, X., Sharma, A., & Zhang, J. (2025). Probabilistic framework for resilience assessment of soil slopes against rainfall infiltration. *Bulletin of Engineering Geology and the Environment*, 84(7), 349. https://doi.org/10.1007/s10064-025-04367-z

Melchers, E. M., & Beck, A. T. (2018). *Structural Reliability Analysis and Prediction* (R. E. Melchers & A. T. Beck (eds.); 3er Editio). John Wiley & Sons Ltd. https://doi.org/10.1002/9781119266105

Nunes, G. B., Portelinha, F. H. M., Futai, M. M., & Yoo, C. (2022). Numerical study of the impact of climate conditions on stability of geocomposite and geogrid reinforced soil walls. *Geotextiles and Geomembranes*, 50(4), 807–824. https://doi.org/10.1016/j.geotexmem.2022.04.004

Richards, L. a. (1931). Capillary conduction of Liquids through porous mediums. *Physics*, 1(5), 318–333. https://doi.org/10.1063/1.1745010

Siacara, A. T., Beck, A. T., & Ji, J. (2024). Impact of Random Field Simulations on FEM-Based Earth Slope Reliability. *Geotechnical and Geological Engineering*, *0123456789*. 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(May), 106659. https://doi.org/10.1016/j.compgeo.2024.106659

Siacara, A. T., Napa-García, G. F., Beck, A. T., & Futai, M. M. (2022). Reliability analysis of an earth dam in operating conditions using direct coupling. *SN Applied Sciences*, 4(4). https://doi.org/https://doi.org/10.1007/s42452-022-04980-7

Siacara, A. T., Napa-García, G. F., Beck, A. T., & Futai, M. M. (2024). Reliability Analysis of an Earth Dam Under Rainfall Effects. *International Journal of Geosynthetics and Ground Engineering*, 10(3), 59.

https://doi.org/10.1007/s40891-024-00571-1

Siacara, A.T., Beck, A. T., & Futai, M. M. (2020). Reliability analysis of rapid drawdown of an earth dam using direct coupling. *Computers and Geotechnics*, 118(September 2019), 103336. https://doi.org/10.1016/j.compgeo.2019.103336

Siacara, A.T., Napa-García, G. F., Beck, A. T., & Futai, M. M. (2020). Reliability analysis of earth dams using direct coupling. *Journal of Rock Mechanics and Geotechnical Engineering*, 12(2), 366–380. https://doi.org/10.1016/j.jrmge.2019.07.012

Siacara, Adrian Torrico, Guo, X., & Beck, A. T. (2026). Climate-impacted reliability analysis of earth slopes with spatially variable soils using active learning surrogate modeling. *Computers and Geotechnics*, 195(December 2025), 108074. https://doi.org/10.1016/j.compgeo.2026.108074

Sivakumar Babu, G. L., & Srivastava, A. (2007). Reliability analysis of allowable pressure on shallow foundation using response surface method. *Computers and Geotechnics*, 34(3), 187–194. https://doi.org/10.1016/j.compgeo.2006.11.002

Van Genuchten, M. T. (1980). A Closed-form Equation for Predicting the Hydraulic Conductivity of Unsaturated Soils. *Soil Science Society of America Journal*, 44(5), 892. https://doi.org/10.2136/sssaj1980.03615995004400050002x

Vanapalli, S. K., Fredlund, D. G., Pufahl, D. E., & Clifton, A. W. (1996). Model for the prediction of shear strength with respect to soil suction. *Canadian Geotechnical Journal*, 33(3), 379–392. https://doi.org/10.1139/t96-060

Wilson, G. W., Fredlund, D. G., & Barbour, S. L. (1997). The effect of soil suction on evaporative fluxes from soil surfaces. *Canadian Geotechnical Journal*, 34(1), 145–155. https://doi.org/10.1139/t96-078

Yan, D., Werners, S. E., Ludwig, F., & Huang, H. Q. (2015). Hydrological response to climate change: The Pearl River, China under different RCP scenarios. *Journal of Hydrology: Regional Studies*, 4(PB), 228–245. https://doi.org/10.1016/j.ejrh.2015.06.006

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/COBRAMSEG2026.2/2

Análise de Recalques Primários e Secundários em Solos Compressíveis Utilizando Dados Gerados por Inteligência Artificial

Brenna de Medeiros Santana Pedrosa 1
Mestranda em Engenharia Civil – Geotecnia, Universidade de Brasília (UnB), Brasília – DF, Brasil, brennamdj@gmail.com

Maruska Tatiana Nascimento da Silva Bueno 2
Doutora em Engenharia Civil – Geotecnia, Universidade de Brasília (UnB), Brasília – DF, Brasil, maruskanascimento@gmail.com

RESUMO: A estimativa confiável de recalques primários e secundários é fundamental para a segurança e o desempenho de fundações em solos compressíveis. Entretanto, a limitada disponibilidade de dados experimentais de campo ainda compromete a precisão das previsões convencionais. Neste contexto, este trabalho propõe o uso de Inteligência Artificial (IA) como ferramenta auxiliar para a geração de dados fictícios representativos do comportamento de solos argilosos siltosos de média a alta compressibilidade da região Centro-Oeste do Brasil. A ampliação da base amostral permitiu uma caracterização estatística mais robusta dos parâmetros geotécnicos e a aplicação de análises probabilísticas. Foram empregados o método First-Order Second-Moment (FOSM) e simulações de Monte Carlo para avaliar a variabilidade dos recalques estimados. O modelo de regressão apresentou coeficiente de determinação (R^2) de aproximadamente 0,87 e probabilidade de falha próxima de 62% em relação ao Estado Limite de Serviço adotado, com convergência entre os resultados obtidos pelo FOSM e pela Simulação de Monte Carlo. Os resultados evidenciam o potencial da integração entre IA e métodos probabilísticos como ferramenta de apoio à tomada de decisão em projetos geotécnicos.

PALAVRAS-CHAVE: Inteligência Artificial, Dados Fictícios, Recalques, Solos Compressíveis, Análise Probabilística.

ABSTRACT: Reliable estimation of primary and secondary settlements is essential for the safety and performance of foundations on compressible soils. However, the limited availability of experimental field data still affects the accuracy of conventional prediction methods. This study proposes the use of Artificial Intelligence (AI) as a supporting tool for generating fictitious data representative of the behavior of medium- to highly compressible silty clay soils from the Central-West region of Brazil. Expanding the sample database enabled a more robust statistical characterization of geotechnical parameters and supported probabilistic analyses. The First-Order Second-Moment (FOSM) method and Monte Carlo simulations were employed to evaluate the variability of the estimated settlements. The regression model achieved a coefficient of determination (R^2) of approximately 0.87 and a probability of failure close to 62% with respect to the adopted Serviceability Limit State (SLS), showing strong agreement between the FOSM method and Monte Carlo simulations. The results demonstrate the potential of integrating Artificial Intelligence with probabilistic methods as a decision-support tool for geotechnical engineering projects.

KEYWORDS: Artificial Intelligence, Fictitious Data; Settlements, Compressible Soils, Probabilistic Analysis.

1 INTRODUÇÃO

A previsão de recalques em solos compressíveis permanece como um dos principais desafios da engenharia geotécnica devido à elevada variabilidade dos parâmetros do solo e às incertezas inerentes às investigações de campo e laboratório. Estimativas inadequadas podem comprometer o desempenho em serviço de fundações, especialmente em solos argilosos de média a alta compressibilidade, nos quais pequenas variações dos parâmetros geotécnicos podem resultar em diferenças significativas nos recalques previstos (Terzaghi, Peck

e Mesri, 1996; Burland, Broms e De Mello, 1977). Nesse contexto, a adoção de métodos probabilísticos torna-se necessária para quantificar explicitamente as incertezas associadas às previsões de recalque.

Na prática geotécnica, as estimativas de recalque são frequentemente baseadas em valores médios ou característicos dos parâmetros do solo. Embora amplamente empregadas, essas abordagens determinísticas não permitem avaliar diretamente a confiabilidade das previsões nem a probabilidade de ultrapassagem do Estado Limite de Serviço (ELS), especialmente em cenários de elevada heterogeneidade geológica (Phoon e Kulhawy, 1999).

Outro desafio refere-se à limitada disponibilidade de dados geotécnicos representativos, particularmente em regiões onde campanhas extensas de investigação são técnica ou economicamente inviáveis. Nesse cenário, técnicas de Inteligência Artificial (IA) podem ser empregadas como ferramenta auxiliar para geração de dados fictícios consistentes com o comportamento geotécnico esperado, possibilitando ampliar a base amostral e viabilizar análises estatísticas e probabilísticas mais robustas (Shahin, Maier e Jaksa, 2002; Goh, 1995).

Diante desse contexto, este trabalho propõe a integração entre Inteligência Artificial e métodos probabilísticos para avaliar recalques em solos compressíveis da região Centro-Oeste do Brasil. A metodologia baseia-se na geração de dados fictícios, no desenvolvimento de um modelo de regressão linear múltipla e na aplicação do método First-Order Second-Moment (FOSM) e da Simulação de Monte Carlo para avaliar a confiabilidade das previsões em relação ao Estado Limite de Serviço adotado.

2 FUNDAMENTAÇÃO TEÓRICA

A fundamentação teórica apresentada nesta seção estabelece a base conceitual para a compreensão dos mecanismos responsáveis pelos recalques em solos compressíveis, da utilização da Inteligência Artificial (IA) na ampliação de bases de dados geotécnicos e dos métodos probabilísticos empregados na avaliação da confiabilidade das previsões.

2.1 Recalques em Solos Compressíveis

Os recalques em solos compressíveis estão associados, principalmente, aos processos de adensamento primário e secundário decorrentes da aplicação de carregamentos. A teoria clássica do adensamento unidimensional proposta por Terzaghi permanece como referência para a compreensão desses fenômenos e continua amplamente empregada na prática geotécnica (Terzaghi, Peck e Mesri, 1996). Em solos argilosos de média a alta compressibilidade, pequenas variações dos parâmetros geotécnicos podem produzir diferenças significativas nos recalques estimados.

A elevada variabilidade espacial desses parâmetros e as limitações das investigações geotécnicas tornam insuficiente a utilização exclusiva de abordagens determinísticas, justificando o emprego de métodos probabilísticos para representar explicitamente as incertezas associadas às previsões de recalque (Burland, Broms e De Mello, 1977; Das, 2016).

2.2 Inteligência Artificial Aplicada à Geotecnia

A aplicação da Inteligência Artificial tem se expandido na engenharia geotécnica, especialmente em estudos voltados à previsão de propriedades dos solos, comportamento de fundações e modelagem de sistemas geotécnicos. Em situações caracterizadas pela limitada disponibilidade de dados experimentais, essas técnicas podem ser empregadas para gerar dados fictícios representativos, ampliando a base amostral e permitindo uma caracterização estatística mais robusta das variáveis analisadas (Shahin, Maier e Jaksa, 2002; Goh, 1995).

Neste trabalho, a IA foi utilizada como ferramenta complementar para geração da base de dados empregada nas análises probabilísticas, preservando a coerência física dos parâmetros geotécnicos adotados.

2.3 Análise Probabilística e Método FOSM

A análise probabilística permite incorporar explicitamente as incertezas associadas aos parâmetros geotécnicos e às condições de carregamento, possibilitando quantificar a variabilidade da resposta do sistema.

Entre os métodos de primeira ordem, destaca-se o First-Order Second-Moment (FOSM), que estima a propagação das incertezas por meio da linearização da função de desempenho em torno dos valores médios das

variáveis aleatórias. Sua simplicidade de implementação e reduzido custo computacional tornam esse método adequado para problemas cuja função de desempenho apresenta comportamento aproximadamente linear (Ang e Tang, 2007; Baecher e Christian, 2003).

2.4 Simulação de Monte Carlo

A simulação de Monte Carlo baseia-se na geração repetitiva de amostras aleatórias das variáveis de entrada segundo suas distribuições de probabilidade, permitindo obter a distribuição estatística da resposta do sistema sem necessidade de linearização da função de desempenho (Fenton e Griffiths, 2008).

Neste estudo, a Simulação de Monte Carlo foi empregada como procedimento complementar ao FOSM, permitindo verificar a convergência das estimativas da probabilidade de falha para diferentes números de simulações (Ching, Phoon e Hu, 2017).

3 DEFINIÇÃO DO PROBLEMA

A definição do problema tem por objetivo formalizar o modelo matemático empregado na avaliação probabilística dos recalques, estabelecendo o modelo de previsão, a função estado limite adotada para o Estado Limite de Serviço (ELS) e as variáveis aleatórias consideradas nas análises de confiabilidade.

3.1 Modelo de Previsão de Recalque

O recalque total é estimado a partir de um modelo de regressão linear múltipla ajustado a partir dos dados fictícios gerados pela IA, representativos de solos argilosos siltosos de média a alta compressibilidade da região Centro-Oeste. O modelo relaciona o recalque total às variáveis geotécnicas consideradas relevantes para a previsão do comportamento deformacional do solo, sendo expresso genericamente pela Equação 1:

$$S = a_0 + a_1X_1 + a_2X_2 + a_3X_3 + \cdots + a_nX_n \quad (1)$$

em que S representa o recalque total, X_i são as variáveis independentes e a_i são os coeficientes obtidos pelo ajuste estatístico. A utilização de um modelo de regressão explícita para o recalque viabiliza sua aplicação direta nas análises probabilísticas subsequentes.

3.2 Função Estado Limite (ELS)

A verificação do desempenho em serviço é realizada por meio de uma função estado limite associada ao Estado Limite de Serviço (ELS), definidas em termos da ultrapassagem do recalque admissível. A função estado limite, $g(X)$, é definida pela Equação 2:

$$g(X) = S_{ELS} - S_{(X)} \quad (2)$$

em que (S_{ELS}) corresponde ao recalque admissível adotado em projeto e $S_{(X)}$, representa o recalque total estimado.

Nessa formulação, valores de $g(X) > 0$ indicam atendimento ao critério de serviço, enquanto $g(X) \leq 0$ caracteriza a ocorrência de falha associada à ultrapassagem do limite admissível. Sendo que a probabilidade de falha é definida como a probabilidade de ocorrência do evento $g(X) \leq 0$, podendo ser expressa matematicamente pela Equação 3, conforme, Siacara et al (2022):

$$P_f = P[g\,(\boldsymbol{X}) \leq 0] = \int_{g\,(\boldsymbol{X})\leq 0} f_{\boldsymbol{X}}(\boldsymbol{x})\, d\boldsymbol{x} \quad (3)$$

onde $f_{\boldsymbol{X}}(\boldsymbol{x})$ é a função densidade de probabilidade conjunta de $\boldsymbol{x}$.

Essa abordagem permite quantificar explicitamente o risco associado às previsões de recalque, por meio da probabilidade de falha, fornecendo uma medida objetiva do desempenho estrutural em Estado Limite de Serviço, como mostra a Equação 4, conforme Siacara et al (2022):

$$P_f \approx \phi(-\beta) \tag{4}$$

onde ϕ representa a função de distribuição acumulada da normal padrão, que fornece a probabilidade de uma variável normalmente distribuída assumir valores inferiores a um determinado limiar $(-\beta)$, logo $\phi(-\beta)$ representa a área de falha sobre a curva normal.

O recalque admissível adotado neste estudo foi fixado em 300 mm, valor compatível com critérios de desempenho em serviço para obras executadas sobre solos compressíveis e estruturas com maior tolerância a deslocamentos verticais globais. Por exemplo: obras de silos e suportes robustos, fundos industriais pesados, pavimentos industriais ou plataformas logísitca, entre outras.

A literatura geotécnica ressalta que limites admissíveis de recalque não constituem valores normativos únicos, devendo ser definidos em função do tipo de estrutura, do sistema de fundação e das exigências de desempenho em serviço (Terzaghi, Peck e Mesri, 1996; Burland, Broms e De Mello, 1977). Assim, o valor adotado representa um critério de Estado Limite de Serviço voltado à avaliação de desempenho, e não um limite de segurança última.

3.3 Variáveis Aleatórias e Incertezas

A definição das variáveis aleatórias foi realizada de forma progressiva, considerando inicialmente os parâmetros diretamente associados aos mecanismos físicos dos recalques primário e secundário e, posteriormente, o aprimoramento estatístico do modelo. De acordo com a teoria clássica do adensamento unidimensional, o recalque primário pode ser expresso conforme a Equação 5 (Terzaghi, Peck e Mesri, 1996):

$$S_p = \frac{C_c}{1+e_0} H \log\left(\frac{\sigma'_f}{\sigma'_0}\right) \tag{5}$$

em que C_c é o índice de compressão, e_0 o índice de vazios inicial, H a espessura da camada compressível, σ'_0 a tensão vertical efetiva inicial e σ'_f a tensão vertical efetiva final. Essa expressão evidencia que a estimativa do recalque primário, S_p, é fortemente influenciada por parâmetros de compressibilidade e por condições de carregamento, os quais apresentam elevada variabilidade espacial em depósitos naturais de solos finos (Burland, Broms e De Mello, 1977; Das, 2016).

O recalque secundário, associado aos processos de deformação viscosa e rearranjo estrutural do solo após o término do adensamento primário, pode ser representado, conforme Equação 6 (Mesri e Castro, 1987):

$$S_s = \frac{C_\alpha}{1+e_0} H \log\left(\frac{t}{t_{100}}\right) \tag{6}$$

em que C_α é o índice de adensamento secundário e t e t_{100} representam, respectivamente, os tempos inicial e final do intervalo de análise. Estudos clássicos indicam que o índice de adensamento secundário apresenta significativa dispersão, mesmo em solos de mesma classificação, reforçando a necessidade de sua representação probabilística (Mesri e Godlewski, 1977).

Com base nessas formulações, foram inicialmente selecionados como variáveis aleatórias o índice de compressão (C_c), o índice de adensamento secundário (C_α) e a razão de sobreadensamento (OCR), em função de sua influência direta sobre a compressibilidade do solo e de sua reconhecida variabilidade natural (Burland, Broms e De Mello, 1977; Phoon e Kulhawy, 1999).

Em etapa posterior, visando aprimorar o desempenho estatístico do modelo, avaliado pelo coeficiente de determinação (R^2), foram incorporados o índice de vazios inicial (e_0), a espessura da camada compressível (H) e a diferença das tensões verticais efetivas ($\Delta\sigma$) sem prejuízo da coerência física do problema (Das, 2016; Phoon, 2008).

Essa ampliação elevou o coeficiente de determinação do modelo de aproximadamente 0,32 para 0,87, justificando sua adoção nas análises de confiabilidade.

As médias e desvios-padrão dessas seis variáveis constituíram os parâmetros de entrada empregados tanto no método First-Order Second-Moment (FOSM) quanto na Simulação de Monte Carlo.

4 METODOLOGIA

A metodologia foi estruturada em quatro etapas: (i) geração de uma base de dados fictícios por Inteligência Artificial; (ii) ajuste de um modelo de regressão linear múltipla para estimativa dos recalques; (iii) aplicação do método First-Order Second-Moment (FOSM) para propagação das incertezas; e (iv) validação dos resultados por meio da Simulação de Monte Carlo.

A base de dados foi gerada utilizando o modelo ChatGPT (OpenAI), empregado como ferramenta auxiliar para produzir conjuntos de dados representativos de solos argilosos siltosos de média a alta compressibilidade da região Centro-Oeste do Brasil. As análises estatísticas e probabilísticas foram implementadas em linguagem Python e executadas no ambiente Google Colab.

Os dados produzidos passaram por um processo iterativo de verificação, sendo comparados com faixas de valores reportadas na literatura geotécnica para assegurar a coerência física entre os parâmetros antes de sua utilização nas análises.

4.1 Geração de Dados Fictícios por Inteligência Artificial

Inicialmente foi gerada uma base composta por 50 observações representativas de solos argilosos siltosos de média a alta compressibilidade, compatíveis com as condições geotécnicas predominantes da região Centro-Oeste do Brasil.

O processo de geração foi conduzido de forma iterativa, por meio do refinamento sucessivo dos comandos fornecidos ao modelo de Inteligência Artificial. Após cada iteração, os dados produzidos foram comparados com intervalos de valores amplamente reportados na literatura especializada, descartando-se combinações fisicamente inconsistentes e ajustando-se os critérios de geração até a obtenção de um conjunto de dados coerente com o comportamento esperado dos solos estudados.

Como critérios de referência para a geração dos dados, foram adotadas as seguintes características geotécnicas:

- Alta compressibilidade sendo ($C_c \approx 0{,}24$ e $e_0 \approx 1{,}1$), típico de argilas moles a médias;
- A razão $C_\alpha/C_c \approx 0{,}05$ com a indicação de um solo com o comportamento normalmente consolidado, com pouco recalque secundário;
- O peso específico médio de 18,9 kN/m³ sugerido para um material argiloso saturado;
- Os valores de SPT entre 13 e 24 confirmando uma consistência média do solo.

Os parâmetros gerados compreenderam espessura da camada compressível (H), resistência à penetração (NSPT), índice de vazios inicial (e_0), índice de compressão (Cc), índice de compressão secundária (Cα), tempos de adensamento, tensões verticais efetivas inicial e final, peso específico saturado e posição do nível d'água. Esses parâmetros constituíram a base utilizada para o desenvolvimento do modelo de previsão dos recalques.

4.2 Ajuste do Modelo de Regressão para Previsão de Recalques

Com base na base de dados gerada, ajustou-se inicialmente um modelo de regressão linear múltipla utilizando as variáveis Cc, Cα e OCR. Em seguida, foram incorporadas as variáveis H, e_0 e Δσ, resultando no modelo final empregado nas análises probabilísticas.

O desempenho do modelo foi avaliado por meio do coeficiente de determinação (R^2), da análise dos resíduos e da significância estatística dos coeficientes de regressão.

4.3 Análise Probabilística e Verificação do Estado Limite de Serviço

As médias e os desvios-padrão das variáveis de entrada foram utilizados na aplicação do método FOSM para determinação do índice de confiabilidade (β) e da probabilidade de falha (Pf).

Posteriormente, realizaram-se Simulações de Monte Carlo com 1.000 e 10.000 realizações, considerando distribuições normais para todas as variáveis de entrada. A convergência foi verificada pela estabilidade das estimativas da probabilidade de falha com o aumento do número de simulações, adotando-se o recalque admissível de 300 mm como Estado Limite de Serviço para comparação entre os métodos.

5 RESULTADOS E DISCUSSÃO

5.1 Dados Fictícios Gerados por Inteligência Artificial

A base de dados fictícios gerada por Inteligência Artificial apresentou valores compatíveis com as faixas normalmente reportadas para solos argilosos siltosos de média a alta compressibilidade da região Centro-Oeste do Brasil. A consistência física dos parâmetros permitiu sua utilização no ajuste do modelo estatístico e nas análises probabilísticas, possibilitando a obtenção de médias, desvios-padrão e distribuições de probabilidade representativas das variáveis de entrada.

5.2 Desempenho do Modelo de Regressão para Previsão de Recalques

O modelo inicial, ajustado com as variáveis índice de compressão (Cc), índice de compressão secundária (Cα) e razão de sobreadensamento (OCR), apresentou coeficiente de determinação (R^2) de aproximadamente 0,32, indicando capacidade limitada para representar a variabilidade observada nos recalques.

A incorporação das variáveis espessura da camada compressível (H), índice de vazios inicial (e_0) e incremento da tensão vertical efetiva (Δσ) elevou o coeficiente de determinação para aproximadamente 0,87, evidenciando melhora significativa da capacidade preditiva do modelo, como mostrado na Tabela 1.

Tabela 1. Comparação dos valores de R^2, Índice de Confiabilidade (β) e Probabilidade de Falha (Pf) para o método base (três variáveis) e o método estendido (seis variáveis).

Método Base (C_c, C_α, OCR)	Método Estendido (C_c, C_α, OCR, H, e_0 e $\Delta\sigma$)
$R^2 \approx 0{,}32$	$R^2 \approx 0{,}87$
$\beta \approx -0{,}56$	$\beta \approx -0{,}32$
Pf ≈ 71%	Pf ≈ 62%

A Figura 1 apresenta a comparação entre os recalques observados e estimados pelo modelo final, evidenciando redução da dispersão dos dados e melhor ajuste em torno da linha de tendência. Esses resultados demonstram que a consideração simultânea dos parâmetros de compressibilidade, da geometria da camada compressível e das condições de carregamento proporciona representação estatística mais consistente do comportamento do solo.

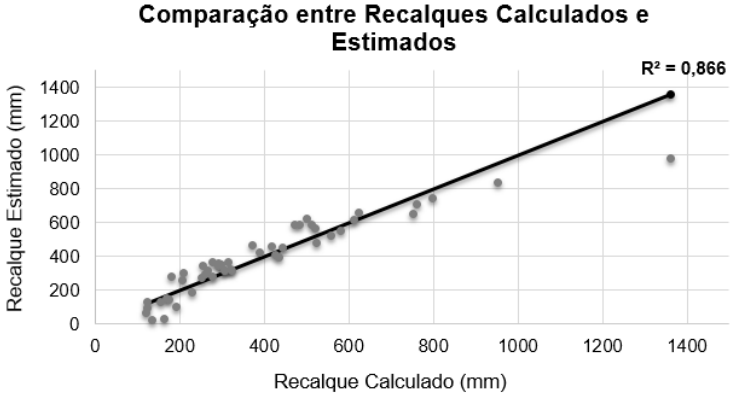


Figura 1. Comparação entre os recalques calculados e os recalques estimados pelo modelo de regressão linear múltipla. A linha 1:1 representa a concordância entre valores calculados e estimados, Autor (2025).

Esse resultado demonstra que, embora os parâmetros de compressibilidade exerçam papel fundamental na previsão dos recalques, a consideração simultânea das características geométricas da camada compressível e das condições de carregamento aumenta significativamente a capacidade do modelo em representar o comportamento do solo.

5.3 Resultados das Análises Probabilísticas e Verificação do Estado Limite de Serviço

Com base no modelo de regressão final, o método First-Order Second-Moment (FOSM) resultou em índice de confiabilidade $\beta \approx -0{,}32$ e probabilidade de falha próxima de 62% para o Estado Limite de Serviço (ELS) correspondente ao recalque admissível de 300 mm.

Para verificar a consistência dessas estimativas, foram realizadas Simulações de Monte Carlo com 1.000 e 10.000 realizações. As distribuições obtidas, apresentadas na Figura 2, mostraram comportamento aproximadamente normal e resultados muito próximos quanto à média, desvio-padrão e probabilidade de falha.

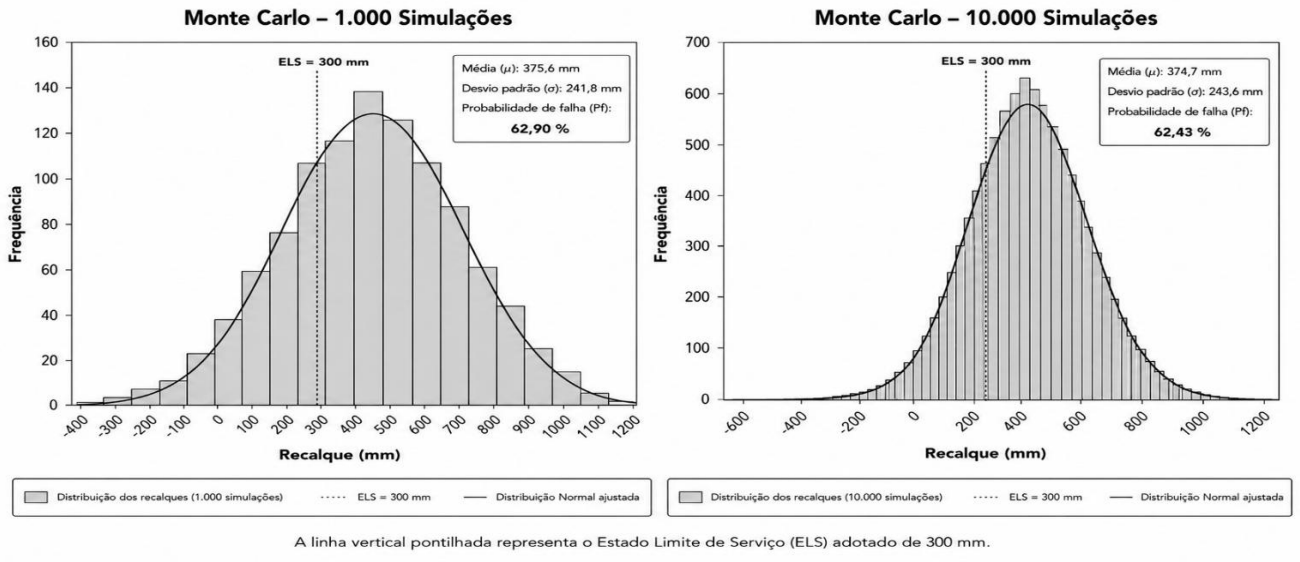


Figura 2. Histogramas de Recalque para simulações de 1.000 e 10.000 - Monte Carlo, Autor (2026).

O aumento do número de simulações promoveu apenas refinamento da distribuição estatística, sem alterações significativas dos parâmetros probabilísticos, evidenciando a convergência do método. A concordância entre os resultados obtidos pelo FOSM e pela Simulação de Monte Carlo confirma a consistência do modelo probabilístico adotado.

Embora a ampliação do modelo de regressão tenha elevado significativamente o coeficiente de determinação, a probabilidade de falha permaneceu elevada, indicando que a variabilidade inerente aos parâmetros geotécnicos continua exercendo influência predominante sobre a confiabilidade das previsões de recalque. Dessa forma, os resultados reforçam a importância da utilização de métodos probabilísticos como complemento às abordagens determinísticas na avaliação do desempenho de fundações em solos compressíveis.

6 CONCLUSÕES

O presente trabalho apresentou uma metodologia para análise probabilística de recalques primários e secundários em solos compressíveis utilizando dados fictícios gerados por Inteligência Artificial. A integração entre IA, regressão linear múltipla e métodos probabilísticos mostrou-se adequada para ampliar a base amostral e avaliar a influência das incertezas associadas aos parâmetros geotécnicos sobre as previsões de recalque.

O modelo inicial de regressão, baseado apenas nas variáveis índice de compressão (Cc), índice de compressão secundária (Cα) e razão de sobreadensamento (OCR), apresentou coeficiente de determinação (R^2) de aproximadamente 0,32. A incorporação das variáveis espessura da camada compressível (H), índice de vazios

inicial (e_0) e incremento da tensão vertical efetiva ($\Delta\sigma$) elevou esse coeficiente para aproximadamente 0,87, evidenciando melhora significativa na capacidade preditiva do modelo.

A aplicação do método First-Order Second-Moment (FOSM) resultou em probabilidade de falha próxima de 62% em relação ao Estado Limite de Serviço adotado, enquanto a Simulação de Monte Carlo apresentou resultados convergentes para 1.000 e 10.000 simulações, confirmando a consistência das estimativas probabilísticas obtidas.

Os resultados demonstram que a utilização de métodos probabilísticos fornece informações adicionais às abordagens determinísticas tradicionais, permitindo quantificar explicitamente a influência da variabilidade dos parâmetros geotécnicos sobre a confiabilidade das previsões de recalque.

Ressalta-se que os resultados apresentados estão condicionados às hipóteses adotadas para a geração dos dados fictícios e ao conjunto de parâmetros considerado neste estudo. Dessa forma, recomenda-se que trabalhos futuros avaliem a aplicação da metodologia utilizando bancos de dados experimentais, diferentes distribuições de probabilidade e modelos probabilísticos mais avançados, ampliando sua aplicabilidade em problemas geotécnicos reais.

REFERÊNCIAS BIBLIOGRÁFICAS

Ang, A. H. S.; Tang, W. H. *Probability concepts in engineering: emphasis on applications to civil and environmental engineering.* 2. ed. Hoboken: John Wiley & Sons, 2007.

Baecher, G. B.; Christian, J. T. *Reliability and Statistics in Geotechnical Engineering.* Chichester: John Wiley & Sons, 2003.

Burland, J. B.; Broms, B. B.; De Mello, V. F. B. *Behaviour of foundations and structures*. In: *Proceedings of the 9th International Conference on Soil Mechanics and Foundation Engineering*. Tokyo: ISSMFE, 1977. p. 495–546.

Ching, J.; Phoon, K.-K.; Hu, Y.-G. *Efficient evaluation of reliability for geotechnical applications using Monte Carlo simulation.* Computers and Geotechnics, v. 82, p. 13–24, 2017.

Das, B. M. *Principles of geotechnical engineering*. 9. ed. Stamford: Cengage Learning, 2016.

Fenton, G. A.; Griffiths, D. V. *Risk assessment in geotechnical engineering*. Hoboken: John Wiley & Sons, 2008.

Goh, A. T. C. *Back-propagation neural networks for modeling complex systems*. Artificial Intelligence in Engineering, v. 9, n. 3, p. 143–151, 1995.

Mesri, G.; Castro, A. *Settlement of organic soils*. Journal of Geotechnical Engineering, v. 113, n. 4, p. 381–397, 1987.

Mesri, G.; Godlewski, P. *Time- and stress-compressibility interrelationship*. Journal of the Geotechnical Engineering Division, v. 103, n. GT5, p. 417–430, 1977.

Phoon, K.-K. *Reliability-based design in geotechnical engineering: computations and applications*. Georisk, v. 2, n. 2, p. 81–102, 2008.

Phoon, K.-K.; Kulhawy, F. H. *Characterization of geotechnical variability*. Canadian Geotechnical Journal, v. 36, n. 4, p. 612–624, 1999.

Siacara, A. T.; Futai, M. A.; Beck, A. T. *Reliability analysis of a shallow foundation*. 20th International Conference on Soil Mechanics and Geotechnical Engineering (ICSMGE), Sydney. 2022.

Shahin, M. A.; Maier, H. R.; Jaksa, M. B. Predicting settlement of shallow foundations using neural networks. Journal of Geotechnical and Geoenvironmental Engineering, v. 128, n. 9, p. 785–793, 2002.

Terzaghi, K.; Peck, R. B.; Mesri, G. *Soil mechanics in engineering practice*. 3. ed. New York: John Wiley & Sons, 1996.

Publico

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/COBRAMSEG2026.2/3

Análise e Monitoramento de Aterros Ferroviários Instrumentados Utilizando Técnicas de *Business Intelligence*

Rânila Evellin Guedes Cardoso Mantovani Pereira
Engenheira Geotécnica, IDG Engenharia, Primavera do Leste-MT, Brasil, ranila_evellin@hotmail.com

Cleyton Guerino Dall'agnol da Cruz
Analista de Dados, Rumo S. A., Curitiba-PR, Brasil, cleytondacruz@gmail.com

Paola Dutra
Engenheira Geotécnica, Rumo S.A., Curitiba-PR, Brasil, paola_dutra@outlook.com

Mariane Sliwinski
Engenheira Civil, IDG Engenharia, Rondonópolis-MT, Brasil, marianesliwinski@gmail.com

RESUMO: A instrumentação para o monitoramento de estruturas geotécnicas é fundamental para garantir a segurança, análise de desempenho e identificação de desvios não previstos ao longo da construção. Na Ferrovia Estadual de Mato Grosso há alguns aterros instrumentados com placas de recalque, marcos superficiais e indicadores de nível de água, sendo a análise dos resultados realizada através de planilhas Excel. Em função da quantidade de dados analisados houve a necessidade da implementação de um controle integrado e confiável dos dados monitorados, reduzindo o tempo de análise e permitindo ações rápidas quando necessário. Este trabalho tem como objetivo apresentar a aplicação de *business intelligence (BI)* no acompanhamento de aterros instrumentados da Ferrovia de Mato Grosso. Foi realizado um diagnóstico da atual situação de monitoramento e redefinido um novo fluxo de coleta e armazenamento dos dados, bem como desenvolvido um painel com software *Power* BI para análise dos resultados. O painel permite visualizar a magnitude e a velocidade dos recalques, além de emitir alertas para leituras inconsistentes, recalques elevados ou velocidades expressivas. O desenvolvimento dessa ferramenta resultou em maior assertividade das análises, tornou mais dinâmico o acompanhamento e liberação dos aterros e viabilizou o acesso ao histórico dos dados de monitoramento, fornecendo *insights* relevantes para o projeto executivo de trechos ainda em elaboração.

PALAVRAS-CHAVE: Instrumentação, Ferrovia, Business Intelligence, Placa de recalque, Marco superficial.

ABSTRACT: Instrumentation for monitoring geotechnical structures is fundamental to ensuring safety, performance analysis, and identification of unforeseen deviations during construction. On the Mato Grosso State Railway, several embankments are instrumented with settlement plates, surface settlement marker, and water level indicators, with results analysis performed using Excel spreadsheets. Due to the amount of analyzed data, there was a need to implement integrated and reliable control of the monitored data, reducing analysis time and allowing for quick actions when necessary. This work aims to present the application of business intelligence (BI) in the monitoring of instrumented embankments on the Mato Grosso Railway. A diagnosis of the current monitoring situation was carried out, and a new data collection and storage flow was redefined, as well as the development of a dashboard using Power BI software for results analysis. The dashboard allows visualization of the magnitude and speed of settlements, in addition to issuing alerts for inconsistent readings, high settlements, or significant speeds. The development of this tool resulted in more accurate analyses, made the monitoring and release of landfills more dynamic, and enabled access to historical monitoring data, providing relevant insights for the detailed design of sections still under development.

KEYWORDS: Instrumentation, Railway, Business Intelligence, Settlement plate, Surface Settlement Marker.

Publico

1 INTRODUÇÃO

O monitoramento geotécnico constitui uma etapa essencial em obras de infraestrutura, pois garante maior segurança, previsibilidade e controle do comportamento do maciço e das estruturas associadas. Conforme apresentado no estudo de caso da modernização da Ferrovia na Eslováquia, o monitoramento geotécnico de um corte corroborou para o acompanhamento do deslizamento ocorrido durante e após a execução da obra, assim como a avaliação da variação do nível de água (KOPECKÝ et al; 2020).

De forma análoga, a Ferrovia Estadual do Mato Grosso possui diversos aterros que foram instrumentados para acompanhar o comportamento geotécnico durante a implantação da via. Considerando que a natureza linear da referida obra amplia a complexidade do monitoramento, dado o grande número de pontos instrumentados distribuídos por longas extensões, e utilizar métodos tradicionais de análise de dados, baseados em planilhas Excel, mostraram-se limitados frente ao crescente volume de dados.

Com isso a consolidação manual das leituras e a dificuldade de correlacionar informações de diferentes instrumentos tornaram os processos lentos, suscetíveis a erros e menos eficientes para a tomada de decisão.

Nesse contexto, tornou-se necessário um sistema mais integrado e dinâmico para o tratamento das informações de monitoramento. Ferramentas de *Business Intelligence* (BI) apresentam-se como solução ao automatizar o processamento dos dados, integrar múltiplas fontes e permitir visualizações intuitivas e atualizadas. Além disso, possibilitam a criação de alertas automáticos e a avaliação conjunta da magnitude e velocidade dos recalques, favorecendo a rápida identificação de leituras anômalas.

Dessa forma, este trabalho apresenta o desenvolvimento e a aplicação de uma solução em BI para o acompanhamento de aterros instrumentados da Ferrovia Estadual de Mato Grosso. O estudo abrange o diagnóstico do sistema atual de monitoramento, a reestruturação do fluxo de coleta e armazenamento das informações e a elaboração de um painel interativo em Power BI, destinado à análise integrada dos resultados.

O artigo está organizado da seguinte forma: na seção 2, descreve-se a metodologia adotada para o desenvolvimento da solução; na seção 3, apresentam-se e discutem-se os resultados obtidos com a implementação do BI; e, por fim, na seção 4, são apresentadas as conclusões da utilização da ferramenta.

2 METODOLOGIA

A metodologia deste trabalho estruturou-se, inicialmente, em um diagnóstico situacional do fluxo de monitoramento. Identificou-se que o armazenamento dos dados ocorria em planilhas eletrônicas descentralizadas, segregadas por tipo de instrumento e localização geográfica. Esse modelo de controle apresentava limitações críticas, como a dificuldade na correlação de leituras entre diferentes instrumentos e a inexistência de filtros dinâmicos que permitissem uma análise fluida e integrada.

Diante desse cenário, seguiu-se para a padronização e higienização dos dados, culminando na unificação das fontes em três repositórios principais, classificados como Tabelas Fato (uma para cada tipo de instrumento). Paralelamente, aplicou-se o conceito de Tabelas Dimensão para o gerenciamento de dados categóricos e metadados dos instrumentos e aterros. Após a consolidação das fontes, as bases foram integradas ao software Power BI, dando início ao processo de ETL (*Extract, Transform, Load*), visando a garantia da integridade e a automação do fluxo de informações e posterior geração dos dashboards (FERREIRA *et al*, 2010).

2.1 Instrumentos Geotécnicos

Instrumentos geotécnicos são dispositivos utilizados para medir, monitorar e controlar o comportamento do solo e das estruturas geotécnicas ao longo do tempo. Na Ferrovia de Mato Grosso foram instalados, nos aterros, 3 (três) tipos de instrumentos geotécnicos: placas de recalque (PR), marcos superficiais (MS) e indicadores de nível de água (INA).

A precisão e a periodicidade dessas leituras são fundamentais, pois fornecem os dados brutos necessários para a identificação precoce de comportamentos anômalos que possam comprometer a integridade da via.

Publico

2.1.1 Placa de Recalque

A placa de recalque é um instrumento composto por uma base quadrada e uma haste central com rosca na ponta, e é instalada, no geral, na base do aterro. Conforme o aterro é alteado, adiciona-se uma nova haste, possibilitando assim a leitura do instrumento até a finalização do aterro (ALMEIDA E MARQUES, 2010).

O objetivo da placa de recalque é medir os deslocamentos verticais desde a fundação e para isso o monitoramento é realizado com a leitura da cota da haste em conjunto com a leitura da cota do aterro. Assim, é possível avaliar o recalque ocorrido em detrimento da altura do aterro.

O recalque é a diferença entre a leitura atual e a leitura anterior. Cabe destacar que no gráfico é representado no eixo das abcissas a data das leituras, e no eixo negativo das ordenadas, o recalque acumulado, já no eixo positivo das ordenadas, a cota do aterro acumulada.

2.1.2 Indicador de Nível de Água

O indicador de nível de água tem como objetivo monitorar a variação do nível de água, podendo ser instalado na fase de projeto de forma a se ter dados de referência para o projeto, ou pode ser instalado no início da obra.

No geral, o instrumento é instalado no pé do talude e tem como referência a cota do terreno natural. As leituras são realizadas com o pio e a diferença entre a cota do terreno natural e a leitura corresponde a cota do nível de água.

Tem-se, no gráfico, o eixo das abcissas se referindo a data das leituras, enquanto o eixo das ordenadas contém cota do nível de água e uma constante que se refere ao terreno natural.

2.1.3 Marco superficial

O marco superficial é composto por um bloco de concreto e uma haste central que serve para realizar as leituras e pode ser instalado no pé do talude, na berma ou na plataforma do aterro.

O instrumento tem como objetivo medir os deslocamentos verticais e horizontais da plataforma. O vertical é a diferença entre a cota da leitura atual e a cota da primeira leitura, já o deslocamento horizontal é calculado pela Equação 1.

$$Deslocamento\ horizontal = \sqrt{(X_n - X_i)^2 + (Y_n - Y_i)^2} \quad (1)$$

Sendo:
X_i e Y_i – Leituras de norte e leste iniciais;
X_n e Y_n – Leituras de norte e leste atuais.

O gráfico apresenta no eixo das abcissas a data da leitura, já nas ordenadas se tem os deslocamentos verticais e horizontais.

2.2 Limpeza e Tratamento dos Dados

A etapa de ETL (*Extract, Transform, Load*) foi executada por meio da ferramenta Power Query. O processo de extração conectou-se às fontes de dados padronizadas, seguido por uma fase rigorosa de transformação. Nesta fase, aplicou-se a limpeza de registros inconsistentes, a tipagem correta de variáveis (datas, coordenadas e medidas decimais) e a criação de colunas condicionais para validação de erros de campo. Essa transformação prévia ao carregamento (*Load*) no modelo de dados garantiu a redução da redundância e a otimização da performance analítica.

Após o carregamento dos dados, a inteligência analítica foi implementada por meio da linguagem DAX (*Data Analysis Expressions*) que permite uma análise dinâmica dos desvios geotécnicos, fundamentada em dois pilares comparativos: os parâmetros nominais de projeto e o histórico de leituras sucessivas.

Para a avaliação de deslocamentos, como no caso das placas de recalques (PR), a lógica computacional foi estruturada para calcular a variação em relação ao *v0* (leitura inicial de instalação). Essa variação é contrastada

continuamente com as leituras imediatamente anteriores para determinar a velocidade de movimentação. Para operacionalizar a gestão de riscos, foram desenvolvidas colunas auxiliares de alerta e 'faróis' de criticidade. Essas colunas aplicam regras lógicas que classificam o status do instrumento como “Sem Ação”, “Atenção” ou “Alerta”, baseando-se em limites normativos de velocidade e magnitude de deslocamento, permitindo a identificação imediata de comportamentos anômalos ou desvios do projeto executivo.

2.3 Definição do Modelo de Dados

A estruturação dos dados seguiu o modelo dimensional *Star Schema*, visando a otimização da performance de processamento e clareza analítica. O modelo é composto por tabelas de dimensões, que contêm os metadados e parâmetros de projeto, e tabelas de fatos que armazenam os registros históricos das medições de campo. A integridade dos dados é mantida através de relacionamentos de um-para-muitos (1:*), utilizando chaves primárias únicas por instrumento (KIRMANI; 2017). Adicionalmente, implementou-se uma tabela de “Calendário” para viabilizar funções de inteligência de tempo, permitindo a análise da evolução dos desvios em períodos.

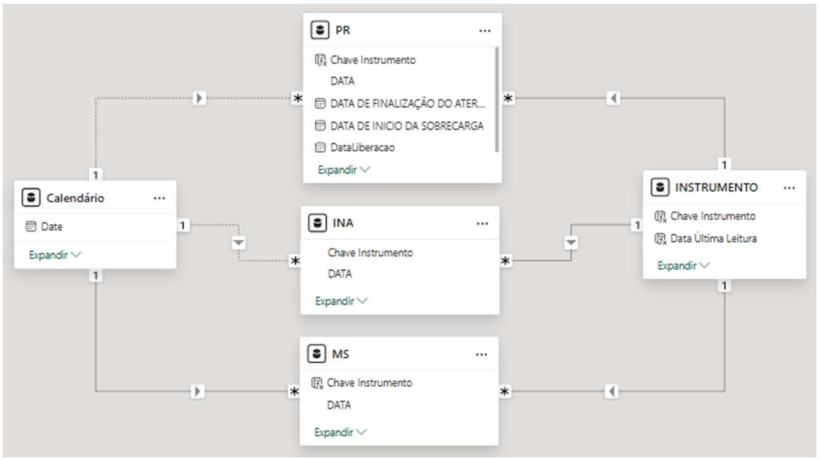


Figura 1: Diagrama de Entidade-Relacionamento (DER) em *star schema*.

A adoção do *Star Schema* permitiu a desnormalização controlada dos dados, o que facilita o consumo por usuários finais e agiliza o tempo de resposta das consultas (*queries*). Enquanto as tabelas fato (PR, INA e MS) registram a volatilidade das leituras de campo, as tabelas dimensão funcionam como o “dicionário” do projeto, armazenando os códigos dos instrumentos, cotas de projeto e coordenadas. Essa separação é fundamental para evitar o crescimento desordenado das bases de dados, garantindo que o histórico de milhares de leituras não comprometa a velocidade de filtragem por trecho ou construtora.

2.4 Desenvolvimento do Dashboard

A última etapa consistiu na estruturação da interface de visualização (*front-end*), projetada para oferecer uma hierarquia de informações que suportasse a tomada de decisão ágil. O painel foi segmentado em abas específicas para cada tipologia de instrumentação (PR, MS e INA), mantendo uma identidade visual padronizada para facilitar a curva de aprendizado dos usuários.

O diferencial geoespacial foi obtido através da integração do visual ArcGIS for Power BI, o que permitiu a criação de um mapa com a localização exata de cada instrumento em relação ao traçado ferroviário. Para realizar essa integração, elaborou-se um mapa no ArcGIS Enterprise, Figura 2, utilizando os arquivos *shapefile* contendo, dentre outras informações, o traçado ferroviário, estaqueamento e plataforma.

O uso desse visual eleva o painel de um gráfico estático para um Sistema de Informação Geográfica (SIG) dinâmico. A sobreposição dos dados de monitoramento ao *shapefile* da plataforma ferroviária permite que o engenheiro identifique padrões espaciais de recalque, como trechos com solos moles que podem estar apresentando comportamentos similares em diferentes instrumentos.

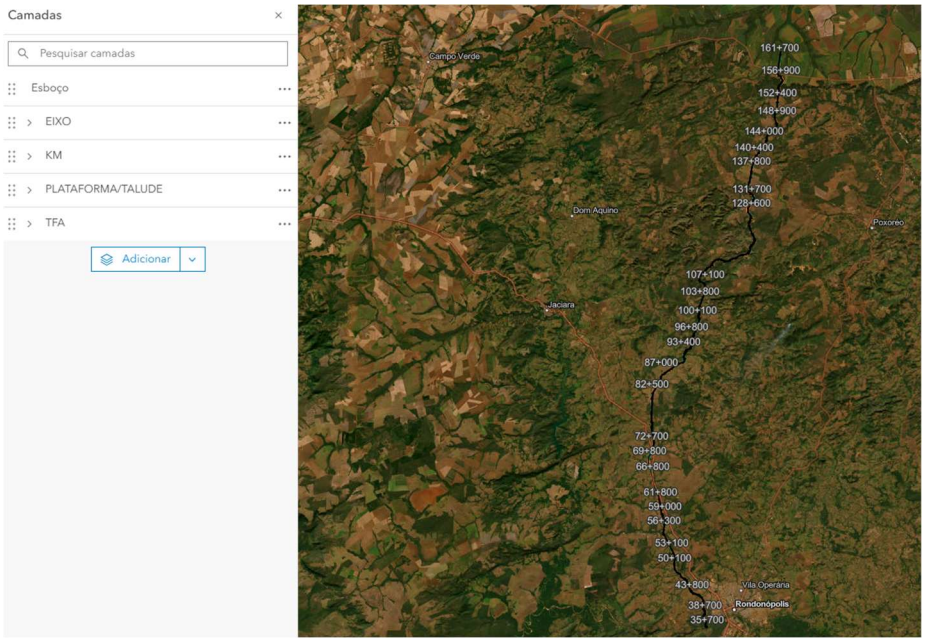


Figura 2: Elaboração do mapa no ArcGIS Enterprise.

A evolução temporal dos dados é apresentada em gráficos de linhas, que correlacionam a altura do aterro com o recalque medido. Por fim, uma tabela analítica detalha as leituras individuais, utilizando a técnica de formatação condicional (coluna 'Farol') que atua como uma camada de inteligência preventiva. A lógica inserida não se limita a valores estáticos. Ela processa cálculos automáticos que comparam a velocidade de recalque com os limites de segurança estabelecidos na literatura técnica e no histório de leituras realizadas. Assim, o destaque em vermelho serve como um gatilho para a suspensão imediata de novas camadas de aterro ou para o início de investigações complementares, reduzindo o intervalo entre o evento físico em campo e a ação mitigadora da gestão de engenharia.

3 RESULTADOS

Foram desenvolvidas três (03) interfaces gráficas interativas destinadas à consolidação e análise dos dados de instrumentação. Essas interfaces permitem a seleção do pacote de contratação da obra, do segmento de localização dos instrumentos, do código do Tratamento de Fundação (TFA), da linha/eixo de implantação e do código individual de cada instrumento. Por meio desses filtros, torna-se possível avaliar tanto um conjunto específico de instrumentos associados a determinado eixo quanto todos os instrumentos de uma mesma região, otimizando a interpretação dos resultados e aumentando a agilidade na análise.

Os gráficos, anteriormente alimentados manualmente via planilhas Excel, passaram a ser atualizados automaticamente, permitindo a visualização e interpretação de instrumentos de forma isolada ou integrada. Essa automatização reduziu significativamente o tempo despendido e o número de etapas necessárias para atualização e validação das informações.

Além disso, a análise gráfica encontra-se integrada à visualização espacial dos instrumentos em planta, o que facilita a correlação entre os dados monitorados e sua posição no empreendimento. Dessa forma, a equipe de engenharia consegue navegar de maneira rápida e intuitiva entre diferentes instrumentos e localidades, superando limitações anteriormente existentes no modelo baseado exclusivamente em planilhas.

Na sequência, são apresentadas as interfaces desenvolvidas para placas de recalque, marcos superficiais e indicadores de nível d'água. As plataformas são atualizadas semanalmente pelas construtoras e analisadas periodicamente pela equipe de engenharia da Rumo e IDG Engenharia, garantindo maior confiabilidade e eficiência no acompanhamento do comportamento geotécnico da obra.

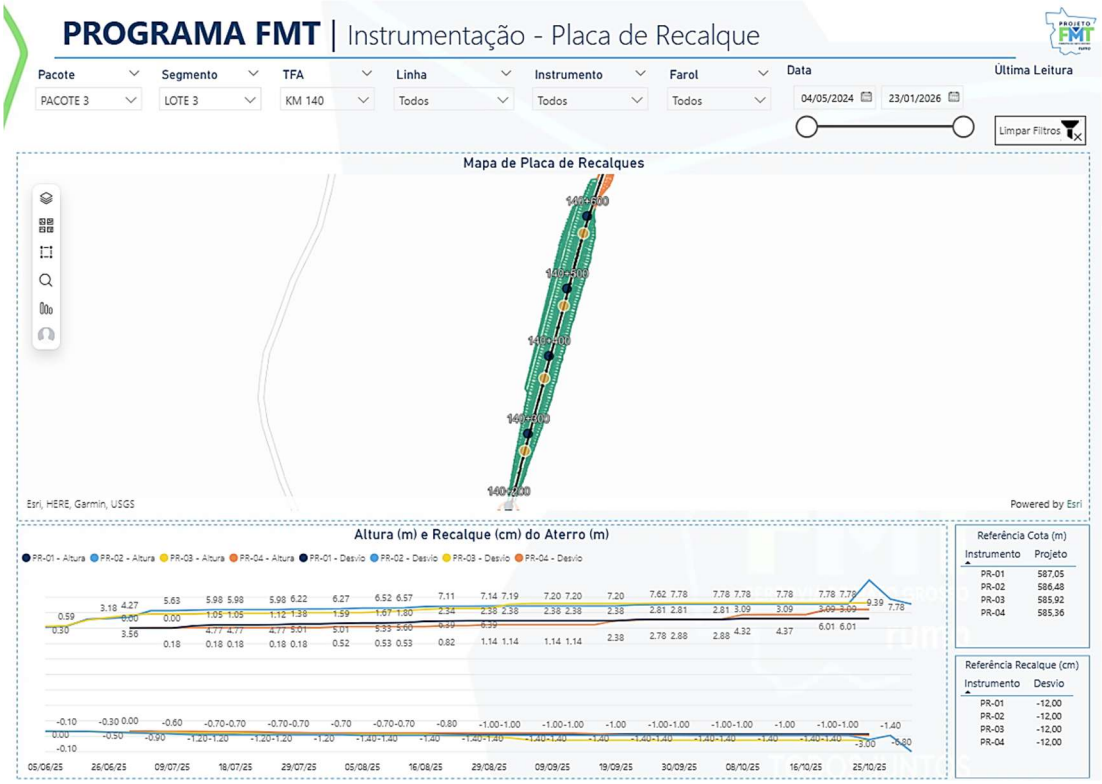


Figura 3. Instrumentação – Placa de Recalque.

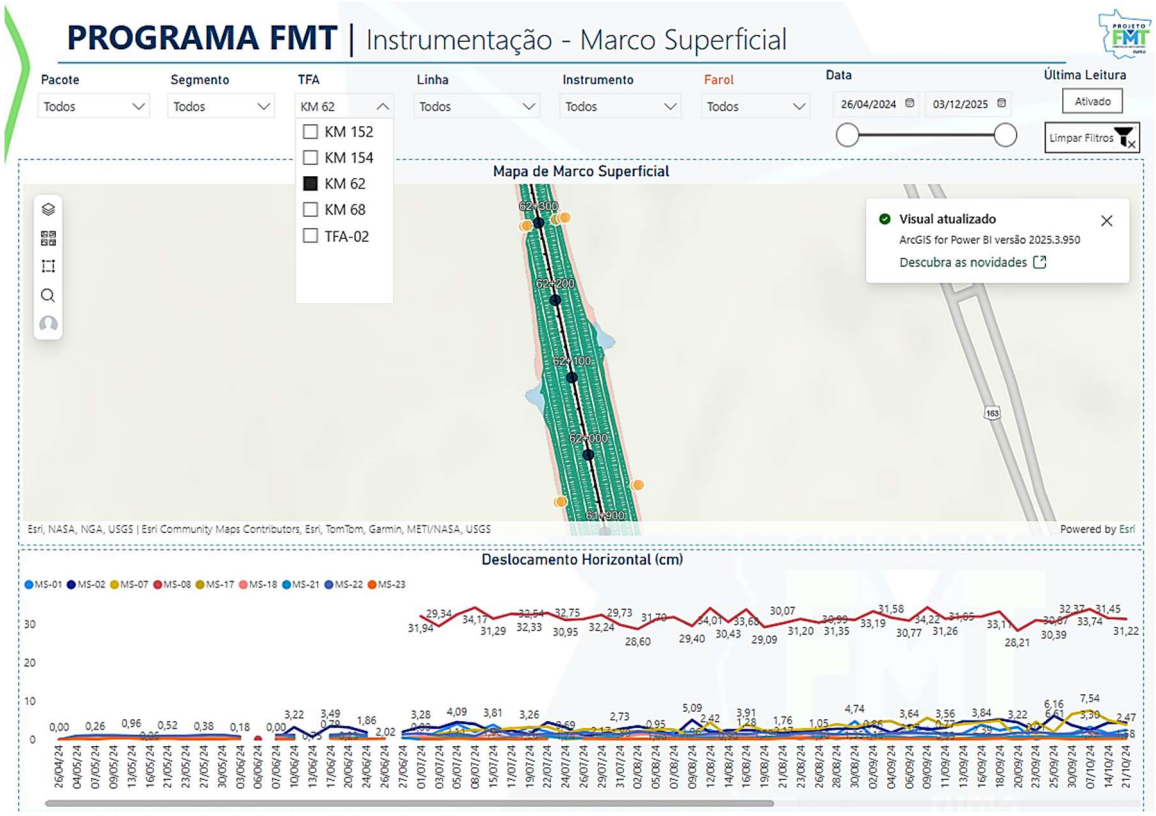


Figura 4. Instrumentação - Marco Superficial.

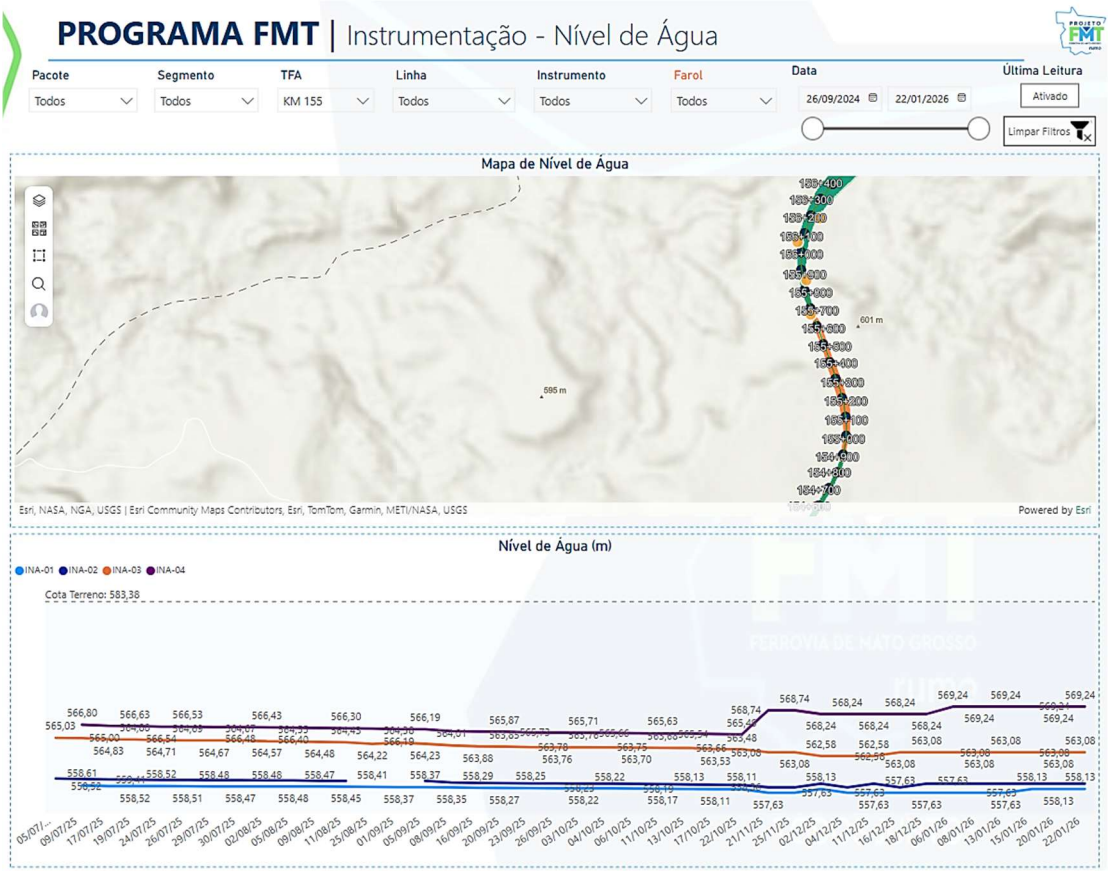


Figura 5. Instrumentação – Indicador de nível de água.

Além da visualização gráfica, a interface disponibiliza informações detalhadas de cada instrumento. Como exemplificado na Figura 6, para as placas de recalque são apresentados parâmetros como: cota atual do aterro, altura do aterro, data de prolongamento da haste, recalque de projeto, recalque observado, percentual de recalque (considerando 100% como o recalque máximo previsto), percentual de alteamento do aterro (considerando 100% como o alteamento máximo de projeto) e recalque diário.

Adicionalmente, a interface possui um campo de farol de acompanhamento, responsável por sinalizar automaticamente leituras que apresentem comportamento divergente do previsto em projeto. Na Figura 6, observa-se a ocorrência de instrumentos que registraram recalques significativamente superior à previsibilidade de projeto, resultando na emissão de alerta e demandando avaliações complementares pela equipe de engenharia nas respectivas localidades.

Dados das Leituras

Ordem	KM	TFA	Linha	Instrumento	Data Leitura	Cota Proj Aterro	Cota do Aterro	Altura do Aterro (m)	Cota PR	Prolong Haste	Recalque Proj (cm)	Recalque (cm)	% Recalque	% Aterro	Recalque Diário	Farol Recalque
304	51+860	KM 51	LINHA CC	PR-01	26/08/25	292,20	292,30	3,85	293,94		-3,00	-4,56	152,00%	100,04%	-0,10	Alerta
1105	152+850	KM 152	KM 152+850	PR-02	19/05/25	589,22	587,07	6,30	588,32		-12,00	-19,00	158,33%	99,64%	-0,22	Alerta
1106	152+850	KM 152	KM 152+850	PR-02	20/05/25	589,22	588,26	7,49	589,81	589,81	-12,00	-19,00	158,33%	99,84%	0,00	Alerta
1107	152+850	KM 152	KM 152+850	PR-02	24/05/25	589,22	588,29	7,52	589,80		-12,00	-20,50	170,83%	99,84%	-0,37	Alerta
1108	152+850	KM 152	KM 152+850	PR-02	27/05/25	589,22	588,76	7,99	589,80		-12,00	-20,50	170,83%	99,92%	0,00	Alerta
1109	152+850	KM 152	KM 152+850	PR-02	28/05/25	589,22	588,81	8,04	589,80		-12,00	-20,50	170,83%	99,93%	0,00	Alerta
1110	152+850	KM 152	KM 152+850	PR-02	30/05/25	589,22	588,81	8,04	589,80		-12,00	-20,50	170,83%	99,93%	0,00	Alerta
1111	152+850	KM 152	KM 152+850	PR-02	05/06/25	589,22	589,01	8,24	589,80		-12,00	-20,50	170,83%	99,97%	0,00	Alerta
1112	152+850	KM 152	KM 152+850	PR-02	09/06/25	589,22	589,20	8,43	589,80		-12,00	-20,50	170,83%	100,00%	0,00	Alerta
1113	152+850	KM 152	KM 152+850	PR-02	14/06/25	589,22	589,23	8,46	589,80		-12,00	-20,50	170,83%	100,00%	0,00	Alerta
1114	152+850	KM 152	KM 152+850	PR-02	26/06/25	589,22	589,23	8,46	589,80		-12,00	-20,50	170,83%	100,00%	0,00	Alerta
1115	152+850	KM 152	KM 152+850	PR-02	02/07/25	589,22	589,19	8,42	589,80		-12,00	-20,50	170,83%	100,00%	0,00	Alerta
1116	152+850	KM 152	KM 152+850	PR-02	05/07/25	589,22	589,19	8,42	589,80		-12,00	-20,50	170,83%	99,99%	0,00	Alerta
1117	152+850	KM 152	KM 152+850	PR-02	09/07/25	589,22	589,18	8,41	589,80		-12,00	-20,50	170,83%	99,99%	0,00	Alerta
1118	152+850	KM 152	KM 152+850	PR-02	17/07/25	589,22	589,19	8,42	589,80		-12,00	-20,50	170,83%	100,00%	0,00	Alerta
1119	152+850	KM 152	KM 152+850	PR-02	19/07/25	589,22	589,19	8,42	589,80		-12,00	-20,50	170,83%	100,00%	0,00	Alerta
1120	152+850	KM 152	KM 152+850	PR-02	24/07/25	589,22	589,19	8,42	589,80		-12,00	-20,50	170,83%	100,00%	0,00	Alerta
1121	152+850	KM 152	KM 152+850	PR-02	26/07/25	589,22	589,19	8,42	589,80		-12,00	-20,50	170,83%	100,00%	0,00	Alerta

Figura 6. Instrumentação – Placa de recalque – Dados detalhados.

4 CONSIDERAÇÕES FINAIS

O desenvolvimento do painel de monitoramento geotécnico em *Power BI* representou uma mudança de paradigma na gestão da Ferrovia Estadual de Mato Grosso. A transição do controle manual e descentralizado em planilhas para um ecossistema de *Business Intelligence* permitiu a redução drástica do tempo de resposta entre a leitura de campo e a tomada de decisão técnica. A automação das métricas em linguagem DAX e a integração geoespacial via ArcGIS garantiram que desvios de comportamento, como velocidades de recalque excessivas ou níveis freáticos críticos, fossem identificados visualmente de forma imediata através do sistema de alertas (faróis).

Além do ganho de produtividade para a equipe de engenharia, a centralização do histórico em um modelo de dados estruturado viabilizou *insights* retroalimentadores para o projeto executivo de trechos adjacentes. Como perspectiva futura, o grupo de trabalho vislumbra a implementação de algoritmos de *Machine Learning* integrados à base de dados consolidada. O objetivo é transitar de um modelo de monitoramento reativo para um preditivo, onde modelos de regressão e redes neurais possam estimar, com base no histórico de leituras e características do solo, o risco probabilístico de colapso ou instabilidade de aterros, elevando ainda mais os padrões de segurança operacional da infraestrutura ferroviária.

AGRADECIMENTOS

Os autores agradecem à IDG Engenharia e a Rumo S.A. pelo suporte para o desenvolvimento deste trabalho.

REFERÊNCIAS BIBLIOGRÁFICAS

Almeida, M. S. S.; Marques, M. E. S. (2010) *Aterros sobre solos moles: projeto e desempenho*, 1 ed. Oficina de Textos, São Paulo, Brasil, 256 p.

Ferreira, J., Mirranda, M., Abelha, A., Machado, J. (2010) *O Processo ETL em sistemas data warehouse*. In: INForum II Simpósio de Informática, Braga, Portugal. v. 1, p. 757-765.

Kopecký, M., Ondrášik, M., Brček, M. (2020) *Remediation and monitoring of unstable slope of railway cut*. In: 5th World Multidisciplinary Civil Engineering-Architecture-Urban Planning Symposium – WMCAUS, Praga, Tchéquia. v. 960, p. 10.

Kirmani, M. M. (2017) *Dimensional Modeling using star schema for data warehouse creation*. In: Oriental Journal of Computer Science and Technology, Srinagar, India. v. 10, p. 10.

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.

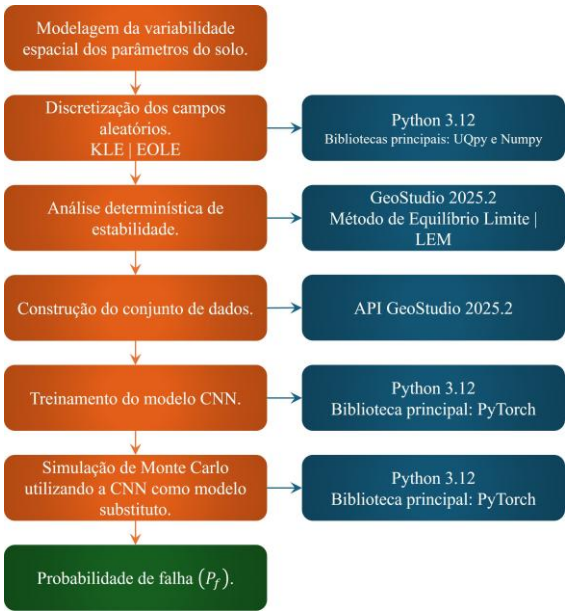


Figura 1. Estrutura metodológica para previsão do *FoS* em taludes com variabilidade espacial do solo utilizando redes neurais convolucionais.

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).

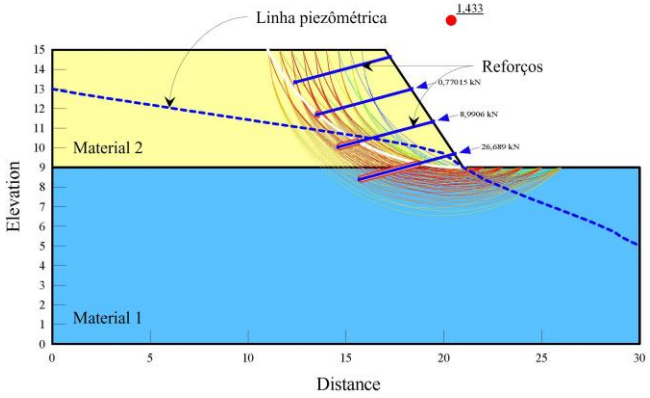


Figura 2. Geometria do modelo de talude grampeado utilizado no estudo de caso.

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.

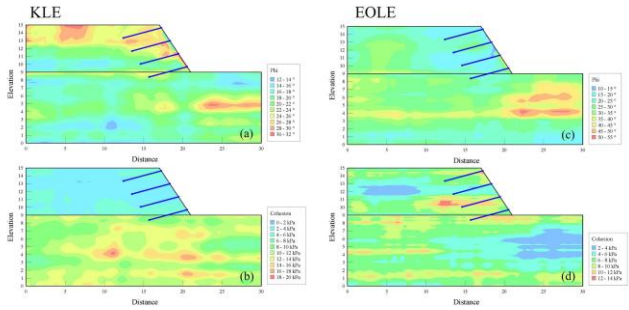


Figura 3. Realização de campos aleatórios. (a - c) ângulo de atrito efetivo; (b - d) coesão efetiva.

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.

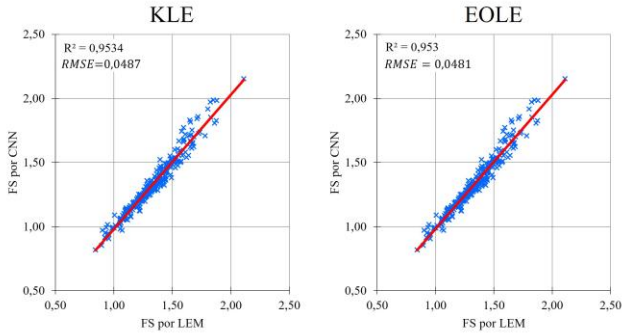


Figura 4. Desempenho do modelo CNN na previsão do fator de segurança.

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

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/COBRAMSEG2026.2/5

ANN-Based Prediction of Slope Stability Using a Dimensionless Formulation for Homogeneous Dry Slopes

Pablo Gondim de Oliveira
Civil Engineer, Prefeitura Municipal de Joinville, Joinville, Brazil, pablo.gondim.oliveira@gmail.com

Naloan Coutinho Sampa
Professor, Federal University of Santa Catarina, Florianópolis, Brazil, naloan.sampa@ufsc.br

Maria Eduarda Vieira
Student of Civil Engineer, Federal University of Santa Catarina, Florianópolis, Brazil, maria.eduarda.v@grad.ufsc.br

ABSTRACT: This study presents the development of an artificial neural network (ANN) model as a surrogate tool for predicting the factor of safety (FS) of homogeneous dry slopes with circular failure surfaces. A dataset of 455 samples was generated through parametric analyses using the Morgenstern–Price limit equilibrium method implemented in Slope/W. The problem was formulated using dimensionless and geometric parameters, namely the stability number (N_s), slope angle (β), and soil friction angle (ϕ). A systematic evaluation of ANN architectures was conducted, considering variations in the number of hidden layers, neurons, activation functions, and optimization algorithms. The optimal configuration consisted of four hidden layers with a total of 95 neurons, ReLU activation functions, and the Adam optimizer. Model training incorporated data normalization and cross-validation to improve generalization. The selected model achieved high predictive accuracy within the training domain, with a coefficient of determination (R^2) of 0.999 and a mean absolute error (MAE) of 0.0344 for the test dataset. Comparisons with limit equilibrium methods and strength reduction analyses indicated strong agreement. Consistent trends were also observed in relation to empirical stability equations. However, larger discrepancies were identified when compared with stability charts, particularly for conditions outside the training range, indicating limitations in extrapolation. The results demonstrate that ANN-based models can provide efficient and accurate predictions of slope stability for homogeneous dry conditions, serving as a practical alternative for preliminary analyses. The results highlight both the efficiency of ANN-based surrogate models and the importance of representative datasets for reliable application.

KEYWORDS: artificial neural networks; slope stability; factor of safety; stability number; surrogate modeling.

1 INTRODUCTION

Slope stability analysis is a fundamental problem in geotechnical engineering, involving the estimation of the factor of safety (FS) and the identification of potential failure mechanisms. Among the available approaches, limit equilibrium methods (LEM) are widely used in engineering practice due to their simplicity, robustness and ability to incorporate different loading and soil conditions (Duncan, 2005; Abramson et al., 2002). However, these methods typically require iterative procedures with varying slip surfaces to determine the critical condition, which can be computationally demanding and time-consuming (Mamat et al., 2022; Ray et al., 2020).

Numerical approaches based on the method (SRM) provide more rigorous solutions by incorporating stress-strain relationships and failure mechanisms without predefining the slip surface (Dawson et al., 1999; Cheng et al., 2007). Despite their advantages, these methods involve high computational cost and require careful modeling assumptions, including mesh discretization, constitutive models, and convergence criteria (Duncan, 1996; Kolbadi et al., 2019). On the other hand, simplified tools such as stability charts and empirical equations allow rapid estimation of FS, but their applicability is generally limited to specific conditions (Taylor, 1937; Barnes, 1991; Sampa and Schorr, 2024).

Given these limitations, there is an increasing demand for methods that combine accuracy with computational efficiency. In recent years, artificial intelligence techniques, particularly artificial neural

networks (ANNs), have been increasingly applied to geotechnical problems due to their ability to model complex and nonlinear relationships between input parameters and system responses (Shahin et al., 2002; Haykin, 2001; Bui et al., 2019). Several studies have demonstrated the effectiveness of ANNs in predicting slope stability and related geotechnical phenomena (Abdalla et al., 2014; Gelisli et al., 2015; Rukhaiyar et al., 2017; Mamat et al., 2022; Ray et al., 2020). However, the predictive performance and generalization capability of these models depend strongly on the representativeness and range of the training dataset.

For homogeneous slopes, the use of dimensionless parameters, such as the stability number (N_s), provides a consistent framework to relate soil strength and slope geometry, reducing problem dimensionality and facilitating generalization (Taylor, 1937; Duncan, 1996; Sampa and Schorr, 2024). This approach has been widely adopted in stability charts and analytical formulations for preliminary design and analysis.

In this context, this study proposes the development of an ANN-based model to predict the factor of safety of homogeneous dry slopes with circular failure surfaces. The model is formulated using the stability number (N_s), slope angle (β), and soil friction angle (ϕ) as input variables. A dataset comprising 455 samples was generated through parametric analyses using the Morgenstern–Price method (Morgenstern and Price, 1965) implemented in Slope/W (GeoStudio, 2021).

A systematic evaluation of ANN architectures is conducted to identify the optimal configuration. The performance of the proposed model is assessed through comparisons with limit equilibrium methods, strength reduction analyses, stability charts, and empirical equations reported in the literature. Additionally, the generalization capability of the model is evaluated, particularly for conditions outside the training domain.

Despite the increasing application of artificial neural networks in slope stability analysis, there remains a lack of studies that integrate dimensionless formulations, such as the stability number (NS), with systematic comparisons across different classes of methods, including limit equilibrium, numerical methods, stability charts, and stability equations. In addition, the generalization capability of ANN models under controlled parametric conditions is still not fully understood.

The main contribution of this study lies in the development of a computationally efficient ANN model and a comprehensive comparison with established methods.

2 METHODOLOGY

The proposed methodology aims to develop a predictive artificial neural network (ANN) model for estimating the factor of safety (FS) of homogeneous dry slopes. The approach is structured into four main stages (Figure 1): (i) problem definition and dataset generation, (ii) data preprocessing, (iii) ANN model development, and (iv) model evaluation and comparison.

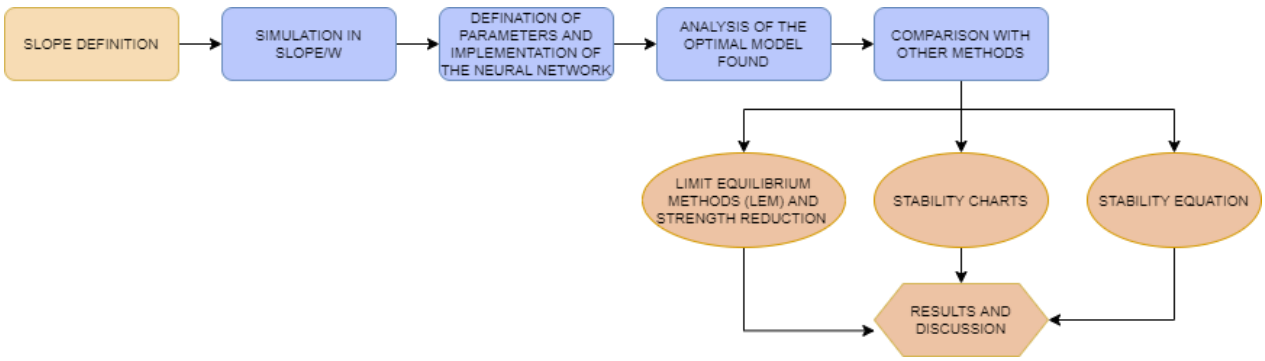


Figure 1. The methodology structure.

2.1 Problem Definition and Dataset Generation

The study focuses on homogeneous dry slopes subjected to circular failure mechanisms. The factor of safety (FS) is computed using the Morgenstern-Price method (Morgenstern and Price, 1965), a rigorous limit equilibrium formulation that satisfies both force and moment equilibrium. All analyses were performed using the Slope/W module of GeoStudio (GeoStudio, 2021).

A parametric analysis was conducted to generate a consistent and controlled dataset. The following variables were considered: slope angle (β): 15º to 85º; friction angle (ϕ): 10º to 40º; cohesion (c): 0 to 16 kPa; soil unit weight (γ): 10 to 25 kN/m³; and foundation depth (d) of 10 m.

The slope height (H) was kept constant at 3.5 m, and the foundation width was fixed at 30 m to ensure consistency across simulations (Figure 2). A total of 455 slope configurations were analyzed. For each case, the critical FS was determined through an automatic search of potential slip surfaces, based on multiple trial circles.

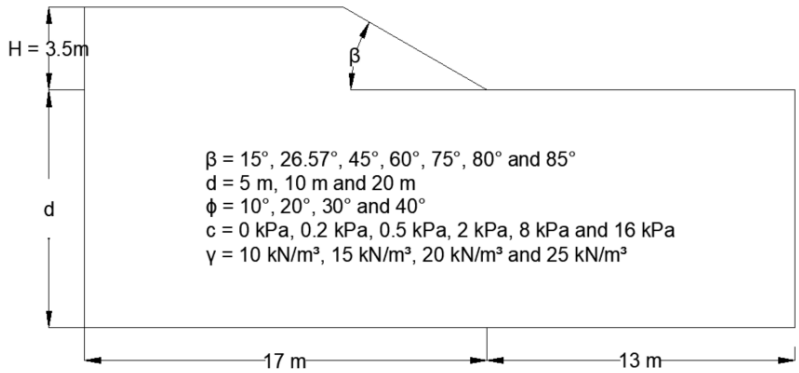


Figure 2. Representation of the theoretical slope and parameters.

To reduce the dimensionality of the problem and improve generalization, the results were reformulated using the stability number ($N_s = c/(\gamma\, H)$), which relates soil strength parameters and slope geometry in a dimensionless form. This approach is consistent with classical stability charts and enables a more compact representation of the problem. The final dataset was defined as stability number (N_s), slope angle (β), and friction angle (ϕ) for input variables, and as factor of safety (FS) for output variable.

Figure 3 illustrates the range of variation for N_s, β, ϕ and FS, as well as the frequency of values within each range

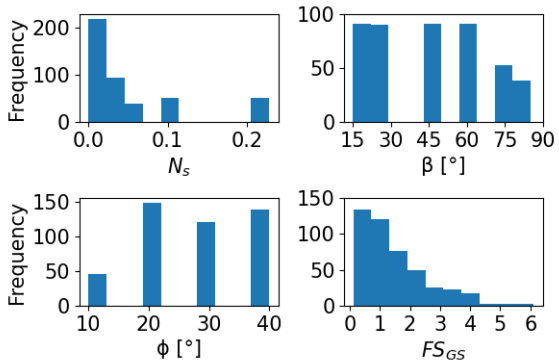


Figura 2. Intervalo de dados dos parâmetros do modelo.

Although the dataset size is relatively limited, the use of a controlled parametric study ensures a structured and consistent coverage of the input space. This approach reduces noise and variability typically associated with field data and allows the ANN model to learn the underlying relationships more effectively.

2.2 Data Preprocessing and Partitioning

Prior to training, all input variables were normalized using standardization (zero mean and unit variance), which improves numerical stability and convergence of gradient-based optimization algorithms (Haykin, 2001; Géron, 2021). The normalization parameters were computed exclusively from the training dataset to prevent information leakage.

The dataset was randomly divided into three subsets: training set: 68% (309 samples), validation set: 12% (55 samples), and testing set: 20% (91 samples).

The validation set was used to monitor model performance during training and to define the stopping criterion, aiming to mitigate overfitting. This strategy is consistent with best practices in machine learning applications for geotechnical problems.

2.3 ANN model development

A feedforward multilayer perceptron (MLP) architecture was adopted due to its proven capability to approximate nonlinear relationships in geotechnical systems (Shahin et al., 2002; Haykin, 2001). The model maps the input variables (N_s, β, ϕ) to the output variable (FS).

Given the absence of a universal procedure for defining the optimal ANN architecture, a systematic parametric analysis of hyperparameters was conducted. The following aspects were investigated: number of hidden layers: 1 to 4; number of neurons per layer: 2 to 45; activation functions: hyperbolic tangent (tanh) and rectified linear unit (ReLU); and optimization algorithms: Adam and RMSprop.

Weight initialization followed established practices to improve training stability. He initialization was adopted for ReLU-based networks (He et al., 2015), while Glorot initialization was used for tanh-based models (Glorot and Bengio, 2010).

The loss function used during training was the mean squared error (MSE), due to its sensitivity to large deviations and suitability for regression problems. Model performance was also evaluated using the mean absolute error (MAE) and the correlation coefficient (r).

It is noted that the relatively small dataset size, combined with a multi-layer architecture, may introduce a risk of overfitting. This issue was mitigated through cross-validation, dataset partitioning, and consistency checks between training, validation, and testing errors.

2.4 Training Strategy and Model Selection

The training process employed mini-batch gradient descent, with batch sizes ranging from 32 to 128. The optimal performance was achieved with a batch size of 32.

Cross-validation was used as a stopping criterion, based on the performance of the validation dataset. This approach prevents excessive fitting to the training data and improves the generalization capability of the model.

Batch normalization was also evaluated as a regularization strategy. However, it did not lead to significant improvements in predictive accuracy and increased computational cost; therefore, it was not included in the final model.

The optimal ANN architecture consisted of four hidden layers with 35, 30, 20, and 10 neurons, respectively, using ReLU activation functions and the Adam optimizer. This configuration provided the best balance between accuracy and generalization.

2.5 Model Evaluation and Comparison

The predictive performance of the selected model was evaluated using the independent testing dataset. The predicted FS values were compared with those obtained from Slope/W analyses, which served as reference solutions.

To further assess the robustness of the proposed model, comparisons were performed with different classes of methods: (i) limit equilibrium methods (e.g., Fellenius, Janbu); (ii) strength reduction method using finite elements (Plaxis); (iii) stability charts (e.g., Barnes, Bishop and Morgenstern), and (iv) stability equations (e.g., Sah et al., Yang et al., Huang, Chien and Tsai, Sampa and Schorr).

Finally, the generalization capability of the ANN model was evaluated by analyzing its predictive performance across the range of input parameters and identifying deviations for conditions outside the training domain.

3 RESULTS AND DISCUSSION

This section presents a detailed evaluation of the predictive performance of the proposed artificial neural network (ANN) model, followed by a comparative analysis with conventional methods and an assessment of its generalization capability.

3.1 ANN predictive performance

The performance of the ANN model was evaluated using training, validation, and testing datasets. A strong correlation was observed between the predicted factor of safety (FS_{ANN}) and the reference values obtained from Slope/W analyses (FS_{GS}), with a correlation coefficient (r) equal to 0.999 (Figure 4).

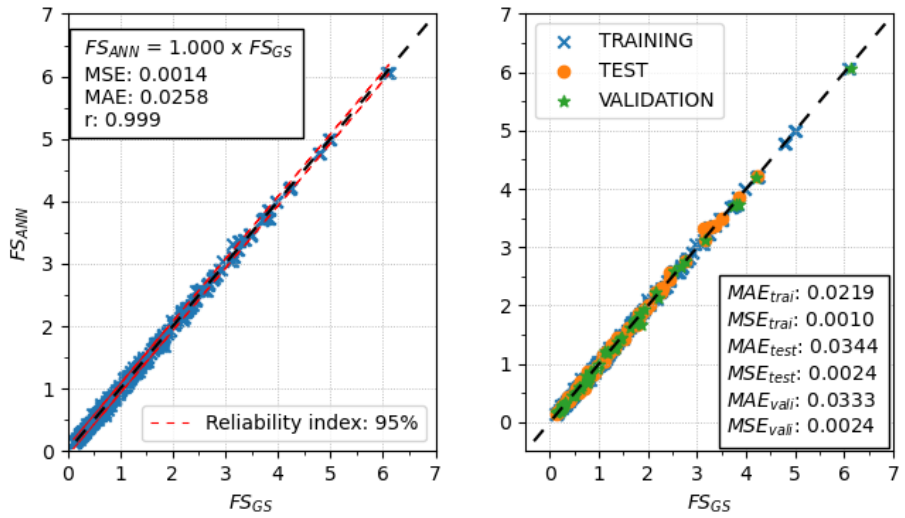


Figure 4. Comparison of ANN model predictions with Factor of Safety (FS) values obtained from GeoStudio (GS).

The error metrics indicate high predictive accuracy, with mean absolute error (MAE) values of 0.0219, 0.0333, and 0.0344 for the training, validation, and testing datasets, respectively. The low dispersion of results and the consistency between datasets suggest that the model achieved an adequate balance between fitting capability and generalization.

The slightly higher error observed in the testing dataset, compared to training and validation, is expected and indicates that the model is not overfitted to the training data. This behavior is consistent with the use of cross-validation as a stopping criterion.

From a functional perspective, the ANN successfully captured the nonlinear relationship between the input variables (N_s, β, ϕ) and the factor of safety. The high accuracy obtained suggests that the model effectively approximates the solution space defined by the limit equilibrium analyses.

3.2 Influence of Input Parameters

The results indicate that the factor of safety is strongly influenced by the stability number (N_s), which governs the relationship between shear strength and slope geometry. Higher values of N_s generally correspond to more stable conditions, as expected from classical formulations (Taylor, 1937).

The slope angle (β) also plays a critical role, with steeper slopes leading to lower FS values due to increased driving forces. Similarly, the friction angle (ϕ) contributes positively to stability, as higher values increase the shear strength along the potential failure surface.

The ANN model was able to capture these trends consistently, as evidenced by the smooth variation of predicted FS values across the input parameter space. This indicates that the model learned physically meaningful relationships rather than merely interpolating the dataset.

3.3 Comparison with Conventional Methods

The ANN predictions were compared with results obtained from different classes of methods (Figure 5), including limit equilibrium methods (LEM), strength reduction method (SRM), stability charts, and empirical equations.

In comparison with LEM results (e.g., Fellenius, Janbu, and generalized Janbu), the ANN model showed very close agreement, with minimal dispersion and no significant bias. This is expected, as the ANN was trained on data generated using a rigorous LEM formulation (Morgenstern–Price).

Similarly, comparisons with SRM results obtained from finite element analyses (Plaxis) showed consistent trends, indicating that the ANN model is capable of reproducing solutions obtained from more advanced numerical methods.

For empirical stability equations (e.g., Huang, Chien and Tsai, and Sampa and Schorr), the ANN predictions exhibited good agreement in most cases, although some deviations were observed in Sah et al., Yang et al.. These differences can be attributed to the simplifying assumptions inherent in regression-based formulations, which may not fully capture the nonlinear interactions between parameters.

In contrast, larger discrepancies were observed in comparisons with stability charts (e.g., Barnes, Bishop and Morgenstern, O'Connor and Mitchell). These methods showed greater variability and occasional outliers. This behavior is associated with the inherent limitations of stability charts, including interpolation errors, discretization of parameter space, and simplified assumptions regarding geometry and boundary conditions.

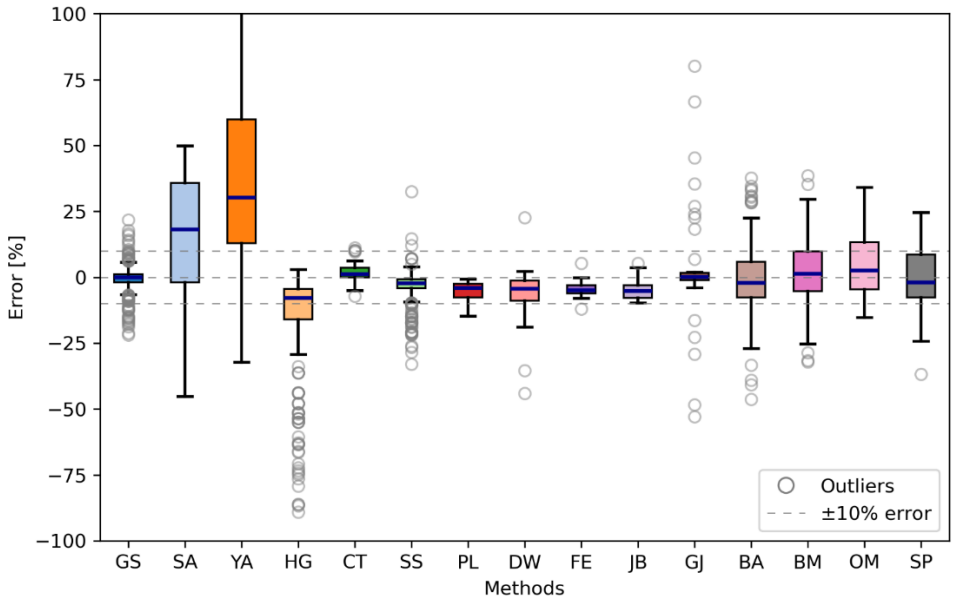


Figure 5. Boxplot chart comparing the prediction results of the developed artificial neural network model and the methods of GS, SA, YA, HG, CT, SS, PL, DW, FE, JB, JG, BA, BM, OM, and SP.

Note: Slope/w (GS), Chien and Tsai (CT), Huang (HG), Sampa and Schorr (SS), Plaxis (PL), Fellenius (FE), Janbu (1968), Janbu Generalizado (JG), Barnes (BA), Bishop and Morgenstern (BM), O'Connor and Mitchell (OM), Spencer (SP).

Quantitatively, most of the ANN predictions remained within a deviation range of approximately ±10% when compared to the reference solutions, which is consistent with acceptable variability observed among traditional methods. This further supports the reliability of the proposed model as an alternative predictive tool. Overall, the ANN model demonstrated a level of accuracy comparable to rigorous methods, while providing significantly faster predictions.

3.4 Generalization capability

The generalization capability of the ANN model was evaluated by analyzing its performance across different regions of the input space.

Within the range of the training data, the model exhibited stable and accurate predictions, with low error and consistent trends. However, deviations were observed when comparing ANN predictions with methods based on conditions that extend beyond the training domain, particularly in the case of stability charts.

These discrepancies indicate that the ANN model has limited extrapolation capability, as it approximates the solution space defined by the training data rather than the governing physical equations explicitly. Consequently, predictions outside the trained parameter range may not follow the expected mechanical behavior, particularly in regions where nonlinear interactions between variables become more pronounced.

Additionally, variations in parameters such as foundation depth (d), which are not explicitly included in the ANN input variables but influence the calculation of N_s, may contribute to differences observed in comparisons with external methods.

These findings highlight the importance of ensuring that the training dataset adequately represents the range of conditions for which the model is intended to be applied.

4 CONCLUSIONS

An artificial neural network (ANN) model was developed to predict the factor of safety (FS) of homogeneous dry slopes using a dimensionless formulation based on the stability number (N_s), slope angle (β), and friction angle (ϕ). The model demonstrated high predictive accuracy and was able to consistently reproduce results obtained from rigorous limit equilibrium analyses.

Comparisons with conventional methods showed strong agreement with limit equilibrium and strength reduction approaches, as well as with stability equations, while larger discrepancies were observed for stability equations proposed by Sah et al. and Yang et al.. and stability charts due to their simplified assumptions and discretization.

The use of N_s proved effective in reducing problem dimensionality and contributed to consistent predictions across different slope configurations. However, the model is limited to the range of the training dataset and to simplified conditions, not accounting for pore pressure, soil heterogeneity, or external loading.

From a practical perspective, the ANN can be used as a fast surrogate tool for preliminary analyses and parametric studies. Future work should focus on expanding the dataset and incorporating more complex conditions to improve generalization.

REFERENCES

ABDALLA, J. A.; ATTOM, M. F.; HAWILEH, R. Prediction of minimum factor of safety against slope failure in clayey soils using artificial neural network. Environmental Earth Sciences, v. 73, p. 5463–5477, 2014.

ABRAMSON, L. W.; LEE, T. S.; SHARMA, S.; BOYCE, G. M. Slope Stability and Stabilization Methods. 2nd ed. New York: Wiley, 2002.

BARNES, G. E. A simplified version of the Bishop and Morgenstern slope stability charts. Canadian Geotechnical Journal, v. 28, n. 4, p. 630–637, 1991.

BUI, X.-N.; MUAZU, M. A.; NGUYEN, H. Optimizing Levenberg–Marquardt backpropagation technique in predicting factor of safety of slopes after two-dimensional analysis. Engineering with Computers, v. 36, p. 941–952, 2020.

CHENG, Y. M.; LIU, H. T.; WEI, W. B. Limit equilibrium analysis of slope stability: a review. Computers and Geotechnics, v. 34, n. 3, p. 137–150, 2007.

DAWSON, E. M.; ROTH, W. H.; DRESCHER, A. Slope stability analysis by strength reduction. Géotechnique, v. 49, n. 6, p. 835–840, 1999.

DUNCAN, J. M. State of the art: limit equilibrium and finite-element analysis of slopes. Journal of Geotechnical Engineering, v. 122, n. 7, p. 577–596, 1996.

DUNCAN, J. M.; WRIGHT, S. G. Soil Strength and Slope Stability. New York: Wiley, 2005.

GELISLI, K.; KAYA, T.; BABACAN, A. E. Assessing the factor of safety using an artificial neural network: case studies on landslides in Giresun, Turkey. Environmental Earth Sciences, v. 73, p. 8639–8646, 2015.

GEOSTUDIO. Stability Modeling with GeoStudio. Calgary: GEO-SLOPE International Ltd., 2021.

GÉRON, A. Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow. 2nd ed. Sebastopol: O'Reilly Media, 2021.

GLOROT, X.; BENGIO, Y. Understanding the difficulty of training deep feedforward neural networks. Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics (AISTATS), p. 249–256, 2010.

HAYKIN, S. Neural Networks and Learning Machines. 3rd ed. Upper Saddle River: Pearson, 2001.

HE, K.; ZHANG, X.; REN, S.; SUN, J. Delving deep into rectifiers: surpassing human-level performance on ImageNet classification. Proceedings of the IEEE International Conference on Computer Vision (ICCV), p. 1026–1034, 2015.

HUANG, W. Stability of Unsaturated Soil Slopes under Rainfall and Seismic Loading. PhD Thesis. Nanyang Technological University, Singapore, 2018.

KOLBADI, S. M.; ARYA, A.; KAZEMI, M. A review of slope stability analysis methods. International Journal of Engineering Research and Technology, v. 12, n. 6, p. 835–848, 2019.

MAMAT, R. C.; RAMLI, A.; YAZID, M. R.; KASA, A.; RAZALI, S. F. M.; BASTAM, M. N. Slope stability prediction of road embankment using artificial neural network combined with genetic algorithm. Jurnal Kejuruteraan, v. 34, n. 1, p. 165–173, 2022.

MORGENSTERN, N. R.; PRICE, V. E. The analysis of the stability of general slip surfaces. Géotechnique, v. 15, n. 1, p. 79–93, 1965.

O'CONNOR, M. J.; MITCHELL, R. J. An extension of the Bishop and Morgenstern slope stability charts. Canadian Geotechnical Journal, v. 14, n. 1, p. 144–151, 1977.

RAY, A.; KUMAR, V.; RAI, R.; KHANDELWAL, M.; SINGH, T. N. Stability prediction of Himalayan residual soil slopes using artificial neural network. Natural Hazards, v. 103, p. 3523–3540, 2020.

RUKHAIYAR, S.; ALAM, M. N.; SAMADHIYA, N. K. A PSO–ANN hybrid model for predicting factor of safety of slope. International Journal of Geotechnical Engineering, 2017.

SAH, N. K.; SHEOREY, P. R.; UPADHYAYA, L. N. Maximum likelihood estimation of slope stability. International Journal of Rock Mechanics and Mining Sciences, v. 31, n. 1, p. 47–53, 1994.

SAMPA, N. C.; SCHORR, J. A novel stability equation for the estimation of the factor of safety for homogeneous dry finite slopes. International Journal for Numerical and Analytical Methods in Geomechanics, 2024.

SHAHIN, M. A.; MAIER, H. R.; JAKSA, M. B. Predicting settlement of shallow foundations using neural networks. Journal of Geotechnical and Geoenvironmental Engineering, v. 128, n. 9, p. 785–793, 2002.

TAYLOR, D. W. Stability of Earth Slopes. Boston: MIT Press, 1937.

YANG, X.; YANG, G.; YU, T. Comparison of strength reduction method for slope stability analysis based on Abaqus FEM and FLAC FDM. Applied Mechanics and Materials, v. 170–173, p. 918–922, 2004.

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/COBRAMSEG2026.2/6

Aplicações e Eficácia das Análises de Correlação Estatística na Caracterização de Propriedades Geotécnicas: Uma Revisão Sistemática

Victor Lima Cunha Borges
Discente, Universidade Federal de Goiás, Goiânia, Brasil, lima_cunha@discente.ufg.br

Larissa Andrade de Aguiar
Docente, Instituto Federal de Brasília, Samambaia, Brasil, larissa.aguiar@ifb.edu.br

Renato Resende Angelim
Docente, Universidade Federal de Goiás, Goiânia, Brasil. angelim@ufg.br

Márcia Maria dos Anjos Mascarenha
Docente, Universidade Federal de Goiás, Goiânia, Brasil, marciamascarenhaa@ufg.br

RESUMO: A caracterização precisa das propriedades geotécnicas dos solos é fundamental para projetos de engenharia civil, mas frequentemente depende de ensaios de laboratório onerosos e demorados. Este artigo apresenta uma revisão sistemática da literatura com o objetivo de compilar, caracterizar e analisar criticamente as principais aplicações de análises de correlação estatística utilizadas para predição e caracterização de propriedades geotécnicas. A metodologia seguiu o *framework* PICOC, com estratégia de busca abrangente em múltiplas bases de dados. Vinte e sete artigos foram selecionados para análise detalhada, revelando uma evolução significativa das técnicas empregadas, desde correlações lineares simples até algoritmos avançados de *Machine Learning* (ML), incluindo Random Forest, XGBoost, redes neurais e modelos Bayesianos. Os resultados destacam a superioridade dos métodos não-lineares e de ML na captura de relações complexas entre propriedades geotécnicas, com estudos demonstrando reduções substanciais em erros de predição quando comparados a correlações empíricas tradicionais. A análise individual dos estudos forneceu *insights* sobre a confiabilidade de correlações para parâmetros como resistência ao cisalhamento e compressibilidade. Conclui-se que a integração de métodos estatísticos avançados e ML representa uma mudança paradigmática na predição da caracterização geotécnica, oferecendo ferramentas mais precisas e confiáveis para engenheiros, embora a seleção adequada do método deva considerar o tamanho da amostra, a complexidade do fenômeno e a aplicabilidade regional.

PALAVRAS-CHAVE: Correlação Estatística; Propriedades Geotécnicas; Machine Learning; Caracterização de Solos; Métodos Preditivos.

ABSTRACT: Accurate characterization of geotechnical soil properties is fundamental for civil engineering projects but often relies on costly and time-consuming testing. This article presents a systematic literature review aimed at compiling, characterizing, and critically analyzing the main applications of statistical correlation analyses used for prediction and characterization of geotechnical properties. The methodology followed the PICOC framework, with a comprehensive search strategy across multiple databases. Twenty-seven articles were selected for detailed analysis, revealing a significant evolution in employed techniques, from simple linear correlations to advanced Machine Learning (ML) algorithms, including Random Forest, XGBoost, neural networks, and Bayesian models. The results highlight the superiority of non-linear and ML methods in capturing complex relationships between geotechnical properties, with studies demonstrating substantial reductions in prediction errors compared to traditional empirical correlations. Individual analysis of studies provided insights into the reliability of correlations for parameters such as shear strength and compressibility. It is concluded that the integration of advanced statistical methods and ML represents a paradigmatic shift in geotechnical characterization, offering more accurate and reliable tools for engineers,

although appropriate method selection must consider sample size, phenomenon complexity, and regional applicability.

KEYWORDS: Statistical Correlation; Geotechnical Properties; Machine Learning; Soil Characterization; Predictive Methods.

1 INTRODUÇÃO

A caracterização adequada das propriedades geotécnicas dos solos é essencial para o projeto seguro e econômico de obras de engenharia civil, incluindo fundações, estruturas de contenção, pavimentos e obras subterrâneas. Propriedades como resistência ao cisalhamento, compressibilidade, permeabilidade e rigidez dinâmica tradicionalmente requerem ensaios laboratoriais ou de campo especializados, que demandam tempo, recursos financeiros significativos e expertise técnica (Mola-Abasi & Shooshpasha, 2016; Xu et al., 2025). Em contextos onde recursos são limitados ou investigações geotécnicas abrangentes são impraticáveis, correlações estatísticas entre propriedades de fácil obtenção e parâmetros geotécnicos complexos tornam-se ferramentas valiosas para estudos e anteprojetos (Chatterjee et al., 2024; Mola-Abasi et al., 2015; Puri et al., 2018).

Historicamente, a engenharia geotécnica tem se baseado em correlações empíricas simples, frequentemente estabelecidas por meio de regressão linear (Burt et al., 2002; Chatterjee et al., 2024). Embora úteis, essas correlações tradicionais apresentam limitações significativas: assumem relações lineares que podem não capturar a complexidade do comportamento dos solos e podem apresentar baixa precisão quando aplicadas fora de suas condições de calibração (Chakraborty et al., 2020; Li et al., 2022; Wei et al., 2024).

Nas últimas duas décadas, o avanço de métodos de Machine Learning (ML) tem revolucionado o desenvolvimento de correlações geotécnicas (Chakraborty et al., 2020; Guo et al., 2025; Li et al., 2022; Puri et al., 2018). Algoritmos como Random Forest, Support Vector Machines (SVM), XGBoost e métodos Bayesianos demonstraram capacidade superior para modelar relações não-lineares complexas e fornecer predições mais precisas (Chakraborty et al., 2020; Li et al., 2022; Puri et al., 2018; Xu et al., 2025). Estudos recentes ilustram essa evolução: Chakraborty et al. (2020) demonstraram que XGBoost supera métodos tradicionais na predição de propriedades de solos; Cheng et al. (2024) introduziram o índice de comportamento do solo em correlações SPT-CPT; Xu et al. (2025) aplicaram modelos Bayesianos para reconstruir matrizes de correlação a partir de dados incompletos; e Mola-Abasi et al. (2015, 2016) utilizaram redes neurais polinomiais para aprimorar correlações tradicionais.

Diante desse cenário, o presente artigo tem como objetivo realizar uma revisão sistemática da literatura para identificar, caracterizar e analisar criticamente as principais aplicações, métodos e confiabilidade das análises de correlação estatística utilizadas para caracterização e predição de propriedades geotécnicas. A metodologia adotada segue rigorosamente os princípios de uma revisão sistemática, visando responder à questão: "Quais são as principais análises de correlação estatística aplicadas na avaliação de propriedades geotécnicas e qual sua confiabilidade para caracterização de propriedades dos solos?"

2 METODOLOGIA

Este estudo foi conduzido como Revisão Sistemática da Literatura (RSL), seguindo metodologia rigorosa para identificar, selecionar, analisar e sintetizar o conhecimento existente sobre análises de correlação estatística aplicadas à caracterização de propriedades geotécnicas. A abordagem metodológica foi alinhada com as diretrizes de revisões sistemáticas, garantindo transparência e reprodutibilidade dos resultados.

A questão de pesquisa central que guiou esta revisão foi: "Quais são as principais análises de correlação estatística aplicadas na avaliação de propriedades geotécnicas e qual sua confiabilidade para caracterização de propriedades dos solos?" Esta questão foi formulada para identificar métodos estatísticos e de *Machine Learning* empregados, avaliar sua precisão e confiabilidade, e sintetizar as melhores práticas para aplicação em contextos geotécnicos diversos.

Para estruturar a revisão e definir os critérios de inclusão e exclusão, foi utilizado o framework PICOC: População - solos e materiais geotécnicos de diferentes origens e características; Intervenção - análises de correlação estatística (Pearson, Spearman, regressão linear/não-linear) e modelos de *Machine Learning* (RF,

SVM, ANN, XGBoost); Comparação - métodos diretos de ensaio *versus* correlações indiretas, diferentes técnicas estatísticas e algoritmos de ML, modelos locais *versus* globais; *Outcomes* - precisão (R^2, RMSE, MAE), confiabilidade, aplicabilidade e vantagens/limitações das correlações para predição de propriedades geotécnicas; Contexto - projetos de engenharia geotécnica, caracterização de materiais, investigações de campo e laboratório.

A estratégia de busca utilizou a *string*: ("statistical correlation" OR "correlation analysis") AND ("geotechnical properties" OR "soil properties") AND ("database" OR "characterization" OR "prediction") aplicada nas bases de dados *Scopus, Web of Science, Engineering Village* (EI Compendex) e *Science Direct*, sem restrições de ano de publicação, para artigos em inglês e português.

A seleção dos estudos seguiu o protocolo PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) em duas etapas sequenciais. Na primeira, todos os registros foram submetidos à análise inicial baseada em título e resumo para identificar estudos potencialmente relevantes. Na segunda etapa, os artigos pré-selecionados foram lidos integralmente para confirmar elegibilidade. Os critérios de inclusão consideraram artigos que abordam correlações estatísticas ou ML para predição de propriedades geotécnicas, estudos com validação estatística clara (R^2, RMSE, MAE, validação cruzada) e publicações em periódicos revisados por pares ou anais de conferências com relevância científica. Foram excluídos estudos focados exclusivamente em aspectos ambientais ou agrícolas sem relevância geotécnica direta e registros duplicados. Para cada artigo selecionado, procedeu-se à extração sistematizada de informações: título, autores, ano, método estatístico ou algoritmo empregado, tamanho e características do banco de dados (tipo de solo, localização), métricas de validação, propriedades geotécnicas investigadas e principais resultados e inovações metodológicas.

A qualidade foi avaliada por cinco critérios pontuados de 1 a 5: definição do método (clareza na descrição da técnica), robustez do banco de dados (adequação do tamanho amostral e descrição da população), validação estatística (métricas de desempenho claras), relevância geotécnica (foco direto em propriedades de engenharia) e inovação metodológica (comparação entre métodos ou melhorias sobre correlações tradicionais). A soma totalizou máximo de 25 pontos para classificar a contribuição dos estudos.

A análise dos 27 artigos selecionados foi qualitativa, envolvendo síntese de metodologias e contribuições, e quantitativa, focando em padrões metodológicos, distribuição temporal e geográfica, métricas de desempenho reportadas e evolução das técnicas estatísticas, formando a base para a seção de resultados deste artigo.

3 RESULTADOS

Esta seção apresenta os resultados detalhados da revisão sistemática, com foco na análise bibliométrica, caracterização metodológica e síntese das principais contribuições dos 27 artigos selecionados.

3.1 Processo de Seleção dos Estudos

O processo de busca nas quatro bases de dados (*Scopus, Web of Science, Engineering Village* e *ScienceDirect*) resultou em um total de 507 registros. A distribuição inicial por base foi: *Scopus* (n = 254), Web of Science (n = 107), Engineering Village (n = 67) e ScienceDirect (n = 79).

Após a importação dos registros para o *software* de gerenciamento bibliográfico Parsif.al, foram identificados e removidos 261 artigos duplicados, resultando em 246 estudos únicos. Na etapa de triagem baseada em títulos, foram excluídos 191 artigos que claramente não atendiam aos objetivos da revisão. Posteriormente, a triagem baseada nos resumos (*abstracts*) eliminou 25 artigos adicionais, resultando em 30 estudos elegíveis para leitura completa.

Durante a etapa de leitura na íntegra, nenhum artigo foi excluído por problemas metodológicos ou falta de informações relevantes. Entretanto, foram removidos 3 artigos por estarem em idiomas que não português ou inglês, impossibilitando sua análise adequada.

Ao final do processo de triagem PRISMA, 27 artigos foram selecionados para compor a revisão sistemática e foram submetidos à análise detalhada e extração de dados.

3.2 Análise Bibliométrica

A análise bibliométrica foi conduzida com os 27 artigos incluídos, visando caracterizar o panorama das publicações sobre correlações estatísticas e modelos de aprendizado de máquina aplicados a propriedades geotécnicas. Esta análise permitiu identificar padrões de publicação, principais métodos empregados, distribuição temporal e geográfica das pesquisas, bem como as tendências emergentes na área de predição de propriedades geotécnicas de solos.

A distribuição temporal das publicações e por base indexadora (Figura 1) demonstra um crescimento significativo no interesse científico pelo tema nas últimas duas décadas. Observa-se uma concentração de publicações a partir de 2015, com picos notáveis entre 2022-2025, refletindo a crescente adoção de técnicas de Machine Learning e análise de grandes conjuntos de dados (big data) na engenharia geotécnica. Este padrão temporal evidencia a transição de métodos estatísticos clássicos para abordagens computacionais avançadas, impulsionada tanto pela disponibilidade de dados quanto pelo desenvolvimento de ferramentas analíticas mais sofisticadas. A distribuição por base indexadora revelou que *Scopus* e *Web of Science* foram as fontes primárias mais relevantes, com vários artigos indexados exclusivamente em uma dessas bases ou em ambas simultaneamente. A base EI Compendex apresentou sobreposição significativa com as anteriores, confirmando-se como complementar mas não essencial para cobertura abrangente. Este resultado sugere que pesquisas futuras na área podem concentrar esforços em Scopus e Web of Science para máxima eficiência na busca bibliográfica.

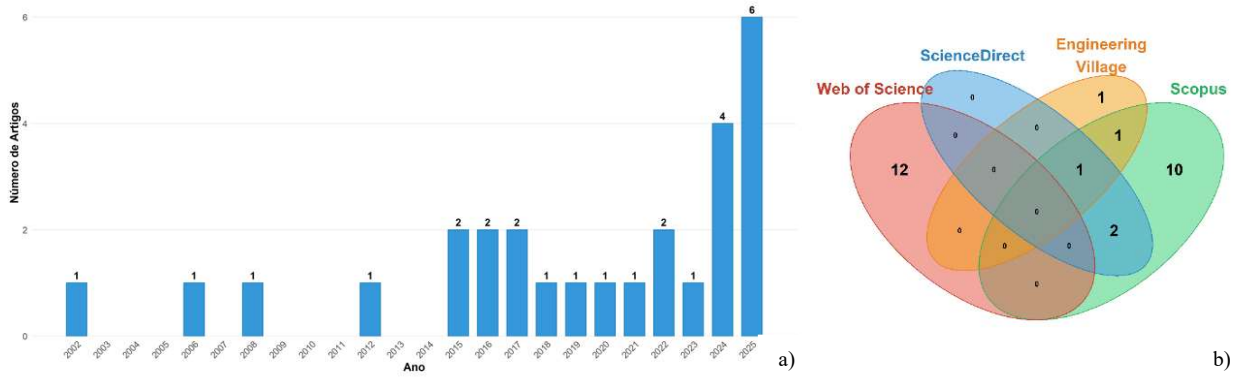


Figura 1: a) Produções por ano; b) Distribuição de artigos por base indexadora (Imagens produzidas no programa RStudio).

A distribuição geográfica das pesquisas (Figura 2) revela uma representação global significativa, com estudos conduzidos em diversos continentes. Destacam-se contribuições da Ásia (China, Índia, Irã, Turquia, Sri Lanka) (Chakraborty et al., 2020; Chatterjee et al., 2024; Cheng et al., 2024; Mola-Abasi et al., 2015; Mola-Abasi & Shooshpasha, 2016; Xu et al., 2025; Şahin & Gündüz, 2025), Europa (Chipre, Itália, Espanha, Croácia) (Micó et al., 2006; Tzampoglou et al., 2025; Viti & Tanganelli, 2017), América do Sul (Peru) (Araujo & Ruiz, 2025), América do Norte (Canadá e EUA) (Biswas & Si, 2012; Burt et al., 2002) e África (Quênia e Camarões) (Ng et al., 2024; Yannick et al., 2022). Esta diversidade geográfica demonstra a relevância universal do tema e a necessidade de desenvolver correlações adaptadas a diferentes contextos geológicos, climáticos e práticas de engenharia locais.

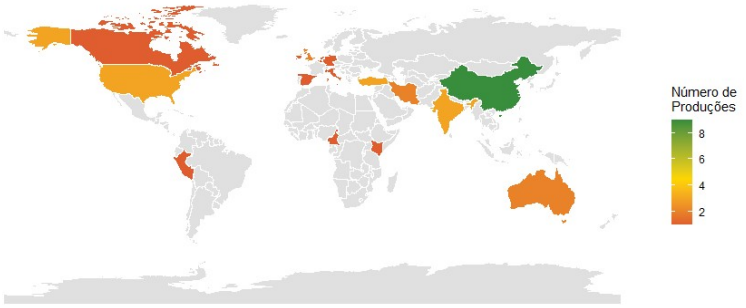


Figura 2. Mapa de distribuição de artigos por país (Imagem produzida no programa RStudio).

Em termos de colaborações internacionais e análise de frequência dos termos-chave (Figura 3), identificaram-se parcerias entre instituições de diferentes países em diversos estudos, particularmente em pesquisas envolvendo grandes bancos de dados ou validação de modelos em múltiplos contextos geográficos (Ng et al., 2024; Xu et al., 2025; Şahin & Gündüz, 2025). Esta tendência colaborativa reflete a natureza cada vez mais interdisciplinar e globalizada da pesquisa em geotecnia, facilitada por plataformas digitais de compartilhamento de dados e cooperação científica.

A análise de frequência dos termos-chave mais relevantes identificou os conceitos centrais que permeiam as pesquisas na área. Para esta análise, aplicou-se a técnica de *stemming* (redução de palavras à raiz comum), permitindo agrupar variações morfológicas de um mesmo termo, como "correlation" e "correlations", que foram unificadas como "correlation". Os termos mais frequentes foram "soil" (17 ocorrências), "correlation" (8 ocorrências), "analysis" e "model" (7 ocorrências cada), "compression" e "statistical" (4 ocorrências cada), confirmando que a predição de propriedades do solo por meio de correlações estatísticas e modelagem é o tema unificador central. Termos com frequência moderada incluem "test", "clay", "distribution", "heavy metal", "learning", "penetration", "prediction" e "settlement" (3 ocorrências cada), evidenciando o foco em propriedades mecânicas fundamentais, ensaios de campo e aplicações em contaminação do solo.

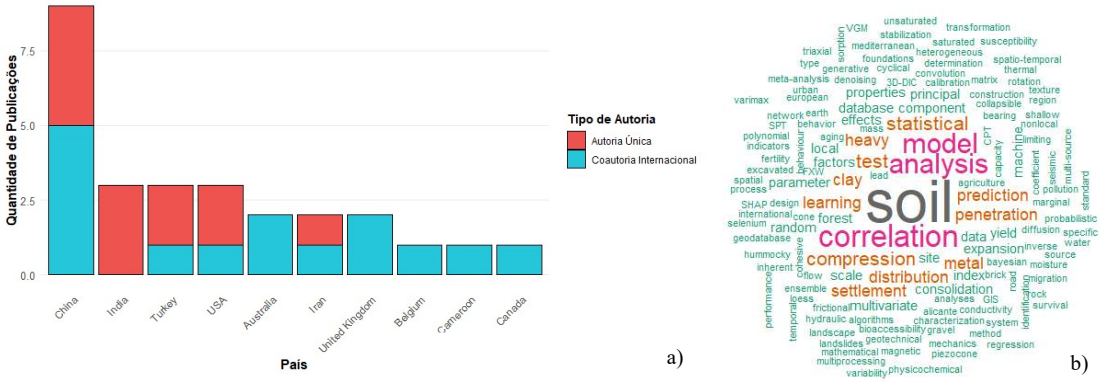


Figura 3: a) Gráfico de colaborações internacionais; b) Nuvem de palavras-chave (Imagens produzidas no programa RStudio).

Termos metodológicos específicos revelam a amplitude de técnicas empregadas: "machine learning" e "random forest" (2 ocorrências cada), "principal component analysis", "multivariate", "bayesian", "SHAP" (SHapley Additive exPlanations) e "ensemble" (presentes na base de dados). Esta diversidade metodológica demonstra a evolução da área, transitando de análises de correlação bivariada simples para modelagens multivariadas complexas e algoritmos de aprendizado de máquina interpretáveis. A presença significativa de termos relacionados a ensaios *in situ* ("SPT", "CPT", "cone penetration", "standard penetration") e propriedades físico-químicas ("physicochemical", "texture", "moisture") indica a integração entre dados de campo, laboratório e características intrínsecas do solo.

3.3 Caracterização Metodológica e Análise por Propriedade Geotécnica

A análise dos 27 artigos revelou cinco categorias metodológicas principais. Correlações Lineares Tradicionais (8 estudos) empregam regressão linear e correlações de Pearson/Spearman, caracterizando-se por simplicidade mas apresentando R^2 moderado (0,46-0,75) e limitações para relações não-lineares (Araujo & Ruiz, 2025; Güner & Özgan, 2025). Regressão Não-Linear e Polinomial (6 estudos) demonstram melhorias substanciais, com Güner & Özgan (2025) reportando aumento de R^2 de 0,46 para 0,90 na predição de recalques. Machine Learning Supervisionado (11 estudos) apresenta desempenho superior consistente, com Chakraborty et al. (2020) demonstrando que XGBoost captura não-linearidades melhor que regressão tradicional, e Li et al. (2022) mostrando superioridade do AdaBoost sobre modelos empíricos clássicos. Análise Multivariada (5 estudos) utiliza PCA e geoestatística para identificar padrões em dados complexos (Lu et al., 2023; Ng et al., 2024). Métodos Bayesianos (3 estudos) destacam-se pela capacidade de quantificar incertezas e reconstruir dados incompletos (Xu et al., 2025; Zou et al., 2017).

Para resistência ao cisalhamento, Puri et al. (2018) demonstraram que M5 Model Tree e SVM superaram regressão linear para predição de ϕ e c, enquanto Mola-Abasi et al. (2015) utilizaram GMDH para correlacionar Vs (velocidade da onda de cisalhamento) com CPT, reduzindo drasticamente o erro. Em compressibilidade, Chatterjee et al. (2024) provaram que Pc (tensão de pré-adensamento) é o melhor preditor individual para Cc (índice de compressão), e Xu et al. (2025) aplicaram modelos Bayesianos para reconstruir matriz de correlação completa a partir de dados incompletos. Para correlações SPT-CPT, Cheng et al. (2024) desenvolveram modelo de curva-S com índice Ic que superou 10 modelos existentes, especialmente para solos mistos. Em propriedades térmicas e hidráulicas, Li et al. (2022) mostraram que AdaBoost superou modelos empíricos para condutividade térmica. Aplicações emergentes incluem uso de IA generativa para correlacionar imagens com propriedades mecânicas (Guo et al., 2025) e SHAP para explicar influência de variáveis em predições (Tzampoglou et al., 2025).

A análise comparativa revelou superioridade consistente de ML sobre regressão linear, importância de modelos não-lineares mesmo sem ML, e valor da validação rigorosa. Estudos com maior impacto (pontuação $\geq$24) compartilham bancos de dados robustos, técnicas avançadas e validação estatística rigorosa (Chakraborty et al., 2020; Cheng et al., 2024; Xu et al., 2025; Zou et al., 2017). Limitações de amostras pequenas ($n<50$) resultaram em R^2 inferior e maior risco de overfitting (Biswas & Si, 2012; Güner & Özgan, 2025). Correlações desenvolvidas localmente superaram modelos globais genéricos, destacando a importância da calibração regional (Cheng et al., 2024; Zou et al., 2017).

4 CONSIDERAÇÕES FINAIS

Esta revisão sistemática da literatura demonstrou a evolução significativa das análises de correlação estatística aplicadas à caracterização de propriedades geotécnicas. A análise detalhada dos 27 artigos selecionados revelou uma transição clara de métodos estatísticos clássicos para abordagens computacionais avançadas que incorporam *Machine Learning*, análise multivariada e modelagem de incertezas.

Os resultados evidenciam que algoritmos de ML como XGBoost, Random Forest, SVM e AdaBoost consistentemente superam correlações empíricas tradicionais na predição de propriedades geotécnicas complexas, capturando relações não-lineares que métodos convencionais não conseguem representar adequadamente. Estudos demonstraram reduções substanciais em erros de predição, com aumentos em R^2 de 0,46 para 0,90 ao transitar de modelos lineares para cúbicos ou baseados em ML (Güner & Özgan, 2025).

Identificou-se que a contextualização regional permanece essencial, com correlações desenvolvidas para condições específicas superando modelos globais genéricos (Zou et al., 2017). Simultaneamente, métodos Bayesianos demonstraram potencial para maximizar o uso de bancos de dados incompletos (Xu et al., 2025), problema comum em geotecnia.

Mesmo com os avanços apresentados, recomenda-se que os dados e correlações obtidos por meio dessas metodologias sejam aplicados com critério e parcimônia na prática geotécnica. O solo é um material de natureza intrinsecamente heterogênea e variável, cujo comportamento é condicionado por fatores intrínsecos como mineralogia e por fatores extrínsecos relacionados ao processo de investigação. Correlações estatísticas e modelos de ML, por mais robustos que sejam, são desenvolvidos a partir de conjuntos de dados específicos e podem não capturar adequadamente a variabilidade natural de perfis geológicos distintos daqueles utilizados

no treinamento. Portanto, sua utilização deve ser acompanhada de análise crítica por parte do engenheiro, validação com dados locais sempre que possível e consciência das limitações inerentes a qualquer modelo preditivo.

Em suma, a integração de métodos estatísticos avançados e *Machine Learning* representa uma mudança paradigmática na caracterização geotécnica, oferecendo ferramentas mais precisas e confiáveis para engenheiros. A seleção adequada do método deve considerar o tamanho amostral disponível, a complexidade do fenômeno e a aplicabilidade regional. O futuro da área aponta para maior adoção de IA explicável (Tzampoglou et al., 2025; Wei et al., 2024), integração de múltiplas fontes de dados (Guo et al., 2025; Ng et al., 2024) e desenvolvimento de plataformas abertas de compartilhamento de dados geotécnicos.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001 e do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela bolsa e produtividade em pesquisa da coautora M.M.A. Mascarenha (Processo: 304529/2025-7).

REFERÊNCIAS BIBLIOGRÁFICAS

Araujo, W.; Ruiz, G. (2025). *Preliminary Analysis of the Identification of Key Parameters in Expansive Clay Soil.* In: International Conference on Civil Structural and Transportation Engineering (ICCSTE 2025), 10., London. *Proceedings...* London: Avestia Publishing. Paper No. 310. DOI: 10.11159/iccste25.310.

Biswas, A.; Si, B. C. (2012). *Identifying effects of local and nonlocal factors of soil water storage using cyclical correlation analysis. Hydrological Processes,* v. 26, n. 24, p. 3670–3677. DOI: 10.1002/hyp.8459.

Burt, R. et al. (2002). *Phosphorus characterization and correlation with properties of selected benchmark soils of the United States. Communications in Soil Science and Plant Analysis,* v. 33, n. 1-2, p. 117–141. DOI: 10.1081/CSS-120002382.

Chakraborty, P. et al. (2020). *Spatial structure, parameter nonlinearity, and intelligent algorithms in constructing pedotransfer functions from large-scale soil legacy data. Scientific Reports,* v. 10, art. 13576. DOI: 10.1038/s41598-020-72018-2.

Chatterjee, S. et al. (2024). *Estimation of Compression Index of Cohesive-Frictional Soil in Southwest Delhi District Using Statistical Correlations. Journal of the Geological Society of India,* v. 100, n. 6, p. 841–851. DOI: 10.17491/jgsi/2024/173914.

Cheng, X. et al. (2024). *A new SPT-CPT correlation by statistical analysis based on a database from Anhui, China. Georisk: Assessment and Management of Risk for Engineered Systems and Geohazards,* v. 18, n. 4, p. 838–853. DOI: 10.1080/17499518.2024.2379965.

Guo, Q.-M. et al. (2025). *Correlation of excavated soil multi-source heterogeneous data using multimodal diffusion model. Acta Geotechnica.* DOI: 10.1007/s11440-025-02690-z.

Güner, A. B. S.; Özgan, E. (2025). *Statistical Analysis of Soil Parameters Affecting the Bearing Capacity and Settlement Behaviour of Gravel Soils. Applied Sciences,* v. 15, n. 10, art. 5271. DOI: 10.3390/app15105271.

Li, K.-Q.; Liu, Y.; Kang, Q. (2022). *Estimating the thermal conductivity of soils using six machine learning algorithms. International Communications in Heat and Mass Transfer,* v. 136, art. 106139. DOI: 10.1016/j.icheatmasstransfer.2022.106139.

Liu, D. et al. (2016). *Spatial distribution of soil magnetic susceptibility and correlation with heavy metal pollution in Kaifeng City, China. Catena,* v. 139, p. 53–60. DOI: 10.1016/j.catena.2015.11.004.

Lu, X. et al. (2023). *A global meta-analysis of the correlation between soil physicochemical properties and lead bioaccessibility. Journal of Hazardous Materials,* v. 453, art. 131440. DOI: 10.1016/j.jhazmat.2023.131440.

Micó, C. et al. (2006). *Assessing heavy metal sources in agricultural soils of an European Mediterranean area by multivariate analysis. Chemosphere,* v. 65, n. 5, p. 863–872. DOI: 10.1016/j.chemosphere.2006.03.016.

Mola-Abasi, H.; Dikmen, U.; Shooshpasha, I. (2015). *Prediction of shear-wave velocity from CPT data at Eskisehir (Turkey), using a polynomial model. Near Surface Geophysics,* v. 13, n. 2, p. 155–168. DOI: 10.3997/1873-0604.2015010.

Mola-Abasi, H.; Shooshpasha, I.; Ebrahimi, A. (2016). *Prediction of the compression index of saturated clays (Cc) using polynomial models. Scientia Iranica. Transactions A: Civil Engineering,* v. 23, n. 2, p. 500–507. DOI: 10.24200/sci.2016.2134.

Ng, W. et al. (2024). *Exploring mid-infrared spectral transfer functions for the prediction of multiple soil properties using a global dataset. Soil Science Society of America Journal,* v. 88, n. 4, p. 1234–1247. DOI: 10.1002/saj2.20697.

Puri, N.; Prasad, H. D.; Jain, A. (2018). *Prediction of Geotechnical Properties using Machine Learning Techniques. Procedia Computer Science,* v. 125, p. 509–517. DOI: 10.1016/j.procs.2017.12.066.

Şahin, O. G.; Gündüz, O. (2025). *Derivation of soil hydraulic properties (SHPs) using a Physics-Based inverse calibration method and International soil moisture network database. Journal of Hydrology,* v. 660, art. 133445. DOI: 10.1016/j.jhydrol.2025.133445.

Tzampoglou, P. et al. (2025). *Correlation Between Geotechnical Indexes and Landslide Occurrence in Southwestern Cyprus Using GIS and Machine Learning. Geotechnical and Geological Engineering,* v. 43, art. 43. DOI: 10.1007/s10706-024-03031-9.

Viti, S.; Tanganelli, M. (2017). *Effects of soil characterization on the seismic input.* In: International Conference on Computational Methods in Structural Dynamics and Earthquake Engineering (COMPDYN 2017), 6., Rhodes. *Eccomas Proceedia...* p. 1007–1017. DOI: 10.7712/120117.5472.17353.

Wei, W. et al. (2024). *Characterization and modeling of exogenous selenite aging in soils using machine learning and traditional data analysis. Geoderma,* v. 451, art. 117074. DOI: 10.1016/j.geoderma.2024.117074.

Whetton, R. L. et al. (2021). *Modelling the Influence of Soil Properties on Crop Yields Using a Non-Linear NFIR Model and Laboratory Data. Soil Systems,* v. 5, n. 1, art. 12. DOI: 10.3390/soilsystems5010012.

Xiao, H.; Böttcher, J.; Utermann, J. (2015). *Evaluation of field-scale variability of heavy metal sorption in soils by scale factors — Scaling approach and statistical analysis. Geoderma,* v. 241–242, p. 115–125. DOI: 10.1016/j.geoderma.2014.11.012.

Xu, J. et al. (2025). *Development of a database on multivariate soil properties for collapsible loess in Xi'an, China. Bulletin of Engineering Geology and the Environment,* v. 84, art. 245. DOI: 10.1007/s10064-025-04265-4.

Yannick, T. L. et al. (2022). *Statistical analysis of Nkoulou soils properties and suitability for earthen constructions. Heliyon,* v. 8, n. 5, e11141. DOI: 10.1016/j.heliyon.2022.e11141.

Zhang, C. et al. (2008). *Identifying sources of soil inorganic pollutants on a regional scale using a multivariate statistical approach: Role of pollutant migration and soil physicochemical properties. Environmental Pollution,* v. 151, n. 3, p. 470–476. DOI: 10.1016/j.envpol.2007.04.017.

Zhu, Y.; Medina-Cetina, Z.; Pineda-Contreras, A. R. (2022). *Spatio-Temporal Statistical Characterization of Boundary Kinematic Phenomena of Triaxial Sand Specimens. Materials,* v. 15, n. 6, art. 2189. DOI: 10.3390/ma15062189.

Zou, H. et al. (2017). Multivariate correlation analysis of seismic piezocone penetration (SCPTU) parameters and design properties of Jiangsu quaternary cohesive soils. Engineering Geology, v. 228, p. 11–38. DOI: 10.1016/j.enggeo.2017.07.005.

DOI: 10.47094/COBRAMSEG2026.2/7

Automação da Extração de Dados Geotécnicos Históricos com *Document Intelligence* e OCR Avançado

Rafael Cristiano Piton
Engenheiro Sênior, VALE S.A., Parauapebas, Brasil, rafael.piton@vale.com

Helena Paula Nierwinski
Docente, Universidade Federal de Santa Catarina, Joinville, Brasil, helena.paula@ufsc.br

Gabriel de Barros Valim
Cientista de Dados, MOGAI, Rio de Janeiro, Brasil, c0709322@vale.com

Danúbia Vieira Dias de Oliveira
Analista Tecnologia da Informação Master, VALE S.A., Belo Horizonte, Brasil, Danubia.Oliveira1@vale.com

Darlis Devise
Engenheira Sênior, Concremat, Navegantes, Brasil, c0701140@vale.com

RESUMO: Acervos geotécnicos históricos, em geral dispersos e não estruturados (PDFs digitalizados e documentos manuscritos), impõem alto esforço de transcrição e dificultam a reutilização de dados em modelos e projetos. Este trabalho apresenta a aplicação de *Document Intelligence* com OCR avançado e orientado a *layout* para extrair, padronizar e validar informações de boletins de sondagem e ensaios *in situ*, com saídas em tabelas e JSON aderentes a princípios de AGS. O fluxo contempla pré-processamento, segmentação e extração estruturada de campos (profundidade, Nspt, nível d'água, litologia), seguidos de QA/QC com sinalização de revisão. Em ensaios com boletins simples, a latência ponta a ponta ficou entre 1 e 5 s por documento, enquanto a transcrição humana de referência levou ≈ 10–20 min (e até 40 min, em casos complexos). Na amostra de Sondagem à Percussão (SP), a acurácia global atual é de aproximadamente 65%, com meta operacional ≥ 95%. As principais fontes de erro residem em metadados geodésicos ausentes (ex., sistema de referência), variação/omissão do método de avanço e elementos gráficos (ex., Nspt) que exigem interpretação humana. Conclui-se que a automação reduz significativamente o tempo de processamento e cria uma base auditável para retroanálises e calibração, cabendo evoluções em dicionários, normalizações e regras de consistência para atingir a meta de acurácia.

PALAVRAS-CHAVE: OCR, *document intelligence*, geotecnia, digitalização e dados históricos.

ABSTRACT: Historic geotechnical archives typically dispersed and unstructured (scanned PDFs and handwritten records), entail high transcription effort and hinder consistent data reuse in models and design. This work presents the application of Document Intelligence with layout-aware, advanced OCR to extract, standardize, and validate information from borehole logs and in-situ test reports, producing table-based and JSON outputs aligned with AGS principles. The workflow comprises pre-processing, segmentation, and structured extraction of key fields (depth, Nspt, groundwater level, lithology), followed by QA/QC with review flagging. In trials with simple logs, end-to-end latency was 1–5 s per document, whereas reference human transcription took ≈ 10–20 min (and up to 40 min for complex cases). For the Standard Penetration Test (SP) sample, current overall accuracy is approximately 65%, with an operational target ≥ 95%. The main error sources are missing geodetic metadata (e.g., reference system), variation/omission of drilling/advancement method, and graphical elements (e.g., Nspt plotted) that require human interpretation. We conclude that automation significantly reduces processing time and establishes an auditable basis for back-analysis and calibration, with further gains expected from enhanced dictionaries, normalizations, and consistency rules to reach the accuracy target.

KEYWORDS: OCR, document intelligence, geotechnics, digitalization e historical data.

1 INTRODUÇÃO

A qualidade das decisões de engenharia geotécnica em obras de infraestrutura ou mineração está diretamente associada à disponibilidade, confiabilidade e integração dos dados provenientes das investigações geológico-geotécnicas. Boletins de sondagem, perfis estratigráficos, registros de nível d'água e resultados de ensaios *in situ* e de laboratório constituem a base técnica para a interpretação do maciço e para o desenvolvimento de modelos geológico-geotécnicos consistentes ao longo do ciclo de vida dos empreendimentos (ABGE, 2023).

A Norma ABGE 100/2023 estabelece que as investigações geológico-geotécnicas devem ser planejadas, executadas e apresentadas de forma sistemática, assegurando rastreabilidade, coerência técnica e possibilidade de reaproveitamento das informações em fases posteriores do projeto e da operação. Entretanto, em grandes organizações, especialmente nos setores de mineração e infraestrutura, é comum que acervos históricos formados ao longo de décadas estejam armazenados em formatos não estruturados, como PDFs digitalizados, imagens e registros manuscritos, frequentemente dispersos em múltiplos repositórios e produzidos segundo diferentes padrões técnicos e épocas.

Essa condição impõe limitações relevantes à gestão da informação geotécnica. A leitura e a transcrição manual de documentos legados demandam elevado esforço operacional, são suscetíveis a erros e inconsistências de transcrição e dificultam a consolidação de bases de dados corporativas. Além disso, a baixa acessibilidade a dados históricos pode resultar em investigações redundantes e perfurações adicionais, com impactos negativos em custos, prazos e exposição a riscos, em desacordo com os princípios de progressividade e otimização das investigações recomendados pela norma ABGE 100/2023.

A dificuldade é agravada pela heterogeneidade dos documentos, uma vez que boletins de sondagem e relatórios de ensaios apresentam variações significativas de *layout*, terminologia e simbologia conforme o executor, o período e o objetivo da investigação. Soma-se a isso a ocorrência frequente de arquivos com baixa qualidade de digitalização, incluindo baixa resolução, inclinação, ruído e sombras, o que compromete tanto a interpretação técnica quanto a extração automatizada de informações confiáveis.

Nos últimos anos, a ABGE tem enfatizado a necessidade de digitalização estruturada e padronizada dos dados geológico-geotécnicos, em consonância com os conceitos de BIM Geotécnico. A Diretriz Normativa ABGE 300/2024 introduz o conceito de níveis de confiabilidade das investigações, destacando a importância de explicitar a qualidade e a origem dos dados utilizados em modelos e análises. Complementarmente, a Diretriz Normativa ABGE 301/2024 estabelece um padrão digital para uso e compartilhamento de dados geológico-geotécnicos, baseado em dicionários de dados, padronização de campos e interoperabilidade entre sistemas (ABGE, 2024).

Nesse contexto, técnicas de *Document AI*, combinando reconhecimento óptico de caracteres (OCR) avançado e interpretação de *layout*, apresentam potencial para viabilizar a transformação de acervos documentais legados em bases de dados estruturadas e auditáveis. Essas técnicas permitem automatizar a extração de informações relevantes, mantendo vínculos com o documento de origem e possibilitando a aplicação de rotinas sistemáticas de validação e controle de qualidade, em alinhamento com as diretrizes atuais da ABGE e demais associações normativas.

Este trabalho propõe e aplica uma solução de *Document Intelligence* com OCR orientado a *layout* para automatizar a extração de informações geotécnicas de acervos históricos, preservando estrutura tabular (colunas/cabeçalhos) e mantendo rastreabilidade e controle de qualidade. As contribuições são: (i) fluxo reprodutível de pré-processamento → segmentação → extração → QA/QC → exportação (Excel/JSON) aderente a princípios de AGS; (ii) validação técnica com sinalização "necessita revisão" e reaproveitamento seguro de resultados; (iii) medidas de desempenho (latência e acurácia por campo/tipologia) que orientam ajustes de dicionários e normalizações. Demonstra-se ganho de tempo de ordens de grandeza frente à transcrição manual e um caminho claro para atingir $\geq 95\%$ de acurácia, ao atacar causas-raiz (metadados geodésicos, método de avanço e elementos gráficos/manuscritos) com regras e dicionários específicos.

2 MATERIAIS E MÉTODOS

Este capítulo descreve os materiais e métodos utilizados para o desenvolvimento e avaliação da solução de automação da extração de dados geotécnicos históricos. Inicialmente são apresentados os tipos de

documentos e a base de dados utilizada no estudo. Em seguida, descreve-se a arquitetura lógica do sistema e o *pipeline* de processamento adotado para segmentação, classificação e extração das informações estruturadas, bem como os procedimentos de controle de qualidade e armazenamento dos dados resultantes.

2.1 Base de dados e tipologias documentais

O estudo utilizou um conjunto de 148 *layouts* distintos de documentos do *backlog* corporativo de aproximadamente 29.000 unidades de sondagens e relatórios técnicos, abrangendo diferentes tipologias de investigação: Sondagem Percussiva (SP), Sondagem Mista (SM), Sondagem à Trado (ST) e Sondagem Rotativa (SR). Estima-se que cerca de 30% do acervo apresente baixa qualidade de digitalização, caracterizada por inclinação de páginas, baixa resolução, presença de sombras e ruído, além de elementos gráficos complexos, conforme ilustrado na Figura 1. Essas condições são reconhecidas como críticas para processos de OCR, especialmente em documentos contendo colunas e tabelas densas.

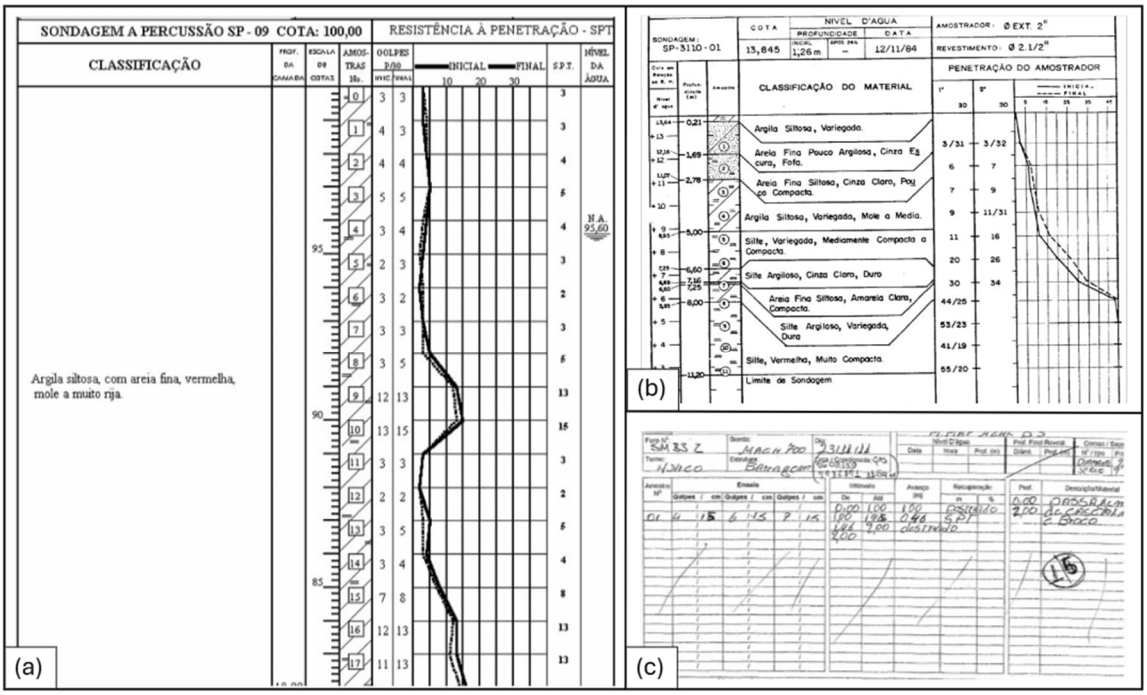


Figura 1. Documento *scan* (a), modelo datilografia (b) e boletim manuscrito (c).

As informações de interesse incluem metadados do furo (identificação, coordenadas e datas), registros de avanço, resultados de ensaios *in situ* (por exemplo SPT quando aplicável), descrições estratigráficas e leituras de nível d'água, além de dados associados a ensaios complementares usuais conforme a tipologia de investigação (ex., infiltração/perda d'água).

2.2 Arquitetura lógica do sistema e visão geral do *pipeline*

O sistema é implementado como uma *Azure Functions App* em *Python*, destinada a processar documentos de sondagens/boletins e gerar artefatos estruturados: JSON de extração e *template* (*xlsx.* ou *csv.*) em padrão AGS. O *pipeline* funcional segue as etapas de segmentação do documento, classificação do tipo de boletim, extração estruturada de campos e exportação de dados em formatos tabulares. A Figura 2 apresenta uma visão geral do fluxo operacional do sistema, desde a ingestão dos documentos até a geração dos artefatos estruturados de saída. O fluxo contempla as etapas de ingestão, segmentação e classificação do documento, extração dos campos relevantes e exportação dos dados em formatos estruturados para posterior integração com sistemas corporativos.

A extração utiliza serviços de *Document Intelligence* para leitura e interpretação estruturada do documento (texto/tabelas/*layout*), o que é coerente com práticas modernas de Document AI que preservam estrutura para reduzir ambiguidades em documentos técnicos (Microsoft, 2025a; Huang *et al*., 2022).



Figura 2. Fluxo do sistema.

A entrada dos documentos pode ocorrer por dois mecanismos principais: (i) ingestão via ADLS acionada pela API HTTP, e (ii) ingestão opcional via *Sharepoint* (*Microsoft Graph*), com controle em *Azure Table Storage* e processamento em lotes. No segundo caso, o sistema registra os metadados dos arquivos em *Azure Table Storage* e cria uma fila de tarefas para processamento em lote, permitindo controle e rastreabilidade do fluxo de execução.

A etapa de segmentação divide o documento em segmentos (intervalos de páginas) e registra marcadores de segmentação e *layout*, permitindo processamento granular e rastreável. Em seguida, o *pipeline* executa classificação para identificar se o documento contém boletim e o tipo de sondagem, controlando roteamento e bloqueios do fluxo quando o conteúdo não é elegível. O roteamento por tipo de documento (SPT/SM/SR/ST) e mapeamentos de modelo é controlado por configuração (ex.: YAML de extração), permitindo evolução por "famílias" de documentos.

Em cenários com documentos altamente degradados ou manuscritos, arquiteturas recentes de *Document AI*, como *TrOCR*, *LayoutLMv3* e *Donut*, têm sido exploradas como alternativas para leitura e interpretação estrutural de documentos, podendo orientar evoluções futuras do *pipeline* em casos limite (Li *et al*., 2021; Huang *et al*., 2022; Kim *et al*., 2022).

2.3 Processamento de documentos e QAQC operacional

Ferramentas de *Document Intelligence* permitem reconhecer texto, tabelas e elementos estruturais de *layout* (títulos, cabeçalhos/rodapés), melhorando a interpretação de relatórios técnicos com formatação tabular. Os resultados são padronizados no formato de planilhas para consumo operacional em banco de dados legado e JSON estruturado (integrações e auditoria), conforme Figura 3.

Para intercâmbio de dados e redução de retrabalho entre sistemas, são adotadas regras de consistência alinhadas ao formato AGS (dicionário de campos, chaves obrigatórias, etc.), reconhecido internacionalmente para investigação de campo e laboratórios geotécnicos. Na consistência técnica dos campos, observam-se as referências normativas de SPT (ABNT NBR 6484:2020 e ASTM D1586/D1586M) para conferir plausibilidade de Nspt, intervalos, nível d'água e unidades em SI.

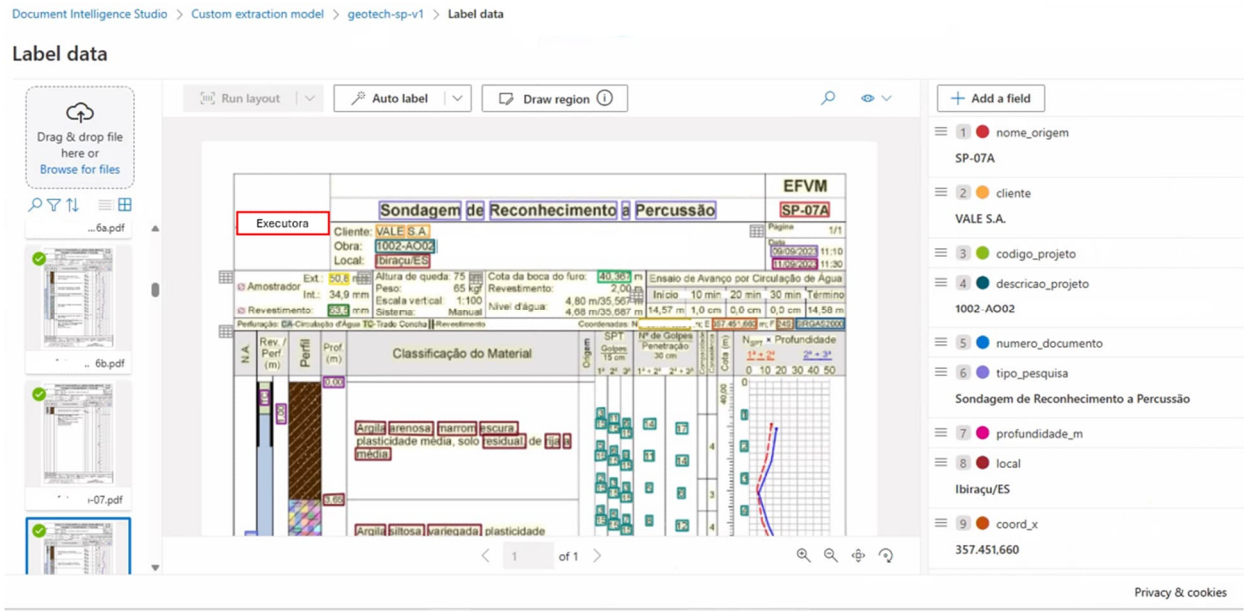


Figura 3. Treinamento da ferramenta e detecção de campos.

O sistema sinaliza inconsistências com indicador colorido nas planilhas de saída para análise técnica (Figura 4), sem bloquear a entrega, priorizando a revisão humana de campos obrigatórios apenas quando necessário e reaproveitando resultados estáveis quando o arquivo não mudou (rastreabilidade, treinamento contínuo da ferramenta e reprocessamento controlado).

Furo*	Profundid	N° Golpes - Interv. 1	Penet. - Interv. 1 (cm)	N° Golpes - Interv. 2	Penet. - Interv. 2 (cm)	N° Golpes - Interv. 3	Penet. - Interv. 3 (cm)	nSPT
SP-02D	1	2	15	3	15	4	15	7
SP-02D	2	3	15	2	15	2	15	4
SP-02D	3	30	9					

Origem*	De (m)*	Até (m)*	Fração Primária*	Fração Secundária	Fração Terciária	Fração Arenosa	Presença de	Origem do Material	Compacidade/Consistência	Cor Primária	Cor Secundária	Tonalidade
SP-02D	0,00	1,60	Argila	Areia			Pedregulhos	Residual	MD | Média(o)	ma - Marrom		e - Escuro
SP-02D	1,60	3,43	Areia	Argila		Fina	Pedregulhos	Residual	F-MTC | Fofa(o) a Muito compacta(o)	ma - Marrom		e - Escuro

Figura 4. Indicador de campos obrigatórios não preenchidos em: Nspt (a) e estratigrafia (b).

2.4 Armazenamento em banco legado e visualização dos dados

O banco de dados oficial utilizado pela Vale S.A é o GDMS *Fusion* (*Geological Database Management System*) da Datamine®, um sistema destinado ao gerenciamento integrado de dados geológicos, , geotécnicos, geofísicos e outros (Datamine, 2024). A Vale S.A possui três soluções de banco de dados GDMS: (i) GDMS Ferrosos para os furos de sondagem geológicos; (ii) GDMS Investigações Geotécnicas para os furos de sondagem e ensaios *in situ* de projetos geotécnicos; e, (iii) GDMS Sondagem para gestão e produção de equipamentos (Piton *et al.*, 2025).

Como forma de apoiar o acesso aos dados técnicos armazenados no GDMS, foi desenvolvido um relatório de saída em *Power BI* que consome ambos os bancos com visualização geoespacializada e em perfil, conforme apresentado na Figura 5. Por meio de programação que utiliza bibliotecas em *Phyton*, além da conversão de coordenadas geográficas para espacialização dos furos armazenados no banco, o relatório prevê os gráficos (*logs*) a partir dos resultados já inseridos no banco de dados.



Figura 5. Apresentação de dados geotécnicos armazenados no GDMS.

3 RESULTADOS

Nos ensaios realizados, a ferramenta apresentou latência de processamento compatível com uso operacional, porém sensível à complexidade documental. Para documentos simples — isto é, com *layout* estável, boa legibilidade e baixa densidade de tabelas — o tempo ponta a ponta manteve-se tipicamente entre 1 e 5 segundos por documento. À medida que a complexidade aumenta, com múltiplas colunas, quadros densos, anotações/manuscritos e/ou digitalização degradada, o tempo de transcrição tende a crescer, podendo aproximadamente dobrar em relação ao observado no cenário simples. Em contraste, no mesmo conjunto de teste, a transcrição humana levava cerca de 10 a 20 minutos em boletins simples e até 40 minutos nos boletins mais complexos.

Em termos de qualidade de extração, a avaliação em modelos de Sondagem à Percussão (SP) — apurada por confronto campo a campo com fonte de verdade — indica acurácia global atual em torno de 65%, enquanto a meta operacional estabelecida para a ferramenta é $\geq 95\%$. A análise de erro mostra que os campos com texto explícito e tabelas bem formadas alcançam desempenho superior, ao passo que elementos que dependem de contexto ou não estão textualizados tendem a concentrar as discordâncias. Entre os fatores que impactam diretamente a acurácia, destacam-se: (i) a incompletude de metadados geodésicos, em especial a ausência do sistema de referência (por exemplo, SIRGAS2000), o que dificulta a validação de coordenadas e a consistência espacial; (ii) a variação e/ou omissão do método de avanço de sondagem (por exemplo, trado e circulação de água), que reduz a precisão do mapeamento para campos padronizados; e (iii) a presença de elementos gráficos e notações específicas — como Nspt — que exigem interpretação humana quando a informação não aparece como texto legível.

Em síntese, os resultados mostram que a solução já entrega desempenho temporal adequado para processar lotes de boletins simples e apresenta acurácia funcional em SP, mas o desempenho depende fortemente da qualidade do insumo e da padronização dos campos críticos. Para convergir à meta de $\geq 95\%$, impõe-se um conjunto de ações complementares: endurecimento das regras de validação, enriquecimento de dicionários (unidades, litologia, métodos), normalização sistemática de metadados geodésicos e tratamento dedicado de elementos gráficos/manuscritos — priorizando justamente os pontos identificados na análise de erro.

4 DISCUSSÕES

Os resultados indicam que a automação já entrega ordens de grandeza de ganho de produtividade frente ao processo manual — de 1–5 s em boletins simples (ainda com aumentos esperados em casos complexos) contra 10–20 min (simples) e até 40 min (complexos) na transcrição humana do mesmo conjunto de teste — ao mesmo tempo em que viabiliza rastreabilidade e padronização das saídas (*Excel/JSON*) para uso corporativo. Esse desempenho temporal, associado ao controle de reprocesso e aos registros de execução, atende ao objetivo de tornar os acervos históricos utilizáveis em rotinas de engenharia e governança de dados.

Do ponto de vista da qualidade de extração, a acurácia global em Sondagem à Percussão (SP) ainda se encontra abaixo da meta ($\approx 65\%$ *vs.* $\geq 95\%$), mas os erros observados são coerentes com a literatura e com a natureza dos boletins geotécnicos: campos críticos não textualizados (p. ex., Nspt representado de forma gráfica), metadados geodésicos incompletos (ausência do sistema de referência, como SIRGAS2000) e variações na indicação de método de avanço (ex., trado, circulação de água) — todos elementos que demandam contexto e, muitas vezes, interpretação humana.

A estratégia adotada — preservar a estrutura do documento (colunas/cabeçalhos/tabelas) na extração — está alinhada às capacidades do modelo de *layout* do *Azure Document Intelligence*, que retorna uma representação estruturada para pós-processamento, condição crítica para boletins com quadros densos e múltiplas colunas. Para casos manuscritos ou com grande variabilidade de *layout*, a literatura recomenda explorar combinações e ablações com arquiteturas recentes: *TrOCR* (OCR neural fim-a-fim), *LayoutLMv3* (compreensão multimodal texto-imagem-layout) e *Donut* (abordagem OCR-*free* que mapeia a imagem diretamente para JSON). Em particular, revisões sistemáticas sobre OCR de manuscrito destacam que ganhos consistentes dependem de segmentação adequada, pré-processamento e modelos profundos treinados para cenários ruidosos.

No contexto geotécnico, o valor está em transformar acervos heterogêneos em uma base auditável e reutilizável: o *Excel/JSON* alimenta o banco de dados e relatórios analíticos, enquanto a rastreabilidade permite ciência de dados aplicada (séries de Nspt, N.A., padrões estratigráficos por profundidade) e retroanálises. A discussão dos resultados sugere que o gargalo não é apenas "algoritmo", mas, sobretudo, governança de conteúdo: campos-chave obrigatórios, dicionários de palavras e normalizações fazem a acurácia aumentar — e isso está perfeitamente alinhado ao que o pipeline já implementa (marcadores de execução, reaproveitamento de resultados estáveis, prioridade de revisão onde há incerteza).

Por fim, há riscos e limites que devem ser explicitados. A dependência da qualidade do insumo continuará afetando a extração; há risco de *overfitting* a *layouts* específicos caso os dicionários e as regras não sejam generalistas o suficiente; e elementos intrinsecamente gráficos (p. ex., colunas "Nspt" desenhadas) podem requerer etapas híbridas (heurísticas + revisão) até que o *corpus* seja suficiente para treinos especializados. A boa notícia é que a curva de ganhos tende a ser rápida à medida que regras, dicionários e pré-processamento são "calibrados" sobre as famílias de documentos mais recorrentes (SP/SM/ST/SR), como recomenda a literatura e a própria prática documentária.

5 CONCLUSÃO

A integração de *Document Intelligence* e OCR orientado a *layout* demonstrou capacidade de destravar acervos históricos, com ordens de grandeza de ganho de tempo e padronização auditável para consumo operacional, criando base sólida para retroanálises e calibração de modelos geotécnicos. Consolidar a qualidade até a meta ($\geq 95\%$) requer: *ground truth* amostral e métricas por campo (Profundidade, Nspt, N.A., Litologia, Unidades), dicionários e normalizações (método de avanço, unidades, abreviações), metadados geodésicos padronizados e regras AGS como referência de consistência e interoperabilidade.

Como evolução tecnológica, recomenda-se avaliar, sob ablação controlada, modelos recentes para casos-limite (manuscrito e forte variabilidade de *layout*) — *TrOCR, LayoutLMv3 e Donut* — mantendo a estrutura tabular como requisito de negócio.

No conjunto, a solução eleva a maturidade digital geotécnica ao converter informação difusa em base auditável, interoperável e pronta para análise/modelagem — objetivo central quando se busca reduzir incerteza e retrabalho em projetos, operar com segurança e confiabilidade, e criar as condições para retroanálises e calibração de modelos que reflitam, com fidelidade, o histórico da área e das intervenções.

AGRADECIMENTOS

Os autores agradecem às equipes da Diretoria de Geociências e Sondagem da VALE e da Universidade Federal de Santa Catarina, pela colaboração técnica em geotecnolgia e inteligência artificial, bem como o apoio na padronização e integração das saídas.

REFERÊNCIAS BIBLIOGRÁFICAS

AGS – Association of Geotechnical and Geoenvironmental Specialists. (2022). *Electronic Transfer of Geotechnical and Geoenvironmental Data (AGS 4.1.1).* Disponível em: <https://www.ags.org.uk/content/uploads/2022/02/AGS4-v-4.1.1-2022.pdf>. Acesso em: 27 jan. 2026.

ABGE - Associação Brasileira de Geologia de Engenharia e Ambiental. (2023). *Norma ABGE 100: Investigações geológico-geotécnicas para obras de infraestrutura – Métodos e técnicas*. 1. ed. São Paulo: ABGE.

ABGE - Associação Brasileira de Geologia de Engenharia e Ambiental. (2024a). *Diretriz Normativa ABGE 300: BIM geotécnico – Níveis de confiabilidade de investigações geológico-geotécnicas*. 1. ed. São Paulo: ABGE.

ABGE - Associação Brasileira de Geologia de Engenharia e Ambiental. (2024b). *Diretriz Normativa ABGE 301: BIM geotécnico – Padrão digital de uso e compartilhamento de dados geológico-geotécnicos.* 1. ed. São Paulo: ABGE.

ABNT – Associação Brasileira de Normas Técnicas. (2020). *NBR 6484 — Solo — Sondagem de simples reconhecimento com SPT — Método de ensaio*. Rio de Janeiro: ABNT. Disponível em: <https://idoc.pub/documents/nbr-64842020-solo-sondagem-de-simples-reconhecimento-d4p72yoo5d4p>. Acesso em: 27 fev. 2026.

ASTM International. (2018). *D1586/D1586M-18e1 — Standard Test Method for Standard Penetration Test (SPT) and Split-Barrel Sampling of Soils*. West Conshohocken, 2018 (corrigido 2022). Disponível em: <https://img.antpedia.com/standard/files/pdfs_ora/20221211/astm/ASTM%20D1586_D1586M-18e1.pdf>. Acesso em: 27 fev. 2026.

Datamine. (2024). *Brochura Fusion*. Disponível em: https://cdn-msaudata.pressidium.com/wpcontent/uploads/2023/05/Fusion_Brochure_230510_PT .pdf. Acesso em: 5 de março de 2026. (DATAMINE, 2024)

Huand, Y.; Lv, T.; Cui, L.; Lu, Y.; Wei, F. (2022). *LayoutLMv3: Pre-training for Document AI with Unified Text and Image Masking.* arXiv:2204.08387. Disponível em: < https://arxiv.org/pdf/2204.08387>. Acesso em: 27 jan. 2026.

Kim, G.; Hong, T.; Yim, M.; Nam, J.; Park, J.; Yim, J.; Hwang, W.; Yun, S.; Han, D.; Park, S. (2022) *OCR-free Document Understanding Transformer (Donut).* In: ECCV 2022. Springer. Disponível em: <https://link.springer.com/content/pdf/10.1007/978-3-031-19815-1_29>. Acesso em: 27 jan. 2026.

Li, M.; Lv, T.; Chen, J.; Cui, L.; Lu, Y.; Florencio, D.; Zhang, C.; Li, Z.; Wei, F. (2021). *TrOCR: Transformer-based Optical Character Recognition with Pre-trained Models*. arXiv:2109.10282. Disponível em: < https://arxiv.org/pdf/2109.10282>. Acesso em: 27 jan. 2026.

Microsoft. (2025). *Document layout analysis – Azure AI Document Intelligence (v4.0).* Microsoft Learn. Disponível em: <https://learn.microsoft.com/en-us/azure/ai-services/document-intelligence/prebuilt/layout?view=doc-intel-4.0.0>. Acesso em: 20 fev. 2026.

Piton, R.; Biondo, M.; Oliveira, E.; Devise, D. (2025). Uso de bancos de dados e ferramentas computacionais para otimizar investigações geotécnicas em estruturas de rejeitos. In: Congresso Brasileiro de Geologia de Engenharia e Ambiental, Belo Horizonte. Anais eletrônicos […]. Belo Horizonte: ABGE, 2025. Disponível em: <https://schenautomacao.com.br/cbge2025/envio/files/anais/trabalho1_124.pdf>. Acesso em: 1 mar. 2026.

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/COBRAMSEG2026.2/8

Avaliação da performance de diferentes modelos de inteligência artificial generativa na resolução de problemas de cálculo na Mecânica dos Solos

Daniel de Abreu Henriques
Analista de Projetos, Tractebel, Belo Horizonte, Brasil, danielabreuh@gmail.com

Lucas Martins Correa
Engenheiro Geotécnico, Tractebel, Belo Horizonte, Brasil

William da Fonseca Simões
Assistente Técnico, Tractebel, Belo Horizonte, Brasil

RESUMO: A inteligência artificial (IA) tem se tornado um dos instrumentos mais utilizados para tarefas do cotidiano profissional, desde a realização de tarefas mais simples até mais complexas. Nesse contexto, as IA's generativas têm aparecido em posição de destaque, pela sua facilidade de utilização em plataformas consolidadas, a partir de simples prompts de comando. No campo da engenharia geotécnica, levanta-se a questão sobre a confiabilidade desses modelos no auxílio teórico e numérico. Com isso, este artigo visou a avaliar a performance de diferentes modelos de IA na resolução de questões associadas à geotecnia. A partir de um prompt inicial de configuração, foram definidas 15 questões de cálculo, retiradas da literatura pertinente da Mecânica dos Solos e divididas entre os níveis básico, intermediário e avançado. Notou-se que as IA's apresentam, no geral, uma boa performance na resolução destes problemas geotécnicos. Modelos mais robustos e pagos possuem maior taxa de acerto, mas tem maior prejuízo no custo computacional, enquanto modelos mais simples e gratuitos ainda apresentam um desempenho adequado, com menor tempo de processamento das respostas. Apesar de serem úteis e poderem servir de consulta, essas ferramentas não são infalíveis e apresentam erros conceituais e numéricos, mesmo em questões de livros didáticos.

PALAVRAS-CHAVE: Inteligência artificial, performance, Mecânica dos Solos, questões de cálculo.

ABSTRACT: Artificial intelligence (AI) has become one of the most widely used tools for everyday professional tasks, ranging from the simplest to the most complex activities. In this context, generative AIs have gained prominence due to their easy use on established platforms, through simple command prompts. In the field of geotechnical engineering, questions arise regarding the reliability of these models in providing theoretical and numerical support. Therefore, this article aimed to evaluate the performance of different AI models in solving issues related to geotechnics. Starting from an initial configuration prompt, 15 calculation problems were defined, taken from relevant soil mechanics literature and divided into basic, intermediate, and advanced levels. It was observed that AIs generally perform adequately in solving these geotechnical problems. More robust and paid models have higher accuracy rates but come at a greater computational cost, while simpler and free models still deliver adequate performance with shorter response processing times. Although useful and suitable for consultation, these tools are not infallible and exhibit conceptual and numerical errors, even in textbook problems.

KEYWORDS: Artificial intelligence, performance, soil mechanics, calculation problems.

1 INTRODUÇÃO

A inteligência artificial (IA) tem se consolidado como uma ferramenta transformadora no cotidiano profissional de diversas áreas do conhecimento. Na engenharia geotécnica, há aplicações recentes que já exploram essas tecnologias, conforme discutido por Simões et al. (2025). No entanto, à medida que ferramentas generativas são incorporadas para o auxílio em tarefas de projeto ou dimensionamento, torna-se imperativo verificar a confiabilidade desses modelos em aplicações de cálculo desta natureza.

Embora o potencial das IA's seja amplamente discutido na literatura técnica, existem poucos estudos que quantifiquem a precisão desses modelos na resolução de problemas específicos da Mecânica dos Solos. Em áreas correlatas, como a Hidráulica, Simões et al. (2024) evidenciaram que, apesar de úteis, essas ferramentas apresentam erros conceituais e recomendam cautela em sua aplicação técnica. Essa incerteza reside no fato de que tais ferramentas estão suscetíveis a estes erros mesmo ao tratar de questões clássicas da área do conhecimento.

Com vistas a preencher tal lacuna, este artigo objetiva avaliar a performance de diferentes modelos de IA generativa na resolução de problemas de cálculo aplicados à geotecnia. O estudo compara o desempenho de plataformas amplamente difundidas, como o Gemini (Google), Copilot (Microsoft) e ChatGPT (OpenAI), ao submetê-las a 15 questões extraídas da literatura de referência, categorizadas em níveis de dificuldade básico, intermediário e avançado.

De forma complementar à taxa de acerto, a pesquisa analisa o custo computacional, mensurado pelo tempo de processamento das respostas. Busca-se, assim, fornecer um panorama sobre quais ferramentas oferecem o melhor equilíbrio entre precisão e eficiência para estudantes e profissionais da área, confrontando desde modelos gratuitos e simplificados até versões pagas e mais robustas.

2 MATERIAIS E MÉTODOS

2.1 Inteligência Artificial Generativa

Segundo Liu et al. (2023), um prompt pode ser definido como uma instrução ou conjunto de entradas textuais que reformulam uma tarefa para que ela possa ser solucionada por um modelo de linguagem pré-treinado. A qualidade da resposta dos modelos está diretamente relacionada com a formulação do *prompt* utilizado, que, com requisitos bem definidos, assegura que a IA generativa receba um direcionamento claro sobre as necessidades do usuário. Além disso, essa padronização garante que, neste estudo, todas as IA's partam da mesma base de comando, o que viabiliza a comparação direta entre os resultados obtidos.

Utilizou-se o seguinte comando neste estudo: *"Você será avaliado quanto à sua performance em questões relacionadas à engenharia geotécnica e Mecânica dos Solos. Responda as perguntas a seguir, relacionadas a tópicos simples a avançados, como um profissional geotécnico de ampla expertise em uma avaliação acadêmica de conhecimentos. Utilize como base conceitos traçados pela literatura pertinente e com base teórica relevante e demonstre conhecimento profundo sobre a geotecnia. As questões terão cálculos, apresente seu raciocínio e resuma suas respostas e os valores obtidos ao final."*

Para avaliar e comparar diferentes modelos, foram selecionadas três plataformas amplamente utilizadas por profissionais e estudantes: Gemini (Google), Copilot (Microsoft) e ChatGPT (OpenAI). Cada ferramenta foi submetida às mesmas questões sob o mesmo prompt. Adicionalmente, testou-se mais de um modelo dentro das plataformas Gemini e Copilot, para verificar o impacto da utilização de arquiteturas mais simples em comparação às mais robustas.

A Tabela 1 reúne as plataformas e os modelos utilizados neste estudo. Nota-se que o Copilot possui função integrada com o GPT-5 da OpenAI, que permite sua comparação com o GPT-5.2 nativo do ChatGPT.Essa comparação também pode ser feita nos modelos 2.5 Flash e 3 Pro da plataforma do Gemini.

Tabela 1. IAs utilizadas neste estudo.

Plataforma	**Gemini**		**Copilot**		**ChatGPT**
Modelo	2.5 Flash	3 Pro	Padrão	GPT-5	GPT-5.2

2.2 Problemas de cálculo da Mecânica dos Solos

O estudo abrange sete eixos temáticos fundamentais da Mecânica dos Solos: caracterização física, permeabilidade, tensões, adensamento, resistência ao cisalhamento, estados críticos e estabilidade de taludes. Tais tópicos constituem a base conceitual desta disciplina, sendo obrigatórios nos currículos de graduação e pós-graduação.

Para avaliar a eficácia das IA's, definiu-se uma hierarquia de complexidade em três níveis: básico, intermediário e avançado. A classificação e atribuição de pontos máximos para as questões se baseou na experiência dos autores e na sequência didática das disciplinas de Mecânica dos Solos I e II da Universidade Federal de Minas Gerais (UFMG), de forma a permitir a analisar variações de desempenho mediante o nível de complexidade das questões, uma vez que questões avançadas pressupõem o domínio de conceitos fundamentais.

A Tabela 2 detalha as questões por nível, tema e fonte bibliográfica. Foram utilizadas obras de referência clássica como Maranha das Neves (2016), Souza Pinto (2006), Craig (2005) e Das e Sobhan (2014), com um total de cinco questões por nível.

Devido às restrições de extensão do artigo, os enunciados integrais foram suprimidos, porém se preservou a descrição dos procedimentos de cálculo exigidos e a pontuação atribuída. É importante ressaltar que foram excluídos problemas dependentes de interpretação gráfica que continham figuras ou diagramas, o que limitou o escopo a enunciados estritamente textuais ou tabulares. Esses enunciados foram apresentados às IA's para testar o raciocínio lógico sem a interferência da interpretação de desenhos técnicos.

Tabela 2. Questões selecionadas.

Nível	ID	Pontos	Fonte	Tema	Descrição
Básico	5.5.E	10	Maranha das Neves (2016)	Caracterização física	Cálculo de índice de vazios, peso específico, índice de liquidez e plasticidade
	8.3.E	1		Permeabilidade	Cálculo da condutividade hidráulica
	6.1.E	1		Tensões	Cálculo da tensão vertical nos solos
	6.3.E	3		Tensões	Cálculo da tensão vertical nos solos
	12.6	5	Souza Pinto (2006)	Tensões	Cálculo do coeficiente de empuxo, tensões totais e efetivas
Intermediário	10.1 e 10.2	2		Adensamento	Cálculo do coeficiente de adensamento e tempo de recalque
	8.1.E	18	Maranha das Neves (2016)	Tensões	Cálculo de acréscimo de tensões e poropressão de acordo com o tempo de carregamento
	10.1.E	2		Resistência ao cisalhamento	Cálculo do ângulo de atrito de ruptura e de pico de *direct simple shear*
	10.3.E	1		Resistência ao cisalhamento	Cálculo do ângulo de atrito de triaxial CU
	10.6.E	5		Resistência ao cisalhamento	Cálculo do ângulo de atrito e tensões na ruptura de *direct simple shear*
Avançado	12.1.E	11		Estados críticos	Cálculo de parâmetros do estado crítico, Linha dos Estados Críticos (LEC), resistência crítica
	12.3.E	3		Estados críticos	Cálculo de parâmetros do estado crítico e resistência crítica
	Ex. 4.4	1		Estados críticos	Cálculo da resistência crítica

Nível	ID	Pontos	Fonte	Tema	Descrição
	Ex. 9.3	4	Craig (2004)	Estabilidade de taludes	Cálculo de fator de segurança e estabilidade por resistência residual e do estado crítico
	Ex. 14.1	5	Das e Sobhan (2014)	Empuxo	Cálculo de empuxo passivo em um muro de arrimo por diferentes teorias

É evidente que o espaço amostral não é extenso, de forma a ter um resultado absoluto sobre a superioridade ou inferioridade de um determinado modelo. As 15 questões selecionadas cobrem um *range* de temas mais relevantes e usuais na prática contemporânea de Mecânica dos Solos e os resultados devem ser entendidos como exploratórios, sendo apenas indicações do desempenho identificado de cada IA generativa.

2.3 Métricas de avaliação

A avaliação de performance dos modelos de IA generativa se baseou em duas métricas principais: a pontuação obtida e o tempo de processamento. A primeira quantifica diretamente a eficácia de cada modelo pela mensuração da taxa de acerto em cada questão proposta. Esse indicador permite inferir a confiabilidade técnica das respostas geradas frente aos gabaritos da literatura.

A segunda métrica se refere ao intervalo de tempo demandado para o processamento e a geração completa da resposta. Essa variável atua como um indicador indireto do custo computacional envolvido na interpretação do prompt, na execução dos cálculos e na redação da solução. Dessa forma, é possível estabelecer um comparativo entre a robustez dos modelos e a agilidade de entrega, o que permite identificar quais ferramentas demandam maior processamento.

Ressalta-se que, devido à ausência de logs nativos de tempo nas interfaces das plataformas avaliadas, a aferição foi realizada de forma independente pelos autores. Para garantir a isonomia do estudo, cronometrou-se, em segundos, o intervalo exato entre o envio do comando (envio da questão) e a conclusão da geração do texto pela inteligência artificial.

3 RESULTADOS E DISCUSSÃO

Com base na metodologia supracitada, todas as questões foram processadas pelos modelos de IA generativa, cujos resultados constam na Tabela 3. É incluída na tabela a discretização da pontuação individual para cada questão, bem como a totalização dos acertos sob a forma de mapa de calor.

Tabela 3. Pontuação obtida para cada modelo.

Nível	ID	Pontuação máxima	Pontuação				
			Gemini 2.5 Flash	Gemini 3 Pro	Copilot	Copilot GPT-5	ChatGPT 5.2
Básico	5.5.E	10	9	9	7	9	9
	8.3.E	1	1	1	1	1	1
	6.1.E	1	1	1	1	1	0
	6.3.E	3	3	3	3	3	3
	12.6	5	5	5	3	5	3
Interme-diário	10.1 e 10.2	2	2	2	2	2	2
	8.1.E	18	16	17	18	18	16
	10.1.E	2	2	2	2	2	2
	10.3.E	1	1	1	0	1	1
	10.6.E	5	2	5	0	2	2

Nível	ID	Pontuação máxima	Pontuação				
			Gemini 2.5 Flash	Gemini 3 Pro	Copilot	Copilot GPT-5	ChatGPT 5.2
Avançado	12.1.E	11	5	9	7	8	5
	12.3.E	3	2	3	1	1	1
	Ex. 4.4	1	1	1	1	1	1
	Ex. 9.3	4	4	4	3	2	0
Total		**72**	**55**	**64**	**49**	**56**	**46**

O melhor desempenho foi obtido pelo Gemini 3 Pro, com uma total de 64 pontos, correspondente a 89% da pontuação máxima. O Copilot GPT-5 foi o segundo melhor, com 56 acertos, o que equivale a 78%, seguido pelo Gemini 2.5 Flash, com 55 acertos ou 76%. O Copilot e o ChatGPT 5.2 apresentaram desempenhos inferiores, com acertos de 49 (68%) e 46 (64%), respectivamente.

Os menores índices de assertividade foram registrados nas questões 10.6.E de nível intermediário, 12.1.E de nível avançado e 12.3.E de nível avançado. A primeira abordou o tema de resistência ao cisalhamento, sendo exigido o cálculo do ângulo de atrito e das tensões na ruptura a partir de dados de um ensaio de *direct simple shear*. Já as questões avançadas trataram da Mecânica dos Estados Críticos e demandaram a determinação de parâmetros de estado crítico, da Linha de Estados Críticos (LEC) e da resistência crítica, sendo um tema reconhecidamente complexo da área da Mecânica dos Solos.

A Figura 1 apresenta a evolução da taxa de acerto por nível de dificuldade para cada modelo.

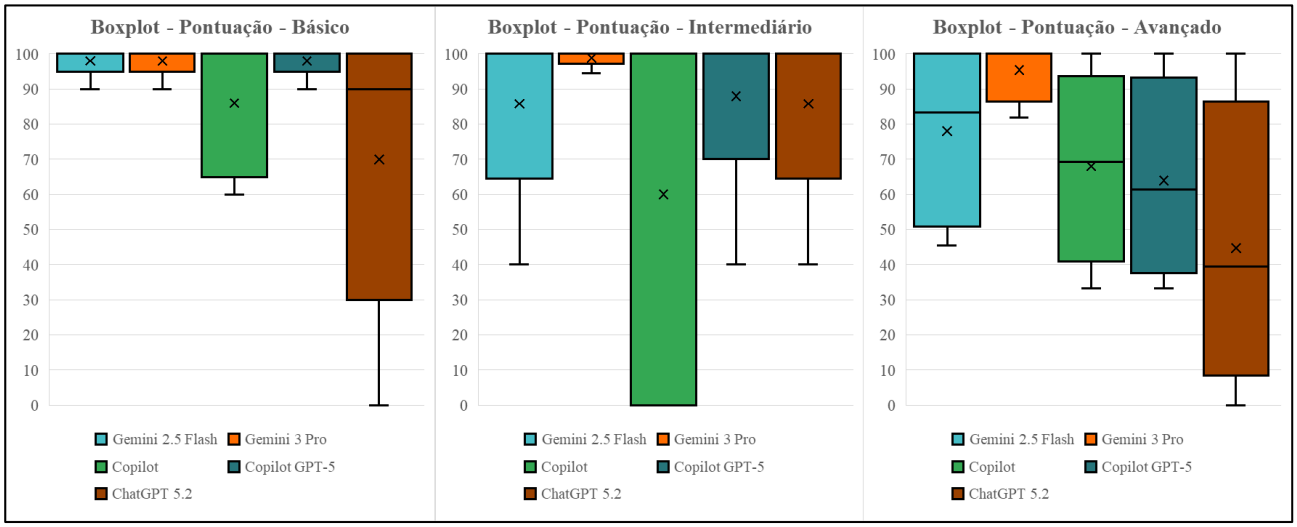


Figura 1. Evolução da taxa de acerto em percentual de cada modelo.

Confirma-se a tendência de acertos em questões de nível fácil e intermediário, ao passo que se reduzem nas questões mais difíceis. Ao comparar ChatGPT 5.2 e Copilot GPT-5, percebe-se que arquiteturas mais recentes não necessariamente implicam em melhores resultados, visto que a versão 5.2 do GPT, mais recente, apresentou desempenho inferior à versão 5, mais antiga. É evidente que o ChatGPT 5.2 teve o pior desempenho, com base na Figura 1, diante de erros mesmo em questões básicas. Em contrapartida, confirma-se que o Gemini 3 Pro obteve melhor desempenho quando comparado aos demais modelos.

Em um panorama geral, as IA's apresentaram coerência quanto à teoria dos exercícios avaliados e da Mecânica dos Solos clássica e dos estados críticos. Alguns erros, especialmente no Ex. 14.1 sobre empuxo passivo, consistem em problemas de formulação. Entretanto, o padrão de erro consiste em problemas matemáticos, seja por conversão de unidades ou na aplicação em fórmulas. Outra questão persistente é a geração de raciocínios equivocados, de forma a desviarem do gabarito das referências bibliográficas.

Vale ressaltar que a qualidade do *prompt* de entrada é importante para o resultado apresentado pela IA. O parágrafo utilizado para o presente trabalho foi eficaz em induzir o processamento das IA's de forma que

fossem estabelecidas linhas de raciocínio para cada questão, o que impacta significativamente o resultado. Assim, as IA's apresentaram, no geral, robustez teórica.

Além do número absoluto de acertos, é interessante verificar o tempo de processamento de cada modelo de IA. Esse resultado está explicitado na Tabela 4, que apresenta o tempo para cada questão, além do somatório total. Também é apresentada a eficiência geral de cada IA em termos de pontos obtidos por segundo de processamento, que consiste na média global da eficiência de cada questão.

Tabela 4. Tempo de processamento.

Nível	ID	Tempo (s)				
		Gemini 2.5 Flash	Gemini 3 Pro	Copilot	Copilot GPT-5	ChatGPT 5.2
Básico	5.5.E	15	59	30	25	48
	8.3.E	13	70	16	19	73
	6.1.E	19	55	21	20	91
	6.3.E	9	38	15	14	36
	12.6	22	47	20	17	54
Intermediário	10.1 e 10.2	15	56	23	22	50
	8.1.E	15	57	31	25	74
	10.1.E	15	70	22	19	67
	10.3.E	13	40	30	22	58
	10.6.E	15	96	28	55	72
Avançado	12.1.E	23	73	33	44	90
	12.3.E	17	70	32	19	57
	Ex. 4.4	16	58	33	35	69
	Ex. 9.3	66	66	33	32	56
	Ex. 14.1	30	88	28	29	65
Total (segundos e pontos/segundo)		303	943	395	397	960
		0.222	0.071	0.121	0.153	0.051

Nota-se, pela Tabela 4, que o Gemini 3 Pro, apesar de ser o modelo que mais teve acertos, possui o segundo pior desempenho do conjunto avaliado, quando se insere a métrica temporal na avaliação. Apesar da sua alta taxa de acertos, demanda um elevado tempo de processamento, o que o torna uma opção menos atrativa. Enquanto isso, a versão 2.5 Flash, da mesma plataforma, apresentou a melhor eficiência da relação acertos por tempo. Já as duas versões do Copilot, tanto a padrão quanto com GPT-5, tiveram desempenho intermediário.

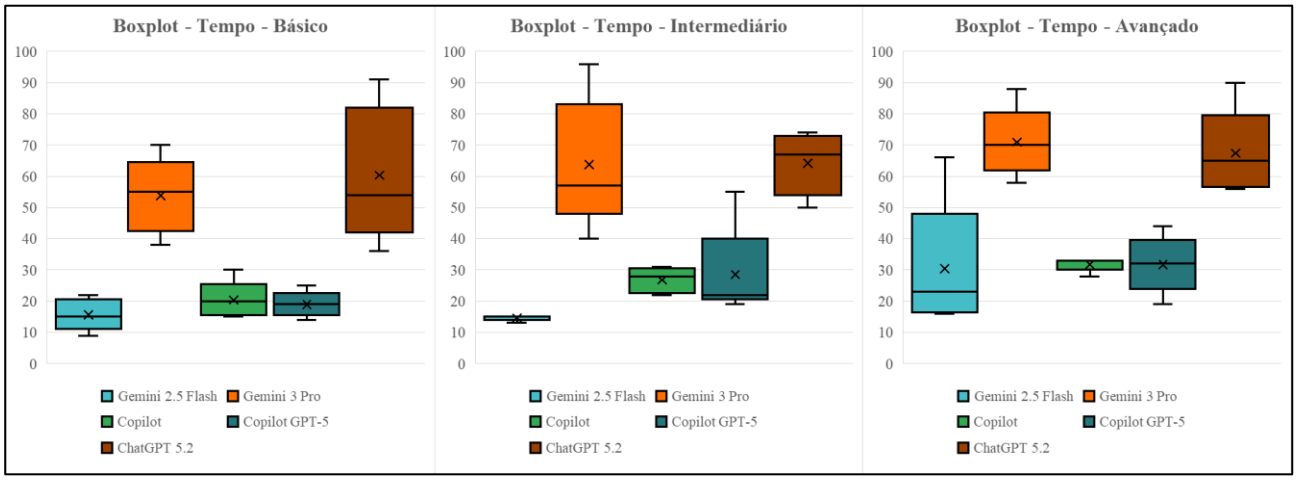


Figura 2. Evolução do tempo de processamento em segundos de cada modelo.

De forma similar ao desempenho em relação aos acertos absolutos, o ChatGPT 5.2 teve a pior performance em relação ao tempo de processamento, garantindo o pior desempenho geral neste artigo, como está evidente nas Figuras 1 e 2. Vale ressaltar que foi observado, durante a obtenção desses resultados, que o ChatGPT 5.2 foi o modelo que apresentou melhor detalhamento do raciocínio utilizado e a metodologia adotada nas questões, em conjunto do Gemini 3 Pro, que são os modelos mais robustos avaliados. Entretanto, no caso do GPT 5.2, o raciocínio apresentou erros fundamentais de cálculo, que inviabilizam sua utilização em comparação aos outros modelos.

É válido ressaltar que as plataformas avaliadas (Gemini, Copilot e ChatGPT), apesar de facilmente acessíveis, possuem diferenciação entre modelos gratuitos e pagos pelos usuários. Notou-se que modelos pagos (Gemini 3 Pro e Copilot GPT-5) apresentaram performance superior aos respectivos modelos gratuitos das mesmas plataformas (Gemini 2.5 Flash e Copilot). Apesar disso, a versão gratuita do Gemini ainda apresenta performance superior à versão paga do Copilot, tanto em termos de acertos quanto de tempo de processamento. O único modelo pago que foge dessa perspectiva é o ChatGPT 5.2, que apresentou o pior desempenho geral.

4 CONSIDERAÇÕES FINAIS

O objetivo deste trabalho foi verificar a acurácia da IA generativa na resolução de cálculos na Mecânica dos Solos, permitindo a verificação dos melhores modelos. Os resultados demonstram que as ferramentas de IA generativa possuem capacidade adequada para auxiliar na resolução de problemas da Mecânica dos Solos, desde que utilizadas com critério.

Observou-se uma clara correlação entre a robustez dos modelos e a precisão das respostas: versões mais sofisticadas, como o Gemini 3 Pro, alcançaram as maiores taxas de acerto. Entretanto, versões mais robustas, apesar de mais precisas, usualmente demandam maiores tempos de processamento, o que pode impactar a fluidez em fluxos de trabalho que exigem respostas rápidas. Para consultas rotineiras e com nível baixo de dificuldade, modelos intermediários e mais velozes se mostraram como alternativas adequadas.

O tempo de processamento, apesar de importante para comparação entre modelos de IA, não se compara ao tempo que levaria para um profissional ou um estudante realizar os mesmos cálculos de forma manual. Logo, esse tempo não é o gargalo para a avaliação, visto que qualquer modelo a ser utilizado é consideravelmente mais rápido que o processamento humano. Assim, deve-se dar preferência à métrica de acertos, sendo o tempo um fator secundário.

Com os resultados deste trabalho, é interessante levantar também a problemática e o impacto relacionados ao ensino da Mecânica dos Solos. Com modelos de IA muito precisos, como o Gemini 3 Pro com 89% de acertos, incluindo questões avançadas, as listas de exercícios tradicionais das disciplinas podem não ter a mesma relevância quanto antes da disseminação das IA's. No geral, entende-se que é essencial que alunos passem pelo aprendizado dos fundamentos e da lógica por trás da teoria na Mecânica dos Solos, mas a restrição de avaliações acadêmicas por cálculos pode estar se tornando obsoleta.

É fundamental destacar, todavia, que o uso dessas ferramentas não elimina a necessidade de verificação técnica. A identificação de erros em cálculos fundamentais demonstra que a IA deve atuar como um copiloto para o engenheiro. O julgamento crítico do profissional geotécnico permanece sendo o fator determinante para a aplicação segura dessas informações em projetos reais.

5 REFERÊNCIAS

Craig, R.F. (2004). *Craig's Soil Mechanics*. 7ª ed., Spon Press, Taylor & Francis Group, London, ISBN 0-415-32702-4), 458 p.

Das, B., Sobhan, K. (2014). *Fundamentos de engenharia geotécnica*. 8ª ed., Cengage Learning, São Paulo, ISBN 978-85-221-1824-3, 632 p.

Liu, P. et al. (2023). Pre-train, Prompt, and Predict: A Systematic Survey of Prompting Methods in Natural Language Processing. *ACM Computing Surveys*, v. 55, n. 9, p. 1-35, 2023. DOI:10.1145/3560815.

Maranha das Neves, E. (2016). *Mecânica dos Estados Críticos*: solos saturados e não saturados. 1ª ed, IST Press, Lisboa, ISBN 978-989-8481-48-1, 528 p.

Simões, A. L. A.; Fontes, D. C. H.; Anjos, I. S. M. (2024). Análise de erros conceituais produzidos por algoritmos de IA generativa quando consultados sobre hidráulica. In: *XVII Simpósio Recursos Hídricos do Nordeste*, João Pessoa.

Simões, W. F.; Costa, M.; Pereira, M. F.; Brasil, L. S. S. (2025). *Aplicação da inteligência artificial na gestão de segurança de barragens:* cenário atual e perspectivas para o futuro. In: *XXXV Seminário Nacional de Grandes Barragens*, Porto Alegre.

Souza Pinto, C. (2006). *Curso Básico de Mecânica dos Solos: em 16 aulas*. 3ª ed., Oficina de Textos, São Paulo, ISBN 978-85-86238-51-2, 363p.

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/COBRAMSEG2026.2/9

Avaliação do Desempenho de Rede Neural Treinada com Dados Sintéticos Aplicada à Estabilidade Geotécnica

Robert Nagai Gonçalves da Cruz
Mestrando em Geotecnia, Universidade Federal de Santa Catarina, Florianópolis, Brasil, robertnagaig@gmail.com

Helena Paula Nierwinski
Professora, Programa de Pós-Graduação em Engenharia Civil, Universidade Federal de Santa Catarina, Florianópolis, Brasil, helena.paula@ufsc.br

Gabriela Menghini de Godoy
Mestranda em Geotecnia, Universidade Federal de Santa Catarina, Florianópolis, Brasil, gabrielaminglindegodoy@gmail.com

Laura Zappellini Sassi
Mestranda em Geotecnia, Universidade Federal de Santa Catarina, Florianópolis, Brasil, lazasassi@gmail.com

Jose Manuel Guerra Colque
Professor, Universidade Privada de Santa Cruz de la Sierra, Santa Cruz, Bolívia, jmguerra@upsa.edu.bo

RESUMO: O fator de segurança (FS) de estruturas geotécnicas é influenciado por incertezas que podem ser associadas à variabilidade dos parâmetros geomecânicos do solo, às condições geométricas do maciço e à posição da linha freática. Redes Neurais Artificiais (RNA) têm sido empregadas na estimativa do FS, porém seu desempenho depende fortemente da disponibilidade de bases de treinamento suficientemente amplas e representativas, condição nem sempre atendida em problemas geotécnicos reais. Neste estudo, avaliou-se o desempenho de uma RNA do tipo *Multilayer Perceptron* treinada com dados sintéticos gerados por acoplamento automatizado entre o *software* Slide2 e *scripts* em Python, com variação de parâmetros geotécnicos e da linha freática. Foram consideradas bases com 600, 1.200, 1.800 e 3.000 simulações, e o desempenho foi analisado por meio das métricas RMSE, R^2 e erro percentual médio. Os resultados indicaram melhora progressiva do desempenho com o aumento do número de simulações, com ganhos marginais a partir de aproximadamente 1.200 simulações, sugerindo convergência do modelo para o problema analisado. A RNA reproduziu com boa precisão os valores de FS obtidos no modelo numérico, com erro percentual médio inferior a 5%. A metodologia proposta mostra potencial para geração de modelos preditivos aplicáveis à estabilidade geotécnica, com perspectiva de integração a sistemas de monitoramento automatizado para suporte à avaliação contínua da segurança de estruturas geotécnicas.

PALAVRAS-CHAVE: Redes Neurais Artificiais; Dados Sintéticos; Estabilidade Geotécnica; Fator de segurança; Treinamento de RNA.

ABSTRACT: The safety factor of geotechnical structures is influenced by uncertainties associated with the variability of the soil geomechanical parameters, the geometric conditions of the mass, and the position of the groundwater table. Artificial Neural Networks (ANNs) have been employed to estimate FS, however, their performance strongly depends on the availability of sufficiently large and representative training datasets, a condition that is not always met in real geotechnical problems. In this study, the performance of a Multilayer Perceptron (MLP) ANN trained on synthetic data generated through automated coupling between the Slide2 software and Python scripts was evaluated, considering variations in geotechnical parameters and groundwater conditions. Datasets containing 600, 1,200, 1,800, and 3,000 simulations were considered, and performance was assessed using RMSE, R^2, and mean percentage error. The results indicated progressive improvement in performance as the number of simulations increased, with marginal gains observed beyond approximately 1,200 simulations, suggesting model convergence for the problem analyzed. The ANN reproduced the factor

safety values obtained from the numerical model with good accuracy, with mean percentage errors below 5%. The proposed methodology shows potential for the development of predictive models applicable to geotechnical stability, with prospects for integration into automated monitoring systems to support the continuous safety assessment of geotechnical structures.

KEYWORDS: Artificial Neural Networks; Synthetic Data; Geotechnical Stability; Safety Factor; ANN Training.

1 INTRODUÇÃO

Técnicas de Inteligência Artificial (IA), especialmente Redes Neurais Artificiais (RNA), têm se destacado como ferramentas promissoras para modelar relações não lineares entre variáveis geotécnicas e o fator de segurança (FS). Estudos demonstraram que RNAs podem reproduzir com boa precisão o FS de taludes, mesmo em cenários complexos, atingindo desempenhos comparáveis a métodos numéricos (Choobbasti, Farrokhzad e Barari, 2009). Trabalhos mais recentes também avaliaram comparativamente diferentes técnicas de _machine learning _aplicadas à predição do FS em taludes, evidenciando o potencial dessas abordagens em problemas geotécnicos (Mahmoodzadeh *et al.*, 2022).

Entretanto, o desempenho de modelos baseados em RNA depende fortemente da quantidade e da representatividade dos dados utilizados no treinamento, o que constitui uma limitação recorrente em aplicações geotécnicas. Em muitos casos, não há disponibilidade de bases extensas, obtidas a partir de investigações de campo, ensaios laboratoriais ou histórico dos registros de instrumentação geotécnica, o que motiva o uso de dados sintéticos gerados por modelos numéricos. Essa abordagem permite explorar a variabilidade dos parâmetros de entrada e avaliar o comportamento preditivo do modelo, ainda que não substitua a necessidade de validação posterior com dados reais de campo.

O presente estudo investiga o desempenho de uma RNA treinada com dados sintéticos gerados por acoplamento automatizado entre o *software* Slide2 e *scripts* em Python, considerando um modelo representativo de uma barragem de solo compactado. Especificamente, avaliam-se:

(i) a influência do número de simulações sobre a convergência das métricas de desempenho;
(ii) a tendência de estabilização do erro com o aumento do número de simulações;
(iii) a capacidade preditiva do modelo em combinações pré-definidas de parâmetros dentro do domínio analisado.

2 METODOLOGIA

2.1 Geração da Base de Dados Sintética

O modelo geológico-geotécnico utilizado na análise está apresentado na Figura 1. Trata-se de um modelo representativo elaborado com base em condições reais de uma barragem de solo compactado, adaptado para fins de estudo. A geometria e a estratigrafia foram ajustadas de modo a preservar a confidencialidade da estrutura original. O maciço considerado possui altura aproximada de 22 m e taludes com inclinação média de 1,8H:1V. A barragem é constituída por aterro de solo compactado, filtro vertical em areia e dreno de pé, apoiados sobre fundação formada por colúvio, solo residual jovem, solo residual maduro e saprólito. Os parâmetros geotécnicos adotados, apresentados na Tabela 1, foram obtidos a partir de resultados de ensaios laboratoriais e de campo.

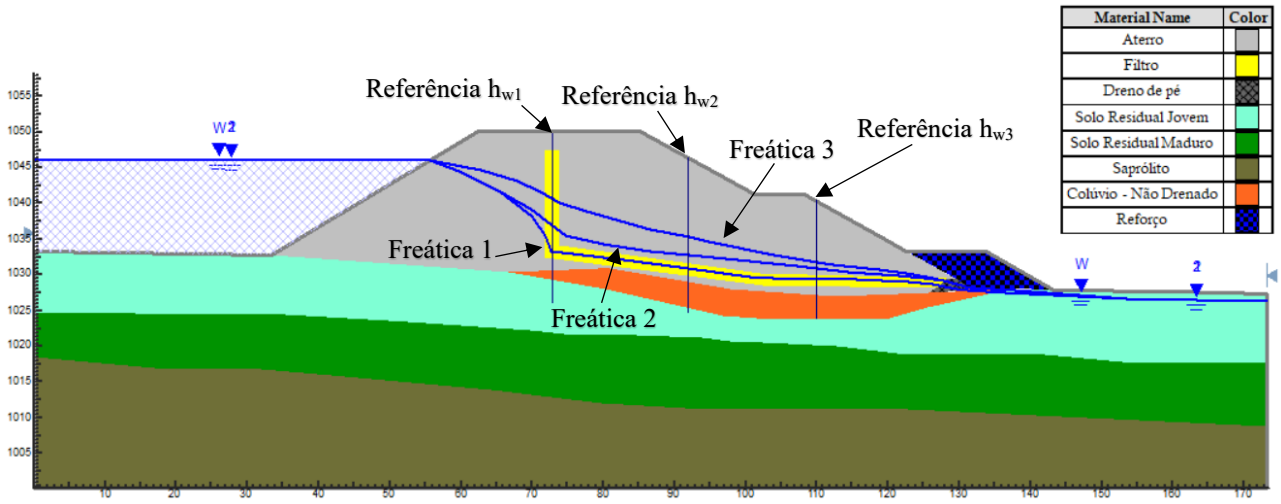


Figura 1. Modelo geológico-geotécnico, variações da linha freática e pontos de referência.

A análise probabilística concentrou-se na variação da razão de resistência não drenada do colúvio e nos parâmetros geotécnicos do aterro (coesão, ângulo de atrito e peso específico), por serem variáveis com influência relevante na estabilidade da estrutura avaliada pelo método de Equilíbrio Limite (LEM). Para os parâmetros probabilísticos, adotou-se distribuição lognormal, sem realização de teste formal de aderência. Os valores médios e desvios padrão foram definidos a partir do coeficiente de variação (COV), considerando faixas de variabilidade apresentadas na literatura (Zevgolis *et al*., 2010). A Tabela 1 apresenta os parâmetros variáveis do modelo, bem como seus valores médios e desvios padrão.

Tabela 1. Estatística dos parâmetros variáveis do modelo para o maciço e colúvio.

Estatística	**Aterro**			**Colúvio**
	Coesão	**Ângulo de atrito**	**Peso específico**	**Razão de resistência não drenada de pico – (Su_{pico}/σ'_{v0})**
Média	5 (kPa)	30 (º)	20 (kN/m³)	0,23
COV	30 (%)	15 (%)	8 (%)	4 (%)
Desvio padrão	1,50 (kPa)	4,5 (º)	1,6 (kN/m³)	0,01

As análises foram realizadas utilizando o *software* Slide2, da Rocscience, integrado ao Python por meio de *scripts* automatizados. O procedimento consistiu em abrir o modelo original, modificar os parâmetros definidos para cada simulação, salvar as alterações e realizar a análise por meio do executável do Slide2. Após cada execução, o *script* realiza a leitura automática do FS calculado e armazena o resultado para compor a base de dados. O número de simulações, o total de valores de entrada gerados e o tempo computacional correspondente são apresentados na Tabela 2. As variáveis de entrada consideradas incluíram:

- Nível freático: h_{w1}, h_{w2}, h_{w3} para três cenários de linha freática (Figura 1);
- Parâmetros geotécnicos do aterro: coesão (c), ângulo de atrito (φ) e peso específico (γ);
- Parâmetro geotécnico do colúvio: razão de resistência não drenada do colúvio (Su_{pico}/σ'_{v0}).

Tabela 2. Número de simulações, variáveis e tempo computacional.

Número de simulações	**Número de variáveis (7 por simulação)**	**Tempo computacional**
600	4.200	1 h 02 min
1.200	8.400	2 h 13 min
1.800	12.600	3 h 23 min
3.000	21.000	5 h 41 min

2.2 Arquitetura da RNA

A Rede Neural Artificial (RNA) utilizada neste estudo é do tipo *Multilayer Perceptron* (MLP), implementado por meio da biblioteca *scikit-learn* em Python. A MLP foi adotada por sua capacidade de aproximar relações não lineares em problemas supervisionados de regressão, sendo uma arquitetura adequada para problemas com múltiplas variáveis de entrada e saída escalar, como a predição do fator de segurança. Além disso, redes neurais artificiais têm sido amplamente empregadas em aplicações geotécnicas para modelagem de respostas complexas e não lineares (Shahin, Jaksa & Maier, 2008; Shao *et al*., 2023).

A RNA adotada é do tipo *feedforward* totalmente conectada, composta por: (i) uma camada de entrada com 7 variáveis independentes (h_{w1}, h_{w2}, h_{w3}, coesão, ângulo de atrito, peso específico e razão de resistência não drenada de pico do colúvio); (ii) uma camada oculta única com 10 neurônios e função de ativação ReLU; e (iii) uma camada de saída com 1 neurônio, correspondente ao fator de segurança (FS) calculado no Slide2.

A normalização das variáveis foi realizada com o *MinMaxScaler*, aplicado tanto às entradas quanto à saída, de modo a manter todas as variáveis no intervalo entre 0 e 1. Essa etapa contribui para a estabilidade do treinamento e reduz o efeito de diferenças de escala entre as variáveis de entrada. O treinamento foi realizado com o algoritmo de otimização *Adam* (Kingma e Ba, 2015), função de perda *Mean Squared Error* (MSE), divisão de 30% dos dados para teste e semente fixa (*random_state* = 42), visando à reprodutibilidade dos resultados. A documentação do *scikit-learn* indica que o otimizador *Adam* apresenta bom desempenho para bases com milhares de amostras, em termos de tempo de treinamento e qualidade de validação.

Ao final do treinamento, o desempenho do modelo foi avaliado com base nas métricas *Root Mean Square Error* (RMSE), coeficiente de determinação (R^2) e erro percentual médio. Em seguida, a RNA treinada foi utilizada para estimar o FS em cinco combinações pré-definidas de parâmetros geotécnicos e linha freática, mantidas dentro dos intervalos de variação adotados na geração da base sintética, permitindo comparar os valores preditos com aqueles obtidos nas análises de estabilidade executadas no Slide2.

3 RESULTADOS

Esta seção apresenta o desempenho da Rede Neural Artificial (RNA) treinada com bases sintéticas de diferentes tamanhos. Para cada conjunto de treinamento, são apresentadas as métricas de ajuste (RMSE, R^2 e erro percentual médio), bem como as previsões obtidas para cinco combinações pré-definidas de parâmetros. Adicionalmente, os resultados da RNA são comparados aos valores de fator de segurança (FS) obtidos no modelo determinístico no Slide2, permitindo avaliar a capacidade preditiva do modelo no domínio analisado.

3.1 Desempenho da RNA em função do número de simulações

A Tabela 3 resume os valores de RMSE, coeficiente de determinação (R^2) e erro percentual médio para cada conjunto de treinamento. Observa-se que o aumento do número de simulações promove melhora gradual nos indicadores de ajuste, especialmente entre 600 e 1.200 simulações, faixa em que o ganho é mais expressivo.

A partir de aproximadamente 1.200 a 1.800 simulações, os ganhos adicionais tornam-se marginais, evidenciando tendência de convergência das métricas de desempenho. Esse comportamento sugere que, para o problema analisado, o aumento da base além desse intervalo produz benefícios mais limitados em termos de qualidade preditiva.

Embora os valores de R^2 sejam moderados, os baixos valores de RMSE e de erro percentual médio indicam que a RNA foi capaz de reproduzir adequadamente o comportamento do FS no domínio analisado. Essa interpretação também é corroborada pela proximidade entre os valores preditos pela RNA e aqueles obtidos no Slide2, o que é compatível com a complexidade e a natureza não linear das interações entre os parâmetros geotécnicos considerados.

Tabela 3 – Métricas de desempenho da RNA treinada.

Número de simulações	Número de variáveis	RMSE	R^2	Erro percentual médio
600	4.200	0,08	0,50	4,54%
1.200	8.400	0,07	0,57	4,03%
1.800	12.600	0,07	0,59	3,84%
3.000	21.000	0,06	0,67	3,59%

3.2 Avaliação preditiva da RNA em cinco combinações de parâmetros

Cinco combinações de parâmetros, denominadas Combinações 1 a 5, foram avaliadas para analisar a capacidade preditiva da RNA em diferentes condições de dados de entrada. Essas combinações foram mantidas dentro dos intervalos de variação considerados na geração da base sintética, de modo a permitir a comparação entre os valores de fator de segurança estimados pela RNA e aqueles obtidos pelo modelo determinístico no Slide2. A Tabela 4 apresenta os conjuntos de variáveis de entrada considerados na análise comparativa, enquanto a Tabela 5 mostra os valores de FS obtidos pela mesma arquitetura de RNA, treinada com diferentes números de simulações, e pelo modelo determinístico do Slide2.

Tabela 4 – Variáveis de entrada para as análises comparativas.

Combinações	Elevação da linha freática			Aterro			Colúvio
	h_{w1} (m)	h_{w2} (m)	h_{w3} (m)	c (kPa)	φ (°)	γ (kN/m³)	(Su_{pico}/σ'_{v0})
Combinação 1	1.040,6	1.035,2	1.031,7	4,0	26,0	19,0	0,22
Combinação 2	1.033,2	1.030,8	1.029,4	5,5	30,0	20,5	0,23
Combinação 3	1.036,0	1.033,0	1.030,8	6,0	33,0	21,0	0,24
Combinação 4	1.038,0	1.032,0	1.030,0	3,8	28,5	18,5	0,22
Combinação 5	1.034,0	1.031,0	1.030,0	5,0	32,0	19,5	0,23

Tabela 5 – Resultados das análises comparativas de fator de segurança (FS).

Combinações	RNA treinada com 600 simulações	RNA treinada com 1.200 simulações	RNA treinada com 1.800 simulações	RNA treinada com 3.000 simulações	Slide2
Combinação 1	1,23	1,27	1,29	1,27	1,32
Combinação 2	1,44	1,44	1,45	1,43	1,50
Combinação 3	1,50	1,51	1,50	1,52	1,53
Combinação 4	1,39	1,42	1,42	1,42	1,41
Combinação 5	1,48	1,50	1,49	1,49	1,52

Os resultados indicam leve tendência de subestimação do FS pela RNA em relação ao modelo determinístico. Observa-se, ainda, que o desempenho melhora progressivamente com o aumento do número de simulações de treinamento, refletindo maior capacidade de representar as relações entre os parâmetros geotécnicos e o fator de segurança. Além disso, a diferença entre os resultados obtidos com 1.800 e 3.000 simulações é pequena, sugerindo estabilização do desempenho preditivo a partir de determinado tamanho de base.

De modo geral, os resultados mostram que a RNA reproduziu adequadamente os valores de FS obtidos no Slide2 para combinações de parâmetros mantidas dentro dos intervalos de variação adotados na geração da base sintética.

4 CONCLUSÕES

Os resultados deste estudo mostram que a RNA treinada com dados sintéticos gerados por acoplamento entre o Slide2 e *scripts* em Python foi capaz de reproduzir adequadamente os valores de fator de segurança (FS) obtidos no modelo numérico analisado. Para os conjuntos avaliados, os erros percentuais médios permaneceram inferiores a 5%, indicando bom desempenho preditivo no domínio considerado. Observou-se que o aumento do número de simulações melhora progressivamente as métricas de ajuste, porém os ganhos tornam-se marginais a partir de aproximadamente 1.200 a 1.800 simulações.

Ressalta-se, contudo, que o presente trabalho corresponde a um exercício metodológico baseado em dados sintéticos gerados a partir de simulações numéricas automatizadas. Nesse sentido, embora a RNA tenha representado adequadamente o comportamento do modelo numérico adotado, aplicações práticas devem ser desenvolvidas com base em dados reais de campo, obtidos por investigações, instrumentação e histórico de monitoramento da própria estrutura.

Sob essa perspectiva, a abordagem apresenta potencial de aplicação futura em estruturas que disponham de registros consistentes de campo, obtidos por campanhas de investigação, instrumentação ou histórico de monitoramento. Em contextos com maior nível de instrumentação, incluindo estruturas com integração a Centros de Monitoramento Geotécnico (CMG) e aquisição contínua ou quase em tempo real de dados, modelos desse tipo podem ser treinados, calibrados e atualizados, contribuindo para a avaliação contínua da segurança e para o apoio à tomada de decisão operacional.

AGRADECIMENTOS

Os autores agradecem à GWS Engenharia pela disponibilização da licença do *software* Slide2 utilizada nas análises deste estudo. Os autores agradecem, também, ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Santa Catarina.

REFERÊNCIAS BIBLIOGRÁFICAS

Choobbasti, A. J., Farrokhzad, F., & Barari, A. (2009). *Prediction of slope stability using artificial neural network* (case study: Noabad, Mazandaran, Iran). Arabian Journal of Geosciences, 2(4), 311–319. https://link.springer.com/article/10.1007/s12517-009-0035-3

Kingma, D. P., & Ba, J. *Adam: A Method for Stochastic Optimization*. arXiv preprint arXiv:1412.6980, 2015. https://doi.org/10.48550/arXiv.1412.6980

Mahmoodzadeh, A.; Mohammadi, M.; Hama Ali, H. F.; Ibrahim, H. H.; Abdulhamid, S. N.; Nejati, H. R. (2022). *Prediction of safety factors for slope stability: comparison of machine learning techniques.* Natural Hazards, 111(2), 1771–1799

Shahin, M. A., Jaksa, M. B., & Maier, H. R. (2008). *State of the art of artificial neural networks in geotechnical engineering*. Electronic Journal of Geotechnical Engineering, 8, 1–26

SHAO, W.; YUE, W.; ZHANG, Y.; ZHOU, T.; ZHANG, Y.; DANG, Y.; WANG, H.; FENG, X.; CHAO, Z. *The Application of Machine Learning Techniques in Geotechnical Engineering: A Review and Comparison*. Mathematics, v. 11, n. 18, 3976, 2023

Zevgolis, I. E.; Koukouzas, N. C.; Roumpos, C.; Deliveris, A. V.; Marshall, A. M. (2010). *Evaluation of geotechnical property variability: the case of spoil material from surface lignite mines*. International Journal of Mining, Reclamation and Environment, v. 24, n. 2, p. 104–120

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/COBRAMSEG2026.2/10

BIM Geotécnico: Revisão Sistemática

Auanny Alícia Alves da Silva
Mestranda em Engenharia Civil e Ambiental, Universidade Federal de Campina Grande - UFCG, Campina Grande - PB, Brasil, auannyaliciasilva@gmail.com

Jucimara Cardoso da Silva
Doutoranda em Engenharia Civil e Ambiental, Universidade Federal de Campina Grande, Campina Grande, Brasil, jucimara.engenhariacivil@gmail.com

Filipe Cordeiro Rodrigues
Graduando em Engenharia Civil, Universidade Federal de Campina Grande, Campina Grande, Brasil, filipecrodrigues1281@gmail.com

Carina Silvani
Doutora Professora do Departamento de Engenharia Civil, Universidade Federal de Campina Grande, Campina Grande, Brasil, carinasilvani@gmail.com

RESUMO: O *Building Information Modeling* (BIM) tem avançado de forma significativa no setor da Engenharia Civil, porém sua incorporação na Geotecnia ainda ocorre de maneira gradual e heterogênea. Este trabalho apresenta uma revisão sistemática da literatura sobre o uso do BIM aplicado à Geotecnia, com o objetivo de mapear o estado da arte, identificar lacunas e apontar tendências de pesquisa e aplicação. A pesquisa foi conduzida por meio do método *Systematic Search Flow* (SSF), utilizando as bases ScienceDirect, Scopus, Web of Science, Portal de Periódicos CAPES e anais do Congresso Brasileiro de Mecânica dos Solos e Engenharia Geotécnica (COBRAMSEG), considerando publicações entre 2010 e 2025. Após a aplicação de critérios de inclusão e exclusão, 186 estudos foram selecionados para análise qualitativa. Os resultados evidenciam que o BIM geotécnico tem sido aplicado principalmente em projetos de infraestrutura, como túneis, barragens e obras subterrâneas, com foco na integração de modelos geológicos, gestão de riscos e compatibilização multidisciplinar. Entretanto, persistem desafios importantes, especialmente relacionados à padronização de objetos geotécnicos, limitada interoperabilidade entre softwares, escassez de bibliotecas específicas e dificuldades na representação de solos e maciços rochosos em ambientes BIM. Conclui-se que, embora em expansão, o BIM geotécnico ainda carece de consolidação metodológica e tecnológica, destacando-se a necessidade de maior integração entre pesquisa acadêmica e indústria, bem como o desenvolvimento de ferramentas e protocolos adequados às particularidades da Geotecnia.

PALAVRAS-CHAVE: Dados geotécnicos; Tecnologias de informação e comunicação; Gestão de dados BIM; Interoperabilidade; Compatibilização multidisciplinar.

ABSTRACT: Building Information Modeling (BIM) has advanced significantly in the Civil Engineering sector, but its incorporation into Geotechnical Engineering is still gradual and heterogeneous. This work presents a systematic literature review on the use of BIM applied to Geotechnical Engineering, aiming to map the state of the art, identify gaps, and point out research and application trends. The review was conducted using the Systematic Search Flow (SSF) method, based on searches in the ScienceDirect, Scopus, Web of Science, CAPES Periodicals Portal, and the proceedings of the Brazilian Conference on Soil Mechanics and Geotechnical Engineering (COBRAMSEG), considering publications between 2010 and

2025. After applying inclusion and exclusion criteria, 186 studies were selected for qualitative analysis. The results indicate that geotechnical BIM has been mainly applied to infrastructure projects, such as tunnels, dams, and underground works, with emphasis on the integration of geological models, risk management, and multidisciplinary coordination. However, significant challenges persist, especially related to the standardization of geotechnical objects, limited interoperability between software, a scarcity of specific libraries, and difficulties in representing soils and rock masses in BIM environments. It is concluded that, although expanding, geotechnical BIM still lacks methodological and technological consolidation, highlighting the need for greater integration between academic research and industry, as well as the development of tools and protocols suited to the particularities of Geotechnics.

KEYWORDS: Geotechnical data; Information and communication technologies; BIM data management; Interoperability; Multidisciplinary compatibility.

1 INTRODUÇÃO

A crescente complexidade dos projetos de engenharia, aliada à necessidade de maior eficiência, redução de custos e mitigação de riscos, tem impulsionado a adoção de novas tecnologias digitais ao longo do ciclo de vida dos empreendimentos. Nesse contexto, o *Building Information Modeling* (BIM) se consolidou como uma abordagem inovadora que integra informações geométricas e não geométricas em um modelo digital inteligente e colaborativo (Borrmann et al., 2018; Eastman et al., 2011). A partir da sua expansão ascendente, a tecnologia BIM opera como um repositório centralizado de dados, de modo que permite a visualização, a coordenação e a gestão das diferentes etapas de um projeto (Fabozzi et al., 2021; Satyanaga et al., 2023).

Nas últimas décadas, o BIM tem sido amplamente aplicado em projetos de edificações e infraestrutura, especialmente devido à sua capacidade de promover compatibilização multidisciplinar, visualização tridimensional e gerenciamento integrado de informações ao longo do ciclo de vida das obras. Como resultado, diversos países passaram a incentivar ou exigir sua adoção em projetos públicos por meio de políticas e normativas específicas, como ocorre no Reino Unido, Estados Unidos e Cingapura (Satyanaga et al., 2023). No Brasil, a disseminação dessa metodologia foi impulsionada pelo Decreto nº 9.377/2018, que institui a Estratégia BIM BR e estabelece diretrizes para sua implementação gradual em órgãos e entidades da administração pública federal (Brasil, 2018, 2024).

Apesar de sua ampla aplicação em projetos estruturais e arquitetônicos, a incorporação do BIM na área da geotecnia ainda ocorre de forma limitada. Diferentemente de componentes estruturais como concreto ou aço, os solos e maciços rochosos apresentam elevada variabilidade espacial e propriedades dependentes de dados indiretos obtidos por investigações de campo, como sondagens e ensaios laboratoriais. Essas características dificultam a representação contínua do subsolo em ambientes BIM e impõem desafios adicionais relacionados à modelagem tridimensional contínua do maciço e à integração de dados geológico-geotécnicos provenientes de diferentes fontes (Huang et al., 2022; Shi et al., 2023).

Outro desafio relevante refere-se à interoperabilidade entre plataformas BIM e softwares especializados de análise geotécnica, como modelagens numéricas baseadas em métodos de elementos finitos (FEM). Em muitos casos, a ausência de padrões consolidados para a representação de dados geotécnicos e a limitada integração entre formatos de dados exigem etapas manuais de conversão e processamento, reduzindo a eficiência do fluxo de trabalho digital (Huang et al., 2022; Satyanaga et al., 2023; Zirpoli; Sattamino, 2024).

Mesmo diante dessas limitações, observa-se um crescimento recente de estudos voltados ao desenvolvimento do chamado GeoBIM ou BIM Geotécnico. Nessas aplicações, o modelo digital pode incorporar dados de investigação do subsolo, resultados de análises numéricas e informações de monitoramento, contribuindo para a avaliação de riscos associados a condições geotécnicas incertas, especialmente em obras subterrâneas como túneis, escavações profundas e sistemas de transporte urbano

como metrôs (Deng et al., 2016; Fabozzi et al., 2021; Shi et al., 2023). Além disso, novas abordagens vêm explorando a integração entre BIM, sensores de monitoramento e algoritmos de aprendizado de máquina, como Inteligência Artificial (IA) e *Internet of Things* (IoT) permitindo a atualização dinâmica dos modelos com base em dados obtidos em tempo real (Rane et al., 2023).

Diante desse cenário, torna-se relevante compreender como o BIM tem sido aplicado no contexto geotécnico e quais avanços vêm sendo propostos para superar os desafios associados à representação e integração de dados do subsolo. Assim, este trabalho tem como objetivo apresentar uma revisão sistemática da literatura sobre a aplicação do BIM na geotecnia, buscando identificar tendências de pesquisa, principais áreas de aplicação e limitações ainda presentes, contribuindo para a consolidação e ampliação do uso dessa abordagem em projetos geotécnicos no meio acadêmico e profissional.

2 METODOLOGIA

A presente pesquisa foi conduzida por meio de revisão sistemática da literatura, adotando o método *Systematic Search Flow* (SSF), o qual estrutura o processo de identificação, seleção e análise de estudos relevantes de forma transparente e reprodutível (Farenhof; Fernandes, 2016; Kitchenham, 2004).

Todo o procedimento de identificação, triagem e elegibilidade é descrito na Figura 1, permitindo o levantamento inicial nas bases de dados, a análise preliminar e, por fim, a aplicação de critérios de inclusão e exclusão para os trabalhos.

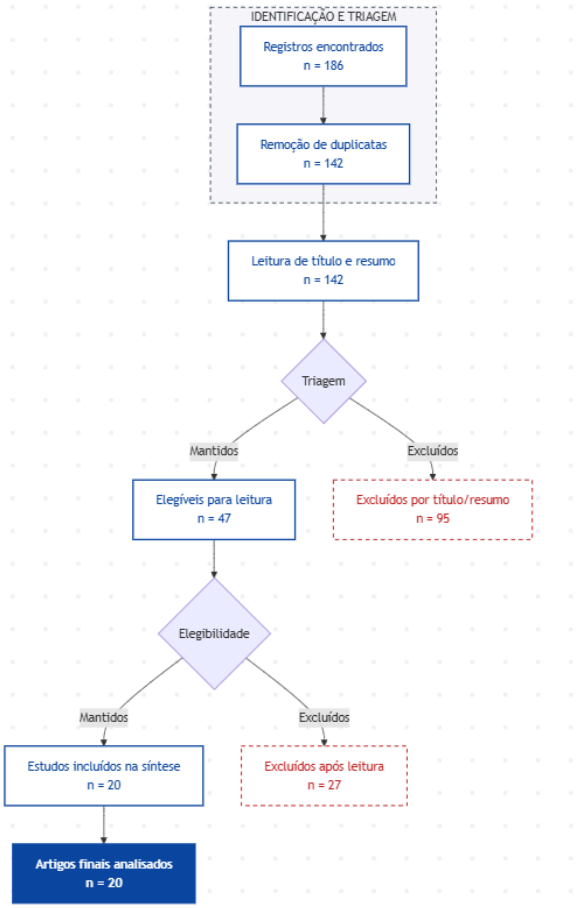


Figura 1. Fluxograma de seleção de trabalhos.

A busca bibliográfica foi realizada nas bases de dados ScienceDirect, Scopus, Web of Science, Portal de Periódicos CAPES e nos anais do Congresso Brasileiro de Mecânica dos Solos e Engenharia Geotécnica

(COBRAMSEG), considerando o período entre 2010 e 2025, intervalo que abrange o crescimento recente das aplicações do Building Information Modeling (BIM) em projetos geotécnicos. Para tal processo, foram utilizadas combinações de palavras-chave relacionadas ao tema ("BIM", "GeoBIM", "geotechnical BIM", "subsurface modeling", "geotechnical investigation data", "BIM geotechnical engineering", "BIM underground") com operadores booleanos (AND/OR), de forma a ampliar a recuperação de estudos relevantes nos últimos 15 anos.

Os critérios de inclusão foram considerados para:

- Estudos que apresentassem aplicação do BIM em contextos geotécnicos, como modelagem de subsolo, integração de dados de sondagem, obras subterrâneas ou análises numéricas associadas;
- Discussões sobre integração entre dados geológico-geotécnicos e plataformas BIM;
- Publicações revisadas por pares ou trabalhos completos em congressos relevantes da área.

Ao mesmo tempo, foram excluídos estudos que abordassem BIM exclusivamente em edificações ou arquitetura (sem dados geotécnicos), apresentassem discussões conceituais sem aplicação técnica ou fossem registros duplicados entre as bases.

Por fim, os estudos elegíveis foram analisados qualitativamente, buscando identificar principais áreas de aplicação do GeoBIM, abordagens metodológicas utilizadas e tendências de desenvolvimento da integração entre modelagem digital e engenharia geotécnica, conforme apresentado na Tabela 1.

Tabela 1. Caracterização dos estudos analisados.

Autor	Ano	Aplicação do GeoBIM	Contribuição prática
Antonio et al.	2021	Edificações residenciais	Dimensões 3D a 5D em projetos de fundações e contenções
Barros et al.	2024	Investigações de campo	Digitalização e modelagem 3D em sondagem à trado
Fabozzi et al.	2021	Túneis	FEM-BIM e gestão 4D
Huang et al.	2022	Estações de metrô	BIM multi-LOD (*Level of detail*)
Rane et al.	2023	Caracterização de solo	Integração de IA e Iot para monitoramento de subsolo
Shi et al.	2023	Escavações profundas	Extração de geometrias do BIM com programação
Sibaii et al.	2022	Sondagem	Template de dados e programação para automatização de modelos do subsolo
Zirpoli e Sattamino	2024	Pontes	Interoperabilidade na interação solo-estrutura com Midas Civil e Flac3D

3 RESULTADOS E DISCUSSÕES

A análise dos estudos selecionados permitiu identificar padrões relevantes relacionados à bases de estudo, evolução temporal, distribuição geográfica e principais áreas de aplicação da produção científica com foco no BIM voltado para a engenharia geotécnica.

Na Figura 2, é possível observar que a base ScienceDirect detêm o maior número de resultados, seguida por Scopus e Web of Science, evidenciando a predominância de periódicos internacionais na produção científica sobre BIM aplicado à engenharia geotécnica.

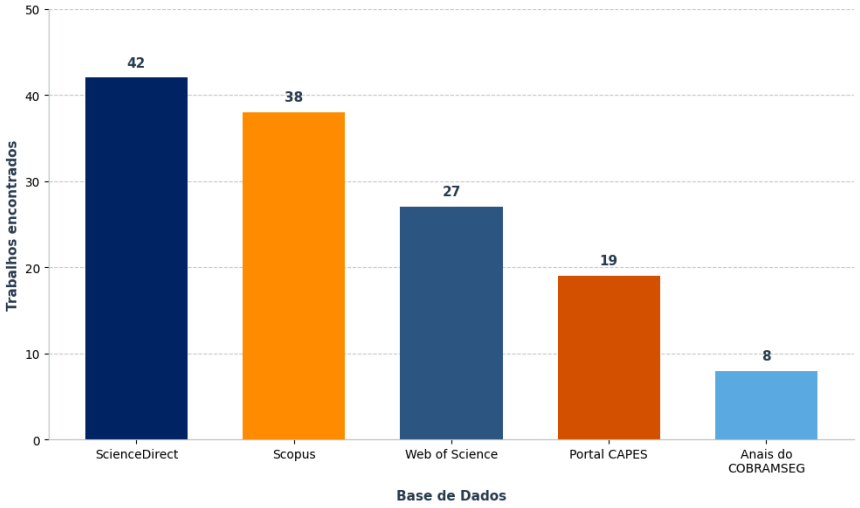


Figura 2. Distribuição dos trabalhos identificados nas bases de dados consultadas.

Uma presença considerável acima de 40 trabalhos nessas fontes científicas indica que o tema tem sido discutido principalmente em periódicos internacionais voltados à infraestrutura e, principalmente, à evolução tecnológica para a digitalização das obras.

A evolução temporal das publicações, apresentada na Figura 3, evidencia o crescimento das publicações entre 2010 e 2025, demonstrando o nível de interesse científico pelo BIM aplicado à geotecnia.

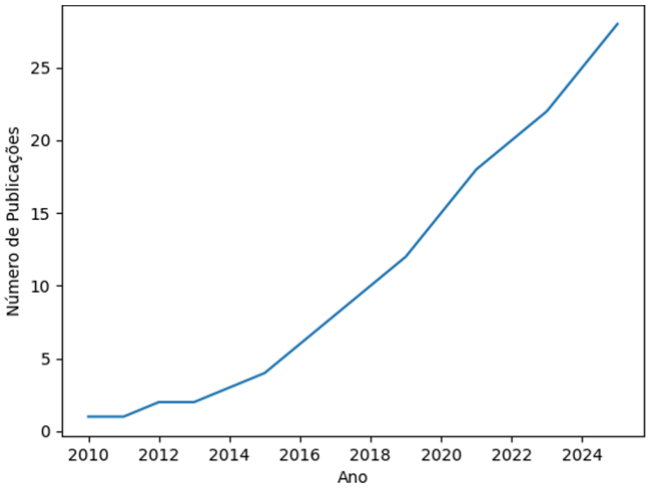


Figura 3. Linha do tempo das publicações sobre BIM geotécnico.

Entre 2010 e 2014, o número de estudos publicados permaneceu reduzido, com valores variando entre uma e quatro publicações anuais. A partir de 2016, observa-se uma tendência mais clara de crescimento contínuo, indicando que o tema conseguiu obter maior consolidação dentro da comunidade científica. Esse crescimento possivelmente está associado ao avanço das tecnologias de modelagem tridimensional e ao desenvolvimento de extensões do padrão IFC (*Industry Foundation Classes*), culminando no seu maior pico com mais de 25 publicações, registradas no ano de 2024.

Logo, o comportamento sugere que o GeoBIM é um campo emergente de pesquisa, impulsionado pela crescente digitalização da engenharia e, ao mesmo tempo, pela necessidade de integração de dados, muitas vezes ausente ou insuficiente quando voltados à projetos de infraestrutura.

A análise da distribuição geográfica das publicações (Figura 4) revela uma elevada concentração de pesquisas nos eixos europeu e asiático, com ambos os continentes registrando mais de 30 estudos no intervalo entre 2010 e 2025. Em contrapartida, a produção na América do Norte totaliza aproximadamente 20 trabalhos, enquanto as demais regiões, somadas, excedem 10 publicações. Nota-se que a contribuição brasileira permanece incipiente, figurando abaixo de 10 estudos identificados.

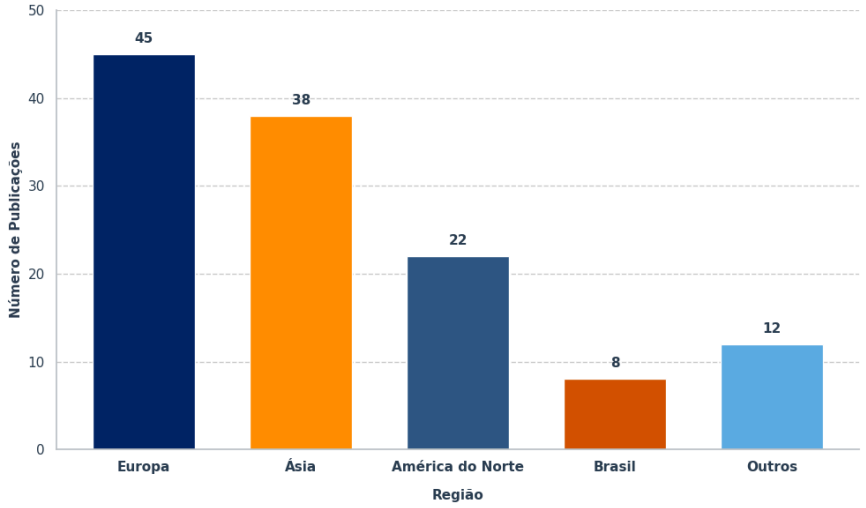


Figura 4. Distribuição geográfica das publicações sobre BIM geotécnico.

A disparidade de publicações reflete os diferentes estágios de maturidade tecnológica e normativa entre as diferentes regiões do mundo, dado que a consolidação dos estudos geotécnicos é impulsionada na Europa e na Ásia pelas obras de infraestrutura subterrânea, onde a gestão de riscos geológicos em modelos 3D é mandatória para a viabilidade de grandes obras de engenharia.

Em países como o Reino Unido, os dados de investigação geotécnica são geralmente trocados utilizando formatos padronizados, como o formato de dados AGS (*Association of Geotechnical and Geoenvironmental Specialists*), que se tornou uma referência do setor para a transferência de dados digitais. Nos Estados Unidos, iniciativas como o DIGGS (*Data Interchange for Geotechnical and Geoenvironmental Specialists*) visam padronizar a troca de informações geotécnicas utilizando esquemas baseados em XML.

Em contrapartida, muitos países em desenvolvimento – como o exemplo do Brasil – ainda dependem predominantemente de formatos não estruturados, como relatórios em PDF ou planilhas em Excel, o que limita a interoperabilidade e a automação em ambientes BIM.

As principais áreas de aplicação do BIM na engenharia geotécnica, apresentadas na Figura 5, indicam uma predominância de estudos voltados para projetos de túneis, seguidos por aplicações relacionadas à integração BIM-FEM, modelagem tridimensional do subsolo, fundações profundas e estruturas de contenção.

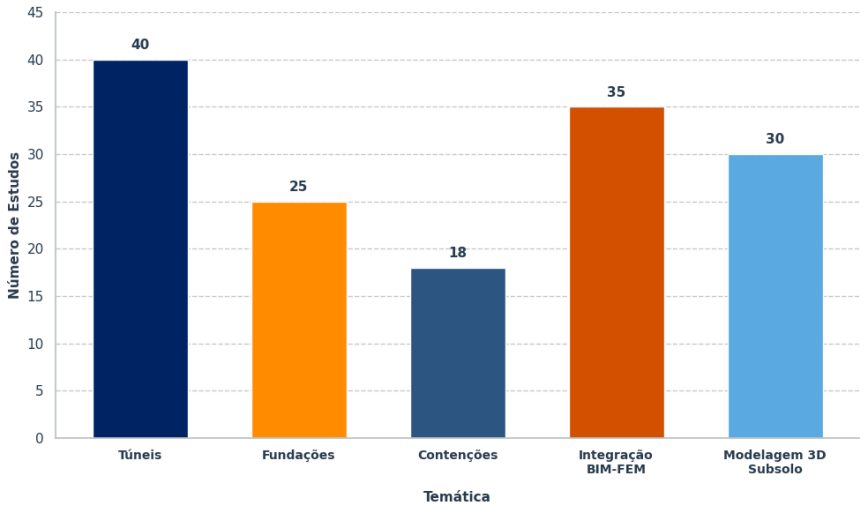


Figura 5. Principais áreas de aplicação do BIM geotécnico.

Observa-se que a predominância dos estudos de GeoBIM é voltada para projetos de túneis, refletindo a complexidade de obras subterrâneas, nas quais a integração de informações geológicas, geotécnicas e estruturais é um fator determinante para a mitigação de riscos. Analogamente, outro destaque é a integração BIM com o método dos elementos finitos para análise de estabilidade estrutural (BIM-FEM).

E assim, pode-se observar que, houve um crescimento significativo das publicações a partir de 2016, indicando consolidação progressiva do GeoBIM no cenário internacional, com histórico de aplicações que envolvem túneis urbanos, fundações profundas, contenções e integração BIM-FEM. Entretanto, no Brasil, a produção científica ainda é limitada, concentrando-se principalmente em eventos técnicos.

4 CONCLUSÕES

A revisão sistemática evidencia que o BIM Geotécnico apresenta elevado potencial para aprimorar o planejamento e a gestão de riscos em obras de engenharia. Contudo, desafios técnicos ainda limitam sua aplicação plena. A partir da presente pesquisa desenvolvida pode-se constatar que, os principais desafios identificados referem-se à ausência de padronização específica para dados geotécnicos no IFC, além da necessidade de automatização da importação de dados de sondagens.

Por fim, objetivando agregar e contribuir com o desenvolvimento de pesquisas futuras referentes ao tema aqui abordado, recomenda-se o desenvolvimento de bibliotecas geotécnicas padronizadas, bem como a ampliação da produção científica nacional sobre o tema.

REFERÊNCIAS BIBLIOGRÁFICAS

Antonio, D. F., Dellaroli, F., & Antunes, G. B. S. (2021). Implantação da plataforma BIM em projetos geotécnicos nas dimensões 3D, 4D e 5D. *M-SR: Multi-Science Research*, *4*(2), 28–43.

Barros, M. L., Cavalcante, A. L. B., & Silva Júnior, E. E. A. (2024). *BIM Geotécnico: Digitalização de dados de sondagens para modelagem de informação do subterrâneo*. XXI Congresso Brasileiro de Mecânica dos Solos e Engenharia Geotécnica (COBRAMSEG 2024), Balneário Camboriú, SC, Brasil.

Borrmann, A., König, M., Koch, C., & Beetz, J. (Eds.). (2018). *Building Information Modeling: Technology foundations and industry practice*. Springer.

Brasil. (2024). *Decreto nº 11.888, de 22 de janeiro de 2024*. Dispõe sobre a Estratégia Nacional de Disseminação do Building Information Modelling no Brasil - Estratégia BIM BR e institui o Comitê Gestor da Estratégia do Building Information Modelling - BIM BR. Presidência da República.

Brasil. Ministério do Desenvolvimento, Indústria, Comércio e Serviços. (2024). *Plano de Trabalho - Nova BIM BR*. https://plataformabimbr.abdi.com.br/guias-normas/Plano-de-trabalho-Nova-BIM-BR.pdf

BuildingSMART. (2021). *FC 4.3 infrastructure extension deployment: Production standard.* Industry Foundation Classes (IFC).

Deng, Y., Cheng, J. C. P., & Anumba, C. (2016). Mapping between BIM and geotechnical information models. *Automation in Constructio*n, 70, 52–67.

Eastman, C., Teicholz, P., Sacks, R., & Liston, K. (2011). *BIM handbook: A guide to building information modeling* (2 ed.). Wiley.

Fabozzi, S., Biancardo, S. A., Veropalumbo, R., & Bilotta, E. (2021). I-BIM based approach for geotechnical and numerical modelling of a conventional tunnel excavation. *Tunnelling and Underground Space Technology*, 108, 103723.

Farenhof, H. A., & Fernandes, R. F. (2016). Desmistificando a revisão de literatura como base para redação científica: Método SSF. *Revista ACB: Biblioteconomia em Santa Catarina*, 21(2), 350–363.

Huang, M. Q., Zhu, H. M., Ninić, J., & Zhang, Q. B. (2022). Multi-LOD BIM for underground metro station: Interoperability and design-to-design enhancement. *Tunnelling and Underground Space Technology*, 119, 104232.

Kitchenham, B. (2004). *Procedures for performing systematic reviews*. Keele University.

Rane, N., Choudhary, S., & Rane, J. (2023). Leading-edge Artificial Intelligence (AI) and Internet of Things (IoT) technologies for enhanced geotechnical site characterization. *Social Science Research Network*.

Satyanaga, A., Aventian, G. D., Makenova, Y., Zhakiyeva, A., Kamaliyeva, Z., Moon, S.-W., & Kim, J. (2023). Building Information Modelling for Application in Geotechnical Engineering. *Infrastructures*, 8(6), 103.

Shi, C., Jin, Y., Lu, H., & Shi, J. (2023). A BIM-based framework for automatic numerical modelling and geotechnical analysis of a large-scale deep excavation for transportation infrastructures. *Intelligent Transportation Infrastructure*, 2, 1-13.

Zirpoli, A., & Sattamino, P. (2024). Interoperability between structural and geotechnical analysis for the study of safety in existing bridges. *Procedia Structural Integrity*, 62, 492–498.

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/COBRAMSEG2026.2/11

Da Conversa à Simulação: Modelagem Numérica Geotécnica Mediada por Modelos de Linguagem de Larga Escala (LLMs)

Matheus Tavares Dias
Engenheiro Geotécnico, Universidade de Brasília – UnB, Brasília, Brasil, matheusttd@gmail.com

André Luís Brasil Cavalcante, D.Sc.
Professor, Universidade de Brasília – UnB, Brasília, Brasil, albrasilc@gmail.com

Luan Carlos de Sena Monteiro Ozelim, D.Sc.
Engenheiro Civil, Universidade de Brasília – UnB, Brasília, Brasil, luanoz@gmail.com

RESUMO: O avanço da Inteligência Artificial (IA) tem transformado a forma como engenheiros interagem com sistemas computacionais complexos. Na engenharia geotécnica, o método dos elementos finitos (MEF) é amplamente empregado para simular o comportamento tensão-deformação e avaliar a estabilidade de estruturas de solo sob condições hidromecânicas diversas, embora sua aplicação ainda exija conhecimento especializado e dedicação na etapa de configuração. Nesse contexto, o presente trabalho apresenta o GeoAssist AI, uma plataforma inteligente desenvolvida para integrar modelos de linguagem de larga escala (LLMs) a ferramentas de modelagem numérica de código aberto, utilizando Python como base de integração. O principal objetivo da plataforma é automatizar e simplificar o processo de criação de modelos geotécnicos, permitindo que o engenheiro configure e execute simulações por meio de comandos em linguagem natural. A partir de descrições textuais, o sistema interpreta as instruções do usuário, gera a estrutura do modelo, define propriedades de materiais, condições de contorno e malhas, e executa automaticamente a simulação numérica. O GeoAssist AI é composto por três módulos complementares: (i) o módulo de interpretação semântica, que traduz a linguagem natural em comandos técnicos; (ii) o módulo de geração automática de modelos, que cria os arquivos de entrada compatíveis com o solver numérico; e (iii) o módulo de análise e visualização, que processa os resultados e apresenta gráficos de tensões, deformações e fatores de segurança. Como demonstração funcional, foi implementado um teste de execução automática de uma simulação geotécnica simples, em que o usuário fornece apenas instruções descritivas para gerar e visualizar um modelo de estabilidade. O sistema executa o processo de forma autônoma, convertendo o texto em código e exibindo os resultados numéricos e gráficos de forma integrada. Os resultados preliminares indicam que o GeoAssist AI representa um avanço metodológico na integração entre IA e modelagem numérica, aproximando o engenheiro do ambiente de simulação e ampliando a acessibilidade às análises. Além disso, o sistema demonstra potencial para uso em ensino, pesquisa e prática profissional, reforçando seu papel como ferramenta inovadora de apoio à engenharia geotécnica.

PALAVRAS-CHAVE: Inteligência Artificial, Modelagem Numérica, Elementos Finitos, Estabilidade, Python.

ABSTRACT: The advancement of Artificial Intelligence (AI) has transformed the way engineers interact with complex computational systems. In geotechnical engineering, the Finite Element Method (FEM) is widely employed to simulate stress–strain behavior and assess the stability of soil structures under different hydromechanical conditions, although its application still requires specialized knowledge and considerable effort during the model setup stage. In this context, the present study introduces GeoAssist AI, an intelligent platform developed to integrate large language models (LLMs) with open-source numerical modeling tools, using Python as the integration framework. The main objective of the platform is to automate and simplify the process of creating geotechnical models, allowing engineers to configure and execute simulations through natural language commands. From textual descriptions, the system interprets user instructions, generates the model structure, defines material properties, boundary conditions, and meshes, and automatically runs the numerical simulation. GeoAssist AI is composed of three complementary modules: (i) the semantic interpretation module, which translates natural language into technical commands; (ii) the automatic model

generation module, which creates input files compatible with the numerical solver; and (iii) the analysis and visualization module, which processes the results and presents stress, deformation, and factor-of-safety plots. As a functional demonstration, an automatic execution test of a simple geotechnical simulation was implemented, in which the user provides only descriptive instructions to generate and visualize a stability model. The system autonomously executes the process, converting text into code and displaying the numerical and graphical results in an integrated manner. Preliminary results indicate that GeoAssist AI represents a methodological advance in the integration of AI and numerical modeling, bringing engineers closer to the simulation environment and increasing the accessibility of geotechnical analyses. In addition, the system shows potential for application in teaching, research, and professional practice, reinforcing its role as an innovative support tool for geotechnical engineering.

KEYWORDS: Artificial Intelligence, Numerical Modeling, Finite Elements, Stability, Python.

1 INTRODUÇÃO

A modelagem numérica é uma ferramenta central na análise de problemas geotécnicos complexos, especialmente quando estão presentes não linearidades constitutivas, heterogeneidade estratigráfica e acoplamento hidromecânico. Nesse contexto, o Método dos Elementos Finitos (MEF) consolidou-se como uma abordagem dominante, ao permitir a resolução de problemas governados por equações diferenciais parciais por meio de discretização espacial e formulações constitutivas elasto-plásticas (Zienkiewicz, Taylor, Zhu 2013; Potts, Zdravkovic 1999).

Apesar de sua consolidação teórica e de seu amplo uso, a aplicação do MEF em rotinas de projeto e pesquisa ainda enfrenta uma barreira operacional relevante. A construção de um modelo exige a definição explícita de geometria, malha, propriedades dos materiais, condições de contorno e etapas de carregamento, além da manipulação de arquivos de entrada e interfaces com sintaxes particulares de cada *solver*. Na prática, essa fase de pré-processamento demanda domínio geotécnico e computacional simultaneamente, o que pode restringir a acessibilidade, aumentar o tempo de preparação e ampliar a probabilidade de inconsistências ou omissões na configuração.

Em paralelo, modelos de linguagem natural de larga escala (LLMs), baseados na arquitetura Transformer (Vaswani et al. 2017), têm demonstrado capacidade de interpretar instruções técnicas e produzir representações estruturadas, inclusive código. O conceito de *foundation models* (Bommasani et al. 2021) ampliou o uso desses sistemas como intermediários entre linguagem humana e sistemas formais.

Diante disso, observa-se uma lacuna operacional: a ausência de um mecanismo estruturado que conecte, de modo rastreável, a descrição conceitual do problema geotécnico à sua implementação numérica. Este trabalho apresenta o GeoAssist AI, uma arquitetura que formaliza essa mediação por meio de um *schema* intermediário que separa a interpretação semântica da execução numérica determinística. A contribuição do artigo é metodológica: propor e demonstrar um *pipeline* reprodutível que conecta descrições em linguagem natural à modelagem geotécnica via MEF, preservando a coerência entre hipóteses físicas, organização de entradas e execução do *solver*.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Método dos Elementos Finitos na Engenharia Geotécnica

Sob uma perspectiva formal, problemas geotécnicos analisados pelo Método dos Elementos Finitos (MEF) podem ser formulados como problemas de valor de contorno governados pelas equações de equilíbrio, pelas relações cinemáticas entre deslocamentos e deformações e pelas leis constitutivas do material. Em notação contínua, busca-se o campo de deslocamentos u(x) que satisfaça as equações de equilíbrio $\nabla \cdot \sigma + b = 0$ no domínio, em conjunto com condições de contorno essenciais e naturais. A formulação em elementos finitos resulta da conversão do problema diferencial em forma fraca, com aproximação dos campos por funções de interpolação definidas em um conjunto discreto de elementos, conduzindo a um sistema algébrico que fornece

aproximações para deslocamentos, deformações e tensões (Zienkiewicz, Taylor, Zhu 2013; Potts, Zdravkovic 1999).

Em geotecnia, a não linearidade é frequentemente dominante, uma vez que os solos apresentam comportamento elasto-plástico e dependente da trajetória de tensões. Por isso, a solução numérica exige procedimentos incremental-iterativos para atualização de tensões, verificação de plastificação e convergência do equilíbrio global. Em análises de estabilidade, destaca-se o procedimento de redução progressiva da resistência (*Strength Reduction Method*), no qual os parâmetros resistentes são degradados até a perda de convergência, usualmente interpretada como condição limite numérica (Potts, Zdravkovic 1999). Outro aspecto central é a definição das condições hidráulicas: em problemas com poropressão, o equilíbrio mecânico se relaciona diretamente à distribuição de pressões neutras e, consequentemente, às tensões efetivas, seja em meios saturados, seja em formulações que considerem sucção em solos não saturados (Biot 1941; Fredlund, Rahardjo 1993).

No contexto deste artigo, a relevância do MEF não se limita à sua capacidade de simulação, mas à sua função como formalização rigorosa de hipóteses físicas em uma representação matemática e computacional. Assim, qualquer abordagem que pretenda automatizar ou mediar a construção de modelos numéricos deve preservar a consistência entre hipóteses adotadas, representação das entradas e execução efetiva do *solver*.

2.2 Modelos de Linguagem Natural de Larga Escala (LLMs)

Modelos de linguagem natural de larga escala (*Large Language Models* — LLMs) são sistemas baseados predominantemente na arquitetura Transformer, capazes de capturar dependências contextuais em sequências extensas e de generalizar para múltiplas tarefas linguísticas e técnicas (Vaswani et al. 2017). No contexto dos *foundation models*, esses sistemas podem servir como base adaptável para tarefas como síntese de texto técnico, extração de informações estruturadas e geração de código (Bommasani et al. 2021). Essa última capacidade é particularmente relevante em engenharia, pois permite mapear descrições textuais em representações formais computacionais (Chen et al. 2021).

Em aplicações técnicas, entretanto, a geração textual livre é insuficiente quando se exige confiabilidade. Nessas condições, o papel dos LLMs é mais adequadamente entendido como o de mediadores semânticos entre linguagem humana e sistemas formais, desde que acoplados a mecanismos determinísticos de validação, tipagem e execução, capazes de reduzir ambiguidades e assegurar consistência das entradas.

3 METODOLOGIA: ESTRUTURAÇÃO DO *PIPELINE* DO GEOASSIST AI

3.1 Visão Geral do Pipeline

O GeoAssist AI é estruturado como um *pipeline* que organiza o processo de modelagem numérica geotécnica em três etapas: (i) estruturação conceitual das entradas, (ii) tradução programática para o *solver* e (iii) execução com pós-processamento automatizado. A proposta não altera a formulação matemática do MEF; ela reorganiza o fluxo operacional introduzindo uma camada estruturada entre linguagem natural e *solver*. Na **Erro! Fonte de referência não encontrada.** é apresentado um esquema geral do *pipeline*.

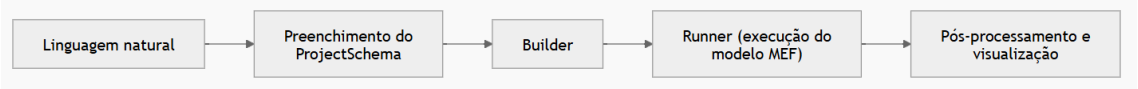


Figura 1. Estrutura conceitual do pipeline do GeoAssist AI, evidenciando a separação entre estruturação conceitual, tradução programática e execução numérica.

Essa camada é formalizada por meio de um *schema* de projeto, que atua como contrato entre a descrição conceitual do problema e sua materialização computacional. A etapa de linguagem natural não é tratada como garantia de correção técnica, mas como interface para preenchimento da estrutura de entradas. A consistência das informações é delegada ao *schema*, por meio de validações e restrições formais. Essa decisão é coerente com princípios de ciência computacional reprodutível, nos quais a confiabilidade depende de um caminho de execução auditável e de premissas registradas como dados, e não como inferências implícitas.

3.2 Estruturação das Entradas por Meio de *Schema*

O núcleo da mediação é o *ProjectSchema*, que representa o gabarito de entrada do sistema. Esse *schema* organiza parâmetros conceituais em quatro blocos: (I) especificação geométrica, (II) biblioteca de materiais, (III) condições de contorno e (IV) configurações do *solver*. O *schema* não armazena comandos específicos do *solver*; ele registra informações físicas e operacionais de alto nível, estruturadas de modo a permitir validação e tradução determinística.

A biblioteca de materiais contempla definições baseadas no modelo de Mohr–Coulomb, com parâmetros como densidade, módulos elásticos, coesão, ângulo de atrito, dilatância e resistência à tração. Esses parâmetros permanecem no nível conceitual até serem convertidos para a sintaxe do *solver* na etapa de compilação.

A geometria é descrita em um nível de abstração que favorece reconstrução programática. Quando expressa de forma paramétrica, essa representação reduz ambiguidades ao explicitar relações geométricas relevantes (altura, inclinações, camadas, crista) e restringir variáveis a parâmetros definidos. De modo análogo, a linha freática é representada por pontos de controle, permitindo interpolação e imposição coerente de poropressões iniciais, aspecto sensível em análises de estabilidade e problemas hidromecânicos (Biot 1941; Fredlund, Rahardjo 1993).

Condições de contorno e configurações do *solver* são descritas em termos conceituais, incluindo fixações geométricas, parâmetros de malha, unidade de tensão, gravidade e peso específico da água. O *schema* busca garantir consistência interna, como correspondência entre materiais e camadas e coerência de unidades.

3.3 Tradução para o *Solver: Builder*

Após validação do *ProjectSchema*, o *pipeline* avança para a etapa de compilação programática, implementada pelo *builder*. Essa etapa realiza a transição do nível conceitual para o operacional do *solver*, convertendo descrições abstratas em entidades discretizadas, identificadores internos e comandos executáveis. Essa necessidade decorre da natureza do MEF: embora o engenheiro formule o problema em termos físicos, o *solver* opera sobre discretizações e instruções formais.

Nesse processo, são geradas as linhas de contorno que definem o domínio e as interfaces internas entre camadas. A biblioteca de materiais é mapeada para identificadores numéricos internos, permitindo associar cada região geométrica ao material correspondente. A atribuição regional é realizada com base em pontos internos representativos, utilizados para identificar regiões fechadas delimitadas pela geometria.

Adicionalmente, a linha freática é convertida para uma representação compatível com a imposição de poropressão inicial, e as condições de contorno são traduzidas em entidades geométricas adequadas para aplicação de restrições.

A etapa é deliberadamente determinística: para um mesmo *schema*, o *builder* deve produzir o mesmo conjunto de entradas executáveis. Essa propriedade é essencial para reprodutibilidade e auditoria, especialmente quando se acopla uma etapa semântica a um procedimento numérico que exige controle e rastreabilidade.

3.4 Execução Numérica e Pós-Processamento: *Runner*

A etapa final do *pipeline* é implementada pelo *runner*, responsável por interagir com o software e executar, em sequência controlada, operações típicas do ciclo do MEF: construção do domínio, discretização e geração de malha, criação e atribuição de materiais, aplicação de gravidade e condições de contorno, imposição de poropressões iniciais e execução do procedimento SRF/FOS.

A imposição de poropressão inicial é tratada explicitamente, preservando coerência com a formulação de tensões efetivas e as hipóteses hidráulicas do problema. Em seguida, a análise SRF/FOS é conduzida como procedimento numérico para identificação de condição limite via redução progressiva de resistência, compatível com a prática de estabilidade em MEF e com modelos elasto-plásticos usuais. Após a solução, o *runner* aciona rotinas de pós-processamento para geração de visualizações de campos relevantes (tensões, deformações e indicadores de estabilidade), produzindo saídas consistentes.

Do ponto de vista metodológico, o produto do *pipeline* não é apenas o resultado final, mas um registro executável do caminho de geração e execução do modelo, sustentando a proposta de conectar linguagem natural à simulação sem perder rastreabilidade.

4 DEMONSTRAÇÃO FUNCIONAL: DA ESTRUTURA CONCEITUAL À EXECUÇÃO NUMÉRICA

A demonstração funcional foi concebida para verificar, em cenário controlado, a exequibilidade do fluxo ponta a ponta proposto: partir de uma descrição conceitual em linguagem natural, consolidá-la em uma representação formal (*ProjectSchema*) e, a partir dela, gerar e executar automaticamente um modelo numérico de estabilidade, com saídas gráficas e numéricas integradas. O foco recai sobre a robustez do encadeamento computacional e sobre a preservação de coerência física ao longo da tradução programática.

A etapa de execução numérica foi realizada no ADONIS, um programa gratuito de elementos finitos para aplicações geotécnicas disponibilizado pelo projeto GeoWizard (GeoWizard, 2026), que inclui rotinas de pré/pós-processamento e módulo de redução progressiva da resistência ao cisalhamento para análises de estabilidade (SRF/SSR).

Ressalta-se que esta demonstração não tem por objetivo avaliar sistematicamente o componente semântico (LLM) nem comparar desempenho com fluxos tradicionais. O objetivo é evidenciar que, uma vez formalizado o problema em um *schema* completo e verificável, o *pipeline* executa de forma determinística e reprodutível do pré-processamento ao pós-processamento, sem intervenção manual adicional.

4.1 Aquisição das Entradas via Linguagem Natural

Para tornar explícito o tipo de interação que alimenta a camada estruturada (*ProjectSchema*), apresenta-se a seguir uma transcrição ilustrativa de diálogo referente ao caso demonstrativo. O *listing* documenta o tipo de informação fornecida pelo usuário (geometria via segmentos extraídos de DXF, materiais, zoneamento, condições de contorno e linha freática) e como ela é organizada para posterior validação e execução.

Listing 1 – Transcrição ilustrativa (Usuário/GeoAssist AI) para preenchimento das entradas do caso demonstrativo.

Usuário: Quero rodar uma análise de estabilidade (SRF/FOS) no ADONIS usando o pipeline automático. Tenho um DXF com a seção do talude, de onde consegui extrair as coordenadas dos segmentos da geometria e também os pontos da linha freática. Também quero usar 3 materiais e modelo de Mohr-Coulomb.
GeoAssist AI: Perfeito.
Vamos por etapas: Geometria; Materiais; Distribuição por regiões; Condições de contorno; Freática; Configurações do solver.
Você quer fornecer a geometria como segmentos (x1,y1,x2,y2) exportados do DXF?
Usuário: Aqui estão os segmentos (do DXF):
(0.000, 0.000) ; (0.000, 60.000)
(114.208, 10.122) ; (111.787, 10.343) [..]
GeoAssist AI: Perfeito. Agora sobre os materiais: quantos materiais você quer e quais nomes você prefere?
Usuário: Quero 3 materiais: Solo Arenoso, Solo Argiloso e Rocha.
GeoAssist AI: Certo. Informe os parâmetros em unidades do SI: density (kg/m³), shear (Pa), bulk (Pa), coh (Pa), fric (°), dil (°), tens (Pa).
Usuário: Solo_Arenoso: density=2000.0, shear=5.0e7, bulk=1.0e8, coh=1.0e3, fric=35.0, dil=5.0, tens=0.0.
Solo_Argiloso: density=1900.0, shear=2.0e7, bulk=5.0e7, coh=2.0e4, fric=25.0, dil=0.0, tens=0.0.
Rocha: density=2400.0, shear=5.0e8, bulk=8.0e8, coh=2.0e5, fric=40.0, dil=0.0, tens=0.0.
GeoAssist AI: Agora vem a atribuição dos materiais. Você prefere por camadas (paramétrico) ou por pontos internos por região (mais seguro para geometria do DXF)?
Usuário: Vamos de pontos internos por região. Rocha: (10,2), (60,3), (110,2). Solo Argiloso: (10,20), (50,18), (90,15). Solo Arenoso: (10,55), (25,52), (40,50).
GeoAssist AI: Agora sobre condições de contorno: você quer fixar quais partes?

Usuário: base e lateral esquerda.
GeoAssist AI: Agora a linha freática: informe os pontos do DXF.
Usuário: wt_x = [0.000, 19.543, 25.938, 35.177, 42.994, 56.851, 72.485, 116.993]; wt_y = [30.000, ..]
GeoAssist AI: Vou gerar as entradas e executar SRF/FOS no ADONIS, com pós-processamento do SSI.

4.2 Representação estruturada: *ProjectSchema* simplificado

As informações coletadas são consolidadas em uma representação estruturada (*ProjectSchema*), utilizada como contrato entre intenção e execução. Para fins de transparência metodológica, apresenta-se abaixo um *schema* simplificado (ilustrativo) no estilo Pydantic, evidenciando os blocos de informação empregados nesta demonstração.

Listing 2 – ProjectSchema simplificado usado como contrato de entrada.

ProjectSchema = {geometry, materials, zoning, boundary_conditions, water_table, solver_config}.
Onde, *geometry* armazena segmentos extraídos de DXF; *materials*, a biblioteca Mohr–Coulomb; *zoning*, os pontos internos por região; *boundary_conditions*, as restrições geométricas; *water_table*, os pontos da polilinha freática; e *solver_config*, os parâmetros de execução no ADONIS.

4.3 Definição do Caso e Estrutura Física do Modelo

Para demonstrar a operacionalização do pipeline, conduziu-se uma análise de estabilidade de um talude estratificado em seção bidimensional, com aproximadamente 60 m de altura e inclinação global descendente da esquerda para a direita. A geometria foi definida explicitamente por segmentos de reta, permitindo representar quebras locais de inclinação e interfaces internas inclinadas entre unidades. A Figura 2 apresenta a geometria discretizada e a separação regional dos materiais após a geração automática da malha.

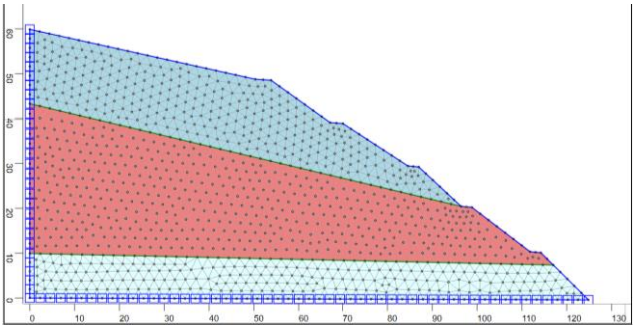


Figura 2. Geometria do talude, discretização triangular (T3) e distribuição dos materiais.

O domínio foi restringido na base e na lateral esquerda, eliminando modos de corpo rígido e assegurando estabilidade numérica. O modelo contempla três unidades geotécnicas (rocha, solo argiloso e solo arenoso), com atribuição regional realizada por pontos internos associados aos identificadores constitutivos, o que evita a necessidade de definição manual de polígonos e é compatível com geometrias oriundas de DXF.

4.4 Execução Numérica e Pós-Processamento: *Runner*

A linha freática foi definida como polilinha interpolada linearmente ao longo do talude, e o campo inicial de poropressão foi imposto sob hipótese hidrostática. O modelo foi resolvido no ADONIS com elementos triangulares lineares (T3), com geração automática de malha e aplicação de peso próprio via campo gravitacional uniforme. A estabilidade foi avaliada pelo método de redução de resistência (SRF/FOS), procedimento consolidado em análises por MEF para identificação de condição limite (Griffiths, Lane 1999; Dawson, Roth, Drescher 1999).

4.5 Resultados Numéricos e Padrão de Plastificação

Os contornos do índice de estabilidade (SSI) indicaram concentração de deformações ao longo do talude, com desenvolvimento de uma superfície potencial de ruptura iniciando em porções superiores e propagando-se em direção ao pé jusante. A distribuição das zonas plastificadas foi compatível com um mecanismo de ruptura rotacional composta, coerente com taludes estratificados sob carregamento gravitacional e influência de pressões neutras. A Figura 3 apresenta o contorno do índice de estabilidade obtido no pós-processamento.

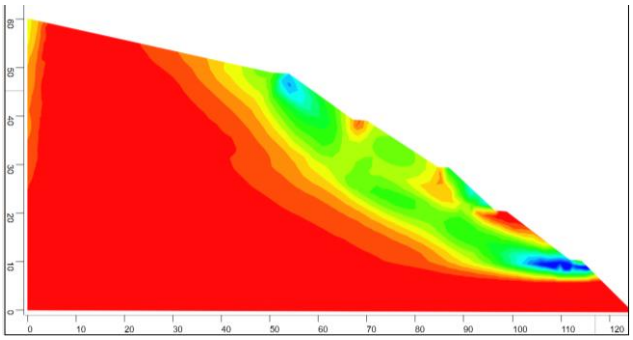


Figura 3. Contorno (SSI), com zonas de plastificação e desenvolvimento de superfície potencial de ruptura.

A região crítica localizou-se próxima ao contato entre a camada argilosa intermediária e a rocha subjacente, o que é mecanicamente plausível. De um lado, o contraste de rigidez tende a concentrar deformações e favorecer mobilização diferencial ao longo da interface. De outro, a menor resistência friccional da unidade intermediária constitui zona preferencial de plastificação, em especial quando tensões efetivas são reduzidas pela presença de poropressões associadas à linha freática (Terzaghi, Peck, Mesri 1996; Fredlund, Rahardjo 1993). Assim, o mecanismo observado se mantém consistente com a interpretação esperada para um problema com estratigrafia contrastante e regime hidráulico capaz de afetar tensões efetivas em regiões-chave do domínio.

4.6 Validação da Mediação Computacional

A evidência produzida por esta demonstração refere-se à consistência do encadeamento computacional entre a representação estruturada do problema e a execução numérica. A compatibilidade entre um mecanismo geotécnico esperado (ruptura composta influenciada por estratigrafia e poropressão) e a resposta observada (plastificação em regiões mecanicamente consistentes) sugere que a tradução programática não introduziu alterações conceituais relevantes ao converter o *schema* em comandos do *solver*. Essa verificação é condição necessária para escalabilidade: antes de ampliar complexidade constitutiva, hidráulica ou geométrica, é importante assegurar que o encadeamento formal preserve a intenção do problema.

Do ponto de vista de engenharia de software, o *schema* intermediário estabelece uma camada auditável entre intenção e execução, reduzindo suscetibilidade a erros típicos de configuração manual (por exemplo, inconsistências de unidade, omissões e associações incorretas de propriedades) e contribuindo para reprodutibilidade ao registrar o estado do problema como dados estruturados. Embora esta demonstração não quantifique ganhos de produtividade nem avalie sistematicamente o componente semântico (LLM), os resultados apresentados sustentam a premissa central deste estudo: é possível conduzir, de forma automatizada e reprodutível, a transição entre uma descrição estruturada e a execução numérica com pós-processamento integrado, criando base para avaliações futuras de robustez semântica e ampliação do repertório constitutivo e hidráulico.

5 CONCLUSÃO

Este trabalho apresentou o GeoAssist AI como uma arquitetura de mediação entre modelos de linguagem natural (LLMs) e modelagem numérica geotécnica por MEF, implementada em Python e acoplada a um ambiente de simulação. O objetivo foi formalizar e demonstrar um fluxo capaz de transformar descrições técnicas em uma representação estruturada e, a partir dela, executar de forma automatizada uma análise numérica, preservando coerência física e rastreabilidade do processo.

A contribuição principal é metodológica: a introdução de um *schema* intermediário como contrato formal entre a intenção do usuário e a execução computacional. Ao separar explicitamente a etapa de interpretação/extração, potencialmente mediada por LLMs, da etapa de execução numérica determinística, a abordagem favorece auditabilidade e reprodutibilidade do caminho de geração do modelo, além de reduzir pontos recorrentes de falha associados ao pré-processamento manual.

A demonstração funcional confirmou a exequibilidade ponta a ponta do *pipeline* no contexto de um talude estratificado 2D, com geometria definida por linhas, materiais Mohr–Coulomb, condições de contorno e linha freática. O modelo foi construído e resolvido automaticamente por SRF/FOS e produziu saídas compatíveis com interpretação geotécnica: reconstrução geométrica consistente com o *schema*, atribuição regional de materiais conforme definido, imposição hidrostática de poropressão coerente com a linha freática e um padrão de plastificação/ruptura mecanicamente plausível diante do contraste de rigidez e resistência entre camadas e do regime hidráulico adotado.

Por fim, delimita-se o escopo do estudo: não foram quantificados ganhos de produtividade, nem avaliada de forma sistemática a acurácia do componente semântico sob variações linguísticas, tampouco conduzidas comparações com fluxos tradicionais ou soluções de referência. Assim, os resultados devem ser interpretados como evidência de viabilidade técnica do encadeamento formal proposto e de consistência entre entradas estruturadas e execução numérica, e não como validação abrangente de desempenho.

REFERÊNCIAS BIBLIOGRÁFICAS

Biot, M. A. (1941) General theory of three-dimensional consolidation. Journal of Applied Physics, 12 (2), p. 155–164.

Bommasani, R.; Hudson, D. A.; Adeli, E.; Altman, R.; Arora, S.; von Arx, S.; Bernstein, M. S.; et al. (2021) On the opportunities and risks of foundation models. arXiv preprint arXiv:2108.07258, p. 1–137. https://doi.org/10.48550/arXiv.2108.07258

Chen, M.; Tworek, J.; Jun, H.; Yuan, Q.; de Oliveira Pinto, H. P.; Kaplan, J.; Edwards, H.; et al. (2021) Evaluating large language models trained on code. arXiv preprint arXiv:2107.03374, p. 1–37. https://doi.org/10.48550/arXiv.2107.03374

Dawson, E. M.; Roth, W. H.; Drescher, A. (1999) Slope stability analysis by strength reduction. Géotechnique, 49 (6), p. 835–840. https://doi.org/10.1680/geot.1999.49.6.835

Fredlund, D. G.; Rahardjo, H. (1993) Soil mechanics for unsaturated soils. John Wiley & Sons, New York.

GeoWizard (2026). ADONIS: Free finite element program for Geo-Engineers. Disponível em: <https://www.geowizard.org/download_adonis.html>. Acesso em: 10 jun. 2026.

Griffiths, D. V.; Lane, P. A. (1999) Slope stability analysis by finite elements. Géotechnique, 49 (3), p. 387–403. https://doi.org/10.1680/geot.1999.49.3.387

Potts, D. M.; Zdravkovic, L. (1999) Finite element analysis in geotechnical engineering: theory. Thomas Telford, London.

Terzaghi, K.; Peck, R. B.; Mesri, G. (1996) Soil mechanics in engineering practice. 3rd ed., John Wiley & Sons, New York.

Vaswani, A.; Shazeer, N.; Parmar, N.; Uszkoreit, J.; Jones, L.; Gomez, A. N.; Kaiser, L.; Polosukhin, I. (2017) Attention is all you need. Advances in Neural Information Processing Systems, 30, p. 5998–6008.

Zienkiewicz, O. C.; Taylor, R. L.; Zhu, J. Z. (2013) The finite element method: its basis and fundamentals. 7th ed., Elsevier.

XXII Congresso Brasileiro de Mecânica dos Solos e Engenharia GeotécnicaXI
XII Congresso Luso Brasileiro de Geotecnia (CLBG)
XI Simpósio Brasileiro de Engenheiros Geotécnicos Jovens
24 a 28 de agosto de 2026 – Brasília/DF
DOI: 10.47094/COBRAMSEG2026.2/12

Detecção e Mensuração de Danos em Pavimentos Asfálticos com YOLOv11: um Estudo em Rodovias Brasileiras

Vanessa Ramos Fontes
Graduanda em Engenharia de Computação, UFRB, Cruz das Almas, Brasil, E-mail: nessa1vane@aluno.ufrb.edu.br

Acbal Rucas Andrade Achy
Professor, Programa de Pós-graduação em Engenharia Elétrica e Computação, UFRB, Cruz das Almas, Brasil, E-mail: acbal@ufrb.edu.br

Brenner Dos Santos De Araújo
Pós-graduando, Programa de Pós-graduação em Engenharia Elétrica e Computação, UFRB, Cruz das Almas, Brasil, E-mail: brennersa@aluno.ufrb.edu.br

Daniel José Cerqueira Brito
Graduando em bacharelado em ciências exatas e tecnológicas, UFRB, Cruz das Almas, Brasil, E-mail: danielze@aluno.ufrb.edu.br

Weiner Gustavo Silva Costa
Professor, Laboratório de Pavimentação PaveLab CETEC, UFRB, Cruz das Almas, Brasil, E-mail: weiner@ufrb.edu.br

Mario Sergio de Souza Almeida
Professor, Laboratório de Pavimentação PaveLab CETEC, UFRB, Cruz das Almas, Brasil, E-mail: mario.almeida@ufrb.edu.br

RESUMO: A manutenção eficiente da malha viária depende da identificação precoce e confiável de danos em pavimentos. Métodos tradicionais de inspeção, predominantemente manuais, são custosos, lentos e sujeitos à variabilidade entre avaliadores. Este trabalho apresenta um sistema de visão computacional baseado em YOLOv11 para detecção e classificação de defeitos em pavimentos asfálticos, com mensuração inicial por estimativa de área a partir de *bounding boxes*. A abordagem utiliza (i) pré-processamento para realce de contraste e bordas, (ii) uma cascata de modelos de detecção para robustez e refinamento de predições e (iii) detecção constrangida à região efetiva da pista para reduzir falsos positivos fora da via. O estudo utiliza um *dataset* brasileiro em construção a partir de imagens de rodovias com anotações automáticas assistidas por modelos treinados previamente em bases anotadas. Como prévia dos resultados: o modelo de detecção de defeitos alcançou mAP@0.5 de 85,0% com Precision de 89,1%, enquanto o modelo de segmentação de via atingiu desempenho superior a 99% em todas as métricas. A cascata de modelos mostrou ganho relevante na detecção de remendos, e a restrição espacial eliminou falsos positivos em regiões fora da pista. Como trabalhos futuros, prevê-se o refinamento das anotações brasileiras, consolidação de métricas quantitativas e evolução para estratégias de mensuração mais precisas baseadas em segmentação.

PALAVRAS-CHAVE: pavimentos asfálticos; detecção de danos; YOLOv11; visão computacional; restrição espacial.

ABSTRACT: Efficient maintenance of road networks depends on the early and reliable identification of pavement damage. Traditional inspection methods, predominantly manual, are costly, slow and subject to variability among evaluators. This paper presents a computer vision system based on YOLOv11 for the detection and classification of defects in asphalt pavements, with initial measurement by area estimation from bounding boxes. The approach uses (i) preprocessing for contrast and edge enhancement, (ii) a cascade of detection models for robustness and prediction refinement, and (iii) detection constrained to the effective road region to reduce false positives outside the road. The study uses a Brazilian dataset under construction from road images with automatic annotations assisted by models previously trained on annotated datasets. Preliminary results show the damage detection model achieved mAP@0.5 of 85.0% with Precision of 89.1%,

while the road segmentation model reached over 99% performance on all metrics. The model cascade improved patch detection, and spatial constraint eliminated off-road false positives. Future work includes refinement of Brazilian annotations, consolidation of quantitative metrics and evolution toward more accurate segmentation-based measurement strategies.

KEYWORDS: asphalt pavements; damage detection; YOLOv11; computer vision; spatially restricted.

1 INTRODUÇÃO

A infraestrutura rodoviária é um pilar fundamental para o desenvolvimento econômico e a integração logística de qualquer país. No Brasil, a malha viária supera 1,7 milhão de quilômetros, dos quais apenas cerca de 12% são pavimentados (SETCEMG, 2025). Desse percentual pavimentado, mais da metade apresenta algum tipo de deficiência no pavimento, como fissuras, buracos e deformações (CNT, 2019). A deterioração dos pavimentos não apenas reduz a segurança como também eleva os custos operacionais de transporte.

Os métodos tradicionais de inspeção, baseados em levantamentos visuais de campo conforme a norma DNIT 005 (DNIT, 2003), embora consolidados, são lentos, custosos, perigosos para os avaliadores e sujeitos à variabilidade entre inspetores. Assim, o avanço do aprendizado profundo (*deep learning*), especialmente das CNNs para detecção de objetos, oferece uma alternativa promissora para automatizar inspeções viárias. A família YOLO (*You Only Look Once*), introduzida por Redmon *et al.* (2016), consolidou-se como referência em detecção em tempo real, capaz de processar a imagem em uma única passagem.

A pesquisa em detecção automática de defeitos em pavimentos tem evoluído através de diversas variantes da família YOLO, com foco em mecanismos de atenção e otimização para dispositivos embarcados. Pham *et al.* (2022) utilizaram o YOLOv7 com *coordinate attention* para obter alta acurácia em imagens do Google Street View, enquanto Ren *et al.* (2023) criaram uma versão aprimorada do YOLOv5, o YOLOv5s, para detecção de danos em pavimentos a partir de imagens urbanas de *street view*. A busca por eficiência para dispositivos embarcados levou ao desenvolvimento de modelos leves, como o YOLOv8-PD proposto por Li *et al.* (2024), que reduziu parâmetros em mais de 25% através de módulos *Ghost* e *Transformers*.

Apesar dos avanços, identificam-se lacunas relevantes na literatura. Primeiramente, a maioria dos *datasets* disponíveis é composta por imagens de rodovias internacionais cujas condições de pavimento, clima e padrões de desgaste diferem da realidade brasileira. Em segundo lugar, grande parte dos trabalhos limita-se à detecção e classificação dos defeitos, sem abordar a mensuração da área danificada. Por fim, a ocorrência de falsos positivos em regiões fora da pista, como calçadas, acostamentos, vegetação e sombras, é um problema recorrente que poucos trabalhos tratam de forma explícita.

Este trabalho propõe um sistema baseado em YOLOv11 para detectar e classificar defeitos em pavimentos e estimar, inicialmente, a área danificada. As principais contribuições incluem: (i) um *pipeline* com pré-processamento para realce de contraste e bordas; (ii) uma cascata de modelos de detecção; (iii) detecção constrangida à região efetiva da pista; (iv) a construção de um *dataset* brasileiro a partir de imagens de pavimentações nacionais com anotações assistidas por IA; e (v) a análise das limitações de *bounding boxes* para mensuração de área, fundamentando a evolução futura para segmentação de instância.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Defeitos em Pavimentos Asfálticos

Os defeitos em pavimentos flexíveis são classificados pela norma DNIT 005 (DNIT, 2003). Este trabalho, adota uma simplificação em quatro categorias principais, compatível com os *datasets* internacionais, conforme ilustrado na Figura 1. D00 (Fissuras) são caracterizadas por rachaduras longitudinais e transversais, geralmente associadas à fadiga do material e à variação térmica; D10 (Buracos) são definidos como cavidades na superfície do pavimento resultantes da evolução de fissuras sob a ação combinada de água e tráfego; D20 (Remendos) correspondem a áreas previamente reparadas, relacionadas a manutenções anteriores; e D30 (Trinca em malha), marcada por fissuras conectadas, típico de fadiga estrutural avançada. A subclassificação por severidade prevista na norma foi omitida, concentrando-se o esforço na detecção entre categorias.

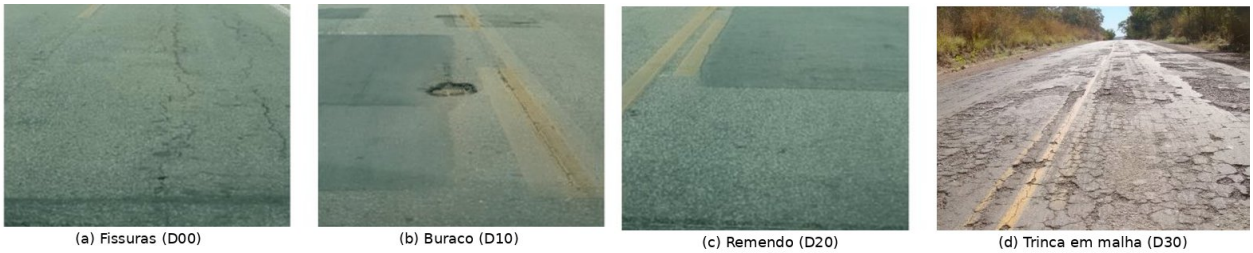


Figura 1. Categorias de defeitos. Fonte: adaptado de Oliveira et al. (2022).

2.2 Detecção de Objetos com *Deep Learning*

A família YOLO, introduzida por Redmon *et al*. (2016), destaca-se pela velocidade de inferência em tempo real. Desde a versão original, o YOLO passou por diversas evoluções arquiteturais: YOLOv3 (Redmon e Farhadi, 2018) introduziu detecção multi-escala; YOLOv5 (Jocher et al., 2021) popularizou o *framework* Ultralytics com melhorias em *data augmentation* e treinamento; YOLOv8 (Ultralytics, 2023) reformulou a arquitetura *backbone* e a predição; e o YOLOv11 (Ultralytics, 2024), versão mais recente utilizada neste trabalho, introduziu melhorias na eficiência computacional e na acurácia, oferecendo suporte nativo tanto para detecção por *bounding box* quanto para segmentação de instância nas variantes de tamanho: *nano*, *small*, *medium*, *large* e *xlarge*.

A detecção de objetos por *bounding box* localiza o defeito dentro de um retângulo alinhado aos eixos da imagem. Isso é adequado para localização e classificação, mas limita a mensuração de área, pois o retângulo inclui regiões sem dano. Por exemplo, em uma fissura diagonal de 1 cm de largura orientada a 45°, a razão entre a área efetiva do defeito e a área do *bounding box* pode ser inferior a 5%, resultando em super estimação da área danificada. A segmentação de instância, por outro lado, produz máscaras que delineiam o contorno exato do defeito, permitindo cálculos de área muito mais precisos. Em contrapartida, exige anotações mais custosas com máscaras ou polígonos, enquanto *bounding boxes* são mais rápidas de rotular. O compromisso entre precisão na mensuração e viabilidade de anotação é, portanto, central para este trabalho.

3 METODOLOGIA

3.1 Visão Geral do Sistema

O sistema proposto opera como um *pipeline* sequencial composto por quatro etapas principais: (1) busca e preparação de *datasets*; (2) pré-processamento da imagem para realce de contraste e bordas; (3) definição da arquitetura com treinamento de modelos e utilização de cascata de modelos; e (4) consolidação dos resultados com classificação e estimativa de área. Os experimentos foram executados em um desktop com processador Intel Core i9-14900, 32 GB de memória RAM DDR4 e GPU NVIDIA RTX 2000 Ada Generation, garantindo capacidade computacional adequada para o treinamento.

3.2 *Datasets*

Foram utilizados dois conjuntos de dados complementares. O *dataset* internacional de detecção de danos em rodovias (Arya et al., 2022), compreende 47.420 imagens de seis países com anotações no formato YOLO, reduzidas as quatro categorias de defeitos (D00, D10, D20, D30). O *dataset* brasileiro foi construído a partir de 2.235 imagens de rodovias brasileiras disponibilizadas pelo DNIT (Passos et al., 2020), originalmente sem anotações de detecção. Para viabilizar seu uso, os modelos treinados no dataset internacional foram aplicados às imagens via detecção constrangida (Seção 3.4), gerando anotações automáticas em formato YOLO atualmente em processo de revisão e validação manual. A Tabela 1 sintetiza as características dos *datasets* utilizados.

Tabela 1. Comparação dos *datasets* utilizados.

Característica	*Dataset* Internacional	*Dataset* DNIT (Brasil)
Nº de imagens	47.420	2.235
Classes	Reduzidas a D00, D10, D20, D30	D00, D10, D20, D30
Tipo de anotação	Já existente	Assistida por IA
Origem geográfica	Japão, Índia, Rep. Tcheca, outros	Rodovias brasileiras (DNIT)
Uso neste trabalho	Treinamento base dos modelos	Validação e retreinamento futuro

3.3 Pré-processamento de Imagens

O pré-processamento visa realçar defeitos de baixo contraste em relação ao pavimento circundante, especialmente fissuras finas e danos em estágio inicial. Foram implementadas e avaliadas comparativamente diversas técnicas: equalização adaptativa de contraste por CLAHE (Zuiderveld, 1994); correção gamma para ajuste não-linear de brilho; *unsharp mask* para realce de bordas por subtração de versão borrada; filtros Sobel e Laplaciano para detecção de gradientes direcionais e de segunda derivada; e morfologia direcional para realce de fissuras finas. A seleção da técnica ótima foi conduzida por meio de testes em lote, aplicando cada técnica isoladamente e em combinações a um subconjunto representativo de imagens. A comparação visual e quantitativa dos resultados de detecção indicou que uma combinação otimizada (denominada "combined2") composta por CLAHE seguido de *unsharp mask* e realce de bordas com pesos calibrados, ofereceu o melhor equilíbrio entre realce de defeitos e preservação de textura do pavimento.

3.4 Arquitetura de Detecção

3.4.1 Modelo base

O modelo de detecção de defeitos (pavelab-v1) foi construído sobre a arquitetura YOLOv11 na variante small (YOLOv11s), inicializado com pesos pré-treinados e refinado no dataset internacional por 800 épocas. O modelo de segmentação de via (pavelab-line-detection-v1) utiliza a variante YOLOv11s-seg. A Tabela 2 apresenta os principais hiperparâmetros de treinamento dos modelos desenvolvidos.

Tabela 2. Hiperparâmetros de treinamento dos modelos.

Hiperparâmetro	Detecção de Defeitos	Segmentação de Via
Arquitetura	YOLOv11s	YOLOv11s-seg
Imagem de entrada	640 × 640 px	640 × 640 px
Épocas treinadas	800	391 (convergência)
Batch size	16	32
Otimizador	AdamW (auto)	AdamW (auto)
Técnicas de aumento de dados	Mosaic, flip, scale, erasing, HSV, randaugment	Mosaic, flip, scale, erasing, HSV, randaugment

3.4.2 Cascata de modelos

A análise dos resultados de detecção revelou que nenhum modelo isolado alcança cobertura satisfatória em todas as quatro categorias simultaneamente. A classe D20 (remendos), em particular, apresentou sub-detecção consistente, possivelmente devido à menor representatividade nos dados de treinamento e à similaridade visual com o pavimento circundante. Para mitigar essa limitação, implementou-se uma estratégia de cascata com três modelos, em que o modelo próprio treinado neste trabalho (pavelab-v1) atua como modelo

principal, realizando a varredura inicial da imagem. Como apoio, utilizou-se um modelo pré-treinado disponibilizado em repositório público, com boa capacidade de generalização e se mostrou complementar para reduzir falhas pontuais (DAYEEEN, 2025). Caso o pavelab-v1 não detecte defeitos ou não identifique remendos (D20), o modelo auxiliar é acionado; por fim, um terceiro modelo complementar foi incorporado, também disponibilizado publicamente, com o objetivo de fornecer uma última checagem quando persistem incertezas na detecção (TANG, 2025). Uma regra de dupla validação garante que, mesmo quando o modelo principal detecta outras categorias, o modelo secundário é sempre consultado especificamente para D20.

3.4.3 Detecção constrangida à via

Um problema recorrente em sistemas de detecção de defeitos em pavimentos é a geração de falsos positivos em regiões fora da pista, como calçadas, acostamentos, faixas de tinta, vegetação, sombras e objetos adjacentes à via. Para conter esse problema, desenvolveu-se um módulo de detecção constrangida. O modelo de segmentação de via (pavelab-line-detection-v1) gera uma máscara binária da pista. As detecções de defeitos são então filtradas: predições cujo centro geométrico cai fora da máscara são descartadas, e *bounding boxes* que ultrapassam os limites da via são recortados pela máscara. Essa abordagem reduz significativamente os falsos positivos sem descartar detecções legítimas.

3.5 Mensuração de Área e suas Limitações

A mensuração inicial da área danificada foi realizada a partir das dimensões dos *bounding boxes* preditos, calculando-se a área em pixels como o produto da largura pela altura do retângulo. Embora simples, essa abordagem tende a superestimar defeitos de geometria irregular. Como alternativa, avaliou-se uma abordagem híbrida, na qual a segmentação de instância foi utilizada para a classe de buracos (D10). Para isso, foram aproveitadas máscaras de segmentação previamente disponibilizadas para o dataset de Passos et al. (2020) em um projeto no Roboflow Universe (UNIVERSITETET, 2024), o que permitiu obter contornos mais precisos nessa classe. Para as demais categorias, manteve-se a mensuração via *bounding boxes*. Contudo, as classes D00 e D30, as classes de geometria mais irregular, permaneceram com mensuração imprecisa. Essa constatação reforça a necessidade de migração completa para segmentação de instância em todas as classes, o que constitui a principal direção de trabalho futuro deste projeto.

4 RESULTADOS E DISCUSSÃO

4.1 Desempenho do Modelo de Detecção de Defeitos

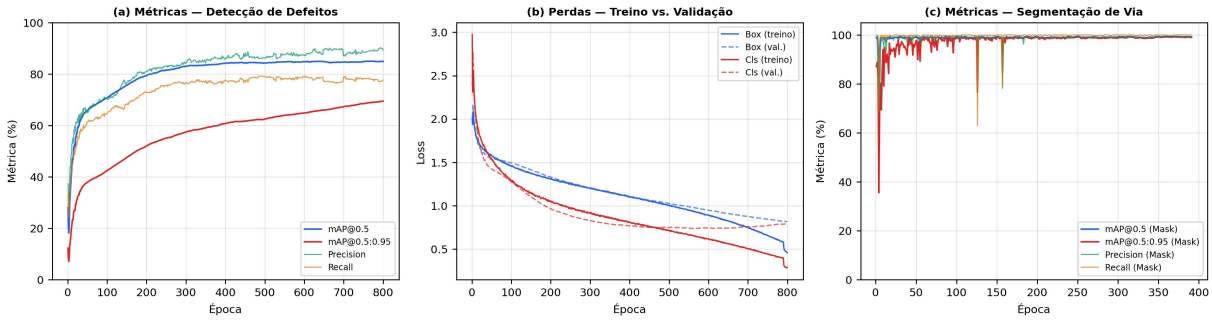


Figura 2. Curvas de treinamento: (a) métricas de detecção de defeitos; (b) perdas de treino vs. validação; (c) métricas de segmentação de via.

O modelo pavelab-v1 foi treinado por 800 épocas no *dataset* internacional, totalizando 187 horas de treinamento em GPU. A Tabela 3 apresenta as métricas consolidadas ao final do treinamento e no ponto de melhor desempenho. O modelo alcançou mAP@0.5 de 85,0% no melhor ponto de validação (época 772), com *Precision* de 89,1% e *Recall* de 77,9%. A *Precision* elevada indica uma baixa taxa de falsos positivos; o Recall

mais moderado sugere que aproximadamente 22% dos defeitos presentes não são capturados pelo modelo isolado, observação que motivou a implementação da cascata de modelos descrita na Seção 3.4.2. A Figura 2(a) apresenta a evolução das métricas ao longo das 800 épocas de treinamento.

Tabela 3. Métricas de desempenho do modelo de detecção de defeitos.

Ponto de Avaliação	Precision	Recall	mAP@0.5	mAP@0.5:0.95
Época 800 (final)	89,3%	77,6%	84,9%	69,4%
Época 772 (melhor mAP@0.5)	89,1%	77,9%	85,0%	69,0%

A análise das curvas de perda na Figura 2(b) revela um intervalo crescente entre as perdas de treinamento e validação, especialmente na perda de classificação (classification loss: 0,285 no treino versus 0,792 na validação ao final das 800 épocas), indicando leve *overfitting* nas épocas finais.

4.2 Desempenho do Modelo de Segmentação de Via

O modelo pavelab-line-detection-v1 convergiu rapidamente em 391 épocas (~23 horas). A Tabela 4 apresenta as métricas finais. Com mAP@0.5 superior a 99% e Recall de 100,0%, o modelo identifica a região de pavimento com alta confiabilidade. Esse resultado é fundamental para a viabilidade da detecção constrangida: a máscara gerada é suficientemente precisa para que a filtragem espacial não introduza perda significativa de detecções legítimas.

Tabela 4. Métricas de desempenho do modelo de segmentação de via.

Avaliação	Precision	Recall	mAP@0.5	mAP@0.5:0.95
Bounding box	99,1%	100,0%	99,2%	98,8%
Máscara de segmentação	99,1%	100,0%	99,2%	99,0%

4.3 Efeito da Detecção Constrangida

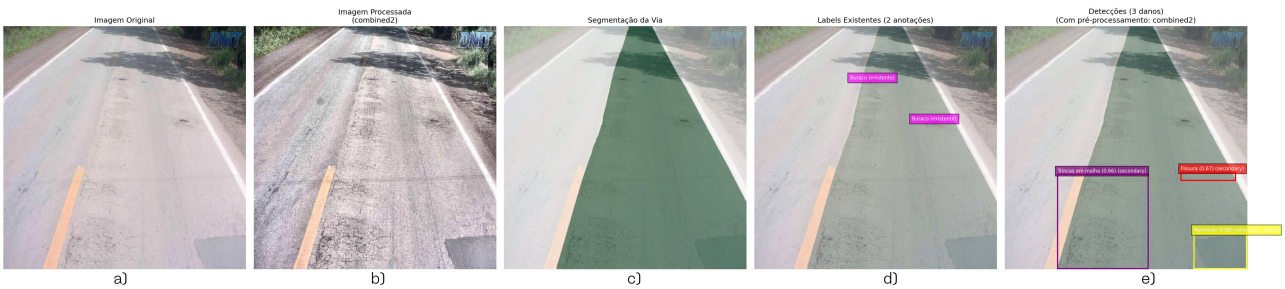


Figura 3. Exemplo do pipeline aplicado a uma imagem do dataset DNIT: (a) imagem original; (b) pré-processamento combined2; (c) segmentação da via; (d) anotações existentes; (e) detecções do sistema com classes e confiança.

A detecção constrangida à via demonstrou ganho qualitativo na redução de falsos positivos. Observou-se que, sem a restrição espacial, os modelos frequentemente produziam predições em regiões como calçadas, acostamentos com textura irregular, sombras de árvores e objetos à margem da estrada que mimetizam padrões de defeitos. Com a aplicação da máscara de via, essas detecções espúrias foram sistematicamente eliminadas, mantendo-se as detecções legítimas na área de pavimento. A análise qualitativa de amostras dos *datasets* utilizados indica que a detecção constrangida é particularmente eficaz em cenários de rodovias urbanas, onde há maior diversidade de elementos visuais na pista. A Figura 3 ilustra um exemplo representativo do *pipeline* aplicado a uma imagem do *dataset* DNIT, evidenciando, da esquerda para a direita: a imagem original, o

resultado do pré-processamento (combined2), a máscara de segmentação da via, as anotações existentes (*labels*) e as detecções finais do sistema com as respectivas classes e confiança.

4.4 Efeito da Cascata de Modelos

A cascata de modelos demonstrou contribuição relevante para a cobertura de detecção, especialmente para a classe D20 (remendos). Em diversas imagens, o modelo principal não identificou remendos que foram corretamente detectados pelo modelo secundário. A regra de dupla validação para D20 mostrou-se essencial, dado que os remendos apresentam características visuais mais sutis como diferenças de textura e tonalidade em relação ao pavimento original, que desafiam modelos treinados predominantemente em fissuras e buracos. A parte negativa dessa abordagem é o aumento proporcional no tempo de processamento, que é multiplicado pelo número de modelos na cascata.

4.5 Limitações do *Bounding Box* para Mensuração de Área

A análise revelou limitação estrutural do *bounding box* para mensuração de área em defeitos de geometria irregular. Uma fissura diagonal de 200 px de comprimento e 5 px de largura orientada a 45° produz um *bounding box* de 141 × 141 px (≈19.881 px²), enquanto a área real do defeito é de apenas ≈1.000 px², uma super estimação de quase 20 vezes. Esse fenômeno afeta mais severamente as classes D00 e D30, cujas geometrias são lineares ou ramificadas; para buracos (D10), de formas mais compactas, a discrepância é menor. A constatação de que a mensuração por *bounding box* é inadequada para avaliação quantitativa de área danificada constitui um resultado importante deste trabalho e fundamenta a decisão de evoluir para segmentação completa de instância.

4.6 Anotação Assistida do *Dataset* DNIT

O sistema de detecção constrangida foi aplicado integralmente às 2.235 imagens do *dataset* Passos *et al.* (2020), gerando anotações automáticas em formato YOLO para as quatro categorias de defeitos. O processo combinou os três modelos da cascata com pré-processamento combined2 e filtragem por máscara de via. As anotações geradas constituem a base para a construção do primeiro *dataset* brasileiro robusto para detecção de defeitos em pavimentos, encontrando-se atualmente em fase de revisão, complementação e validação manual. A disponibilidade de um *dataset* nacional é relevante para a comunidade de pesquisa, uma vez que as condições de pavimentação, clima, tipo de asfalto e padrões de desgaste das rodovias brasileiras diferem substancialmente das condições representadas em *datasets* internacionais.

5 CONCLUSÃO E TRABALHOS FUTUROS

Este trabalho apresentou um sistema de visão computacional baseado no YOLOv11 para detecção, classificação e mensuração inicial de defeitos em pavimentos asfálticos, aplicado a rodovias brasileiras. O sistema integra pré-processamento otimizado para realce de defeitos, uma cascata de modelos para ampliação da cobertura de detecção e um módulo de detecção constrangida à região efetiva da pista.

Os resultados demonstram que o modelo de detecção alcançou mAP@0.5 de 85,0% nas quatro categorias de defeitos, com Precision de 89,1%, enquanto o modelo de segmentação de via atingiu desempenho superior a 99% em todas as métricas, validando a confiabilidade da restrição espacial. A cascata de modelos complementou a detecção, especialmente para remendos, e a detecção constrangida reduziu falsos positivos em regiões fora da pista. Identificou-se que *bounding boxes* são inerentemente limitados para a mensuração precisa de área em defeitos de geometria irregular, como fissuras diagonais, onde a superestimação pode ser de uma a duas ordens de grandeza. Essa constatação motiva a evolução para segmentação de instância.

Como trabalhos futuros, destacam-se: (i) migração completa para segmentação de instância em todas as categorias de defeitos, possibilitando mensuração precisa de área; (ii) refinamento e validação manual das anotações do *dataset* DNIT; (iii) consolidação de métricas quantitativas com avaliação por classe no *dataset*

brasileiro; (iv) expansão do sistema de classificação para incluir níveis de severidade conforme a norma DNIT; e (v) avaliação da viabilidade de processamento em tempo real para uso embarcado em veículos de inspeção.

REFERÊNCIAS BIBLIOGRÁFICAS

ARYA, Deeksha et al. RDD2022: A multi-national image dataset for automatic road damage detection. Geoscience Data Journal, v. 11, n. 4, p. 846-862, 2024. DOI: 10.1002/gdj3.260.

CNT. Conheça os 13 principais defeitos do pavimento das rodovias. Confederação Nacional do Transporte, 12 fev. 2019. Disponível em: https://www.cnt.org.br/agencia-cnt/conheca-principais-defeitos-pavimento.

DAYEEEN. Road Damage Detection (V1): road-damage-detection-yolov11. Repositório no GitHub, 2025. Disponível em: https://github.com/dayeeen/road-damage-detection-yolov11. Acesso em: 2 ago. 2025.

DNIT. Defeitos nos pavimentos flexíveis e semi-rígidos — Terminologia. Norma DNIT 005/2003 – TER. Rio de Janeiro: DNIT, 2003.

JOCHER, *G*. et al. Ultralytics YOLOv5. GitHub, 2021. Disponível em: https://github.com/ultralytics/yolov5.

PASSOS, *Bianka* T. et al. Cracks and Potholes in Road Images. Mendeley Data, v. 4, 2020. DOI: 10.17632/t576ydh9v8.4. Disponível em: https://data.mendeley.com/datasets/t576ydh9v8/4.

PHAM, Vung; NGUYEN, Du; DONAN, Christopher. Road damage detection and classification with YOLOv7. In: IEEE INTERNATIONAL CONFERENCE ON BIG DATA, 10., 2022, Osaka. IEEE, 2022. p. 6416-6423.

REDMON, *Joseph* et al. You only look once: Unified, real-time object detection. In: Proceedings of the IEEE conference on computer vision and pattern recognition. 2016. p. 779-788.

REDMON, *J*.; FARHADI, *A*. YOLOv3: an Incremental Improvement. arXiv preprint arXiv:1804.02767, 2018. Disponível em: https://arxiv.org/abs/1804.02767.

REN, *M*. et al. YOLOv5s-M: A deep learning network model for road pavement damage detection from urban street-view imagery. International Journal of Applied Earth Observation and Geoinformation, v. 120, 103335, 2023.

SETCEMG. Qual a vantagem do transporte rodoviário no Brasil? Belo Horizonte: SETCEMG, 21 jan. 2025. Disponível em: https://setcemg.org.br/qual-a-vantagem-do-transporte-rodoviario-no-brasil-2/.

SOUZA, Cornélio el al. Comparação de arquiteturas de redes neurais convolucionais na detecção automática de defeitos em imagens de pavimentos capturadas com smartphone. In: ENCONTRO NACIONAL DE CONSERVAÇÃO RODOVIÁRIA (ENACOR), 23., 2021, Brasília, DF;

TANG, K. RoadDamageDetection. Repositório em GitHub, 2026. Disponível em: https://github.com/ks-tang/RoadDamageDetection.

ULTRALYTICS. YOLOv8 Documentation. Ultralytics, 2023. Disponível em: https://docs.ultralytics.com.

ULTRALYTICS. YOLO11 Documentation. Ultralytics, 2024. Disponível em: https://docs.ultralytics.com/models/yolo11/

UNIVERSITETET I AGDER. road_crack_segmentation (v1). Roboflow Universe, 2024. Disponível em: https://universe.roboflow.com/universitetet-i-agder/road_crack_segmentation-8kvrh/dataset/1.

ZENG, Jiayi; ZHONG, Han. YOLOv8-PD: an improved road damage detection algorithm based on YOLOv8n model. Scientific reports, v. 14, n. 1, p.12052, 2024. DOI: 10.1038/s41598-024-62933-z.

ZUIDERVELD, K. Contrast limited adaptive histogram equalization. In: HECKBERT, Paul S. (ed.). Graphics Gems IV. San Diego: Academic Press, 1994. p. 474–485.

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/COBRAMSEG2026.2/13

Estatística Aplicada à Integração de Monitoramento Automatizado e Inspeção Geotécnica em Barragens

João Antônio Teixeira Soares
Engenheiro Geotécnico, Tellus Company Engenharia, Belo Horizonte, Brasil, jats.joao@gmail.com

Germano Silva de Araújo
Diretor, Tellus Company Engenharia, Belo Horizonte, Brasil, garaujo@telluscompany.com.br

Gerson da Rocha Izidoro
Gerente de Geotecnia de Barragens, CBMM, Araxpa, Brasil, gerson.izidoro@cbmm.com

Marcos Antônio Lemos Júnior
Gerente Sênior de Meio Ambiente e Barragens, CBMM, Araxá, Brasil, marcos.lemos@cbmm.com

Jonatas de Souza Ferreira
Analista de Geoprocessamento, CBMM, Araxá, Brasil, jonatas.ferreira@cbmm.com

RESUMO: O monitoramento de deslocamentos superficiais é um elemento essencial na gestão da segurança de barragens e de grandes estruturas geotécnicas, pois permite a identificação precoce de comportamentos atípicos e a avaliação contínua da performance da estrutura. Este trabalho apresenta uma metodologia estatística aplicada à análise de deslocamentos horizontais e verticais medidos por marcos superficiais lidos por estação total robótica, fundamentada na avaliação do comportamento histórico da instrumentação. A metodologia foi aplicada a um conjunto de dados coletados entre janeiro de 2022 e março de 2025, abrangendo deslocamentos nas direções norte, leste e vertical (recalques). A abordagem adotada baseia-se na utilização de estatísticas descritivas e robustas, com destaque para o desvio padrão em diferentes escalas temporais (diária, mensal e anual) e para a mediana, analisada em janelas móveis de 15 dias. Adicionalmente, foram desenvolvidos modelos de regressão linear para investigar a relação entre a variabilidade das leituras e a distância dos instrumentos em relação à estação total de referência, bem como aplicado o teste de normalidade de Anderson-Darling para avaliação da distribuição dos dados. Com base nos resultados obtidos, foram definidos níveis de controle estatísticos associados a múltiplos da mediana, sendo adotado o critério de cinco vezes o desvio padrão global como limite de referência para a identificação de deslocamentos atípicos. A análise dos resultados demonstrou que a maior parte das leituras se mantém dentro do comportamento histórico esperado, não sendo observadas tendências progressivas ou aceleradas que indiquem condições de instabilidade. Conclui-se que a metodologia proposta constitui uma ferramenta objetiva, consistente e tecnicamente fundamentada para subsidiar a interpretação de dados de monitoramento geotécnico, devendo ser aplicada de forma integrada a inspeções de campo e análises multidisciplinares no contexto da segurança de barragens.

PALAVRAS-CHAVE: monitoramento geotécnico; marcos superficiais; estação total robótica; estatística aplicada; segurança de barragens.

ABSTRACT: Surface displacement monitoring is an essential component of dam safety management and of large geotechnical structures, as it enables the early identification of atypical behavior and the continuous assessment of structural performance. This paper presents a statistical methodology applied to the analysis of horizontal and vertical displacements measured by surface benchmarks surveyed using a robotic total station, based on the evaluation of the historical behavior of the instrumentation. The methodology was applied to a dataset collected between January 2022 and March 2025, comprising displacements in the north, east, and vertical directions (settlements). The adopted approach relies on the use of descriptive and robust statistics, with emphasis on the standard deviation at different temporal scales (daily, monthly, and annual)

and on the median, analyzed using 15-day moving windows. In addition, linear regression models were developed to investigate the relationship between measurement variability and the distance of the instruments from the reference total station, and the Anderson–Darling normality test was applied to assess the data distribution. Based on the obtained results, statistical control levels associated with multiples of the median were defined, adopting the criterion of five times the median as a reference threshold for the identification of atypical displacements. The results demonstrate that most measurements remain within the expected historical behavior, with no evidence of progressive or accelerating trends indicative of instability conditions. It is concluded that the proposed methodology constitutes an objective, consistent, and technically sound tool to support the interpretation of geotechnical monitoring data and should be applied in an integrated manner with field inspections and multidisciplinary analyses within the context of dam safety.

KEYWORDS: geotechnical monitoring, marks, robotic total stations, statistical applied, safety of dams

1. INTRODUÇÃO

O acompanhamento sistemático do comportamento deformacional de estruturas geotécnicas é fundamental para a identificação precoce de anomalias e para a mitigação de riscos associados à sua operação. Em barragens, os deslocamentos superficiais fornecem informações relevantes sobre possíveis processos de instabilidade, recalques ou translações do maciço. Entretanto, a interpretação isolada de leituras individuais pode conduzir a conclusões equivocadas, uma vez que medições estão sujeitas a ruídos instrumentais, efeitos ambientais e eventos operacionais. Nesse contexto, abordagens estatísticas baseadas no histórico de monitoramento permitem caracterizar o comportamento típico da estrutura e definir critérios objetivos para a identificação de desvios significativos. O presente trabalho tem como objetivo apresentar e discutir uma metodologia estatística para definição de níveis de controle integrados à rotina de inspeção visual da estrutura.

Segundo Clarckson (2020), os processos de monitoramento automatizado, ou em tempo real, aprimoram as análises técnicas de barragens, principalmente em função da redução do tempo de coleta de dados e do ganho de agilidade na avaliação técnica. Neste sentido, os recursos da estatística descritiva se mostram como ferramenta robusta para atestar a qualidade da base de dados e permitir o estabelecimento de níveis de controles baseado no hitórico de dados. Importante reforçar que o recurso estátistico não sobrepõe o julgamento de engenharia, tampouco exime a necessidade de avaliar toda a instrumentação sob a perspectiva da análise geotécnica.

Engenheiros geotécnicos trabalham constantemente com incertezas. De modo geral, esses profissionais não podem controlar os materiais com os quais trabalham, uma vez que a natureza os formou por meio de processos aleatórios, resultando em condições não uniformes e altamente variáveis (Marr, 2013). Azeez (2025) realiza uma comparação de dados de inspeção visual aos resultados apresentados pelo monitoramento de deslocamento superficial via InSAR em barragem, Kang (2017) propôs metodologia para aprimorar a confiabilidade das Estações Totais baseada em calibração estatística. Este cenário corrobora para a importância de comparar métodos, retroanalisar a base de dados e estabelecer uma rotina operacional baseada na performance das estruturas.

O processo de inspeção visual tem um caráter rotineiro em que se deve atentar para o risco em que a equipe envolvida no processo se acostume com o cenário visual da estrutura e acabe não percebendo pequenas mudanças ou anomalias em estágio inicial de materialização. Portanto, o controle operacional estatístico proposto no estudo propõe a rápida identificação dos marcos superficias que apresentaram mudanças significativas no período entre as inspeções realizadas.

2. METODOLOGIA

A base de dados utilizada neste estudo refere-se ao monitoramento de uma barragem de aterro compactado, alteada a jusante, com aproximadamente 90 m de altura, cerca de 1.000 m de extensão de crista e uma área de aproximdamente 160.000 m² de área inspecionada. O sistema de instrumentação é composto por 69 marcos superficiais distribuídos ao longo da barragem, com espaçamento médio de aproximadamente 50 m, permitindo a avaliação contínua do comportamento deformacional da estrutura. As leituras dos marcos

são realizadas por meio de uma Estação Total Robótica, operando em regime automatizado, instalada na ombreira esquerda da estrutura, com frequência de aquisição de dados a cada 30 minutos e utiliza três marcos de referência estáveis para controle geométrico. Adicionalmente, o programa de monitoramento contempla inspeções visuais sistemáticas na barragem, realizadas em periodicidade quinzenal (a cada 14 dias), cujas observações são utilizadas de forma integrada às análises estatísticas dos dados instrumentais, reforçando a interpretação do comportamento estrutural e a confiabilidade dos resultados obtidos.

Para o controle dos deslocamentos superficiais é proposta uma metodologia de controle com base no histórico registrado para cada instrumento e o deslocamento acumulado diário registrado. As análises foram desenvolvidas com base nos dados disponibilizados entre os dias 01/01/2022 e 09/03/2025.

Os valores de referência apresentados têm como objetivo caracterizar o comportamento típico da estrutura com base no histórico de monitoramento. Para essa finalidade, são adotados dois indicadores estatísticos complementares: (i) o desvio-padrão das medições, calculado em bases diária, mensal e anual, utilizado para avaliar a dispersão dos dados; e (ii) a variação da mediana em intervalos de 15 dias, empregada para identificar possíveis alterações na tendência central das observações ao longo do tempo. Adicionalmente, é ajustado um modelo de regressão linear para avaliar a relação entre o desvio-padrão e a distância. Posteriormente, a distribuição dos dados é submetida ao teste de normalidade de Anderson-Darling, considerando nível de significância de 5%, por meio do software Minitab Statistical Software 22. Com base nesses procedimentos estatísticos, são estabelecidos critérios para a distinção entre registros compatíveis com o comportamento esperado da estrutura e registros potencialmente atípicos, os quais demandam análise específica.

No monitoramento, avaliam-se os deslocamentos da estrutura em dois sentidos: no eixo vertical e no eixo horizontal, investigando eventuais translações na estrutura. Os tópicos a seguir apresentam as análises realizadas, bem como os níveis estatísticos para o deslocamento vertical.

3. ESTATÍSTICA E ANÁLISE DOS DESLOCAMENTOS VERTICAIS

3.2 Desvio Padrão e Comportamento Histórico

Para a análise dos deslocamentos verticais, foram utilizados os registros de leitura obtidos entre os dias 01/01/2022 e 09/03/2025. Avaliou-se o desvio padrão diário, mensal e anual para todos os instrumentos.

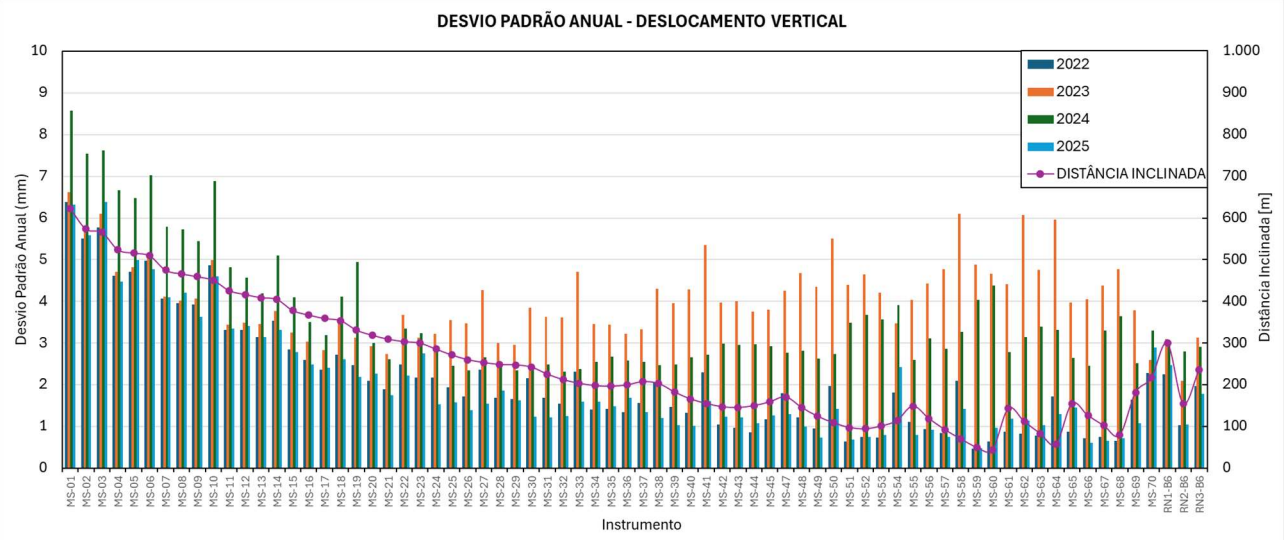


Figura 1 - Desvio padrão em função da distância.

Observa-se um desvio padrão variando entre, aproximadamente 8,0 mm e 3,0 mm em orden decrescente em relação à distância entre o marco superficial e a ETR. É esperada a redução do desvio padrão

em função da redução da distância, baseado no funcionmento dos equipamentos de geomensura, que possuem margem de erro magioritariamente atreladas a distância do monitoramento e condições climáticas.

A Figura 1 também demonstra que o ano de 2023 apresenta o maior desvio padrão. Este comportamento foi observado em função da realização de uma obra de engenharia próximo aos marcos de referência da ETR. Importante reforçar que o aumento no desvio padrão não afetou qualidade do monitoramento, uma vez que este é composto por outras tecnologias e rotinas de avaliação geotécnica que atestaram a segurança da estrutura e a qualidade do monitoramento durante o período.

Considerando a média do desvio padrão durante todo o período avaliado e a distância de cada instrumento em relação à ETR, foi realizada uma análise estatística de regressão utilizando o programa Minitab Statistical Software 22, conforme apresentado na Figura 2.

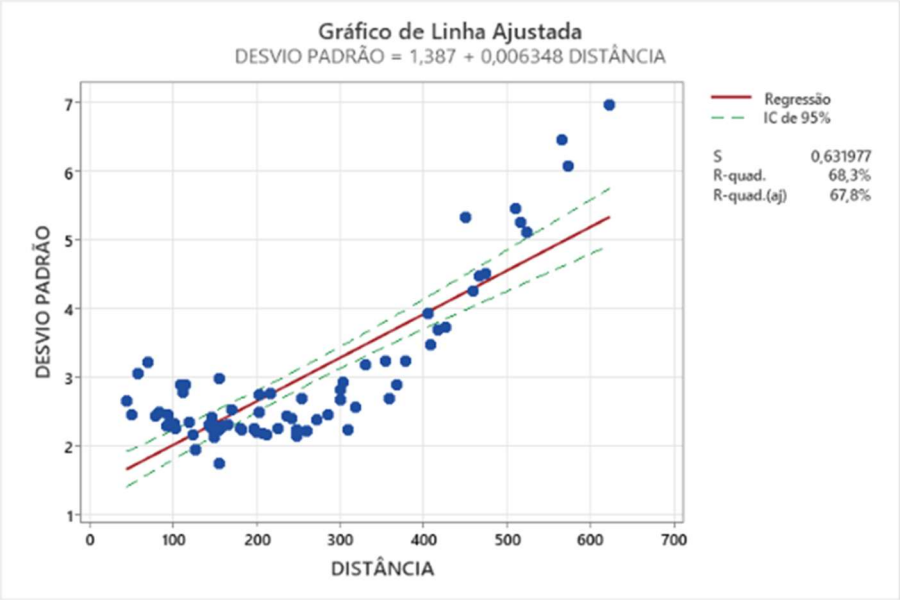


Figura 2 - Regressão linear - Desvio Padrão e Distância.

É observado um fator R^2 de 68,3% e um S de 0,632 mm para o deslocamento vertical. Do ponto de vista estatístico, o resultado indica um ajuste ineficiente da regressão linear, porém, baseado no julgamento de engenharia, decidiu-se manter o modelo e avaliar o seu comportamento a partir da perspectiva geotécnica. É observado que existem dois comportamentos distintos na relação entre desvio padrão e distância. Esta mudança de comportamento ocorre a partir dos 300 metros de distância entre os marcos supericiais e a ETR. A Figura 3 ilustra um mapa de calor que relaciona o gradiente de cor em função da distância inclinada entre o marco superficial e a ETR. É possível observar que a zona central da barragem demonstrada pela região em amarelo claro e verde claro são as que apresentam um desvio padrão entre 2,0 mm e 3,0 mm, corroborando com o gráfico apresentado na Figura 2.

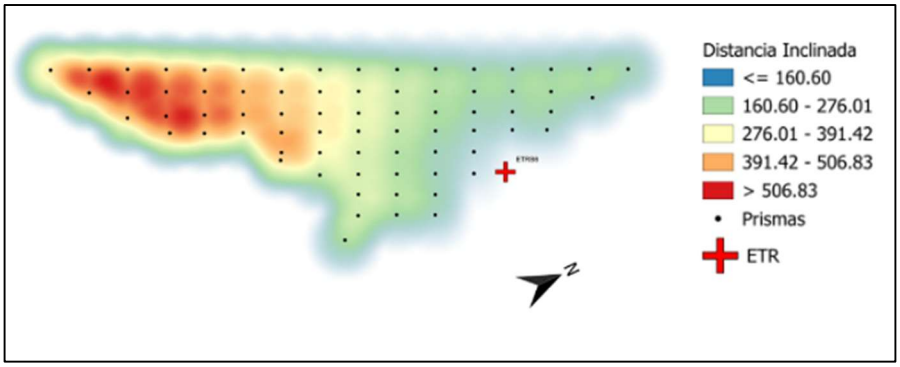


Figura 3 - Mapa de calor em relação à distânca inclinada.

Quanto aos marcos superficiais com distancia superior a 300 m, estão concentrados na região da ombreira direita da estrutura, local em que não são esperados recalques significativos.

3.2 Teste de Normalidade e Desvio Padrão Global

Foi realizado o teste de normalidade Anderson-Darling utilizando o Minitab Statistical Software 22. Esse teste é uma análise estatística que verifica se o conjunto de dados segue uma distribuição normal. Os resultados obtidos para a direção vertical estão apresentados na Figura 4.

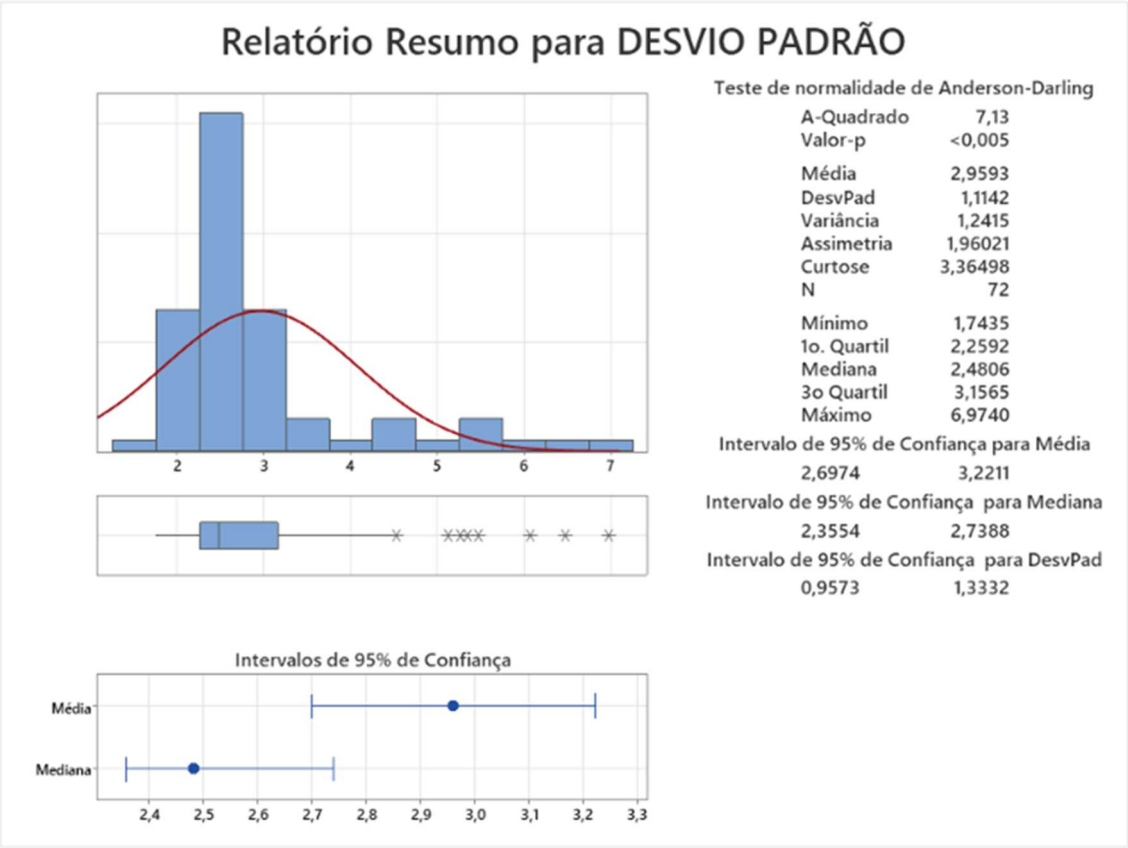


Figura 4 - Teste de Normalidade - Anderson Darling.

O teste de Anderson-Darling apresentou um valor-p < 0,005 para a direção vertical, indicando que poucos dados se encontram fora do padrão de comportamento dos demais. Além disso, observa-se que a mediana apresenta um intervalo de confiança consistente. Portanto, para a definição dos níveis de controle dos marcos superficiais, optou-se por utilizar a mediana como referência. A mediana representa um valor de 2,48 mm que será arredondado para 2,50 mm para utilização no estabelecimento do nível de controle, doravante denominado como Desvio Padrão Global (DPG).

O valor de mediana encontrado pode ser observado nos instrumentos com distância de até aproximadamente 300,0 m conforme a Figura 2, que é justamente a zona mais susceptível a recalques, por ser as regiões de maiores alturas de aterro da estrutura.

A identificação dos outliers foi realizada por meio da análise gráfica dos boxplots e do critério da amplitude interquartil (IQR). Considerando os quartis observados (Q1 = 2,26 mm e Q3 = 3,16 mm), o limite superior para identificação de valores atípicos foi estimado em aproximadamente 4,5 mm. Verificou-se que tais registros correspondem predominantemente a marcos superficiais localizados em regiões de ombreira, onde não são esperados recalques significativos em função das menores alturas de aterro. Assim, por não representarem o comportamento predominante da população de dados utilizada para a definição dos níveis de

controle, sua exclusão foi considerada adequada e consistente com o julgamento de engenharia adotado no estudo.

4. NÍVEL DE CONTROLE ESTATÍSTICO

Segundo Clarckson (2021), a engenharia geotécnica está inserida em um contexto multidisciplinar no qual o monitoramento de barragens é centralizado em uma rotina integrada, sendo o principal desafio identificar e utilizar a capacidade dos sistemas de monitoramento para compreender o desempenho e o comportamento complexos das barragens, com foco na capacidade de previsão de seu comportamento em relação aos seus modos de falha.

4.2 Fundamento do Nível de Controle

O objetivo principal do nível de controle proposto no estudo é de permitir uma inspeção baseada em dados de monitoramento, no que se refere à avaliação de eventuais recalques na estrutura. Será estabelecido um múltiplo do desvio padrão global encontrado no Item 3 como nível de controle a ser verificado anteriormente à inspeção. O marco superficial que indicar o atingimento de nível de controle deverá ser inspecionado com maior rigor, pois entende-se que há uma mudança de comportamento em sua região e esta está propensa ao surgimento de anomalias, tais como: trincas, abatimentos, empoçamentos d'água, etc.

É importante reforçar que o processo de inspeção visual em si não se altera, ou seja, a área inspecionada, os itens do check-list a serem observados e o restante da rotina permanecem o mesmo. O nível de controle proposto irá indicar pontos que são susceptíveis à demonstração de anomalias. Destaca-se ainda que, tão importante quanto o monitoramento de valores de deslocamentos absolutos ocorridos, é a observação das tendências de movimentação da estrutura, como o aumento linear ou progressivo dos deslocamentos medidos.

1.1.1.Método de verificação

Para verificação do atingimento do nível de controle, deve-se subtrair o deslocamento acumulado do dia anterior à inspeção com o deslocamento acumulado da última inspeção realizada (14 dias anteriores). Este valor deverá ser comparado ao nível de controle estabelecido e, caso inferior (valor esperado), mantem-se a rotina operacional normal, caso superior (nível de controle atingido), procede-se com a inspeção detalhada na região do marco superficial.

A determinação do deslocamento acumulado por estar sujeito a efeitos climatológicos e leituras a cada 30 minutos são muito sensíveis a este efeito, portanto, é importante definir um método para a sua determinação. Para o estudo foi utilizada a mediana diária.

5.2 Definição do Nível de Controle

A Tabela 1 mostra os fatores de desvio padrão aplicados à mediana, considerados para a análise dos recalques.

Tabela 1 - Múltiplos do Desvio Padrão Global (DPG).

Desvio Padrão Global (DPG)	1 x DPG	2 x DPG	3 x DPG	4 x DPG	5 x DPG
2,5	2,5	5,0	7,5	10,0	12,5

Com base nos valores adquiridos, foi realizado uma avaliação da variação do atingimento do nível de controle para as quinzenas em que ocorreram inspeção visual, utilizando os registros de leitura compreendidos entre 01/01/2022 e 09/03/2025. A análise também considerou os fatores apresentados na tabela acima. Em

complemento, a Figura 5 demonstra a quantidade de vezes que cada marco superficial avaliado no estudo atingiu o nível

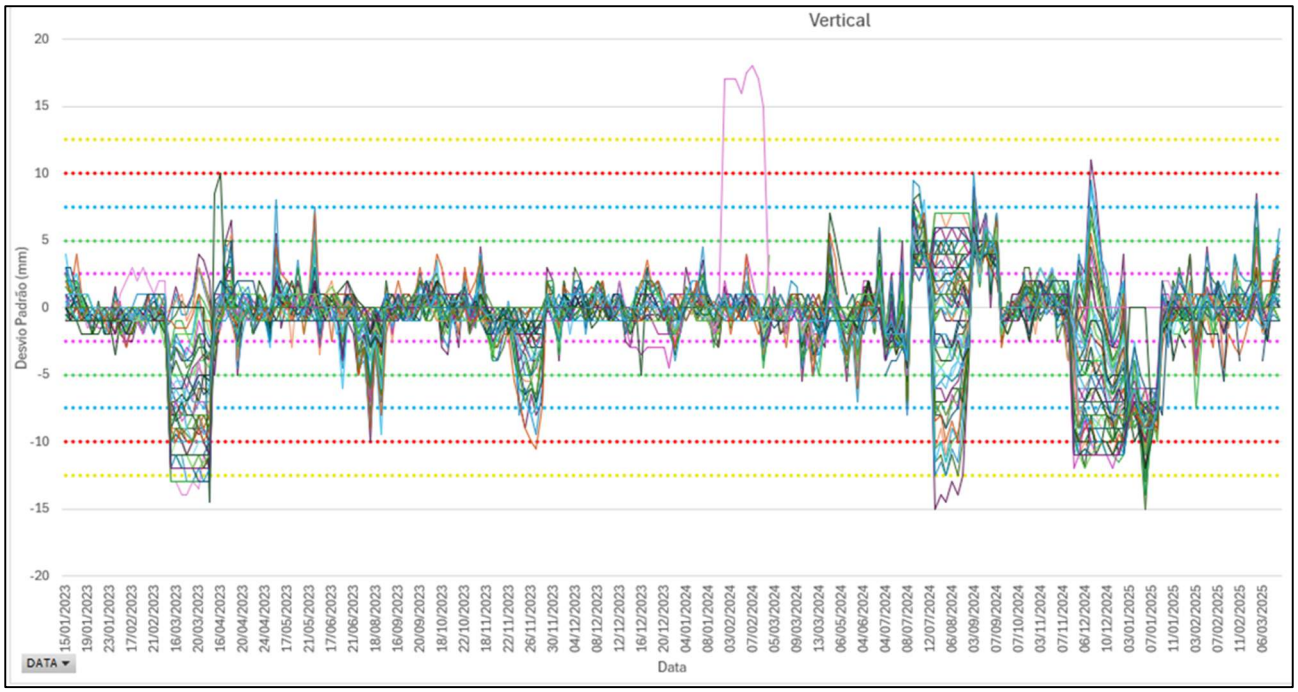


Figura 5 - Verificação do atingimento do nível de controle.

A partir da avaliação dos dados de deslocamento vertical, não foram identificadas leituras que indicassem uma tendência de recalque nociva à performance da estrutura. Além disso, é possível observar também congruência no comportamento dos marcos.

É importante destacar que os pontos em que há movimentações acentuadas das leituras em conjunto (degraus), correspondem aos momentos de calibração da ETR ou situaçõe em que o equipamento foi retirado do ponto de instalação. Após esses eventos, identifica-se o retorno ao comportamento histórico do instrumento.

Nota-se também que, durante o período avaliado, ocorreram algumas leituras anômalas. Essas leituras podem estar associadas a fenômenos climáticos, como as variações de temperatura e pressão, ou a fenômenos externos, como as movimentações de equipamentos, obras ou tráfego de veículos.

Observa-se que a maioria dos dados analisados apresentam valores inferiores a cinco vezes a mediana, o que indica um desvio padrão de menor que 12,5 mm no eixo vertical. Com base nesses resultados, foi realizada uma análise da frequência de leituras que atingiram os valores iguais ou superiores a cinco vezes ao DPG. A Tabela 2 mostra os resultados encontrados.

Tabela 2 - Acionamentos históricos verificados.

Instrumento	Acionamentos	Distância Inclinada
MS-01	6	623,169
MS-02	1	573,441
MS-03	1	566,094
MS-05	1	515,991
MS-06	1	509,543
MS-08	1	466,218
MS-12	1	416,638
MS-14	1	404,876
MS-19	8	331,264

Tabela 2 - Acionamentos históricos verificados. - Continuação

Instrumento	Acionamentos	Distância Inclinada
MS-43	6	145,464
MS-54	1	114,506
MS-58	3	70,371
MS-59	8	50,274
MS-60	8	43,975
MS-64	3	57,514

A análise da quantidade de atingimentos do nível de controle identificou, ao longo de todo o histórico avaliado, um máximo de 50 ocorrências na direção vertical, considerando os eventos de anômalos da base de dados.

Quando se desconsidera os eventos anômalos, o nível de controle nunca foi atingido, esse resultado reforça que tais movimentações acentuadas não fazem parte do comportamento histórico dos marcos superficiais.

O maior valor atingido foi de 10,0 mm (4xDPG) e não foram observadas a materialização de anomalias visuais no entorno dos marcos superficiais, portanto, decidiu-se por manter o valor de 12,5 mm (5xDPG) como nível de controle para a estrutura.

5. CONCLUSÃO

O estudo compreendeu toda a avaliação de *Quality Assurance and Quality Control* (QA/QC) da base de dados de marcos superciais lidos por ETR. Este processo demonstrou a qualidade e robustez deste monitoramento, absorvendo situações rotineiras, obras de engenharia, processo de manutenção e calibração dos equipamentos. O julgamento de engenharia associado à estatística aplicada corroborou para uma operação segura, reforçando a importância do monitoramento de deslocamentos superficiais.

A determinação do Desvio Padrão Global (DPG) considerou o comportamento geotécnico esperado das estruturas e sua verificação indicou um mútiplo de 5 vezes o DPG como nível de controle.

Importante reforçar que o recurso estátistico não sobrepõe o julgamento de engenharia, tampouco exime a necessidade de avaliar toda a instrumentação sob a perspectiva da análise geotécnica. Uma movimentação isolada de um marco superficial não necessariamente caracteriza uma zona potencial de ruptura de toda estrutura, uma vez que avarias, danos localizados, choques com outros equipamentos, vandalismo e mesmo erros de leitura são passíveis de ocorrer nos instrumentos ao longo do tempo. Sendo assim, a metodologia é apenas indicativa e orientativa, de modo a subsidiar as necessidades de avaliações mais criteriosas para uma tomada de decisão quanto aos níveis de segurança da barragem. Um instrumento nunca deverá ser analisado de forma isolada, fora de um contexto de avaliação da condição integral da estrutura, para situação de atingimento de níveis de controle, é necessário o complemento da análise multidisciplinar com a presença de equipes de engenharia responsáveis pela estrutura.

6. REFERÊNCIAS BIBLIOGRÁFICAS

AZEEZ, A.; KARIMZADEH, S.; VALIZADEH KAMRAN, K.; MATSUOKA, M. *Deformation analysis of embankment dam using field survey and multisensor InSAR time-series: A case study of Mosul Dam, Iraq*. Turkish Journal of Remote Sensing, v. 7, n. 2, p. 244–262, 30 dez. 2025. DOI: 10.51489/tuzal.1690530.

CLARKSON, Luke; WILLIAMS, David John. *Critical review of tailings dam monitoring best practice*. **International Journal of Mining, Reclamation and Environment**, v. 34, n. 2, p. 119–148, 2019. DOI: 10.1080/17480930.2019.1625172.

CLARKSON, Luke; WILLIAMS, David. Catalogue of real-time instrumentation and monitoring techniques for tailings dams. Mining Technology, [S.L.], v. 130, n. 1, p. 52-59, 2 jan. 2021. Informa UK Limited. http://dx.doi.org/10.1080/25726668.2021.1874094;

KANG, Gi-Chun. Improving reliabilities of dam displacement based on monitoring given points by total station. Journal of the Korean Geosynthetics Society, v. 16, n. 1, 2017. DOI: https://doi.org/10.12814/jkgss.2017.16.1.001

MARR, W. Allen. Instrumentation and Monitoring of Slope Stability. Geo-Congress 2013 ASCE, [S. l.], p. 2231-2252, 2013.

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/COBRAMSEG2026.2/14

Fundação Inteligente: Um Chatbot Especializado para Apoio Técnico em Engenharia Civil

Ana Maria Rodrigues Barbosa
Engenheira Civil, Instituto Federal do Tocantins, Palmas/TO, Brasil, enganamrodrigues@gmail.com

Flávio da Silva Ornelas
Professor, Instituto Federal do Tocantins, Palmas/TO, Brasil, flavioornelas@ifto.edu.br

Ricardo Loureiro Soares
Professor, Instituto Federal do Tocantins, Palmas/TO, Brasil, ricardo.soares@ifto.edu.br

RESUMO: Este trabalho tem como objetivo o desenvolvimento de um chatbot inteligente, baseado no modelo de linguagem Llama 2, para atuar como uma ferramenta de apoio técnico na área de fundações da engenharia civil. A proposta visa auxiliar profissionais e estudantes, fornecendo respostas confiáveis e imediatas para dúvidas técnicas recorrentes, com foco em todos os tipos de fundações utilizados na construção civil, incluindo fundações rasas (como sapatas, radier e blocos de fundação) e fundações profundas (como estacas escavadas, hélice contínua e strauss). O sistema será estruturado como uma consultoria virtual, oferecendo respostas fundamentadas nas normas técnicas brasileiras vigentes, especialmente a NBR 6122:2019. Utilizando técnicas de Processamento de Linguagem Natural (PLN), o chatbot será capaz de interpretar perguntas formuladas em linguagem natural e fornecer respostas claras, coerentes e tecnicamente embasadas. O trabalho apresenta todo o processo de desenvolvimento da ferramenta, a estrutura computacional adotada, os critérios utilizados para validação das respostas e os testes aplicados para avaliar sua eficiência como suporte técnico na área de fundações.

PALAVRAS-CHAVE: Inteligência Artificial, Fundações, Chatbot.

ABSTRACT: This undergraduate thesis aims to develop an intelligent chatbot based on the Llama 2 language model, designed to serve as a technical support tool in the field of foundations in civil engineering. The proposal seeks to assist professionals and students by providing reliable and immediate answers to recurring technical questions, with a focus on all types of foundations used in construction, including shallow foundations (such as footings, raft slabs, and foundation blocks) and deep foundations (such as bored piles, continuous flight auger piles, and Strauss piles). The system will be structured as a virtual consultancy, offering responses grounded in current Brazilian technical standards, especially NBR 6122:2019. Using Natural Language Processing (NLP) techniques, the chatbot will be capable of interpreting questions formulated in natural language and providing clear, coherent, and technically accurate answers. This work presents the entire development process of the tool, the adopted computational architecture, the criteria used for response validation, and the tests conducted to evaluate its effectiveness as a technical support resource in the field of foundations.

KEYWORDS: Artificial intelligence. Foundations. Chatboot.

1 INTRODUÇÃO

A indústria da construção civil enfrenta desafios constantes no que diz respeito à padronização, segurança e conformidade técnica dos projetos, especialmente quando se trata das fundações, elementos essenciais para a estabilidade das edificações. No contexto de fundações, é comum que profissionais e

estudantes encontrem dificuldades na correta interpretação e aplicação das normas técnicas, bem como na escolha da solução mais adequada diante das características do solo e das cargas envolvidas.

Em muitos casos, essas dúvidas técnicas surgem no cotidiano da prática profissional ou acadêmica e exigem consultas rápidas a fontes seguras, como normas da ABNT e literatura especializada. No entanto, esse processo nem sempre é direto, podendo demandar tempo para localizar e interpretar as informações pertinentes. Dessa forma, ferramentas que reúnem o conhecimento técnico de maneira clara e acessível podem tornar a tomada de decisão mais eficiente e segura.

Nesse cenário, a inteligência artificial (IA) surgiu como uma aliada estratégica, oferecendo novas possibilidades de acesso à informação técnica de forma ágil, padronizada e confiável. A utilização de modelos de linguagem natural permitiu a criação de sistemas inteligentes, como chatbots, capazes de compreender perguntas formuladas em linguagem cotidiana e fornecer respostas fundamentadas em normas e literatura especializada.

Este artigo apresenta o desenvolvimento de um chatbot baseado no modelo de linguagem Llama 2, voltado à consultoria técnica em fundações rasas e profundas, com foco nos tipos mais utilizados em Palmas/TO. A ferramenta proposta buscou auxiliar profissionais e estudantes com respostas rápidas, claras e fundamentadas, contribuindo para a qualidade dos projetos de fundações e para decisões de engenharia mais seguras e eficientes.

Além de sua utilidade como suporte técnico, o chatbot configurou uma aplicação real da inteligência artificial generativa no campo da engenharia civil, ilustrando como tecnologias linguísticas puderam ser moldadas para contextos especializados. Essa proposta combinou avanço tecnológico com a rotina profissional, favorecendo a aproximação entre engenharia e TI e estimulando a criação de soluções mais direcionadas e democráticas no setor da construção.

2 REFERENCIAL TEÓRICO

2.1 Fundações e Normatização Técnica

Segundo a NBR 6122:2019, fundações rasas são elementos cuja base está assentada em profundidade inferior a duas vezes a sua menor dimensão. Já as fundações profundas transmitem a carga por meio do fuste (atrito lateral) ou ponta em camadas mais resistentes do solo. O projeto e execução desses elementos são regidos principalmente pela NBR 6122 (fundações) e NBR 6118 (estruturas de concreto).

A segurança estrutural das edificações depende intrinsecamente da observância rigorosa de critérios técnicos durante as fases de projeto e execução. No Brasil, esse setor é regido por um conjunto de normas da ABNT que estabelecem os requisitos mínimos de desempenho, estabilidade e durabilidade das estruturas. O chatbot desenvolvido fundamentou suas respostas nas seguintes normas:

2.1.1 ABNT NBR 6122:2019 – Projeto e Execução de Fundações

Esta é a norma principal que rege o dimensionamento de fundações rasas e profundas no país. Ela define os procedimentos para a investigação geotécnica, critérios de segurança, verificação de capacidade de carga e recalques, além de diretrizes executivas para diversos tipos de elementos, como sapatas, blocos, radier e estacas.

2.1.2 ABNT NBR 6118:2014 – Projeto de Estruturas de Concreto

Complementa a NBR 6122 ao fornecer diretrizes específicas para o dimensionamento estrutural dos elementos de fundação em concreto armado. Ela aborda critérios de resistência, detalhamento de armaduras e verificações de punção, garantindo a integridade dos blocos e sapatas sob carregamentos verticais.

2.1.3 ABNT NBR 12655:2022 – Concreto de Cimento Portland

Estabelece as exigências para o preparo, controle, recebimento e aceitação do concreto. Sua inclusão na base de conhecimento do sistema buscou garantir que as orientações sobre a qualidade do material utilizado nas fundações estivessem em conformidade com os padrões de durabilidade exigidos.

2.1.4 ABNT NBR 8681:2003 – Ações e Segurança nas Estruturas

Define os critérios para a consideração das cargas atuantes e os coeficientes de segurança. Esta norma foi essencial para fundamentar as respostas do chatbot sobre combinações de ações e fatores de ponderação, visando evitar o subdimensionamento que poderia levar a colapsos estruturais.

2.1.5 ABNT NBR 14931:2004 – Execução de Estruturas de Concreto

Especifica as boas práticas durante a fase executiva, abordando fôrmas, escoramentos, montagem de armaduras e lançamento do concreto. Sua aplicação no sistema visou reduzir erros humanos e padronizar procedimentos em campo.

2.2 Fundações Rasas e Profundas

O conhecimento técnico inserido na base do chatbot abrange as classificações fundamentais da geotecnia conforme a NBR 6122: As fundações rasas são elementos cuja base está assentada em profundidade inferior a duas vezes a sua menor dimensão. Entre as tipologias estudadas estão as sapatas (isoladas, corridas, associadas e alavancadas), dimensionadas para resistir à tração por meio de armaduras , os blocos de fundação, que utilizam a resistência do próprio concreto , e o radier, uma laje que distribui cargas em áreas extensas. Essas soluções são indicadas quando as camadas superficiais possuem capacidade de suporte adequada. Já as fundações profundas transmitem cargas a níveis inferiores do solo através de estacas ou tubulões. O trabalho focou em três tipos de estacas moldadas in loco: a escavada, que minimiza vibrações em áreas urbanas ; a hélice contínua, caracterizada pela rapidez e monitoramento eletrônico ; e a Strauss, que utiliza equipamentos leves e de baixo custo para locais de difícil acesso. A escolha correta entre essas tecnologias é vital para evitar recalques diferenciais e garantir a vida útil da edificação.

2.3 Inteligência Artificial e Chatbots

Chatbots são programas que simulam interações humanas usando Processamento de Linguagem Natural (PLN). O modelo Llama 2, utilizado neste trabalho, emprega a arquitetura Transformer com mecanismo de atenção, o que permite o processamento contextualizado de normas técnicas. O diferencial desta ferramenta técnica reside no fato de seu conteúdo ser inteiramente fundamentado na literatura normativa da ABNT.

3 METODOLOGIA

3.1 Abordagem e Pesquisa Bibliográfica

A metodologia deste trabalho seguiu inicialmente uma abordagem de pesquisa bibliográfica, concentrada na revisão crítica de normas técnicas brasileiras e artigos científicos sobre fundações rasas e profundas. Foram analisadas a NBR 6122:2019, NBR 6118:2014, NBR 12655:2022, NBR 14931:2004 e NBR 8681:2003, garantindo uma base teórica sólida para o treinamento do chatbot. Adicionalmente, buscou-se fundamentação em estudos sobre inteligência artificial e arquiteturas de processamento de linguagem natural, como o modelo Transformer.

3.2 Desenvolvimento do Chatbot (FundIA)

O desenvolvimento da ferramenta, denominada FundIA, foi estruturado para oferecer uma consultoria virtual baseada em IA. A implementação foi dividida entre a interface do usuário e o processamento de dados de bastidores.

3.2.1 Interface (Front-end)

Desenvolvida com o framework Streamlit, a interface foi projetada para ser intuitiva, contando com campo de perguntas em linguagem natural, botão de envio, exibição de respostas formatadas e um sistema de feedback (útil, parcialmente útil ou não útil).



Figura 1. Interface do FundIA.



Figura 2. Interface do FundIA.

3.2.2 Arquitetura de Pastas

Para garantir escalabilidade, o projeto foi organizado em diretórios específicos: /documents (normas em PDF), /models (Llama 2 quantizado), /static (recursos visuais), /cache (armazenamento de buscas rápidas) e /venv (ambiente virtual Python).

3.3 Backend e Processamento de Linguagem Natural

O backend foi configurado para realizar o carregamento e a interpretação automática dos documentos técnicos através de etapas coordenadas:

3.3.1 Leitura e Indexação

Os arquivos PDF foram extraídos via SimpleDirectoryReader e divididos em partes menores (chunks) de aproximadamente 512 palavras, mantendo um trecho repetido entre elas para preservar o contexto.

3.3.2 Vetorização

Cada chunk foi transformado em vetores matemáticos utilizando o modelo all-MiniLM-L6-v2 da Hugging Face, permitindo que o sistema realize buscas semânticas baseadas no significado das palavras e não apenas em termos isolados.

3.3.3 Geração de Respostas

Utilizou-se o modelo Llama 2-7B Chat (versão quantizada) para processar as dúvidas. O modelo foi configurado com temperatura 0.1 para priorizar a precisão técnica e limitar a criatividade da IA, garantindo que as respostas fossem focadas estritamente no conteúdo normativo.

3.3.4 Memória e Cache

Implementou-se um cache inteligente para armazenar respostas já geradas, agilizando o atendimento de perguntas repetidas e otimizando o desempenho do sistema.

3.4 Critérios e Validação

Após a conclusão do software, o sistema foi submetido a testes práticos com um grupo de 20 participantes, divididos igualmente entre profissionais experientes (incluindo docentes do IFTO) e estudantes de Engenharia Civil. Foram avaliadas a clareza, a coesão e a precisão técnica das respostas geradas frente a dúvidas reais e simuladas do cotidiano da engenharia.

4 RESULTADOS E DISCUSSÕES

4.1 Validação e Perfil dos Participantes

A validação do chatbot FundIA foi realizada por meio de testes práticos com um grupo de 20 participantes, selecionados para representar tanto o ambiente acadêmico quanto o profissional. O grupo foi composto por 10 profissionais experientes, incluindo três docentes do IFTO e sete engenheiros colaboradores, além de 10 estudantes de graduação em Engenharia Civil. Cada voluntário submeteu, em média, cinco perguntas ao sistema, totalizando 100 interações que variaram desde dúvidas genéricas até questões técnicas de alta complexidade sobre fundações rasas e profundas. Essa diversidade de questionamentos foi fundamental para avaliar a versatilidade do modelo Llama 2 em diferentes níveis de demanda técnica.

4.2 Precisão Técnica e Satisfação do Usuário

Os resultados demonstraram uma performance sólida do sistema, com **96% das respostas** sendo classificadas como tecnicamente corretas e devidamente fundamentadas nas normas brasileiras, com destaque para a NBR 6122:2019. A análise quantitativa revelou uma **taxa de satisfação geral de 98%**, com os participantes classificando a ferramenta como útil e eficaz para o suporte técnico cotidiano. Enquanto os profissionais ressaltaram a agilidade na consulta normativa para a rotina de projetos, os estudantes enfatizaram o valor pedagógico da ferramenta ao facilitar o acesso a explicações técnicas complexas.

4.3 Análise de Interações e Comportamento do Sistema

Durante os testes, o FundIA foi submetido a perguntas que exigiam interpretação normativa e raciocínio sobre métodos executivos e interação solo-estrutura. Um ponto relevante da análise qualitativa foi

a postura ética e consciente do modelo. Ao realizar estimativas de capacidade de carga para estacas hélice contínua, o sistema apresentou os cálculos pertinentes, mas incluiu alertas obrigatórios ressaltando que tais resultados são simplificações e que o dimensionamento final deve ser validado por um engenheiro especializado. Esse comportamento evidencia que o chatbot compreende seus limites funcionais, não se posicionando como substituto do profissional, mas como uma ferramenta de apoio consultivo.

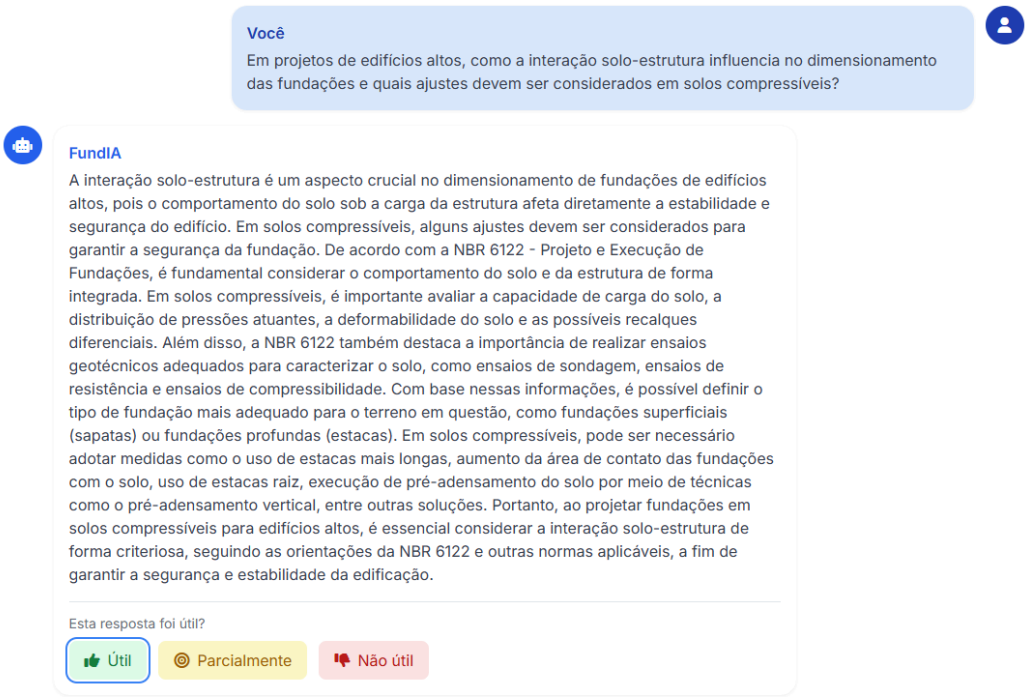


Figura 3. Demonstração de uso do FundIA.

Adicionalmente, o sistema demonstrou robustez ao lidar com perguntas fora de seu escopo técnico. Quando questionado sobre temas irrelevantes, como resultados de loterias, o chatbot recusou a resposta de forma adequada, reafirmando seu propósito exclusivo de fornecer informações especializadas em engenharia civil com base nas normas ABNT. Essa consistência assegura a confiabilidade da ferramenta, impedindo desvios de finalidade e garantindo o foco na segurança normativa.

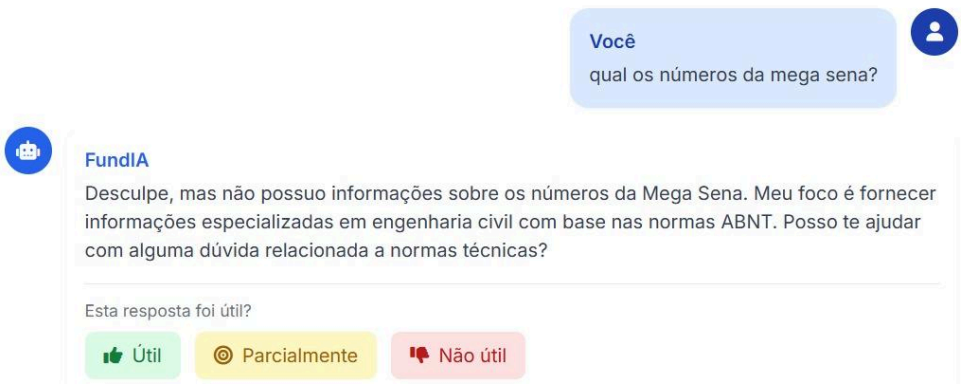


Figura 4. Demonstração de uso do FundIA.

5 CONCLUSÕES

O FundIA demonstrou ser uma ferramenta eficiente para consulta rápida de conceitos e parâmetros geotécnicos, facilitando o acesso a informações técnicas de forma interativa. A exibição de referências bibliográficas junto às respostas reforça a credibilidade do sistema, incentivando o uso responsável das informações. A arquitetura modular possibilita futuras expansões, como integração com IA generativa ou ampliação da base de conhecimento. O desenvolvimento do FundIA representa um avanço no uso de tecnologias conversacionais aplicadas à engenharia geotécnica. Ao proporcionar acesso facilitado a informações técnicas confiáveis, o sistema contribui para a formação acadêmica e prática profissional, podendo ser expandido para outras áreas da engenharia.

REFERÊNCIAS BIBLIOGRÁFICAS

Associação Brasileira de Normas Técnicas (2003). NBR 8681: *Ações e segurança nas estruturas - Procedimento*. Rio de Janeiro.

Associação Brasileira de Normas Técnicas (2004). NBR 14931: *Execução de estruturas de concreto - Procedimento*. Rio de Janeiro.

Associação Brasileira de Normas Técnicas (2014). NBR 6118: *Projeto de estruturas de concreto - Procedimento*. Rio de Janeiro.

Associação Brasileira de Normas Técnicas (2019). NBR 6122: *Projeto e execução de fundações*. Rio de Janeiro.

Associação Brasileira de Normas Técnicas (2022). NBR 12655: *Concreto de cimento Portland* - Preparo, controle, recebimento e aceitação - Procedimento. Rio de Janeiro.

Brown, T. et al. (2020). *Language Models are Few-Shot Learners. Advances in Neural Information Processing Systems*, v. 33, p. 1877-1901.

Fontes, M. P. C. F., Corga, J. C. B., Cortat, M. J. B. (2022). *Estaca hélice contínua: análise de cenário na construção civil.* Tudo é Ciência: Congresso Brasileiro de Ciências e Saberes Multidisciplinares, v. 1, p. 1-8.

McCarthy, J., Minsky, M., Rochester, N., Shannon, C. (1971). *A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence*. Artificial Intelligence, vol. 2, issue 1-2, pp. 1-24.

Oliveira, T. H. G. et al. (2024). *Transformação da engenharia civil através da inteligência artificial: Um novo horizonte de inovação*. Nativa-Revista de Ciências Sociais do Norte de Mato Grosso, v. 13, n. 1.

Touvron, H. et al. (2023). *LLaMA 2: Open Foundation and Fine-Tuned Chat Models*. Meta AI. Disponível em: https://arxiv.org/abs/2307.09288.

Vaswani, A. et al. (2017). *Attention is All You Need. Advances in Neural Information Processing Systems*, v. 30.

DOI: 10.47094/COBRAMSEG2026.2/15

Gerenciamento Digital de Tailings Storage Facilities

Thiago Franklin Santos de Almeida
Gerente de Produto, TPF Engenharia, Belo Horizonte/MG, Brasil, thiago.almeida@tpfe.com.br

Felipe Leal Barros
Coordenador Corporativo, TPF Engenharia, São Paulo/SP, Brasil, felipe.barros@tpfe.com.br

Julia de Melo Rocha
Diretora de Gestão e Finanças, TPF Engenharia, Recife/PE, Brasil, julia.rocha@tpfe.com.br

Juliana Scanoni Silva
Gerente Corporativa, TPF Engenharia, Recife/PE, Brasil, juliana.scanoni@tpfe.com.br

André Jabir Assumpção
Diretor Executivo, TPF Engenharia, São Paulo/SP, Brasil, andre.jabir@tpf.com.br

RESUMO: A gestão de barragens de rejeitos (Tailings Storage Facilities – TSFs) exige governança, rastreabilidade e confiabilidade de informações em um contexto de elevado volume de dados e múltiplas origens. Este trabalho apresenta e avalia uma abordagem de gerenciamento digital integrado, baseada em plataforma modular em nuvem, para enfrentar quatro desafios recorrentes: (i) volume e diversidade de dados; (ii) padronização; (iii) confiança e rastreabilidade; e (iv) dinamismo de fluxos e processos. A solução organiza as informações em sete eixos temáticos (consolidação de dados, inspeções, segurança geotécnica, hidráulica e operacional, sumário das estruturas e análise de risco) e doze módulos, com governança de acesso, trilhas de auditoria e fluxos de revisão/aprovação. Integra aplicativos móveis para inspeções, consolidação de leituras instrumentais, visualização geoespacial via GeoBIM e painéis analíticos (BI) para suporte ao Engineer of Record (EoR). A eficácia foi verificada pela aplicação em um portfólio de cinco TSFs, em ciclos de feedback com o EoR, com aderência aos requisitos da ANM e aos princípios do Global Industry Standard on Tailings Management (GISTM). Os resultados indicaram ganhos em eficiência, padronização transversal, atualização de dados, redução de esforço manual em relatórios e aumento da rastreabilidade e auditabilidade, fortalecendo a governança e o suporte à decisão.

PALAVRAS-CHAVE: Governança da informação, Rastreabilidade de Dados, Segurança de Barragens, Conformidade Normativa, GISTM.

ABSTRACT: Tailings Storage Facilities (TSFs) management requires strong governance, traceability, and information reliability in a context of large data volumes and multiple sources. This paper presents and evaluates an integrated digital management approach, based on a modular cloud platform, to address four recurring challenges: (i) data volume and source diversity; (ii) standardization; (iii) confidence and traceability; and (iv) dynamic workflows and processes. The solution organizes TSF information into seven thematic axes (data consolidation, field inspections, geotechnical, hydraulic and operational safety, facility summary, and risk analysis) and twelve interconnected modules, supported by access governance, audit trails, and configurable review/approval workflows. It integrates mobile applications for inspections, consolidation of instrumentation readings, geospatial visualization through GeoBIM, and analytical dashboards (BI) to support the Engineer of Record (EoR). Effectiveness was verified through application to a portfolio of five TSFs, using iterative feedback cycles with the EoR, while ensuring adherence to Brazil's National Mining Agency (ANM) requirements and the principles of the Global Industry Standard on Tailings Management (GISTM). Results indicate improvements in operational efficiency, cross-facility standardization, data currency, reduced manual effort for reporting, and increased traceability and auditability, strengthening governance and decision support.

KEYWORDS: Information Governance, Data Traceability, Dam Safety, Regulatory Compliance, GISTM.

1 INTRODUÇÃO

A gestão segura de barragens de rejeitos (Tailings Storage Facilities – TSFs) tem assumido papel central na engenharia geotécnica contemporânea, especialmente após acidentes de grande magnitude que evidenciaram a necessidade de fortalecer os sistemas de governança, monitoramento e tomada de decisão associados a essas estruturas. Estudos internacionais têm destacado que a segurança de TSFs depende não apenas de soluções técnicas adequadas de projeto e operação, mas também da qualidade dos sistemas de gestão da informação utilizados no acompanhamento de seu desempenho ao longo do ciclo de vida (Crous & Marais, 2025; ICMM; UNEP; PRI, 2020; Franks et al., 2021

Nesse contexto, o Global Industry Standard on Tailings Management (GISTM) estabeleceu princípios e requisitos que reforçam a importância da transparência, rastreabilidade e confiabilidade das informações utilizadas no gerenciamento dessas estruturas (ICMM, UNEP & PRI, 2020). De forma complementar, diretrizes internacionais como as propostas pela Mining Association of Canada (2021) destacam que o desempenho esperado na gestão de TSFs depende da combinação entre tecnologias adequadas (Best Available Technology – BAT) e práticas consolidadas de gestão (Best Available/Applicable Practice – BAP). Essa combinação pressupõe a existência de sistemas capazes de integrar informações provenientes de diferentes disciplinas e suportar a tomada de decisão técnica baseada em dados confiáveis e atualizados.

Apesar dos avanços observados nas últimas décadas, o gerenciamento de TSFs ainda enfrenta desafios significativos relacionados à gestão e integração de informações. Diferentes publicações apontam que a intensificação da instrumentação, do monitoramento e da digitalização nas operações de mineração tem ampliado substancialmente o volume de dados disponíveis, provenientes de sistemas diversos, sensores, levantamentos de campo e documentação técnica (UNEP; GRID-Arendal, 2017; Franks et al., 2021). Entretanto, em muitos casos essas informações permanecem fragmentadas em múltiplas bases de dados ou ferramentas isoladas, dificultando a consolidação, interpretação e utilização eficiente desses dados no suporte à gestão das estruturas.

Nesse cenário, quatro desafios principais são frequentemente observados no gerenciamento das informações associadas a TSFs: (i) o grande volume e diversidade das fontes de dados, provenientes de diferentes sistemas e formatos; (ii) a falta de padronização na organização e armazenamento das informações; (iii) a necessidade de garantir confiança e rastreabilidade dos dados, assegurando que as informações utilizadas nas análises correspondam às versões mais atualizadas e devidamente validadas; e (iv) o dinamismo dos fluxos de trabalho, que envolve múltiplas equipes e disciplinas responsáveis pelo monitoramento e gestão das estruturas.

A superação desses desafios tem sido apontada como um dos principais vetores para o avanço da governança de barragens de rejeitos, especialmente no contexto da transformação digital da mineração. Soluções baseadas em integração de dados, geotecnologias, plataformas digitais e ferramentas analíticas têm demonstrado potencial significativo para melhorar a eficiência operacional, a transparência das informações e a capacidade de análise das equipes técnicas responsáveis pela gestão dessas estruturas (Azam & Li, 2010; Bowker & Chambers, 2015; Franks et al., 2021).

Diante desse contexto, este trabalho apresenta o desenvolvimento e a aplicação de uma plataforma digital integrada voltada ao gerenciamento de dados e processos associados às TSFs. A solução foi concebida para consolidar e padronizar informações provenientes de diferentes fontes, garantindo rastreabilidade e confiabilidade dos dados e permitindo sua transformação em indicadores e informações relevantes para o suporte à tomada de decisão.

A abordagem proposta busca contribuir para o fortalecimento da governança das informações associadas às barragens de rejeitos, alinhando-se aos princípios do GISTM e às boas práticas internacionais de gestão de TSFs. A partir da integração de módulos funcionais, ferramentas de análise de dados e geotecnologias, a solução procura responder aos principais desafios relacionados ao volume de dados, padronização das informações, rastreabilidade e dinamismo dos fluxos de trabalho observados no gerenciamento dessas estruturas. A Figura 1 sintetiza a arquitetura conceitual da transformação digital considerada neste trabalho.

Com base nesses desafios, foram definidos os objetivos apresentados a seguir, estruturando a avaliação da abordagem proposta e sua aplicação em um portfólio de TSFs.

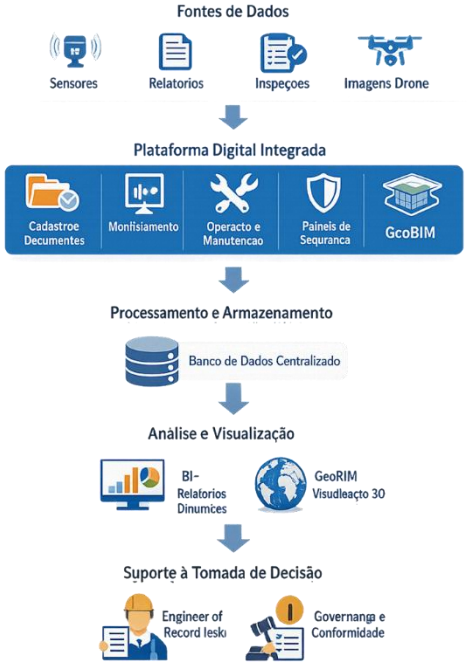


Figura 1. Arquitetura de transformação digital na gestão de TSFs.

2 OBJETIVOS

Esse trabalho teve por finalidade apresentar e avaliar, a partir de aplicação em um portfólio de barragens de rejeitos (Tailings Storage Facilities – TSFs), uma abordagem de gerenciamento digital integrado baseada em plataforma modular em nuvem, orientada à consolidação, padronização, confiabilidade/rastreabilidade e governança de dados e processos, de modo a apoiar o Engineer of Record (EoR) e demais partes interessadas na tomada de decisão técnica e no atendimento aos requisitos regulatórios e aos princípios do Global Industry Standard on Tailings Management (GISTM). De forma específica, teve-se como finalidade:

- Diagnosticar os principais desafios de gestão da informação no gerenciamento de TSFs, com foco em: (i) volume e diversidade de dados; (ii) padronização; (iii) confiança e rastreabilidade; e (iv) dinamismo de fluxos e processos.
- Estruturar um modelo de informação e processos para TSFs organizado em sete eixos temáticos (consolidação de dados, inspeção de campo, segurança geotécnica, segurança hidráulica, segurança operacional, sumário das estruturas e análise de risco), traduzindo necessidades técnicas em requisitos de dados e governança.
- Desenvolver e implementar uma arquitetura digital modular e escalável (plataforma em nuvem), com mecanismos de governança da informação (perfis de acesso, trilhas de auditoria e fluxos de revisão/aprovação), visando garantir integridade, rastreabilidade e atualização contínua dos dados.
- Integrar a captura/validação de dados de campo e monitoramento (aplicativos móveis, inspeções, evidências digitais e consolidação de leituras instrumentais) e habilitar a transformação de dados em informação por meio de relatórios dinâmicos (BI) e visualização geoespacial (GeoBIM), apoiando o EoR e partes interessadas.
- Avaliar os impactos da solução em um portfólio de cinco TSFs, evidenciando ganhos em eficiência operacional, padronização transversal, rastreabilidade/auditabilidade, redução de esforço manual na elaboração de relatórios e aderência ao GISTM e requisitos regulatórios aplicáveis.

3 METODOLOGIA

Segundo o guia da Mining Association of Canada (2021), o alicerce fundamental para atingir a performance e os objetivos esperados na gestão de TSFs consiste na combinação de dois pilares:

1. A utilização de tecnologias e técnicas que sejam economicamente viáveis e reduzam significativamente riscos relacionados à gestão de resíduos (BAT – Best Avaliable Technology).
2. A definição de sistemas de gestão, técnicas e procedimentos que comprovadamente demonstraram por meio da sua aplicação um grau efetivo de confiabilidade no que tange ao gerenciamento de riscos relacionados à gestão de resíduos (BAP – Best Available/Applicable Practice).

Partindo desse pressuposto, a combinação de um sistema robusto, capaz de unir tecnologias variadas capazes de suportar efetivamente a gestão de TSFs, aliado a um corpo técnico experiente, com processos e práticas bem definidas, constituem os vetores fundamentais para uma gestão eficiente e digitalizada.

Antes de adentrar nas nuances específicas da plataforma digital apresentada, vale ressaltar brevemente o contexto inicial da sua concepção. Em suma, ao avaliar criticamente o cenário de apoio ao gerenciamento de barragens de rejeitos em uma grande empresa de engenharia consultiva, o cenário identificado foi o de um time amplamente qualificado, com processos bem definidos, e que já se utilizava de um pequeno conjunto de soluções tecnológicas descentralizadas, focadas majoritariamente em questões pontuais, como, por exemplo, a digitalização do processo de inspeções de campo.

Nesse contexto, o primeiro passo rumo à construção da solução foi o estabelecimento de uma equipe multidisciplinar de consultores, composta por engenheiros especialistas em diferentes áreas, incluindo: Business Intelligence, desenvolvimento de sistemas digitais, geoprocessamento, gerenciamento de barragens de rejeito e inovação, cujo propósito inicial seria avaliar profundamente os processos e atividades das equipes envolvidas diretamente no dia a dia do gerenciamento de TSFs, identificando todas as disciplinas envolvidas no processo, a estrutura de processos consolidados, o fluxo de dados, as tecnologias utilizadas, gargalos existentes e possíveis oportunidades de melhoria.

Como resultado dessa avaliação, foi percebido que embora existisse uma ampla gama de processos envolvidos no gerenciamento de TSFs, os principais desafios poderiam ser resumidos em 4 frentes, conforme descrito a seguir:

1. **Volume e diversificação das fontes de dados:** Grandes volumes de dados recebidos para processamento e análise, oriundos de fontes variadas (softwares, relatórios, documentos, dentre outros), as quais nem sempre eram de fácil acesso e interpretação para as equipes.
2. **Padronização:** Em muitas oportunidades, um mesmo tipo de dado era recebido em formatos diferentes, a depender da sua origem.
3. **Confiança e rastreabilidade:** Apesar do dado estar disponível/acessível, era difícil verificar se aquela era a versão mais atualizada da informação, ou até mesmo se aquele dado foi validado previamente.
4. **Dinamismo de fluxos e processos:** Sem o apoio de soluções tecnológicas centralizadas, o dinamismo dos fluxos constituía um desafio no estabelecimento de rotinas das equipes.

Além dos desafios listados acima, outra importante informação identificada no processo de consultoria foi a natureza dos dados acompanhados no contexto de gestão de barragens de resíduos. De modo geral, apesar da grande variedade de informações necessárias, era possível estruturá-las em uma EAP com sete eixos temáticos, nominalmente: consolidação de dados, inspeção de campo, segurança geotécnica, segurança hidráulica, segurança operacional, sumário das estruturas e análise de risco.

Combinando os desafios encontrados com a identificação e categorização de todos os tipos de informações acompanhadas, o passo final rumo à concepção foi o alinhamento da arquitetura da solução a um conjunto de boas práticas e normativas capazes de sustentar a sua coluna dorsal. Nesse sentido, a avaliação dos princípios citados no GISTM (Global Industry Standard on Tailings Management), um dos guias mais relevantes no que tange ao gerenciamento de barragens de rejeito, constituiu o elemento final para a estruturação da ferramenta.

A solução foi desenvolvida utilizando-se de uma infraestrutura 100% em nuvem, pautada na utilização de tecnologias como: base em plataforma low-code (propiciando agilidade no desenvolvimento), bancos de dados SQL Server (permitindo a consolidação de um grande volume de dados), integração com ferramentas de geoprocessamento (permitindo a incorporação de voos de drone, tour virtual e modelos BIM

georreferenciados), construção de relatórios dinâmicos (integração ao Power BI) e aplicativos mobile (digitalização de inspeções de campo).

A plataforma conta com 12 módulos funcionais, capazes de operar de maneira independente ou integrada, e diretamente alinhados aos princípios do GISTM, conforme apresentado na Figura 2:

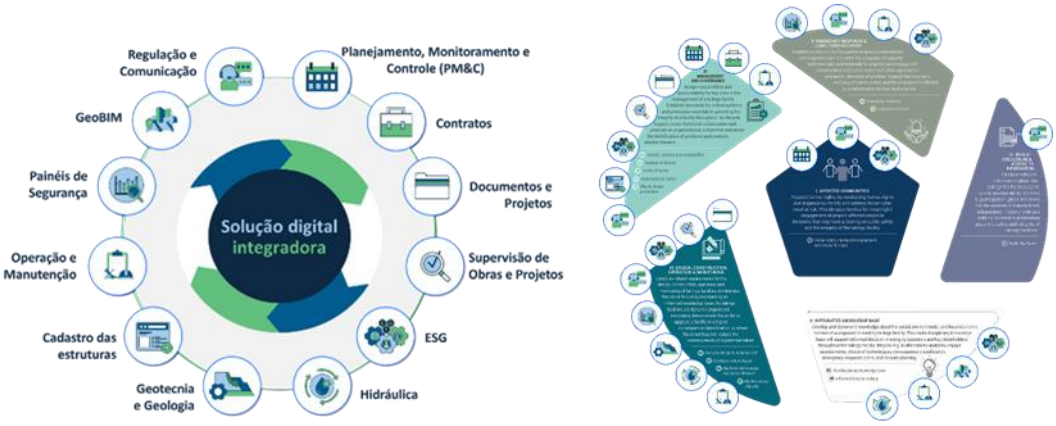


Figura 2. Módulos da Solução x Princípios GISTM

4 RESULTADOS

Ao avaliar a utilização da solução digital no apoio ao gerenciamento de diferentes TSFs, foi possível observar claramente os principais impactos nas rotinas das equipes. O foco da observação foi destinado principalmente aos 4 principais desafios identificados durante a concepção da plataforma, nominalmente: Volume e diversificação das fontes de dados, Padronização, Confiança e Rastreabilidade, Dinamismo de Fluxos e Processos.

De modo a facilitar a observação dos resultados, a avaliação de impactos será feita de maneira correlata a cada um dos desafios, buscando destacar de maneira clara e objetiva como a plataforma contribuiu em cada um deles.

Iniciando pelo desafio enfrentado pelas equipes no acesso estruturado e facilitado a um grande volume de dados, oriundos de várias fontes, é imprescindível destacar a importância da ferramenta. Por contar com uma ampla gama de módulos voltados ao registro e recebimento estruturado de informações das mais diversas naturezas, a plataforma constituiu uma aliada fundamental na consolidação de todos os dados em um único ambiente (banco de dados).

Antes da utilização da plataforma, a maior parte dos dados de entrada eram recebidos e armazenados em planilhas de Excel, com formatos bastante variados, e pouca trabalhabilidade, especialmente em um contexto em que são recebidos centenas de milhares de registros mensalmente, utilizar-se de ferramentas pouco escaláveis começava a se tornar um gargalo relevante na condução das atividades e na elaboração dos entregáveis. Além disso, por se tratar de uma solução digital acessível a partir de qualquer navegador por usuários devidamente habilitados, o processo de consulta da informação bruta tornou-se muito mais célere, uma vez que a necessidade de realizar incessantes buscas pela localização de planilhas foi substituída pelo simples ato de consulta nos diferentes módulos voltados à entrada de dados. A Figura 3 demonstra de modo simplificado um dos fluxos de registro de dados na plataforma:

Sob a ótica do desafio de Padronização, observou-se novamente o papel essencial exercido pela plataforma. Ao criar ambientes padronizados de registros dos dados, via cadastros em tela ou importação em massa a partir de templates bem definidos, foram estabelecidos padrões únicos de organização dos diferentes tipos de dados de entrada no sistema, contribuindo diretamente para o estabelecimento de um padrão transversal à todas as equipes acompanhadas, contribuindo para fatores como: linguagem universal das equipes (dados estruturados de maneira idêntica para todas as estruturas), facilidade de integração de novos membros no ciclo de gerenciamento (padrões conhecidos facilitam a familiarização), visão transversal de várias TSFs (organizadas sob os mesmos padrões e consolidadas em um mesmo banco de dados), homogeneização de entregáveis (relatórios idênticos para todas as equipes).

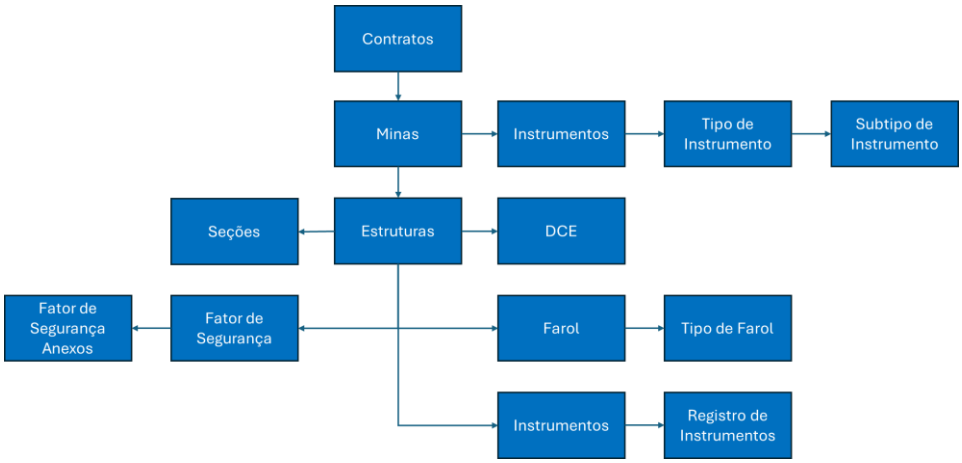


Figura 3. Fluxo de registro de informações na plataforma (Módulo - Cadastro de estruturas)

No que tange à Confiança e Rastreabilidade e ao Dinamismo de Fluxos e Processos das informações, a plataforma proporciona o estabelecimento de fluxos de revisão/aprovação personalizáveis de todos os dados registrados na ferramenta, garantindo, por exemplo, a análise prévia do EoR antes da consolidação definitiva dos dados no banco da plataforma. Ao estabelecer fluxos controlados de entrada, revisão e aprovação de dados brutos de entrada, a plataforma permite às equipes identificarem o status de avaliação de uma determinada informação e a versão mais recente de um documento, garantindo que o dado consolidado no banco de dados seja de fato confiável e atualizado. Além disso, a plataforma conta com um registro histórico de todas as ações realizadas no sistema, permitindo identificar "quando?", "quem?" e "qual foi a ação realizada?", garantindo assim um rastreio completo de todas as atividades realizadas, contribuindo para a realização de auditorias referentes ao fluxo da informação no sistema, e prezando pela integridade de todos os dados armazenados.

A criação de uma plataforma capaz de consolidar um grande volume de dados de diferentes naturezas, de maneira padronizada e bem estruturada, com fluxos controlados de trabalho e módulos integrados à tecnologias como o GeoBIM e o Power BI trouxe consigo outro importante resultado, uma ampla capacidade de transformar dados brutos em indicadores e informações valiosas de forma muito mais eficiente.

A consolidação de um banco de dados único com todas as informações necessárias ao gerenciamento de TSFs, possibilitou a construção de relatórios BI desenvolvidos sob medida de acordo com as necessidades das equipes acompanhadas. Relatórios robustos, dinâmicos e atualizados automaticamente, conforme as informações são alimentadas na plataforma. Através de integração ao Power BI, os relatórios construídos são alocados dentro da própria plataforma, em módulos transversais como Painéis de Segurança e Planejamento, Monitoramento e Controle. O acesso facilitado a estes relatórios provou-se um forte aliado na condução das rotinas das equipes, permitindo que elas dedicassem menos tempo em atividades manuais de consolidação e atualização de relatórios e direcionassem um maior esforço a atividades de interpretação e consolidação técnica das análises realizadas.

Por fim, o módulo GeoBIM trouxe inteligência geográfica como um forte aliado às análise realizados pelas equipes, permitindo a criação de um SIG capaz de consolidar as informações registradas nos demais módulos em uma visão espacial única, permitindo também: a visualização de dados oriundos de levantamentos realizados com o auxílio de aplicativos mobile, câmeras 360º e drones, a visão georreferenciada de modelos BIM tratados em outras ferramentas consolidadas no mercado, como o Leapfrog e a integração direta com camadas de domínio público e/ou privado (Geologia Regional, Manchas de Inundação, Bacias Hidrográficas, dentre outras). Na Figura 4 são apresentados outputs visuais da plataforma.

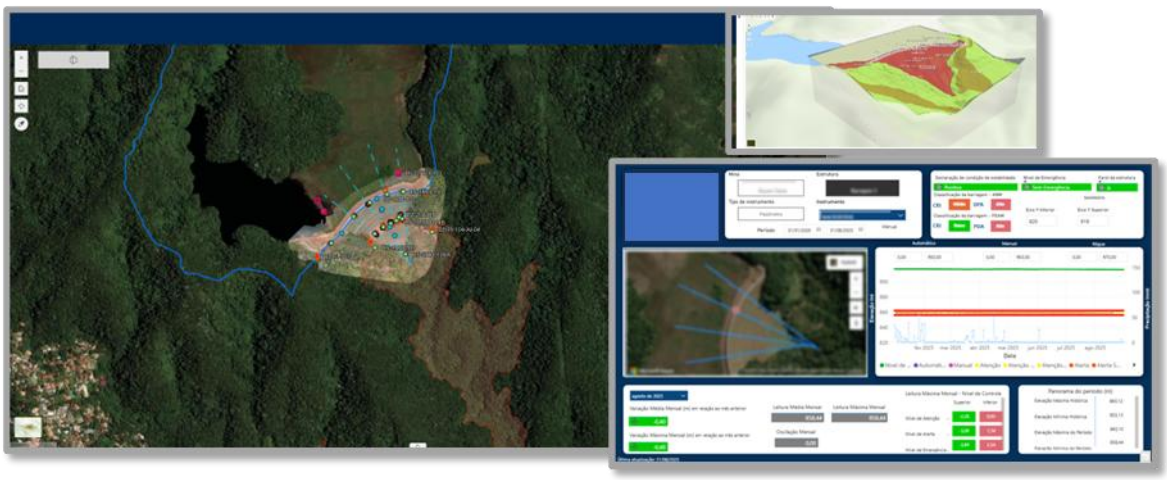


Figura 4. Outputs da plataforma (Módulos – GeoBIM e Painéis de Segurança)

5 CONCLUSÃO E RECOMENDAÇÕES

Este trabalho apresentou e avaliou uma abordagem de gerenciamento digital integrado aplicada à gestão de *Tailings Storage Facilities* (TSFs), estruturada para enfrentar desafios recorrentes de gestão da informação ao longo do ciclo de vida dessas estruturas. A crescente complexidade do gerenciamento de TSFs — marcada por elevado volume de dados, múltiplas fontes e diferentes níveis de confiabilidade — exige soluções que fortaleçam a governança, a rastreabilidade e a disponibilidade de informações para suportar análises técnicas e decisões críticas. Nesse contexto, os resultados obtidos reforçam a relevância da transformação digital como vetor para reduzir fragilidades operacionais e elevar a robustez dos processos de gestão, com suporte ao atendimento a requisitos regulatórios aplicáveis e aos princípios do *Global Industry Standard on Tailings Management* (GISTM).

Em termos de atendimento aos objetivos propostos, observou-se que a abordagem contribuiu para mitigar os principais gargalos associados à gestão da informação em TSFs, por meio da consolidação e padronização de registros, do fortalecimento da confiabilidade e rastreabilidade dos dados e da organização de fluxos de trabalho dinâmicos e auditáveis. A consolidação de informações em um banco de dados único e disciplinar reduziu a dispersão de registros e a dependência de bases heterogêneas, viabilizando maior agilidade e consistência na consulta e utilização dos dados. A padronização de ambientes de registro e importação (via templates e cadastros estruturados) favoreceu linguagem transversal entre equipes e estruturas, contribuindo para a homogeneização de entregáveis e a escalabilidade do processo de gestão em portfólios com múltiplas TSFs.

Adicionalmente, mecanismos de governança incorporados — tais como controle refinado de permissões, trilhas de auditoria e fluxos configuráveis de revisão/aprovação — demonstraram impacto direto na confiabilidade e rastreabilidade das informações, permitindo identificar com clareza a versão vigente de documentos e dados, bem como o histórico de ações (“quem”, “quando” e “o que”). Esses elementos são particularmente relevantes para o suporte ao *Engineer of Record* (EoR), ao reduzir incertezas associadas à atualização e validação dos registros utilizados em análises, recomendações e reportes técnicos.

A integração entre captura de dados de campo e monitoramento (aplicativos móveis, inspeções e consolidação de leituras instrumentais) e recursos analíticos e geoespaciais (BI e GeoBIM) ampliou a capacidade de transformação de dados brutos em informação útil, com ganhos de eficiência operacional e redução de esforço manual para consolidação e atualização de relatórios. Observou-se, assim, que o tempo das equipes pode ser redirecionado de tarefas operacionais repetitivas para atividades de interpretação técnica, verificação crítica e tomada de decisão, reforçando a qualidade do processo de gestão.

Em síntese, as principais contribuições deste trabalho podem ser consolidadas em quatro pontos: (i) demonstrar, por meio de aplicação em portfólio, que uma abordagem digital integrada pode mitigar gargalos típicos de gestão de TSFs associados ao volume e diversidade de dados, ao consolidar informações multidisciplinares em base única e acessível; (ii) evidenciar que a padronização de cadastros, templates e

estruturas de registro favorece consistência transversal entre equipes e estruturas, com impactos diretos na escalabilidade e na homogeneização de entregáveis; (iii) evidenciar que mecanismos de governança, rastreabilidade e auditabilidade, incluindo perfis de acesso, trilhas de auditoria e fluxos de revisão/aprovação, fortalecem a confiabilidade da informação e reduzem incertezas relevantes para o EoR; e (iv) indicar que a integração entre captura digital de campo, consolidação de monitoramento, painéis analíticos (BI) e visualização geoespacial (GeoBIM) amplia a capacidade de transformar dados em informação para suporte à decisão, com ganhos de eficiência e direcionamento do esforço das equipes para análise técnica. Esses achados reforçam o potencial da transformação digital para elevar a governança e a segurança na gestão de TSFs, em alinhamento com os princípios do GISTM e com requisitos regulatórios aplicáveis.

Como recomendação para trabalhos futuros, sugere-se ampliar a quantificação dos ganhos observados por meio de indicadores comparativos (por exemplo, tempo de inspeção e emissão de relatórios, completude de registros e métricas de rastreabilidade), bem como aprofundar a integração com sistemas corporativos e rotinas de auditoria, de modo a fortalecer a avaliação do impacto da digitalização na segurança e na governança de TSFs.

AGRADECIMENTOS

À TPF Engenharia pelo incentivo à pesquisa e ao desenvolvimento de soluções técnicas que atendam os interesses da coletividade.

REFERÊNCIAS BIBLIOGRÁFICAS

Azam, S.; Li, Q. (2010) Tailings dam failures: a review of the last one hundred years. *Geotechnical News*, v. 28, n. 4, p. 50–54.

Bowker, L. N.; Chambers, D. M. (2015) *The risk, public liability, and economics of tailings storage facility failures*. Earthworks. Disponível em: https://files.dnr.state.mn.us/input/environmentalreview/polymet/request/exhibit3.pdf. Acesso em: 22 nov. 2025.

Crous, C.; Marais, L. (2025) Transparency of reporting on tailings storage facilities by the six largest members of the International Council on Mining and Metals. *Resources Policy*, v. 111, art. 105784. DOI: 10.1016/j.resourpol.2025.105784. Disponível em: https://www.sciencedirect.com/science/article/pii/S0301420725003265. Acesso em: 06 mar. 2026.

Franks, D. M. et al. (2021) Tailings facility disclosures reveal stability risks. *Scientific Reports*, v. 11, 5353. DOI: 10.1038/s41598-021-84897-0.

ICMM; UNEP; PRI (2020) *Global Industry Standard on Tailings Management*. Global Tailings Review. Disponível em: https://globaltailingsreview.org/wp-content/uploads/2020/08/global-industry-standard-on-tailings-management.pdf. Acesso em: 13 jan. 2026.

Mining Association of Canada (2021) *A guide to the management of tailings facilities*. Version 3.2 (March 2021). Mining Association of Canada, Ottawa. Disponível em: https://mining.ca/wp-content/uploads/dlm_uploads/2021/06/MAC-Tailings-Guide-Version-3-2-March-2021.pdf. Acesso em: 06 jan. 2026.

UNEP; GRID-Arendal (2017) *Mine tailings storage: safety is no accident*. United Nations Environment Programme (UNEP) / GRID-Arendal. Disponível em: https://miningwatch.ca/sites/default/files/2017-11-unepgrid-minetailingssafety-finalreport_0.pdf. Acesso em: 06 mar. 2026.

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/COBRAMSEG2026.2/16

Integração de Business Intelligence, Inteligência Artificial e Computação em Nuvem no Mapeamento de Solos Colapsíveis e Expansivos do Brasil

Jesce John da Silva Borges
Doutor, Universidade Federal de Pernambuco, Recife, Brasil, jescejohn@gmail.com

Maria Júlia de Oliveira Holanda,
Doutora, Universidade Federal de Pernambuco, Recife, Brasil, mariajulia.holanda@ufpe.br

Larissa Ferreira Gomes de Araújo,
Doutoranda, Universidade Federal de Pernambuco, Recife, Brasil, larissa.ferreira@ufpe.br

Samuel Franca Amorim,
Professor Titular, Universidade Federal de Pernambuco, Recife, Brasil, samuel.famorim@ufpe.br

Silvio Romero de Melo Ferreira,
Professor Titular, Universidade Federal de Pernambuco, Recife, Brasil, silvio.romero@ufpe.br

RESUMO: Solos colapsíveis e expansivos representam problemas para a engenharia no Brasil, exigindo identificação para o planejamento territorial. O objetivo deste trabalho é integrar *Business Intelligence* (BI), Computação em Nuvem e Inteligência Artificial para aprimorar a gestão dessas informações geotécnicas. A metodologia envolveu a consolidação do Banco de Dados de Solos Especiais (BANDASE) utilizando o pacote *Google Workspace*, a elaboração de cartas de suscetibilidade via Redes Neurais Artificiais no programa QGIS, bem como o desenvolvimento de painéis no *Looker Studio* e aplicativos web na plataforma *Google Earth Engine* (GEE). A análise estatística revelou comportamento não paramétrico das variáveis. Nos resultados, baseando-se nas medianas, classificaram-se os solos colapsíveis como Areia Argilosa (SC) e os expansivos como Argila Siltosa de Alta Compressibilidade (CH-MH). O teste não paramétrico de *Mann-Whitney* apontou haver evidência suficiente para concluir que existe diferença estatisticamente significativa entre as medianas referentes às propriedades dos solos colapsíveis e expansivos. As cartas indicaram alta suscetibilidade ao colapso em 27,8% do território nacional e à expansão em 35,9%. Como produtos resultantes, obtiveram-se os Painéis de *Business Intelligence* de Solos Expansivos e Colapsíveis (PABISEC) e os Aplicativos de Solos Expansivos e Colapsíveis (APPSEC). Evidencia-se que estas plataformas oferecem visualizações interativas, transformando o grande volume de dados em conhecimento acessível e proporcionando suporte dinâmico à tomada de decisão em engenharia.

PALAVRAS-CHAVE: Solos Expansivos e Colapsíveis, Cartas de suscetibilidade, Banco de Dados, *Business Intelligence*, Aplicativos.

ABSTRACT: Collapsible and expansive soils pose problems for engineering in Brazil, requiring identification for territorial planning. The objective of this work is to integrate Business Intelligence (BI), Cloud Computing, and Artificial Intelligence to improve the management of this geotechnical information. The methodology involved consolidating the Special Soils Database (BANDASE) using the Google Workspace suite, generating susceptibility maps via Artificial Neural Networks in QGIS software, as well as developing dashboards in Looker Studio and web applications on the Google Earth Engine (GEE) platform. Statistical analysis revealed non-parametric behavior of variables. In the results, based on medians, collapsible soils were classified as Clayey Sand (SC) and expansive ones as High Compressibility Silty Clay (CH-MH). The non-parametric Mann-Whitney test indicated sufficient evidence to conclude that there is a statistically significant difference between the medians regarding the properties of collapsible and expansive soils. The maps indicated high susceptibility to collapse in 27.8% of the national territory and to expansion in 35.9%. As resulting products,

the Expansive and Collapsible Soils Business Intelligence Dashboards (PABISEC) and the Expansive and Collapsible Soils Applications (APPSEC) were obtained. It is evidenced that these platforms offer interactive visualizations, transforming the large volume of data into accessible knowledge and providing dynamic support for decision-making in engineering.

KEYWORDS: Expansive and Collapsible Soils, Susceptibility Maps, Database, Business Intelligence, Applications.

1 INTRODUÇÃO

Os solos não saturados com comportamento instável, especificamente os colapsíveis e expansivos, impõem desafios à engenharia geotécnica brasileira. O desconhecimento sobre a ocorrência e o comportamento destes solos é frequentemente a causa raiz de patologias em fundações, pavimentos e infraestruturas urbanas, gerando prejuízos econômicos que poderiam ser mitigados com investigações preliminares adequadas (Ferreira, 1995).

No cenário atual, a engenharia civil vivencia a era da Indústria 4.0, onde a gestão eficiente de dados se torna um ativo valioso. Embora exista um volume considerável de pesquisas acadêmicas sobre solos especiais no Brasil, essas informações encontram-se historicamente dispersas em teses, dissertações e anais de congressos, dificultando o acesso rápido e a análise integrada por parte dos profissionais. A cartografia geotécnica tradicional, embora essencial, muitas vezes carece de dinamismo e interatividade, limitando-se a mapas estáticos que podem se tornar obsoletos rapidamente (Borges, 2024).

Diante dessa lacuna, este artigo apresenta uma abordagem multidisciplinar que integra Geotecnia, *Business Intelligence* (BI) e Ciência de Dados. O objetivo principal é detalhar a construção do Banco de Dados de Solos Especiais (BANDASE), a elaboração de cartas interpretativas, a implementação dos Painéis de *Business Intelligence* de Solos Expansivos e Colapsíveis (PABISEC) e o desenvolvimento dos Aplicativos de Solos Expansivos e Colapsíveis (APPSEC). Essa metodologia propõe uma mudança de paradigma: da consulta estática para a análise interativa, permitindo a democratização do conhecimento geotécnico e o suporte à tomada de decisão em projetos de engenharia.

2 MATERIAIS E MÉTODOS

A metodologia adotada integrou ferramentas de Geotecnia, Ciência de Dados e Geoprocessamento. Para a gestão e processamento, utilizou-se o pacote *Google Workspace* (*Drive,* Planilhas, Documentos), garantindo a integridade dos dados em nuvem (*Cloud Computing*). As análises espaciais foram realizadas no programa QGIS (versão 3.28 "*Firenze*") e as estatísticas no programa Jamovi (versão 2.3.21). Adicionalmente, empregou-se o *Google Looker Studio* para a estruturação dos painéis interativos de *Business Intelligence* e a plataforma *Google Earth Engine* (GEE) para o processamento de dados em nuvem e desenvolvimento dos aplicativos web.

2.1 Construção do Banco de Dados de Solos Especiais (BANDASE) e da Análise Estatística

O BANDASE representa a evolução de esforços anteriores de catalogação iniciados na década de 1990 (Ferreira, 1990). Para a sua consolidação atual, realizou-se uma Revisão Sistemática da Literatura abrangendo as principais bases de dados acadêmicas (Capes, SciELO, BDTD, Google Acadêmico).

A arquitetura do banco de dados foi desenvolvida inteiramente em ambiente de Computação em Nuvem (*Cloud Computing*), utilizando o *Google* Planilhas integrado ao *Google Drive*. Essa escolha estratégica permitiu a colaboração em tempo real da equipe de pesquisa e garantiu a integridade e segurança dos dados. O banco foi estruturado com atributos (campos) que abrangem identificação da obra, localização, propriedades físicas, mineralogia, resultados de ensaios de campo e laboratório, e classificação pedológica conforme o Sistema Brasileiro de Classificação de Solos (Santos et al., 2018).

A análise dos dados armazenados no BANDASE foi realizada com o auxílio do programa estatístico Jamovi. Inicialmente, aplicou-se o teste de normalidade de *Shapiro-Wilk* para verificar a distribuição das variáveis geotécnicas. Confirmada a predominância de distribuições não paramétricas, adotou-se a mediana como medida de tendência central para a caracterização dos solos. O teste não paramétrico de *Mann-Whitney* foi empregado para verificar a existência de diferenças estatisticamente significativas entre os grupos de solos colapsíveis e expansivos.

2.2 Cartas de Suscetibilidade via Redes Neurais Artificiais (RNA)

Para a elaboração das cartas interpretativas baseadas em Inteligência Artificial, adotou-se o modelo de Rede Neural Artificial (RNA) denominado "BR03", desenvolvido por Holanda (2022). Este modelo foi estruturado a partir de uma amostra de 393 dados (237 para treinamento, 78 para seleção e 78 para teste) e utiliza como variáveis de entrada condicionantes climatológicos, pedológicos e geológicos.

O processamento geoespacial integrou três bases cartográficas fundamentais: (i) Tipos climáticos segundo Thornthwaite (Embrapa, 1:1.000.000); (ii) Pedologia (IBGE, 1:250.000); e (iii) Geologia/Províncias estruturais (IBGE, 1:250.000). Inicialmente, realizou-se a padronização do Sistema Geodésico de Referência para SIRGAS2000 (EPSG 4674) e a correção topológica de todas as camadas vetoriais no programa QGIS.

A metodologia consistiu na seleção dos campos de atributos pertinentes (tipos climáticos, ordem do solo e províncias estruturais), seguida pela aplicação das ferramentas de "Dissolve" (agregação de registros idênticos) e "União" (Union), resultando em uma única camada vetorial contendo a interseção dos três condicionantes.

A tabela de atributos resultante foi exportada (formato CSV) e processada no programa *Neural Designer*, onde se aplicou a equação matemática da RNA. O modelo retorna um índice numérico decimal variando de 0 a 1:

- Valores tendendo a 0 (zero) indicam alta suscetibilidade ao colapso;
- Valores tendendo a 1 (um) indicam alta suscetibilidade à expansão.

A definição das classes de suscetibilidade (alta, média e baixa) foi determinada pela análise de histogramas gerados a partir da sobreposição dos dados reais do BANDASE sobre a carta interpretativa. Áreas urbanas sem informação de condicionantes e corpos d'água foram excluídos da classificação.

2.3 Desenvolvimento dos Painéis de BI (PABISEC)

A arquitetura do PABISEC foi desenvolvida no ecossistema *Google Workspace*, utilizando o Drive como repositório em nuvem (*Data Warehouse*) e o *Google* Planilhas para estruturar os dados. O processamento no *Looker Studio* seguiu um fluxo metodológico de cinco etapas: (i) tratamento dos dados; (ii) conexão com a fonte de dados; (iii) modelagem (ajuste de dimensões e métricas); (iv) criação de visualizações analíticas; e (v) estruturação da interface de usuário com navegação lateral. O sistema opera com sincronização automática em tempo real, garantindo que qualquer inserção no BANDASE reflita instantaneamente nos painéis, eliminando a necessidade de reprocessamento manual.

2.4 Desenvolvimento dos Aplicativos (APPSEC)

Para a disponibilização dos produtos cartográficos em plataforma web, optou-se pelo desenvolvimento de aplicativos próprios, denominados APPSEC (Aplicativos de Solos Expansivos e Colapsíveis). Diante da robustez dos dados gerados nesta pesquisa (arquivos vetoriais superiores a 490 MB), utilizou-se o *Google Earth Engine* (GEE), uma plataforma de computação em nuvem que oferece alta capacidade de armazenamento e processamento de grandes conjuntos de dados geoespaciais (Gorelick et al., 2017).

O desenvolvimento envolveu o uso da linguagem de programação JavaScript (JS) para as funções lógicas e de geoprocessamento, HTML (*HyperText Markup Language*) e CSS (*Cascading Style Sheets*) para o design da interface gráfica. Preliminarmente, os dados espaciais (11 vetoriais e 3 matriciais) receberam tratamento no programa QGIS, onde tabelas de atributos complexas foram simplificadas e camadas vetoriais densas foram convertidas para formato raster (matricial) para viabilizar a importação no GEE. O algoritmo

final integrou cerca de 3.000 linhas de código em cada aplicativo, estruturando a visualização das cartas interpretativas e mapas fundamentais.

3 RESULTADOS

A integração das tecnologias descritas resultou em um ecossistema de dados robusto, cujos principais achados são discutidos a seguir.

3.1 Caracterização Geotécnica via BANDASE

A catalogação resultou em 526 registros validados, sendo 267 referentes a solos colapsíveis e 259 a solos expansivos. A análise estatística descritiva, baseada em medianas, revelou distinções claras quanto à textura: os solos expansivos apresentam maior concentração de frações finas, enquanto os colapsíveis predominam em frações grossas. Essa característica permitiu enquadrá-los, respectivamente, nas categorias de solos finos e grossos pelo Sistema Unificado de Classificação de Solos (SUCS), e como Argila Siltosa e Areia Argilosa pela classificação triangular da *Mississippi River Commission* (Figura 1).

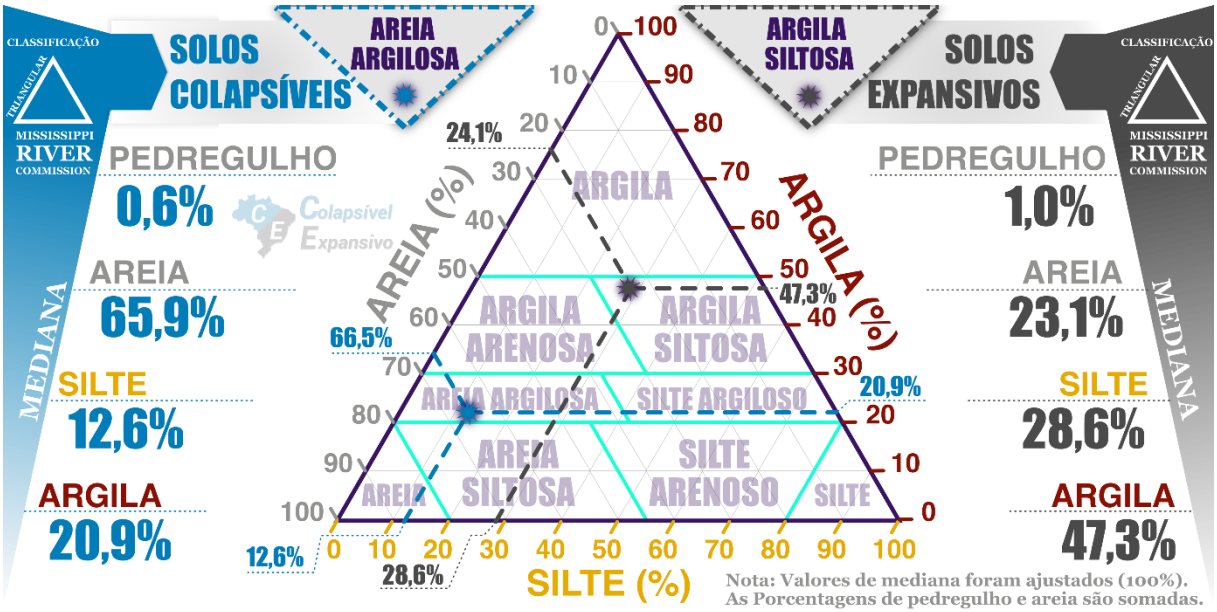


Figura 1. Classificação triangular da *Mississippi River Commission*.

Em relação à plasticidade, os solos expansivos exibem valores mais elevados nos limites de consistência, sendo classificados pelo SUCS como Argila Siltosa de Alta Compressibilidade (CH-MH). Em contraste, os solos colapsíveis foram categorizados como Areia Argilosa (SC).

A distinção entre os grupos foi validada estatisticamente pelo teste não paramétrico de *Mann-Whitney*, que apontou diferenças significativas entre as medianas das propriedades. Adicionalmente, os resultados mostraram-se compatíveis com as classificações das Redes Neurais PE04 e PE07 de Holanda (2022), corroborando o comportamento geotécnico identificado.

3.2 Cartas da Suscetibilidade (SIGSEC)

A aplicação do modelo de RNA resultou em duas cartas interpretativas. Para os solos colapsíveis, constatou-se alta suscetibilidade em 27,8% do território nacional (média em 3,4% e baixa em 16,8%). Geograficamente, as áreas críticas concentram-se na região Centro-Oeste (centro do MT, sul do MS e sul de GO), na porção oeste da região Sudeste (com destaque para SP) e no norte do Pará.

Em relação aos solos expansivos, a alta suscetibilidade abrange 35,9% da área (média em 9,8% e baixa em 3,7%). A ocorrência predominou nas regiões Nordeste e Sul, estendendo-se à faixa litorânea do Sudeste

(SP ao ES) e aos estados do AC, AP, RR e RJ. Notou-se uma correlação direta entre a alta suscetibilidade e a ocorrência da classe Vertissolo no Nordeste e Pantanal (Figura 2).

A validação do modelo, realizada pela superposição dos registros pontuais do BANDASE sobre as cartas geradas, demonstrou boa eficácia preditiva. A aplicação da Matriz de Confusão resultou nas seguintes métricas: acurácia de 74,3%, sensibilidade de 72,1% e especificidade de 77,4%.

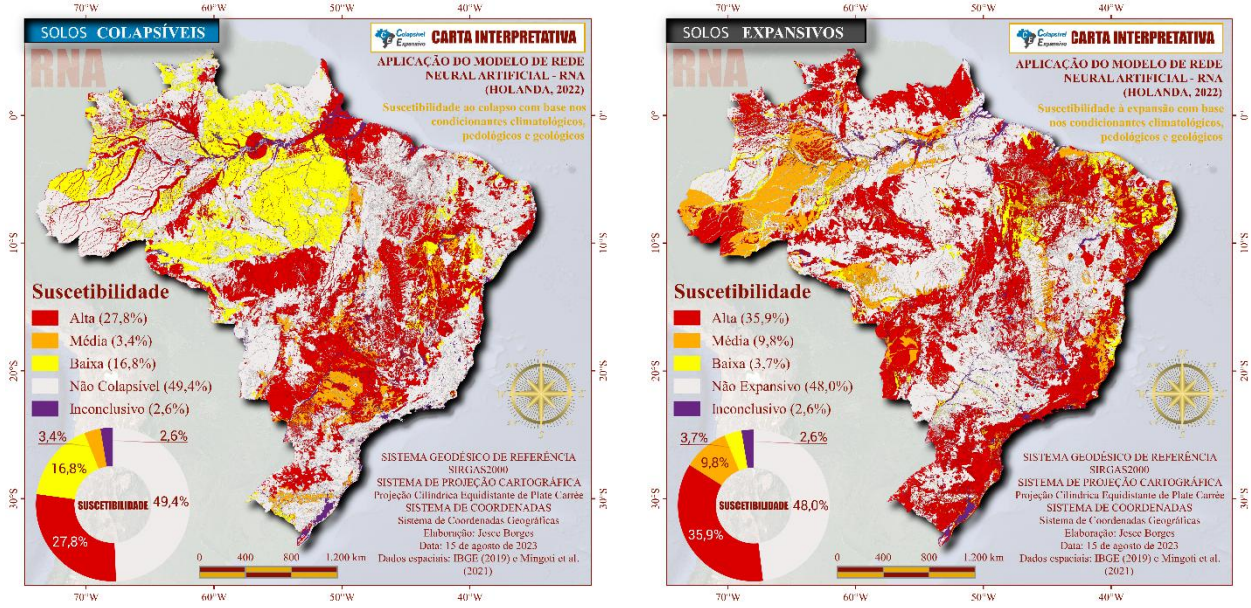


Figura 2. Carta interpretativa resultante da aplicação de RNA para solos colapsíveis e expansivos.

3.3 *Business Intelligence* e Interatividade (PABISEC)

Os Painéis de *Business Intelligence* de Solos Expansivos e Colapsíveis (PABISEC) materializa o conceito de *Business Intelligence* aplicado à geotecnia, transformando o volume massivo de dados do BANDASE em conhecimento. A plataforma é composta por 6 (seis) painéis interativos (Tabela 1), acessíveis via web, que permitem análises desde a escala continental até a municipal:

- PABISEC - Climatologia: explora a classificação de Thornthwaite (1948), permitindo visualizar os tipos climáticos e as suscetibildiade ao colapso e à expansão;
- PABISEC - Pedologia: detalha a taxonomia dos solos brasileiros (ordens, subordens e grandes grupos), evidenciando a predominância de Latossolos (31,7%) e permitindo correlações com os critérios de suscetibilidade ao colapso e à expansão;
- PABISEC - Cartas Interpretativas: apresenta os resultados dos métodos convencionais (critérios conservador, ponderado e inverso), facilitando a comparação visual entre diferentes cenários;
- PABISEC - Cartas RNA: exibe os resultados do modelo de Inteligência Artificial, incluindo métricas de validação (matriz de confusão);
- PABISEC - BANDASE: focado na caracterização geotécnica, este painel inova ao permitir que o usuário acesse os dados atinentes aos solos colapsíveis e expansivos, bem como plote seus próprios dados (LL, IP, %Argila) para gerar automaticamente Cartas de Plasticidade e Atividade, verificando o enquadramento em critérios de colapso/expansão em tempo real;
- PABISEC - Pernambuco: um recorte regional que digitaliza e torna interativo o mapeamento de Amorim (2004).

Tabela 1. Acesso aos Painéis de *Business Intelligence* (PABISEC).

Painel PABISEC	Link de Acesso	QR Code
Climatologia	Acessar Painel	
Pedologia	Acessar Painel	
Cartas Interpretativas	Acessar Painel	
Cartas Interpretativas RNA	Acessar Painel	
BANDASE	Acessar Painel	
Pernambuco	Acessar Painel	

As funcionalidades implementadas englobam filtragem dinâmica (por Estado, tipo de solo), possibilitando análises visuais instantâneas. A integração com bases do Google assegura a geolocalização dos pontos de coleta, democratizando o acesso a informações que antes estavam dispersas em documentos estáticos (Figura 3).

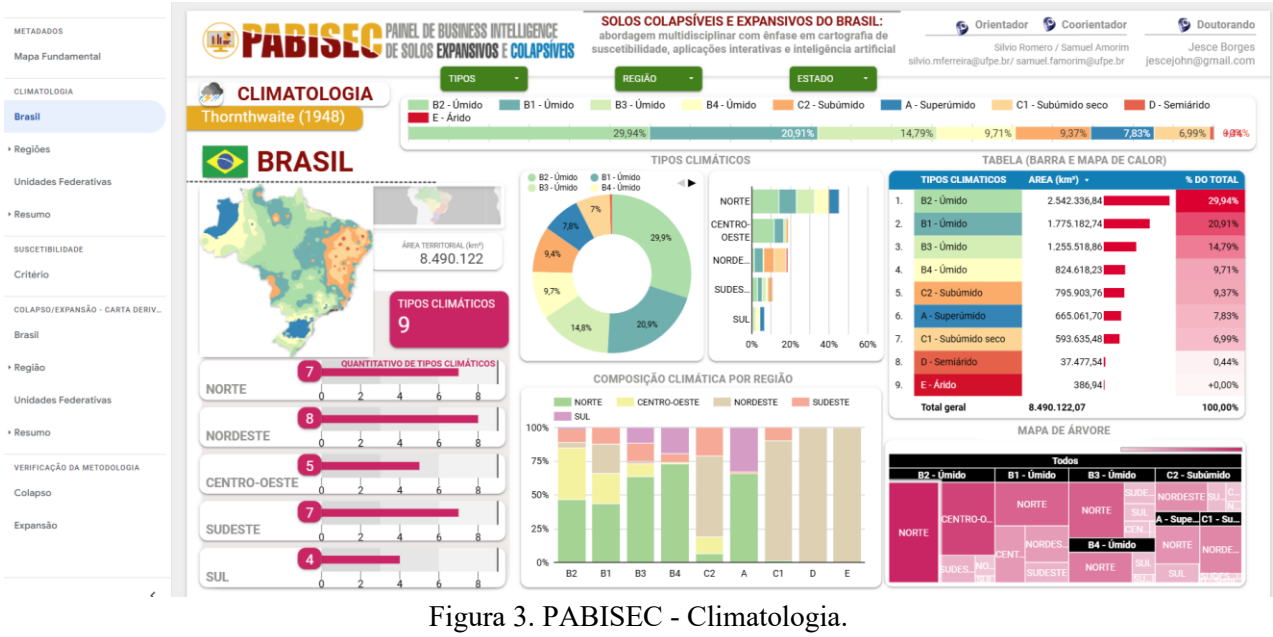


Figura 3. PABISEC - Climatologia.

3.4 Aplicativos de Solos Expansivos e Colapsíveis (APPSEC)

Como resultado do processamento em nuvem, foram obtidos 3 (três) aplicativos web interativos, acessíveis via navegador e independentes de sistema operacional. Os aplicativos foram segmentados conforme a abrangência e a metodologia de origem dos dados:

- APPSEC - PE: disponibiliza os produtos cartográficos elaborados por Amorim (2004) para o estado de Pernambuco;
- APPSEC - BR: apresenta as cartas de suscetibilidade e mapas fundamentais desenvolvidos para todo o território nacional (Borges, 2024);
- APPSEC - BR RNA: dedicado exclusivamente às cartas interpretativas elaboradas por Borges (2024) a partir do modelo matemático de Redes Neurais Artificiais desenvolvido por Holanda (2022).

Tabela 2. Acesso aos Aplicativos de Solos Expansivos e Colapsíveis (APPSEC).

Painel APPSEC	Link de Acesso	QR Code
Pernambuco	Acessar Painel	
Brasil	Acessar Painel	
Brasil RNA	Acessar Painel	

Essas ferramentas proporcionam benefícios diretos à engenharia prática, tais como: acessibilidade e gratuidade, permitindo consulta por qualquer dispositivo com internet; ausência de instalação, eliminando a necessidade de programas SIG pesados; e interatividade, permitindo que o usuário adicione marcadores em locais de obra para obter instantaneamente a classificação da suscetibilidade do solo (alta, média ou baixa) e os atributos pedológicos locais (Figura 4).

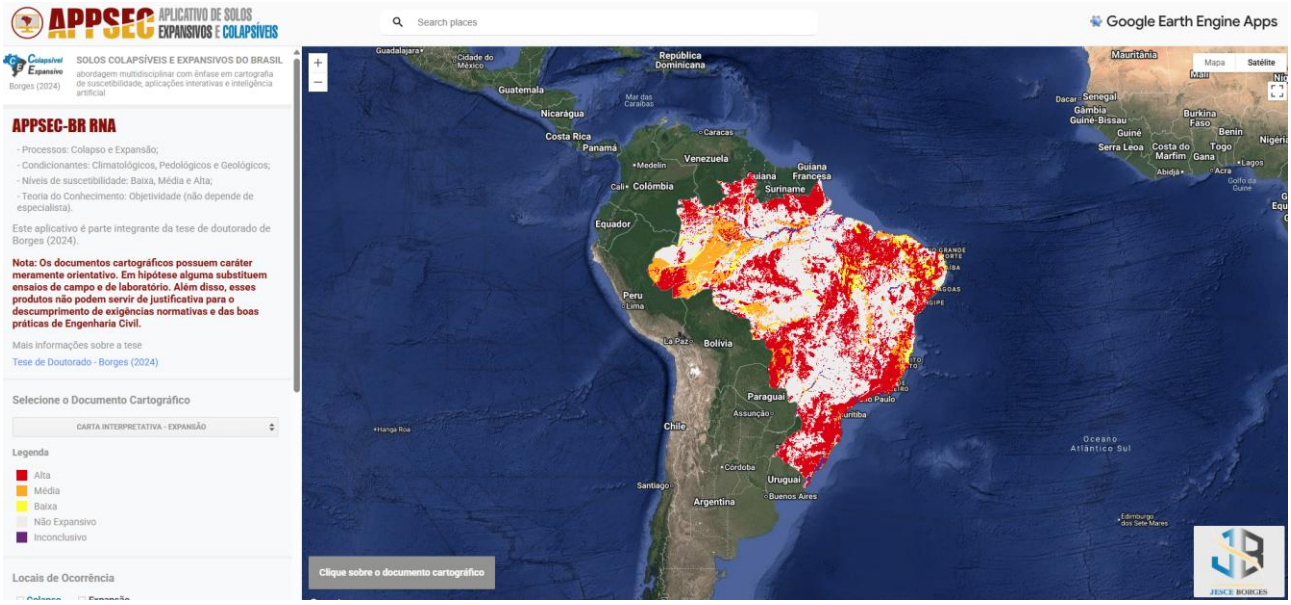


Figura 4. APPSEC – Brasil RNA.

4 CONCLUSÕES

A pesquisa demonstrou que a integração entre a Engenharia Geotécnica e as tecnologias de Ciência de Dados é viável e essencial para mitigar os riscos associados aos solos não saturados.

O desenvolvimento do BANDASE consolidou o conhecimento geotécnico disperso, revelando, através da estatística descritiva, distinções claras de comportamento físico dos dois solos. Os solos colapsíveis caracterizam-se predominantemente como Areia Argilosa (SC), enquanto os expansivos se enquadram como Argila Siltosa de Alta Compressibilidade (CH-MH). O teste de *Mann-Whitney* confirmou a significância estatística dessas diferenças, fornecendo parâmetros de referência (medianas) úteis para anteprojetos.

As cartas de suscetibilidade, elaboradas via Redes Neurais Artificiais, indicaram alta suscetibilidade ao colapso em 27,8% do território nacional e à expansão em 35,9%.

Por fim, a implementação dos painéis PABISEC e dos aplicativos APPSEC introduz uma inovação na forma como consumimos dados geotécnicos. Ao migrar da cartografia estática para plataformas dinâmicas em nuvem, o trabalho democratiza o acesso à informação, oferecendo à comunidade técnica ferramentas ágeis para a identificação preliminar. Ressalta-se, contudo, que tais produtos possuem caráter orientativo e não substituem a realização de ensaios de campo e laboratório específicos para cada obra.

REFERÊNCIAS BIBLIOGRÁFICAS

Amorim, S. F. (2004) *Contribuição à cartografia geotécnica: sistema de informações geográficas dos solos expansivos e colapsíveis do Estado de Pernambuco*. Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Civil, Universidade Federal de Pernambuco, Recife, 244 p.

Borges, J. J. S. (2024) *Solos Colapsíveis e Expansivos do Brasil: Abordagem Multidisciplinar com Ênfase em Cartografia de Suscetibilidade, Aplicações Interativas e Inteligência Artificial*. Tese de Doutorado, Programa de Pós-Graduação em Engenharia Civil, Universidade Federal de Pernambuco, Recife.

Ferreira, S. R. M. (1990) Banco de dados de solos especiais: colapsíveis do estado de Pernambuco. In: Congresso Brasileiro de Mecânica dos Solos e Engenharia de Fundações, Salvador. *Anais...* ABMS. p. 81–86.

Ferreira, S. R. M. (1995) *Colapso e Expansão de Solos Não Saturados do Nordeste Brasileiro. Tese de Doutorado*, COPPE/UFRJ, Rio de Janeiro.

Gorelick, N.; Hancher, M.; Dixon, M.; Ilyushchenko, S.; Thau, D.; Moore, R. (2017) Google Earth Engine: Planetary-scale geospatial analysis for everyone. Remote Sensing of Environment, v. 202, p. 18–27.

Holanda, M. J. O. (2022) *Solos colapsíveis e expansivos no Brasil: classificação da suscetibilidade de ocorrência aplicando redes neurais artificiais*. Tese de Doutorado, Programa de Pós-Graduação em Engenharia Civil, Universidade Federal de Pernambuco, Recife.

Santos, H. G. et al. (2018) *Sistema Brasileiro de Classificação de Solos*. 5. ed., Embrapa, Brasília, 356 p.

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/COBRAMSEG2026.2/17

Integração de Campos Estocásticos e Aprendizado de Máquina para Previsão de Condições Críticas em Aterros Ferroviários Lateríticos Amazônicos

Felipe Santos de Almeida
Engenheiro Geotécnico, Doutorando, POLI-USP, São Paulo, Brasil, almeida.felipe@usp.br

Luiz Felipe Goulart Fiscina
Engenheiro Geotécnico, Doutorando, POLI-USP, São Paulo, Brasil, luizfiscina@usp.br

David Sebastian Calpa
Engenheiro Geotécnico, Pós-Doutorando, POLI-USP, São Paulo, Brasil, sebastiancalpaj@usp.br

Marcos Massao Futai
Professor Titular da Escola Politécnica da Universidade de São Paulo, São Paulo, Brasil, futai@usp.br

RESUMO: Este trabalho avalia uma estrutura preditiva para antecipação de respostas hidrológicas em taludes de aterros lateríticos localizados na bacia do rio Pindaré, Maranhão (Amazônia). A pesquisa tem como ponto de partida resultados prévios que validaram a relação entre a curva de retenção de água (SWRC) e o índice de vazios para um solo recompactado da Formação Itapecuru, representativo da região de estudo, fornecendo base para a representação da variabilidade hidráulica do material. A metodologia compara dois cenários: homogêneo (determinístico) e heterogêneo (probabilístico). No cenário heterogêneo, a variabilidade espacial é incorporada por campos estocásticos, acoplados a simulações de fluxo transiente no RS2. Séries diárias de precipitação do CHIRPS e respostas simuladas em pontos de interesse (sensores virtuais) foram utilizadas para treinar um modelo de aprendizado de máquina (XGBoost) com previsão multi-horizonte (3, 7 e 15 dias), adotando como *benchmark* comparativo os dados obtidos pelo sensor alvo no caso homogêneo. Os resultados indicam bom desempenho global, porém mostram que o R^2 isoladamente não garante utilidade operacional, devido ao ruído nas previsões e à tendência de subpredição, mais pronunciada em horizontes longos. A abordagem probabilística reduz a instabilidade das estimativas e fornece intervalos (Q05–Q95) capazes de englobar o *benchmark* nas regiões de transição, reforçando o potencial do framework como suporte à previsão antecipada e à avaliação de excedência de limiares em aplicações de monitoramento.

PALAVRAS-CHAVE: Amazônia; solos lateríticos; campos estocásticos; machine learning; fluxo não-saturado.

ABSTRACT: This study evaluates a predictive framework to anticipate hydrological responses in lateritic embankment slopes located in the Pindaré River basin, Maranhão (Brazilian Amazon). The approach builds on previous findings that validated the relationship between the soil-water retention curve (SWRC) and void ratio for a recompacted soil from the Itapecuru Formation, representative of the study area, providing a basis to represent hydraulic variability. Two scenarios are compared: a homogeneous (deterministic) embankment and a heterogeneous (probabilistic) embankment. In the heterogeneous case, spatial variability is introduced through stochastic fields, coupled with transient seepage simulations in RS2. Daily precipitation series from CHIRPS and simulated responses at selected points (virtual sensors) were used to train an XGBoost model for multi-horizon forecasting (3, 7, and 15 days), adopting as a comparative benchmark the target sensor response obtained under the homogeneous scenario. Results show good overall performance; however, they also indicate that R^2 alone is insufficient for operational assessment due to prediction noise and a systematic underestimation trend, which becomes more pronounced for longer horizons. The probabilistic framework reduces instability in the predictions and provides uncertainty bounds (Q05–Q95) that encompass the benchmark during transition periods, highlighting its potential to support early forecasting and threshold exceedance assessment in geotechnical monitoring applications.

KEYWORDS: Amazon; lateritic soils; stochastic fields; machine learning; unsaturated flow.

1 INTRODUÇÃO

Obras lineares, como rodovias e ferrovias, frequentemente requerem a execução de aterros. Em geral os aterros da Estrada de ferro Carajás (EFC) são construídos utilizando solos lateríticos, uma vez que esses materiais são de ampla disponibilidade regional e apresentam desempenho geralmente satisfatório em processos de compactação (Santha Kumar et al., 2022). Entretanto, mesmo quando há adequado controle construtivo, estes aterros em regiões tropicais permanecem suscetíveis a deslizamentos em função da elevada variabilidade climática local. Nesse contexto, o entendimento das propriedades hidráulicas em condição não saturada torna-se fundamental, a saber que a geração de poropressões excessivas pode ocorrer não apenas pela elevação do nível freático interno, mas também pelo avanço da frente de infiltração associada às chuvas. Esses processos reduzem as tensões efetivas e comprometem a resistência ao cisalhamento, favorecendo a ocorrência de mecanismos de instabilidade (Fredlund & Rahardjo, 1993). Além disso, a variabilidade interna dessas estruturas causada pela compactação não pode ser descartada, já que os métodos de controle utilizam resultados pontuais para aferir a qualidade de compactação destas estruturas.

Os campos aleatórios espacialmente correlacionados têm se mostrado eficazes para representar heterogeneidades geotécnicas (Li et al., 2016), ainda assim, sua integração com técnicas de aprendizado de máquina para previsão probabilística multi-horizonte permanece pouco explorada em engenharia geotécnica. Neste contexto, o presente estudo propõe uma estrutura integrada que combina análise numérica transiente em meio não saturado e aprendizado de máquina para previsão multi-horizonte de poropressão em sensores virtuais. A chuva diária é aplicada como condição de contorno no modelo numérico, e as respostas são monitoradas por *History Queries* (HQs), considerados como sensores virtuais posicionados no domínio, com foco na previsão do sensor-alvo (HQ12) em horizontes de $+3$, $+7$ e $+15$ dias. Em cada tempo t_0, o modelo recebe como entradas a chuva observada em t_0, as leituras de poropressão em t_0(HQ8, HQ12 e HQ16) e a chuva prevista associada ao horizonte a partir da série temporal utilizada, permitindo emitir previsões compatíveis com aplicações de alerta antecipado. O algoritmo adotado para os dois cenários avaliados é o XGBoost, calibrado com separação temporal (treino/validação/teste) para evitar vazamento de informação.

A contribuição central do trabalho está na comparação entre um cenário homogêneo e um cenário heterogêneo, em que a variabilidade do aterro é representada por campos estocásticos espacialmente correlacionados aplicados ao material compactado. Essa variabilidade é incorporada via expansão de Karhunen–Loève (KLE) com covariância Matérn, fundamentada em calibração da variação da SWCC de acordo com a mudança de densidade do material previamente validada em Almeida et al. (2025). Além da avaliação determinística, o estudo introduz uma leitura probabilística baseada na distribuição de predições das leituras do instrumento para cada caso observado a partir dos campos estocásticos, permitindo comparar de forma consistente como a heterogeneidade altera não apenas o valor previsto, mas também a incerteza da ocorrência de condições críticas no horizonte de previsão.

Os resultados principais indicam que, embora os modelos apresentem bom desempenho global (alto R^2), a utilidade prática em séries temporais depende fortemente da análise de MAE/RMSE e do comportamento ao longo do tempo, já que o erro cresce com o aumento do horizonte de previsão. No caso determinístico, observou-se ruído associado às variações de precipitação e boa aderência às transições para horizontes curtos (3 e 7 dias), enquanto no horizonte de 15 dias ocorre perda de sensibilidade e suavização do sinal. Já a abordagem probabilística promove maior estabilidade das estimativas e fornece intervalos Q05–Q95 que englobam o benchmark sobretudo nas regiões de transição, embora persista tendência de subpredição, mais evidente em horizontes longos.

2 MATERIAIS E MÉTODOS

2.1 Área de estudo

O presente estudo foi desenvolvido em um trecho de aterro da EFC, localizado nas proximidades do km 374, inserido na Bacia Hidrográfica do Rio Pindaré. O trabalho de Silva et al. (2025), a partir de uma análise de suscetibilidade, indica a ocorrência de setores com elevada propensão a deslizamentos na plataforma ferroviária, contribuindo para a necessidade de melhor compreensão do comportamento geotécnico dessas estruturas. No mesmo estudo, observa-se no inventário elaborado pelos autores diversas ocorrências de

instabilidades em trechos de aterro, reforçando a necessidade de investigações e avaliações mais detalhadas sobre os mecanismos que controlam esse tipo de evento. Na Figura 1 está ilustrado um exemplo de ruptura registrada em um aterro nas proximidades da área de estudo.



Figura 1 - Exemplo de ruptura ocorrida em um aterro ferroviário situado próximo a área de estudo (KM-378).

2.2 Dados de precipitação

Os dados de precipitação foram obtidos a partir do produto orbital CHIRPS (Climate Hazards Group InfraRed Precipitation with Station Data), amplamente utilizado em regiões com baixa densidade de estações pluviométricas (Dos Santos Silva et al., 2023). O CHIRPS fornece séries diárias com resolução espacial de 0,05° (≈ 5 km) desde 1981. Para este estudo, foi extraída a série de 2015 a 2025 para um pixel representativo (Lat.: −4,26; Long.: −46,53), próximo ao km 375 da ferrovia, por meio da plataforma Climate Engine, que permite consultar e baixar séries temporais derivadas de sensoriamento remoto (Huntington et al., 2017). A Figura 2 apresenta os acumulados diários de chuva nesse ponto.

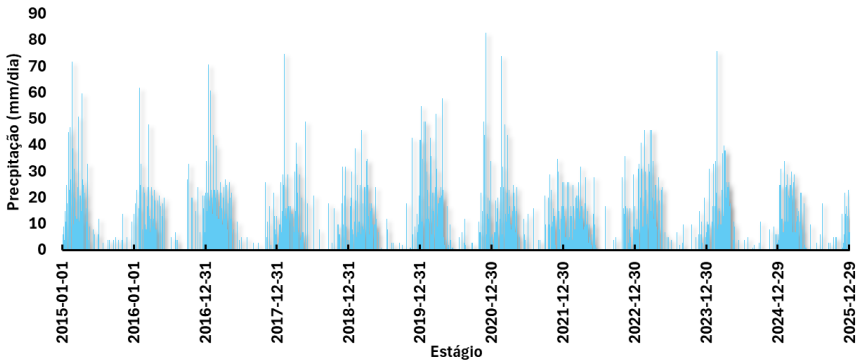


Figura 2 - Série temporal dos acumulados diários de precipitação (2015 à 2025)

2.3 Dados de entrada, modelagem numérica e aplicação de aprendizado de máquina (ML).

Esta parte da metodologia foi organizada em duas etapas principais: (i) geração de séries temporais sintéticas por análise de fluxo transiente no RS2 distribuído pela Rocscience e (ii) previsão multi-horizonte com aprendizado de máquina, comparando cenários homogêneo e heterogêneo.

Na etapa numérica, simulou-se fluxo transiente em meio não saturado em uma seção simplificada de um aterro ferroviário próximo ao KM-375, aplicando chuva diária como condição de contorno variável, conforme a formulação do RS2. As respostas hidrológicas foram capturadas por History Queries (HQ), atuando como sensores virtuais para exportar séries diárias de poropressão (kPa) em HQ8 (topo do aterro), HQ16 (fundação) e HQ12 (meio do talude) (). O aterro representado no modelo numérico tem como dimensões principais 17,5 metros de altura, largura de crista de 33 metros e taludes com inclinação de 1,5H:1V.

No cenário homogêneo, as propriedades do aterro foram mantidas constantes; no heterogêneo, a variabilidade do "Aterro compactado" foi representada por campos estocásticos via KLE com covariância Matérn (3/2), prática consolidada em geotecnia (Figura 3 – a e b) (Feng et al., 2025), os parâmetros de flutuabilidade utilizados foram de 5 na direção X e 2 na direção Y em uma malha de elementos finitos de 1x1 m.

Com base no trabalho de Almeida et al. (2025), que validou a calibração e a aplicação de um modelo matemático capaz de representar os efeitos da variação de densidade na curva de retenção de água de solos compactados, cada realização foi utilizada para converter a variabilidade espacial em termos do parâmetro θ_s, estimado a partir da variação de densidade inerente aos campos estocásticos gerados, além disto o estudo realizado apresenta ainda as características geotécnicas do material utilizado nas análises. O número de iterações (200) na simulação de Monte Carlo foi estabelecido a partir da convergência da média espacial dos campos gerados, observada pela estabilização da variação incremental dessa estatística ao longo das realizações (Figura 3 – c).

Na etapa de ML, o XGBoost previu o sensor HQ12 em horizontes $h = \{3,7,15\}$ dias, configurado para previsão multi-horizonte de séries temporais (Głowacki & Bortnowski, 2025). Para cada t_0, as entradas incluíram chuva observada, poropressões dos sensores e chuva prevista em $[t_0 + h]$ (Figura 3 – d). O particionamento temporal utilizado consistiu na divisão de 7 anos iniciais para o treino e validação (70/30) e 3 anos posteriores para teste, evitando o vazamento de informação (Figura 3 – e), além disto foi realizada a otimização dos hiperparâmetros do modelo via Optuna/TPE com 150 iterações (Otimização Bayesiana) (Figura 3 – f) (Akiba et al., 2019). No caso heterogêneo para cada amostra gerada a partir das iterações dos campos estocásticos foi obtida uma predição, ao final os resultados foram resumidos em métricas estatísticas da variabilidade dos dados obtidos (média, desvio padrão e valores do quantis Q05 e Q95).

A avaliação permitiu a comparação direta entre os cenários propostos no estudo. As predições determinísticas junto a média das predições realizadas a partir das amostras gerados pelos campos estocásticos foram analisadas via R^2, MAE, RMSE e gráficos predito vs. observado, a partir disto os horizontes previstos foram comparados com as leituras em um período específico, considerado crítico, do conjunto de teste, no caso determinístico foram apresentadas as previsões pontuais, já para o caso heterogêneo foi apresentado a média junto ao intervalo Q95-Q05 (Figura 3 – h e i). Na figura, está ilustrada a metodologia empregada para a obtenção dos resultados. As comparações realizadas foram todas baseadas nas leituras do instrumento HQ12 para o caso homogêneo.

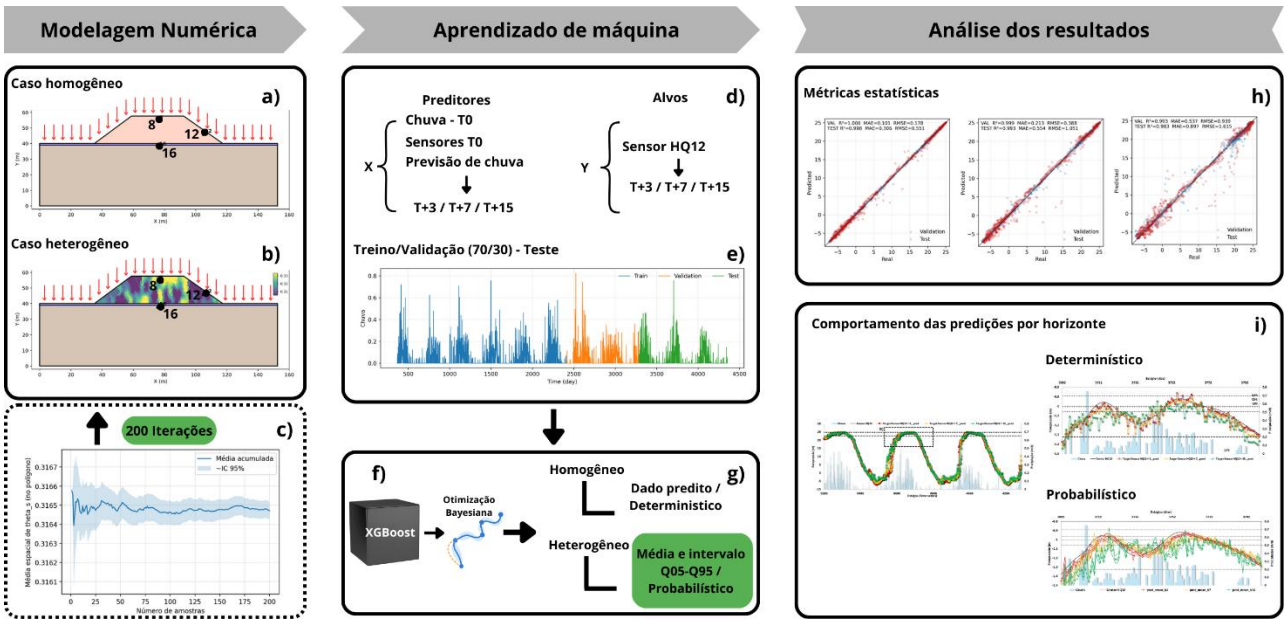


Figura 3 – Descrição da etapa metodologica desenvolvida no trabalho, a) Modelagem numérica para o caso homogêneo; b) Modelagem numérica para o caso heterogêneo; c) Convergência estatística da média no polígono de interesse; d) Preditores e alvos do modelo de ML para previsão das séries temporais junto aos horizontes associados; e) Divisão de treino, validação e teste; f) Modelo de ML utilizado e otimização aplicada; g) Tratamento dos resultados obtidos; h) Avaliação das métricas estatísticas; i) comparação do comportamento dos dados preditos.

3 DISCUSSÃO E RESULTADOS

Com base na metodologia apresentada, os resultados são mostrados nas Figuras 4, 5 e 6, iniciando-se pela comparação entre dados preditos e reais para cada horizonte de previsão, nas abordagens determinística e probabilística. Em seguida, apresenta-se uma análise estágio a estágio (dias), confrontando as predições com as leituras do instrumento virtual HQ12 obtidas no modelo homogêneo, que foi adotado como benchmark em ambos os casos. A Figura 4 sintetiza as comparações real vs. predito.

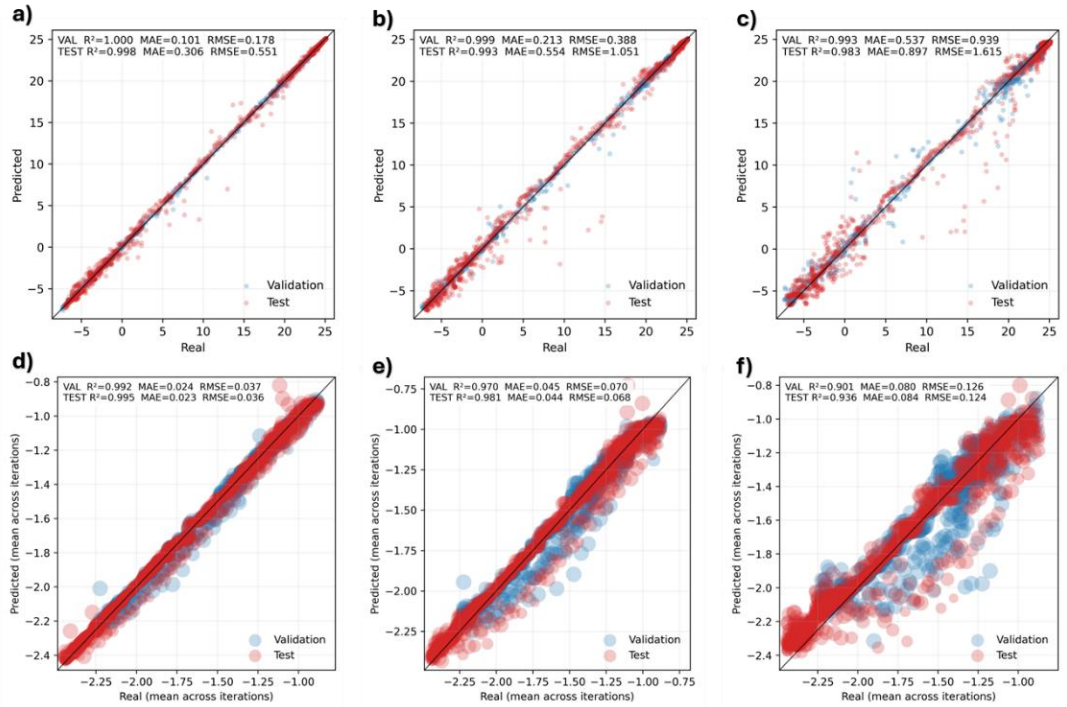


Figura 4 – Avaliação dos resultados Predito vs Real para os conjuntos de validação e teste para os casos determinístico e probabilístico nos horizontes de análise (3, 7 e 15 dias). a) Caso determinístico horizonte de 3 dias; b) Caso determinístico horizonte de 7 dias; c) Caso determinístico horizonte de 15 dias; d) Caso probabilístico horizonte de 3 dias; e) Caso probabilístico horizonte de 7 dias; f) Caso probabilístico horizonte de 15 dias.

As dispersões entre predito e real (Figura 4) indicam elevado desempenho do modelo no cenário determinístico, com R^2 em teste variando de aproximadamente 0,998 (h=3 dias) a 0,983 (h=15 dias), e aumento progressivo dos erros (MAE/RMSE) à medida que o horizonte de previsão cresce. Esse comportamento evidencia a maior dificuldade em representar condições mais extremas, antecipações ou ambos, mais longas, refletida pelo maior espalhamento observado no horizonte de 15 dias.

Na parcela probabilística (Figura 4d–f), a avaliação baseada na média das previsões ao longo das iterações mantém forte concordância com a média real (R^2 em teste ≈0,995 para h=3; ≈0,981 para h=7; ≈0,936 para h=15), com erros absolutos menores em comparação ao cenário determinístico, o que é consistente com a estabilização estatística proporcionada pelo conjunto de realizações. Adicionalmente, o tamanho dos marcadores (desvio padrão predito) evidencia heterocedasticidade, que a incerteza se amplia precisamente nas regiões onde a dispersão aumenta, sugerindo que o modelo captura não apenas o valor esperado, mas também a confiabilidade associada às previsões.

Após apresentar as métricas globais, é necessário detalhar as séries temporais preditas nos cenários homogêneo e heterogêneo, dia a dia, para verificar o comportamento das previsões, identificar sub ou superestimação e avaliar a consistência do modelo frente à variabilidade observada. Além disso, a análise conjunta das leituras do sensor virtual com a chuva e com limiares históricos (quantis) permite medir a capacidade do modelo de antecipar anomalias conforme o horizonte de previsão. Para isso, foram gerados gráficos integrando observações, predições, precipitação e limiares, analisados em duas janelas (100 e 40 dias) representativas de um evento extremo no HQ12 (Figuras 5 e 6).

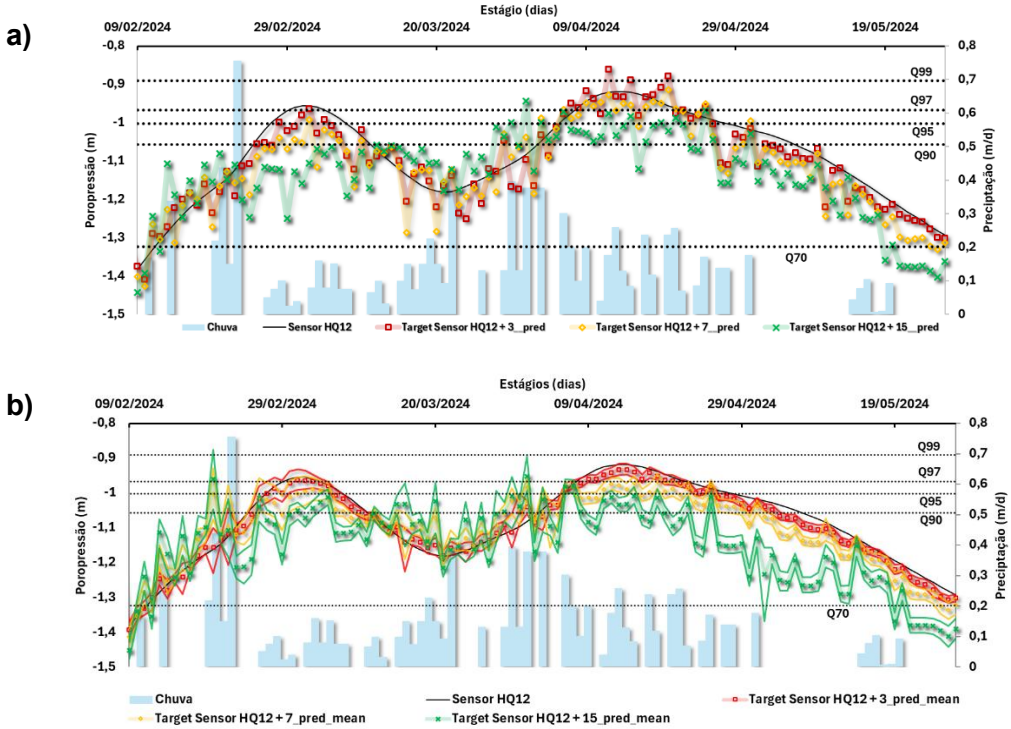


Figura 5 – Comportamento das predições nos horizontes de interesse para os casos avaliados na janela de 108 dias, a) Caso determinístico; b) Caso probabilístico.

Observa-se que o modelo reproduz adequadamente a evolução temporal da poropressão no sensor HQ12, incluindo a subida inicial, o vale intermediário, o pico principal e a tendência de queda ao final da janela analisada, em coerência com a dinâmica de precipitação e com os limiares Q70–Q99 definidos a partir do histórico do instrumento. As previsões pontuais (Figura 5a) apresentam melhor aderência no curto prazo (h=3 dias), enquanto horizontes maiores exibem maior dispersão.

Na representação probabilística (Figura 5b), as médias previstas permanecem próximas ao benchmark e as faixas q05–q95 se ampliam principalmente nos trechos de transição e próximos aos picos e vales, indicando aumento de incerteza em condições hidrológicas mais críticas.

No caso determinístico, observa-se a presença de ruído associado às previsões, em parte relacionado às variações de precipitação ao longo do período analisado. Esse comportamento sugere uma dependência elevada do modelo em relação às variáveis de chuva utilizadas como preditoras, o que pode induzir instabilidades nas estimativas, ainda que os valores previstos permaneçam, em geral, próximos aos dados de referência (Kouame & Wang, 2024). Para os horizontes de 3 e 7 dias, os modelos determinísticos apresentam boa concordância com as transições de comportamento observadas no benchmark. Em contrapartida, no horizonte de 15 dias, nota-se maior dificuldade em capturar essas mudanças, resultando em uma resposta mais suavizada quando comparada à série de referência.

No caso probabilístico, a incorporação da variabilidade tende a estabilizar as previsões em torno da média do conjunto de amostras, o que indica que o número de realizações adotado foi suficiente para representar a variabilidade inerente ao sistema (Raia et al., 2014). Observa-se, adicionalmente, melhor ajuste da média predita ao benchmark no horizonte de 3 dias. Ainda assim, para os demais horizontes, permanece um comportamento relativamente ruidoso nas estimativas centrais. Entretanto, o intervalo probabilístico (Q05–Q95) engloba o benchmark nas regiões de transição, sugerindo que, mesmo com flutuações, a faixa de incerteza capturou adequadamente a dinâmica do fenômeno nos trechos críticos. Em ambos os cenários, verifica-se uma tendência geral de subpredição em relação aos dados de benchmark. Na Figura 6 é possível observar os dados para a janela de 40 dias.

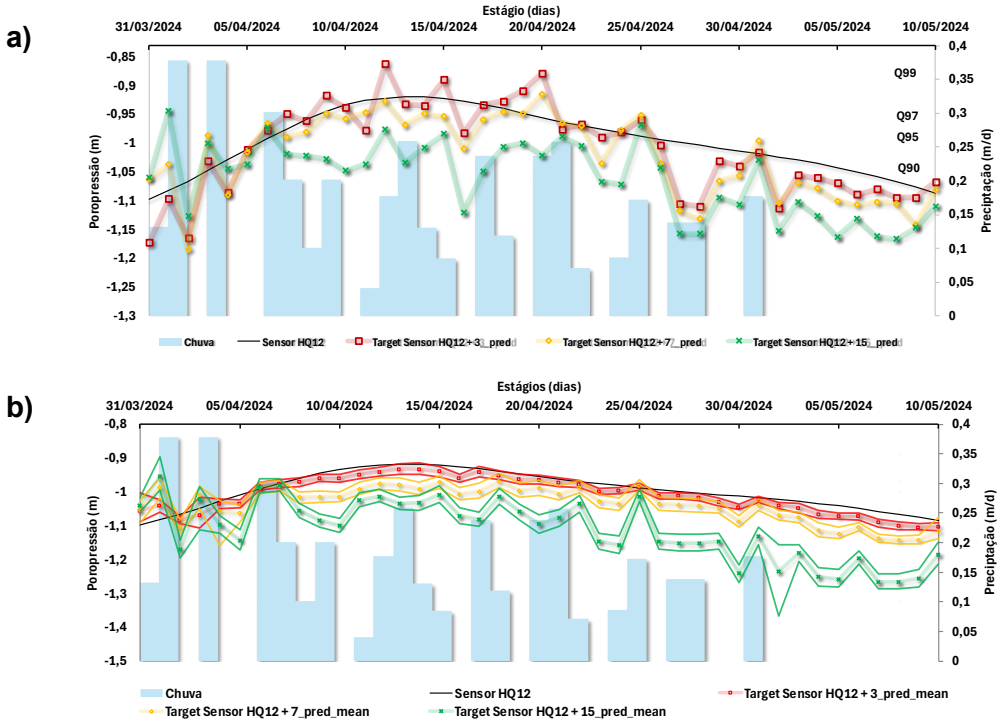


Figura 6 - Comportamento das predições nos horizontes de interesse para os casos avaliados na janela de 40 dias, a) Caso determinístico; b) Caso probabilístico.

A redução da janela de avaliação evidencia um comportamento consistente com o observado anteriormente, porém com maior contraste entre os efeitos identificados. Com a análise em escala mais aproximada, torna-se mais claro o impacto da acumulação de chuvas nas previsões e a forma como esse efeito se propaga para a variação temporal das estimativas, sendo particularmente evidente no horizonte de 15 dias. Observa-se que, à medida que o horizonte de predição se torna mais distante, aumenta a sensibilidade do modelo às transições de comportamento, o que tende a amplificar oscilações e a resposta às mudanças no regime pluviométrico.

Nesse contexto, a introdução de variabilidade no modelo contribui para estabilizar as previsões, reduzindo flutuações e concentrando a resposta em torno de um comportamento médio mais consistente. Ainda assim, permanece um viés sistemático de subpredição, associado principalmente aos horizontes mais longos, indicando que, embora a abordagem probabilística melhore a robustez das estimativas, ainda há limitações na calibração da magnitude prevista em relação ao *benchmark*.

4 CONCLUSÕES

Os modelos determinístico e probabilístico apresentaram bom desempenho nas métricas avaliadas, porém o R^2 isolado não é suficiente; MAE e RMSE são essenciais para quantificar erros e avaliar a confiabilidade em séries temporais sujeitas a ruído, especialmente em aplicações de alerta. Observou-se tendência de subpredição em ambos os cenários, possivelmente ligada ao conjunto de variáveis preditoras, indicando que futuras etapas devem incluir variáveis de comportamento temporal (tendência, variabilidade e memória) para reduzir viés. Esse viés também dificulta avaliar a ultrapassagem de limiares (quantis), reforçando a necessidade de estimar probabilidades de excedência como pós-processamento.

Destaca-se, ainda, o papel da introdução de variabilidade na estabilização das previsões, resultando em respostas mais consistentes em torno da média do conjunto de realizações em cada estágio. No presente trabalho, as diferentes iterações foram utilizadas para compor métricas estatísticas no caso probabilístico. Contudo, abordagens probabilísticas nativas, como modelos do tipo NGBoost, permitem estimar diretamente uma distribuição preditiva para cada instante, fornecendo não apenas um valor central, mas também parâmetros de incerteza associados. Ainda assim, para que essa estratégia seja efetiva, é indispensável a presença de dados

com variabilidade representativa, o que, neste estudo, é viabilizado pela geração de cenários via campos estocásticos.

Os resultados contribuem para entender o desempenho de modelos preditivos em instrumentos de monitoramento de estruturas geotécnicas, além de auxiliar na modelagem para previsão de eventos críticos e apoio a sistemas de alerta. A metodologia proposta pode beneficiar a engenharia geotécnica em aterros rodoviários e ferroviários, ajudando na tomada de decisões para mitigação de riscos associados a tais estruturas.

AGRADECIMENTOS

Os autores agradecem ao Grupo de Pesquisa GeoinfraUSP, à Cátedra Under Rail - VALE e à CAPES

REFERÊNCIAS BIBLIOGRÁFICAS

Akiba, T., Sano, S., Yanase, T., Ohta, T., & Koyama, M. (2019). Optuna: A next-generation hyperparameter optimization framework. *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2623–2631. https://doi.org/10.48550/arXiv.1907.10902

de Almeida, F. S., Fiscina, L. F. G., & Futai, M. M. (2025). Análise Experimental e Modelagem da Curva de Retenção de Água de um Solo Laterítico da Formação Itapecuru sob Diferentes Índices de Vazios Iniciais. *IX Conferência Brasileira sobre Estabilidade de Encostas - COBRAE 2025 (11. : 2025 : Garibaldi, RS)*, 201–207. https://doi.org/10.4322/978-65-86819-41-0

dos Santos Silva, F. D., da Costa, C. P. W., dos Santos Franco, V., Gomes, H. B., da Silva, M. C. L., dos Santos Vanderlei, M. H. G., Costa, R. L., da Rocha Júnior, R. L., Cabral Júnior, J. B., dos Reis, J. S., Cavalcante, R. B. L., Tedeschi, R. G., de Jesus da Costa Barreto, N., Nogueira Neto, A. V., dos Santos Jesus, E., & da Silva Ferreira, D. B. (2023). Intercomparison of Different Sources of Precipitation Data in the Brazilian Legal Amazon. *Climate*, 11(12), 241. https://doi.org/10.3390/cli11120241

Feng, C., Zheng, Z., & Beer, M. (2025). Efficient simulation of conditional random fields and its geotechnical applications. *Engineering Geology*, 108284. https://doi.org/10.1016/j.enggeo.2025.108284

Głowacki, T., & Bortnowski, P. (2025). Long-term prediction of post-mining land deformation with XGBoost, Bayesian optimization, and time series feature engineering. *Measurement, 231*, 119630. https://doi.org/10.1016/j.measurement.2025.119630

Kouame, A. R., & Wang, H. (2024). Random analysis of deposit landslide deformation under uniformly increasing rainfall using machine learning. *European Journal of Environmental and Civil Engineering*, *28*(12), 2787-2806. https://doi.org/10.1080/19648189.2024.2319868

Santha Kumar, G., Saini, P. K., Deoliya, R., Mishra, A. K., & Negi, S. K. (2022). Characterization of laterite soil and its use in construction applications: A review. *Resources, Conservation & Recycling Advances*, *16*, 200120. https://doi.org/10.1016/j.rcradv.2022.200120

Li, X. Y., Zhang, L. M., & Li, J. H. (2016). Using conditioned random fields to characterize the variability of geologic profiles. *Journal of Geotechnical and Geoenvironmental Engineering*, *142*(4), 04015096. https://doi.org/10.1061/(ASCE)GT.1943-5606.0001428

Raia, S., Alvioli, M., Rossi, M., Baum, R. L., Godt, J. W., & Guzzetti, F. (2014). Improving predictive power of physically based rainfall-induced shallow landslide models: a probabilistic approach. *Geoscientific Model Development*, *7*(2), 495-514. https://doi.org/10.5194/gmd-7-495-2014

Silva, F. P., Fiscina, L. F. G., de Almeida, F. S., de Sousa, M. T. R., Cordeiro, W. B., Vitelli, G., & Futai, M. M. (2025). Landslide Susceptibility Modeling in a Railway in the Amazon Region: Integration of the Weight of Evidence (WOE) Method and InSAR Monitoring Data. *Geotechnical and Geological Engineering*, *43*(8), 438. https://doi.org/10.1007/s10706-025-03418-2

Fredlund, Delwyn & Rahardjo, Harianto. (1993). Soil Mechanics for Unsatured Soils. John Wiley & Sons. https://doi.org/10.1002/9780470172759

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/COBRAMSEG2026.2/18

Metodologia para Avaliação da Aderência de Distribuições Acumuladas em Parâmetros Geotécnicos Utilizando Software R.

Filipe Guarnieri Xavier
Doutorando em Geotecnia, Escola Politécnica da Universidade de São Paulo (USP) / Engenheiro Geotécnico, Knight Piésold, Belo Horizonte, Brasil, fxavier@knightpiesold.com.

Pedro Henrique Oliveira Silva Leite
Bacharelado em Engenharia Civil, Universidade Federal de Minas Gerais, Belo Horizonte, Brasil, pedrohosleite@gmail.com

Roberto Cezar Rego Silva
WSP Brasil, Engenheiro Geotécnico, Belo Horizonte, Brasil, robertocezarrs@outlook.com

Domenico Oliveira Gontijo
Engenheiro Civil, Universidade Federal de Ouro Preto, Ouro Preto, Minas Gerais, domenico.gontijo@gmail.com

Maria Daniela Camilo Felício
Graduanda em Engenharia Civil pela Universidade Federal de Minas Gerais (UFMG) – Minas Gerais, Brasil.
mariadcfelicio@gmail.com

RESUMO: A quantidade de informações disponíveis representa um desafio para a engenharia geotécnica, pois, quanto maior o volume de dados, maior o potencial de redução das incertezas e de aprimoramento da tomada de decisão. Assim, é essencial compreender o comportamento da distribuição dos parâmetros, com intuito de representar a anisotropia geotécnica. Para isso, é necessário obter a função de distribuição acumulada, com intuito de subsidiar indicadores de desempenho mais assertivos, como a probabilidade de falha e o índice de confiabilidade. O presente trabalho traz uma metodologia de aderência da distribuição acumulada, para 18 parâmetros, utilizando o software R e o pacote fitdistrplus. Os resultados obtidos foram validados a partir de critérios de informação de Akaike (AIC) e Bayesiano (BIC), para diferentes parâmetros, e a metodologia mostrou-se uma ferramenta fundamental para a realização de simulações numéricas probabilísticas mais precisas, principalmente para análises de variáveis aleatórias (Random Variable – RV).

PALAVRAS-CHAVE: Função de distribuição acumulada, R (software estatístico), Variabilidade geotécnica, Análise probabilística, Variáveis aleatórias

ABSTRACT: The growing volume of available data poses a significant challenge in geotechnical engineering, as larger datasets can contribute to reducing uncertainties and improving decision-making. In this context, understanding the probabilistic behavior of geotechnical parameters is essential for adequately representing geotechnical anisotropy. To this end, determining the cumulative distribution function is necessary to support more reliable performance indicators, such as the probability of failure and the reliability index. This paper presents a methodology for cumulative distribution fitting applied to 18 parameters using the R software and the fitdistrplus package. The results were validated using the Akaike Information Criterion (AIC) and the Bayesian Information Criterion (BIC) for different parameters, demonstrating that this approach is a valuable tool for performing more accurate probabilistic numerical simulations, particularly in analyses involving Random Variables (RVs).

KEYWORDS: Cumulative Distribution Function; R (statistical software); Geotechnical Variability; Probabilistic Analysis; Random Variables.

1 INTRODUÇÃO

As análises de estabilidade constituem uma rotina crucial na engenharia geotécnica, fundamentais tanto para garantir a segurança operacional de empreendimentos quanto para assegurar a viabilidade econômica de projetos de infraestrutura e mineração. Tradicionalmente, essas avaliações baseiam-se em abordagens determinísticas, validadas pela utilização de um único indicador de desempenho: o Fator de Segurança (FS). Tal prática, embora corroborada por normas e legislações técnicas vigentes, assume parâmetros de resistência fixos e constantes para o cálculo da estabilidade.

Não obstante, as propriedades de solos e rochas — incluindo parâmetros de resistência ao cisalhamento, deformabilidade e permeabilidade — são naturalmente anisotrópicas e devem ser tratadas como Variáveis Aleatórias (Random Variables – RV). Essa variabilidade é uma característica intrínseca aos geomateriais, resultante de processos geológicos complexos, como o transporte de sedimentos por distintos agentes e os históricos de tensão, pressão e temperatura aos quais a rocha matriz e o regolito foram submetidos (Xavier, 2025). Ignorar essas incertezas em análises exclusivamente determinísticas pode conduzir a uma falsa percepção de segurança ou, inversamente, a projetos excessivamente conservadores e antieconômicos.

Assim, na abordagem de Variável Aleatória (Random Variable – RV), as propriedades geotécnicas são tratadas como grandezas cujos valores possuem incerteza intrínseca. Matematicamente, essas propriedades dos materiais são representadas por um vetor de variáveis aleatórias X = {X1, X2, …, Xn}. A caracterização completa do comportamento dessas variáveis depende fundamentalmente de sua Função de Densidade de Probabilidade (PDF) conjunta, denotada como $f_{\mathbf{X}}(\mathbf{x})$ (Torrico Siacara, 2021). A definição correta dessa função permite descrever plenamente a estrutura probabilística dos parâmetros e seu comportamento.

O presente trabalho propõe uma metodologia sistemática para a obtenção do melhor ajuste da PDF dos geomateriais. Para tal, foram utilizados critérios estatísticos, especificamente o Critério de Informação de Akaike (AIC) e o Critério de Informação Bayesiano (BIC), processados com o auxílio do software estatístico R. O estudo avaliou a melhor aderência probabilística de 18 parâmetros geotécnicos ligados a ensaio de campo, caracterização física e de resistência, em rejeitos, regolito de filito e regolito carbonático, de matrizes arenosas, siltosas e argilosas respectivamente.

2 FUNDAMENTAÇÃO TEÓRICA

Historicamente, na ausência de softwares estatísticos avançados, a determinação da PDF dos parâmetros geotécnicos fundamentava-se na análise de extensos bancos de dados. Um exemplo clássico dessa abordagem é o trabalho de Lacasse e Nadim (1996), que estabeleceram as distribuições mais adequadas a partir da compilação de resultados de ensaios e testes de aderência simplificados.

Conforme esses autores, parâmetros físicos e índices (como peso específico e limites de Atterberg) tendem a seguir uma distribuição Normal devido à natureza aditiva de suas variáveis constituintes e à baixa variabilidade observada.

Em contrapartida, parâmetros de resistência e hidráulicos (como s_u e permeabilidade) ajustam-se melhor à distribuição Lognormal. Essa preferência estatística justifica-se tanto pela restrição física de não-negatividade dos valores quanto pela natureza multiplicativa dos processos geológicos de formação, os quais frequentemente geram distribuições assimétricas com outliers.

A Tabela 1 traz alguns valores típicos obtidos de PDF.

Tabela 1: Valores típicos de PDF. Adaptado (Bretas, 2020).

Parâmetro do Solo	Tipo de solo	Tipo de distribuição
Resistência não drenada s_u	Argila (Triaxial)	Log normal
	Argila (Su)	Log normal
Razão $\frac{s_u}{\sigma' v}$	Argila	Normal / Log normal
Limite Plasticidade	Argila	Normal
Limite Liquidez	Argila	Normal
Peso unitário submerso	Todos	Normal
Ângulo de atrito	Areia	Normal
Índice de vazios	Todos	Normal
Razão de Adensamento	Argila	Normal / Log normal

O presente trabalho traz uma avaliação de PDF que vai além de modelos clássicos Normal e Lognormal. O estudo amplia o escopo analítico ao avaliar também distribuições do tipo Weibull, Gamma e Gumbel, com o objetivo de obter melhor aderência estatística aos dados e representar de forma mais adequada comportamentos assimétricos que podem não ser capturados pelas distribuições tradicionais.

3 METODOLOGIA

Para a determinação das funções de probabilidade que melhor representam cada parâmetro geotécnico, empregou-se o ambiente de computação estatística R (versão 4.4.2). O procedimento analítico teve como objetivo avaliar o grau de aderência dos dados amostrais em relação a diferentes curvas de PDF teóricas, permitindo a seleção do modelo estatístico mais representativo para a variabilidade observada.

Akaike (1974) e Schwarz (1978) propuseram, respectivamente, os critérios AIC (Akaike information criterion) e BIC (Bayesian information criterion) respectivamente, ambos os critérios são baseados na função de verossimilhança e quanto menores seus valores, melhor o ajuste da distribuição.

Utilizou-se critérios de informação AIC e BIC, a Tabela 2 traz as análises utilizadas neste estudo para a verificação da aderência de distribuição de probabilidade.

Tabela 2: Avaliação da distribuição de probabilidade.

Métodos quantitativos	Bases	Regras para análise estatística
Gráfico Função Distribuição Acumulada Empírica Teórica (CDF)	Avalia a aderência de curvas de distribuição acumuladas com empíricas	Visualmente quanto mais a curva aproximar da teórica mais vinculado esta
Critério de Informação Akaike (AIC)	AIC = −2. log L (q) + 2p L (q) - é a verossimilhança máxima do modelo (quanto maior, melhor o ajuste), p corresponde ao número de parâmetros estimados no modelo, −2log (q) penaliza modelos com baixo ajuste e 2p, penaliza modelos mais complexos, com mais parâmetros.	Menor valor maior aderência
Critério de Informação Bayesiano (BIC)	BIC = −2. log L (q) + p log (n) L (q) - é a verossimilhança máxima do modelo (quanto maior, melhor o ajuste), p corresponde ao número de parâmetros estimados no modelo, −2.log L (q) penaliza modelos com baixo ajuste e n é o número total de observações no conjunto de dados	Menor valor maior aderência

4 EXEMPLO DE APLICAÇÃO

Como exemplo de aplicação da metodologia proposta foram avaliados ensaios de campo vem diferentes litologias (N_{SPT}) e de laboratório, sendo ensaios de caracterização em rejeitos (ρd, $w$ót) e de parâmetros geotécnicos em rochas (ε,ν) e solos (c, ϕ). A Tabela 3 traz a nomenclatura adotada juntamente com a descrição geotécnica de cada um dos materiais.

Tabela 3: Parâmetros avaliados.

Ensaio de Campo	Nomenclatura	Descrição do material
Índice de resistência à penetração obtido através da sondagem a percussão (N_{spt})	SAP_{Nspt}	Saprólito Filítico
	SR_{Nspt}	Solo Residual Filítico
	SRJ_{Nspt}	Solo Residual Jovem de Xisto Micáceo
	SRM_{Nspt}	Solo Residual Maduro de Xisto Micáceo
	ALR_{Nspt}	Aluvião Arenoso
	ALG_{Nspt}	Aluvião Argiloso
Parâmetros de elasticidade	Nomenclatura	Descrição do material
ε - Módulo de elasticidade (Young)	RO_{MT}	Rocha Metatonalito
	RO_{MD}	Rocha Metadiorito
ν - Coeficiente de Poisson		
Parâmetro de resistência	Nomenclatura	Descrição do material
c – Coesão	RG_{CR}	Rególito de solo Carbonático
ϕ – Ângulo de atrito	SAP_{FL}	Saprólito Filítico
	SR_{FL}	Solo Residual Filítico
Parâmetro de caracterização	Nomenclatura	Descrição do material
ρd – Densidade seca máxima	$RJ\rho$	Rejeito proveniente de Xisto Metamorfizado
$w$ót – Umidade ótima		

As Figura 1 aFigura 4 trazem os resultados de PDF obtidos para cada um dos 18 parâmetros avaliados.

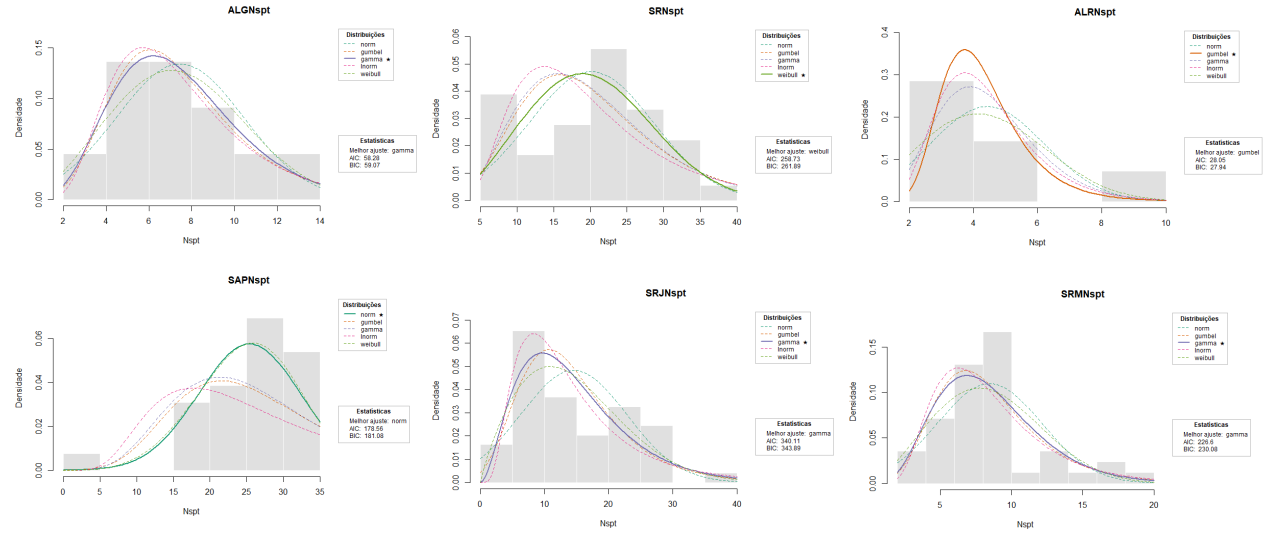


Figura 1: PDF para os ensaios de campo.

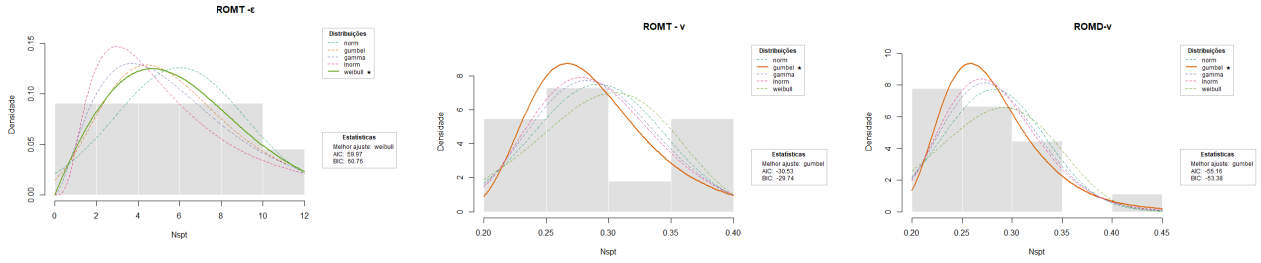


Figura 2: PDF dos Parâmetros de elasticidade.

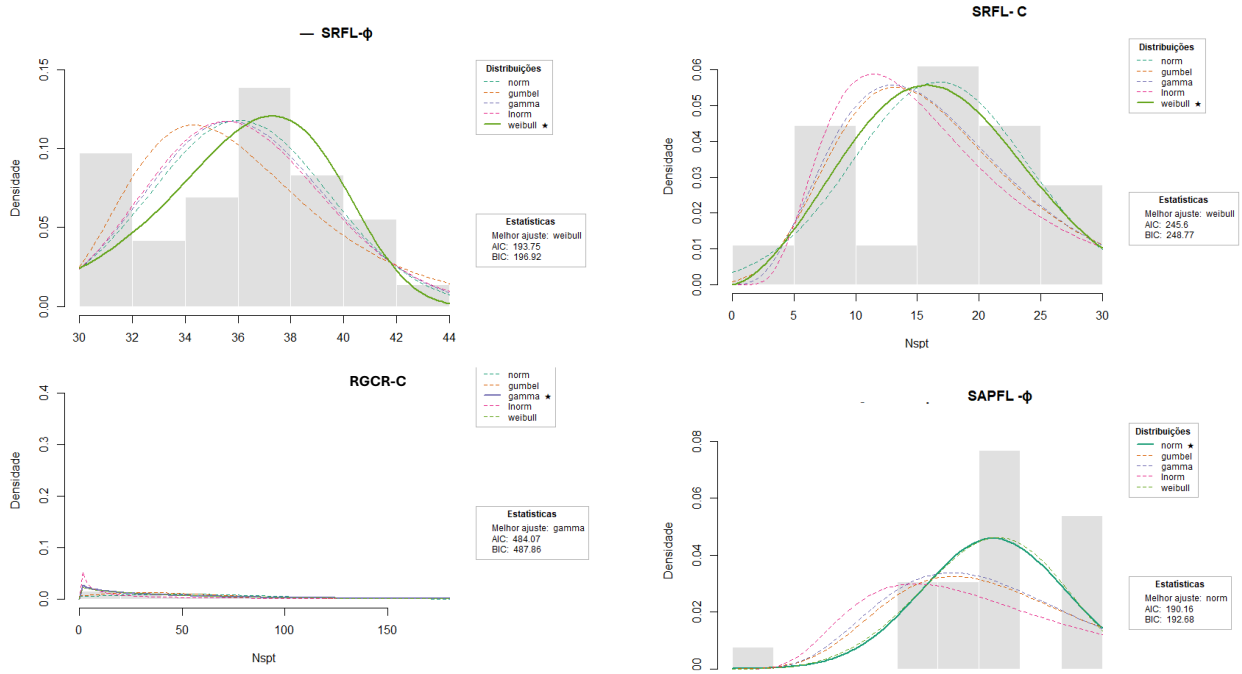


Figura 3: PDF Parâmetro de resistência

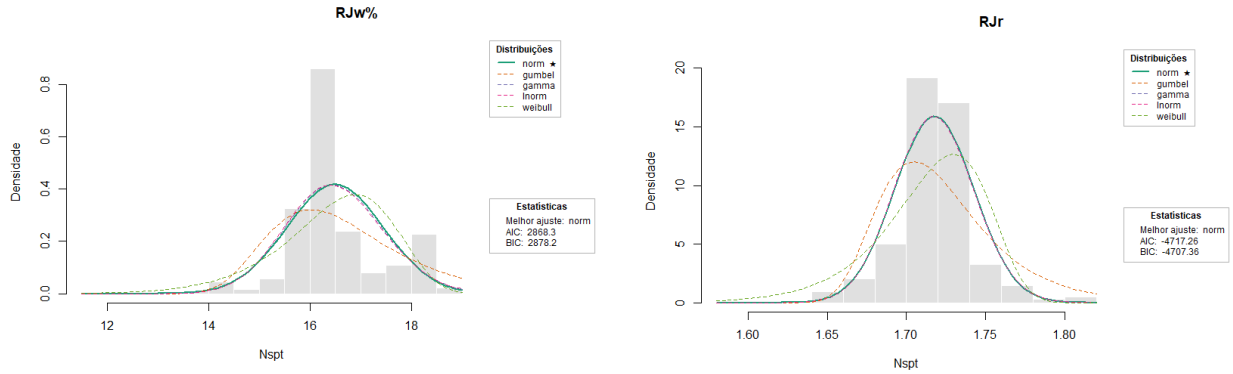


Figura 4: PDF Parâmetro de caracterização.

A Tabela 4 apresenta um resumo dos resultados obtidos, incluindo os menores valores de AIC e BIC.

Tabela 4: Resultados de critério de informação por AIC e BIC.

Parâmetro	PDC	AIC	BIC	Análises
SAPNspt	norm	178.560037	181.07623	26
SRNspt	weibull	258.72524	261.892278	36
SRJNspt	gamma	340.107398	343.891039	49
SRMNspt	gamma	226.603495	230.078834	42
ALRNspt	gumbel	28.0506013	27.9424216	7
ALGNspt	gamma	58.2770705	59.072861	11
ROMT -ε	weibull	59.9681739	60.7639644	11
ROMT - ν	gumbel	-30.533109	-29.737319	11
ROMD-ε	gumbel	96.8457298	98.6264733	18
ROMD-ν	gumbel	-55.158448	-53.377705	18
RGCR - C	gamma	484.072944	487.856585	49
RGCR -ϕ	weibull	284.030334	287.813975	49
SAPFL- C	norm	169.079316	171.595509	26

SAPFL -ϕ	norm	190.163501	192.679694	26
SRFL- C	weibull	245.598089	248.765127	36
SRFL-ϕ	weibull	193.748511	196.915549	36
RJr	norm	-4717.2625	-4707.3647	1042
RJw%	norm	2868.30214	2878.19993	1042

Os resultados obtidos demonstram que a melhor aderência estatística para os parâmetros analisados raramente seguiu as distribuições probabilísticas clássicas (Normal e Lognormal), comumente citadas na literatura internacional para solos sedimentares. Em contrapartida, observou-se uma predominância de ajustes superiores com distribuições alternativas, como Weibull, Gamma e Gumbel.

Tal constatação evidencia a necessidade crítica de avaliar criteriosamente o comportamento probabilístico dos materiais, especialmente no contexto de solos tropicais, cuja gênese intempérica e estrutura lixiviada podem gerar assimetria e ocorrência de outliers de distribuição distintas daquelas previstas pelos modelos tradicionais. A adoção automática de distribuições padrão (Normal/Lognormal) em análises de Variável Aleatória (RV) pode enviesar significativamente a estimativa da probabilidade de falha.

Com isso, a metodologia proposta de seleção de PDF via critérios de informação (AIC/BIC) mostra-se fundamental para garantir a precisão e a confiabilidade dos indicadores de desempenho (FS, Pf e β) das estruturas geotécnicas.

5 CONCLUSÃO

O estudo buscou identificar a distribuição probabilística mais adequada para cada parâmetro geotécnico, de modo a permitir a obtenção de sua função densidade de probabilidade (PDF) e de sua função de distribuição acumulada (FDA), utilizando critérios de informação estatística (AIC e BIC) no ambiente computacional R. Foi realizada a análise de 18 parâmetros distintos, abrangendo ensaios de campo, caracterização física e resistência mecânica em diferentes geomateriais (rejeitos, regolito de filito e regolito carbonático).

Assim, conforme supracitado os resultados demonstraram que as distribuições Normal e Lognormal, tradicionalmente sugeridas na literatura internacional para solos sedimentares, não foram as que apresentaram a melhor aderência para a maioria dos parâmetros analisados. Observou-se uma prevalência de melhores ajustes com distribuições alternativas, como Weibull, Gamma e Gumbel

A predominância dessas distribuições alternativas reforça a necessidade de considerar as particularidades dos solos tropicais e materiais de mineração (rejeitos). A estrutura lixiviada, a cimentação natural e a variabilidade intrínseca desses materiais geram assimetrias e comportamentos de cauda que não são capturados adequadamente pelos modelos gaussianos simples.

A correta identificação da PDF é crucial para análises de Variável Aleatória (RV). A adoção arbitrária de uma distribuição incorreta pode enviesar significativamente os indicadores de desempenho, como a Probabilidade de Falha (Pf) e o Índice de Confiabilidade (β), conduzindo a projetos excessivamente conservadores ou perigosamente inseguros.

A utilização do software R em conjunto com o pacote *fitdistrplus* e os critérios de Akaike e Bayesiano mostrou-se uma ferramenta robusta e acessível para a engenharia geotécnica. Essa abordagem permite reduzir as incertezas epistêmicas associadas à modelagem estatística, proporcionando simulações numéricas mais precisas e assertivas para a tomada de decisão em projetos de infraestrutura e mineração.

REFERÊNCIAS BIBLIOGRÁFICAS

Akaike, H. (1974). *A new look at the statistical model identification*. IEEE Transactions on Automatic Control, 19(6), 716-723.

Bretas, Thiago Cruz. *Retroanálise probabilística tridimensional por equilíbrio-limite de rupturas de talude em Belo Horizonte/MG.* Dissertação (Mestrado em Engenharia Geotécnica) – Programa de Pós-Graduação em Engenharia Geotécnica, Universidade Federal de Ouro Preto, Ouro Preto, 2020.

Lacasse, S., & Nadim, F. (1996*). Uncertainties in characterizing soil properties. In: Uncertainty in the Geologic Environment: From Theory to Practice*. ASCE Geotechnical Special Publication No. 58, 49-75.

Schwarz, G. (1978). *Estimating the dimension of a model.* The Annals of Statistics, 6(2), 461-464.

Torrico Siacara, Adrian. *Reliability-based design of an earth and concrete dam. 2021*. Tese (Doutorado em Engenharia Geotécnica) - Escola Politécnica, Universidade de São Paulo, São Paulo, 2021. doi:10.11606/T.3.2021.tde-22102021-094317. Acesso em: 2026-06-09.

Xavier, F. G. (2025). *Retroanálise de rompimento de talude com dados de sondagem: uma abordagem factível usando métodos probabilísticos e simulações computacionais.* Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia de Minas, Metalúrgica e de Materiais (PPGE3M), Universidade Federal do Rio Grande do Sul (UFRGS), Porto Alegre.

DOI: 10.47094/COBRAMSEG2026.2/19

Modelagem Preditiva da Deformação Permanente de Subleitos de Solos Tropicais através de Regressão Polinomial Evolucionária Orientada por Sensibilidade

Bruno Oliveira da Silva
Doutorando, Universidade Federal de Ouro Preto, Ouro Preto, Brasil, bruno.silva1@aluno.ufop.edu.br

Guilherme José Cunha Gomes
Docente, Universidade Federal de Ouro Preto, Ouro Preto, Brasil, guilhermejcg@ufop.edu.br

RESUMO: Este trabalho propõe e valida uma abordagem de Regressão Polinomial Evolucionária orientada à sensibilidade para prever a deformação permanente (DP) de subleitos em solos tropicais, buscando conciliar capacidade preditiva e interpretabilidade por meio de equações explícitas, parcimoniosas e de um critério de seleção baseado na consistência paramétrica. O banco de dados foi composto por resultados de ensaios triaxiais de cargas repetidas extraídos de teses e dissertações brasileiras, complementados por simulações controladas no MeDiNa, que representaram diferentes níveis de tráfego e configurações estruturais do pavimento. O algoritmo utilizado foi configurado com uma estratégia de busca híbrida para identificar a estrutura ótima dos modelos, combinando Algoritmo Genético e Evolução Diferencial. Paralelamente, foram conduzidas análises de sensibilidade baseadas em simulações de Monte Carlo para quantificar a resposta da DP às variáveis preditoras; essa etapa também foi incorporada como critério adicional na seleção dos modelos ótimos, privilegiando tendências fisicamente coerentes. O desempenho foi avaliado por validação cruzada com três repetições, resultando em modelos com boa acurácia ($R^2 \approx 0{,}80$ e erro absoluto médio em torno de 0,40 mm em teste) e comportamento consistente entre os *batches* de validação cruzada, indicando robustez e potencial de aplicação prática com parâmetros de fácil obtenção.

PALAVRAS-CHAVE: Deformação permanente, Subleito, Solos tropicais, Regressão Polinomial Evolucionária (EPR).

ABSTRACT: This study proposes and validates a sensitivity-driven Evolutionary Polynomial Regression (EPR) approach to predict permanent deformation (PD) of subgrades in tropical soils, aiming to reconcile predictive capability and interpretability through explicit, parsimonious equations and a selection criterion based on parametric consistency. The dataset comprises results from repeated load triaxial tests extracted from Brazilian theses and dissertations, complemented by controlled MeDiNa simulations representing different traffic levels and pavement structural configurations. The algorithm was configured with a hybrid search strategy to identify the optimal model structure, combining a Genetic Algorithm and Differential Evolution. In parallel, Monte Carlo–based sensitivity analyses were performed to quantify the PD response to the predictor variables; this step was also incorporated as an additional criterion for selecting optimal models, prioritizing physically coherent trends. Model performance was assessed using cross-validation with three repetitions, yielding models with good accuracy ($R^2 \approx 0.80$ and a mean absolute error of about 0.40 mm in testing) and consistent behavior across the cross-validation batches, indicating robustness and strong potential for practical application using readily obtainable parameters.

KEYWORDS: Permanent deformation; Subgrade; Tropical soils; Evolutionary Polynomial Regression (EPR).

1 INTRODUÇÃO

Em conjunto com o trincamento da camada superior de concreto asfáltico por fadiga, o afundamento de trilha de roda (ATR) consiste em um dos principais defeitos estruturais de pavimentos flexíveis (Medina e Motta, 2015). O ATR resulta do acúmulo de deformações permanentes (DP) nas diferentes camadas do pavimento ao longo da vida em serviço e compromete as características funcionais, reduzindo o conforto e a segurança dos usuários, e aumentando os custos operacionais e de manutenção (Guimarães, 2009; M. F. da Silva et al., 2021). Trata-se de um mecanismo de deterioração de evolução progressiva, governado por uma interação complexa entre tráfego, estado de tensões, propriedades dos materiais e condições ambientais (Liu et al., 2024; Saraiva et al., 2026; Singh e Sahoo, 2021).

A contribuição da DP do subleito no ATR varia significativamente em função das condições estruturais do pavimento e do tipo de solo empregado e, portanto, deve ser analisada de forma sistemática (Romanoschi, 2017). Conforme relatado por Medina e Motta (2015), ensaios realizados em uma pista experimental da *American Association of State Highway Officials* (AASHO) indicaram que o subleito contribuiu com menos de 20% da DP total do pavimento. Em contrapartida, Salour et al. (2016) apontam que, em pavimentos esbeltos, é comum o subleito contribuir com mais de 40% no ATR.

Além disso, condições ambientais e particularidades do meio físico tropical influenciam a deformabilidade de solos e agregados de forma significativa. Em grande parte do território brasileiro, predominam condições climáticas tropicais, associadas à intensa atuação dos diferentes mecanismos de intemperismo, o que tende a gerar solos com características e respostas mecânicas frequentemente distintas daquelas observadas em ambientes temperados (Nogami e Villibor, 1991). Como consequência, podem ocorrer diferenças relevantes na deformabilidade dos materiais empregados em pavimentos, tanto no regime elástico quanto no plástico (de Carvalho et al., 2015; Guimarães, 2001; Sousa et al., 2023).

O método mecanístico-empírico implementado no Brasil (MeDiNa) inclui a DP como parâmetro de dimensionamento de pavimentos flexíveis (DNIT, 2021). Para investigar o comportamento de deformabilidade dos materiais, a realização de ensaios de cargas repetidas tem sido amplamente empregada (Cabral et al., 2021; Guimarães, 2009; Pascoal, 2024). No entanto, o equipamento e a mão de obra especializada necessários à sua realização são pouco acessíveis, sobretudo na realidade brasileira. Além disso, trata-se de um ensaio de alto custo e longa duração, podendo exigir cerca de uma semana para a execução completa em uma única amostra (de Lima et al., 2021; Mota et al., 2026; Saraiva et al., 2026).

Como alternativa aos ensaios de cargas repetidas, diferentes técnicas de aprendizado de máquina têm sido empregadas para estimativa da DP, reduzindo custos, tempo de obtenção de resultados e a dependência de infraestrutura laboratorial especializada (Liu et al., 2024). Nesse contexto, a Regressão Polinomial Evolucionária (*Evolutionary Polynomial Regression* - EPR) se apresenta como uma alternativa promissora para a modelagem preditiva da DP. A técnica combina regressão polinomial e algoritmos evolutivos para selecionar a estrutura ótima dos modelos, aliando capacidade preditiva, simplicidade e interpretabilidade física (Giustolisi e Savic, 2006; G. J. C. Gomes et al., 2021; Rezania et al., 2010). A EPR gera equações explícitas e transparentes, facilitando a análise da influência das variáveis de entrada na resposta, a verificação de coerência física e a inclusão do conhecimento de engenharia, ao contrário de modelos do tipo ‘caixa-preta’, como as redes neurais artificiais (B. O. da Silva e Gomes, 2025; R. G. S. Gomes et al., 2022).

A partir de buscas em bases de dados e repositórios de ampla utilização na Engenharia, não foram identificados estudos que apliquem a técnica EPR à previsão da DP de materiais empregados na pavimentação. Assim, este trabalho tem como objetivo propor e validar uma abordagem de EPR orientada por sensibilidade, com desempenho avaliado por validação cruzada, de modo a combinar capacidade preditiva e interpretabilidade por meio de equações explícitas e critérios de seleção que privilegiem consistência paramétrica. A modelagem é conduzida a partir de um banco de dados composto por resultados de ensaios de cargas repetidas extraídos de teses e dissertações publicadas nacionalmente, abrangendo 11 solos de diferentes localidades. Adicionalmente, são realizadas simulações controladas no software MeDiNa para representar o efeito de diferentes níveis de tráfego, características dos materiais de subleito e espessuras das camadas do pavimento sobre a DP do subleito. Adicionalmente, discute-se o papel relativo das variáveis de entrada na DP, oferecendo suporte consistente à compreensão do fenômeno modelado.

2 METODOLOGIA

A pesquisa foi estruturada nas etapas apresentadas no fluxograma da Figura 1. Não foram incluídas no fluxograma etapas gerais, comuns a qualquer estudo, como a revisão bibliográfica do tema ou a definição dos objetivos. Na sequência desta seção, cada etapa do fluxograma é descrita em detalhe para facilitar a compreensão do percurso metodológico adotado.

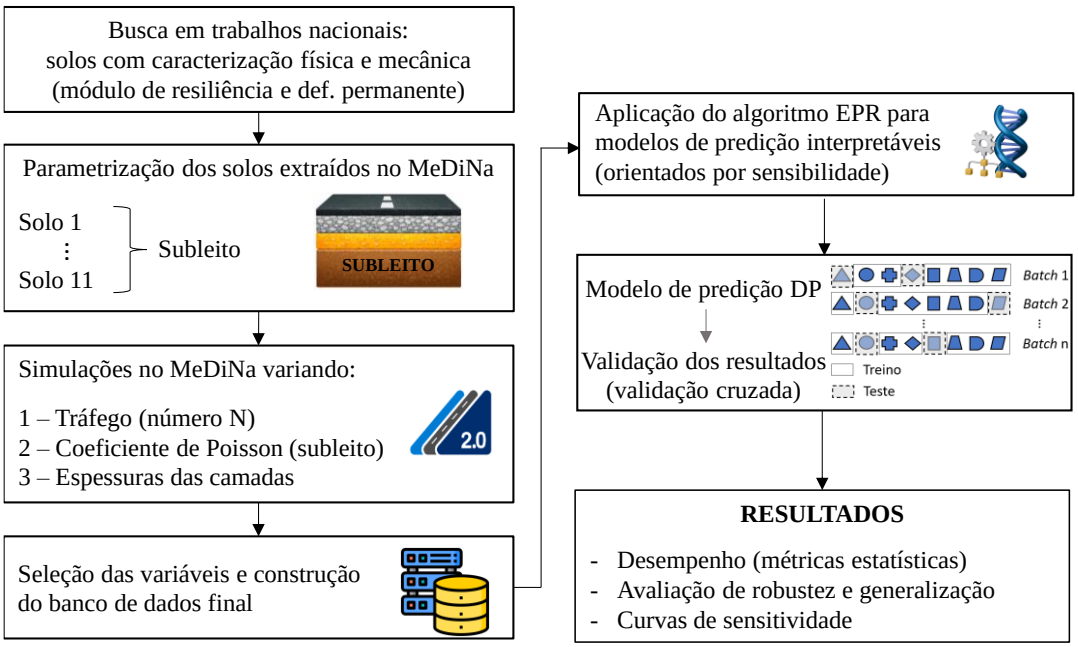


Figura 1. Fluxograma da metodologia para desenvolvimento de modelos de predição de deformação permanente (DP) de solos empregado no subleito.

A etapa de levantamento dos dados dos materiais de subleito utilizada neste trabalho baseou-se em uma busca na literatura nacional por dissertações e teses que disponibilizassem resultados experimentais para solos compatíveis com aplicação em subleito. Foram considerados elegíveis os estudos que reportassem resultados de caracterização física, parâmetros ótimos de compactação, caracterização resiliente e avaliação da deformação permanente por meio de ensaios triaxiais de carga repetida. Além disso, exigiu-se que a deformação permanente estivesse apresentada segundo o modelo proposto por Guimarães (2009), adotado no programa MeDiNa.

Com base nesse levantamento, foram selecionados 11 solos. Parte desses materiais, inclusive, já integra o banco de dados nativo do MeDiNa. A Tabela 1 apresenta a descrição textural dos materiais, sua origem e as respectivas referências utilizadas para a obtenção dos dados.

Tabela 1. Descrição, origem e referências utilizadas para seleção dos solos utilizados.

Identificação	Descrição textural	Origem da coleta	Autoria
S1	Solo argiloso	Ribeirão Preto - SP	Guimarães (2009)
S2	Solo siltoso	Cachoeiras de Macacu - RJ	Guimarães (2009)
S3	Argila siltosa	Tapes - RS	Pascoal (2024)
S4	Solo argiloso	São Lourenço do Sul - RS	Pascoal (2024)
S5	Solo argiloso	Pelotas - RS	Pascoal (2024)
S6	Argila arenosa	Cruz Alta - RS	Santos (2020)
S7	Solo argiloso	Cruz Alta - RS	Pascoal (2020)
S8	Solo areno-argiloso	Santa Maria - RS	Zago (2016)
S9	Solo argiloso	Magé - RJ	Norback (2018)
S10	Solo arenoso	Magé - RJ	Norback (2018)
S11	Solo argiloso	Magé - RJ	Norback (2018)

De posse dos resultados dos ensaios de caracterização física e caracterização mecânica mencionados, procedeu-se à configuração dos 11 materiais no MeDiNa, atribuindo sua utilização como materiais de subleito. Para as demais camadas do pavimento (revestimento asfáltico, base e sub-base), adotaram-se materiais fixos já presentes no banco de dados do MeDiNa: revestimento em concreto betuminoso usinado a quente (CBUQ) com CAP 30/45 e diâmetro máximo nominal dos agregados de 12,5 mm, base em brita graduada tratada com cimento (BGTC) e sub-base composta por um solo argiloso com comportamento laterítico. O subleito, por sua vez, foi simulado utilizando os onze solos selecionados.

Com os materiais parametrizados, foram realizadas simulações controladas no MeDiNa combinando níveis de tráfego, resposta elástica do subleito e arranjos estruturais. O planejamento considerou cinco níveis de tráfego, cinco valores de ν e três estruturas diferentes em relação às espessuras das camadas. A variação de ν foi motivada pelo fato de não ser comum a investigação desse parâmetro no meio rodoviário, sendo recomendada a faixa de valores mencionada (DER - SP, 2025). O esquema completo do planejamento das simulações é apresentado na Tabela 2.

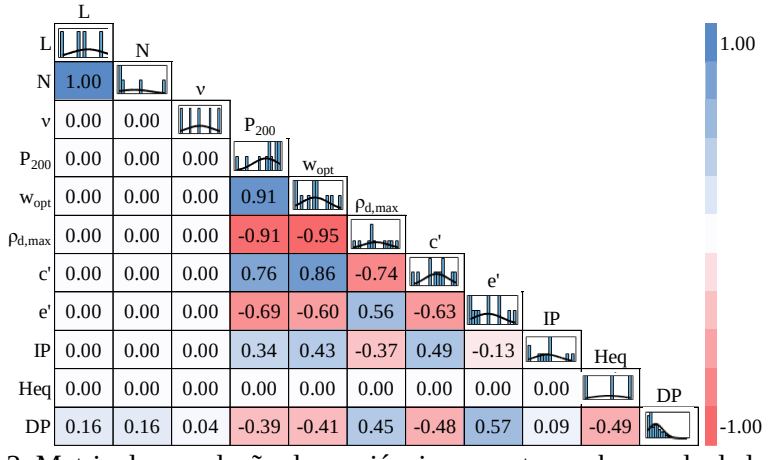
Tabela 2. Combinações usadas para a realização das simulações no MeDiNa.

Camadas	Material	Espessuras			Poisson
		Arranjo 1	Arranjo 2	Arranjo 3	
Revestimento asfáltico	CBUQ - CAP 30/45, #12,5 mm	5 cm	10 cm	12.5 cm	0.30 (fixo)
Base	BGTC	15 cm	20 cm	25 cm	0.25 (fixo)
Sub-base	Solo argiloso laterítico	15 cm	20 cm	25 cm	0.45 (fixo)
Subleito	11 solos (variável)	Não se aplica*			0.30 a 0.50
Tráfego - Número N	1×10^6 - 5×10^6 - 1×10^7 - 5×10^7 - 1×10^8				

* Para fins de simulação numérica, a espessura do subleito é considerada infinita.

Após as simulações, os resultados foram organizados e consolidados para compor o banco de dados final. As variáveis preditoras iniciais foram selecionadas com base na literatura, que aponta a relevância de atributos ligados à granulometria, índices de consistência, compactação, carregamento e estado de tensões (Liu et al., 2024; Mota et al., 2026; Saraiva et al., 2026), embora não haja consenso absoluto sobre o conjunto ideal de preditores. O banco de dados bruto continha as seguintes variáveis: carga por eixo, em ton. (L), número de repetições do eixo padrão (N), coeficiente de Poisson (ν), percentagem passante na peneira N°200, em % (P_{200}), teor de umidade ótimo, em % (w_{opt}), densidade aparente seca máxima, em g/cm³ ($\rho_{d,max}$), coeficiente de argilosidade (c'), índice de laterização (e'), índice de plasticidade, em % (IP), espessura equivalente sobre o subleito, em cm (Heq) e a variável resposta, deformação permanente, em mm (DP). A variável Heq consiste na soma das espessuras de cada camada ponderadas pelo respectivo fator de equivalência estrutural, conforme Manual de Pavimentação (DNIT, 2006). Em conjunto com o Número N, a variável Heq representa, de forma indireta, o estado de tensões atuante no subleito.

A Figura 2 apresenta a matriz de correlação aplicada ao conjunto de dados brutos. Para otimizar o modelo e evitar variáveis redundantes, foram excluídas as variáveis preditoras que apresentaram alta colinearidade entre si (r > 0,90) e baixa força de associação com a variável dependente (r < 0,10).



	L	N	ν	P_{200}	w_{opt}	$\rho_{d,max}$	c'	e'	IP	Heq	DP
L											
N	1.00										
ν	0.00	0.00									
P_{200}	0.00	0.00	0.00								
w_{opt}	0.00	0.00	0.00	0.91							
$\rho_{d,max}$	0.00	0.00	0.00	-0.91	-0.95						
c'	0.00	0.00	0.00	0.76	0.86	-0.74					
e'	0.00	0.00	0.00	-0.69	-0.60	0.56	-0.63				
IP	0.00	0.00	0.00	0.34	0.43	-0.37	0.49	-0.13			
Heq	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00		
DP	0.16	0.16	0.04	-0.39	-0.41	0.45	-0.48	0.57	0.09	-0.49	

Figura 2. Matriz de correlação das variáveis presentes no banco de dados bruto.

Pelo critério de exclusão mencionado e priorizando a manutenção de w_{opt} e N em função da recorrência destes parâmetros nos modelos consultados na literatura, restaram as seguintes preditoras para composição do banco de dados final: N, w_{opt}, c', e' e Heq. A exclusão de *outliers* não foi realizada de forma intencional com o objetivo de preservar amostras associadas a maiores valores de DP, que ocorrem em menor frequência em comparação à maior parte dos registros (DP < 5,0 mm). O banco de dados resultante contém 825 instâncias (linhas) e 5775 registros de dados. A Tabela 3 apresenta as estatísticas descritivas do banco de dados final.

Tabela 3. Estatística descrita do banco de dados final.

Variável	Média	Desvio Padrão	Mínimo	1° quartil	Mediana	3° quartil	Máximo	Assimetria	Curtose
N	3.32E+07	3.77E+07	1.00E+06	5.00E+06	1.00E+07	5.00E+07	1.00E+08	0.88	2.17
w_{opt}	19.85	4.75	13.00	15.40	19.50	24.00	28.90	0.31	2.26
c'	1.69	0.48	0.80	1.47	1.72	1.96	2.45	-0.26	2.43
e'	1.06	0.34	0.68	0.72	1.07	1.30	1.68	0.47	1.89
Heq	72.33	17.20	50.50	50.50	74.00	92.50	92.50	-0.14	1.50
DP	1.39	1.24	0.06	0.45	1.02	1.96	6.67	1.63	6.17

Em termos globais, a tabela evidencia não normalidade do conjunto de dados, com assimetria e curtose indicando distribuições assimétricas com caudas longas. Nesse contexto, o uso de técnicas como a EPR se justifica pela flexibilidade para capturar relações complexas e acomodar padrões de assimetria dos dados.

Para a modelagem por meio da EPR, adotou-se uma configuração de algoritmo com busca híbrida da estrutura ótima, combinando Algoritmo Genético e Evolução Diferencial, visando maximizar o ajuste e manter a parcimônia (menor número de termos polinomiais). A sensibilidade da variável resposta a cada variável foi avaliada por simulações de Monte Carlo, e o modelo final foi selecionado pelos critérios previamente definidos, incorporando também a análise de sensibilidade, de modo a assegurar modelos robustos, com bom desempenho e coerência física. Detalhes do algoritmo podem ser encontrados em (B. O. da Silva e Gomes, 2025; R. G. S. Gomes et al., 2022). O *software* MATLAB – versão R2024b foi utilizado nesta etapa.

O procedimento de treinamento incluiu a divisão dos dados em conjuntos de treinamento e teste, na proporção 75% - 25%. O processo envolveu 1000 gerações e 100 simulações de Monte Carlo para avaliação da análise de sensitividade. O número máximo de termos polinomiais foi definido em 5 e utilizou-se um *range* de expoentes de -3 a 3. Para avaliar robustez e capacidade de generalização do modelo, adotou-se um procedimento de validação cruzada do tipo Monte Carlo, com 3 repetições (denominadas *batches*).

O desempenho preditivo foi quantificado ao longo dos 3 *batches* por meio das métricas estatísticas: coeficiente de determinação (R^2), raiz do erro quadrático médio (RMSE), coeficiente de correlação (r) e erro médio absoluto (MAE). Os modelos foram também foram avaliados por curvas de sensibilidade da DP em função das variáveis de entrada, conferindo importância também à coerência das tendências paramétricas.

3 RESULTADOS E DISCUSSÕES

A Tabela 4 sintetiza o desempenho dos modelos selecionados nos três batches da validação cruzada, com base nas métricas de ajuste e de erro. A Figura 3, por sua vez, reúne: (a) o gráfico de dispersão entre os valores observados e os valores simulados; (b) a variação das métricas ao longo dos três batches de validação cruzada; e (c) os gráficos de sensibilidade da variável resposta (DP) em relação às cinco variáveis preditoras. Ressalta-se que as discussões a seguir devem ser interpretadas à luz do conjunto de amostras analisado, sendo sua validade restrita a materiais com características similares às consideradas neste estudo.

Tabela 4. Métricas de avaliação de desempenho dos modelos.

Métricas	*Batch* #1		*Batch* #2		*Batch* #3	
	Treino	Teste	Treino	Teste	Treino	Teste
R^2	0.833	0.797	0.802	0.797	0.798	0.798
RMSE (mm)	0.508	0.560	0.551	0.567	0.567	0.531
r	0.913	0.892	0.895	0.893	0.894	0.894
MAE (mm)	0.377	0.427	0.401	0.408	0.411	0.375

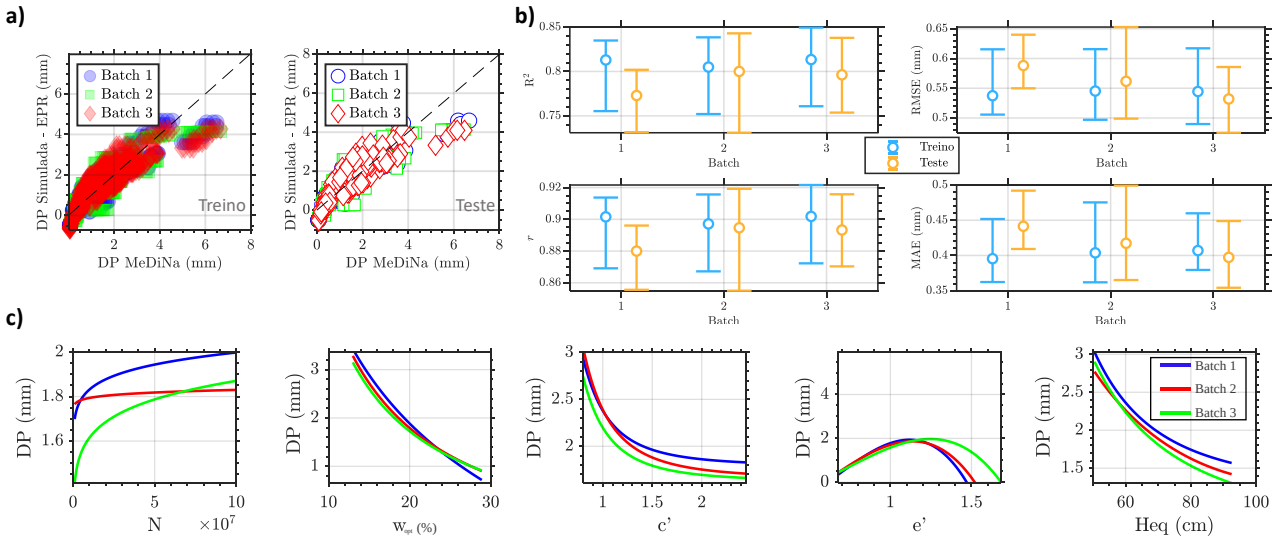


Figura 3. Desempenho e interpretação do modelo EPR para previsão da DP.

A Figura 3a mostra a relação entre os valores de DP obtidos no MeDiNa e as estimativas produzidas pelos modelos EPR, para treino e teste nos três *batches* de validação cruzada. Observa-se boa aderência dos pontos à linha 1:1 até cerca de DP ≈ 5 mm. Para valores superiores, nota-se uma tendência de subestimação, o que leva a uma subavaliação do dano por DP. Esse comportamento tem relação com a própria composição do banco de dados, uma vez que mais de 90% dos registros apresentam DP < 5 mm, de modo que o processo de calibração fica naturalmente mais "informado" nessa região. Assim, duas estratégias tendem a melhorar o desempenho global: a primeira seria complementar o banco com mais amostras na faixa DP > 5 mm, reduzindo o viés amostral; ou restringir o domínio de aplicação, o que pode aumentar a precisão e a consistência do modelo dentro do intervalo de interesse.

A Figura 3b, em conjunto com a Tabela 4, evidencia que os três modelos obtidos nos *batches* apresentaram desempenho muito semelhante, tanto em treino quanto em teste, além de variabilidade comparável ao longo das simulações. Os valores de treino e teste são próximos em todos os *batches*, sugerindo baixa tendência a sobreajuste e boa capacidade de generalização dentro do domínio amostral considerado.

Por fim, a Figura 3c sintetiza as análises de sensibilidade, permitindo verificar a consistência paramétrica dos modelos nos três *batches*. De modo geral, as curvas indicam tendências coerentes e, em grande parte, semelhantes entre si, o que reforça a estabilidade da configuração algorítmica adotada. A variável N apresentou relação positiva com a DP em todos os *batches*, como esperado, embora com diferenças de forma entre as curvas, indicando maior sensibilidade a efeitos de amostragem nessa variável. O parâmetro e' também exibiu tendência predominantemente positiva com a DP até cerca de e' ≈ 1,3, com alteração de comportamento a partir desse ponto, atribuída à baixa densidade de dados nessa faixa, o que reduz a confiabilidade local da sensitividade. Valores de e' acima de aproximadamente 1,15, indicam comportamento não laterítico para solos finos, em geral associado a menor resistência e maior deformabilidade (Nogami e Villibor, 1991). O padrão observado é compatível com evidências recentes obtidas por modelagem desenvolvida por Saraiva et al. (2026).

As demais variáveis apresentaram relação negativa com a DP. Para w_{opt}, apesar de diversos autores associarem maiores teores de umidade (estado) a maiores deformações permanentes (Pascoal, 2024; Santos, 2020; M. F. da Silva et al., 2021), aqui discute-se o efeito da umidade ótima entre solos distintos: valores mais elevados de w_{opt} tendem a indicar maior fração de finos (Elkady et al., 2013). Em condição não saturada, comum em subleitos tropicais operando próximos ao teor ótimo (Medina e Motta, 2015), isso pode favorecer valores de sucção mais elevados, aumentando a tensão efetiva e reduzindo a deformabilidade plástica, em concordância com achados reportados por Everton e Erlingsson (2024) e Santos et al. (2024). O comportamento de c' acompanha essa interpretação, uma vez que maiores valores de c' também indicam materiais mais finos/argilosos e, portanto, maior propensão a w_{opt} mais alto. Por sua vez, Heq apresentou o comportamento mecanístico esperado: maiores espessuras equivalentes implicam maior atenuação das tensões transmitidas ao subleito, resultando em menores valores de DP. A equação a seguir apresenta o modelo obtido

no *batch* #3, o qual apresentou o melhor desempenho segundo as métricas estatísticas avaliadas. A equação apresenta apenas quatro termos polinomiais e permite a obtenção rápida de estimativas de DP.

$$\mathrm{DP} = -2{,}15 + \frac{0{,}54}{c'^{3{,}0}}. + \frac{1026{,}43.\mathrm{N}^{0{,}1}}{\mathrm{Heq}^{2.0}} - \frac{413{,}86}{w_{opt}} e'^{3{,}0} + \frac{463{,}47}{w_{opt}} e'^{2.8} \quad (1)$$

4 CONCLUSÃO

Os resultados indicam que a abordagem proposta produziu modelos robustos, com boa capacidade de predição, generalização e desempenho consistente sob validação cruzada. O diferencial do modelo está na possibilidade de obteção de estimativas confiáveis de DP a partir de parâmetros de fácil obtenção. Além disso, a equação produzida é transparente e fisicamente interpretável. Em conjunto, esses atributos permitem a compreensão do fenômeno modelado e favorecem o uso prático do modelo, aspecto corroborado pelas curvas de sensitividade. Como principal limitação, observou-se redução da precisão para DP > 5 mm, com tendência de subestimação, associada à baixa representatividade dessa faixa no banco de dados. Como trabalhos futuros, recomenda-se ampliar e balancear o banco com mais observações em níveis elevados de DP, investigar modelos específicos por faixa de DP e avaliar a transferência dos modelos para bases independentes.

AGRADECIMENTOS

O primeiro autor agradece o Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

REFERÊNCIAS BIBLIOGRÁFICAS

Cabral, W. S., De Barroso, S. H. A., e De E Silva, S. A. T. (2021). Consideration of the permanent deformation of soils that occurred in the northeast region in the mechanistic-empirical analysis of pavements. *Revista Materia*, *26*(4). https://doi.org/10.1590/S1517-707620210004.1396

da Silva, B. O., e Gomes, G. J. C. (2025). Resilient modulus of fine-grained tropical soils from sensitivity-driven evolutionary polynomial regression. *Transportation Geotechnics*, *55*. https://doi.org/10.1016/j.trgeo.2025.101709

de Carvalho, J. C., de Rezende, L. R., Cardoso, F. B. da F., Lucena, L. C. de F. L., Guimarães, R. C., e Valencia, Y. G. (2015). Tropical soils for highway construction: Peculiarities and considerations. *Transportation Geotechnics*, *5*, 3–19. https://doi.org/10.1016/j.trgeo.2015.10.004

de Lima, C. D. A., da Motta, L. M. G., e Aragão, F. T. S. (2021). Permanent deformation tests: Effect of the number of loading cycles on the interpretation of the behavior of soils and gravels. *Revista Materia*, *26*(3). https://doi.org/10.1590/S1517-707620210003.13044

DER - SP. (2025). Instrução de Projeto - IP-DE-P00/001 D. Em *Departamento de Estradas de Rodagem do Estado de São Paulo* (p. 1–86).

DNIT. (2006). Manual de Pavimentação - Publicação IPR-719. Em *Departamento Nacional de Infraestrutura de Transportes* (IPR-719; p. 1–274).

DNIT. (2021). Instrução de Serviço-IS-247: Estudos para Elaboração de Projetos de Implantação usando o Método de Dimensionamento Nacional – MeDiNa. Em *DNIT* (p. 1–22). DNIT.

Elkady, T. Y., Dafalla, M. A., Al-Mahbashi, A. M., e Al Shamrani, M. (2013). Evaluation of Soil Water Characteristic Curves of Sand-Clay Mixtures. *International Journal of GEOMATE*, *4*, 528–532.

Everton, J. H. C., e Erlingsson, S. (2024). Characterising the permanent deformation of subgrade soils under seasonal variation. *Canadian Journal of Civil Engineering*, *52*(3), 317–333. https://doi.org/10.1139/cjce-2024-0077

Giustolisi, O., e Savic, D. A. (2006). A symbolic data-driven technique based on evolutionary polynomial regression. *Journal of Hydroinformatics*, *8*(4), 235–237. https://doi.org/10.2166/hydro.2006.020

Gomes, G. J. C., Gomes, R. G. de S., e Vargas, E. do A. (2021). A dual search-based EPR with self-adaptive offspring creation and compromise programming model selection. *Engineering with Computers*, *38*, 2155–2173. https://doi.org/10.1007/s00366-021-01313-x

Gomes, R. G. S., Gomes, G. J. C., e Vrugt, J. A. (2022). A hybrid multi-step sensitivity-driven evolutionary polynomial regression enables robust model structure selection. *Engineering Applications of Artificial Intelligence*. https://doi.org/10.1016/j.engappai.2022.105421

Guimarães, A. C. R. (2001). *Estudo de Deformação Permanente em Solos e a Teoria do Shakedown Aplicada à Pavimentos Flexíveis*. Universidade Federal do Rio de Janeiro.

Guimarães, A. C. R. (2009). *Um Método Mecanístico-Empírico para a Previsão da Deformação Permanente em Solos Tropicais Constituintes de Pavimento*. Universidade Federal do Rio de Janeiro.

Liu, X., Li, J., Liu, J., Huang, C., e Liu, L. (2024). Prediction of permanent deformation of subgrade soils under F-T cycles using SABO-optimized CNN-BiLSTM network. *Case Studies in Construction Materials*, *21*. https://doi.org/10.1016/j.cscm.2024.e03807

Medina, J. de, e Motta, L. M. G. da. (2015). *Mecânica dos pavimentos* (3a). Editora Interciência.

Mota, B. C., da Silva, G. V., Ubaldo, M. de O., de Lima, C. D. A., Espíndola, R. P., do Nascimento, L. A. H., e Aragão, F. T. S. (2026). A data-driven approach to optimize the permanent deformation analysis of soils and granular materials based on the construction of master curves. *International Journal of Pavement Engineering*, *27*(1). https://doi.org/10.1080/10298436.2026.2613101

Nogami, J. S., e Villibor, D. F. (1991). Use of lateritic fine-grained soils in road pavement base courses. *Geotechnical and Geological Engineering*, *9*, 167–182. https://doi.org/https://doi.org/10.1007/BF00881739

Norback, C. (2018). *Caracterização do Módulo de Resiliência e da Deformação Permanente de Três Solos e Misturas Solos-Brita*. Universidade Federal do Rio de Janeiro.

Pascoal, P. T. (2020). *Estudo da Influência da Compactação no Comportamento Resiliente e Deformação Permanente de Solo Laterítico do Rio Grande do Sul*. Universidade Federal de Santa Maria.

Pascoal, P. T. (2024). *Deformabilidade de subleitos de trechos monitorados da BR-116 considerando variações de umidade em laboratório e campo*. Universidade Federal de Santa Maria.

Rezania, M., Javadi, A. A., e Giustolisi, O. (2010). Evaluation of liquefaction potential based on CPT results using evolutionary polynomial regression. *Computers and Geotechnics*, *37*(1–2), 82–92. https://doi.org/10.1016/j.compgeo.2009.07.006

Romanoschi, S. A. (2017). Empirical Models for Permanent Deformation of Subgrade Soils from the Data Collected at the Pavement Subgrade Performance Study. *Journal of Materials in Civil Engineering*, *29*(3). https://doi.org/10.1061/(asce)mt.1943-5533.0001785

Salour, F., Rahman, M. S., e Erlingsson, S. (2016). Characterizing Permanent Deformation of Silty Sand Subgrades by Using a Model Based on Multistage Repeated-Load Triaxial Testing. Em *Transportation Research Record* (Vol. 2578, Número 1, p. 47–57). SAGE Publications Ltd. https://doi.org/10.3141/2578-06

Santos, T. A. dos, Pinheiro, R. J. B., e Specht, L. P. (2024). Effects of moisture content and soil suction on the permanent deformation of tropical subgrade soils: experimental investigations and modelling. *Road Materials and Pavement Design*, *25*(11), 2358–2381. https://doi.org/10.1080/14680629.2024.2310823

Santos, T. A. (2020). *A influência da sucção na deformabilidade de subleitos rodoviários: efeitos da variação de umidade, método de compactação e gênese dos solos*. Universidade Federal de Santa maria.

Saraiva, F. M. G., Guimarães, A. C. R., Júnior, O. S. da S., Monteiro, S. N., e Coelho, L. M. (2026). Performance analysis of Gradient Boosting Regressor Using K-fold and Group K-fold for Predicting Permanent Deformation in Tropical Soils. *Journal of Materials Research and Technology*. https://doi.org/10.1016/j.jmrt.2025.12.152

Silva, M. F. da, Ribeiro, M. M. P., Furlan, A. P., e Fabbri, G. T. P. (2021). Effect of compaction water content and stress ratio on permanent deformation of a subgrade lateritic soil. *Transportation Geotechnics*, *26*. https://doi.org/10.1016/j.trgeo.2020.100443

Singh, A. K., e Sahoo, J. P. (2021). Rutting prediction models for flexible pavement structures: A review of historical and recent developments. Em *Journal of Traffic and Transportation Engineering (English Edition)* (Vol. 8, Número 3, p. 315–338). Chang'an University. https://doi.org/10.1016/j.jtte.2021.04.003

Sousa, M. A. da S., Coutinho, R. Q., e Motta, L. M. G. da. (2023). Analysis of the unsaturated behaviour of compacted lateritic fine-grained tropical soils for use in transport infrastructure. *Road Materials and Pavement Design*, *24*(1), 31–58. https://doi.org/10.1080/14680629.2021.2009008

Zago, J. P. (2016). *Estudo da Deformação Permanente de Três Solos Típicos de Subleitos Rodoviários de Santa Maria - RS*. Universidade Federal de Santa Maria.

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/COBRAMSEG2026.2/20

Modelo Constitutivo Baseado em Redes Neurais Artificiais para Areias Reforçadas com Fibras Poliméricas

João Paulo de Araújo Rodrigues
Mestrando, Universidade Federal de Uberlândia, Uberlândia, Brasil, jparodrigues@ufu.br

Michael Andrade Maedo
Professor, Universidade Federal de Uberlândia, Uberlândia, Brasil, michael.maedo@ufu.br

Sandro Lemos Machado
Professor, UFBA, Salvador, Brasil, smachado@ufba.br

RESUMO: Este trabalho apresenta um modelo constitutivo baseado em redes neurais artificiais do tipo Multilayer Perceptron (MLP) para a previsão do comportamento mecânico de areias reforçadas com fibras poliméricas submetidas a ensaios triaxiais drenados. A estratégia adotada combina pré-treinamento com dados sintéticos gerados pelo modelo constitutivo de Machado *et al*. (2002, 2024), seguido de ajuste fino (*fine-tuning*) com dados experimentais de ensaios triaxiais. A rede neural, composta por uma camada de entrada com 4 variáveis, três camadas ocultas com 256, 128 e 64 neurônios, e uma camada de saída com 3 variáveis (arquitetura 4-256-128-64-3), recebe como entrada a tensão de confinamento, o teor e comprimento da fibra e a deformação axial, prevendo diretamente a tensão desviadora, a tensão média efetiva e a deformação volumétrica. Os resultados demonstram que o modelo proposto é capaz de prever curvas tensão-deformação completas de ensaios nunca vistos durante o treinamento, atingindo coeficientes de determinação globais de 0,988 para a tensão desviadora, 0,995 para a tensão média efetiva e 0,920 para a deformação volumétrica. O ganho proporcionado pelo ajuste fino é evidenciado pela melhoria expressiva nas métricas em relação ao modelo apenas pré-treinado, validando a estratégia de transferência de aprendizado.

PALAVRAS-CHAVE: Redes Neurais Artificiais, Modelo Constitutivo, Solo Reforçado com Fibras, Transferência de Aprendizado, Ensaio Triaxial.

ABSTRACT: This paper presents a constitutive model based on Multilayer Perceptron (MLP) artificial neural networks for predicting the mechanical behavior of fiber-reinforced sands under drained triaxial tests. The adopted strategy combines pre-training with synthetic data generated from the constitutive model by Machado *et al*. (2002, 2024), followed by fine-tuning with experimental triaxial test data. The neural network consists of an input layer with 4 variables, three hidden layers with 256, 128, and 64 neurons, and an output layer with 3 variables (4-256-128-64-3 architecture), receiving confining pressure, fiber content, fiber length, and axial strain as inputs, directly predicting deviatoric stress, mean effective stress, and volumetric strain. Results demonstrate that the proposed model can predict complete stress-strain curves for tests never seen during training, achieving global coefficients of determination of 0.988 for deviatoric stress, 0.995 for mean effective stress, and 0.920 for volumetric strain. The improvement provided by fine-tuning is evidenced by significant metric gains compared to the pre-trained-only model, validating the transfer learning strategy.

KEYWORDS: Artificial Neural Networks, Constitutive Model, Fiber-Reinforced Soil, Transfer Learning, Triaxial Test.

1 INTRODUÇÃO

O reforço de solos com fibras poliméricas tem se consolidado como uma técnica promissora na engenharia geotécnica, proporcionando melhorias significativas na resistência ao cisalhamento e na ductilidade de solos arenosos. A inclusão aleatória de fibras no solo promove uma distribuição mais uniforme

das tensões e restringe a formação de planos preferenciais de ruptura, resultando em um comportamento mais isotrópico do compósito solo-fibra (Diambra *et al*., 2010).

A modelagem constitutiva de solos reforçados com fibras representa um desafio considerável, uma vez que o comportamento mecânico do compósito depende de múltiplos fatores, como o teor e o comprimento das fibras, a tensão de confinamento e o índice de vazios inicial. Modelos constitutivos clássicos, como o Cam-Clay Modificado, têm sido adaptados para incorporar o efeito das fibras (Diambra *et al*., 2013), porém requerem calibração cuidadosa de parâmetros e podem apresentar limitações na representação de comportamentos complexos, como a transição entre contração e dilatância volumétrica.

Nesse contexto, as redes neurais artificiais (RNA) têm emergido como uma alternativa robusta para a modelagem de materiais geotécnicos. A capacidade das RNA de aproximar funções não lineares arbitrárias as torna adequadas para capturar relações complexas entre variáveis de estado e variáveis de resposta do solo. A aplicação de aprendizado de máquina tem se mostrado uma ferramenta poderosa na engenharia geotécnica desde os trabalhos pioneiros para a previsão de comportamento e resposta de solos em diferentes contextos (Ghaboussi *et al.*, 1991; Goh, 1994; Cabalar *et al.*, 2012). Mais recentemente, essas abordagens vêm sendo aplicadas com sucesso para capturar a complexidade da interação matriz-inclusão e prever parâmetros mecânicos, como resistência ao cisalhamento e rigidez, especificamente em solos reforçados com fibras (Chou *et al.*, 2016; Al-Janabi *et al.*, 2023).

Um desafio recorrente na aplicação de RNA à modelagem constitutiva é a escassez de dados experimentais, uma vez que ensaios triaxiais são custosos e demorados. A técnica de transferência de aprendizado (*transfer learning*) oferece uma solução para esse problema, permitindo que uma rede pré-treinada com dados sintéticos abundantes seja refinada com um conjunto menor de dados experimentais (Pan e Yang, 2010). Essa estratégia combina o conhecimento prévio do modelo numérico com a fidelidade dos dados laboratoriais.

O presente trabalho propõe um modelo constitutivo baseado em uma rede neural do tipo *Multilayer Perceptron* (MLP) para a previsão do comportamento mecânico de areias reforçadas com fibras poliméricas. A metodologia emprega um *pipeline* de treinamento em duas fases: pré-treinamento com dados sintéticos gerados a partir da formulação elasto-plástica proposta por Machado *et al.* (2002) e validada para solos reforçados por Machado *et al.* (2024), seguido de ajuste fino com dados experimentais de ensaios triaxiais drenados. A validação é realizada por meio da previsão de curvas tensão-deformação de ensaios completos reservados exclusivamente para teste, não utilizados em nenhuma etapa do treinamento.

2 MATERIAIS E MÉTODOS

2.1 Dados Sintéticos

Os dados sintéticos foram gerados a partir de simulações numéricas de ensaios triaxiais drenados. O arcabouço matemático utilizado baseia-se no framework elasto-plástico proposto por Machado *et al*. (2002), incorporando as adaptações para a inclusão de fibras descritas em Machado *et al*. (2024). A formulação constitutiva emprega a teoria do Cam-Clay Modificado como estrutura matemática de base.

Os parâmetros do modelo numérico foram calibrados utilizando os ensaios de Conceição *et al.* (2022) como referência. Foram simuladas 42 trajetórias de carregamento, combinando seis tensões de confinamento (50, 100, 150, 200, 250 e 300 kPa) com sete configurações de reforço: uma sem fibras e seis com fibras (teores de 0,5% e 1,0%, comprimentos de 12,5, 25 e 51 mm). Após a remoção de pontos sem variação de tensão ou deformação, o conjunto de dados sintéticos totaliza 8.887 pontos.

2.2 Dados Experimentais

Os dados experimentais foram obtidos a partir de ensaios triaxiais drenados conduzidos por Conceição *et al.* (2022) em areia uniforme reforçada com fibras de polipropileno, com teor de fibra fixado em 1,0%. Foram realizados 12 ensaios, combinando quatro tensões de confinamento (50, 100, 200 e 300 kPa) com três comprimentos de fibra (12,5, 25 e 51 mm). Após o tratamento dos dados, que incluiu a remoção de pontos inconsistentes e a filtragem de ruídos de medição, o conjunto experimental final totalizou 551 pontos.

2.3 Estratégia de Validação

Para garantir uma validação cientificamente rigorosa, adotou-se a estratégia de validação *leave-one-out* (exclusão de ensaios completos), na qual três ensaios experimentais foram integralmente reservados para validação, sendo excluídos de qualquer etapa do treinamento. Dessa forma, o modelo é avaliado em condições nunca vistas, garantindo uma medida realista de sua capacidade de generalização. Os ensaios selecionados abrangem diferentes condições de confinamento e comprimento de fibra, conforme apresentado na Tabela 1. Os nove ensaios restantes (413 pontos) foram utilizados no ajuste fino.

Tabela 1. Ensaios experimentais reservados para validação.

Ensaio	σ_3 (kPa)	L (mm)	Pontos
1	50	25,0	48
2	200	51,0	43
3	300	12,5	47

2.4 Sequência de Treinamento

O treinamento segue uma sequência em duas fases. Na Fase 1 (pré-treinamento), a rede é treinada com os 8.887 pontos sintéticos utilizando o otimizador Adam (Kingma e Ba, 2015), com taxa de aprendizado inicial de 10^{-3} e redução automática quando a função de perda estagna, por até 500 épocas. Adota-se o critério de parada antecipada (*early stopping*), que interrompe o treinamento caso não haja melhoria na função de perda de validação após 40 épocas consecutivas, evitando o sobreajuste aos dados de treino. O objetivo é que a rede aprenda os padrões constitutivos gerais do modelo de Machado *et al.* (2024).

Na Fase 2 (ajuste fino), os pesos pré-treinados são refinados com os 413 pontos experimentais de treino. Emprega-se uma estratégia de liberação progressiva das camadas, na qual os parâmetros da rede são ajustados de forma gradual e controlada.

Inicialmente, apenas os parâmetros da camada de saída são atualizados, mantendo-se fixos os pesos das camadas anteriores (Fase A, épocas 1-30). Em seguida, libera-se o ajuste das duas últimas camadas (Fase B, épocas 31-60), depois das três últimas (Fase C, épocas 61-100) e, por fim, toda a rede tem seus parâmetros ajustados simultaneamente (Fase D, a partir da época 101), com taxas de aprendizado progressivamente menores a cada fase. Essa abordagem gradual evita o esquecimento catastrófico, fenômeno em que o ajuste fino com novos dados sobrescreve o conhecimento adquirido no pré-treinamento.

3 RESULTADOS E DISCUSSÃO

3.1 Histórico de Treinamento

A Figura 1 apresenta a evolução da função de perda (*loss function*) ao longo das épocas de treinamento nas duas fases do processo. A função de perda é uma métrica que quantifica o erro quadrático médio entre as previsões da rede neural e os valores reais, sendo que valores menores indicam melhor ajuste do modelo aos dados. O gráfico exibe tanto a perda calculada sobre o conjunto de treinamento quanto sobre o conjunto de validação, permitindo avaliar a capacidade de generalização da rede.

Na Fase 1 (pré-treinamento), o erro nos dados sintéticos decresce rapidamente nas primeiras épocas, indicando a assimilação eficiente dos padrões da formulação de Machado *et al.* (2024). Em contrapartida, o erro de validação estabiliza-se em um patamar superior, evidenciando as limitações do modelo analítico em reproduzir fielmente as complexidades experimentais. Assim, a Fase 1 foi interrompida na época 51 pelo critério de parada antecipada (*early stopping*), após 40 épocas sem melhoria significativa na validação.

Na Fase 2 (ajuste fino), tanto o erro de treino quanto o de validação decrescem de forma consistente ao longo das fases de liberação progressiva das camadas (indicadas no gráfico como Fases A, B, C e D). É notável que a redução no erro de validação acompanha a redução no erro de treino, evidenciando que a rede se adapta efetivamente aos dados experimentais sem perder a capacidade de generalização para ensaios não vistos. A

ausência de divergência entre as curvas de treino e validação demonstra que não houve sobreajuste (*overfitting*) aos dados de treinamento, validando a eficácia da estratégia de liberação progressiva e das taxas de aprendizado decrescentes empregadas.

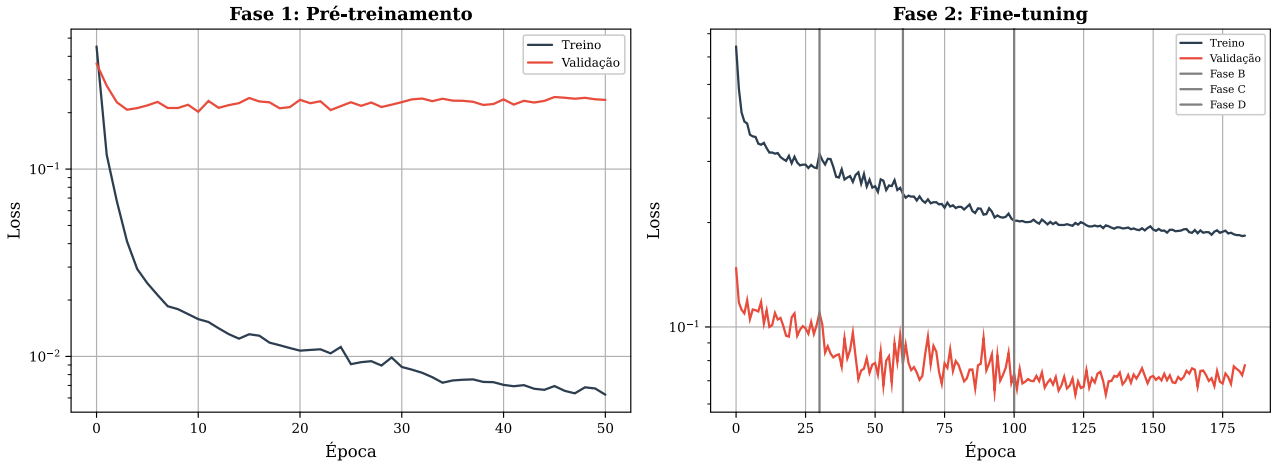


Figura 1. Histórico de treinamento: Fase 1 (pré-treinamento com dados sintéticos) e Fase 2 (ajuste fino com dados experimentais, com indicação das fases de liberação progressiva).

3.2 Curvas Tensão-Deformação

A Figura 2 apresenta as curvas de validação para os três ensaios reservados. Na linha superior, são exibidas as curvas de evolução da tensão desviadora com a deformação axial (εa, q), e na linha inferior, as curvas de variação da deformação volumétrica com a deformação axial (εa, εv). Em cada gráfico, são comparadas quatro curvas: os dados experimentais (pontos pretos), a resposta do modelo de Machado *et al*. (2024) (verde, traço-ponto), a previsão da RNA apenas com pré-treinamento (cinza tracejado) e a previsão após o ajuste fino (vermelho).

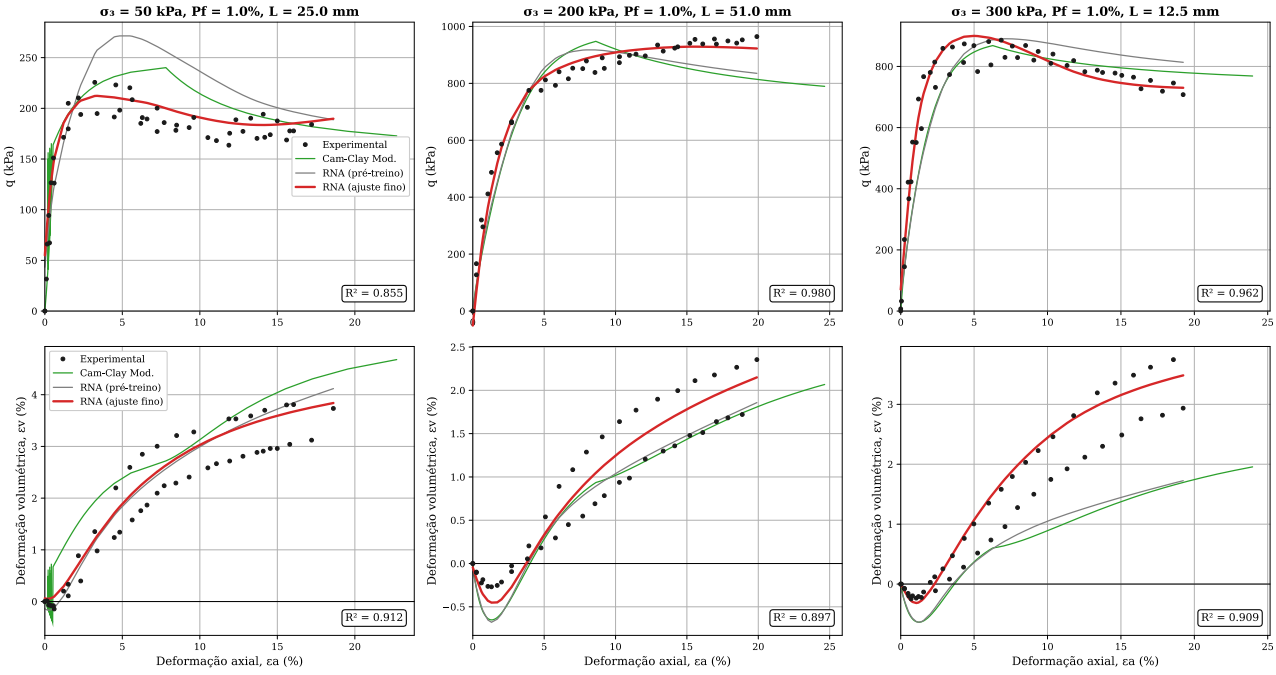


Figura 2. Curvas de validação: tensão desviadora q versus deformação axial εa (superior) e deformação volumétrica εv *versus* deformação axial εa (inferior) para os três ensaios de validação.

A qualidade das previsões é avaliada pelo coeficiente de determinação (R^2), que varia de 0 a 1 e indica a proporção da variação dos dados experimentais que é explicada pelo modelo. Valores próximos a 1 representam previsões muito próximas dos dados reais, enquanto valores baixos indicam previsões insatisfatórias.

Para o ensaio com σ_3 = 200 kPa (R^2 = 0,980), o modelo apresenta boa concordância com os dados experimentais, reproduzindo adequadamente tanto o pico de resistência quanto o comportamento pós-pico. No ensaio com σ_3 = 300 kPa (R^2 = 0,962), a curva prevista acompanha adequadamente a tendência experimental, inclusive na região de amolecimento. O ensaio com σ_3 = 50 kPa apresenta o menor R^2 (0,855), o que se explica pela maior variabilidade experimental típica de baixos confinamentos e pelo comportamento de amolecimento mais acentuado.

Em relação às curvas de deformação volumétrica, o modelo captura adequadamente a transição entre contração inicial e dilatância subsequente em todos os três ensaios, com R^2 variando de 0,897 a 0,912. Esse comportamento não monotônico é particularmente desafiador para modelos de aprendizado de máquina e demonstra a eficácia do pré-treinamento com dados do modelo constitutivo, que fornece à rede o conhecimento prévio sobre os padrões de variação volumétrica.

3.3 Análise Global

A Figura 3 apresenta os diagramas de dispersão entre valores previstos e experimentais para a tensão desviadora (q) e a tensão média efetiva (p'). Os pontos distribuem-se próximos à linha de igualdade 1:1, com R^2 global de 0,988 para q e 0,995 para p'.

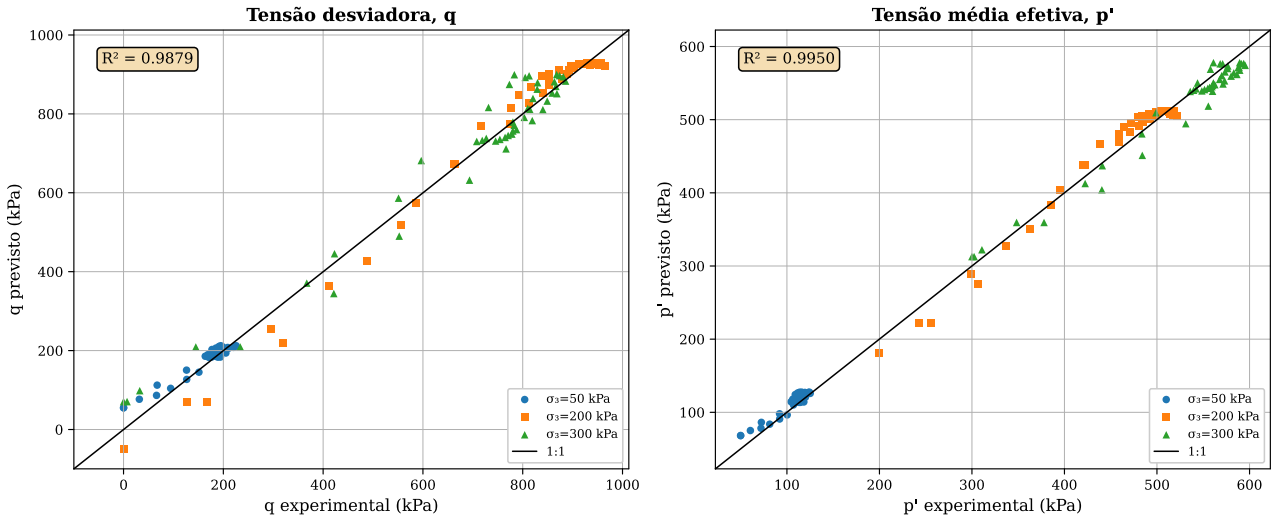


Figura 3. Diagramas de dispersão entre valores previstos e experimentais para tensão desviadora (q) e tensão média efetiva (p').

A Tabela 2 sintetiza as métricas de desempenho por ensaio de validação e globais. Destaca-se que o ajuste fino elevou o R^2 da deformação volumétrica de 0,754 (apenas pré-treinamento) para 0,920, demonstrando o ganho expressivo proporcionado pela transferência de aprendizado. As métricas para q e p' também apresentaram melhorias, passando de 0,949 para 0,988 e de 0,985 para 0,995, respectivamente.

Tabela 2. Métricas de desempenho do modelo (R^2) nos ensaios de validação.

Ensaio	R^2(q)	R^2(p')	R^2(εv)
σ_3=50 kPa, L=25,0 mm	0,855	0,732	0,912
σ_3=200 kPa, L=51,0 mm	0,980	0,972	0,897
σ_3=300 kPa, L=12,5 mm	0,962	0,956	0,909
Global	**0,988**	**0,995**	**0,920**

Os resultados indicam que a estratégia de transferência de aprendizado é particularmente eficaz quando aplicada com liberação progressiva, permitindo que as camadas iniciais da rede preservem os padrões constitutivos gerais aprendidos do modelo de Machado *et al*. (2024), enquanto as camadas finais se adaptam às especificidades dos dados experimentais. O modelo com ajuste fino supera consistentemente o modelo apenas pré-treinado em todas as métricas e ensaios avaliados.

4 CONCLUSÕES

Este trabalho apresentou um modelo constitutivo baseado em redes neurais artificiais do tipo MLP para a previsão do comportamento de areias reforçadas com fibras poliméricas. Os resultados obtidos permitem as seguintes conclusões.

A estratégia de transferência de aprendizado, combinando pré-treinamento com dados sintéticos do modelo de Machado *et al*. (2024) e ajuste fino com dados experimentais, mostrou-se eficaz para superar a limitação de dados experimentais escassos, desafio recorrente na modelagem constitutiva de materiais geotécnicos. O ganho mais expressivo foi observado na previsão da deformação volumétrica, cujo R^2 passou de 0,754 para 0,920.

O modelo proposto é capaz de prever curvas tensão-deformação completas de ensaios nunca vistos durante o treinamento, com coeficientes de determinação superiores a 0,85 para a tensão desviadora e superiores a 0,89 para a deformação volumétrica em todos os ensaios de validação. As métricas globais atingem R^2 de 0,988 (q), 0,995 (p') e 0,920 (εv), demonstrando que redes neurais artificiais constituem uma ferramenta viável para a modelagem de solos reforçados com fibras, capturando fenômenos complexos como transição contração-dilatância e comportamento pós-pico.

A liberação progressiva das camadas da rede durante o ajuste fino demonstrou ser essencial para evitar o esquecimento catastrófico, permitindo que a rede preserve o conhecimento constitutivo geral do pré-treinamento enquanto se adapta às especificidades dos dados experimentais.

AGRADECIMENTOS

Os autores agradecem à Universidade Federal de Uberlândia (UFU) e ao Programa de Pós-Graduação em Engenharia Civil pelo apoio institucional. O presente trabalho foi realizado com apoio financeiro da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001, do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), por meio do Processo nº 134533/2025-9, e da Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG), por meio do processo APQ-00990-22 (Edital N 001/2022).

REFERÊNCIAS BIBLIOGRÁFICAS

Al-Janabi, A. M. A. *et al*. (2023) Prediction of Elastic Modulus for Fibre-Reinforced Soil-Cement Mixtures: A Machine Learning Approach. *Applied Sciences*, 13(4), 2345.

Cabalar, A.F., Cevik, A., Gokceoglu, C. (2012) Some applications of Adaptive Neuro-Fuzzy Inference System (ANFIS) in geotechnical engineering. *Computers and Geotechnics*, 40, p.14-33.

Chou, J.-S., Yang, K.-H., Lin, J.-Y. (2016) Peak shear strength of discrete fiber-reinforced soils computed by machine learning and metaensemble methods. *Journal of Computing in Civil Engineering*, 30(6), 04016036.

Conceição, M.P.S., Carvalho, M.F., Machado, S.L. (2022) Análise do comportamento tensão-deformação de uma areia uniforme reforçada com fibra polimérica. In: Anais do XX Congresso Brasileiro de Mecânica dos Solos e Engenharia Geotécnica (COBRAMSEG), Campinas, SP, 23-26 agosto. DOI: 10.4322/cobramseg.2022.0950.

Diambra, A., Ibraim, E., Muir Wood, D., Russell, A.R. (2010) Fibre reinforced sands: experiments and modelling. *Geotextiles and Geomembranes*, 28(3), p.238-250.

Diambra, A., Ibraim, E., Muir Wood, D. (2013) Fibre reinforced sands: from experiments to modelling and beyond. *International Journal for Numerical and Analytical Methods in Geomechanics*, 37(13), p.2427-2455.

Ghaboussi, J., Garrett, J.H., Wu, X. (1991) Knowledge-based modeling of material behavior with neural networks. *Journal of Engineering Mechanics*, 117(1), p.132-153.

Goh, A.T.C. (1994) Seismic liquefaction potential assessed by neural networks. *Journal of Geotechnical Engineering*, 120(9), p.1467-1480.

Kingma, D.P., Ba, J. (2015) Adam: A method for stochastic optimization. In: International Conference on Learning Representations (ICLR), San Diego. *Proceedings...* p.1-15.

Machado, S.L., Carvalho, M.F., Vilar, O.M. (2002) Constitutive model for municipal solid waste. *Journal of Geotechnical and Geoenvironmental Engineering*, 128(11), p.940-951.

Machado, S.L., Vilar, O.M., Carvalho, M.F., Karimpour-Fard, M., Pinto, C.M.T., Conceição, M.P.S. (2024) Modeling the mechanical behaviour of fibre reinforced sands. *Geomechanics and Geoengineering*. DOI: 10.1080/17486025.2024.2319619.

Pan, S.J., Yang, Q. (2010) A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10), p.1345-1359.

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/COBRAMSEG2026.2/21

Modelo neural para previsão da capacidade de carga de estacas pré-moldadas de concreto

Juliele Nascimento Jesus
Docente, DTEC/UEFS, Feira de Santana – BA, Brasil, jnjesus@uefs.br

Maria do Socorro Costa São Mateus
Docente, PPGECEA/UEFS, Feira de Santana – BA, Brasil, socorro@uefs.br

Anderson de Souza Matos Gádea
Docente, DTEC/UEFS, Feira de Santana – BA, Brasil, gadea@uefs.br

RESUMO: A estimativa da capacidade de carga de estacas continua sendo um desafio na engenharia geotécnica, em razão da heterogeneidade dos solos e da complexidade do mecanismo de interação solo-estaca. Este artigo apresenta um modelo de rede neural do tipo *perceptron* multicamadas, treinado com o algoritmo de *Levenberg-Marquardt*, com o objetivo de prever a capacidade de carga de estacas pré-moldadas de concreto. O banco de dados utilizado reuniu resultados de sondagens SPT e de provas de carga estática e dinâmica realizadas em 141 estacas pré-moldadas de concreto. A determinação da capacidade de carga foi realizada a partir das curvas carga-recalque, aplicando o método de Van der Veen (1953) e os critérios da NBR 6122 (ABNT, 2022). As variáveis de entrada consideradas no modelo foram: diâmetro e comprimento da estaca, valor de N_{SPT} e tipo de solo. Diferentes combinações dessas variáveis foram testadas e validadas no MATLAB®, sendo selecionada a configuração com melhor desempenho a partir dos coeficientes de determinação (R^2) e do erro quadrático médio (RMSE). Os resultados obtidos, com R^2 de 0,85 e RMSE de 0,06, mostraram-se satisfatórios diante da complexidade do problema. O estudo de caso mostrou que o modelo proposto apresentou desempenho superior aos métodos semiempíricos de Aoki-Velloso (1975) e Décourt-Quaresma (1978). Dessa forma, a rede neural *perceptron* multicamadas mostra-se uma ferramenta com potencial para a previsão da capacidade de carga de estacas pré-moldadas de concreto.

PALAVRAS-CHAVE: Capacidade de Carga, Redes Neurais Artificiais (RNA), Estacas Pré-moldadas de Concreto.

ABSTRACT: Predicting pile bearing capacity remains a critical issue in geotechnical engineering due to heterogeneous soil conditions and the complex mechanisms of soil–pile interaction. This paper presents a multilayer perceptron neural network model, trained with the Levenberg-Marquardt algorithm, to predict the bearing capacity of precast concrete piles. Data from Standard Penetration Tests (SPT) and static and dynamic load tests on 141 precast concrete piles were compiled. Bearing capacity was determined from load–settlement curves using the Van der Veen (1953) method and the criteria established by NBR 6122 (ABNT, 2022). The model's input variables included pile diameter and length, N_{SPT} values, and soil type. Different combinations of these variables were tested and validated using MATLAB®, with the best-performing configuration selected based on the coefficient of determination (R^2) and root mean square error (RMSE). The results, with $R^2 = 0.85$ and RMSE = 0.06, were satisfactory given the problem's complexity. The case study showed that the proposed neural model outperformed the semi-empirical methods of Aoki-Velloso (1975) and Décourt-Quaresma (1978). Thus, the multilayer perceptron neural network is a promising tool for predicting the bearing capacity of precast concrete piles.

KEYWORDS: Bearing Capacity, Artificial Neural Networks (ANN), Precast Concrete.

1 INTRODUÇÃO

A estimativa da capacidade de carga de estacas constitui um dos problemas mais importantes da Engenharia Geotécnica, especialmente no projeto de fundações. Essa complexidade decorre da heterogeneidade

dos solos, da dificuldade em determinar parâmetros representativos de resistência (coesão e ângulo de atrito) e da própria natureza do mecanismo de interação entre o elemento estrutural e o maciço terroso, tanto durante a execução quanto ao longo da vida útil da fundação.

Embora as provas de carga, estáticas ou dinâmicas, constituam as melhores ferramentas para o dimensionamento geotécnico, pois permitem testar as fundações em escala real e avaliar a transferência de carga para o solo, sua aplicação envolve custos, prazos e condicionantes operacionais que frequentemente inviabilizam sua realização na etapa de projeto. Em consequência, muitos projetistas recorrem a métodos teóricos ou semiempíricos para estimar a capacidade de carga das fundações.

Na prática brasileira, os métodos semiempíricos de Aoki-Velloso (1975) e Décourt-Quaresma (1978), este último posteriormente modificado por Décourt *et al*. (1996), são os mais difundidos. Esses métodos baseiam-se em correlações estatísticas entre ensaios de campo, inicialmente o *Cone Penetration Test* (CPT) e, posteriormente, o *Standard Penetration Test* (SPT), e resultados de provas de carga. Todavia, um aspecto que exige cautela é o fato de tais métodos terem sido desenvolvidos a partir de solos e regiões específicas, refletindo condições geotécnicas particulares que demandam análises criteriosas quando aplicadas em contextos distintos daqueles que lhes deram origem.

Estudos comparativos têm mostrado dispersões relevantes entre as previsões fornecidas por esses métodos e os resultados observados em campo a partir de ensaios de prova de carga (estáticas e/ou dinâmicas). Essas diferenças foram verificadas em diferentes tipos de estacas, como hélice contínua, pré-moldadas de concreto e estacas do tipo raiz (Silva, 2020; Gomes, Verri e Ribeiro, 2021; Jesus, São Mateus e Gádea, 2026). Em muitos casos, observa-se uma tendência conservadora nas estimativas, o que pode resultar em projetos superdimensionados e impactar o consumo de materiais, a logística executiva e os custos globais da obra.

Nos últimos anos, técnicas de aprendizado de máquina têm sido aplicadas na análise de dados geotécnicos, principalmente para identificar relações não lineares entre variáveis. Entre essas técnicas, destacam-se as redes neurais artificiais (RNA), especialmente as do tipo perceptron multicamadas, que apresentam boa capacidade de generalização a partir de dados experimentais e são adequadas para problemas envolvendo múltiplas variáveis (Moayedi *et al*., 2020). O uso de RNA na previsão da capacidade de carga remonta a Chan *et al*. (1995), que aplicaram modelos neurais a estacas cravadas de seção circular. Desde então, diversos estudos têm demonstrado a viabilidade e a precisão dessas técnicas. No entanto, a maior parte da literatura ainda se concentra em estacas cravadas (Pham *et al*., 2020; Kardani *et al*., 2020; Nguyen *et al*., 2023; Nhat *et al*., 2025).

Recentemente, pesquisas brasileiras buscaram desenvolver modelos *perceptron* multicamadas capazes de prever a capacidade de carga em diferentes tipos de estacas, com base em dados de NSPT e provas de carga estáticas e/ou dinâmicas. Esses estudos evidenciaram a precisão dos modelos ao compará-los com provas de carga e métodos semiempíricos, tendo como foco estacas pré-moldadas de concreto e estacas hélice contínua, executadas, em grande parte, nas regiões Sul e Sudeste do Brasil (Delazzeri, 2018; Gomes, Verri e Ribeiro, 2021; Jesus, São Mateus e Gádea, 2022; Amâncio, Dantas Neto e Cunha, 2022; Jesus, São Mateus e Gádea, 2026).

Mesmo com esses avanços, ainda existem limitações relacionadas à transparência e à reprodutibilidade dos modelos, uma vez que informações importantes, como arquitetura da rede, funções de ativação e procedimentos de treinamento, nem sempre são divulgadas, dificultando a validação independente e a replicação dos resultados. Além disso, observa-se o uso recorrente de bases de dados limitadas ou pouco representativas, que não contemplam a diversidade de solos brasileiros, comprometendo a capacidade de generalização dos modelos. Outro ponto crítico é que muitos trabalhos não disponibilizam os parâmetros internos dos modelos neurais (como os pesos sinápticos), o que limita sua aplicabilidade prática no dimensionamento geotécnico de estacas (Hanandeh *et al*., 2020; Silva, 2020; Gomes, 2022; Nhat *et al*., 2025).

Assim, este artigo apresenta o desenvolvimento de modelos preditivos baseados em redes neurais artificiais do tipo *perceptron* multicamadas para estimar a capacidade de carga de estacas pré-moldadas de concreto, contribuindo para o aprimoramento das ferramentas de apoio ao dimensionamento geotécnico e ampliando a aplicabilidade prática dessas técnicas.

2 METODOLOGIA

2.1 Banco de Dados

O banco de dados utilizado nesta pesquisa consiste em uma compilação de 141 estacas desse tipo. Dessas, 131 são provenientes da base de dados de Lobo (2005) e 10 foram adicionadas a partir de estudos realizados na Bahia (Souza, 2014; Souza *et al*., 2015; Jesus, 2021).

Das 141 estacas, 113 foram submetidas a provas de carga estática, 15 a ensaios de carregamento dinâmico e, para 13 estacas, o tipo de ensaio não pôde ser identificado. Entre elas, apenas 20 estacas pré-moldadas de concreto atingiram a ruptura durante os ensaios. Ressalta-se que nenhuma das estacas foi instrumentada ao longo do fuste para a execução do ensaio de carga.

No que se refere às características geométricas, os diâmetros das estacas variam entre 15 cm e 70 cm, com predominância de diâmetros na faixa de 20 cm a 40 cm. Já os comprimentos apresentam variação de 3,30 m a 39,90 m, sendo mais comum o intervalo entre 7 m e 15 m.

Quanto à caracterização geotécnica, a distribuição dos tipos de solo onde as estacas foram instaladas evidencia predominância de solo argiloso (47,84%), seguido por solo siltoso (27,21%) e solo arenoso (24,95%).

2.2 Variáveis de Entrada e de Saída Adotadas

O modelo neural adotou como variáveis de entrada a geometria das estacas (diâmetro, D, e comprimento, L), o índice de resistência à penetração (N_{SPT}) e os fatores de estratigrafia do solo predominante (areia, silte e argila). Esses fatores foram representados pelos coeficientes k_{Lar}, k_{Lsil} e k_{Larg}, ao longo do fuste, e por k_p na ponta da estaca.

O N_{SPT} foi utilizado por considerar a resistência do solo (Décourt *et al*., 1996). Para o fuste da estaca, os valores foram determinados de duas formas:

- N_{L1} – soma do N_{SPT} ao longo do fuste, considerando resistência por metro (Aoki-Velloso, 1975).
- N_{L2} – média do N_{SPT} ao longo do fuste, desconsiderando o valor incluído na resistência de ponta (Décourt-Quaresma, 1978).

Na ponta da estaca, também foram adotados dois critérios:

- N_{p1} – N_{SPT} imediatamente abaixo da ponta (Aoki-Velloso, 1975).
- N_{p2} – média do N_{SPT} imediatamente acima e abaixo da ponta (Décourt-Quaresma, 1978).

Todos os valores de NSPT foram extraídos dos boletins de sondagem à percussão e limitados ao intervalo, $3 \leq N_{SPT} \leq 50$ conforme os critérios de Décourt-Quaresma (1978).

Os coeficientes de estratigrafia (k_{Lar}, k_{Lsil} e k_{Larg}) foram calculados pelas equações (1), (2) e (3), respectivamente, considerando apenas o solo predominante em cada camada, mesmo quando havia mais de um tipo de solo. Esses coeficientes levam em conta dois fatores, espessura e resistência, para evitar que apenas um parâmetro, isoladamente, defina o comportamento da estaca.

$$k_{Lar} = \frac{\Delta_{Lar}}{L} * \frac{N_{Lar}}{N_{Lacum}} \quad (1)$$

$$k_{Lsil} = \frac{\Delta_{Lsil}}{L} * \frac{N_{Lsil}}{N_{Lacum}} \quad (2)$$

$$k_{Larg} = \frac{\Delta_{Larg}}{L} * \frac{N_{Larg}}{N_{Lacum}} \quad (3)$$

onde:

- L_{ar}, L_{sil}, L_{arg} = espessura das camadas de areia, silte e argila ao longo do fuste.
- L = comprimento da estaca (m).
- N_{Lar}, N_{Lsil}, N_{Larg} = índices de resistência à penetração das respectivas camadas.
- N_{Lacum} = índice de resistência à penetração acumulado ao longo do fuste.

O tipo de solo na ponta da estaca foi representado por k_p, considerando apenas o material predominante (k_p = 1, para areia; k_p = 2, para silte; e k_p = 3, para argila). Essa classificação levando em conta apenas a fração do solo predominante é pertinente, visto que o método de Décourt-Quaresma (1978) apresenta categorização semelhante: areia, silte arenoso, silte argiloso e argila.

A variável de saída do modelo foi a capacidade de carga (Q_r), obtida a partir da mesma metodologia proposta por Lobo (2005), que determinou Q_r a partir da análise das curvas carga-recalque, seguindo o procedimento estabelecido pela NBR 6122 (ABNT, 2022) e utilizando a extrapolação (quando necessário) da curva carga-recalque pelo método de van der Veen (1953), adaptado por Aoki (1975). As estacas pré-moldadas de concreto apresentam capacidade de carga predominante entre 20 kN e 843 kN.

2.3 Configuração dos Modelos

Foram estabelecidas diferentes configurações para os modelos neurais de capacidade de carga (M-Q_r) a fim de analisar a contribuição das variáveis de entrada adotadas, de acordo com dois critérios: o Critério 1 considera a influência do cálculo do N_{SPT} (ao longo do fuste e na ponta da estaca) nos modelos neurais, com base na simulação dos critérios de cálculo de N_L e N_p adotados pelos métodos semiempíricos utilizados nesta pesquisa; o Critério 2 considera influência dos fatores de estratigrafia do tipo de solo (k_{Lar}, k_{Lsil}, k_{Larg} e k_p) nos modelos neurais.

As combinações resultaram nos seguintes modelos:

- M_{11}-Q_r: considera apenas o Critério 1, utilizando a metodologia de Aoki-Velloso (1975) (N_{L1} e N_{p1}).
- M_{12}-Q_r: combina os Critérios 1 e 2, utilizando a metodologia de Aoki-Velloso (1975) e os quatro fatores de estratigrafia (k_{Lar}, k_{Lsil}, k_{Larg} e k_p).
- M_{21}-Q_r: considera apenas o Critério 1, mas utiliza a metodologia de Décourt-Quaresma (1978) (N_{L2} e N_{p2}).
- M_{22}-Q_r: combina os Critérios 1 e 2, utilizando a metodologia de Décourt-Quaresma (1978) e os quatro fatores de estratigrafia (k_{Lar}, k_{Lsil}, k_{Larg} e k_p).

2.4 Parâmetros da RNA, Treinamento e Validação

O estudo utilizou redes neurais do tipo perceptron multicamadas (MLP) implementadas no MATLAB®, aplicando o algoritmo de aprendizado de *Levenberg-Marquardt*, conhecido por acelerar a convergência dos pesos sinápticos com menor número de iterações. As camadas intermediárias usaram função de ativação sigmoide, enquanto a saída foi linear, conforme trabalhos anteriores (Dantas Neto, 2004; Proni *et al*., 2020).

Os modelos neurais foram treinados com parâmetros de *momentum* $\alpha = 0{,}8$ e taxa de aprendizado $\eta = 0{,}01$, que regulam o ajuste dos pesos sinápticos (Dantas Neto, 2004; Amâncio, Dantas Neto, Cunha, 2022). A camada de entrada contou com um neurônio para cada variável, enquanto a rede possuía uma única camada intermediária, com o número de neurônios variando de *1* até *2x + 1*, conforme indicado por Kolmogorov (1957 *apud* Hecht-Nielsen, 1987). A camada de saída incluiu um neurônio.

O treinamento foi conduzido para evitar o excesso de treinamento, isto é, o ajuste excessivo da rede aos dados de treinamento (*overfitting*) que compromete sua capacidade de generalização. O processo era interrompido caso o erro de validação aumentasse em seis iterações consecutivas ou, na ausência desse aumento, após 100 épocas. Para prevenir que a rede ficasse presa em mínimos locais, os pesos foram reinicializados 50 vezes por época. O modelo final foi selecionado com base no menor erro quadrático médio (MSE) obtido na validação. A performance da rede foi avaliada pelo R^2 e pelo RMSE, métricas estatísticas largamente utilizadas em redes neurais aplicadas à engenharia geotécnica (Pham *et al*., 2020; Gomes, Verri, Ribeiro, 2021; Amâncio *et al*., 2022; Carvalho *et al*., 2023).

Antes do treinamento, as variáveis de entrada e saída foram normalizadas entre 0,15 e 0,85 para equilibrar sua influência. O conjunto de dados foi dividido aleatoriamente em 70% para treinamento e 30% para validação, conforme Tabela 1.

Tabela 1. Subconjuntos para treinamento e validação dos modelos neuronais. Fonte: Autores.

Prova de carga	Conjunto de dados	Subconjunto de treinamento	Subconjunto de validação
Todas	141	99	42
Somente estática	113	79	34

Inicialmente, foram treinados modelos usando todos os tipos de prova de carga disponíveis, tanto estáticas quanto dinâmicas, devido à falta de informações completas sobre o tipo de ensaio em algumas estacas do banco de dados de Lobo (2005). Depois, treinou-se apenas com as provas estáticas, predominantes no conjunto, garantindo resultados mais consistentes, mesmo com um volume de dados menor.

3 RESULTADOS

3.1. Modelo de Melhor Desempenho

O modelo mais eficaz para prever a capacidade de carga das estacas pré-moldadas de concreto é o M_{22}-Q_r, considerando, além das métricas estatísticas, o fato de ele possuir uma única camada oculta com um neurônio e oito variáveis de entrada. Ele se baseia no método de Décourt-Quaresma (1978) para a obtenção do N e N_p e utiliza variáveis de entrada associadas ao tipo de solo (Critério 2), como mostrado na Tabela 2. É importante observar que o treinamento do M_{22}-Q_r incorporou todas as estacas ensaiadas, sem fazer distinção entre provas de carga estáticas e dinâmicas.

Tabela 2. Configuração, arquitetura e desempenho dos modelos neuronais. Fonte: Autores.

Prova de carga	Modelo	Arquitetura	R^2	RMSE	Variáveis de entrada
Todas	M_{11}-Q_r	A:4:1:1	0,81	0,07	$f(D,L,N_{L1},N_{p1}) = Q_r$
	M_{12}-Q_r	A:8:1:1	0,85	0,06	$f(D,L,N_{L1},N_{p1},k_{Lar},k_{Lsil},k_{Larg},k_p) = Q_r$
	M_{21}-Q_r	A:4:2:1	0,79	0,07	$f(D,L,N_{L2},N_{p2}) = Q_r$
	M_{22}-Q_r	A:8:1:1	0,85	0,06	$f(D,L,N_{L2},N_{p2},k_{Lar},k_{Lsil},k_{Larg},k_p) = Q_r$
Estática	M_{11}-Q_r	A:4:5:1	0,87	0,06	$f(D,L,N_{L1},N_{p1}) = Q_r$
	M_{12}-Q_r	A:8:4:1	0,88	0,06	$f(D,L,N_{L1},N_{p1},k_{Lar},k_{Lsil},k_{Larg},k_p) = Q_r$
	M_{21}-Q_r	A:4:3:1	0,77	0,10	$f(D,L,N_{L2},N_{p2}) = Q_r$
	M_{22}-Q_r	A:8:4:1	0,85	0,08	$f(D,L,N_{L2},N_{p2},k_{Lar},k_{Lsil},k_{Larg},k_p) = Q_r$

A avaliação do desempenho dos modelos neuronais revelou que a maioria obteve resultados satisfatórios, com R^2 acima de 0,77 na fase de validação. Essa avaliação está em concordância com as conclusões de estudos anteriores, como Pham *et al*. (2020), Kardani *et al*. (2020), Gomes, Verri e Ribeiro (2021) e Amâncio, Dantas Neto e Cunha (2022). Em relação ao RMSE, constatou-se que os modelos neuronais apresentam valores aceitáveis, em conformidade com os resultados de estudos anteriores conduzidos por Kardani *et al*. (2020) e Amâncio, Dantas Neto e Cunha (2022), os quais encontraram valores de RMSE situados entre 0,08 kN e 0,177 kN.

3.2. Estudo de Caso

Para a avaliação da aplicabilidade do modelo neuronal em estacas pré-moldadas de concreto, foram utilizadas 11 estacas circulares, com dimensões variando de 17,00 cm a 33,00 cm de diâmetro e comprimentos entre 10,50 m e 15,40 m. Essas estacas foram cravadas na região de Brasília-DF, em solo predominantemente argiloso, e submetidas a ensaios de prova de carga dinâmica. Para as estacas cravadas próximas aos furos SP01 e SP02, o solo é composto por argila pouco siltosa a argila pouco arenosa. Já para as estacas próximas ao furo SP11, o perfil estratigráfico apresenta argila arenosa e silte arenoso. As características das estacas analisadas, bem como a respectiva capacidade de carga (com faixa de valores entre 277 kN e 736 kN), obtida a partir dos ensaios de carregamento dinâmico, podem ser encontradas no estudo conduzido por Marchezini (2013).

A Figura 1 ilustra os valores da capacidade de carga (Qr) obtidos tanto pelo modelo neuronal quanto pelos ensaios de prova de carga. A análise dos resultados mostra que, para quase todas as estacas, o modelo neuronal apresentou valores próximos aos obtidos nos ensaios de prova de carga, exceto para a estaca CC08, na qual o modelo apresentou um valor cerca de duas vezes maior do que o experimental.

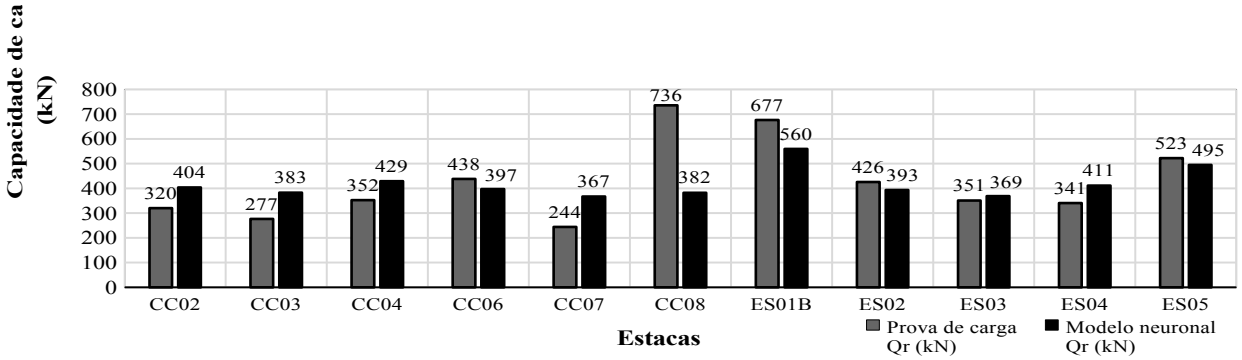


Figura 1. Capacidade de carga das estacas pré-moldadas de concreto: valores experimentais versus modelo neuronal. Fonte: Autores.

A Figura 2 traz a diferença percentual entre os resultados experimentais (provas de carga) e os valores obtidos pelo modelo neuronal e pelos métodos semiempíricos, destacando que o método de Aoki-Velloso (1975) adota uma abordagem conservadora, apresentando consistentemente valores das provas de carga superiores em todas as estacas, com uma faixa de erro variando entre 12% e 74%. Por outro lado, o método de Décourt-Quaresma (1978) revela valores de capacidade de carga superiores aos obtidos nos ensaios de prova de carga, abrangendo mais da metade das estacas, com uma faixa de erros situando-se entre -30% e 60%. No que se refere ao modelo neuronal, destaca-se que, para seis das onze estacas, os valores experimentais foram inferiores aos calculados pela equação, apresentando uma faixa de erro entre -50% e 48%.

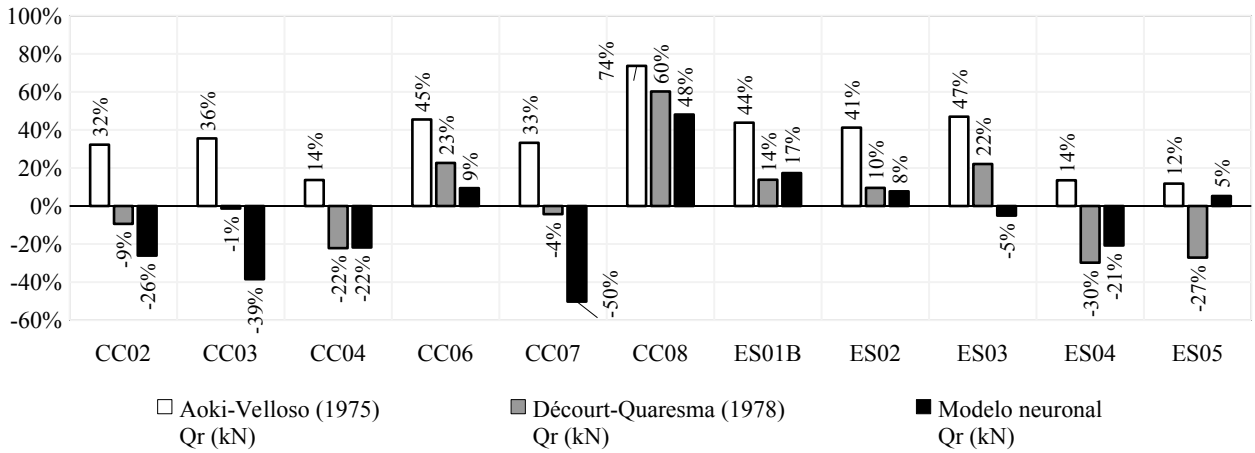


Figura 2. Capacidade de carga das estacas pré-moldadas de concreto: erro percentual, em relação aos valores experimentais, do modelo neuronal e dos métodos semiempíricos. Fonte: Autores.

As análises mostram que o método de Aoki-Velloso (1975) exibiu um melhor desempenho apenas para as estacas CC04 e ES04, representando 18% do total de estacas. O método de Décourt-Quaresma (1978) mostrou-se mais eficaz para 36% do total de estacas, incluindo CC02, CC03, CC07 e ES01B. Por fim, o modelo neuronal destacou-se como mais eficiente para 55% do total de estacas, englobando as estacas CC06, CC08, ES02, ES03 e ES05.

Em síntese, os resultados indicam que o modelo neuronal se mostra uma ferramenta promissora na previsão da capacidade de carga de estacas pré-moldadas de concreto com diâmetro variando entre 17,00 cm e 33,00 cm e comprimento entre 10,50 m e 15,40 m, cravadas em solo predominantemente argiloso. A análise comparativa revela um desempenho superior desse modelo em relação aos métodos semiempíricos específicos considerados nesse estudo de caso.

Destaca-se que durante o processo de treinamento e validação do modelo neuronal, nenhuma estaca utilizada foi executada na região de Brasília, DF. Essa inclusão inédita de dados nesse estudo de caso sugere que o modelo neuronal foi capaz de generalizar o aprendizado para um contexto geotécnico diferente daquele introduzido durante o treinamento.

4 CONCLUSÕES

O modelo neural desenvolvido apresentou resultados satisfatórios, com R^2 superior a 0,85 e RMSE de 0,06, considerados adequados conforme estudos anteriores. O melhor desempenho foi observado no modelo que considerou o tipo de solo, apesar da predominância de estacas em solo argiloso no banco de dados, e integrou todas as provas de carga, sem distinção do tipo. O estudo de caso mostrou que os valores estimados de capacidade de carga foram próximos aos experimentais, sendo, no geral, melhores que os métodos semiempíricos de Aoki-Velloso (1975) e Décourt-Quaresma (1978).

Ressalta-se que apesar do potencial do modelo, ele pode apresentar limitações em sua aplicabilidade, devido à natureza dos dados usados para treinamento e validação. Essas limitações envolvem o tipo de estacas (pré-moldadas de concreto, com diâmetro entre 20 cm e 40 cm e comprimento entre 7 m e 15 m), o tipo de solo (predominantemente argiloso, seguido de siltoso e arenoso) e a faixa de capacidade de carga (entre 20 kN e 843 kN). Assim, o modelo pode ser mais adequado para estacas em solos argilosos e dentro dessa faixa de carga, sendo menos representativo para cenários diferentes.

AGRADECIMENTOS

Os autores agradecem ao Programa de Pós-Graduação em Engenharia Civil e Ambiental (PPGECEA) da Universidade Estadual de Feira de Santana (UEFS) e à Fundação de Amparo à Pesquisa do Estado da Bahia (FAPESB) pelo incentivo e apoio financeiro oferecidos na realização da pesquisa que resultou neste artigo.

REFERÊNCIAS BIBLIOGRÁFICAS

ABNT – Associação Brasileira de Normas Técnicas (2022). *NBR 6122: Projeto e execução de fundações*. Rio de Janeiro, 126 p.

Amâncio, L. B.; Dantas Neto, S. A.; Cunha, R. P. (2022). Estimative of shaft and tip bearing capacities of single piles using multilayer perceptrons. *Soils and Rocks*, v. 45, n. 3, p. 1–14.

Aoki, N.; Velloso, D. A. (1975). An approximate method to estimate the bearing capacity of piles. In: *Panamerican Conference on Soil Mechanics and Foundation Engineering*, 5., Buenos Aires. *Proceedings...*, p. 367–376.

Carvalho, S.; Sales, M.; Cavalcante, A. (2023). Systematic literature review and mapping of the prediction of pile capacities. *Soils and Rocks*, v. 46, n. 3, p. 1–12.

Chan, W. T.; Chow, Y. K.; Liu, L. F. (1995). Neural network: an alternative to pile driving formulas. *Computers and Geotechnics*, v. 17, p. 135–156.

Dantas Neto, S. A. (2004). *Avaliação das Propriedades dos Ligantes e das Misturas Asfálticas Modificadas com Borracha Granulada de Pneus Usados*. Tese, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, 265 p.

Décourt, L.; Albiero, J.; Cintra, J. (1996). Análise e projeto de fundações profundas. In: Hachich, W. et al. *Fundações: teoria e prática*. São Paulo: Pini, v. 2, p. 265–327.

Décourt, L.; Quaresma, A. R. (1978). Capacidade de carga de estacas a partir de valores de SPT. In: *Congresso Brasileiro de Mecânica dos Solos e Engenharia de Fundações*, 6. *Anais...*, p. 45–53.

Delazzeri, M. L. C. (2018). *Estimativa da capacidade de carga de fundações profundas utilizando rede neural artificial*. Dissertação, Programa de Pós-Graduação em Engenharia Civil e Ambiental, Universidade Estadual de Feira de Santana, Feira de Santana, 212 p.

Gomes, Y. F. (2022). *Aprendizado de máquinas para estimar a capacidade de carga em estacas pré-moldadas de concreto*. Dissertação, Instituto Tecnológico de Aeronáutica, São José dos Campos, 107 p.

Gomes, Y. F.; Verri, F.; Ribeiro, D. (2021). Use of machine learning techniques for predicting the bearing capacity of piles. *Soils and Rocks*, v. 44, n. 4, p. 1–14.

Hanandeh, S.; Alabdullah, S. F.; Aldahwi, S.; Obaidat, A.; Alqaseer, H. (2020). Development of a constitutive model for evaluation of bearing capacity from CPT and theoretical analysis using ANN techniques. *International Journal of GEOMATE*, v. 19, n. 74, p. 229–235.

Hecht-Nielsen, R. (1987). Kolmogorov's mapping neural network existence theorem. In: *International Conference on Neural Networks*. Proceedings..., v. 3, p. 11–14.

Jesus, J. N. (2021). *Capacidade de carga do sistema solo-estaca: análise das soluções teóricas e semiempíricas com base no ensaio de carregamento dinâmico para uma obra no município de Feira de Santana-BA*. TCC (Graduação em Engenharia Civil), Universidade Estadual de Feira de Santana, Feira de Santana, 132 p.

Jesus, J. N. (2024). *Modelos neuronais para o cálculo da capacidade de carga em estacas cravadas, escavadas e hélice contínua*. Dissertação (Mestrado em Engenharia Civil e Ambiental), Universidade Estadual de Feira de Santana, Feira de Santana, BA, 155 p.

Jesus, J. N.; São Mateus, M. S. C.; Gádea, A. S. M. (2022). Predicting load capacity of precast concrete piles using SPT and artificial neural network. In: *Ibero-Latin-American Congress on Computational Methods in Engineering*, 43., Foz do Iguaçu. *Anais...* ABMEC.

Jesus, J. N.; São Mateus, M. S. C.; Gádea, A. S. M. (2026). Neural model for calculating the bearing capacity of driven and bored piles. *REM – International Engineering Journal*, v. 79, n. 2, p. 10

Kardani, N.; Zhou, A.; Nazem, M.; Shen, S. (2020). Estimation of bearing capacity of piles in cohesionless soil using optimised machine learning approaches. *Geotechnical and Geological Engineering*, v. 38, n. 2, p. 2271–2291.

Lobo, B. O. (2005). *Método de previsão de capacidade de carga de estacas: aplicação dos conceitos de energia do ensaio SPT*. Dissertação (Mestrado em Engenharia Civil), Universidade Federal do Rio Grande do Sul (UFRGS), Porto Alegre, 139 p.

Marchezini, S. F. (2013). *Comparação entre métodos estáticos e dinâmicos de previsão de capacidade de carga em estacas assentes em solo tropical*. Dissertação (Mestrado em Geotecnia), Universidade de Brasília, Brasília, 171 p.

Moayedi, H.; Mosallanezhad, M.; Rashid, A. S. A.; Jusoh, W. A. W.; Muazu, M. A. (2020). A systematic review and meta-analysis of artificial neural network application in geotechnical engineering: theory and applications. *Neural Computing and Applications*, v. 32, p. 495–518.

Nguyen, T.-H.; Nguyen, K.-V. T.; Ho, V.-C.; Nguyen, D.-D. (2023). Efficient hybrid machine learning model for calculating load-bearing capacity of driven piles. *Asian Journal of Civil Engineering*, v. 25, n. 1, p. 883–893.

Nhat, L. V.; Anh, T. N.; Van, H. T. V. (2025). Ultimate Bearing Capacity of Bored Piles in Clayey Sand Determined Using Artificial Neural Networks. *Transportation Infrastructure Geotechnology*, v. 12, n. 132.

Pham, T. A.; Ly, H.; Tran, V. Q.; Van Giap, L.; Vu, H. T.; Duong, H. (2020). Prediction of pile axial bearing capacity using artificial neural network and random forest. *Applied Sciences*, v. 10, n. 5.

Silva, R. R. C. (2020). Análise de métodos de previsão de capacidade de carga em estaca raiz a partir do comportamento em ensaios de carregamento estático e dinâmico. *Revista Tecnologia*, v. 41, n. 2.

Souza, N. S. (2014). *Capacidade de carga de fundações profundas em estacas pré-moldadas de concreto: estudo de caso em obra de edifício no município de Feira de Santana-BA*. TCC (Graduação em Engenharia Civil), Universidade Estadual de Feira de Santana, Feira de Santana, 112 p.

Souza, N. S.; São Mateus, M. S. C.; Silva, J. C. B.; Aragão, H.; Ramos, J. M. (2015). Capacidade de carga de fundações profundas em estacas pré-moldadas de concreto: estudo de caso em obra de edifício no município de Feira de Santana-BA. In: *Congresso Brasileiro do Concreto*, 57., Bonito. Anais..., Simpósio sobre Estruturas de Fundações: Aspectos Estruturais e Geotécnicos.

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/COBRAMSEG2026.2/22

Otimização da Interpretação de Ensaios CPTU com Modelo de Aprendizado de Máquina: Uma Prova de Conceito

Pedro Gomes dos Santos Pereira
Engenheiro Geotécnico, JETbr, Rio de Janeiro, Brasil, ppereira@jetbr.eng.br

Fabio Marinho da Silva
Gerente de Engenharia, JETbr, Belo Horizonte, Brasil, fsilva@jetbr.eng.br

Nuno Alexandre Braz da Silva
Diretor de Engenharia, JETbr, Lisboa, Portugal, nsilva@jetsj.com

RESUMO: A interpretação de perfis geotécnicos a partir de ensaios de piezocone (CPTu) é essencial para o refinamento de perfis geológicos obtidos por sondagens, porém apresenta limitações decorrentes da subjetividade do analista e da dificuldade de ponderar múltiplas variáveis simultaneamente. Essa condição pode gerar inconsistências na definição dos horizontes geomecânicos, sobretudo em depósitos heterogêneos, como solos residuais. Este trabalho propõe a aplicação de técnicas de machine learning para automatizar e aprimorar a segmentação e parametrização de horizontes geomecânicos com base em dados de CPTu, reduzindo a subjetividade e integrando múltiplos parâmetros no processo decisório. Utilizaram-se dados de 32 ensaios, com classificação inicial baseada em condicionais pré-estabelecidas, contemplando Solo Residual Tipo A (Mole), Saprólito Tipo A, Solo Residual Tipo B (Fofo) e Saprólito Tipo B. A metodologia emprega um modelo supervisionado Random Forest, treinado com seis variáveis: poropressão hidrostática (u_0), poropressão (u_2), resistência de ponta (q_t), índice de comportamento (I_b), razão de atrito (F_r) e parâmetro de poropressão (B_q). Aplicou-se ainda suavização por janela móvel para reduzir hipersegmentação. Os resultados sugerem potencial ganho em produtividade, repetibilidade e eficiência, além de evidenciarem diferenças em relação à classificação inicial, indicando que a abordagem pode contribuir como ferramenta de suporte à decisão geotécnica.

PALAVRAS-CHAVE: CPTu, Machine Learning, Random Forest, Solo Residual

ABSTRACT: The interpretation of geotechnical profiles from piezocone tests (CPTu) is essential for refining geological profiles obtained from borehole investigations; however, it presents limitations arising from analyst subjectivity and the difficulty of simultaneously weighting multiple variables. This condition may lead to inconsistencies in the definition of geomechanical horizons, especially in heterogeneous deposits such as residual soils. This study proposes the application of machine learning techniques to automate and enhance the segmentation and parameterization of geomechanical horizons based on CPTu data, reducing subjectivity and integrating multiple parameters into the decision-making process. Data from 32 tests were used, with initial classification based on predefined conditional criteria, including Residual Soil Type A (Soft), Saprolite Type A, Residual Soil Type B (Loose), and Saprolite Type B. The methodology employs a supervised Random Forest model trained with six variables: hydrostatic pore pressure (u_0), pore pressure (u_2), cone tip resistance (q_t), behavior index (I_b), friction ratio (F_r), and pore pressure parameter (B_q). A moving window smoothing technique was also applied to reduce hyper-segmentation. The results suggest potential gains in productivity, repeatability, and efficiency, and highlight differences compared to the initial classification, indicating that the approach may contribute as a decision-support tool in geotechnical practice.

KEYWORDS: CPTu, Machine Learning, Random Forest, Residual Soil

1 INTRODUÇÃO

Na engenharia de barragens, a investigação geotécnica constitui etapa fundamental para a caracterização das fundações e materiais de construção, condicionante crítico à segurança e ao desempenho da estrutura. O ensaio de piezocone (CPTu), por se tratar de um ensaio confiável de alta repetibilidade e padronização, consolidou-se como ferramenta de alto refinamento para investigação in situ, oferecendo medições praticamente contínuas de resistência de ponta, atrito lateral e poropressão, as quais permitem inferir não apenas a estratigrafia, mas também parâmetros de resistência, deformabilidade e permeabilidade dos solos.

Apesar da interpretação de perfis geotécnicos a partir de dados de CPTu indicar um avanço na representação estratigráfica de modelos geológicos, a segmentação das camadas com base no comportamento geomecânico apresenta limitações inerentes à subjetividade do processo interpretativo. A análise simultânea de múltiplas variáveis e a atribuição implícita de importância relativa a cada parâmetro depende da experiência e do julgamento do analista. Essa limitação torna-se particularmente relevante em depósitos de natureza complexa e heterogênea, como os solos residuais, onde as transições entre horizontes são frequentemente graduais e a variabilidade espacial é elevada. Nessas condições, a definição dos limites de camada pode variar bastante entre diferentes intérpretes, podendo resultar em inconsistências na classificação do comportamento do solo e na formulação de modelos geotécnicos representativos.

Nesse contexto, técnicas de aprendizado de máquina tornam-se alternativa para automatizar e sistematizar a interpretação de grandes volumes de dados, integrando múltiplos parâmetros em métodos de classificação reproduzíveis. Estudos recentes têm demonstrado o potencial dessas técnicas na classificação automática de solos e na identificação de unidades geotécnicas a partir de dados de CPTu, empregando desde redes neurais artificiais até métodos avançados de *deep learning* (Ghaderi et al., 2019; Xiao et al., 2021; Liu et al., 2024). O presente trabalho apresenta uma prova de conceito para aplicação de aprendizado supervisionado na classificação de horizontes geomecânicos a partir de dados de CPTu. Foram utilizados 32 ensaios realizados em perfil de solo residual, adotando-se condicionais pré-estabelecidas para identificação inicial das camadas correspondentes a Solo Residual Tipo A (mole), Saprólito Tipo A, Solo Residual Tipo B (fofo) e Saprólito Tipo B. Um modelo baseado em Random Forest foi treinado com seis variáveis de entrada (u_0, u_2, q_t, I_b, R_f e B_q), sendo posteriormente aplicado para classificar casos não enquadrados pelas condicionais ou com múltiplas classificações possíveis. Para mitigar o efeito de hipersegmentação característico de classificações pontuais, implementou-se suavização por janela móvel, visando uniformizar transições e definir limites de camada mais representativos da continuidade vertical do maciço.

A abordagem discutida não visa substituir o julgamento do engenheiro geotécnico, mas sim potencializar sua capacidade analítica, transferindo o esforço da interpretação individualizada de dezenas de perfis para a definição de critérios de classificação e validação dos resultados obtidos, com ganhos potenciais em produtividade, repetibilidade e consistência das interpretações.

2 REFERENCIAL TEÓRICO

2.1 CPTu

O ensaio de piezocone (CPTu) constitui um método de investigação in situ baseado na cravação estática instrumentada, permitindo a obtenção simultânea da resistência de ponta corrigida (q_t), do atrito lateral (f_s) e da poropressão (u_2). A aquisição contínua desses parâmetros permite a aplicação de correlações para estimativa de propriedades geotécnicas e fornece subsídios à interpretação do comportamento mecânico, contribuindo para a classificação do solo com base em seu desempenho geomecânico. Conforme descrito por Lunne et al (1997), o uso de ensaios de penetração de cone em campo constitui a técnica mais eficiente para obtenção de dados sobre a estratigrafia e as características físico-mecânicas dos solos em profundidade. O índice de comportamento do solo (I_b) constitui um parâmetro derivado dos resultados do CPTu que integra informações de resistência e atrito, permitindo diferenciar materiais com distintos comportamentos geomecânicos, conforme proposto por Robertson (2016). Sua utilização auxilia na identificação de horizontes e na interpretação de perfis geotécnicos, especialmente em depósitos heterogêneos.

2.2 Random Forest

O Random Forest é um algoritmo de aprendizado supervisionado baseado no princípio de *ensemble learning*, proposto por Breiman (2001). O método combina múltiplas árvores de decisão construídas a partir de amostras aleatórias dos dados, utilizando a técnica de *bootstrap aggregating* (*bagging*). Cada árvore é treinada com um subconjunto amostrado com reposição do conjunto original, enquanto, em cada nó de divisão, apenas um subconjunto aleatório de variáveis é considerado para particionamento.

Formalmente, para um conjunto de treinamento $D = \{(x_i, y_i)\}_{i=1}^{n}$, cada árvore T_bé construída a partir de uma amostra bootstrap D_b. No caso de classificação, a predição final é obtida por votação majoritária e, para regressão, pela média das predições individuais:

$$\hat{y} = \frac{1}{B}\sum_{b=1}^{B} T_b\,(x)$$

Onde B representa o número de árvores na floresta.

Uma das principais propriedades do Random Forest é a redução da variância do estimador, mantendo baixo viés relativo, característica que o torna menos suscetível ao *overfitting* (decorar os dados de treino) quando comparado a árvores individuais.

O método também permite avaliar quais variáveis são mais importantes para a classificação. Uma forma de medir isso é pelo índice de Gini, que calcula o quanto cada variável contribui para separar os dados em grupos mais puros (com menos mistura de classes). Quanto maior a redução da impureza proporcionada por uma variável, mais importante ela é considerada no modelo.

2.3 Janela deslizante

A janela deslizante é um procedimento utilizado na análise de dados sequenciais onde um intervalo de comprimento fixo percorre a extensão dos dados com incrementos regulares. Em cada posição, calcula-se uma medida resumo (média, mediana, moda, etc.) com base nos valores contidos no intervalo. O deslocamento entre posições consecutivas, denominado passo ou *overlap*, determina o nível de suavização e a continuidade entre as análises vizinhas. Valores menores de passo produzem maior sobreposição entre janelas consecutivas, resultando em transições mais graduais entre os segmentos. A técnica é aplicada quando se deseja reduzir flutuações locais e extrair padrões predominantes ao longo de uma sequência, agrupando observações adjacentes com comportamentos semelhantes (Datar et al., 2002). Em termos geotécnicos, a janela deslizante atua como um filtro para suavizar as oscilações pontuais observadas nos perfis obtidos pelo ensaio de cone (CPTu) e nas propriedades derivadas por correlações empíricas. Ao agrupar valores consecutivos em intervalos móveis, a técnica permite identificar tendências predominantes do solo.

3 MATERIAL E MÉTODOS

3.1 Ensaios realizados

Foram utilizados 32 ensaios CPTu realizados em perfil de alteração contendo solos residuais e saprolitos de dois litotipos distintos, adotando-se condicionais pré-estabelecidas para identificação inicial das camadas correspondentes a cada unidade geotécnica. Essas classificações foram definidas com base na análise geológica local, considerando o contexto litológico, os processos de intemperismo predominantes e o modelo geológico-geotécnico previamente estabelecido para a área de estudo.

A interpretação dos ensaios CPTU para definição das unidades geológico-geotécnicas foi fundamentada no comportamento predominante do material ao longo do perfil, distinguindo-se domínios do tipo *sand-like* (arenoso) e *clay-like* (argiloso). Essa distinção foi realizada a partir da análise integrada dos principais parâmetros obtidos no ensaio: índice de comportamento do solo (I_b), resistência de ponta corrigida (q_t),

parâmetro de poropressão (B_q), razão de atrito (F_r) e a relação entre a poropressão medida (u_2) e a poropressão estática (u_0). A Tabela 1 apresenta os intervalos limites considerados por parâmetro do ensaio CPTu.

Tabela 1 – Limites dos parâmetros do ensaio CPTu considerados para classificação dos solos.

Unidade	Grupo	Domínio	I_b	q_t (MPa)	B_q	Relação u_2/u_0	F_r (%)
Solo Residual Tipo A	2	Clay-like	< 25	< 3	> 0,2	$u_2 > u_0$	> 2,5
Saprólito Tipo A	4	Clay-like	< 32	< 10	-0,1 < Bq < 0,2	$u_2 < u_0$	> 2,0
Solo Residual Tipo B	1	Sand-like	22 < Ib < 32	< 5	< 0,2	–	1 < FR < 3,5
Saprólito Tipo B	3	Sand-like	> 32	> 5	< 0,1	$u_2 < u_0$	1 < FR < 3

Os materiais enquadrados como *sand-like* apresentam características associadas a comportamento predominantemente drenado, menor desenvolvimento de excesso de poropressão e resposta mecânica típica de solos granulares ou silto-arenosos. Já os materiais classificados como *clay-like* evidenciam maior influência da geração de poropressão durante a cravação, valores relativos de resistência de ponta mais baixos e comportamento compatível com solos de matriz fina.

Destaca-se que os limites apresentados representam faixas típicas de comportamento e não fronteiras rígidas entre materiais, uma vez que solos residuais frequentemente exibem transições graduais entre domínios mais arenosos e mais argilosos. Dessa forma, o enquadramento foi conduzido de maneira interpretativa e iterativa, buscando coerência entre os parâmetros medidos no CPTU e o comportamento geotécnico esperado para cada unidade.

3.2 Processamento dos métodos

A metodologia adotada integra uma etapa de classificação determinística, baseada nos intervalos limites pré-definidos dos parâmetros, seguida de um modelo supervisionado de aprendizado de máquina, visando reduzir ambiguidades na definição de horizontes geomecânicos a partir de dados de CPTu. Inicialmente, cada registro do ensaio é submetido a uma rotina de classificação por regras condicionais previamente estabelecidas (Tabela 1). São consideradas seis variáveis principais: poropressão medida no cone (u_2), resistência de ponta corrigida (q_t), razão de atrito (F_r), índice de comportamento do solo (I_b), parâmetro de poropressão (B_q) e poropressão estática (u_0). A partir de combinações específicas dessas variáveis, são classificados quatro grupos geotécnicos distintos (Grupo 1 a Grupo 4). Quando todas as condições são satisfeitas, o ponto é classificado diretamente no respectivo grupo. Caso nenhuma condição seja atendida, o registro recebe o rótulo "Não Classificado"; quando o ponto se enquadra em mais de um grupo de condição, é marcado como "Múltiplos Grupos", indicando incerteza na interpretação determinística.

Os registros classificados de forma inequívoca (Grupo 1 a 4) constituem o conjunto de treinamento do modelo supervisionado. As variáveis de entrada (u_2, q_t, F_r, I_b, B_q e u_0) são previamente padronizadas por meio de normalização (*standardscaler*), assegurando que diferenças de escala não influenciem o desempenho do algoritmo. Foram utilizados *n_estimators* = 100 e *max_depth* = 4. Segundo Probst, Wright e Boulesteix (2019), o aumento do número de árvores melhora a estabilidade do modelo, mas os ganhos tendem a diminuir após certo ponto, justificando o uso de 100 árvores. Além disso, a limitação da profundidade para quatro níveis reduz a complexidade do modelo e o risco de sobreajuste, sendo a profundidade um hiperparâmetro que deve ser ajustado conforme as características dos dados. O conjunto de dados é dividido em subconjuntos de treino e teste (80%/20%), permitindo avaliar o desempenho do modelo.

Após o treinamento, o modelo é aplicado exclusivamente aos registros inicialmente rotulados como "Não Classificado" ou "Múltiplos Grupos". Para esses casos, o Random Forest fornece tanto a classe prevista quanto as probabilidades associadas a cada grupo possível. A classificação final passa a considerar explicitamente o nível de confiança da predição: quando a probabilidade do grupo estimado é superior a 60%, a classificação é aceita como válida; quando igual ou inferior a esse limiar, o resultado é mantido, porém identificado como "baixa confiança".

Dessa forma, a metodologia estabelece três níveis de decisão:

(i) classificação original determinística, quando inequívoca;
(ii) classificação por aprendizado de máquina independentemente da confiança para a classe;
(iii) classificação devido à confiança da classificação em cada classe.

Após a etapa de classificação, aplica-se um procedimento de suavização por janela deslizante ao longo do perfil de profundidade, visando reduzir as segmentações excessivas comuns em dados de CPTu. Para isso, utiliza-se uma janela de 1 m de espessura, deslocada com sobreposição de 50% (*overlap* = 0,5) entre janelas consecutivas. Em cada intervalo, determina-se o grupo geotécnico predominante, permitindo obter um perfil estratigráfico mais contínuo e representativo das tendências do solo.

4 RESULTADOS

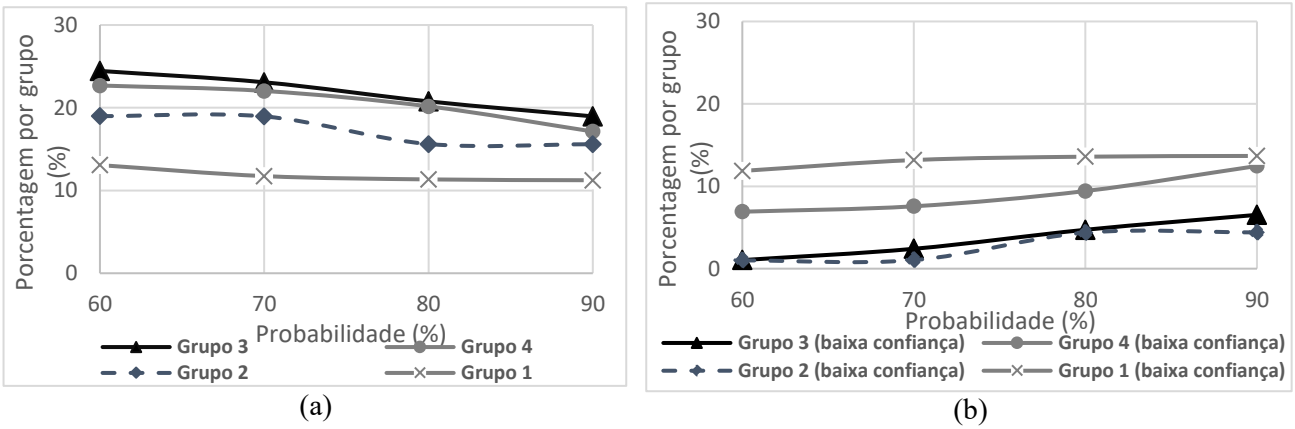
Segundo os resultados obtidos, observa-se que, na etapa de classificação determinística baseada em condicionantes, a maior parte dos registros, 6613 pontos (40,81%), não atendeu a nenhuma das condições definidas, sendo inicialmente rotulados como "Não Classificado". Um pequeno percentual, 648 pontos (4,00%), apresentou condições sobrepostas, sendo categorizado como "Múltiplos Grupos", ou seja, estes pontos se encaixaram em mais de um grupo classificado. Na maior parte dos casos, a sobreposição ocorreu entre os Grupos 1 e 4, indicando incertezas nos limites de classificação entre essas camadas. Entre os pontos classificados de forma inequívoca, o Grupo 4 apresentou a maior quantidade, com 2752 registros (16,98%), seguido pelo Grupo 2 com 2237 registros (13,82%), Grupo 3 com 2136 registros (13,18%) e Grupo 1 com 1817 registros (11,21%). Portanto, a distribuição dos grupos é satisfatória, com variedade e representatividade adequadas para o treinamento do modelo. Os registros inequívocos correspondem a 55,19% do conjunto total, oferecendo uma base consistente para análises subsequentes e para o treinamento de modelos de aprendizado de máquina. A distribuição dos registros mostra que uma parte significativa dos pontos (40,81%) não se enquadra nos grupos previamente definidos, e uma parcela menor (4,00%) atende simultaneamente a mais de um critério. Esses resultados indicam limitações da classificação determinística condicional.

Os registros inicialmente rotulados como "Não Classificados" foram posteriormente processados por um modelo Random Forest, treinado com os registros inequívocos (Grupos 1 a 4) da etapa condicional determinística. Para verificar a presença de overfitting, o desempenho do modelo foi avaliado nos conjuntos de treino e teste. Observou-se acurácia de 0,999 no treino e 0,998 no teste, indicando excelente capacidade de generalização e mínima diferença entre os conjuntos, o que sugere que o modelo aprendeu os padrões dos dados determinísticos sem memorizar os dados de treinamento.

A importância das variáveis foi avaliada pelo critério Gini importance. O parâmetro Bq apresentou a maior contribuição para a classificação, seguido por Ib. As variáveis Fr, u_2 e qt tiveram influência intermediária, enquanto u_0 apresentou contribuição desprezível para o desempenho do modelo.

A aplicação do modelo Random Forest aos registros inicialmente problemáticos permitiu aumentar a quantidade de pontos atribuídos a grupos geotécnicos em relação à classificação determinística. O Random Forest não fornece apenas uma previsão de grupo, mas também a probabilidade associada a cada classe (*predict_proba*), refletindo o grau de confiança do modelo em sua decisão. Essa informação probabilística foi utilizada para estabelecer diferentes limiares de confiança (60%, 70%, 80% e 90%) permitindo distinguir predições consideradas confiáveis daquelas de baixa confiança e, assim, fornecer uma interpretação mais segura do perfil geotécnico.

Com o limiar de 60%, 79,2% dos registros foram classificados com confiança adequada nos grupos de maior confiabilidade, enquanto 20,8% foram identificados como de baixa confiança, ou seja, um aumento de 24,01% em relação à classificação determinística. À medida que o limiar aumenta, o número de registros classificados com confiança diminui, refletindo critérios mais rigorosos: com 90% de probabilidade, 64,14% dos registros permanecem em grupos de maior confiança, um aumento de apenas 8,95%. A parcela de baixa confiança cresce proporcionalmente. Assim, considerando que o limiar de 60% representa um equilíbrio adequado entre nível de confiança e a porcentagem de registros classificados, esse valor foi adotado como critério para a aplicação do método de janelas deslizantes. A Figura 1(a) apresenta a porcentagem de registros classificados com maior confiança por grupo em função do limiar de confiança adotado, enquanto a Figura 1(b) mostra a porcentagem de registros classificados com baixa confiança por grupo em função desse mesmo limiar.



(a) (b)

Figura 1 - Variação da porcentagem de classificações por grupo em função do limiar de confiança adotado no modelo Random Forest: (a) registros classificados com maior confiança; (b) registros classificados com baixa confiança.

Com a aplicação do procedimento de janela deslizante, o perfil originalmente caracterizado por uma segmentação excessiva foi suavizado, resultando em uma representação estratigráfica mais contínua, como pode ser observado no exemplo do ensaio da Figura 2. A classificação de cada intervalo passou a considerar o grupo predominante entre os pontos contidos na janela. Apesar da melhoria na continuidade do perfil, algumas limitações foram observadas na metodologia. Em especial, verificou-se que a direção de varredura da janela ao longo da profundidade pode influenciar a definição dos contatos entre camadas, uma vez que o conjunto de pontos considerados em cada posição da janela não é perfeitamente simétrico em relação às transições litológicas. Esse aspecto indica que o método ainda pode ser aperfeiçoado, especialmente no que se refere ao critério de agrupamente das janelas e à representação das interfaces entre materiais distintos.

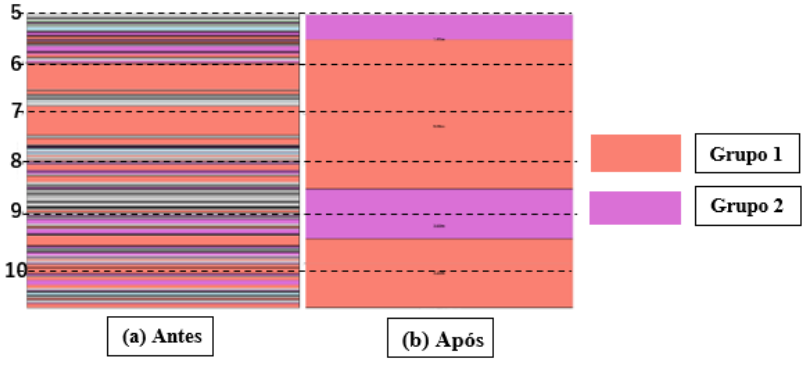


Figura 2 - Perfil geotécnico obtido antes e após a aplicação do método de janela deslizante.

No que tange a comparação entre metodologia de acordo com a porcentagem por grupos, a análise humana apresenta predominância do Grupo 2 (47,25%) e menor representatividade do Grupo 4 (10,86%), enquanto a abordagem apenas determinística deixa 40,81% do perfil não classificado, evidenciando limitações na definição de zonas de transição. Com a aplicação do Random Forest sem adoção do critério de confiança, todo o perfil passa a ser classificado, com redistribuição mais equilibrada entre os grupos e aumento expressivo do Grupo 4 (30,82%), indicando sensibilidade do modelo a padrões que podem não ter sido plenamente capturados na interpretação manual.

Ao aplicar o critério de confiança de 60%, parte dos dados (20,81%) é sinalizada como de baixa confiabilidade, introduzindo um controle objetivo de incerteza sem comprometer significativamente a cobertura. A suavização por janela, por sua vez, promove maior coerência estratigráfica e mantém o Grupo 4 em patamar substancialmente superior ao da análise humana (26,88%), reforçando a hipótese de que este grupo pode ter sido subestimado na interpretação inicial. Assim, os resultados da prova de conceito indicam que a combinação entre aprendizado de máquina, análise de confiança e pós-processamento é tecnicamente viável e potencialmente mais sensível à identificação de determinadas camadas, especialmente aquelas associadas ao Grupo 4. Tabela 2 mostra a distribuição dos registros por grupo e por metodologia de classificação aplicada.

Tabela 2 - Comparação da distribuição dos registros por grupo e por metodologia de classificação.

Classe	Análise humana	Análise determinística	RF sem análise de confiança	RF com análise de confiança (60%)	RF com suavização por janela
Grupo 1	17,56	11,21	23,79	13,07	18,31
Grupo 2	47,25	13,82	20,68	18,99	29,47
Grupo 3	24,33	13,18	24,72	24,45	25,34
Grupo 4	10,86	16,98	30,82	22,69	26,88
Não classificado	-	40,81	-	-	-
Baixa confiança	-	-	-	20,81	-
Múltipla classificação	-	4,00	-	-	-

Comparando metodologias que resultaram na classificação completa dos registros, é possível inferir que o Grupo 4 (Saprólito Tipo A) apresentou subnotificação na análise humana inicial. Esse comportamento pode estar associado a fatores como maior dispersão do grupo ao longo dos perfis ou presença de camadas de pequena espessura, que dificultam sua identificação direta na interpretação manual dos ensaios. Por outro lado, o Grupo 3 (Saprólito Tipo B) manteve participação relativamente constante entre as diferentes metodologias, o que pode indicar que as características associadas a esse material são bem definidas e agrupadas nos ensaios CPTu, permitindo sua identificação de forma consistente tanto na análise humana quanto nas abordagens automatizadas. O Grupo 2 (Solo Residual Tipo A) apresentou variação mais significativa, com predominância na interpretação humana e redução relativa nas classificações automatizadas, sugerindo que parte dos registros inicialmente atribuídos a esse grupo na análise humana pode ter sido classificada de forma excessiva possivelmente devido à contextualização geológica. Já o Grupo 1 (Solo Residual Tipo B) também apresentou variações entre as metodologias, porém em menor magnitude, indicando relativa estabilidade na sua identificação ao longo das diferentes abordagens.

5 CONCLUSÕES

A prova de conceito apresentada demonstra que a aplicação de algoritmos de aprendizado de máquina, em particular o Random Forest, pode contribuir para aprimorar a interpretação de ensaios CPTu. O modelo alcançou acurácia de 0,998 no conjunto de teste, indicando elevada capacidade de reconhecer padrões presentes nas regras condicionais determinísticas dos parâmetros analisados. Como resultado, houve redução significativa dos registros não classificados pelas regras iniciais, que deixavam mais de 40% dos dados sem uma definição clara. A análise de importância das variáveis indicou que os parâmetros B_q e I_b exercem maior

influência na distinção entre os grupos identificados, sugerindo que esses índices desempenham papel mais relevante na caracterização dos horizontes investigados. Além disso, a introdução de critérios de confiança estatística associada à aplicação de uma suavização por janela móvel contribuiu para reduzir a fragmentação excessiva dos perfis, resultando em modelos estratigráficos mais contínuos e compatíveis com a interpretação geológica esperada. Os resultados também indicaram que a abordagem automatizada apresentou com maior frequência a identificação de determinadas camadas, como aquelas associadas ao Grupo 4, que foram menos presentes em interpretações manuais tradicionais. Observou-se ainda que existem variações na participação relativa dos grupos entre as diferentes metodologias de classificação, o que pode indicar possíveis sub ou super-representações de determinadas classes quando a análise depende exclusivamente da interpretação humana. Dentre as principais limitações identificadas no método proposto destacam-se a circularidade metodológica inerente ao processo de treinamento, o efeito do sentido de varredura da janela móvel de suavização e a desconsideração explícita dos perfis de intemperismo dos materiais. Como o modelo foi treinado com classes definidas pelas próprias regras condicionais utilizadas na classificação inicial, sua acurácia deve ser interpretada como a capacidade de reproduzir esses critérios, e não como uma validação independente do comportamento geomecânico dos materiais. Todas elas são passíveis de aprimoramento em evoluções futuras. Dessa forma, a metodologia proposta não tem como objetivo substituir o julgamento do engenheiro geotécnico, mas atuar como uma ferramenta de apoio à análise dos dados. Ainda assim, os resultados apresentados devem ser interpretados como uma etapa inicial de investigação, sendo recomendável a realização de estudos adicionais, a fim de avaliar a coerência e a representatividade das camadas interpretadas perante o modelo geológico local e o perfil de intemperismo dos domínios litológicos.

REFERÊNCIAS BIBLIOGRÁFICAS

Breiman, L. (2001) *Random forests. Machine Learning*, Dordrecht, v. 45, n. 1, p. 5-32, out. https://doi.org/10.1023/A:1010933404324.

Datar M, Gionis A, Indyk P, Motwani R (2002) *Maintaining stream statistics over sliding windows*. SIAM J Comput 31(6):1794–1813windows. SIAM J Comput 31(6):1794–1813

Ghaderi, A.; Abbaszadeh Shahri, A.; Larsson, S. (2019) *An artificial neural network based model to predict spatial soil type distribution using piezocone penetration test data.* Bulletin of Engineering Geology and the Environment, v. 78, n. 6, p. 4579–4588. https://doi.org/10.1007/s10064-018-1400-9.

Liu, W.; Tong, L.; Yan, X.; Liu, S. et al. (2024) *Automatic soil classification method from CPTU data based on convolutional neural networks*. Bulletin of Engineering Geology and the Environment, v. 83, n. 8. https://doi.org/10.1007/s10064-024-03815-6.

Lunne, T.; Robertson, P. K.; Powell, J. J. M. (1997) *Cone penetration testing in geotechnical practice*. Londres: Blackie Academic & Professional, 1997.

Probst P, Wright, M. N, Boulesteix, A. L (2019) *Hyperparameters and tuning strategies for random forest*. WIREs Data Mining and Knowledge Discovery, v. 9, n. 3, e1301.

Robertson, P. K. (2016) *Cone Penetration Test (CPT)-Based Soil Behaviour Type (SBT) Classification System—An Update.* Canadian Geotechnical Journal, 53, 1910-1927. https://doi.org/10.1139/cgj-2016-0044

Xiao, T.; Du, Y.; Zou, H. F.; Yin, K. S.; Zhang, L. M. (2021) *Machine learning-enhanced soil classification by integrating borehole and CPTU data with noise filtering.* Bulletin of Engineering Geology and the Environment, v. 80, n. 12, p. 9157–9171. https://doi.org/10.1007/s10064-021-02478-x.

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/COBRAMSEG2026.2/23

Panorama da Utilização da Inteligência Artificial na Gestão de Risco de Movimento de Massa: Uma Análise Bibliométrica com Foco em Aplicações Geotécnicas e Ambientais

Geovanna Karla da Silva Simões
Mestranda em Engenharia Civil, Universidade Federal de Pernambuco, Recife, Brasil, geovanna.simoes@ufpe.br

Arthur Vinícius Freire Silva Ramos
Mestrando em Engenharia Civil, Universidade Federal de Pernambuco, Recife, Brasil, arthur.vramos@ufpe.br

João Paulo Marçal de Souza
Mestrando em Engenharia Civil, Universidade Federal de Pernambuco, Recife, Brasil, joao.marcal@ufpe.br

Igor Fernandes Gomes
Professor, Universidade Federal de Pernambuco, Recife, Brasil, igor.fernamdes@ufpe.br

Fabio Lopes Soares
Professor, Universidade Federal da Paraíba, João Pessoa, Brasil, flseng@uol.com.br

RESUMO: A crescente frequência de desastres relacionados a movimentos de massa, potencializada por mudanças climáticas e pela rápida urbanização, impõe impactos socioeconômicos severos e crescentes desafios à gestão de risco. Paralelamente, o monitoramento ambiental e geotécnico gera um volume exponencial de dados, Big Data, exigindo ferramentas de análise mais robustas do que os métodos tradicionais. A Inteligência Artificial (IA) surge como uma tecnologia transformadora neste cenário, oferecendo novas capacidades de modelagem preditiva e processamento de informação. O objetivo deste artigo é apresentar um panorama científico abrangente da aplicação da inteligência artificial na gestão de riscos, com ênfase em suas funções de análise e suporte à gestão. Para isso, foi conduzida uma análise bibliométrica sistemática, utilizando dados extraídos da Scopus e analisados com o *software Vosviewer*. Os resultados revelam um crescimento exponencial das publicações nos últimos anos e identificam três principais clusters temáticos de aplicação da inteligência artificial: (1) modelagem preditiva e análise de susceptibilidade a riscos de deslizamentos, (2) otimização de sistemas de alerta precoce, e (3) desenvolvimento de Sistemas de Apoio à Decisão para o auxílio à tomada de decisões em situações críticas. Conclui-se que a inteligência artificial está se consolidando como um pilar estratégico, movendo a gestão de riscos de movimento de massa de uma abordagem reativa para uma postura proativa e preditiva, sendo fundamental para o monitoramento e resposta eficazes.

PALAVRAS-CHAVE: Deslizamento; Monitoramento Geotécnico; Tomada de Decisão; Sistemas de Alerta Precoce; Modelo Preditivo.

ABSTRACT: The increasing frequency of disasters related to mass movements, intensified by climate change and rapid urbanization, imposes severe socioeconomic impacts and growing challenges for risk management. At the same time, environmental and geotechnical monitoring generates an exponential volume of data—Big Data—requiring more robust analytical tools than traditional methods. Artificial Intelligence (AI) emerges as a transformative technology in this context, offering new capabilities for predictive modeling and information processing. The objective of this article is to present a comprehensive scientific overview of the application of artificial intelligence in risk management, with emphasis on its analytical functions and decision-support capabilities. To this end, a systematic bibliometric analysis was conducted using data extracted from Scopus and analyzed with the VOSviewer software. The results reveal an exponential growth in publications in recent years and identify three main thematic clusters in the application of artificial intelligence: (1) predictive modeling and landslide susceptibility analysis; (2) optimization of early warning systems; and (3) development

of Decision Support Systems to assist decision-making in critical situations. It is concluded that artificial intelligence is consolidating itself as a strategic pillar, shifting mass movement risk management from a reactive approach to a proactive and predictive stance, and playing a fundamental role in effective monitoring and response.

KEYWORDS: Landslide; Geotechnical Monitoring; Decision-Making; Early Warning Systems; Predictive Modeling.

1 INTRODUÇÃO

A ocorrência de desastres naturais relacionados a movimentos de massa tem apresentado um crescimento alarmante em escala global, impulsionada pela combinação crítica entre as mudanças climáticas e a rápida urbanização desordenada em áreas de encostas. Estes eventos geram impactos socioeconômicos severos, resultando em perdas de vidas humanas e danos significativos a infraestruturas críticas, o que impõe desafios crescentes às estratégias de gestão de riscos de desastres (Simões, 2023).

Tradicionalmente, a monitorização ambiental e geotécnica dependia de métodos estatísticos e determinísticos que, embora fundamentais, apresentam limitações ao lidar com a natureza não-linear e complexa dos solos. Atualmente, o cenário é marcado pela geração de um volume exponencial de dados provenientes de redes de sensores, imagens de satélite e sistemas de monitorização em tempo real — o chamado Big Data — exigindo ferramentas de análise e processamento muito mais robustas e ágeis do que as abordagens convencionais (Ghaffarian *et al*. 2023).

Neste contexto, a Inteligência Artificial (IA) surge como uma tecnologia transformadora, oferecendo capacidades inéditas de modelagem preditiva e suporte à tomada de decisão. No entanto, a adoção destas tecnologias na geotecnia enfrenta o desafio da natureza de "caixa-preta" de muitos algoritmos complexos, o que tem gerado uma procura crescente por técnicas de IA Explicável (XAI) para garantir a transparência e a confiança necessária em decisões que envolvem a segurança pública (Rai, 2020).

A integração destas inovações tecnológicas está alinhada a marcos globais de resiliência, como o Marco de Sendai (2015-2030) e os Objetivos de Desenvolvimento Sustentável (ODS 11 e 13), que priorizam a redução da mortalidade global e a proteção das cidades contra desastres climáticos.

O objetivo deste artigo é apresentar um panorama científico abrangente da aplicação da inteligência artificial na gestão de riscos de movimentos de massa, com ênfase nas suas funções de análise, predição e suporte à gestão. Para tal, foi conduzida uma análise bibliométrica sistemática, mapeando as tendências, os principais clusters temáticos e as lacunas de investigação, fornecendo uma base estratégica para o avanço da monitorização e resposta eficaz no campo da geotecnia ambiental.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Conceitos de Gestão de Risco de Movimento de Massa

A gestão de riscos de desastres, principalmente aqueles relacionados aos movimentos de massa, consiste na formulação e aplicação de políticas e estratégias voltadas à redução das vulnerabilidades associadas a eventos naturais ou antrópicos, ou seja, é um processo sistemático de planejamento, implementação e avaliação de estratégias voltadas à compreensão e ao controle dos riscos de desastres.

No contexto brasileiro, a Gestão de Riscos de Desastres é norteada pela Política Nacional de Proteção e Defesa Civil (PNPDEC), que estabelece a promoção da resiliência e a mitigação de perdas como pilares fundamentais. Conforme preconizado pela Lei nº 12.608/2012 e regulamentado pelo Decreto nº 10.593/2020, a GRD deve ser operada de forma multissetorial, envolvendo atores nos níveis local, regional e federal. Diferente do gerenciamento de desastres, que atua em situações de anormalidade (resposta e recuperação), a gestão de riscos abrange atividades de proteção realizadas em períodos de normalidade para evitar a instalação de novos riscos ou mitigar os existentes, *Figura 1*.

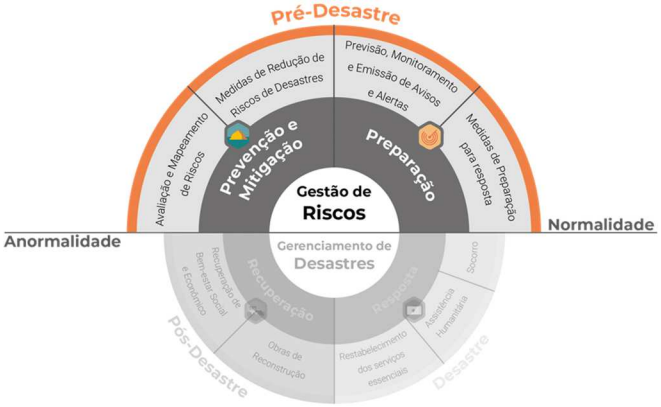


Figura 1. Ciclo da Defesa Civil: etapas da gestão de risco.

A prevenção e a mitigação constituem a primeira etapa da gestão de risco de desastres, que se divide em estratégias como ações de avaliação e mapeamento de riscos, e medidas de redução de riscos de desastres, como medidas estruturais e não estruturais. Já a preparação desempenha um papel essencial na gestão de riscos de desastres (Furtado *et al*., 2013). Seu principal objetivo é desenvolver as habilidades necessárias para lidar de forma eficaz e eficiente com uma variedade de situações de emergência, facilitando uma transição ordenada desde a resposta até uma recuperação sustentável.

No que se refere à definição de risco, as Nações Unidas sobre Redução do Risco de Desastres (2015) definem risco como o resultado da combinação entre perigo, exposição e vulnerabilidade. Assim, os estudos de avaliação de risco precisam analisar de que forma esses três elementos — perigo, vulnerabilidade e exposição — se interrelacionam. A E*quação 1* descreve essa relação.

$$\text{Risco} = \text{Perigo} \times \text{Vulnerabilidade} \times \text{Exposição} \qquad (1)$$

Dessa forma, o risco é definido como a combinação entre o perigo — representado pela suscetibilidade a movimentos de massa em encostas ou taludes —, a vulnerabilidade, que se relaciona à presença de edificações situadas próximas à área potencialmente impactada, e a exposição de pessoas e bens a esses eventos (Simões *et al*., 2026).

2.2 Evolução da IA na Geotecnia

A aplicação da Inteligência Artificial (IA) na engenharia geotécnica pode ser compreendida através de quatro fases distintas, fundamentadas na convergência entre o poder computacional e a disponibilidade de dados de monitoramento, *Figura 2*. Esta periodização não é meramente cronológica, mas tecnocêntrica, refletindo como a ciência respondeu à necessidade de gerir a não-linearidade e o volume massivo de informações geológicas (*Big Data*).

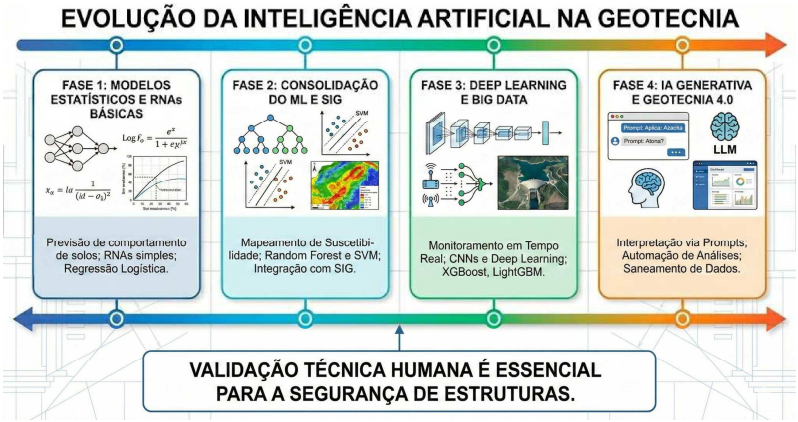


Figura 2. Evolução da Inteligência Artificial na Geotecnia.

Fase 1 – Fundamentação: Caracterizada pelo uso de estatística clássica, regressão logística e redes neurais básicas para prever comportamentos estruturais e recalques, utilizando métodos consolidados como o de Asaoka (1978).

Fase 2 – Consolidação do *Machine Learning*: Marcada pela democratização de dados de sensoriamento remoto, que permitiu a integração massiva de algoritmos como *Random Forest* e *Support Vector Machines* em ambientes de Sistemas de Informação Geográfica (SIG).

Fase 3 – Alta Performance e Big Data: Fase definida pela transição para o Deep Learning e modelos de gradient boosting, que, segudo Mendes *et al.* (2025), alcançam acurácias superiores a 90% ao processar variáveis complexas em tempo real.

Fase 4 – IA Generativa e Geotecnia 4.0: Representa o paradigma atual da interatividade, onde modelos de linguagem (LLMs) e ferramentas especializadas (como o *RSInsight*) são utilizados para interpretação automatizada de instrumentos e suporte à decisão via prompts técnicos.

Apesar do avanço tecnológico, a literatura converge para o fato de que a IA atua como um sistema de apoio (Shahin, 2024), sendo a validação técnica humana o pilar insubstituível para a segurança (Mendonça *et al*., 2024) e a responsabilidade ética em estruturas geotécnicas (Ghaffarian *et al*., 2023).

3 METODOLOGIA

A metodologia deste estudo baseia-se em uma análise bibliométrica sistemática, o mapeamento do panorama científico sobre o uso da Inteligência Artificial na gestão de riscos de movimentos de massa. O fluxo de trabalho foi dividido em quatro etapas: coleta de dados, processamento, mapeamento visual e análise de dados.

3.1 Coleta e Seleção de Dados para a Análise Bibliométrica

A busca bibliográfica foi delimitada ao período compreendido de 2021 a 2026, e realizada na base de dados Scopus, escolhida por sua ampla cobertura de periódicos de alto impacto nas áreas de engenharia geotécnica e ciências ambientais. A estratégia de busca utilizou uma combinação de termos booleanos focados em três eixos: (i) Inteligência Artificial, (ii) movimentos de massa e (iii) gestão de riscos. A search string final aplicada foi:

("Artificial Intelligence" OR "Machine Learning" OR "Deep Learning" OR "Neural Networks" OR "Random Forest" OR "Support Vector Machine" OR "CNN") AND ("Landslide" OR "Mass movement" OR "Debris flow" OR "Rockfall" OR "Slope stability" OR "Slope failure") AND ("Risk management" OR "Risk assessment" OR "Susceptibility" OR "Early warning system" OR "Decision support").

Foram aplicados filtros de refinamento para selecionar apenas artigos originais (*articles*), artigos de revisão (*reviews*) e trabalhos completos em conferências (*conference papers*), publicados no idioma inglês. A amostra final resultou em 2.112 documentos, exportados em formato CSV contendo informações de citação, bibliográficas, resumos e palavras-chave.

3.2 Processamento e Padronização (Tesauro)

Para a análise dos dados, utilizou-se o *software* VOSviewer. Antes da geração dos mapas, procedeu-se à limpeza e padronização dos dados através de um arquivo de tesauro. Esta etapa foi crucial para unificar variantes de um mesmo termo, corrigir plurais e consolidar siglas técnicas, garantindo a precisão estatística da análise de coocorrência.

3.3 Análise Bibliométrica e Mapeamento

A análise bibliométrica utilizou a técnica de coocorrência de palavras-chave no software VOSviewer através do método *full counting*. Com um *threshold* de 30 ocorrências, obteve-se uma rede de 151 termos significativos. Foram gerados mapas de rede (*Network Visualization*), para identificar clusters temáticos, e de sobreposição (*Overlay Visualization*), para analisar tendências temporais e lacunas de pesquisa no campo.

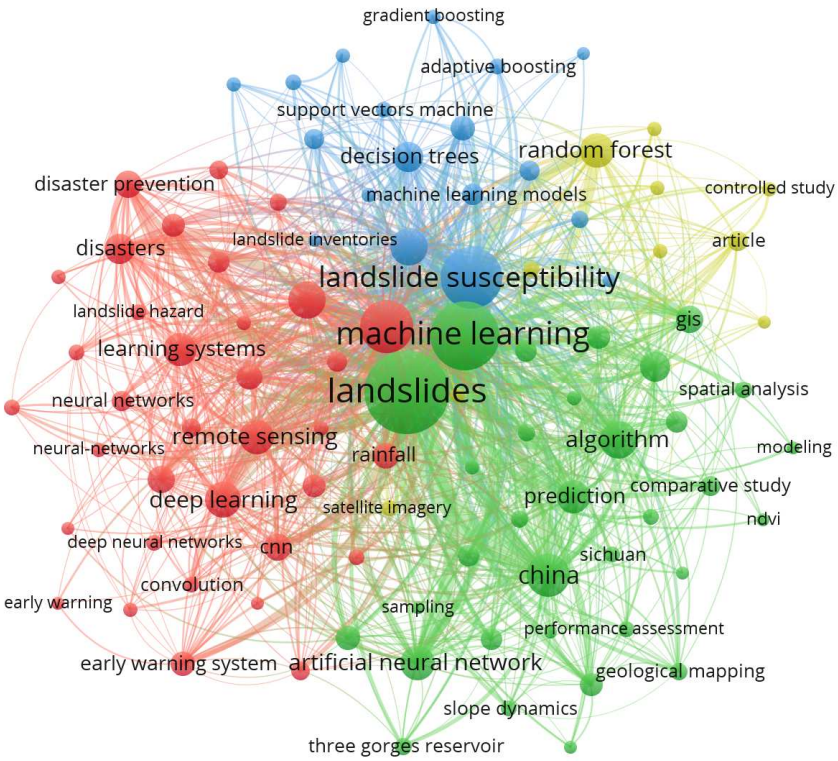
3.4 Análise de Dados

A análise de dados foi estruturada através de uma abordagem híbrida que integrou técnicas quantitativas e qualitativas, iniciando-se com a avaliação estatística dos mapas de coocorrência gerados no software VOSviewer para a identificação dos quatro clusters temáticos detalhados na secção 4.1. Esta etapa quantitativa serviu de base para uma expansão analítica qualitativa posterior, na qual a interpretação técnica dos agrupamentos permitiu correlacionar as tendências bibliométricas observadas com os conceitos práticos da engenharia geotécnica e as diretrizes estratégicas da gestão de riscos. Dessa forma, os conteúdos discutidos no tópico 4.2 derivam diretamente da análise das palavras-chave de maior centralidade em cada cluster, estabelecendo uma ligação lógica.

4 RESULTADOS E DISCUSSÕES

4.1 Análise Bibliométrica

Os resultados obtidos através do mapeamento científico, *Figura 3*, transcendem a métrica quantitativa, revelando como a comunidade acadêmica global está respondendo ao desafio da crescente complexidade dos desastres naturais. Como destacado anteriormente, a dificuldade dos métodos tradicionais em lidar com a não-linearidade e o volume massivo de dados geotécnicos, *Big Data*, impulsionou a ascensão da Inteligência Artificial como um pilar estratégico.



Legenda: O tamanho dos nós (círculos) reflete a frequência de ocorrência do termo nas publicações, as linhas indicam a conexão entre eles, e as cores representam os diferentes agrupamentos temáticos (*clusters*) identificados pelo *software*.

Figura 3. Mapa de coocorrência de palavras.

A análise de coocorrência de palavras-chave permitiu segmentar essa evolução em quatro domínios que explicam a transição de uma gestão de riscos reativa para uma postura proativa.

4.1.1 Cluster Verde - A Resposta ao Big Data e a Hegemonia dos Dados

O *Cluster* Verde reflete a primeira grande transição: a necessidade de ferramentas robustas para processar o volume acentuado de dados gerados pelo monitoramento ambiental. O predomínio de termos como *machine learning, algorithm* e sua forte conexão com a China e grandes projetos de infraestrutura (ex: *Three Gorges Reservoir*) demonstra que a IA não é mais uma ferramenta acessória, mas o motor central para a análise de estabilidade em cenários complexos. Aqui, a importância reside na superação da capacidade humana de análise; algoritmos fundamentais são treinados para identificar padrões em séries históricas que seriam imperceptíveis por métodos estatísticos convencionais, estabelecendo a base para modelos preditivos mais confiáveis.

4.1.2 Cluster Vermelho - O Desafio da Não-Linearidade e a Fronteira do Deep Learning

O *Cluster* Vermelho aborda diretamente essa lacuna através do *Deep Learning* e das Redes Neurais Convolucionais (CNN). A integração com o sensoriamento remoto (*Remote Sensing* e *InSAR*) permite que a gestão de riscos utilize o *Big Data* vindo de satélites para monitorar deformações em tempo real. Esta evolução tecnológica é o que possibilita a existência de Sistemas de Alerta Precoce (*Early Warning Systems*) eficazes: a IA processa a complexidade das variáveis atmosféricas e geotécnicas simultaneamente, oferecendo uma velocidade de resposta que os modelos físicos tradicionais, isoladamente, não conseguem atingir.

4.1.3 Cluster Azul - Buscas de ferramentas mais transparentes para auxílio ao Suporte à Decisão

A importância da IA na gestão de risco não reside apenas na precisão da predição, mas na confiabilidade da informação para o tomador de decisão. O *Cluster* Azul, focado em *landslide susceptibility mapping*, revela uma tendência crucial: a busca pela IA Explicável através do termo *SHAP*. Isso endereça a crítica comum de que modelos de IA são "caixas-pretas" difíceis de interpretar. Ao utilizar ferramentas que explicam os fatores condicionantes, como declividade, geologia e pluviometria, a ciência está entregando aos gestores públicos Sistemas de Apoio à Decisão mais transparentes. Isso permite que a gestão de risco saia do campo da incerteza para o campo da ação estratégica fundamentada.

4.1.4 Cluster Amarelo - Consolidação Geoespacial e Gestão Proativa

Por fim, o *Cluster* Amarelo demonstra a maturação da integração entre o aprendizado de máquina (especialmente *Random Forest*) e os Sistemas de Informação Geográfica (*GIS*). Este domínio representa a aplicação prática da IA no planejamento urbano e na prevenção de desastres. A convergência de dados ambientais estáticos e dinâmicos em mapas de fácil interpretação é o que concretiza a transição para uma gestão proativa. Demonstra que a IA atua como o integrador final, transformando dados brutos em inteligência geográfica, permitindo que a resposta eficaz mencionada no resumo deste artigo se torne uma realidade operacional.

4.2 Inteligência Artificial na Gestão de Riscos de Deslizamento

A integração da Inteligência Artificial na Gestão de Riscos de Desastres marca a transição de um modelo tradicionalmente reativo para uma abordagem estratégica, proativa e preditiva. Esta evolução permite que a engenharia geotécnica enfrente a complexidade e a não-linearidade dos solos (Shahin, 2024), tratando o risco não apenas como um fenômeno físico isolado, mas como uma construção social dinâmica que exige uma governança integrada e resiliente.

A IA atua de forma transversal nas fases do ciclo de gestão de riscos, otimizando a tomada de decisão em cenários de alta incerteza:

4.2.1 Prevenção e Mitigação

A etapa de prevenção e mitigação no ciclo de gestão de riscos de desastres compreende o conjunto de ações antecipatórias realizadas em períodos de normalidade, visando evitar a ocorrência de desastres ou minimizar a severidade de seus impactos. Enquanto a prevenção foca na eliminação do risco em áreas vulneráveis, a mitigação busca reduzir a vulnerabilidade estrutural e social através de intervenções técnicas e planeamento territorial.

Algoritmos de aprendizado de máquina processam dados multimodais, como nuvens de pontos geradas por drones com tecnologia *LiDAR*, para identificar feições de instabilidade (trincas e degraus) sob a densa vegetação, superando as limitações do mapeamento visual convencional.

O emprego de sistemas de drones embarcados com *LiDAR* permite a criação de modelos digitais de terreno (MDT) que, ao filtrar a cobertura vegetal, revelam feições topográficas críticas, como trincas de tração e degraus de abatimento, essenciais para o diagnóstico precoce de instabilidades. Estes dados alimentam modelos de *Machine Learning* que correlacionam fatores condicionantes (declividade, litologia e umidade do solo) para gerar mapas de suscetibilidade com elevada precisão preditiva.

A adoção da Inteligência Artificial Explicável torna-se, portanto, um requisito ético e técnico. Técnicas como o *SHAP* permitem que o engenheiro interprete quais variáveis foram determinantes para uma predição de risco, conferindo a transparência necessária para justificar decisões críticas, como a execução de obras de contenção ou a implementação de medidas de drenagem superficial

4.2.2 Preparação e Monitoramento

A fase de preparação compreende as medidas adotadas para garantir uma resposta eficaz e reduzir os danos em situações onde o desastre é iminente ou provável. No contexto da gestão de riscos de deslizamento, a preparação evoluiu de uma dependência exclusiva de dados pluviométricos para a implementação de Sistemas de Alerta Precoce baseados em monitoramento direto e Inteligência Artificial.

- Monitoramento de Deformação e Antecipação de Rupturas

Um dos avanços mais significativos nesta etapa é a utilização de sensores de rotação de superfície, como a tecnologia Kantaro. Ao contrário da medição de pluviosidade, que pode gerar alarmes falsos por não considerar o grau de saturação prévio do solo, os sensores de rotação medem a resposta mecânica direta da encosta. Algoritmos de IA processam estas variações angulares continuamente, permitindo identificar o início de um movimento de ruptura com uma antecedência média de 16 horas segundo (Melo e Kochen, 2024). Esta janela temporal é crítica para a ativação de rotas de fuga e a evacuação de áreas vulneráveis.

- IA Generativa e Suporte à Decisão em Tempo Real

A preparação moderna integra modelos de linguagem de grande escala (*LLMs*) e agentes inteligentes que atuam como assistentes técnicos 24 horas por dia e 7 dias por semana. Ferramentas como o *RSInsight* permitem que o engenheiro, agindo como um curador técnico, realize consultas rápidas sobre o comportamento de modelos geotécnicos e receba diagnósticos automatizados sobre anomalias detectadas em instrumentos. Esta interatividade acelera a validação de dados brutos, transformando-os em alertas confiáveis que evitam que a Defesa Civil e a população sejam atingidas sem capacidade de resposta imediata.

4.2.3 O Desafio da inteligência artificial

Para que um gestor público confie em uma decisão de evacuação baseada em IA, o modelo não pode ser uma "caixa-preta", ou seja existe a necessidade de compreensão de quais variáveis, como um pico de chuva ou saturação do solo, foram determinantes para aquela predição específica. Dessa forma, a transparência e confiança é um pilar central na modernização da gestão de deslizamentos com o auxílio da IA Explicável. A adoção de técnicas como *SHAP* e *LIME* é essencial para que os modelos deixem de ser "caixas-pretas" e forneçam justificativas transparentes para suas predições, permitindo que engenheiros, geólogos e defesas civis tomem decisões de evacuação baseadas em evidências interpretáveis e confiáveis.

Neste contexto, o papel da equipe geotécnica evolui para o de um curador técnico. Este profissional será responsável por validar as interpretações da IA, as quais a análise sistêmica e o julgamento crítico de equipes especializadas permanecem insubstituíveis, para integrar o saber técnico ao contexto social das comunidades em especialmente em decisões que envolvem riscos de perdas ou danos de vidas humanas ou de patrimônio.

5 CONCLUSÕES

A análise bibliométrica conduzida neste estudo permitiu mapear o panorama científico global, confirmando que a Inteligência Artificial deixou de ser uma ferramenta acessória para se tornar o pilar estratégico da gestão de riscos de movimentos de massa moderna. Os resultados evidenciam que a área atravessa uma transição disruptiva em direção à chamada Geotecnia 4.0, onde a convergência entre o poder computacional e a disponibilidade de dados permite a superação dos modelos estatísticos convencionais em prol de uma postura preditiva e proativa. Observou-se que a evolução do campo atingiu um paradigma de alta interatividade, caracterizado pelo uso de modelos generativos e ferramentas especializadas que auxiliam na interpretação automatizada de instrumentos e no suporte à decisão técnica.

Os dados obtidos por meio da instrumentação em tempo real, ao serem processados por algoritmos de aprendizado profundo, viabiliza um tempo de antecedência de até 16 horas para alertas de evacuação, representando um avanço crítico na salvaguarda de vidas humanas. Paralelamente, a pesquisa enfatiza que a transparência dos modelos, através da IA Explicável, é um requisito inegociável para a confiança dos gestores públicos e a aceitação social das medidas de contingência. Conclui-se, portanto, que o sucesso da aplicação da IA na geotecnia depende da validação técnica humana, onde engenheiros e gestores assumem o papel de curador técnico, integrando a precisão algorítmica ao contexto social e participativo das comunidades vulneráveis para o cumprimento das metas globais de resiliência e segurança.

AGRADECIMENTOS

Este trabalho foi apoiado pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), à qual os autores expressam sua gratidão pelo fomento à pesquisa e ao desenvolvimento acadêmico. Os autores também agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio ao projeto sob os processos nº 308489/2022-5 e 445040/2024-6. Adicionalmente, os autores expressam sua gratidão ao Programa de Formação de Recursos Humanos da Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (PRH-ANP) pelo suporte a esta pesquisa, especialmente ao PRH-ANP 35/UFPB – Transição Energética.

REFERÊNCIAS BIBLIOGRÁFICAS

ASAOKA, A. (1978). *Observational Procedure of Settlement Prediction. Soils and Foundations*, [S. l.], v. 18, n. 4, p. 87-101.

FURTADO, J. *et al*. (2013). *Capacitação básica em Defesa Civil*. 2. ed. Florianópolis: CAD UFSC.

GHAFFARIAN, S.; TAGHIKHAH, F. R.; MAIER, H. R. (2023). Explainable artificial intelligence in disaster risk management: Achievements and prospective futures. *International Journal of Disaster Risk Reduction*, v. 98, p. 104123. DOI: https://doi.org/10.1016/j.ijdrr.2023.104123.

MELO, R.; KOCHEN, R. (2024). *Monitoramento e Gestão de Riscos: GeocCompany*. YouTube: Canal Geotecnia Brasil, 2024. Disponível em: https://www.youtube.com/watch?v=v7ZBkoV9BQ8. Acesso em: 04 jan. 2026.

MENDES, J. C. *et al*. (2025). *Inteligência artificial aplicada à Engenharia: primeiros passos e aplicações*. Juiz de Fora: Editora UFJF.

MENDONÇA, Marco Túlio Gurgel; ZORZAN, Lucas Ghion; JÚNIOR, Silas Pereira da Silva; CAMPOS, Marcelo Rossi. (2024). *Machine Learning na Geotecnia: Treinamento para Tomada de Decisões em Monitoramento de Estruturas Geotécnicas*. XXI COBRAMSEG, Balneário Camboriú. Anais.

RAI, A. (2020). Explainable AI: from prediction to understanding. *Journal of the Academy of Marketing Science*, v. 48, n. 1, p. 137-141.

SHAHIN, Mohamed A. (2024). *Progression of artificial intelligence/machine learning in geotechnical engineering*. Curtin University, School of Civil and Mechanical Engineering.

SIMÕES, G. K. S. (2023). *Gestão de Risco de Movimento de Massa na Cidade de João Pessoa-PB*. Programa de Graduação em Engenharia Civil, Universidade Federal da Paraíba, João Pessoa.

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/COBRAMSEG2026.2/24

Previsão Baseada Em Machine Learning De Resistência Não Drenada (Su) A Partir De Ensaios DSS Para Aplicações Offshore

Gleyce de Souza Baptista, M.Eng
Engª Geotécnica, UTEC-Geoservices, Rio de Janeiro, Brasil, gleycesouzaa@gmail.com

Ana Carolina Viana, M.Eng
Engª Geotécnica, UTEC-Geoservices, Rio de Janeiro, Brasil, ana.viana@benthic.com

Rogeane Seixas
Técnica em Estradas, UTEC-Geoservices, Rio de Janeiro, Brasil, rogeane.seixas@benthic.com

Caroline Juliette Barbosa Fernandes
Engª Geotécnica, UTEC-Geoservices, Rio de Janeiro, Brasil, carolinejuliette@poli.ufrj.br

Felipe Barreto Ribeiro Santos Macedo
Engenheiro, Petrobras, Rio de Janeiro, Brasil, felipe.b.macedo@petrobras.com.br

RESUMO: A estimativa da resistência não drenada (Su) é um elemento central em análises de estabilidade e no projeto de estruturas *offshore* em argilas marinhas. Este trabalho avalia a aplicação de modelos baseados em *machine learning* para a previsão da resistência não drenada obtida em ensaios de *Direct Simple Shear* (DSS), comparando seus resultados com correlações empíricas consagradas na engenharia geotécnica. A base de dados é composta por resultados de ensaios de laboratório realizados em argila marinha proveniente de uma campanha *offshore* na Bacia de Santos. A metodologia adotada fundamenta-se principalmente em regressão simbólica via algoritmo genético (AG), permitindo a obtenção de equações analíticas explícitas e fisicamente interpretáveis. O desempenho dos modelos foi avaliado por meio de métricas estatísticas usuais e confrontado com correlações empíricas tradicionais. Os resultados indicam que os modelos baseados em *machine learning* apresentam desempenho superior na reprodução dos valores medidos de Su,DSS, com redução significativa da dispersão e dos erros médios, sem prejuízo da interpretabilidade. Os achados reforçam o potencial dessas abordagens como ferramentas complementares às correlações empíricas na caracterização geotécnica de argilas marinhas *offshore*.

PALAVRAS-CHAVE: Resistência não drenada, Machine Learning, Ensaio DSS, Argila marinha, Offshore.

ABSTRACT: The estimation of undrained shear strength (Su) is a key parameter in stability analyses and in the design of offshore structures founded on marine clays. This study evaluates the application of machine learning–based models for predicting the undrained shear strength obtained from Direct Simple Shear (DSS) tests, comparing their performance with well-established empirical correlations used in geotechnical engineering. The database comprises laboratory test results from marine clay samples collected during an offshore campaign in the Santos Basin. The adopted methodology is primarily based on symbolic regression using genetic algorithms, enabling the derivation of explicit and physically interpretable analytical equations. Model performance was assessed using standard statistical metrics and benchmarked against traditional empirical correlations. The results indicate that the machine learning–based models provide superior agreement with measured Su,DSS values, with a significant reduction in data dispersion and average errors, without loss of interpretability. These findings highlight the potential of such approaches as complementary tools to empirical correlations for the geotechnical characterization of offshore marine clays.

KEYWORDS: Undrained shear strength, Machine Learning, DSS test, Marine clay, Offshore.

1 Introdução

A resistência não drenada, Su, é um parâmetro fundamental em análises de estabilidade e projetos geotécnicos, sendo usualmente obtida por ensaios de laboratório, como o *Direct Simple Shear*, ou estimada por meio de correlações empíricas baseadas em propriedades físicas e parâmetros de estado do solo. Embora amplamente empregadas devido à sua simplicidade, essas correlações apresentam limitações na representação da variabilidade e da complexidade do comportamento de argilas marinhas, especialmente em contextos *offshore* e bases de dados específicas. Nesse cenário, técnicas de *machine learning* têm sido investigadas como ferramentas complementares às abordagens convencionais, com potencial para aprimorar a estimativa da resistência não drenada sem perda de coerência física.

Este trabalho tem como objetivo avaliar o desempenho de modelos baseados em algoritmo genético (AG) na previsão da resistência não drenada obtida em ensaios de DSS, comparando-os com correlações empíricas tradicionais e discutindo seu potencial de aplicação prática na engenharia geotécnica.

1.1 Métodos empíricos para previsão de Su

Os ensaios de laboratório são essenciais para a compreensão do comportamento dos solos, pois permitem investigar, sob condições controladas, efeitos como anisotropia, histórico de tensões e dependência do caminho de carregamento, que não podem ser plenamente avaliados por ensaios *in situ*. Quando a execução de ensaios avançados, como DSS, triaxial de compressão ou extensão, não é viável, a literatura indica que a resistência não drenada *in situ* pode ser estimada de forma consistente a partir de ensaios edométricos, por meio da determinação da razão de sobreadensamento (OCR) e de correlações empíricas que relacionam Su à tensão vertical efetiva inicial, conforme expresso na equação 1. Essa abordagem tem se mostrado particularmente adequada para algumas análises, embora estudos clássicos ressaltam que, para projetos de maior complexidade, a realização de ensaios com diferentes modos de cisalhamento permanece fundamental para capturar os efeitos da anisotropia e da ruptura progressiva na seleção de parâmetros de resistência (Jamiolkowski et al, 1985).

$$\frac{S_u}{\sigma'_v} = (0.23 \pm 0.04) OCR^{0.8} \quad (1)$$

A correlação empírica para a estimativa da resistência não drenada proposta por Ahmed & Agaiby (2020), equação 2, baseia-se na integração de propriedades índice do solo e parâmetros de estado de tensões, buscando representar de forma consistente o comportamento resistente de argilas sob condições não drenadas. Os autores desenvolveram uma expressão para Su,DSS a partir de dados obtidos em ensaios de caracterização, limites de Atterberg e ensaios de adensamento, incorporando explicitamente a influência do índice de plasticidade (PI), do teor de umidade natural (wn), da massa específica dos sólidos (Gs), da tensão vertical efetiva inicial (σ'v0) e da razão de sobreadensamento (OCR). A formulação reflete o entendimento de que a resistência não drenada é dependente do caminho de tensões, sendo particularmente adequada para representar o modo de cisalhamento associado ao ensaio de cisalhamento direto simples (DSS). Dessa forma, a correlação permite estimar Su,DSS de maneira prática e fundamentada, utilizando parâmetros rotineiramente disponíveis em campanhas geotécnicas *offshore* e *onshore*, sem a necessidade de ensaios mecânicos avançados.

$$S_{u,DSS} = \left[\frac{0.624 G_s PI^{0.32}}{6 + G_s(0.416 PI^{0.32} + 0.06\, W_n)}\right] \sigma'_{v0} OCR^{0.8} \quad (2)$$

1.2 Aplicações de Machine Learning em Geotecnia

De forma geral, técnicas de *machine learning* (ML) têm sido amplamente aplicadas na engenharia para identificar padrões e relações complexas em bases de dados geotécnicas, sobretudo quando abordagens empíricas tradicionais se mostram limitadas (Goodfellow *et al.*, 2016). Entre os modelos mais utilizados destacam-se o *Random Forest*, a *Support Vector Regression* e as Redes Neurais Artificiais, que aprendem a partir de dados observados, mas diferem quanto à estrutura, capacidade de generalização e requisitos de

calibração (James, 2023; Li *et al.*, 2025). O desempenho desses modelos depende diretamente das características da base de dados e do objetivo da análise, sendo empregados com sucesso na previsão de propriedades e parâmetros geotécnicos, como a resistência não drenada Su (Ahmad, 2025; Nguyen *et al.*, 2025). Nesse contexto, a Regressão Simbólica destaca-se por buscar automaticamente uma forma funcional livre para representar a relação entre variáveis, utilizando a Programação Genética como estratégia de busca (Pacheco, s.d.). O núcleo desse método são os Algoritmos Genéticos, formalizados por John Holland (1975), que exploram o espaço de soluções por meio de uma população de candidatos e de operadores de seleção, cruzamento e mutação, permitindo a identificação simultânea da estrutura do modelo e de seus parâmetros. Essa abordagem evolutiva é reconhecida por sua robustez em problemas não lineares e complexos, reduzindo a probabilidade de convergência para ótimos locais e dispensando hipóteses rígidas sobre o comportamento dos dados (Oliveira, 2017; Pacheco, s.d.).

1.3 Ensaio de DSS

O ensaio de *Direct Simple Shear* (DSS) é um ensaio de laboratório empregado para determinar a resistência ao cisalhamento dos solos, no qual o corpo de prova é confinado lateralmente, impedindo deslocamentos horizontais e permitindo apenas a deformação por cisalhamento sob comprimento horizontal constante (Dyvik *et al.*, 1987). Executado, em geral, conforme a norma ASTM D6528-17, o ensaio é realizado em duas etapas principais: carregamento vertical sob confinamento lateral e posterior aplicação do cisalhamento simples. O DSS pode ser conduzido em condições verdadeiramente não drenadas ou drenadas a volume constante, sendo demonstrada a equivalência entre essas condições em termos de tensões efetivas (Dyvik *et al.*, 1987). Apesar de as tensões serem conhecidas apenas no plano horizontal durante o cisalhamento, o ensaio é amplamente reconhecido por representar de forma mais realista, quando comparado ao ensaio de cisalhamento direto, determinadas condições de campo, incluindo a rotação dos eixos das tensões principais (Villet *et al.*, 1985; Airey e Wood, 1987).

2 Materiais e métodos

2.1 Base de dados

A base de dados utilizada neste estudo foi obtida a partir de uma campanha geotécnica *offshore* realizada em uma área marítima da costa brasileira, na Bacia de Santos. A investigação de campo foi conduzida por meio de um sistema de perfuração submarina operado remotamente (PROD), permitindo a execução controlada de ensaios *in situ* e a recuperação de amostras no fundo do mar. As amostras indeformadas foram coletadas com sistemas de amostragem apropriados e, posteriormente, acondicionadas, seladas e preservadas conforme procedimentos técnicos. Então essas amostras foram transportadas para o laboratório e armazenadas até a realização dos ensaios *onshore* da UTEC Geoservices. A Figura 1 ilustra o sistema PROD em diferentes fases operacionais, bem como a embarcação de apoio responsável pela execução da campanha geotécnica.

Após a execução dos ensaios e consolidação dos resultados em planilha única, iniciou-se uma etapa de preparação e inspeção preliminar, cujo objetivo foi avaliar a consistência das medições e compreender a variabilidade inerente às propriedades geotécnicas analisadas. Foram geradas estatísticas descritivas contendo média, mínimo e máximo, conforme Tabela 1, permitindo identificar faixas típicas de valores esperados para argilas marinhas da região e apontar possíveis registros discrepantes.



(a) (b) (c)

Figura 1. (a) PROD sendo preparado para mergulho; (b) Sistema PROD emergindo após a operação; (c) Embarcação de apoio responsável pela execução da campanha geotécnica.

Tabela 1. Dados estatísticos do banco de dados.

	Prof (m)	σ'_{v0} (kPa)	σ'_{vm} (kPa)	OCR	γ_n (kN/m³)	e_0	W (%)	IP (%)	Su_{DSS}
min	0.56	2.84	7.94	1.00	13.89	1.31	37.61	27.00	4.34
média	32.05	190.39	225.78	1.74	15.64	2.00	71.26	56.77	61.00
max	98.99	664.84	870.4	25.35	17.72	2.98	117.42	96	182.62

2.2 Metodologia

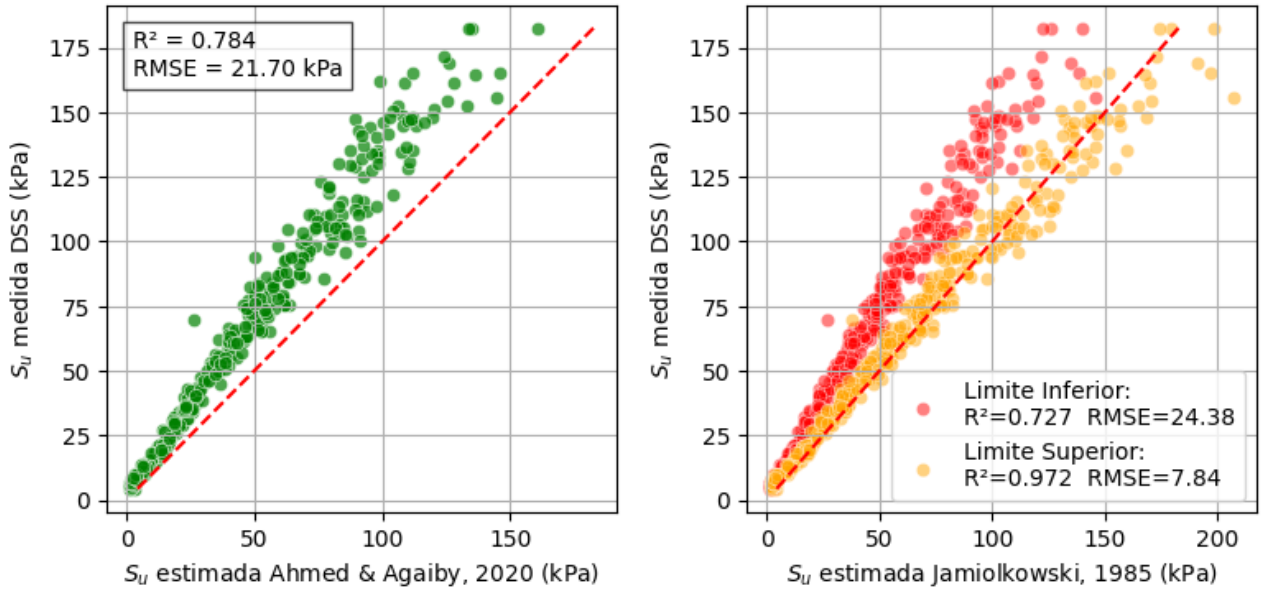
Os dados deste estudo foram consolidados em uma base única composta por resultados de ensaios laboratoriais, passando por etapa de pré-processamento para remoção de registros incompletos e garantia de consistência. A resistência não drenada obtida em ensaios de *Direct Simple Shear* (Su,DSS) foi definida como variável de interesse, enquanto parâmetros físicos e de estado do solo, como tensão vertical efetiva inicial, índice de vazios, teor de umidade, índices de plasticidade e liquidez, razão de sobreadensamento e massa específica dos sólidos, foram utilizados como variáveis de entrada. As variáveis de entrada foram padronizadas segundo $z = (x - \mu)/s$, com média μ e desvio-padrão s calculados no conjunto de treinamento; para as variáveis retidas pelos modelos finais. As equações apresentadas na Seção 3.2 foram reescritas algebricamente em termos das variáveis físicas, de modo a permitir sua aplicação direta em unidades de engenharia. O conjunto de dados foi dividido em subconjuntos independentes de treinamento (70%) e teste (30%). A metodologia baseou-se na aplicação de regressão simbólica via programação genética, visando obter equações analíticas explícitas e interpretáveis que relacionassem as variáveis de entrada à Su,DSS, a partir de um processo evolutivo que privilegia bom ajuste, simplicidade e coerência física. Para fins comparativos, correlações empíricas consagradas da literatura geotécnica, como as propostas por Ahmed & Agaiby (2020) e Jamiolkowski *et al.* (1985), foram aplicadas ao mesmo conjunto de dados. O desempenho dos modelos foi avaliado no conjunto de teste por meio de métricas estatísticas usuais, como o coeficiente de determinação (R^2) e o erro quadrático médio (RMSE), considerando-se adicionalmente a interpretabilidade e o potencial de aplicação prática das equações obtidas. Todo o processamento e as análises foram realizados em ambiente computacional baseado em Python, utilizando a plataforma Google Colab.

3 Resultados e discussões

3.1 Desempenho dos modelos tradicionais empíricos

A Figura 2 apresenta a comparação entre os valores de resistência não drenada medidos em ensaios de cisalhamento direto simples (Su,DSS) e aqueles estimados por correlações empíricas consagradas na literatura, no formato observado *versus* estimado, com a inclusão da linha de referência 1:1. A correlação de

Jamiolkowski et al (1985), apresentou desempenho global moderado (R2=0,727; RMSE = 24,38 kPa), com aumento significativo da dispersão para valores mais elevados de Su e tendência sistemática de subestimação e superestimação em diferentes faixas de tensão, indicando limitação na representação da variabilidade associada às propriedades físicas do solo; embora o limite superior da correlação apresente bom ajuste (R2=0,972; RMSE = 7,84 kPa). Em contraste, a correlação proposta por Ahmed & Agaiby (2020) apresentou desempenho superior (R2=0,784; RMSE = 21,70 kPa), com menor dispersão e melhor aderência à linha 1:1 ao longo da faixa analisada, atribuída à inclusão de parâmetros adicionais relacionados ao estado e à composição do solo; ainda assim, observa-se tendência de subestimação para valores elevados de Su, evidenciando que, apesar de úteis como ferramentas preliminares, as correlações empíricas apresentam limitações intrínsecas, reforçando a motivação para o uso de abordagens complementares baseadas em *machine learning*.



(a) (b)

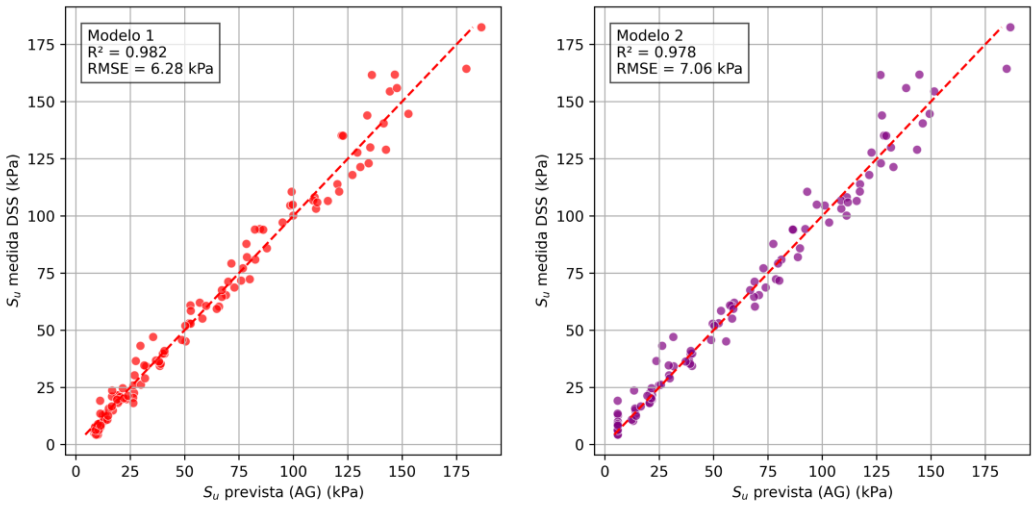
Figura 2. Comparação entre os valores de Su medidos em ensaios de DSS e estimados por correlações empíricas: (a) correlação de Jamiolkowski, 1985; (b) correlação de Ahmed & Agaiby, 2020.

3.2 Desempenho dos modelos de ML

A Figura 3 apresenta a comparação entre os valores de resistência não drenada medidos em ensaios de cisalhamento direto simples (Su,DSS) e aqueles estimados por modelos de *machine learning* baseados em regressão simbólica por programação genética, evidenciando desempenho significativamente superior às correlações empíricas tradicionais. Dois modelos foram desenvolvidos: o Modelo 1, que privilegia equações mais simples e interpretáveis ao restringir as operações matemáticas, resultando na equação 3, apresentou excelente ajuste nos dados de teste (R2=0,982; RMSE = 6,28 kPa), com elevada concentração dos pontos ao longo da linha 1:1; já o Modelo 2, obtido com um conjunto ampliado de operadores, resultou em uma relação linear direta, equação 4, também com desempenho elevado (R2=0,978; RMSE = 7,06 kPa). Nas equações 3 e 4, Su e σ'v0 são expressos em kPa e w em porcentagem. A comparação entre os modelos evidencia o equilíbrio entre complexidade da equação e desempenho preditivo, mostrando que a regressão simbólica é capaz de capturar relações não lineares relevantes com equações explícitas, transparentes e fisicamente interpretáveis, reforçando o potencial de algoritmos genéticos como uma alternativa complementar entre correlações empíricas clássicas para aplicações em engenharia geotécnica.

$$S_u = (0.1381\, w - 21.886)(-0.01914\, \sigma'_{v0} - 0.9001) \quad (3)$$

$$S_u = 0.2902\, \sigma'_{v0} + 4.905 \quad (4)$$



(a) (b)

Figura 3. Comparação entre os valores de Su nos dados de teste pelo (a) Modelo 1; (b) Modelo 2

3.3 Comparação direta entre ML × modelos empíricos

A Tabela 2 compara o desempenho das correlações empíricas tradicionais e dos modelos baseados em *machine learning* na estimativa da resistência não drenada obtida em ensaios DSS. As correlações empíricas apresentaram desempenho moderado (R2≈0,73) e erros médios da ordem de 20–25 kPa, com elevada dispersão, especialmente para valores mais elevados de Su. Em contraste, os modelos de regressão simbólica alcançaram desempenho significativamente superior nos dados de teste (R2≥0,98; RMSE<8kPa), mantendo equações analíticas explícitas e de fácil interpretação. Esses resultados indicam que os modelos de *machine learning* constituem uma alternativa complementar às correlações empíricas, oferecendo maior precisão sem perda de transparência para aplicações em engenharia geotécnica.

Tabela 2. Comparação entre os modelos de ML e tradicionais

Abordagem	Modelo	Variáveis	Forma da equação	R^2	RMSE (kPa)
Empírico tradicional	Jamiolkowski et al (1985)	σ'_{v0}, OCR	Lei potencial simples	≈ 0,73	≈ 24,4
Empírico tradicional	Ahmed & Agaiby (2020)	G_s, IP, w, σ'_{v0}, OCR	Expressão empírica multivariada	0,78	21,7
ML – Algoritmo Genético	Modelo 2	σ'_{v0}	Linear	0,98	7,06
ML – Algoritmo Genético	Modelo 1	w, σ'_{v0}	Não linear explícita	0,98	6,28

4 Conclusões

Este trabalho avaliou a estimativa da resistência não drenada obtida em ensaios de DSS a partir de correlações empíricas tradicionais e de modelos baseados em ML, utilizando uma base de dados composta por argila marinha de uma campanha *offshore* da Bacia de Santos. As análises evidenciaram que as correlações empíricas, embora amplamente utilizadas na prática geotécnica e de fácil aplicação, podem apresentar limitações na reprodução dos valores medidos de Su,DSS, especialmente em faixas mais elevadas de resistência, refletidas em dispersão significativa e erros médios relativamente elevados. Em contraste, os modelos desenvolvidos por regressão simbólica, algoritmo genético, apresentaram desempenho estatisticamente superior, com redução expressiva do erro e melhor aderência aos resultados de laboratório, mantendo coerência com as tendências físicas observadas.

Destaca-se que a melhoria de desempenho obtida com os modelos de ML não ocorreu à custa da perda de interpretabilidade, uma vez que o algoritmo genético forneceu equações analíticas explícitas, passíveis de análise crítica por engenheiros e de aplicação direta com variáveis em unidades de engenharia. A comparação entre modelos de diferentes níveis de complexidade indicou que formulações relativamente simples já são capazes de capturar grande parte da variabilidade observada, reforçando a importância de critérios de semelhança para aplicações práticas. De forma geral, os resultados indicam que abordagens baseadas em ML podem atuar como ferramentas complementares às correlações empíricas tradicionais, contribuindo para a redução de incertezas na estimativa da resistência não drenada quando aplicadas à bases de dados representativas e bem caracterizadas.

REFERÊNCIAS BIBLIOGRÁFICAS

Ahmad, M.; Mohammad A. Z.; Hamad, A.; Mohanad, M. S. S.; Jawad, B. M.; Shay H.; Tariq, O.; Abdullah, A. Improved prediction of soil shear strength using machine learning algorithms: interpretability analysis using SHapley Additive exPlanations. Frontiers in Earth Science, v. 13, art. 1542291, 2025.

Ahmed, S.M.; Agaiby, S.S. (2020). Strength and stiffness characterization of clays using Atterberg limits. Transportation Geotechnics, 25, 100420. Elsevier. https://doi.org/10.1016/j.trgeo.2020.100420

FATEHNIA, Milad; PARAN, Sanaz. Applying machine learning for SPT-N prediction from raw CPT data. In: CONFERENCE ON DEEP FOUNDATIONS, 50., 2025, Nashville (TN). Proceedings… Nashville (TN): Deep Foundations Institute, 2025. p. 345–355.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. Deep Learning. Cambridge: MIT Press, 2016.

JAMES, Gareth et al. An Introduction to Statistical Learning: with Applications in Python. Cham: Springer, 2023. (Springer Texts in Statistics).

Jamiolkowski, M.; Ladd, C.C.; Germaine, J.T.; Lancellotta, R. (1985). New developments in field and laboratory testing of soils. Proceedings of the International Conference on Soil Mechanics and Foundation Engineering, 1985.

LI, Kai; JIA, Pengfei; CHEN, Zihao; WANG, Yong. Fine-Scale Stratigraphic Identification Using Machine Learning Trained on Multi-Site CPTU Data. Geosciences, Basel, v. 15, n. 11, art. 437, 2025.

NGUYEN, Ho-Hong-Duy; NGUYEN, Thanh-Nhan; PHAN, Thi-Anh-Thu; HUYNH, Ngoc-Thi; HUYNH, Quoc-Dat; TRIEU, Tan-Tai. Explainable artificial intelligence model for the prediction of undrained shear strength. Theoretical & Applied Mechanics Letters, v. 15, n. 3, p. 100578, 2025.

OLIVEIRA, N. C. P. Aplicabilidade dos Algoritmos Genéticos na Engenharia Civil. Trabalho de Conclusão de Curso (Graduação em Engenharia Civil) – Universidade Federal da Paraíba, João Pessoa, 2017.

PACHECO, M. A. C. Algoritmos Genéticos: Princípios e Aplicações. Laboratório de Inteligência Computacional Aplicada (ICA), PUC-Rio, [s.d.].

AIREY, D. W.; WOOD, D. M. An evaluation of direct simple shear tests on clay. Geotechnique, v. 37, n. 1, p. 25–35, 1987.

VILLET, W. C. B.; SITAR, N.; JOHNSON, K. A. Simple Shear Tests on Highly Overeonsolidated Offshore Silts. 17th Offshore Technology Conference, 1985.

DYVIK, R. et al. Comparison of truly undrained and constant volume direct simple shear tests. 1987. Geotechnique, v. 37, n. 1, p. 3–10.

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/COBRAMSEG2026.2/25

Previsão da Variação de Temperatura do Solo em Sistema GSHP Vertical usando Redes Neurais Artificiais (RNA)

Letícia Menezes Santos Sá
Professora Substituta, Universidade Federal de Sergipe, Aracaju, Brasil, leticiamenezes0512@gmail.com

Gabrielle Maria Romeiro Lombardi
Professora, PECEGE – ESALQ/USP, Piracicaba, Brasil, glombardi.pecege@gmail.com

Alberto Hernandez Neto
Professor, Universidade de São Paulo, São Paulo, Brasil, ahneto@usp.br

Cristina de Hollanda Cavalcanti Tsuha
Professora, Escola de Engenharia de São Carlos da Universidade de São Paulo, São Carlos, Brasil, chctsuha@sc.usp.br

RESUMO: Diante da crescente demanda por fontes de energia renováveis e do aumento do consumo energético para climatização de edificações no Brasil, esta pesquisa investiga o uso da geotermia superficial por meio de estacas trocadoras de calor, com o objetivo de prever o desempenho térmico de sistemas "Ground Source Heat Pump (GSHP)". Para isso, este estudo propôs e avaliou um modelo de rede neural artificial capaz de estimar parâmetros térmicos desses sistemas acoplados a fundações com estacas trocadoras de calor. Utilizando resultados obtidos a partir de simulações realizadas com o software PILESIM 2.1, o modelo previu três variáveis principais: coeficiente de performance (COP), temperatura da superfície do solo e temperatura média ao longo do perfil de solo. Os resultados evidenciaram a eficácia do modelo, com redução consistente do erro absoluto médio e da função de perda ao longo do treinamento. A análise dos coeficientes de determinação (R^2) e do erro relativo médio confirmou a capacidade preditiva da rede, com maior precisão na estimativa do coeficiente de desempenho e maior variabilidade nas previsões de temperaturas do solo. Com base nestes resultados, a aplicação de redes neurais artificiais apresentou-se como uma alternativa promissora para complementar a análise e a modelagem térmica de longo prazo de sistemas GSHP acoplados a fundações profundas no Brasil. Pesquisas futuras poderão incluir variáveis adicionais, otimizar a arquitetura da rede neural e explorar técnicas avançadas de pré-processamento de dados.

PALAVRAS-CHAVE: Estacas Trocadoras de Calor, Modelagem Preditiva, Geotermia Superficial, Simulação Computacional.

ABSTRACT: Considering the growing demand for renewable energy sources and the increasing energy consumption for climatization in Brazil, this research investigates the use of shallow geothermal energy through energy piles, aiming to predict the thermal performance of Ground Source Heat Pump (GSHP) systems. To this end, the study proposed and evaluated an artificial neural network model capable of estimating thermal parameters of such systems coupled with energy pile foundations. Using results obtained from simulations performed with the PILESIM 2.1 software, the model predicted three main variables: coefficient of performance (COP), ground surface temperature, and average ground temperature along the soil profile. The results demonstrated the effectiveness of the model, showing a consistent reduction in mean absolute error and loss function throughout the training process. The analysis of the coefficients of determination (R^2) and mean relative error confirmed the predictive capability of the network, with higher accuracy in estimating the coefficient of performance and greater variability in ground temperature predictions. Based on these findings, the application of artificial neural networks was shown to be a promising alternative to complement the long-term thermal analysis and modeling of GSHP systems coupled with deep foundations in Brazil. Future studies may incorporate additional variables, optimize the neural network architecture, and explore advanced data preprocessing techniques.

KEYWORDS: Energy Piles, Predictive Modeling, Shallow Geothermal Energy, Computational Simulation.

1 INTRODUÇÃO

A busca por fontes de energia limpas e renováveis tem crescido globalmente, impulsionada pelos problemas ambientais enfrentados nos últimos anos. Nesse contexto, a energia geotérmica superficial emerge como uma alternativa sustentável para reduzir o consumo proveniente de outras fontes poluidoras.

O sistema Ground Source Heat Pump (GSHP) realiza trocas térmicas entre o solo e a superfície por meio da circulação de um fluido em tubos instalados no subsolo e conectados a uma bomba de calor (Amatya et al., 2012). A integração desses tubos com fundações profundas torna o sistema mais economicamente atrativo, originando as estacas trocadoras de calor (Brandl, 2006). Durante a operação do sistema, as trocas térmicas podem alterar a temperatura do solo ao redor das estacas ao longo do tempo, especialmente quando há predominância de resfriamento, como ocorre no Brasil (Olgun et al., 2015). Nessas condições, pode ocorrer acúmulo de calor no subsolo e redução da eficiência do sistema.

No Brasil, onde a demanda por resfriamento dos ambientes (rejeição de calor no solo) é predominante ao longo do ano, pode haver uma perda de eficiência do sistema GSHP após alguns anos de operação, devido ao acúmulo de calor no solo ao redor das estacas geotérmicas. Porém, obter medições precisas e detalhadas das variações de temperatura do solo a longo prazo pode ser desafiador, devido a falhas que vão desde problemas nos sensores instalados em campo até interrupções na aquisição de dados. Assim, o uso de Redes Neurais Artificiais (RNA) para prever o comportamento da temperatura do solo durante a operação de sistemas GSHP, bem como o desempenho desses sistemas ao longo do tempo, surge como uma alternativa promissora para apoiar sua aplicação eficaz. Nesse sentido, alguns estudos têm utilizado RNAs para prever a variação da temperatura do solo a longo prazo associada à operação de sistemas GSHP (Xu et al., 2020; Zhou et al., 2021; Liu et al., 2023).

Diante desse contexto, o principal objetivo deste trabalho foi desenvolver e avaliar um modelo de RNA para prever parâmetros térmicos relacionados a um sistema GSHP acoplado a fundações por estacas trocadoras de calor, utilizando dados provenientes do banco de dados gerados através de simulação com o "software" PILESIM 2.1. As variáveis previstas foram o coeficiente de desempenho [COP], a temperatura da superfície do solo [TmGrndTop] e a temperatura do média do perfil de solo [TmGround]. Para isso, utilizou-se uma rede neural "feedforward" e foi considerada uma edificação hipotética na cidade de São Paulo.

2 MATERIAIS E MÉTODOS

A área de estudo localiza-se na cidade de São Paulo (23°33'15.8"S; 46°43'51.2"W), com temperatura média anual de aproximadamente 19 °C. O estudo baseou-se em simulações numéricas realizadas com o software PILESIM 2.1 por Sá et al. (2022), sendo comparados os resultados dessas simulações com aqueles obtidos por um modelo de Rede Neural Artificial.

O estudo original avaliou a variação da temperatura do solo ao longo de 20 anos de operação de estacas trocadoras de calor utilizadas como fundação de um hotel de negócios hipotético. O solo local é predominantemente arenoso, com lentes de argila orgânica silto-arenosa e nível do lençol freático entre 2 e 4 m de profundidade. Nesta pesquisa foram consideradas apenas estacas do tipo hélice contínua. A fundação analisada é composta por 68 estacas com diâmetro de 0,70 m e comprimento de 20 m.

A base de dados foi obtida a partir das saídas das simulações no PILESIM 2.1, considerando características do solo, parâmetros das estacas, dados da bomba de calor e demandas térmicas da edificação (Sá et al., 2022). As simulações consideraram ciclos de seis meses de resfriamento alternados com seis meses de aquecimento ao longo de 20 anos, resultando em um banco de dados com 12 variáveis e 240 observações.

O estudo foi dividido em duas etapas: análise exploratória dos dados e modelagem preditiva com RNA, ambas realizadas em Python (Rossum, 1995). Na análise exploratória foram realizadas limpeza do banco de dados, estatísticas descritivas e análise de correlação entre variáveis.

Para a modelagem preditiva foram selecionadas como variáveis de entrada tempo_acum_h/mes, QHeat, QCold, QElecTot, num_mes e num_ano. As variáveis numéricas foram normalizadas com MinMaxScaler e as categóricas transformadas por one-hot encoding. As variáveis de saída foram COP, TmGrndTop e TmGround.

Os dados foram divididos em treinamento (70%), validação (15%) e teste (15%) utilizando train_test_split (Brownlee, 2020). Foi implementada uma rede neural "feedforward" com três camadas ocultas

(16, 12 e 8 neurônios) e funções de ativação tanh, tanh e sigmoide, respectivamente, e camada de saída com três neurônios e ativação linear (Cybenko, 1989).

O treinamento foi realizado utilizando função de perda MSE, otimizador Adam e taxa de aprendizado de 0,001. O desempenho do modelo foi avaliado por meio das métricas MAE, RMSE, erro relativo médio (MRE) e coeficiente de determinação (R^2).

3 RESULTADOS E DISCUSSÃO

3.1 Análise Exploratória

Alguns gráficos foram elaborados a fim de permitir uma visualização inicial do comportamento das variáveis ao longo do tempo. A Figura 1 apresenta a variação da demanda de energia para diferentes finalidades — aquecimento (QHeat), resfriamento (QCold) e energia elétrica total (QElectTot) - ao longo do tempo. Observa-se que a demanda total de energia para aquecimento (QHeat) apresenta oscilações menores durante a operação do sistema GSHP em comparação com a demanda total de energia para resfriamento (QCold), que apresenta variações mais expressivas. Essas variações aumentam consideravelmente nos seis meses em que há resfriamento dos ambientes da edificação e diminuem abruptamente nos períodos de utilização do sistema para aquecimento da água. Além disso, a energia elétrica consumida pelo sistema também apresenta um padrão cíclico, com picos de demanda nos períodos de resfriamento.

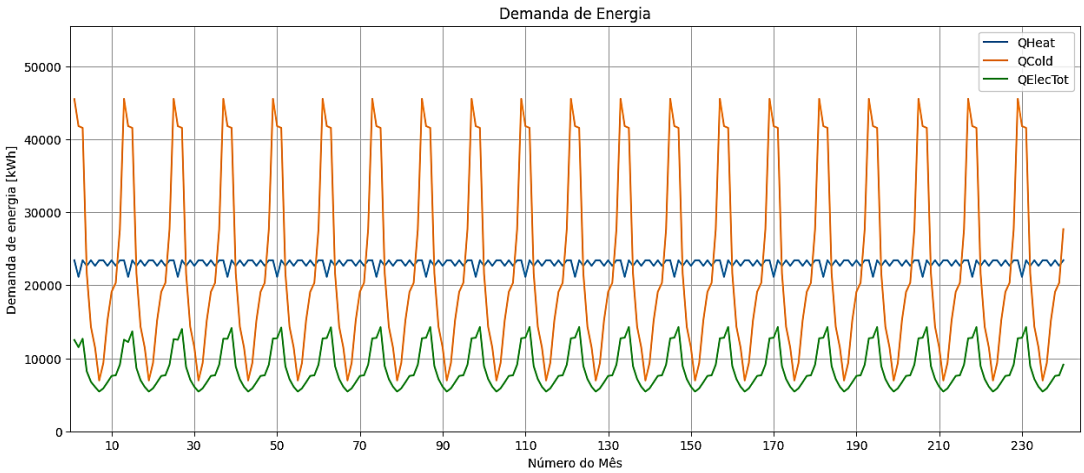


Figura 1. Demanda de energia do sistema ao longo do tempo: QHeat, QCold e QElectTot.

A Figura 2 mostra a variação do COP ao longo do tempo. O gráfico revela que o COP acompanha um padrão semelhante ao da demanda de energia, atingindo valores mais elevados durante os períodos de resfriamento. Ainda assim, o intervalo de variação do COP é pequeno, com valores entre 5,38 (mínimo) e 5,50 (máximo). Esses resultados indicam que, ao longo de todo o período analisado, o COP manteve-se acima da recomendação de Brandl (2006) para sistemas GSHP, que sugere valores superiores a 4. Destaca-se também que, nos períodos de aquecimento, os valores de COP apresentaram uma redução gradual até atingir certa estabilidade.

Por fim, a Figura 3 exibe a variação da temperatura média do volume de solo que é atribuída às estacas trocadoras de calor (TmGround) bem como do solo nos 30 cm iniciais da superfície, onde estão os tubos de conexão horizontal (TmGrndTop). Percebe-se que a temperatura varia de acordo com os ciclos de aquecimento e resfriamento, conforme esperado. No caso do TmGrndTop, provavelmente devido à interferência do ambiente, os valores de temperatura oscilaram em intervalos menores. Verifica-se que há uma tendência de crescimento da temperatura do solo ao longo do tempo, possivelmente devido ao acúmulo de calor ocasionado pela operação do sistema, até atingir uma certa estabilidade, aproximadamente após o mês 90 (~ 7,5 anos de operação).

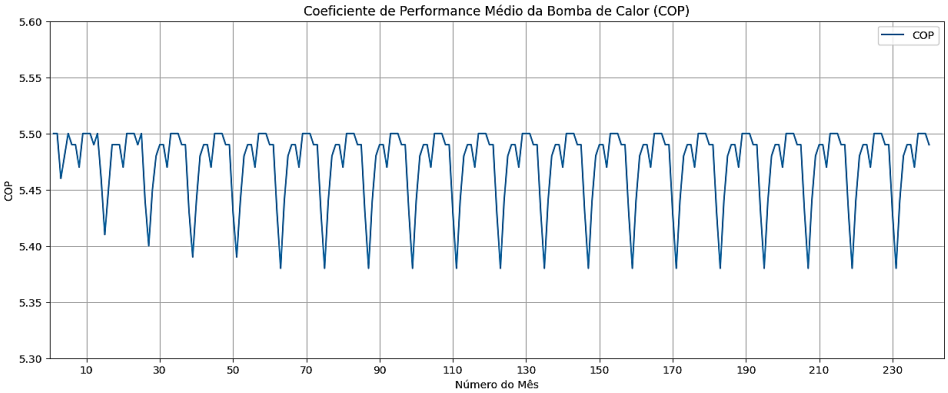


Figura 2. Variação do COP ao longo do tempo.

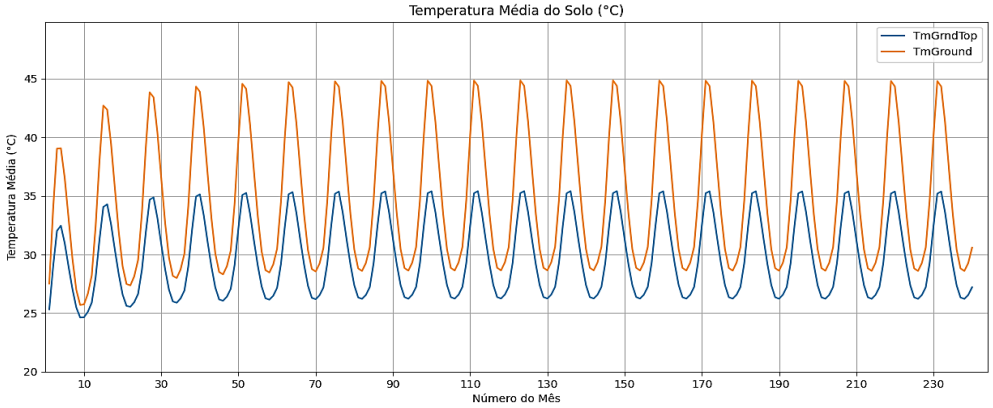


Figura 3. Temperatura média do solo ao longo do tempo de operação do sistema GSHP.

Após a visualização inicial dos dados, foi realizada uma análise descritiva das variáveis quantitativas de interesse, cujos resultados estão apresentados na Tabela 1. Foram excluídas dessa análise a variável "mês", por se tratar de uma categoria nominal, bem como as variáveis "número do mês" e "ano", que não foram consideradas relevantes para a obtenção de medidas descritivas.

Tabela 1. Estatística descritiva das variáveis estudadas

	QHeat	QCold	QElecTot	COP	TmGrndTop	TmGround
Contagem	240	240	240	240	240	240
Média	22977.50	22906.91	8665.13	5.47	29.80	34.94
Desvio Padrão	654.15	12821.31	2836.81	0.03	3.33	5.85
Mínimo	21150	6960	5440	5.38	24.62	25.69
1º Quartil	22660	13600	6557	5.47	26.57	29.31
2º Quartil	23420	19715	7622	5.49	29.17	33.50
3º Quartil	23420	31140	9716.25	5.50	32.43	40.14
Máximo	23420	45530	14280	5.50	35.40	44.85

Em seguida, foi analisada a correlação entre as variáveis estudadas, com exceção do mês (por se tratar de uma variável categórica) e do número do ano, considerados não relevantes para essa etapa (Figura 4). A correlação foi avaliada por meio do coeficiente de correlação de Pearson. Observa-se que as variáveis TmGround e TmGrndTop apresentam uma correlação positiva forte, indicando que a temperatura do solo em profundidade acompanha a variação da temperatura na superfície ao longo do tempo.

O COP apresenta uma correlação negativa forte com TmGround e TmGrndTop, o que é esperado, considerando que a temperatura do solo influencia a eficiência e o desempenho da bomba de calor. Isto é, temperaturas mais altas do solo tendem a reduzir a eficiência do sistema, refletida na diminuição do COP. Além disso, o COP também exibe uma correlação negativa moderada com QElectTOt,o que é esperado, visto

que maior consumo de energia elétrica está associado a menor eficiência do sistema. Há também correlação negativa com QCold, embora de menor magnitude.

Por fim, as variáveis QCold e QElectTot apresentaram correlações fracas com a temperatura do solo, tanto na superfície quanto no volume de solo das estacas, sugerindo influência limitada desses fatores sobre o consumo de energia para resfriamento. As demais variáveis analisadas apresentaram correlações desprezíveis ou nulas entre si. Vale destacar que a análise se baseia exclusivamente em correlações lineares, o que limita a identificação de possíveis relações não lineares entre as variáveis.

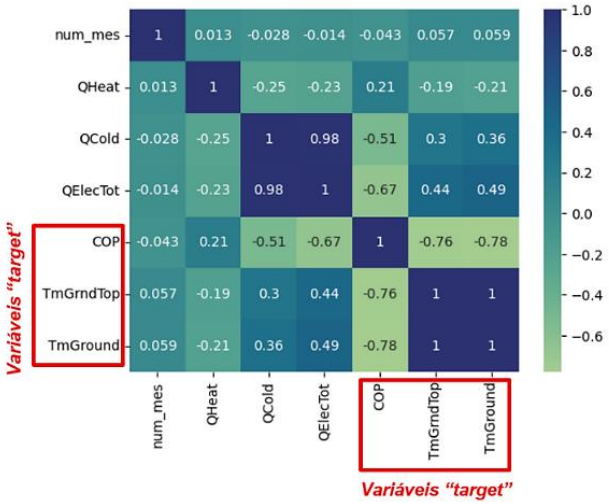


Figura 4. Cálculo das correlações entre as variáveis estudadas.

3.2 Arquitetura do Modelo

A Tabela 2 apresenta um resumo da arquitetura da RNA implementada neste estudo. O modelo é composto por uma camada de entrada, três camadas ocultas densas e uma camada de saída. Cada camada foi configurada com uma quantidade específica de neurônios e funções de ativação distintas, conforme descrito a seguir. A camada de entrada possui um número de neurônios correspondente ao total de variáveis preditoras utilizadas no modelo, a saber, 06 (seis). A primeira e a segunda camadas ocultas empregam a função de ativação tanh, com 16 e 12 neurônios, respectivamente. Já a terceira camada oculta utiliza a função de ativação sigmoid, com oito neurônios. Por fim, a camada de saída é composta por três neurônios com função de ativação linear, adequada para a predição de variáveis contínuas.

Tabela 2. Tabela resumo da arquitetura do modelo.

Camada	Tipo	Número de Neurônios	Função de Ativação
Entrada	Densa	06	-
Oculta 1	Densa	16	tanh
Oculta 2	Densa	12	tanh
Oculta 3	Densa	8	sigmoid
Saída	Densa	3	linear

3.3 Evolução da Função de Perda

Analisando a evolução da função de perda (Figura 5a) - expressa pelo erro quadrático médio (“mean squared error” – MSE) - ao longo das épocas de treinamento e validação da Rede Neural Artificial, observa-

se uma redução progressiva da perda durante o processo de treinamento, refletindo a capacidade do modelo em ajustar seus parâmetros e minimizar o erro preditivo. As curvas correspondentes aos conjuntos de treinamento e validação apresentam trajetórias semelhantes de decaimento, o que é um indicativo de que o modelo está aprendendo os padrões dos dados de forma eficiente, sem sinais evidentes de "overfitting". Essa coerência entre as perdas nos conjuntos de treinamento e validação reforça a estabilidade e a generalização do modelo, aspectos fundamentais para garantir sua aplicabilidade a novos conjuntos de dados.

3.4 Evolução do Erro Absoluto Médio (MAE)

A Figura 5b apresenta a evolução do erro absoluto médio ("mean absolute error" – MAE) ao longo das épocas de treinamento e validação. Essa métrica corresponde à média das diferenças absolutas entre os valores previstos pelo modelo e os valores observados, sendo uma medida direta da precisão das previsões.

Observa-se que os valores de MAE diminuem progressivamente com o avanço das épocas, tanto para o conjunto de treinamento quanto para o de validação. Esse comportamento indica que a rede neural está aprendendo de forma consistente, reduzindo os erros ao longo do tempo e aprimorando sua capacidade de generalização. A trajetória semelhante das curvas também indica possivelmente a ausência de sobreajuste ("overfitting") e sugere um bom equilíbrio entre aprendizado e desempenho preditivo.

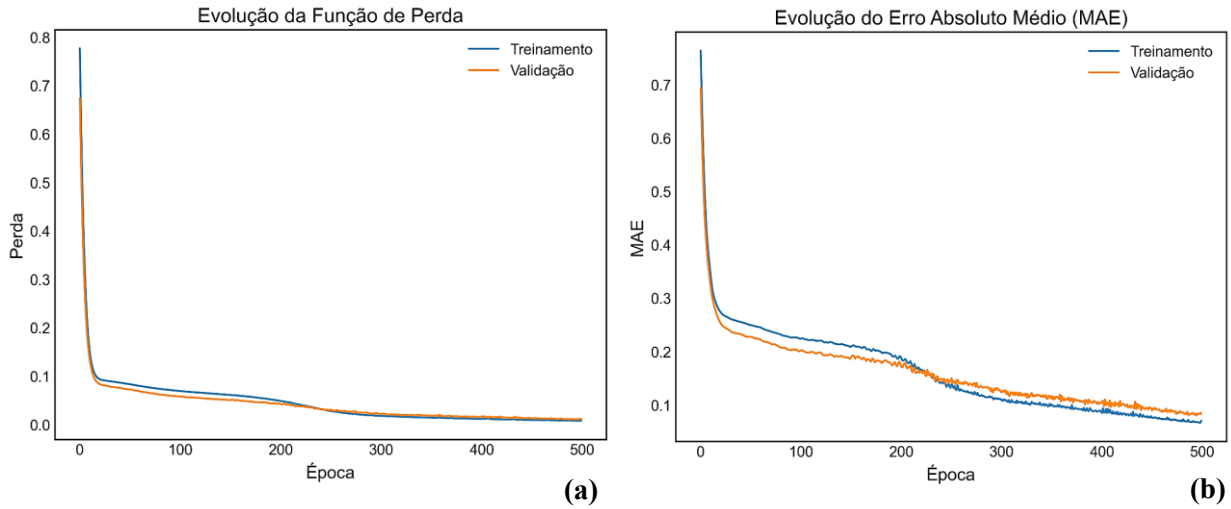


Figura 5. (a) Evolução da Função de Perda e (b) Evolução do erro absoluto médio (MAE).

3.5 Coeficiente de Determinação (R^2)

A Figura 6a apresenta os valores do coeficiente de determinação (R^2) obtidos para cada uma das variáveis dependentes do modelo: COP, TmGrndTop e TmGround. O R^2 representa a proporção da variância total das variáveis-alvo que é explicada pelas predições do modelo, sendo uma métrica amplamente utilizada para avaliar a qualidade do ajuste em modelos de regressão.

Os resultados obtidos indicam que os valores de R^2 se aproximam de um para todas as variáveis preditas, o que sugere que o modelo apresenta elevado poder explicativo. Em outras palavras, a maior parte da variabilidade observada nos dados é capturada pelo modelo, evidenciando sua eficácia na previsão das variáveis de interesse. Esses resultados reforçam o bom desempenho do modelo de rede neural desenvolvido.

3.6 Erro Relativo Médio (MRE)

O erro relativo médio em termos percentuais para cada uma das variáveis "target" pode ser visualizado na Figura 6b. Como o MRE quantifica o erro relativo entre as previsões e os valores reais, deseja-se obter valores menores de MRE, que indicam um erro proporcional menor. Neste caso, o MRE ficou entre 5% e 10%, indicativo de uma boa precisão. Além disso, pode-se notar que o modelo está se comportando de forma semelhante para as variáveis TmGrndTop e TmGround, que tratam da temperatura do solo, e que a previsão é mais simples para a variável COP, com um menor valor de MRE.

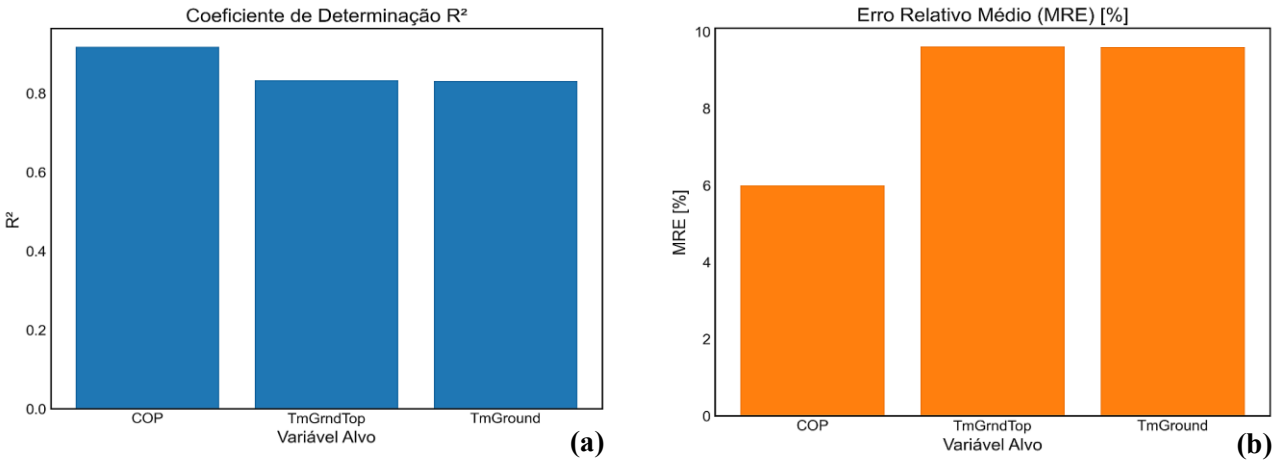


Figura 6. Métricas de avaliação: (a) Coeficiente de determinação (R^2); (b) Erro Relativo Médio (MRE)

3.7 Gráficos de Comparativos entre Valores Reais vs. Previstos

Finalmente, foram elaborados gráficos de dispersão mostrando a relação entre os valores reais e os valores previstos para cada variável "target" (Figura 7). A linha diagonal indica uma previsão ideal (perfeita) em que os valores reais sejam iguais aos previstos. Idealmente, todos os pontos deveriam coincidir com a linha diagonal. Numa situação real, como é o caso, quanto mais próximos os pontos estiverem dessa linha, mais preciso será o modelo. Analisando o gráfico referente ao COP, observa-se uma correlação linear positiva forte, com os pontos distribuídos próximos à linha de tendência. Já no caso do TmGrndTop e do TmGround, há maior dispersão dos pontos. Nesse caso, o modelo de previsão para COP apresentou melhor desempenho do que os modelos para as temperaturas do solo, que mostram maior variabilidade. Com base nas métricas analisadas, de modo geral, é possível concluir que o modelo está performando bem.

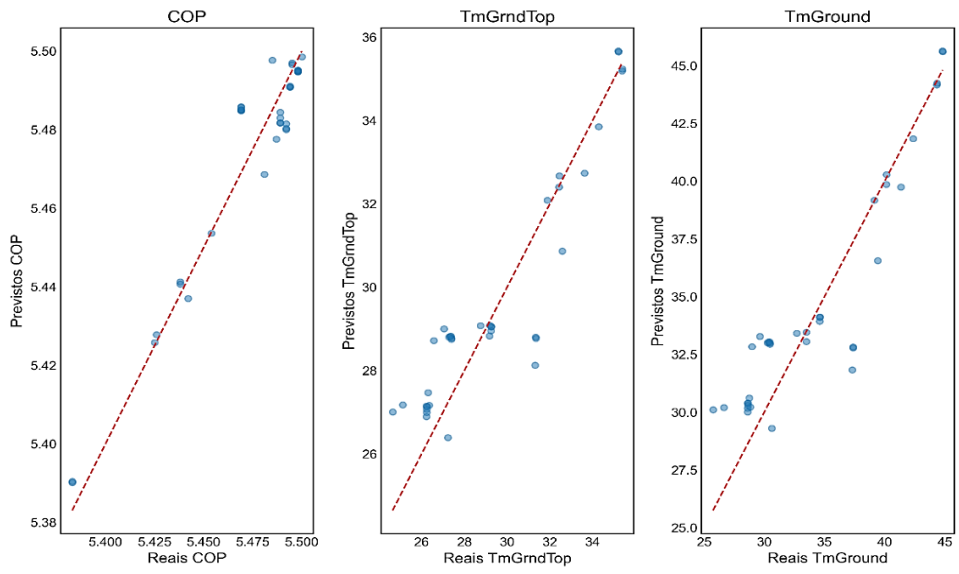


Figura 7. Comparação entre os valores reais e previstos para as variáveis 'target' (COP, TmGrndTop e TmGround).

4 CONSIDERAÇÕES FINAIS

Este trabalho desenvolveu e avaliou um modelo de Rede Neural Artificial para prever parâmetros térmicos em sistemas GSHP acoplados a fundações por estacas trocadoras de calor, utilizando um banco de dados gerado por simulações no "software" PILESIM 2.1.

A análise dos resultados demonstra o bom desempenho geral do modelo. Observou-se uma redução consistente da perda e do MAE ao longo das épocas de treinamento evidenciando o refinamento gradual dos parâmetros do modelo. Já os elevados valores de R^2 e os baixos índices de MRE confirmam a eficácia preditiva para cada variável "target". Os gráficos de dispersão revelam que o modelo apresentou maior precisão na previsão do COP em comparação com as temperaturas do solo, onde se observou maior variabilidade entre valores previstos e reais.

Para trabalhos futuros, recomenda-se ampliar o conjunto de variáveis preditoras, aprimorar a arquitetura da rede neural e adotar técnicas mais avançadas de pré-processamento e seleção de atributos, com o objetivo de aumentar a acurácia do modelo e sua aplicabilidade em contextos reais de engenharia e eficiência energética. Além disso, algumas limitações do estudo atual podem ser abordadas em pesquisas subsequentes, tais como: realizar a divisão do conjunto de dados em treinamento, validação e teste, respeitando a dependência temporal das séries ao invés de utilizar a divisão aleatória dos dados; aplicar "*early stopping*" para determinar automaticamente o número ideal de épocas; e validar o modelo no conjunto de teste.

REFERÊNCIAS BIBLIOGRÁFICAS

Amatya, B. L., Soga, K., Bourne-Webb, P. J., Amis, T., Laloui, L. (2012) Thermo-mechanical behaviour of energy piles. *Géotechnique*, 62 (6), p. 503–519.

Brandl, H. (2006) Energy foundations and other thermo-active ground structures. *Géotechnique*, 56 (2), p. 81–122.

Brownlee, J. (2018) *Deep learning for time series forecasting: predict the future with MLPs, CNNs and LSTMs in Python. Machine learning mystery*. Disponível em: https://www.inf.u-szeged.hu/~korosig/teach/books/Jason%20Brownlee%20-%20Deep%20Learning%20for%20Time%20Series%20Forecasting%20-%20Predict%20the%20Future%20with%20MLPs,%20CNNs%20and%20LSTMs%20in%20Python%20(2018).pdf. Acesso em: 21 de agosto de 2025.

Cybenko, G. (1989) Approximations by superpositions of sigmoidal functions. *Mathematics of Control, Signals, and Systems*, 2 (4), p. 303-314.

Liu, Y.; Mei, X.; Zhang, G.; Cao, Z. 2023. Long-term performance prediction of ground source heat pump system based on co-simulation and artificial neural network. *Journal of Building Engineering*, 79, p. 107949.

Olgun, C. G., Ozudogru, T. Y., Abdelaziz, S. L., Senol, A. (2015) Long-term performance of heat exchanger piles. *Acta Geotechnica*¸10, p.553–569.

Rossum, G. V.; Jr, F. L. D. (1995) Python tutorial. [S.l.: s.n.]: Centrum voor Wiskunde en Informatica Amsterdam, The Netherlands.

Sá, L. M. S., Hernandez Neto, A., Tsuha, C.H.C., Pessin, J., Freitas, M. C., Morais, T.S.O. (2022) Thermal design of energy piles for a hotel building in subtropical climate: a case study in São Paulo, Brazil. *Soils and Rocks*, 45(1), p. 1–14.

Xu, X.; Liu, J., Wang, Y.; Xu, J.; Bao, J. (2020) Performance evaluation of ground source heat pump using linear and nonlinear regressions and artifical neural networks. *Applied Thermal Engineering* 180, p. 115914.

Zhou, S., Li, J., Zhang, Y., Liu, X., Zhang, W. (2021) Prediction of the ground temperature variations caused by the operation of GSHP system with ANN. *Geothermics* 95, p. 102140.

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/COBRAMSEG2026.2/26

Previsão da Velocidade de Onda de Cisalhamento em Argilas Marinhas Utilizando Machine Learning com Dados de SCPT e Bender Element

Gleyce de Souza Baptista, M.Eng
Engª Geotécnica, UTEC-Geoservices, Rio de Janeiro, Brasil, gleycesouzaa@gmail.com

Felipe Bogossian, M.Eng
Engº Geotécnico, UTEC-Geoservices, Rio de Janeiro, Brasil, felipe.bogossian@benthic.com

Mateus Belbuche Paraguassu
Engº Geotécnico, UTEC-Geoservices, Rio de Janeiro, Brasil, mateus.belbuche@benthic.com

Gabriel Viana da Silva
Estagiário, UTEC-Geoservices, Rio de Janeiro, Brasil, gabrielvianads@poli.ufrj.br

Rodrigo Silva Nunes
Geofísico, Petrobras, Rio de Janeiro, Brasil, rodrigosn@petrobras.com.br

RESUMO: A estimativa da velocidade de onda cisalhante (Vs) é essencial para a caracterização geotécnica e sísmica de argilas marinhas e para o suporte a análises e projetos offshore. Este artigo avalia estratégias de previsão de Vs por meio da integração de dados de ensaios in situ (SCPT e CPTu) e de laboratório (Bender Element), com foco em aplicações práticas de engenharia geotécnica. São comparadas uma abordagem física baseada em regressão log–log e um modelo de aprendizado de máquina do tipo Random Forest. Os dados foram pré-processados e organizados em quatro cenários de modelagem, combinando diferentes bases de dados e estratégias preditivas. O desempenho foi avaliado por meio de R^2, RMSE e da comparação de perfis de Vs ao longo da profundidade. Os resultados indicam que o Random Forest apresentou melhor desempenho preditivo global, especialmente com dados de SCPT, enquanto o modelo log–log, embora menos preciso, forneceu relações fisicamente interpretáveis e mostrou maior robustez com a inclusão de dados de Bender Element. A análise dos perfis confirma que modelos de aprendizado de máquina reproduzem melhor as variações locais observadas em campo, enquanto o modelo físico representa adequadamente a tendência global associada ao aumento da tensão efetiva. Os resultados destacam o potencial de abordagens híbridas e a importância da escolha do método e da base de dados conforme o objetivo da aplicação.
PALAVRAS-CHAVE: Velocidade de onda cisalhante; Argilas marinhas; Ensaio sísmico; Ensaio Bender; Aprendizado de máquina;

ABSTRACT: The estimation of shear wave velocity (Vs) is essential for the geotechnical and seismic characterization of marine clays and for supporting offshore engineering analyses and design. This paper evaluates Vs prediction strategies based on the integration of in situ test data (SCPT and CPTu) and laboratory measurements (Bender Element), with emphasis on practical offshore geotechnical applications. A physics-based log–log regression model and a machine learning approach using Random Forest are compared. The data were pre-processed and organized into four modeling scenarios, combining different datasets and predictive strategies. Model performance was assessed using the coefficient of determination (R^2), root mean square error (RMSE), and comparison of Vs profiles with depth. The results indicate that the Random Forest model achieved superior overall predictive performance, particularly when trained exclusively on SCPT data, whereas the log–log model, although less accurate, provided physically interpretable relationships and showed greater robustness when Bender Element data were included. The analysis of Vs profiles confirms that machine learning models better reproduce local field variations, while the physical model adequately represents the global trend associated with increasing effective stress. These findings highlight the potential of hybrid approaches for reliable Vs estimation in offshore environments and

emphasize the importance of selecting the prediction method and dataset according to the intended engineering application.
KEYWORDS: Shear wave velocity; Offshore clays; SCPT; Bender Element; Machine learning;

1 Introdução

A estimativa confiável da velocidade de onda de cisalhamento (Vs) é essencial na caracterização geotécnica de argilas marinhas offshore, devido à sua relação direta com a rigidez do solo em pequenas deformações e sua importância em análises de resposta sísmica e projetos de fundações. Embora ensaios in situ e de laboratório permitam a determinação direta de Vs, sua aplicação pode ser limitada por custos, logística e disponibilidade de dados, motivando o uso de modelos preditivos baseados em correlações empíricas ou técnicas de aprendizado de máquina. Nesse contexto, este estudo avalia a previsão de Vs por meio da integração de dados de ensaios in situ e laboratoriais, comparando um modelo físico do tipo log–log e um modelo de machine learning baseado em Random Forest, com o objetivo de analisar o desempenho preditivo, a coerência geotécnica e a influência da composição da base de dados na estimativa de Vs em ambientes offshore.

2 Base teórica

2.1 Ensaio de CPTU e SCPT

Os ensaios de piezocone (CPT) e de piezocone sísmico (SCPT) são amplamente utilizados em investigações geotécnicas devido à rapidez, repetibilidade e capacidade de fornecer dados quase contínuos do subsolo, sendo apoiados por um arcabouço teórico consolidado (Robertson & Campanella, 1983a, 1983b). A interpretação do CPT baseia-se tradicionalmente em correlações empíricas e semi-teóricas, como os gráficos de tipo de comportamento do solo (SBT) propostos por Robertson (1990), que permanecem amplamente empregados na prática apesar das limitações em representar a complexidade do comportamento real dos solos (Lunne et al., 1997; Mayne, 2007). O *SCPT* estende o *CPT* convencional ao permitir a medição direta da velocidade de onda cisalhante (Vs) e, consequentemente, da rigidez em pequenas deformações, por meio do registro do tempo de propagação de ondas sísmicas geradas na superfície ou no fundo do mar (Robertson et al., 1986). Ao longo dos anos, diversas correlações empíricas foram propostas para estimar Vs a partir de parâmetros do *CPTU*, como aquelas baseadas na resistência de ponta corrigida e no índice de comportamento do solo (Robertson, 2009) ou exclusivamente na resistência de ponta (Long & Donohue, 2010), frequentemente associadas a procedimentos de normalização em função da tensão vertical efetiva para permitir comparações consistentes entre diferentes profundidades (Robertson et al., 1992). Embora essas correlações forneçam estimativas práticas e economicamente viáveis, sua aplicabilidade pode ser limitada fora das faixas de calibração ou em ambientes heterogêneos, motivando o uso de abordagens alternativas, como modelos baseados em aprendizado de máquina, capazes de incorporar múltiplos parâmetros simultaneamente e capturar relações mais complexas nos dados.

2.3 Ensaio de *Bender Element*

O ensaio de *Bender Element* (*BE*) é amplamente utilizado em laboratório para a determinação da velocidade de onda cisalhante e da rigidez do solo em pequenas deformações, constituindo uma ferramenta consolidada na caracterização sísmica de materiais geotécnicos. O método baseia-se na geração e recepção de ondas sísmicas por meio de elementos piezoelétricos instalados no corpo de prova, permitindo medições não destrutivas, de baixo custo e compatíveis com diferentes aparatos laboratoriais, como câmaras triaxiais. Avanços recentes demonstram que a resposta do elemento piezoelétrico é fortemente influenciada pela frequência de excitação, o que possibilita a identificação confiável de ondas de cisalhamento e compressão a partir de um mesmo sistema de ensaio, ampliando a aplicabilidade e a robustez do método (Ferreira et al., 2019).

Os ensaios de *Bender Element* foram realizados como ensaios não destrutivos para a determinação da velocidade de onda cisalhante (Vs) e do módulo de cisalhamento máximo ($G_{máx}$). Os ensaios considerados neste estudo foram executados com reconstituição do estado de tensões, ao final da etapa de adensamento de

corpos de prova em ensaios triaxiais, buscando reproduzir as tensões de campo. A velocidade Vs foi calculada a partir do tempo de propagação da onda de cisalhamento entre elementos piezoelétricos instalados no topo e na base do corpo de prova, conforme a ASTM D8295:2019, e o módulo $G_{máx}$ foi obtido a partir de Vs e da massa específica do solo. Os teores de umidade associados aos ensaios de *Bender Element* foram determinados diretamente nos corpos de prova após a execução dos ensaios.

2.4 *Machine Learning* em Geotecnia

Técnicas de aprendizado de máquina (*machine learning – ML*) têm sido cada vez mais empregadas na engenharia geotécnica para identificar padrões e relações não lineares em bases de dados complexas, especialmente em situações nas quais correlações empíricas tradicionais apresentam desempenho limitado (Goodfellow, 2016). Diferentemente dos modelos empíricos clássicos, que assumem formas funcionais pré-definidas e utilizam um número restrito de variáveis, os modelos de *ML* são ajustados diretamente a partir dos dados observados, permitindo a incorporação simultânea de múltiplos parâmetros geotécnicos (*features*) para a previsão de uma variável de interesse (*rótulo*), como a velocidade de onda cisalhante Vs. O comportamento do modelo é controlado por hiperparâmetros, que regulam sua complexidade e capacidade de generalização, sendo definidos durante a etapa de treinamento (James et al., 2023). Essa abordagem torna o *ML* particularmente adequado para representar relações multivariadas e não lineares, típicas de solos, nos quais diversos fatores atuam de forma interdependente. Entre os algoritmos mais utilizados em aplicações geotécnicas destacam-se o *Random Forest* (*RF*) (James et al., 2023). Esse modelo é baseado em métodos de *ensemble*, apresenta elevada robustez para dados tabulares e boa performance em problemas geotécnicos, como a estimativa do índice NSPT (Fatehnia & Paran, 2025), da resistência não drenada Su (Nguyen et al., 2025) e da velocidade de onda cisalhante Vs. Estudos comparativos recentes demonstram que a escolha do algoritmo influencia diretamente o desempenho preditivo; nesse sentido, Baptista et al. (2025), ao avaliarem oito algoritmos distintos de ML para a previsão de Vs, identificaram o RF como um dos modelos com melhor desempenho, fundamentando sua adoção no presente estudo.

2.3 Modelo físico

A utilização de representações em escala log–log possui base consolidada na engenharia geotécnica como ferramenta para revelar relações físicas fundamentais entre variáveis do solo. Sridharan *et al* (1991) demonstraram que a reescrita das relações entre índice de vazios, volume específico e tensão efetiva em forma logarítmica permite uma interpretação mais clara, estável e confiável do comportamento mecânico dos solos, além de simplificar a estimação de parâmetros-chave, como a pressão de pré-adensamento. Nesse contexto, a linearização de leis de potência por meio de transformações logarítmicas mostrou-se não apenas matematicamente conveniente, mas também fisicamente significativa, preservando a interpretação dos coeficientes associados à compressibilidade e ao estado de tensões. De forma análoga, a velocidade de onda cisalhante (Vs) está diretamente relacionada à rigidez do solo em pequenas deformações e é fortemente influenciada pela tensão vertical efetiva e pelo estado do material, podendo ser descrita por relações do tipo lei de potência. A adoção de um modelo log–log para Vs, portanto, segue uma tradição já estabelecida na geotecnia, na qual transformações logarítmicas são utilizadas para evidenciar relações físicas fundamentais e permitir a estimação robusta de parâmetros com significado mecânico. Neste trabalho, esse modelo log–log é empregado como uma referência física simples e transparente, servindo de base para a comparação com modelos de aprendizado de máquina na previsão de Vs.

3 Materiais e Métodos

3.1 Base de dados

A base de dados deste estudo foi constituída de 68 furos de CPTU, 108 ensaios de Bender Elements realizados em câmara triaxial e 238 ensaios de 11 furos de SCPT. A obtenção destes dados foi realizada a partir de uma campanha geotécnica offshore realizada na costa brasileira, integrando informações de ensaios de campo e de laboratório. Os dados de campo incluem medições de profundidade, peso específico, tensão vertical efetiva e velocidade de onda cisalhante (Vs), obtidas por ensaios sísmicos executados com uma

Perfuratriz portátil de leito marinho operada remotamente (PROD), Figura 1, utilizado também para a recuperação de amostras indeformadas. As amostras foram posteriormente ensaiadas em laboratório, onde se obtiveram medições de umidade e de Vs por meio de ensaios de Bender Element, permitindo a integração entre a representatividade das condições in situ e a caracterização controlada em laboratório. A distribuição de Vs ao longo da profundidade apresentadas na Figura 2, obtida a partir dos ensaios SCPT, Bender Element e correlações baseadas em CPTu, evidencia uma tendência geral de aumento com a profundidade associada ao incremento da tensão vertical efetiva, bem como diferenças sistemáticas entre os métodos de ensaio. As faixas de variação e a dispersão das principais variáveis geotécnicas analisadas, incluindo umidade, profundidade, peso específico, tensão vertical efetiva e Vs, são resumidas por meio de estatísticas descritivas apresentadas na Tabela 1.

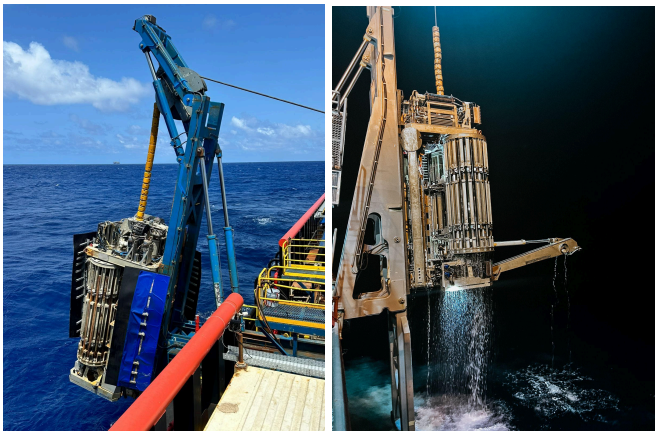


Figura 1. (a) *PROD* sendo preparado para mergulho; (b) *PROD* emergindo após a operação

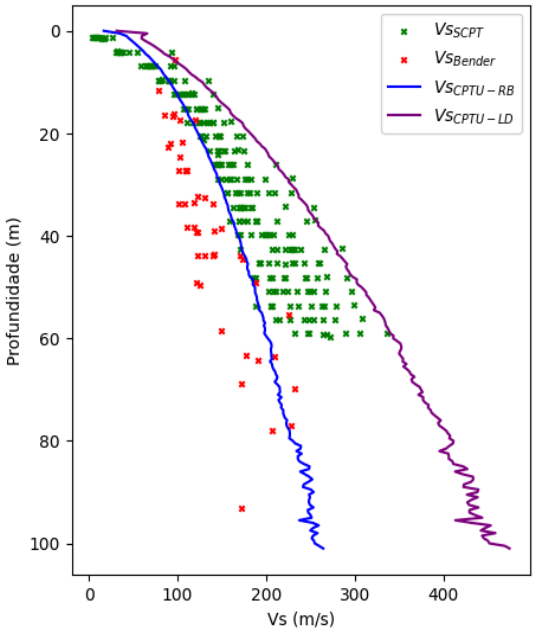


Figura 2. Distribuição da velocidade de onda cisalhante (Vs) em função da profundidade para os dados de SCPT e *Bender Element*.

Tabela 1. Dados estatísticos descritivo do banco de dado

	Bender Element				CPTu		SCPT		
	z(m)	w(%)	Vs(m/s)	γ(kN/m³)	z(m)	σ′v(kPa)	z(m)	Vs(m/s)	σ′v(kPa)
Máx	93.1	83.7	232.3	17.2	100.8	673.1	59.7	336.5	419.5
Média	39.9	64.8	135.9	15.8	30.8	180.0	30.0	167.0	194.6
Min	5.6	35.9	79.0	14.9	0.0	0.0	1.2	4.2	4.6

3.2 Metodologia

3.2.1 Pré-processamento e padronização

A etapa de pré-processamento e padronização dos dados teve como objetivo integrar informações dos ensaios SCPT, Bender Element e CPTu de forma fisicamente consistente para a análise de Vs. Foram adotadas constantes representativas das condições offshore, com a massa específica relativa dos sólidos (Gs) definida conforme a ASTM D854, assumindo argilas de alta plasticidade (CH), típicas de argilas marinhas brasileiras. No SCPT, o peso específico natural foi obtido a partir da massa específica medida, o índice de vazios foi estimado assumindo condição saturada com base na relação clássica entre peso específico e índice de vazios, e o teor de umidade foi calculado por w = e/Gs, sendo descartados valores não físicos; a tensão vertical efetiva foi estimada considerando regime hidrostático. Os dados foram então padronizados para um conjunto comum de variáveis e unificados em um único banco, utilizando-se a Vs medida no SCPT, correlações empíricas de Vs do CPTu propostas por Long e Donohue (2010) eq. 2 e Robertson (2009) eq. 1, e, no caso do Bender Element, valores de umidade medidos em laboratório e Vs obtida em corpos de prova em equipamento triaxial, com reconstituição do estado de tensões de campo.

$$V_{s\,RB} = \left[10^{0.55I_c+1.68} \cdot \left(\frac{q_{net}}{p_a}\right)^{0.5}\right] \quad (1)$$

$$V_{s\,LD} = 2.944 \cdot q_t^{0.613} \quad (2)$$

3.2.2 Modelos utilizados

Foram avaliados dois tipos de modelos para a previsão de Vs: um modelo físico do tipo log–log e um modelo de machine learning baseado em Random Forest. A investigação foi estruturada em quatro cenários, combinando duas estratégias de modelagem com duas composições de dados: utilização exclusiva de dados de campo (SCPT) e utilização de uma base híbrida composta por dados de SCPT e Bender Element. O modelo log–log foi formulado a partir de uma relação de potência entre Vs, a tensão vertical efetiva (σ′v) e o teor de umidade (w), ajustada por regressão linear no espaço logarítmico, sendo adotado como referência física por permitir interpretação direta dos parâmetros. Em paralelo, o modelo Random Forest, baseado em um conjunto de árvores de decisão, foi empregado por sua capacidade de capturar relações não lineares e interações entre variáveis sem impor uma forma funcional pré-definida, sendo aplicado às mesmas bases de dados para permitir uma comparação direta entre abordagens físicas e preditivas, bem como avaliar o impacto da incorporação de ensaios de laboratório com ensaios *in situ*.

3.2.3 Avaliação de desempenho

A avaliação de desempenho dos modelos foi realizada por meio da divisão dos dados em conjuntos de treinamento e teste, adotando-se uma proporção de 80% para treino e 20% para teste, com particionamento aleatório controlado por uma semente fixa para garantir reprodutibilidade e comparabilidade entre os quatro

cenários analisados. O desempenho preditivo foi quantificado utilizando o coeficiente de determinação (R^2) e a raiz do erro quadrático médio (RMSE), calculados separadamente para os conjuntos de treino e teste, sendo o RMSE particularmente relevante do ponto de vista da engenharia por expressar o erro médio na mesma unidade física da Vs. No caso do modelo Random Forest, a arquitetura foi definida por ajuste de hiperparâmetros através de busca em grade.

Além da avaliação quantitativa, foi realizada uma análise qualitativa por meio da comparação de perfis de Vs ao longo da profundidade, confrontando as previsões dos modelos físico log–log e de machine learning, com e sem a inclusão de dados de Bender Element, além das correlações empíricas de previsão de Vs propostas na literatura.

4 Resultados e Discussão

4.1 Desempenho de treinamento dos modelos

A Tabela 2 sintetiza o desempenho dos modelos log–log e Random Forest nos quatro cenários analisados, considerando bases compostas apenas por dados de SCPT e uma base híbrida SCPT + Bender Element. De modo geral, os modelos de machine learning apresentaram melhor desempenho preditivo, com maiores valores de R^2 e menores RMSE em comparação ao modelo físico. No cenário com dados exclusivamente de SCPT, o Random Forest mostrou elevada capacidade de ajuste e boa generalização (R^2 = 0,93 no treino e 0,88 no teste; RMSE = 19,52 m/s e 26,03 m/s), enquanto o modelo log–log apresentou desempenho inferior, porém consistente (R^2 entre 0,83 e 0,86; RMSE da ordem de 29 m/s), mantendo a vantagem da interpretabilidade física. A inclusão de dados de Bender Element resultou em melhora significativa do desempenho do modelo log–log no conjunto de teste, com redução do RMSE e aumento do R^2, indicando calibração mais robusta. Em contraste, para o Random Forest, a base híbrida levou a uma leve redução da performance no teste, possivelmente associada à maior heterogeneidade introduzida pelas diferenças entre dados de campo e de laboratório, apesar do pré-processamento adotado.

Tabela 2. Dados estatísticos descritivo do banco de dados

	Log–log SCPT		Log–log SCPT + BE		ML SCPT		ML SCPT + BE	
	Train	Test	Train	Test	Train	Test	Train	Test
R^2	0.83	0.86	0.69	0.84	0.93	0.88	0.85	0.82
RMSE	29.46	27.79	37.17	30.19	19.52	26.03	25.48	31.80

4.2 Modelos físicos log-log

Os modelos log–log ajustados (eq. 3 e 4) evidenciam comportamentos distintos conforme a base de dados utilizada. O modelo calibrado exclusivamente com dados de SCPT apresenta forte dependência da tensão vertical efetiva e do teor de umidade, refletindo o controle conjunto do estado de tensões e da estrutura natural do solo in situ. Em contraste, o modelo calibrado com a base híbrida SCPT + Bender Element mostra redução significativa da influência da umidade, indicando que a incorporação de dados laboratoriais, obtidos sob condições mais homogêneas e controladas, suaviza a variabilidade associada à estrutura do solo e à heterogeneidade estratigráfica, resultando em um ajuste global mais estável do ponto de vista geotécnico.

$$V_s^{SCPT} = 0.08\,(\sigma'_v)^{0.82} w^{0.81} \quad (3)$$

$$V_s^{SCPT+BE} = 1.79\,(\sigma'_v)^{0.71} w^{0.19} \quad (4)$$

4.3 Comparação dos perfis de Vs com a profundidade

A Figura 3 compara os perfis de velocidade de onda de cisalhamento ao longo da profundidade, incluindo valores medidos em SCPT e Bender Element, previsões dos modelos log–log e Random Forest, bem como correlações empíricas baseadas em CPTu. Observa-se que a Vs medida em SCPT apresenta aumento progressivo com a profundidade, associado ao incremento da tensão vertical efetiva, enquanto as correlações empíricas tendem a superestimar a Vs, especialmente em maiores profundidades. Os modelos log–log reproduzem adequadamente a tendência global do perfil, porém com comportamento suavizado e menor sensibilidade a variações locais, sendo que o modelo calibrado com a base híbrida apresenta melhor aproximação em profundidades intermediárias. Os modelos Random Forest mostram maior aderência aos dados de campo, capturando variações não lineares ao longo do perfil, com melhor concordância quando treinados apenas com dados de SCPT e comportamento mais conservador em maiores profundidades ao incorporar dados de Bender Element. Adicionalmente, a proximidade entre a umidade calculada a partir do CPTu (69,9%) e a umidade medida no ensaio de Bender Element (64,1%) em profundidade equivalente reforça a consistência do pré-processamento adotado e a adequação do teor de umidade como variável explicativa no modelo log–log.

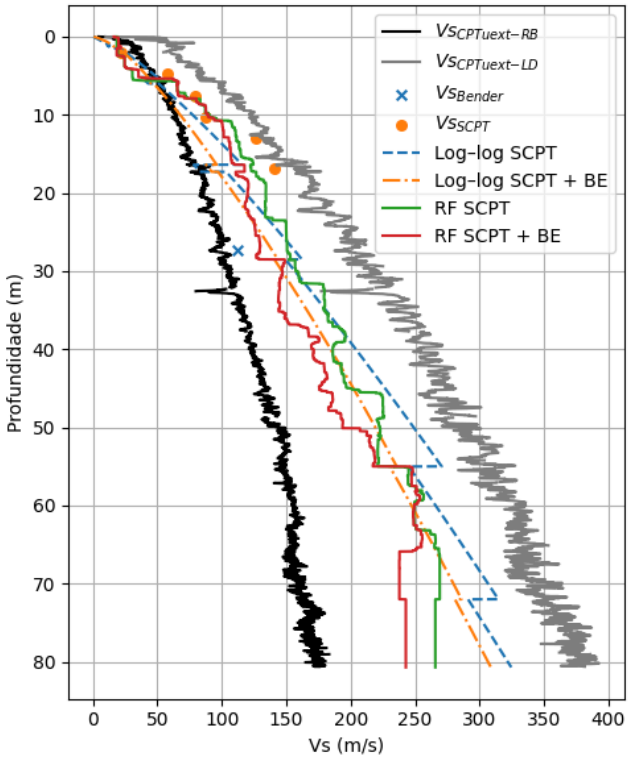


Figura 3. Perfil de solo com os dados de ensaio e as previsões dos modelos

5 Conclusões

Este estudo avaliou a previsão da velocidade de onda de cisalhamento (Vs) em argilas marinhas offshore por meio da integração de ensaios in situ (SCPT e CPTu) e de laboratório (Bender Element), comparando uma abordagem física baseada em modelo log–log com um modelo de machine learning do tipo Random Forest. Os resultados demonstram que o Random Forest apresentou maior desempenho preditivo global, com elevados valores de R^2 e menores RMSE, particularmente quando treinado exclusivamente com dados de SCPT, evidenciando sua capacidade de capturar relações não lineares e variações locais do perfil de Vs. Por outro lado, o modelo log–log, embora menos preciso, mostrou-se consistente do ponto de vista

geotécnico, fornecendo equações fisicamente interpretáveis e desempenho robusto quando calibrado com a base híbrida SCPT + Bender Element.
A análise dos perfis de Vs ao longo da profundidade confirmou que modelos de machine learning reproduzem com maior fidelidade as variações observadas em campo, enquanto o modelo físico representa adequadamente a tendência global associada ao aumento da tensão efetiva. A incorporação de dados laboratoriais mostrou-se benéfica para a calibração de modelos físicos, mas introduziu maior heterogeneidade em modelos puramente preditivos, ressaltando a importância de uma escolha criteriosa da base de dados conforme o objetivo da aplicação. Em conjunto, os resultados indicam que abordagens híbridas, combinando modelos fisicamente interpretáveis e técnicas de machine learning, constituem uma estratégia promissora para a estimativa confiável de Vs em ambientes offshore.

REFERÊNCIAS BIBLIOGRÁFICAS

American Society for Testing and Materials. ASTM D8295-19: *Standard Test Method for Determination of Shear Wave Velocity and Initial Shear Modulus in Soil Specimens using Bender Elements*. West Conshohocken, PA: ASTM International, 2019.

Baptista, G.S.; Silva, L.M.P.; Paraguassu, M.B.; Simões, F.B.; Mello, L.; Viana, A.C.; Macedo, F.; Sieira, A.C. (2025). *Shear wave velocity prediction using machine learning in Brazilian marine clay*. Offshore Technology Conference Brasil, OTC-36249-MS

Camacho-Tauta, J.; Cascante, G.; Santos, J. A.; Viana da Fonseca, A. (2011). M*easurements of shear wave velocity by resonant- column test, bender element test and miniature accelerometers*. 2011 Pan-Am CGS Geotechnical Conference.

Ferreira, C.; Viana da Fonseca, A.; Díaz-Durán, F.; Cascante, G. (2019). *New developments in bender element testing*. Proceedings of the 7th International Conference on Earthquake Geotechnical Engineering (Earthquake Geotechnical Engineering for Protection and Development of Environment and Constructions), Rome, Italy.

Kumar, J.; Shinde, N. S. (2019). *Interpretation of bender element test results using sliding Fourier transform method*. Canadian Geotechnical Journal, 56(12), 1858–1867.

Mayne, P.W.; Rix, G.J. (1995). *Correlations Between Shear Wave Velocity and Cone Tip Resistance in Natural Clays*. Soils and foundations, 35(2), 107–110.

Mayne, P.W. (2014). Interpretation of geotechnical parameters from seismic piezocone tests. Proceedings, 3rd International Symposium on Cone Penetration Testing (CPT'14, Las Vegas), ISSMGE Technical Committee TC 102, Editado por P.K. Robertson e K.I. Cabal, p 47-73.

Robertson, P. K.; Campanella, R. G.; Gillespie, D.; Rice, A. (1986). SEISMIC CPT TO MEASURE IN SITU SHEAR WAVE VELOCITY. Journal of Geotechnical Engineering, 112(8), 791–803.

Sridharan, A.; Abraham, B.M.; Jose, B.T. (1991). I*mproved technique for estimation of preconsolidation pressure*. Géotechnique, 41(2), 263–268.

Taboada, V. M.; Sanchez-Hernandez, Y.; Zhang, Z.; Cruz Roque, D.; Barrera Nabor, P.; Gan, K. C. (2024). *An Application of Machine Learning to Predicting Shear Wave Velocity of Marine Clay.* Offshore Technology Conference (OTC), Houston, TX, USA, 6-9 Maio, OTC-35325-MS, DOI 10.4043/35325-MS.

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/COBRAMSEG2026.2/27

Priorização de Riscos em Pilhas de Mineração: Uma Abordagem Integrada de Estatística e Inteligência Computacional sobre Dados FMEA

Iara Cota Pontes Soares
Engenheira Civil, Universidade Federal de Ouro Preto , Belo Horizonte, Brasil, iara.soares@aluno.ufop.edu.br

Claudia Martins Bhering Dominoni
Engenheira Geotécnica, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, Brasil, claudia.dominoni@aluno.puc-rio.br

Julia Gonçalves Ribeiro
Geóloga, Universidade Federal de Minas Gerais , Belo Horizonte, Brasil, juliagr@ufmg.br

RESUMO: A segurança de estruturas de disposição de rejeitos minerais é crucial para prevenir desastres ambientais e humanos. Este estudo aplica análise estatística multivariada para avaliar riscos em 21 pilhas de estéril e rejeito no Brasil, utilizando dados de FMEA (2023-2024), com o objetivo de identificar padrões entre variáveis como componente estrutural, prioridade de risco e confiabilidade das análises. Os resultados indicam que 93% dos modos de falha apresentam prioridade "Muito Alta" ou "Alta", com destaque para falhas em drenagem superficial (58,82% nos casos críticos). A análise de agrupamentos (K-means) classificou as estruturas em quatro níveis de risco, enquanto a regressão logística ordinal revelou que maior confiança na análise reduz a prioridade de risco. Contudo, 52,18% das avaliações carecem de confiabilidade, atingindo 76% nos riscos mais críticos. Conclui-se que a gestão de riscos deve priorizar a qualidade dos dados e componentes como drenagem e empilhamento.

PALAVRAS-CHAVE: Análise de Riscos, FMEA, Mineração; Pilhas de Rejeito; Análise Estatística; Inteligência Computacional.

ABSTRACT: The safety of mining waste disposal structures is critical to prevent environmental and human disasters. This study applies multivariate statistical analysis to assess risks in 21 waste rock piles in Brazil, using FMEA data (2023-2024), aiming to identify patterns among variables such as structural components, risk priority, and analysis reliability. Results show that 93% of failure modes were classified as "Very High" or "High" priority, with surface drainage failures standing out (58.82% in critical cases). Cluster analysis (K-means) classified the structures into four risk levels, while ordinal logistic regression revealed that higher analysis confidence reduces risk priority (coefficient: −1.7465; $p < 0.001$). However, 52.18% of assessments lacked reliability, reaching 76% for the most critical risks. The study concludes that risk management should prioritize data quality and components such as drainage and stacking systems.

KEYWORDS: Risk Analysis, FMEA, Mining, Waste Rock Pile, Statistical Analysis, Computational Intelligence.

1 INTRODUÇÃO

Os recentes desastres envolvendo barragens de mineração em Minas Gerais, em novembro de 2015 e fevereiro de 2019, levaram o governo brasileiro a impor restrições à construção de novas estruturas, sobretudo àquelas que empregam o método de alteamento a montante. Essa técnica, conforme destacado por Souza (2023), produz materiais com baixa densidade e resistência in situ, além de apresentar maior susceptibilidade a falhas. Diante desse cenário, tornou-se urgente desenvolver alternativas mais seguras, eficientes e sustentáveis para a disposição de rejeitos (CONSOLI et al., 2023).

Com os avanços nas tecnologias de separação sólido/líquido, métodos alternativos, como a disposição de rejeitos filtrados, vêm substituindo progressivamente a disposição hidráulica tradicional em barragens de contenção (SOUZA, 2023). Entre essas soluções, destaca-se o *Dry Stack* (armazenamento em empilhamentos drenados), amplamente adotado por mineradoras no Brasil e em outros setores que lidam com grandes volumes

de resíduos (CONSOLI et al., 2022). Apesar de reduzir significativamente os riscos de rupturas catastróficas, o aumento da escala dessas estruturas geotécnicas exige atenção a desafios relacionados à segurança, aos impactos ambientais e aos efeitos sociais.

Nesse contexto, iniciativas globais, como o *Global Industry Standard on Tailings Management* (GISTM), as diretrizes do *International Council on Mining and Metals* (ICMM) e da *International Commission on Large Dams* (ICOLD) buscam promover práticas de gestão responsável e mitigação de riscos em estruturas de disposição de rejeitos. Em Minas Gerais, o Ministério Público (MPMG, 2021) implementou o projeto Rejeito Zero, com diretrizes técnicas e socioambientais para reforçar a segurança de pilhas de rejeitos. Dentro dessas diretrizes, a análise de risco é um pilar central do Programa de Gestão de Riscos (PGR), visando reduzir incertezas quanto à estabilidade das estruturas. Essa abordagem multidisciplinar envolve a avaliação de probabilidades e consequências de falhas, além da definição de estratégias de mitigação e monitoramento contínuo (MPMG, 2021).

A metodologia semiquantitativa FMEA (*Failure Mode and Effects Analysis*) tornou-se amplamente utilizada nesse contexto por sua aplicabilidade e custo reduzido. No entanto, a análise extensiva de portfólios complexos tem evidenciado uma limitação importante: a tendência de concentração dos resultados nas faixas de risco “Alto” e “Muito Alto”, dificultando a hierarquização e a alocação eficiente de recursos.

Diante disso, este estudo propõe a aplicação de um modelo de avaliação de risco baseado em estatística multivariada e inteligência computacional aplicados a dados FMEA, capaz de identificar e priorizar fatores críticos associados a pilhas de estéreis e rejeitos e compreender o impacto da confiabilidade dos dados na classificação de risco. A relevância da pesquisa reside na geração de subsídios técnicos para otimizar estratégias de mitigação, alinhando-se aos padrões do GISTM, ICMM, ICOLD e regulamentações locais. Assim, busca-se não apenas aprimorar a gestão de riscos no setor mineral, mas também contribuir para a proteção de comunidades e do meio ambiente.

2 MATERIAIS E MÉTODOS

Para a realização deste estudo, foi utilizado um banco de dados contendo avaliações de risco FMEA (Análise de Modo e Efeito de Falha) de 21 estruturas geotécnicas (pilhas de estéril e rejeito) localizadas no Brasil. Vale destacar que as avaliações foram conduzidas por uma equipe multidisciplinar experiente, em conformidade com as diretrizes brasileiras para gestão dessas estruturas. O processo incluiu: identificação e caracterização dos riscos; avaliação de suas consequências e probabilidades e desenvolvimento de estratégias para mitigação e gestão. Para esta análise, focou-se nas seguintes variáveis: localidade (coordenadas geográficas, cidade, estado); componente estrutural avaliada no modo de falha; prioridade do risco; nível de confiança na avaliação.

As variáveis selecionadas e suas classificações são detalhadas na Tabela 1.

Tabela 1. Variáveis analisadas e suas classificações.

Variável	Descrição	Classificação
ID	Identificação do modo de falha para cada estrutura	Nominal
TIPO	- PDE (pilha de estéril) - PDR (pilha de rejeito) ou - PDER (pilha de estéril e rejeito)	Nominal
COORDENADA N/S	Coordenada geográfica Norte/Sul	Nominal
COORDENADA L/O	Coordenada geográfica Leste/Oeste	Nominal
SITE	Localização da estrutura está situada	Nominal
CIDADE	Cidade de localização da estrutura	Nominal

ESTADO	Estado de localização da estrutura	Nominal
COMPONENTE	Componente estrutural avaliada no modo de falha: - Empilhamento - Fundação - Drenagem Interna - Drenagem Superficial - *Sumps*	Nominal
PRIORIDADE DO RISCO	Prioridade atribuída ao risco na avaliação: - Muito Alta - Alta - Média - Baixa	Ordinal
CONFIANÇA	Nível de confiança atribuído à análise - Sim - Não	Nominal

Conforme apresentado na Tabela 1, observa-se que o banco de dados inclui variáveis qualitativas, predominantemente classificadas como nominais. A única exceção é a prioridade do risco, que é classificada como qualitativa ordinal. Com isso, o pré-processamento de dados com as variáveis qualitativas, incluindo variáveis nominais e ordinais, foi realizada através da análise exploratória dos dados a partir dos cálculos de frequências e distribuições.

A Figura 1 ilustra o fluxograma das atividades realizadas durante o estudo. As análises estatísticas foram realizadas no ambiente Jupyter Notebook (Kluyver et al., 2016), utilizando a linguagem de programação Python (Van Rossum & Drake, 2009).

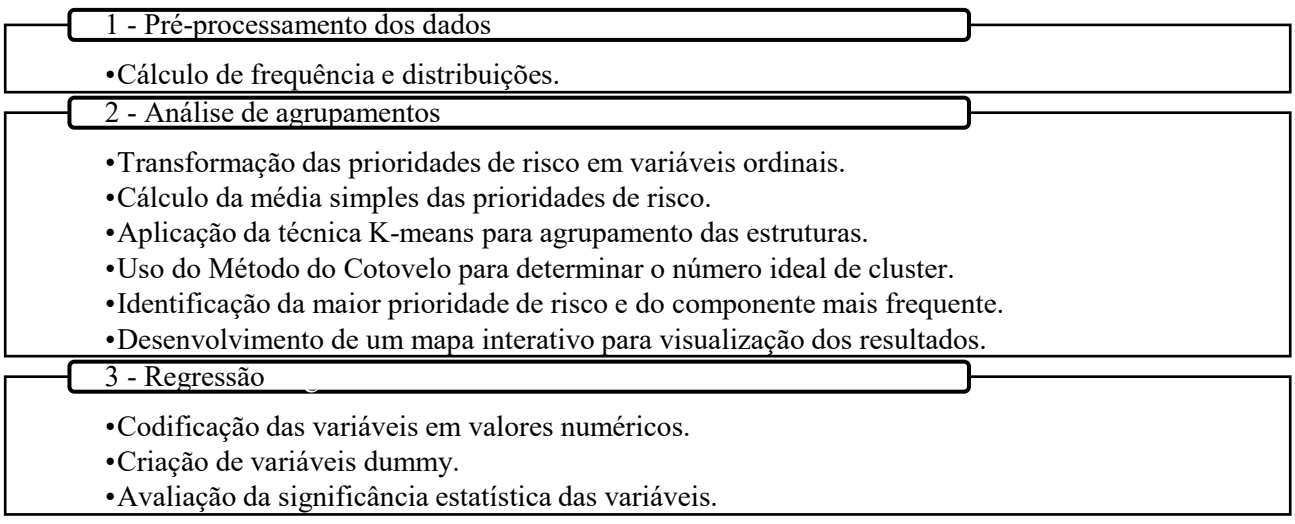


Figura 1. Fluxograma das atividades desenvolvidas.

3 RESULTADOS E DISCUSSÃO

3.1 Pré-Processamento dos Dados

A análise dos dados FMEA (*Failure Mode and Effects Analysis*) revelou que 93% dos modos de falha foram classificados como prioridade "Muito Alta" ou "Alta" (**Erro! Fonte de referência não encontrada.**), indicando um cenário crítico e que reflete a situação atual das estruturas no momento da análise de risco.

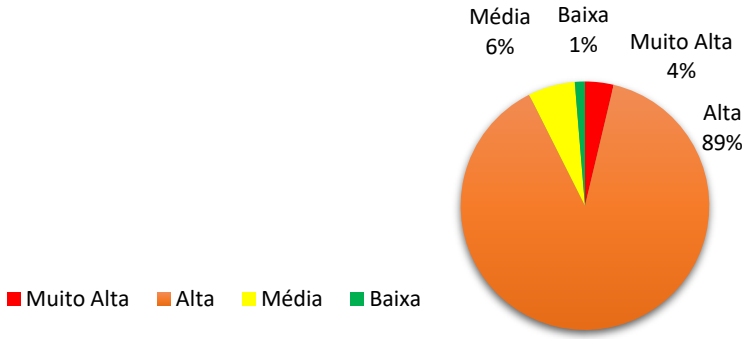


Figura 2. Distribuição da Prioridade do Risco no cenário atual das estruturas.

A distribuição dos modos de falha por componente estrutural mostrou que 43,67% estão associados ao empilhamento, 24,89% à fundação, 22,49% a falhas na drenagem superficial, 4,80% relacionam-se à drenagem interna, 4,15% correspondem a escoamento descontrolado em sumps (dispositivos de contenção de sedimentos).

Entretanto, ao filtrar apenas os modos de falha classificados como "Muito Alta" prioridade, observou-se uma mudança significativa: 58,82% passaram a estar associados à drenagem superficial (Figura 3), destacando-a como o principal fator de risco crítico.

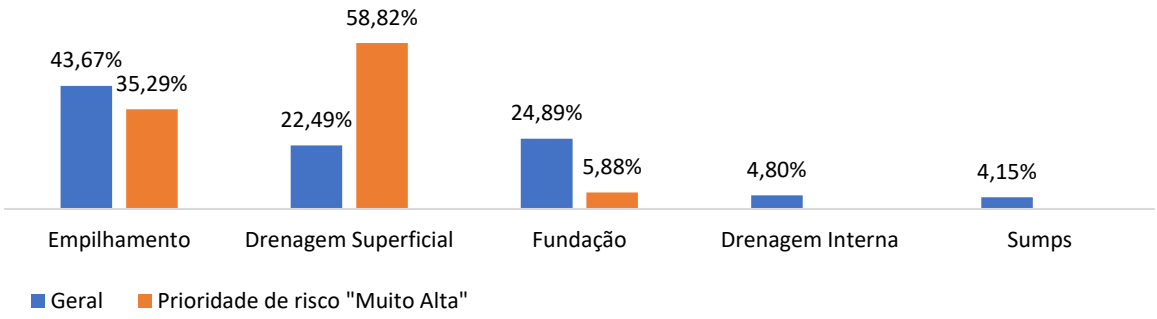


Figura 3. Componentes avaliadas nos modos de falha.

Quanto à confiabilidade das avaliações, 52,18% dos modos de falha não apresentaram níveis satisfatórios de confiança nos dados (Figura 4). Esse problema se intensifica nos casos de prioridade "Muito Alta", onde 76% das análises foram consideradas pouco confiáveis, levantando preocupações sobre a robustez das avaliações de risco para os cenários mais críticos.

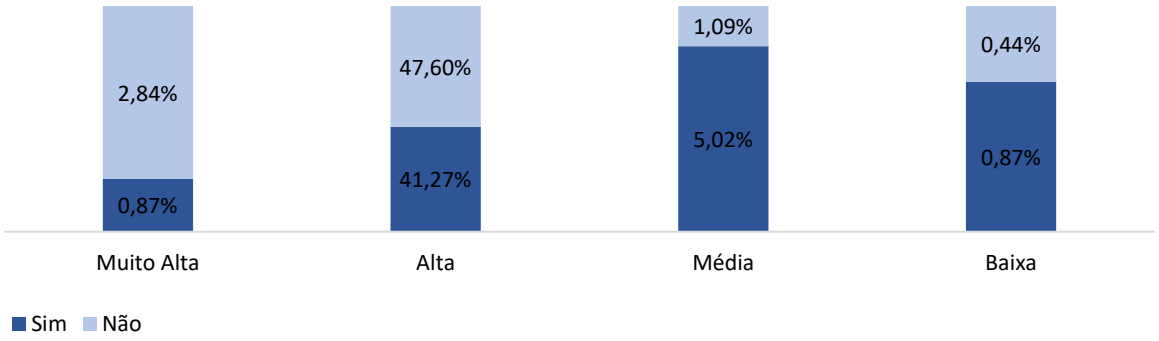


Figura 4. Confiabilidade atribuída nas análises dos modos de falha.

3.2 Análise de Agrupamentos

Para realizar a análise de agrupamentos, foi desenvolvido um código em Python que segue uma abordagem estruturada baseada em técnicas de estatística multivariada para avaliar e classificar os *sites* com base na prioridade de risco residual. Inicialmente, as prioridades de risco foram transformadas em variáveis categóricas ordinais e codificadas em valores numéricos: "Muito Alta" como 4, "Alta" como 3, "Média" como 2 e "Baixa" como 1. A partir dessa codificação, calculou-se a média simples das prioridades para cada site, permitindo uma medida de centralidade que resume a distribuição dos níveis de risco das estruturas avaliadas.

Com base nessas médias, aplicou-se a técnica de *K-means clustering* (distância estatística: euclideana) para agrupar as estruturas avaliadas em quatro clusters distintos, categorizados como “Muto Alta”, "Alta", "Média" e “Baixa”, representando as faixas de prioridade de risco. O método do cotovelo foi utilizado para determinar o número ideal de clusters, avaliando a variância explicada (*WCSS - within-cluster sum of squares*) à medida que o número de clusters aumenta. Esse procedimento justificou a escolha do número de clusters ao identificar o ponto em que adições de clusters não trazem melhorias significativas à segmentação.

Adicionalmente, para cada estrutura, foi identificada a maior prioridade de risco, e dentro dessa categoria, determinou-se o componente mais frequente. Essa abordagem possibilitou a identificação das componentes críticas associadas a cada estrutura, fornecendo uma visão mais detalhada das áreas de maior vulnerabilidade.

Para a visualização dos resultados, foi desenvolvido um mapa interativo, onde cada estrutura é representada por um marcador colorido conforme seu cluster de prioridade de risco e sua componente crítica (**Erro! Fonte de referência não encontrada.**). Com o objetivo de preservar a confidencialidade dos sites e estruturas analisados, a imagem do mapa apresentada não identifica as pilhas estudadas. A *Tabela 2* resume os principais resultados da análise, destacando os agrupamentos obtidos e as componentes críticas de risco associadas a cada estrutura.

Tabela 2. Principais resultados da análise de agrupamentos.

ESTRUTURA	MÉDIA DA PRIORIDADE CODIFICADA	CLUSTER DE PRIORIDADE	COMPONENTE PRIORIDADE
Pilha 1	3,13	0 – Muito Alta	Drenagem Superficial
Pilha 2	3,13	0 – Muito Alta	Empilhamento
Pilha 3	3,04	0 – Muito Alta	Drenagem Superficial
Pilha 4	3,04	0 – Muito Alta	Drenagem Superficial
Pilha 5	3,04	0 – Muito Alta	Empilhamento
Pilha 6	3,00	0 – Muito Alta	Empilhamento
Pilha 7	3,00	0 – Muito Alta	Empilhamento
Pilha 8	3,00	0 – Muito Alta	Drenagem Superficial
Pilha 9	3,00	0 – Muito Alta	Drenagem Superficial
Pilha 10	3,00	0 – Muito Alta	Empilhamento
Pilha 11	2,95	2 - Alta	Empilhamento
Pilha 12	2,95	2 - Alta	Empilhamento
Pilha 13	2,95	2 - Alta	Empilhamento
Pilha 14	2,93	2 - Alta	Empilhamento
Pilha 15	2,91	2 - Alta	Empilhamento
Pilha 16	2,89	2 - Alta	Fundação
Pilha 17	2,89	2 - Alta	Fundação
Pilha 18	2,85	1 – Média	Empilhamento
Pilha 19	2,80	1 – Média	Empilhamento
Pilha 20	2,72	1 – Média	Empilhamento
Pilha 21	2,63	3 - Baixa	Fundação

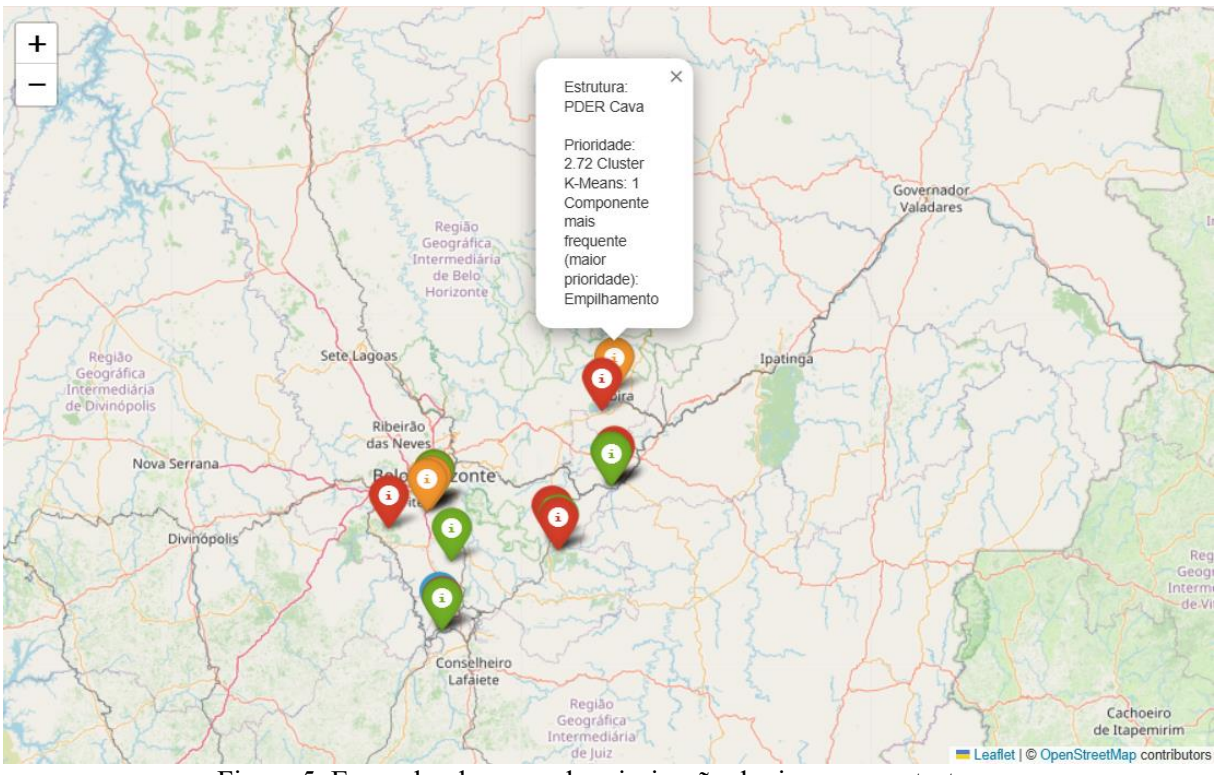


Figura 5. Exemplo do mapa de priorização de riscos por estrutura.

3.3 Regressão Logística Ordinal

Foi utilizada a regressão logística ordinal para modelar a relação entre a prioridade de risco residual e a confiabilidade nas análises, com base nos dados coletados. Inicialmente, os dados foram carregados de uma planilha Excel, e as variáveis categóricas foram codificadas em valores numéricos. A prioridade de risco residual foi transformada em uma variável ordinal, com os seguintes níveis: "Baixa" (1), "Média" (2), "Alta" (3) e "Muito Alta" (4). A variável confiança foi binarizada, onde "Sim" foi codificado como 1 e "Não" como 0.

Utilizando o Python para o desenvolvimento do código, o modelo de regressão logística ordinal foi ajustado utilizando a distribuição logística, com a variável independente sendo a confiança, e a variável dependente sendo a prioridade de risco. O objetivo foi identificar a influência dessa variável qualitativa na determinação da prioridade de risco.

Dados os resultados apresentados na *Tabela 3*, pode-se observar que a variável "Confiança" apresenta um coeficiente negativo (-1,7465), o que indica que, à medida que a confiança nas análises aumenta, a prioridade do risco residual diminui. Como o p-valor é muito baixo (0), essa relação é altamente significativa. O erro padrão relativamente baixo (0,381) sugere que a estimativa é precisa, e o intervalo de confiança não inclui o zero, corroborando a significância dessa variável.

Tabela 3 - Resultados obtidos para a análise da regressão logística ordinal.

Variável	Coeficiente	Erro Padrão	Z	P>|z|	[0.025	0.975]
Confiança	-1,7465	0,381	-4,581	0	-2,494	-0,999

CONCLUSÃO

Os resultados deste estudo evidenciam a importância da aplicação de técnicas estatísticas multivariadas na análise de riscos associados a pilhas de estéril e rejeito, destacando-se como uma ferramenta robusta para a identificação de padrões e relações críticas entre variáveis estruturais e operacionais. A predominância de modos de falha classificados como "Muito Alta" ou "Alta" prioridade (93% dos casos) reforça a urgência de intervenções direcionadas, especialmente nos componentes de empilhamento, fundação e drenagem superficial, que representaram coletivamente mais de 90% das falhas identificadas. A análise revelou ainda que, em cenários de maior criticidade ("Muito Alta" prioridade), a drenagem superficial emerge como o componente mais vulnerável, responsável por 58,82% dos casos, indicando a necessidade de medidas específicas para mitigação nessa área.

A confiabilidade das análises mostrou-se um fator determinante, com 52,18% dos modos de falha apresentando níveis insatisfatórios de confiança nos dados, percentual que se eleva para 76% nos casos de maior prioridade. Essa limitação foi quantificada por meio da regressão logística ordinal, que demonstrou uma relação estatisticamente significativa (p-valor ≈ 0) entre a confiança nas análises e a prioridade do risco residual, com um coeficiente negativo de -1,7465. Esse achado ressalta que a qualidade dos dados é um pilar fundamental para avaliações precisas e para a redução efetiva de incertezas no gerenciamento de riscos.

A aplicação do método K-means clustering permitiu uma segmentação estratificada das estruturas em quatro clusters de risco ("Muito Alta", "Alta", "Média" e "Baixa"), otimizada pelo método do cotovelo. Essa abordagem, combinada com a identificação dos componentes críticos por estrutura, proporcionou uma visualização espacial dos riscos por meio de um mapa interativo, facilitando a priorização de ações e a alocação de recursos. Tal ferramenta demonstra potencial para ser integrada a sistemas de monitoramento contínuo, auxiliando na tomada de decisão em tempo real.

Este estudo contribui para o avanço da gestão de riscos no setor mineral ao propor um modelo analítico replicável, alinhado com as diretrizes do GISTM, ICMM e ICOLD. Os resultados destacam a importância de:

- Fortalecer a coleta e validação de dados para aumentar a confiabilidade das avaliações.
- Priorizar intervenções nos componentes de drenagem superficial e empilhamento, dada sua alta representatividade em cenários críticos.
- Adotar abordagens multivariadas para análises mais abrangentes, capazes de capturar interações complexas entre variáveis.

Como perspectivas futuras, recomenda-se a expansão da base de dados para incluir um maior número de estruturas e variáveis contextualizadas (como características geotécnicas e climáticas), bem como a incorporação de técnicas de aprendizado de máquina para previsão de falhas. Esses avanços poderão aprimorar ainda mais a capacidade preditiva e a eficácia das estratégias de mitigação, promovendo práticas mais seguras e sustentáveis na disposição de rejeitos. Por fim, este trabalho reforça o papel da ciência de dados como aliada na prevenção de desastres, alinhando-se aos objetivos globais de sustentabilidade e segurança na mineração.

REFERÊNCIAS BIBLIOGRÁFICAS

Consoli, N. C.; Vogt, J. C.; Silva, J. P. S.; Chaves, H. M.; Scheuermann Filho, H. C.; Moreira, E. B.; Lotero, A. Behaviour of Compacted Filtered Iron Ore Tailings–Portland Cement Blends: new brazilian trend for tailings disposal by stacking. Applied Sciences, v. 12, n. 2, p. 836, 2022. Disponível em: http://dx.doi.org/10.3390/app12020836. Acesso em: 10 out. 2024.

Consoli, N. C. et al. Evaluation of Strength Parameters for Application in Cemented Iron Ore Tailings Stacks. Indian Geotechnical Journal, 2023. Disponível em: http://doi.org/10.1007/s40098-023-00712-9. Acesso em: 10 out. 2024.

Global Industry Standard on Tailings Management (GISTM). Global Tailings Review. Londres: ICMM; UNEP; PRI, 2020. Disponível em: https://globaltailingsreview.org. Acesso em: 10 out. 2024.

International Council on Mining and Metals (ICMM). Tailings Management: Good practice guide. 2. ed. Londres: ICMM, 2021. Disponível em: https://www.icmm.com. Acesso em: 10 out. 2024.

International Commission on Large Dams (ICOLD). Tailings Dams: Risk of Dangerous Occurrences – Lessons learnt from practical experiences. Paris: ICOLD, 2001. Disponível em: https://www.icold-cigb.org. Acesso em: 10 out. 2024.

Kluyver, Thomas; Ragan-Kelley, Benjamin; Pérez, Fernando; Granger, Brian; Bussonnier, Matthias; Frederic, Jonathan et al. Jupyter Notebooks – a publishing format for reproducible computational workflows. In: LOIZIDES, Fernando; SCHMIDT, Birgit (Eds.). Positioning and Power in Academic Publishing: Players, Agents and Agendas. Amsterdam: IOS Press, 2016. p. 87-90.

SOUZA, Milena Cristina Rocha De; OLIVEIRA, Allan Kewen Câmara De; BEZERRA, Ana Letícia Ramos; VARELA, Gilson Gabriel Teixeira; MENDES, Lara Pereira Tavares. Disposição de rejeito por empilhamento como alternativa para barragens de montante: uma revisão de literatura. In: 6º Congresso Sul-Americano de Resíduos Sólidos e Sustentabilidade – CONRESOL, 2023, Foz do Iguaçu. Anais... Foz do Iguaçu: CONRESOL, 2023. DOI: http://dx.doi.org/10.55449/conresol.6.23.XII-019.

Van Rossum, Guido; Drake, Fred L. Python 3 Reference Manual. Scotts Valley, CA: CreateSpace, 2009.

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/COBRAMSEG2026.2/28

Sistema Web Interativo para Banco de Dados MCT: Ferramenta de Apoio à Caracterização de Solos Tropicais

Larissa Andrade de Aguiar
Docente, Instituto Federal de Brasília (IFB), Coordenação de Construção Civil, Brasília, DF, Brasil, larissa.aguiar@ifb.edu.br

Dênnis Viana Mendes
Programador, DVM, Brasília, Brasil, dvianamendes@gmail.com

João Pedro de Salles Braga
Programador, JPSBTech, Brasília, Brasil, jpsbdbz@gmail.com

Márcia Maria dos Anjos Mascarenha
Docente, Universidade Federal de Goiás (UFG), Departamento de Engenharia Civil e Ambiental, Goiânia, GO, Brasil, marcia.mascarenha@ufg.br

Renato Resende Angelim
Docente, Universidade Federal de Goiás (UFG), Departamento de Engenharia Civil e Ambiental, Goiânia, GO, Brasil, angelim@ufg.br

RESUMO: A metodologia MCT (Miniatura, Compactado, Tropical) é central na caracterização de solos tropicais, mas a dispersão dos dados em múltiplas fontes dificulta aplicações sistemáticas e a identificação de padrões regionais. Este trabalho apresenta o GeoTrop Hub, plataforma web interativa para sistematização, armazenamento e análise de dados MCT, com aplicação inicial na região Centro-Oeste do Brasil. A solução integra padronização classificatória, metadados de procedência e recursos geoespaciais, permitindo inserção validada de registros, busca multicritério (localização, MCT, SUCS, TRB, MCT expedita e G-MCT), exportação de conjuntos filtrados e visualização em mapas interativos. O banco de dados com suporte espacial viabiliza consultas avançadas e integração direta ao módulo cartográfico, favorecendo análises comparativas entre localidades e a identificação qualitativa de padrões na distribuição de tipos de solo. O GeoTrop Hub oferece uma ferramenta moderna para pesquisadores, consultores e órgãos públicos, contribuindo para consolidar conhecimento sobre o comportamento geotécnico de solos tropicais no Centro-Oeste. Como próximos passos, preveem-se testes de usabilidade com usuários externos, incorporação de análises preditivas baseadas em aprendizado de máquina, expansão temática e geográfica do repositório e funcionalidades colaborativas para a comunidade geotécnica nacional.

PALAVRAS-CHAVE: Banco de dados geotécnicos, Geoespacialização, Centro-Oeste

ABSTRACT: Resumo do artigo na língua inglesa seguindo as mesmas regras do RESUMO em português.

KEYWORDS: Palavras chaves em inglês seguindo as mesmas regras da versão em português

1 INTRODUÇÃO

A adequada classificação de solos tropicais constitui etapa fundamental na engenharia geotécnica, especialmente na concepção e execução de obras de infraestrutura rodoviária e fundações superficiais. A relevância desse tema decorre não apenas da ampla ocorrência desses materiais no território brasileiro, mas também das particularidades associadas aos processos intensos de intemperismo químico e laterização, que conferem aos solos tropicais características estruturais e hidromecânicas distintas daquelas observadas em

solos de regiões temperadas. Tais materiais frequentemente apresentam comportamento agregado, elevada influência da sucção matricial e variações significativas de resistência e deformabilidade em função das mudanças no teor de umidade (Fredlund & Rahardjo, 1993; Nogami & Villibor, 1995).

A consolidação de metodologias específicas para solos tropicais representou avanço significativo na engenharia nacional. Nesse contexto, destaca-se a Metodologia de Classificação de Solos Tropicais (MCT), proposta por Nogami e Villibor (1981) e posteriormente sistematizada em trabalhos subsequentes (Cozzolino & Nogami, 1993; Nogami & Villibor, 1995). A MCT foi desenvolvida com o propósito de identificar características estruturais e comportamentais não capturadas de forma adequada por sistemas tradicionais, como o da *American Association of State Highway and Transportation Officials* (AASHTO) e o *Unified Soil Classification System* (USCS). Embora amplamente utilizados em escala internacional, esses sistemas foram concebidos com base predominante em solos de clima temperado, podendo não refletir adequadamente o comportamento típico de solos lateríticos e saprolíticos brasileiros.

Um dos aspectos centrais da metodologia MCT é a consideração indireta de propriedades associadas ao comportamento hidromecânico dos solos tropicais, particularmente aquelas relacionadas à capacidade de suporte, estabilidade estrutural e suscetibilidade à variação volumétrica. A influência do estado não saturado, especialmente da sucção matricial, exerce papel determinante na resistência ao cisalhamento e na rigidez desses materiais (Fredlund & Rahardjo, 1993). Solos lateríticos, em função de sua microestrutura agregada e cimentação natural, podem apresentar desempenho satisfatório mesmo sob condições de umidade elevada, enquanto solos saprolíticos ou pouco laterizados tendem a apresentar redução expressiva de resistência quando submetidos à saturação, podendo manifestar comportamento colapsível (Nogami & Villibor, 1995).

A abrangência territorial dos solos tropicais no Brasil reforça a necessidade de abordagens específicas e sistematização de informações geotécnicas. Levantamentos pedológicos indicam que classes de solos altamente intemperizados ocupam parcela significativa do território nacional (EMBRAPA, 2025), o que amplia o impacto técnico e econômico de decisões associadas à sua caracterização. Nesse cenário, a padronização e integração de dados obtidos por meio da metodologia MCT tornam-se estratégicas para promover comparabilidade entre estudos, reprodutibilidade de resultados e consolidação de conhecimento acumulado.

Entretanto, observa-se que grande parte dos dados geotécnicos produzidos no âmbito acadêmico e profissional permanece dispersa em relatórios técnicos, anais de congressos e bases isoladas. Essa fragmentação dificulta análises regionais integradas, limita a identificação de padrões espaciais e reduz o potencial de utilização de dados históricos para desenvolvimento de análises comparativas e preditivas. A ausência de padronização de metadados — incluindo localização georreferenciada, procedimentos de ensaio, critérios classificatórios e versões normativas — amplia incertezas e impõe retrabalho na consolidação de informações.

Diante desse contexto, o presente artigo apresenta o GeoTrop Hub, um sistema web interativo destinado à sistematização, armazenamento e análise de dados geotécnicos obtidos segundo a metodologia MCT, com aplicação inicial na região Centro-Oeste do Brasil. A proposta enfatiza a integração entre dados geotécnicos e geoespaciais, visando apoiar pesquisa, consultoria técnica e processos de tomada de decisão fundamentados em evidências consolidadas sobre solos tropicais.

2 VISÃO GERAL DO SISTEMA

O GeoTrop Hub é um sistema integrado e inovador, desenvolvido no âmbito de um projeto de pós-doutorado, que tem como missão principal o gerenciamento, a organização e a disponibilização de dados fundamentais sobre a caracterização e o comportamento hidromecânico de solos tropicais. É organizado em um conjunto de abas de navegação intuitivas, cada uma projetada para atender a necessidades específicas e guiar o usuário de forma eficiente através do vasto conteúdo disponibilizado.

Como uma plataforma web interativa, ele disponibiliza:

- inserção padronizada de registros por meio de formulários validados;
- busca multicritério combinando filtros por localização, classes MCT, SUCS e TRB, além de variantes MCT (expedita e G-MCT);
- visualização cartográfica interativa para inspeção e navegação espacial;

- exportação de dados com preservação de metadados.

Em nível conceitual (Figura 1), a arquitetura está organizada em três camadas: apresentação (interface moderna e responsiva), aplicação (APIs e regras de negócio para padronização e validação) e dados (armazenamento relacional com suporte espacial). Os fluxos priorizam usabilidade, padronização e rastreabilidade.

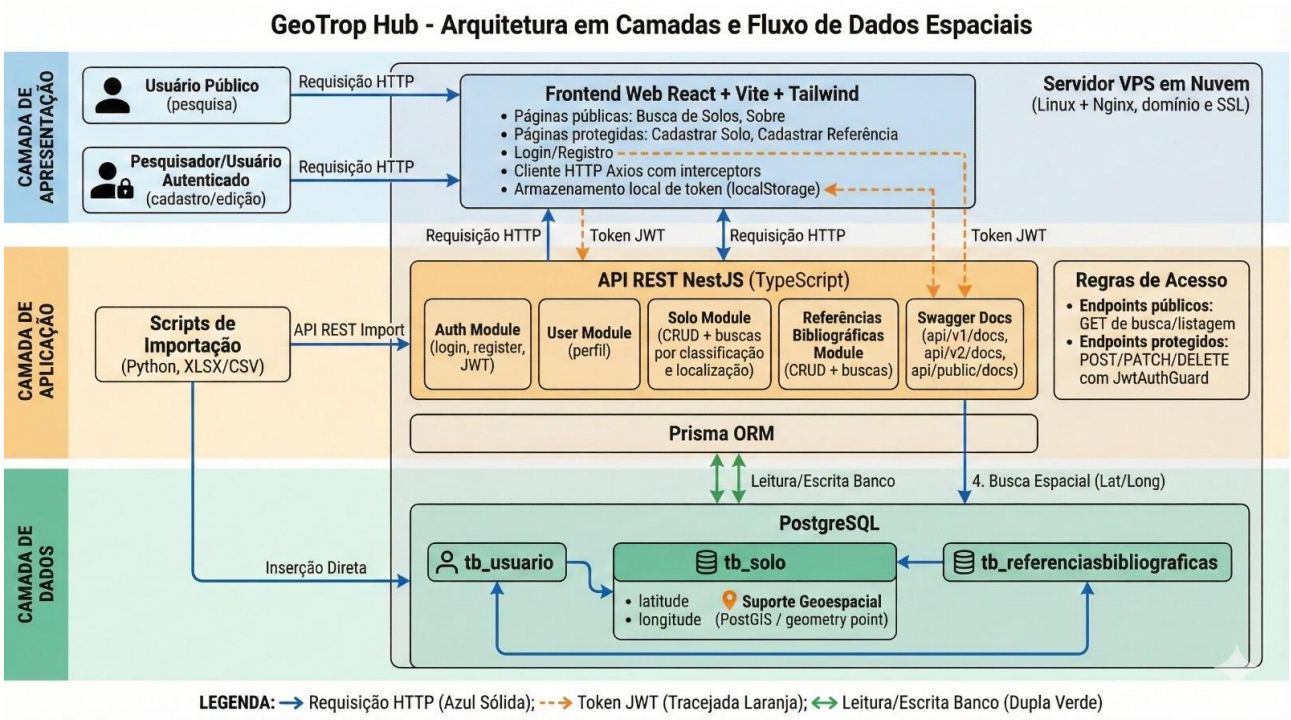


Figura 1 — Visão geral conceitual do sistema (camadas de apresentação, aplicação e dados; fluxo entre usuário, APIs e armazenamento espacial).

2.1 Modelo de dados e padronização

O esquema lógico representa entidades essenciais como amostra, localização, atributos/ensaios, classificações (MCT e correlatas) e fonte. Domínios controlados asseguram consistência de preenchimento, enquanto a camada espacial viabiliza consultas por área, proximidade e interseções temáticas. Metadados registram procedência, datações e anotações curatoriais, favorecendo reuso e auditoria. O modelo é extensível para novas regiões e atributos sem perda de coerência.

2.2 Funcionalidades e fluxos de uso

A Figura 2 apresenta um exemplo da interface do sistema, evidenciando as principais jornadas: (i) cadastro de dados por meio de formulários com validações e campos obrigatórios; (ii) pesquisa e análise por filtros combinados, incluindo inspeção e exploração em mapa; (iii) exportação de subconjuntos filtrados; e (iv) exploração cartográfica temática.

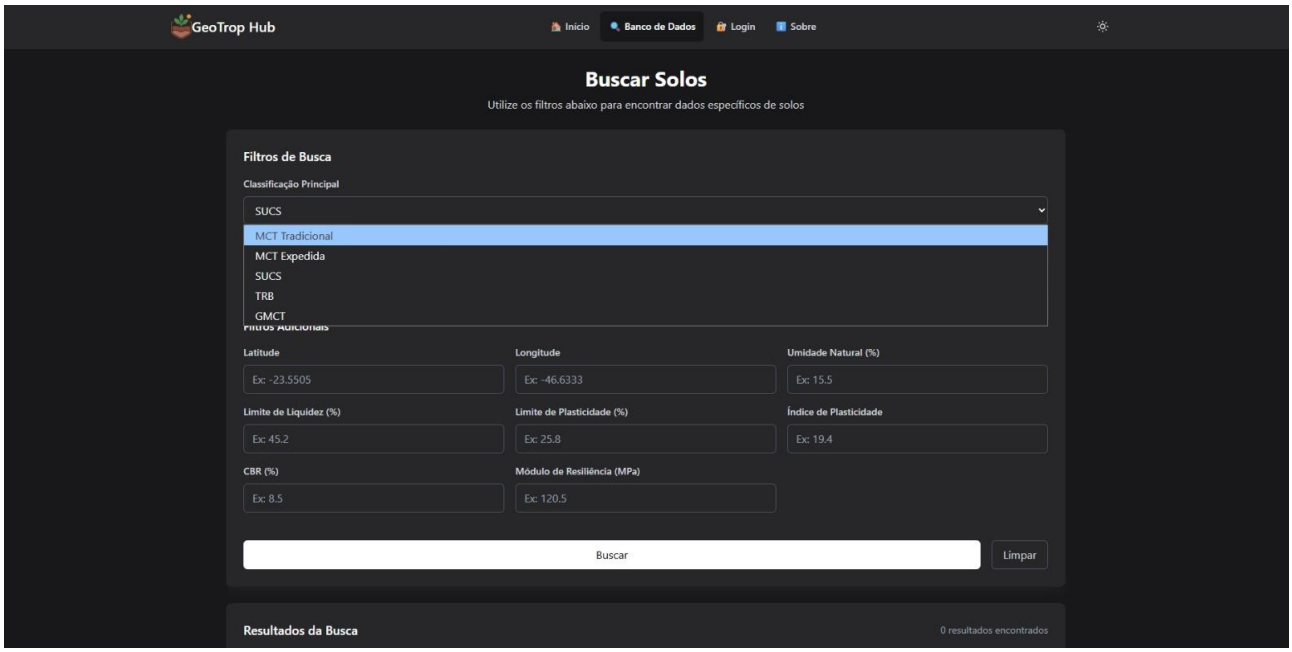


Figura 2 — Exemplo de interface: busca multicritério.

O banco de dados do GeoTrop Hub foi estruturado para armazenar, de forma padronizada e rastreável, informações geotécnicas e geoespaciais associadas a solos tropicais, permitindo consultas integradas por localização e por diferentes sistemas de classificação. Na versão inicial, os registros incluem campos de identificação e procedência (por exemplo, ID do Solo e ID da Fonte), descrição do ponto (Descrição do Local, Estado) e georreferenciamento (Coordenada Geográfica (GD) e Longitude), além de informações de contexto como Jazida/Aterro e Profundidade.

Quanto ao conteúdo técnico, a base contempla múltiplas chaves classificatórias (Classificação, Classificação TRB, Classificação MCT Expedita, Classificação MCT Tradicional e Classificação GMCT) e parâmetros/ensaios organizados por grupos, incluindo MCT (por exemplo, MCT Pastilha, Ensaio MCT Tradicional, Ensaio Mancha), indicadores complementares (Azul de Metileno) e conjuntos voltados à descrição e desempenho (Caracterização, Granulometria com Defloculante, Granulometria sem Defloculante, Comportamento Mecânico e Comportamento Hidráulico). O acesso e a inserção ocorrem via interface web, com validações e campos obrigatórios, reduzindo inconsistências típicas de dados oriundos de fontes heterogêneas e facilitando a comparação entre locais.

Além do uso em pesquisa e consultoria, a organização do banco favorece uma dimensão educacional, ao permitir que estudantes e profissionais relacionem, em um mesmo ambiente, classificações, parâmetros de caracterização/ensaio e distribuição espacial dos registros, apoiando atividades de ensino, treinamento e interpretação de resultados.A aplicação inicial concentra-se na região Centro-Oeste do Brasil, permitindo consolidar dados dispersos, evidenciar padrões espaciais qualitativos e demonstrar o potencial do sistema para consultas exploratórias e suporte à decisão, sem necessidade de métricas nesta fase. Essa definição do escopo inicial do banco e dos parâmetros coletados também estabelece uma base para uma possível evolução, incluindo expansão geográfica e ampliação progressiva do conjunto de atributos e análises.

3 PERSPECTIVAS FUTURAS E CONCLUSÕES

A proposta oferece benefícios práticos e estabelece base para expansão geográfica e acréscimo de capacidades analíticas em versões futuras.

Testes de usabilidade com usuários externos; módulos preditivos (ML) para inferência classificatória; expansão para outras regiões brasileiras; e funcionalidades colaborativas para submissão e revisão de dados com trilhas de auditoria são algumas das possibilidades de ações futuras e melhorias para o sistema.

Espera-se que o resultado deste trabalho possibilite, em pesquisas futuras, a criação de aplicativos que auxiliem no processo de classificação de solos tropicais e otimizem o ensino da metodologia MCT, por meio de banco de dados coletados e retroalimentados pela comunidade acadêmica.

Mais do que um simples repositório de dados, o sistema aspira a ser uma ferramenta dinâmica para ensino, pesquisa e extensão, promovendo a disseminação do conhecimento e incentivando novas investigações. Seu caráter didático e acadêmico visa apoiar estudantes, pesquisadores e profissionais da área na compreensão e aplicação da classificação MCT e em outras análises geotécnicas.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela bolsa de produtividade em pesquisa da coautora M.M.A. Mascarenha (Processo: 304529/2025-7).

REFERÊNCIAS BIBLIOGRÁFICAS

COZZOLINO, V. M. N.; NOGAMI, J. S. Classificação geotécnica MCT para solos tropicais. Solos e Rochas, v. 16, n. 2, p. 77-91, 1993.

EMBRAPA. *Sistema Brasileiro de Classificação de Solos* / Humberto Gonçalves dos Santos … [et al.]. 6. ed., rev. e ampl. − Brasília, DF: Embrapa, 2025.

FREDLUND, D. G.; RAHARDJO, H. *Soil mechanics for unsaturated soils*. New York: John Wiley & Sons, 1993.

NOGAMI, J. S; VILLIBOR, D. F. Uma nova classificação de solos para finalidades rodoviárias. In: Simpósio Brasileiro de Solos Tropicais em Engenharia, 1981. *Anais*... Rio de Janeiro: COPPE/UFRJ, 1981. p. 30-41.

NOGAMI, J. S.; VILLIBOR, D. F. *Pavimentação de baixo custo com solos lateríticos*. São Paulo: Villibor, 1995, 213p.

DOI: 10.47094/COBRAMSEG2026.2/29

Transformação Digital na Mineração: Aplicação da Microsoft Power Platform na Gestão de Projeções Financeiras e Medições de Geotecnia e Geologia

Moises de Araujo Santos Jacinto
Analista Gestão de Contratos, Vale S.A., Parauapebas - PA, Brasil, moises.jacinto@vale.com

Odilaine Teixeira Freitas
Engenheira Especialista, Vale S.A., Itabira - MG, Brasil, odilaine.freitas@vale.com

Bruna da Costa Silva
Engenheira de Planejamento, Concremat, Parauapebas - PA, Brasil, c0702824@vale.com

Fernando Antônio de Oliveira
Analista de Processos, Concremat, Parauapebas - PA, Brasil, c0701387@vale.com

Francisco Stenio Gonçalves Rodrigues
Gerente de contratos Geociências e Sondagem, Vale S.A., Parauapebas - PA, Brasil, francisco.stenio@vale.com

RESUMO: A indústria da mineração vive um ciclo acelerado de Transformação Digital impulsionado pela automação, conectividade, inteligência analítica e plataformas digitais, conforme apontado pela literatura técnica e por organismos internacionais. Nesse contexto, plataformas *low-code* ganham destaque por possibilitarem o desenvolvimento ágil de aplicações corporativas com rastreabilidade, padronização e integração entre áreas. Este estudo apresenta a implantação de um ecossistema baseado na Microsoft Power Platform para gestão de projeções financeiras e medições técnicas na Diretoria de Sondagem e Geociências de uma grande operação de mineração, integrando Power Apps, Power Automate, SharePoint, Forms e Power BI sob diretrizes de ALM, DLP, RBAC e boas práticas de governança.A pesquisa, realizada entre 2024 e 2025, combinou métodos quantitativos e qualitativos e avaliou três versões evolutivas do aplicativo (1.0, 2.0 e 3.1). A versão final apresentou melhorias significativas em desempenho, navegação, padronização de campos, validações técnicas e financeiras e histórico imutável por registro, reduzindo inconsistências e retrabalhos, além de ampliar a auditabilidade. A integração com Power BI proporcionou um pipeline analítico estruturado em camadas RAW, tratada e métricas, permitindo dashboards com indicadores de ciclo, SLA, *throughput*, volumetria e aderência entre valores projetados e executados.Os resultados demonstram maturidade operacional, com tempo médio de medição de 11 dias por administrador e aderência global de 91,49% entre a projeção de 2025 (≈ R$ 1,2 bilhão) e o valor aprovado (≈ R$ 1,067 bilhão). A baixa variabilidade entre administradores evidencia a consolidação do processo após a evolução da plataforma. Elementos como histórico rastreável, controles de permissão e padronização de unidades reforçam conformidade com recomendações nacionais de auscultação geotécnica, garantindo maior consistência para análises e auditorias. O estudo confirma que a Transformação Digital, quando apoiada por governança e arquitetura analítica robusta, aumenta a confiabilidade, transparência e eficiência na gestão contratual e financeira em geotecnia e geologia. A solução demonstra escalabilidade e potencial de replicação, alinhando-se às tendências de *digital geotechnics* e preparando terreno para futuras integrações, como gêmeos digitais e automações avançadas.

PALAVRAS-CHAVE: Transformação Digital; Power Platform; Geotecnia; Mineração.

ABSTRACT: The mining industry is experiencing an accelerated cycle of Digital Transformation driven by automation, connectivity, analytical intelligence, and digital platforms, as highlighted by technical literature and international organizations. In this context, low-code platforms have gained prominence by enabling the rapid development of corporate applications with traceability, standardization, and cross-department integration. This study presents the implementation of an ecosystem based on Microsoft Power Platform for

managing financial projections and technical measurements within the Drilling and Geosciences Directorate of a major mining operation, integrating Power Apps, Power Automate, SharePoint, Forms, and Power BI under ALM, DLP, RBAC, and governance best practices.The research, conducted between 2024 and 2025, employed quantitative and qualitative methods and evaluated three evolutionary versions of the application (1.0, 2.0, and 3.1). The final version achieved significant improvements in performance, navigation, field standardization, technical-financial validations, and immutable historical records, reducing inconsistencies and rework while enhancing auditability. The integration with Power BI enabled the development of a robust analytical pipeline structured in RAW, transformed, and metrics layers, supporting dashboards with indicators such as cycle time, SLA, throughput, volumetrics, and alignment between projected and executed values.
Results demonstrate operational maturity, with an average measurement time of 11 days per administrator and an overall adherence rate of 91.49% between the 2025 projection (≈ BRL 1.2 billion) and the approved amount (≈ BRL 1.067 billion). The low variability between administrators reinforces process consolidation after the platform's evolution. Elements such as traceable history, permission controls, and standardized units align with national recommendations for geotechnical monitoring, ensuring greater consistency for analyses and audits.The study confirms that Digital Transformation, when supported by strong governance and a consistent analytical architecture, enhances reliability, transparency, and efficiency in contractual and financial management in geotechnics and geology. The solution demonstrates scalability and replication potential, aligning with emerging trends in digital geotechnics and paving the way for future integrations such as digital twins and advanced automations.

KEYWORDS: Digital Transformation; Power Platform; Geotechnics; Mining.

1 INTRODUÇÃO

A indústria de mineração atravessa um novo ciclo de inovação, marcado pela convergência entre automação, IA/analytics, conectividade ambígua e plataformas digitais, com evidências de ganhos quando tais iniciativas saem do laboratório e alcançam escala operacional (GLOBAL MINING REVIEW, 2025; WORLD ECONOMIC FORUM, 2023). Esse movimento insere-se no paradigma da Indústria 4.0 e da "mina inteligente", enfatizando workforce digital, plataformas integradas, sensores/IoT e analytics de próxima geração, com benefícios reportados em produtividade, segurança e tomada de decisão desde que acompanhados por governança e interoperabilidade (WORLD ECONOMIC FORUM, 2017; DELOITTE, s.d.). Se no paradigma da Indústria 4.0 e da "mina inteligente", enfatizando workforce digital, plataformas integradas, sensores/IoT e analytics de próxima geração, com benefícios reportados em produtividade, segurança e tomada de decisão desde que acompanhados por governança e interoperabilidade (WORLD ECONOMIC FORUM, 2017; DELOITTE, s.d.).

No plano de tecnologia de aplicação, plataformas low-code têm sido adotadas para acelerar automação e padronização, inclusive em cenários de missão crítica, com destaque para maturidade de recursos de ALM, telemetria, conectores corporativos e controles de segurança; relatórios de mercado registram a Microsoft como líder recorrente no segmento, refletindo a evolução do ecossistema Power Platform (GARTNER, 2024; MICROSOFT, 2024). A documentação oficial da Microsoft descreve diretrizes de Application Lifecycle Management (ALM), segmentação de ambientes, uso de solutions e pipelines, além de políticas de Data Loss Prevention (DLP) e práticas de CoE para equilibrar agilidade e controle (MICROSOFT LEARN, s.d.; MICROSOFTDOCS, 2026).

Em geotecnia e geologia, a digitalização de medições avança com informações conectadas, monitoramento contínuo, ao mesmo tempo em que a literatura técnica aponta desafios de interoperabilidade, qualidade de dados e integração em tempo real, reforçando a necessidade de dados governados, rastreáveis e auditáveis (WANG; TIAN, 2024; WANG; REZAEI; HICKS, 2025). Nesse escopo, Power BI tem sido empregado para consolidar dados geotécnicos e apoiar relatórios interpretativos/dashboards de indicadores, aproximando operação e decisão (FATEHNIA, 2022; NEXACU, 2024).

No Brasil, recomendações técnicas divulgadas em Cobramseg destacam a importância de auscultação confiável, rastreável e com precisão adequada para estruturas de mineração (barragens, cavas, pilhas), convergindo com a necessidade de processos governados e histórico imutável para sustentação das análises e da tomada de decisão (CARDOSO; GIORGINI; DE PAULA, 2022; DE FREITAS; DE FREITAS, 2024).

É nesse contexto que essa pequisa relata a implantação, evolução e resultados de um ecossistema Power Platform na Diretoria de Sondagem e Geociências em uma multinacional, voltado à gestão de projeções financeiras e medições técnicas em Sondagem e Geociências, com governança corporativa (DLP, ALM, RBAC) e integração analítica, contribuindo com evidências empíricas para a literatura setorial e com diretrizes replicáveis para aplicações similares

2 FORMATOS ESPECÍFICOS

2.1 Contextualização

Configura-se como pesquisa aplicada e estudo de caso único, conduzido entre fevereiro/2024 a novembro/2025 no fluxo real de Medições da Diretoria de Sondagem e Geociências em uma multinacional, englobando usuários finais, aprovadores, administradores e dados operacionais processados nas versões 1.0, 2.0 e 3.1 do aplicativo. A abordagem metodológica combinou técnicas quantitativas e qualitativas articuladas a um regime de ALM em Power Platform, com segmentação de ambientes (Desenvolvimento, Homologação/UAT, Produção), versionamento via solutions e pipelines e políticas de DLP e RBAC, conforme diretrizes oficiais (MICROSOFT LEARN, s.d.).

No eixo quantitativo, foram construídos modelos analíticos em Power BI a partir de listas SharePoint (operacionais, parâmetros e histórico), incluindo camada bruta (RAW), camada tratada e tabelas de métricas (ciclo, SLA, throughput e volumetria). Os indicadores foram avaliados por período, fornecedor, contrato e status, com exportações periódicas e agendamentos, bem como análises comparativas entre versões para aferir ganhos de desempenho, redução de inconsistências e eliminação de retrabalho (FATEHNIA, 2022).

No eixo qualitativo, empregaram-se formulários padronizados (críticas, elogios e sugestões) e sessões estruturadas de walkthrough com usuários e aprovadores, além de análises heurísticas de usabilidade. As evidências qualitativas foram trianguladas com os indicadores para alimentar a priorização de backlog pelo comitê multidisciplinar e orientar decisões de interface (navegação em até quatro cliques), padronização de campos e reforço de rastreabilidade (histórico imutável por registro).

Do ponto de vista técnico, adotaram-se boas práticas de desempenho e escalabilidade em Power Apps (delegação, redução de chamadas redundantes e substituição de coleções locais por interação direta com o repositório) e fluxos assíncronos em Power Automate, além de telemetria e trilhas de execução para auditoria. Essas escolhas alinham-se às recomendações de ALM e Governança para plataformas lowcode em ambientes corporativos (MICROSOFT LEARN, s.d.; GARTNER, 2024). Essas escolhas alinham-se às recomendações de ALM e Governança para plataformas low-code em ambientes corporativos (MICROSOFT LEARN, s.d.; GARTNER, 2024).

2.1.1 Ambiente e Ferramentas

- Power Apps: interface, lógica de negócio, validações técnicas-financeiras, navegação e perfis.
- Power Automate: automações, notificações, registros auxiliares e integrações.
- SharePoint: repositório estruturado de listas, parâmetros, anexos e histórico.
- Microsoft Forms: captura padronizada de dados financeiros.

Power BI: modelagem e dashboards de indicadores (ciclo, SLA, *throughput*, volumetria).

O desenho segue recomendações de ALM, DLP e CoE para ambientes controlados e governança ativa (MICROSOFT LEARN, s.d.; MICROSOFTDOCS, 2026).

2.1.2 Desenvolvimento do Aplicativo e Evolução

Linha do tempo (1.0 → 2.0 → 3.1)

- Workflow Medições (1.0) – Prototipagem: registro básico de medições, layout simples, sem integrações externas, lista única no SharePoint e validações mínimas.

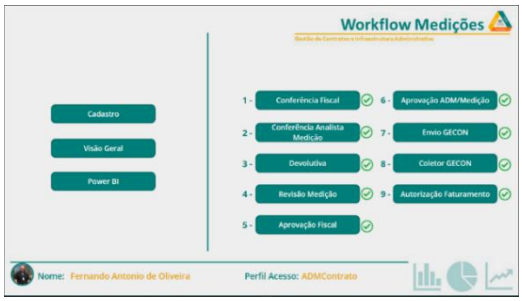


Figura 1. Tela do aplicativo versão 1.0.

- Workflow Medições 2.0 – Primeira revisão estruturada: reformulação de layout; validações técnicas e financeiras; anexos obrigatórios contextuais; primeiros fluxos de automação em Power Automate.



Figura 2. Tela do aplicativo versão 2.0.

- Workflow Medições 3.1 – Salto técnico: navegação reorganizada; histórico completo e imutável por registro; padronização de campos; delegação e otimizações; controles robustos de permissão; integração formal ao Power BI; eliminação de retrabalho por inconsistências; substituição de coleções locais por interação direta com repositório e fluxos assíncronos.



Figura 3. Tela do aplicativo versão 3.1.

2.1.3 Principais funcionalidades (v. 3.1)

- Cadastro estruturado com validações técnicas e financeiras.
- Consolidação automática de valores medidos, glosados e acumulados.
- Regras corporativas (dependência entre etapas, limites, validação cruzada, anexos contextuais).
- Histórico imutável por registro (usuário, data, ação, valores).
- Perfis e permissões (contratos e financeiro).
- Prevenção de erros: duplicidades, conflitos de data, inconsistências e obrigatórios não preenchidos.
- Confidencialidade.

2.1.4 Robustez técnica

- Validação rigorosa de campos críticos.
- Permissões combinadas (SharePoint + lógica de app).

- Padronização de unidades via listas auxiliares.
- Tratamento de nulos/inconsistências com alertas automáticos.
- Arquitetura para escala: delegação, dados operacionais vs. analíticos, fluxos assíncronos. A abordagem está alinhada às boas práticas de ALM/governança para plataformas lowcode (MICROSOFT LEARN, s.d.).

2.1 Integração com Power BI

A integração com o Power BI constitui um dos pilares centrais da solução, pois transforma o fluxo operacional de medições em inteligência acionável para gestão técnica e financeira. O pipeline analítico exporta automaticamente medições, histórico detalhado, parâmetros e listas auxiliares, além de indicadores computados por automação, garantindo atualização programada e contingência manual para dados críticos. A modelagem em camadas RAW, tratada e métricas assegura segurança, versionamento e proteção contra edições manuais, preservando a integridade dos dados mesmo em contextos de alta complexidade operacional.

Essa integração é decisiva porque eleva o processo de medição a um patamar analítico estruturado, permitindo que informações antes dispersas em planilhas, e-mails ou registros isolados passem a compor um ecossistema único, governado e consultável em tempo quase real. Os dashboards derivados desse modelo oferecem visões estratificadas por período, fornecedor, contrato e status, além de análises aprofundadas de ciclo, SLA, *throughput* e volumetria. Com isso, gestores conseguem identificar gargalos, antecipar desvios, comparar desempenhos entre executores e tomar decisões embasadas em evidências reduzindo subjetividades e aumentando a previsibilidade operacional. (FATEHNIA, 2022; NEXACU, 2024).

A importância dessa integração vai além do monitoramento: ela cria um mecanismo contínuo de retroalimentação do processo. As análises fornecidas pelo Power BI orientam melhorias no fluxo, calibram regras internas, aprimoram validações e suportam auditorias, garantindo que ajustes necessários sejam identificados e implementados de forma sistemática. Trata-se, portanto, de um elemento essencial para a maturidade do processo de medições, tornando o sistema mais transparente, auditável e alinhado às melhores práticas de *data governance* e *digital geotechnics* apresentadas na literatura especializada.

3 RESULTADOS E DISCUSSÃO

3.1 Mecanismos causais: do desenho do app ao resultado de negócio

A análise dos indicadores da gestão de contratos e ordens de serviço evidencia um cenário de desempenho consistente, com pontos de estabilidade operacional e oportunidades de aprimoramento no fluxo de medição e execução financeira.

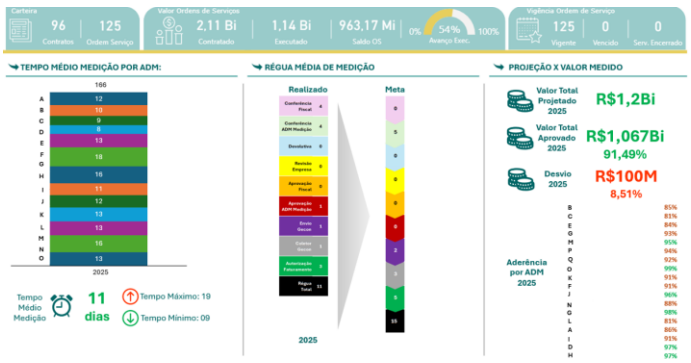


Figura 4. Relatórios Ambiente aplicativo.

- Workflow de Medições 3.1 (salto técnico)
  A navegação reorganizada, a padronização de campos, a delegação de tarefas e os controles robustos de permissões reduziram o esforço cognitivo dos usuários, diminuíram retrabalho e criaram

previsibilidade nas passagens de etapa. O histórico completo e imutável por registro (usuário, data, ação, valores) reforçou a auditabilidade e mitigou contestações, encurtando ciclos de aprovação. A substituição de coleções locais por acesso direto ao repositório corporativo e fluxos assíncronos otimizou a atualização e visualização na tela, ao mesmo tempo em que a integração formal ao Power BI garantiu visibilidade contínua dos indicadores operacionais.

- Funcionalidades críticas (v.3.1).
  O cadastro estruturado com validações técnicas, financeiras e a consolidação automática de valores medidos, glosados e acumulados atuaram como barreiras de qualidade — prevenindo duplicidades, conflitos de data, inconsistências e campos obrigatórios vazios. As regras corporativas (dependências entre etapas, limites, validações cruzadas, anexos contextuais) e os perfis/permissões por papel (contratos e financeiro) elevaram a conformidade e reduziram glosas.
- Robustez técnica e governança
- A arquitetura proposta contemplando escalabilidade com delegação, separação entre dados operacionais e analíticos e uso de fluxos assíncronos está alinhada às boas práticas de ALM e de governança em plataformas low-code, permitindo uma evolução controlada do sistema.
- Além disso, quatro elementos foram fundamentais para garantir a consistência e a confiabilidade dos dados: a validação rigorosa de campos críticos, o modelo combinado de RBAC (SharePoint + regras de negócio), a padronização de unidades por meio de listas auxiliares e o tratamento de valores nulos com alertas automáticos. Esses mecanismos forneceram uma base de dados estável, adequada para medições e projeções futuras.
- Integração analítica (Power BI)
  O pipeline exporta medições, histórico detalhado, parâmetros/listas auxiliares e indicadores computados por automação, com atualização programada e contingência manual para dados críticos. O modelo em camadas (RAW → Tratada → Métricas) preserva segurança, versionamento e proteção contra edições manuais, enquanto os dashboards ampliam a capacidade de gestão (visões por período, fornecedor, contrato e status; análises de ciclo, SLA, throughput e volumetria) (Fatehnia, 2022; Nexacu, 2024).

3.2 Desempenho do processo de medição

O tempo médio de medição por administrador (ADMs anonimizados) foi de 11 dias (mínimo 9, máximo 19). A "régua média" do processo mostrou equilíbrio entre etapas de conferência fiscal, conferência ADM de medição, revisão e aprovações, com autorização de faturamento ao final do ciclo. O histórico imutável por registro e os logs de execução dos fluxos sustentam auditoria e lições aprendidas, contribuindo para o amadurecimento contínuo do processo (WORLD ECONOMIC FORUM, 2017; MICROSOFT LEARN, s.d.).

3.3 Projeções x valores medidos (2025) e aderência

Para 2025, o valor total projetado consolidado foi de ≈ R$ 1,2 bilhão, com valor total aprovado de ≈ R$ 1,067 bilhão, equivalendo a 91,49% de execução frente à projeção e desvio de ≈ R$ 100 milhões (8,51%). A aderência por administradores variou tipicamente entre ~81% e ~97%, com mediana próxima a ~92%, evidenciando baixa variabilidade entre gestores e convergência do processo após a padronização na versão 3.1. Essa consolidação de KPIs críticos (projetado, medido/aprovado, desvio, aderência) respalda a tomada de decisão orçamentária e tática, alinhando-se às recomendações setoriais de analytics e gestão baseada em dados (FATEHNIA, 2022; NEXACU, 2024)

3.4 Importância dos KPIs para decisão e governança corporativa

Os resultados demonstram que a solução integra e orquestra KPIs essenciais ciclo, SLA, *throughput*, aderência, desvios entre projetado e executado, vencimentos e saldo por OS, além de posição de adiantamentos em tempo quase real e com rastreabilidade completa. Em grandes operações de mineração, essa visão unifica finanças e operação, viabilizando priorização dinâmica (ex.: OS >90 dias), mitigações direcionadas (ex.: saldos >30%) e equilíbrio de caixa (ex.: recuperação de adiantamentos). Isso está em linha com a literatura que

posiciona plataformas e analytics como habilitadores de produtividade e transparência quando aliados a governança e escalabilidade (WORLD ECONOMIC FORUM, 2017; 2023; DELOITTE, s.d.).

3.5 Convergência técnico-financeira e lições para geotecnia-financeira e lições para geotecnia

Na cadeia de medições geotécnicas e geológicas, o histórico por registro, a padronização de unidades/serviços e os controles de permissão por perfil diminuem ruídos entre campo, engenharia e finanças, criando lastro de evidências para reconciliações e auditorias. Esse arranjo atende às demandas de auscultação com dados rastreáveis e auditáveis citadas na literatura nacional (COBRAMSEG) e se alinha às tendências de digital geotechnics nas quais dados governados e integráveis formam a base para monitoramento e, futuramente, gêmeos digitais integrados ao processo (WANG; TIAN, 2024; CARDOSO; GIORGINI; DE PAULA, 2022).

3.6 Considerações finais dos resultados

A Transformação Digital na mineração fortalece de forma decisiva a governança financeira ao integrar contratos, medições e custos em um único ecossistema tecnológico. Aplicativos especializados permitem registrar medições de campo com padronização, rastreabilidade e evidências digitais, eliminando divergências entre áreas técnicas, suprimentos e financeiro. A integração entre sistemas viabiliza atualização automática de valores executados, saldo contratual, aditivos e impacto orçamentário em tempo real. Esse fluxo digital reduz discrepâncias, aumenta a acurácia das medições e melhora substancialmente o controle do ciclo de vida dos contratos. Além disso, a digitalização acelera análises de conformidade, suporta auditorias, previne riscos de sobrecustos e fortalece a tomada de decisão com dados estruturados. No conjunto, a Transformação Digital consolida um modelo mais eficiente, transparente e seguro para gestão contratual e financeira aplicada à Geologia e Geotecnia.

4 CONCLUSÃO

A implantação do ecossistema Microsoft Power Platform na gestão de projeções financeiras e medições de geotecnia e geologia demonstrou que soluções low-code, quando associadas a governança robusta (ALM, DLP, RBAC) e arquitetura analítica estruturada, são capazes de gerar ganhos expressivos de padronização, rastreabilidade e eficiência operacional no contexto da mineração. O estudo de caso evidenciou que a evolução do aplicativo da versão 1.0 à 3.1 consolidou um fluxo de trabalho mais confiável, auditável e alinhado às necessidades corporativas, reduzindo inconsistências, eliminando retrabalho e fortalecendo o processo decisório.

Os resultados obtidos, como a média de 91,49% de aderência entre valores projetados e executados e a redução de ciclos por meio de histórico imutável e validações estruturadas, comprovam o impacto direto da digitalização na melhoria do desempenho técnico-financeiro. A integração com Power BI ampliou a visibilidade tática e estratégica, permitindo análises de ciclo, SLA, throughput e volumetria em tempo quase real e subsidiando ações preventivas e corretivas com base em dados confiáveis.

Além disso, o alinhamento do sistema às diretrizes nacionais de auscultação e monitoramento Cobramseg e às tendências internacionais de digital geotechnics reforça o potencial dessas soluções para sustentar futuras camadas de automação avançada e integração com gêmeos digitais. Assim, o estudo demonstra que a Transformação Digital baseada em plataformas integradas não apenas moderniza processos, mas também eleva o nível de governança, segurança e confiabilidade das informações, consolidando um modelo escalável e replicável para operações de mineração que buscam maturidade digital e excelência operacional.

REFERÊNCIAS BIBLIOGRÁFICAS

ACCENTURE. Mining industry digital transformation. [S.l.]: Accenture, 2025. Disponível em: <https://www.accenture.com/us-en/industries/natural-resources/mining>. Acesso em: 11 fev. 2026.

CARDOSO, F. H. C.; GIORGINI, M. G.; DE PAULA, A. Q. Diretrizes para o monitoramento de deformações e deslocamentos em barragens e estruturas de mineração utilizando GNSS. In: COBRAMSEG 2022. [S.l.: s.n.], 2022. Disponível em: <https://proceedings.science/cobramseg-2022/trabalhos/diretrizes-para-o-monitoramento-de-deformacoes-e-deslocamentos-em-barragens-e-es?lang=pt-br>. Acesso em: 11 fev. 2026.

DE FREITAS, I. V. L.; DE FREITAS, G. A. S. C. Revisão metodológica para a análise de monitoramento e instrumentação de barragem de rejeitos de mineração. In: COBRAMSEG 2024. [S.l.: s.n.], 2024. Disponível em: <https://proceedings.science/sites/default/files/callforpapers/fulltext_file/submission-140325-1177130-field_submission_fulltext_file1.pdf>. Acesso em: 11 fev. 2026.

DELOITTE. Digital transformation in mining industry. [S.l.]: Deloitte, s.d. Disponível em: <https://www.deloitte.com/us/en/Industries/energy/perspectives/digital-transformation-mining-industry.html>. Acesso em: 11 fev. 2026.

FATEHNIA, M. Geotechnical data analytics and data mining using Microsoft Power BI. In: Geo-Congress 2022. [S.l.]: ASCE, 2022. Disponível em: <https://www.academia.edu/111179736/Geotechnical_Data_Analytics_and_Data_Mining_Using_Microsoft_Power_BI>. Acesso em: 11 fev. 2026.

GARTNER. Magic Quadrant for Enterprise Low-Code Application Platforms. Stamford, CT: Gartner, 2024. Disponível em: <https://www.gartner.com/en/documents/5844247>. Acesso em: 11 fev. 2026.

GLOBAL MINING REVIEW. McKinsey report highlights technological breakthroughs are creating new tailwinds for innovation in mining and a much-needed boost in productivity. Global Mining Review, 10 dez. 2025. Disponível em: <https://www.globalminingreview.com/mining/10122025/mckinsey-report-highlights-technological-breakthroughs-are-creating-new-tailwinds-for-innovation-in-mining-and-a-much-needed-boost-in-productivity/>. Acesso em: 11 fev. 2026.

MICROSOFT. Microsoft named a Leader in 2024 Gartner® Magic Quadrant™ for Enterprise Low-Code Application Platforms. Redmond, WA: Microsoft, 2024. Disponível em: <https://www.microsoft.com/en-us/power-platform/blog/power-apps/microsoft-named-a-leader-in-2024-gartner-magic-quadrant-for-enterprise-low-code-application-platforms/>. Acesso em: 11 fev. 2026.

MICROSOFTDOCS. Application lifecycle management (ALM) overview – Power Platform. GitHub – MicrosoftDocs/power-platform, 2026. Disponível em: <https://github.com/MicrosoftDocs/power-platform/blob/main/power-platform/alm/overview-alm.md>. Acesso em: 11 fev. 2026.

MICROSOFT LEARN. Application lifecycle management (ALM) with Microsoft Power Platform. Redmond, WA: Microsoft, s.d. Disponível em: <https://learn.microsoft.com/en-us/power-platform/alm/>. Acesso em: 11 fev. 2026.

NEXACU. How is Power BI used in the mining industry? Brisbane: Nexacu, 7 mar. 2024. Disponível em: <https://nexacu.com/insights-blog/how-is-power-bi-used-in-the-mining-industry/>. Acesso em: 11 fev. 2026.

WANG, Y.; TIAN, H.-M. Digital geotechnics: from data-driven site characterisation towards digital transformation and intelligence in geotechnical engineering. Georisk, v. 18, n. 1, p. 8–32, 2024. Disponível em: <https://www.tandfonline.com/doi/pdf/10.1080/17499518.2023.2278136>. Acesso em: 11 fev. 2026.

WANG, Y.; REZAEI, A.; HICKS, S. Digital twin applications in geotechnical engineering: a systematic review. Machine Learning and Applications in Geotechnical Engineering (Emerald), v. 1, n. 1, p. 78–102, 2025. Disponível em: <https://www.emerald.com/mlag/article-pdf/1/1/78/10277430/mlag-02-2025-0005en.pdf>. Acesso em: 11 fev. 2026.

WORLD ECONOMIC FORUM. Mining and metals: trends, challenges and the way forward. Cologny/Geneva: World Economic Forum, 2023. Disponível em: <https://www.weforum.org/publications/mining-and-metals-trends-challenges-and-the-way-forward/>. Acesso em: 11 fev. 2026.

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/COBRAMSEG2026.2/30

USO DE ANN PARA PREDIÇÃO DE MÓDULO DE RESILIÊNCIA

Pedro Luís da Costa Júnior
Estudante, FEB-UNESP, Guaratinguetá, Brasil, pedro.jr@unesp.br

Prof. Dr. Gabriel Orquizas Mattielo Pedroso
Professor, FEG-UNESP, Guaratinguetá, Brasil, gabriel.pedroso@unesp.br

RESUMO
Na área da geotecnia, especialmente no ramo de pavimentação, reconhece-se a importância de estimar e determinar adequadamente os parâmetros dos solos. Nesse contexto, a aplicação de técnicas de inteligência artificial (IA) tem se mostrado uma ferramenta fundamental, uma vez que, por meio de métodos preditivos, é possível realizar estudos preliminares voltados à avaliação de alternativas de projeto e de seus respectivos parâmetros. O objetivo deste trabalho é predizer o MR (módulo de resiliência) de diferentes solos da classificação MCT (Miniatura, Compactado, Tropical), considerando as condições da variação de umidade pós compactação dos materiais. Diante disso, optou-se pela utilização da IA para estimar esse parâmetro, tendo em vista que a quantidade de experimentos disponíveis é insuficiente para a obtenção de médias representativas e de intervalos de confiança adequados, que assegurem maior precisão e confiabilidade no dimensionamento das camadas do pavimento. Ressalta-se que, com o emprego da inteligência artificial, torna-se possível a realização de um número praticamente ilimitado de simulações, ampliando significativamente o potencial de análise. A aplicação de técnicas de IA, por meio de métodos de aprendizado de máquina, possibilita a estimativa de valores a partir de variáveis de entrada, permitindo, assim, a previsão do módulo de resiliência com base em um banco de dados constituído por resultados experimentais de solos brasileiros. Esse banco de dados contempla todos os tipos de solos classificados segundo o sistema MCT, o que permite a previsão do módulo de resiliência para qualquer solo enquadrado nessa classificação. Atualmente, o banco contém mais de 3.000 registros, distribuídos em diferentes categorias. Cabe ressaltar que, em função da correlação entre algumas variáveis, o número de categorias consideradas foi reduzido, visando à obtenção de um modelo mais otimizado e preciso. As técnicas de previsão empregadas neste estudo incluem as Redes Neurais Artificiais (ANN). Para a avaliação do melhor otimizador da ANN, definiu-se o número de épocas em 200, analisando-se o coeficiente de determinação (R^2) obtido. O otimizador que apresentou melhor desempenho foi o ADAM (Adaptive Moment Estimation), com taxa de aprendizado de 0,0005 e $R^2 = 0,97$. Com esse desempenho, o valor previsto de MR foi de 54,45 MPa, enquanto o valor correspondente na base de dados, para as mesmas variáveis de entrada, foi de 57,83 MPa, resultando em um coeficiente de variação relativo de 5,84% e um erro absoluto de 3,38 MPa.

PALAVRAS-CHAVE: Módulo resiliente; Sucção; Solos não saturados; Inteligência artificial; Técnicas de previsão.

ABSTRACT
In the field of geotechnics, especially in the area of pavement engineering, the importance of accurately estimating and determining soil parameters is recognized. In this context, the application of artificial intelligence (AI) techniques has proven to be a fundamental tool, since, through predictive methods, it is possible to carry out preliminary studies aimed at evaluating design alternatives and their respective parameters. The objective of this work is to predict the MR (resilience modulus) of different soils from the MCT (Miniature, Compacted, Tropical) classification, considering the conditions of post-compaction moisture variation of the materials. Therefore, AI was chosen to estimate this parameter, given that the number of available experiments is insufficient to obtain representative averages and adequate confidence intervals that ensure greater precision and reliability in the design of pavement layers. It should be noted that, with the use of artificial intelligence, it becomes possible to carry out a virtually unlimited number of simulations, significantly expanding the potential for analysis. The application of AI techniques, through machine learning methods, enables the estimation of values from input variables, thus allowing the prediction of the resilience

modulus based on a database consisting of experimental results from Brazilian soils. This database includes all types of soils classified according to the MCT system, which allows the prediction of the resilience modulus for any soil within this classification. Currently, the database contains more than 3,000 records, distributed across different categories. It should be noted that, due to the correlation between some variables, the number of categories considered was reduced, aiming to obtain a more optimized and precise model. The prediction techniques employed in this study include Artificial Neural Nets (ANN). To evaluate the best ANN optimizer, the number of epochs was set to 200, and the coefficient of determination (R^2) obtained was analyzed. The optimizer that has the best perfomance was ADAM(Adaptive Moment Estimation), with a learning rate of 0.0005 and $R^2 = 0.97$. Therefore, the previus resilient modulus was 54.45 MPa, although the real one in database, for the same input, was 57.83 Mpa, resulting in a relative variation coeficcient of 5.84% and an absolute error of 3.38 MPa.

KEYWORDS: Resilient modulus; Suction; Non satured soils; Artificial intelligence; Forecasting techniques.

1 INTRODUÇÃO

No campo da Engenharia Civil, especificamente na área da Geotecnia, o estudo dos solos é de suma importância para o conhecimento de suas propriedades, diversidades e possíveis aplicações, desse modo, deve-se garantir que seja realizado corretamente, conforme as normas e com o nível técnico mínimo esperado. (Dos Santos *et al*., 2019 e Lima *et al*, 2018).

Nesse sentido, os solos brasileiros apresentam certa peculiaridade, por se tratarem de solos tropicais, devido aos processos geológicos e pedológicos típicos dessas regiões. Difunde, oriunda dessa característica, a classificação MCT (Miniatura, Compactado, Tropical) a fim de dividir os solos tropicais em lateríticos e saprolíticos (Nogami & Villbor, 1995 e De Freitas *et al*., 2020).

Além dessa diversidade na gênese dos solos da região entre os trópicos, outro assunto também pode ser abordado referente a eles, o fato de serem, em sua grande maioria, não saturados. Isso implica que o solo será constituído por três fases: líquida, sólida e gasosa; diferentemente do solo saturado que conta apenas com as duas primeiras, sendo considerado que seus vazios estão preenchidos inteiramente por água (Fredlund, D. G. & Morgenstern, N. R., 1977; Fredlund, D. G. & Rahardjo H., 1993; Yang *et al*., 2008; Dos Santos *et al*., 2019; Liang *et al*., 2008 e Han *et al*.; 2016).

Ainda no cerne dos solos não saturados, é imprescindível comentar que o estudo da sucção acompanha o entendimento e a aplicação destes. A sucção é dividida em osmótica e matricial, sendo a total a soma das duas, a primeira é referente a diferença de concentração de solutos da água presente no solo, já a segunda, a capilaridade e adsorção da matriz do solo. A fim de estudar a sucção de dado solo é feita a curva de retenção por meio dos ensaios específicos, um exemplo é a técnica da placa de pressão (Fredlund, D. G.; Rahardjo H. & Fredlund, M. D., 2012; Abu-Farsakh *et al*., 2015; Leong *et al*., 1997; Yang *et al*., 2008; Dos Santos *et al*., 2019 e De Freitas *et al*., 2020).

Da mesma maneira, em relação à aplicação de estradas, são feitos os ensaios de ISC (Índice de Suporte California) e MR (Módulo Resiliente) com o intuito de entender o comportamento do solo frente ao carregamento, que é simulado, de forma estática no primeiro e, dinâmica no segundo. Esses ensaios são essenciais para a garantia de qualidade técnica e construtiva das estradas, a fim de verificar a adequabilidade do solo para esta função (DNIT 172, 2016; DNIT 134, 2018; Yang *et al.*, 2008; Heidabaradizadeh *et al*., 2021 e Dos Santos *et al*., 2019).

Devido a carência de ensaios de MR, por conta da dificuldade de realização e encarecimento do processo, influenciando no custo total da obra, é encorajado que haja outras maneiras de simular ou estimar o módulo de resiliência para que seja possível garantir a qualidade dos serviços de engenharia realizados em solos tropicais não saturados, comumente encontrados no Brasil, país objeto do projeto de pesquisa em questão. Dada essa problemática há inúmeras tentativas de formulações ou predições do MR. (Abu-Farsakh *et al*., 2015; Khawaja *et al.*, 2024; Salour *et al*., 2014; Yang *et al.*, 2008 e Heidabaradizadeh *et al*., 2021).

Nesse mesmo contexto, é ainda mais difícil e incomum a realização de ensaios MR para solos não saturados, por contarem com a sucção, característica dos solos não saturados que influência fortemente na magnitude do módulo resiliente, o que dificulta e muito a sua aplicação prática, dado que os solos brasileiros necessitam dessa abordagem por serem não saturados em sua grande maioria, estando principalmente divididos

em saprolíticos e lateríticos, é interessante buscar outras práticas de estimar esse parâmetro para essa condição diferente da usual (Abu-Farsakh *et al.*, 2015; Zhang *et al.*, 2021; Yao *et al.* 2018; Salour *et al.*, 2014 e Blackmore *et al.*, 2020).

Para solucionar essa problemática, a IA nos possibilita a realização de inúmeras medições e predições, por meio das técnicas preditivas, das quais vale ressaltar as redes neurais artificiais (ANN), que por simularem o sistema nervoso humano, utiliza neurônios e ligações entre as camadas, por meio de pesos para no fim predizerem um valor ou outra situação na camada de saída. No entanto, é interessante citar que não são as únicas formas de predizer, há também algoritmo genético, redes híbridas, entre outras. (Zhang *et al.*, 2021; Salour & Erlingsson, 2015 e Salour *et al.*, 2014).

Sendo assim, o presente estudo tem como objetivo principal estimar o comportamento dos solos não saturados brasileiros quanto ao MR, levando em consideração os dados de entrada baseado em uma banco de dados. Essa predição será realizada por meio de ANNs.

Ao passo que o objetivo secundário é analisar as variações presentes dos fatores de desempenho individualmente para encontrar o melhor modelo para cada técnica usada na pesquisa. Para a realização dessa avaliação serão realizados os seguintes fatores de desempenho: MAE (Mean Absolute Error), MAPE (*Mean Absolute Percentage Error*), R^2 (Coeficiente de Determinação), RMSE (*Root Mean Squared Error*) e MSE (*Mean Squared Error*).

2 MATERIAIS E MÉTODOS

A Figura 1, que será apresentada em sequência, ilustra a metodologia utilizada por meio de um fluxograma, dividindo-a em 2 grandes partes, obtenção de dados de literatura e processamento; função de pedotransferência e modelagem com *machine learning*.

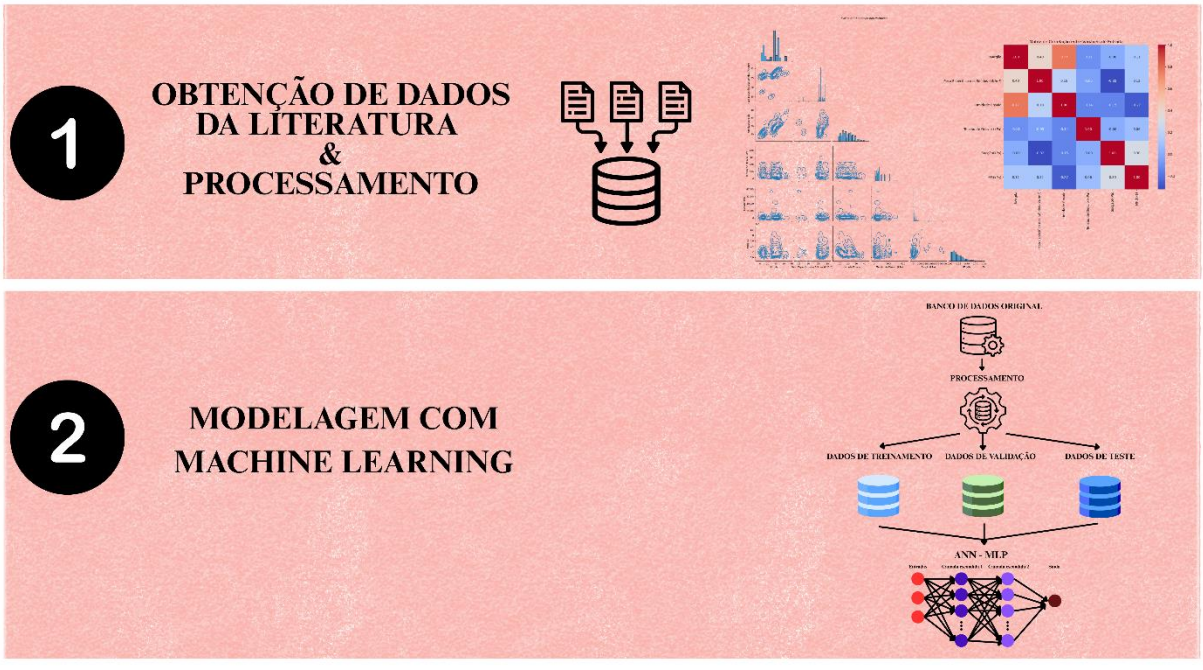


Figura 1. Fluxograma da metodologia utilizada, 2026.

2.1 Obtenção de dados de literatura e processamento

A obtenção de dados pela literatura levou em consideração teses, dissertações e artigos que contivessem resultados de ensaios de módulo resiliência com a maioria dos seguintes parâmetros numéricos: porcentagem de argila, porcentagem de areia, porcentagem de silte, limite de liquidez (LL), limite de plasticidade (LP), índice de plasticidade (IP), peso específico dos sólidos (Ysólidos), umidade de compactação (Wcompactação), umidade de ensaio (Wensaio), peso específico seco máximo (pdmáx), tensão de desvio (σ_{desvio}), tensão de confinamento ($\sigma_{confinamento}$), sucção e módulo resiliência; e os parâmetros categóricos: classificação TRB

(*Transportation Research Board*), classificação MCT, classificação SUCS (Sistema Unificado de Classificação de Solos) e energia de compactação. O banco de dados conta com mais de 3000 registros até o presente momento.

O processamento consiste em trabalhar os dados, de modo que sejam descartados ou reavaliados de modo que o banco de dados inicial passe por um filtro para a posteriori ser realizada a modelagem, uma seção do processamento pode ser demonstrada subsequentemente na Figura 2.

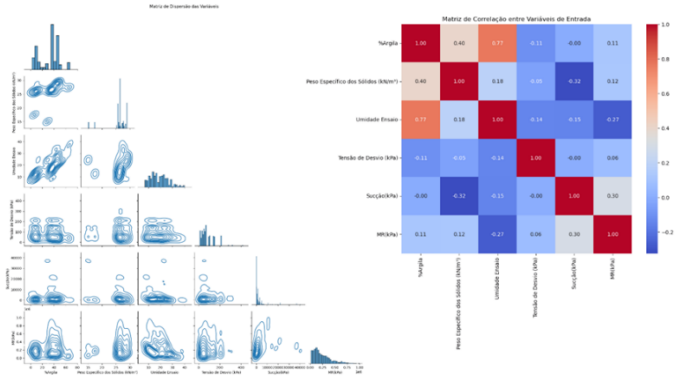


Figura 2. Matrizes de dispersão e de correlação de variáveis, respectivamente, 2026.

Essas matrizes são muito utilizadas para a decisão, ao critério do operador do banco de dados e da técnica de previsão, de quais das categorias devem permanecer ou não na rede neural, pois elas mostram a correlação entre as categorias e a dependência entre elas e quanto mais correlatas pior para a previsão (Almeida *et al*., 2023; Lunardi *et al*., 2025 e Khawaja *et al.*, 2024).

Outra parte do processamento é a seleção dos dados baseado em algum critério matemático, além das matrizes acima. O critério utilizado nesse caso foi o de desvio em relação a média de cada dado, por meio do intervalo interquartil (IQR) (Equação 1), que analisa a representatividade de cada categoria do banco de dados, pois quanto mais representativos melhor é a sua previsão.

Esse critério é calculado pela subtração do Q1 (mediana da metade inferior) de Q3 (mediana da metade superior), com o IQR são calculados os limites inferior (LL) e superior (UL), representados pelas Equações 2 e 3, respectivamente.

$$IQR = Q3 - Q1 \quad (1)$$

$$LL = Q3 + 1{,}5\ IQR \quad (2)$$

$$UL = Q1 - 1{,}5\ IQR \quad (3)$$

2.2 Modelagem com *machine learning*

A modelagem com *machine learning* consiste em utilizar o processamento dos dados do banco, de modo que sejam divididos em dados de treino, dados de teste e dados de validação para que sejam interpretados pela rede neural (ANN – MLP: *Artificial Neural Net – Multilayer Perceptron*, na Figura 4 tem uma representação dela.

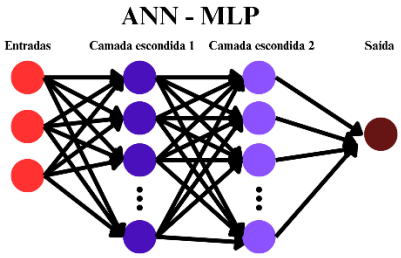


Figura 4. Representação dos modelos de *machine learning*, 2026.

Vale ressaltar que é possível usar cada modelo com vários algoritmos mas o algoritmo utilizado foi o de *backpropagation* (BP), preferiu-se alterar as outras componentes da rede neural, como número de camadas, número de neurônios por camada, otimizador, o número de categorias de entrada e a taxa de aprendizado.

3 RESULTADOS E DISCUSSÃO

Desse modo, preferiu-se por mostrar apenas o resultado ótimo, que foi uma ANN – MLP (*Multilayer Percepetron*), que consiste em uma ANN de várias camadas escondidas, a rede em questão contou com 6 camadas escondidas, começando com 1024 neurônios e reduzindo até 32 dividindo por 2 para cada camada subsequente; o otimizador utilizado na ótima foi o ADAM com uma taxa de aprendizado de 0,0005; a rede foi definida com 200 épocas, mas apresentou *early stop*, que foi configurado para 10 épocas, o que significa que se em 10 épocas não houver melhora nos parâmetros MAE e MSE, a rede neural para os treinamentos, 1 época configura 1 treinamento.

Vale ressaltar que 25% do total dos dados foi destinado ao treinamento e 20% do restante, ao teste da ANN citada a priori. O *label encoder* foi utilizado para a transformação das variáveis categóricas (Classificações TRB, SUCS, MCT e a Energia) ao passo que o *scaler* foi utilizado para transformar as variáveis numéricas.

3.1 Processamento de dados

Abaixo, na Figura 5 serão mostrados dados acerca do processamento.

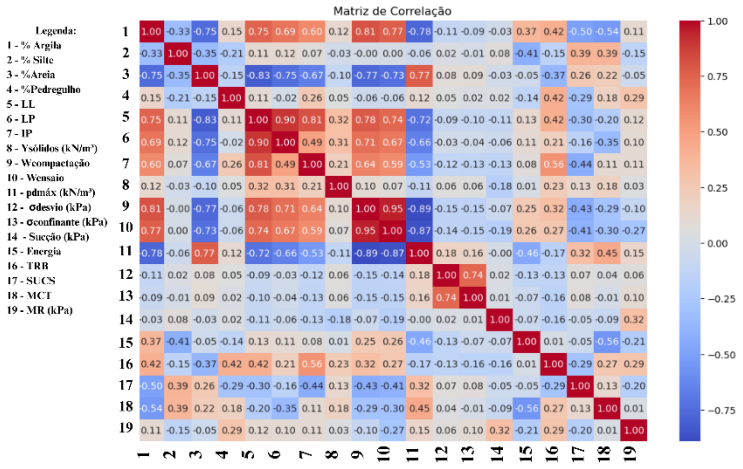


Figura 5. Matriz de Correlação, 2026.

Percebe-se a partir da figura uma forte relação entre 5, 6 e 7, essa relação é explicitada pelo fato de serem os limites de *atterberg*, respectivamente, LL, LP e o índice de plasticidade que é a diferença entre os dois. Além dessa relação, percebe-se alta correlação entre a % de areia e esses mesmos limites; também pode

ser vista a correlação entre a areia e as umidades de compactação e de ensaio; por último, percebe-se que este parâmetro também se relaciona com o peso específico aparente seco máximo do solo. Baseado nessa matriz definiu-se quais categorias seriam excluídas para comparação deste novo modelo com o modelo completo.

Os gráficos 1 e 2 abaixo mostram alguns resultados residuais, de predição de erro e a comparação de dado real com dado previsto. Os gráficos 1(a) e 1(b) utilizaram dados especificamente da ANN, havendo a comparação de dado real apenas na predição de erro com o melhor aproximador (identificado como *best fit*), ao passo que no Gráfico 2, levou em consideração a comparação dos dados previsto após o treino com os reais.

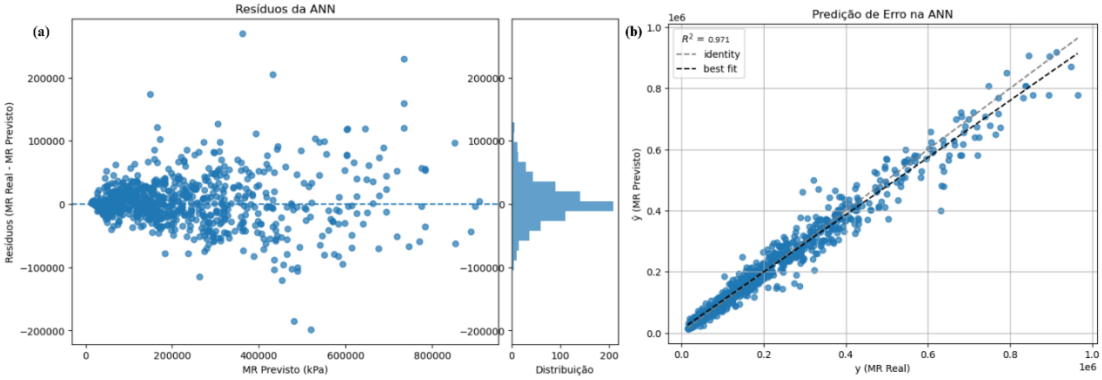


Gráfico 1. (a) – Resíduos da ANN e (b) – Predição de Erro na ANN, 2026.

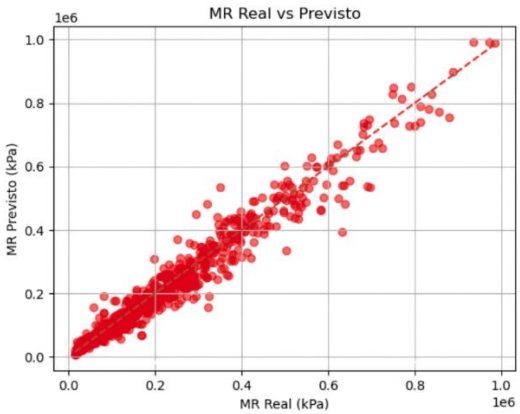


Gráfico 2. MR Real vs Previsto, 2026.

Os parâmetros de desempenho obtidos para o Gráfico 2, são apresentados abaixo na Tabela 1, em uma comparação com o modelo otimizado com menos categorias, sendo elas: 1, 7, 8, 10, 12, 14, 15, 17 e 18.

Identificação	Modelo completo	Modelo otimizado
R^2	0,971	0,863
MAE (kPa)	25256,65	48883,11
MSE $(kPa)^2$	1436468199	4613092590
RMSE (kPa)	37900,77	67919,75
MAPE (%)	14	30

Tabela 1. Comparação dos modelos, 2026.

Percebe-se que os valores dos modelos são bem díspares, sendo o melhor modelo o completo com todos os parâmetros analisados. Com esse desempenho, o valor previsto de MR foi de 54,45 MPa, enquanto o correspondente na base de dados, foi de 57,83 MPa, resultando em um coeficiente de variação relativo de 5,84% e um erro absoluto de 3,38 MPa.

Esse valor de coeficiente de variação é extremamente baixo para uma rede neural, além do que o R^2 de 0,97 pode explicar esse fato, pois significa que os dados treinados estão se aproximando dos reais com um R maior que 0,9848, ou seja, linearmente essa aproximação é de 98,5%, ao passo que quadraticamente é de 97%. Então, o modelo é bem representativo para a base de dados em questão, englobando mais de 3000 linhas de dados.

Desse modo, pode-se perceber que a ANN em questão, com MAE de 25256,65 kPa; MSE de 1436468199,34 $(kPa)^2$; RMSE de 37900,77 kPa; MAPE de 14% e R^2 de 0,97 resolve de maneira assertiva a problemática da estimativa do MR para solos não saturados brasileiros. Além disso, o modelo com 9 categorias totais também apresenta um R^2 elevado, de 0,86, podendo também ser utilizado para essa estimativa.

4 CONCLUSÃO

Em função da predição do MR em solos não saturados brasileiros considerando a sucção em sua previsão ser pouco abordado ou não ser abordado pelas pesquisas recentes, vale-se ressaltar que é possível realizar essa previsão por meio das ferramentas supracitadas.

Assim, utilizando o algoritmo de *backpropagation*, o otimizador que apresentou melhor desempenho foi o ADAM (Adaptive Moment Estimation), com taxa de aprendizado de 0,0005 e $R^2 = 0,97$. Esse otimizador é muito usado quando se espera um resultado mais linear (Almeida *et al*., 2023; Lunardi *et al*., 2025). Com esse desempenho, o valor previsto de MR foi de 54,45 MPa, enquanto o valor correspondente na base de dados, para as mesmas variáveis de entrada, foi de 57,83 MPa, resultando em um coeficiente de variação relativo de 5,84% e um erro absoluto de 3,38 MPa.

Desse modo, pode-se concluir que a ANN em questão resolve de maneira assertiva a problemática da estimativa do MR para solos não saturados brasileiros, tanto no modelo total (18 entradas) quanto no modelo otimizado com metade dos *inputs*. Além de possibilitar uma incalculável quantidade de simulações, a depender do operador, para que sejam feitas análises acerca de limites superiores e inferiores para solos, cujos quais ele deve fornecer os dados de entrada, podendo manter alguns parâmetros fixos, como as porcentagens granulométricas, e simular umidades ótimas e variações no fator sucção.

A inteligência artificial também permite a criação de novos modelos baseados neste, a fim de mudar os dados de entrada ou a combinação de modelos por *ensemble learning*, por exemplo. Pelas motivações explicitadas é altamente recomendada a utilização de *machine learning* para previsões ou simulações de situações de engenharia, no caso explicitado, do Módulo Resiliência.

AGRADECIMENTOS

Agradeço primeiramente a Deus; segundamente a minha família, amigos, professores e orientadores; e terceiramente ao CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) por financiar minha bolsa de mestrado desde 2025.

REFERÊNCIAS BIBLIOGRÁFICAS

ABU-FARSAKH, M. Y. *et al.* (2015) Incorporating the effect of moisture variation on resilient modulus for unsaturated fine-grained subgrade soils. *Transportation Research Record*, 2510 (1), p. 44-53.

ALMEIDA, T. A. C. *et al*. (2023) Influence of the ANN Hyperparameters on the Forecast Accuracy of RAC's Compressive Strength. *Materials*, 16 (24), p. 7683.

BLACKMORE, L. *et al*. (2020) Saturation and its effect on the resilient modulus of a pavement formation material. *Géotechnique*, 70 (4), p. 292-302.

DE FREITAS, J. B.; DE REZENDE, L. R.; DE FN GITIRANA JR, G. (2020) Prediction of the resilient modulus of two tropical subgrade soils considering unsaturated conditions. *Engineering Geology*, 270, p. 105580.

Departamento Nacional de Infraestrutura de Transportes (2016). DNIT 172/2016-ME. *Solos – Determinação do Índice de Suporte Califórnia utilizando amostras não trabalhadas – Método de ensaio*. Brasília.

Departamento Nacional de Infraestrutura de Transportes (2018). DNIT 134/2018-ME. *Pavimentação – Solos – Determinação do módulo de resiliência – Método de ensaio*. Rio de Janeiro.

DOS SANTOS, T. A. *et al*. (2019) Avaliação da resistência e da deformação resiliente de quatro solos de subleitos rodoviários no estado do Rio Grande do Sul. *Transportes*, 27 (1), p. 48-64.

DOS SANTOS PEREIRA, S. A. *et al.* (2024) Prediction of soil–water characteristic curves in bimodal tropical soils using artificial neural networks. *Geotechnical and Geological Engineering*, 42 (5), p. 3043-3062.

FREDLUND, D. G.; MORGENSTERN, N. R. (1977) Stress state variables for unsaturated soils. *Journal of the Geotechnical Engineering Division*, 103 (5), p. 447-466.

FREDLUND, D. G.; RAHARDJO, H. (1993) *Soil Mechanics for Unsaturated Soils*. John Wiley & Sons, New York.

FREDLUND, D. G.; RAHARDJO, H.; FREDLUND, M. D. (2012) *Soil-water characteristic curves for unsaturated soils*. Unsaturated Soil Mechanics in Engineering Practice, p. 184-272.

HAN, Z.; VANAPALLI, S. K. (2016) Relationship between resilient modulus and suction for compacted subgrade soils. *Engineering Geology*, 211, p. 85-97.

HEIDARABADIZADEH, N.; GHANIZADEH, A. R.; BEHNOOD, A. (2021) Prediction of the resilient modulus of non-cohesive subgrade soils and unbound subbase materials using a hybrid support vector machine method and colliding bodies optimization algorithm. *Construction and Building Materials*, 275, p. 122140.

KHAWAJA, L. *et al.* (2024) Development of machine learning models for forecasting the strength of resilient modulus of subgrade soil: genetic and artificial neural network approaches. *Scientific Reports*, 14 (1), p. 18244.

LEONG, E. C.; RAHARDJO, H. (1997) Review of soil-water characteristic curve equations. *Journal of Geotechnical and Geoenvironmental Engineering*, 123 (12), p. 1106-1117.

LIANG, R. Y.; RABAB'AH, S.; KHASAWNEH, M. (2008) Predicting moisture-dependent resilient modulus of cohesive soils using soil suction concept. *Journal of Transportation Engineering*, 134 (1), p. 34-40.

LIMA, C. D. A. *et al.* (2018) *Contribution to the study of Brazilian tropical soils as pavement materials*. Proceedings of the 13th Conference on Asphalt Pavements – ISAP. p. 1-10.

LUNARDI, L. R. *et al.* (2025) Hybrid machine learning model for predicting the fatigue life of plain concrete under cyclic compression. *Buildings*, 15 (10), p. 1618.

NOGAMI, J. S.; VILLIBOR, D. F. (1995) *Pavimentação de Baixo Custo com Solos Lateríticos*. São Paulo.

SALOUR, F.; ERLINGSSON, S. (2015) Resilient modulus modelling of unsaturated subgrade soils: laboratory investigation of silty sand subgrade. *Road Materials and Pavement Design*, 16 (3), p. 553-568.

SALOUR, F.; ERLINGSSON, S.; ZAPATA, C. E. (2014) Resilient modulus modeling of unsaturated subgrade soils with matric suction control. *Canadian Geotechnical Journal*, 51 (12), p. 1413-1422.

YANG, S.-R. *et al.* (2008) Suction-controlled laboratory test on resilient modulus of unsaturated compacted subgrade soils. *Journal of Geotechnical and Geoenvironmental Engineering*, 134 (9), p. 1375-1384.

YAO, Y. *et al*. (2018) Model for predicting resilient modulus of unsaturated subgrade soils in south China. *KSCE Journal of Civil Engineering*, 22 (6), p. 2089-2098.

ZHANG, J. *et al.* (2021) Predicting resilient modulus of fine-grained subgrade soils considering relative compaction and matric suction. *Road Materials and Pavement Design*, 22 (3), p. 703-715.

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/COBRAMSEG2026.2/31

Uso de IA como Ferramenta de Suporte à Decisão em Suprimentos em Empresa de Fundações

Willians Nascimento de Almeida

Analista de Suprimentos Pleno, Geofix Engenharia e Fundações, São Paulo, Brasil, willians.nascimento@geofix.com.br

Giuliano Silva Castro de Oliveira

Engº Civil, Geofix Engenharia e Fundações, São Paulo, Brasil, giuliano.oliveira@geofix.com.br

Marcio Abreu de Freitas

Engº Civil, Geofix Engenharia e Fundações, São Paulo, Brasil, marcio.freitas@geofix.com.br

RESUMO: Este trabalho apresenta um agente de Inteligência Artificial (IA) como ferramenta de suporte à decisão de suprimentos em uma empresa de fundações. O agente é baseado em modelos de linguagem de grande porte comerciais (Anthropic Claude e Azure OpenAI), operados por prompts estruturados, com regras de ponto de pedido e validação humana da equipe de suprimentos antes de qualquer decisão; não é um modelo treinado do zero, mas uma camada generativa de interpretação, diagnóstico e recomendação auditável sobre os dados do ERP. Aplicado a dados reais do almoxarifado da Geofix Engenharia (3.879 movimentações de janeiro/2026 e fichas de doze meses), corrigiu parâmetros de dois itens (arame MIG 1.2 e eletrodo 557), com economia estimada de cerca de R$ 11.888, e revelou um ciclo invisível de perda de cabo de cobre no setor de lama, resolvido por padronização e rastreabilidade. A proposta não exige integração complexa com o ERP e pode ser adotada de forma gradual.

PALAVRAS-CHAVE: Inteligência artificial, suprimentos, almoxarifado, obras de fundações, estoque, nível de serviço.

ABSTRACT: This paper presents an Artificial Intelligence (AI) agent used as a decision-support tool for supply management in a foundation contractor, aimed at keeping construction workfronts supplied and reducing stoppages from missing materials. The agent runs on commercial large language models, in a hybrid setup with Anthropic Claude and Azure OpenAI: for each item it reads the movement history and the parameters registered in the ERP and returns a diagnosis (average consumption, days of coverage, risk of stockout or excess) and a recommended action with its justification, reviewed by the supply team before acting. The replenishment logic follows classic inventory theory. The agent was validated on real warehouse data from Geofix Engenharia: 3,879 outbound transactions in January 2026 and twelve-month item histories (April 2025 to March 2026). The analysis found three concrete problems affecting the work: a maximum stock level nearly three times higher than needed (MIG wire 1.2, about R$ 9,870 tied up); a minimum parameter above real consumption (electrode 557, about R$ 2,018 freed); and an invisible material-loss cycle from the lack of return traceability (copper grounding cable, slurry sector). The approach does not require complex ERP integration and can be adopted gradually.

KEYWORDS: Artificial intelligence, supplies, warehouse, foundation works, inventory, service level.

1 INTRODUÇÃO

Em obras de fundações, a continuidade das frentes depende do abastecimento constante de materiais e insumos de apoio. Quando o almoxarifado falha em atender itens críticos no momento certo, o efeito é imediato: paralisação de frentes de serviço, reprogramação e compras emergenciais. O problema nem sempre

está no grande insumo. Muitas vezes a interrupção ocorre por itens de giro alto e reposição recorrente, ligados à manutenção, operação e segurança (Ballou, 2006).

Na prática, o setor de suprimentos lida com três causas recorrentes de ruptura: solicitação sem padrão definido, visibilidade insuficiente do consumo real por frente e decisão de reposição baseada em percepção, sem indicadores objetivos. Um exemplo direto: o arame MIG 1.2 (item 19276) ficou seis meses sem reposição enquanto o consumo continuava, e a compra só aconteceu quando o saldo já havia caído a níveis críticos, bem abaixo do lead time do fornecedor. A proposta deste artigo é tratar o almoxarifado como componente de confiabilidade operacional da obra, usando um agente de Inteligência Artificial (IA) para apoiar decisões de reposição, priorização e rastreabilidade, com adoção gradual e sem depender de integrações complexas com o ERP. Neste trabalho, nível de serviço do almoxarifado é definido por dois indicadores objetivos: percentual de solicitações atendidas sem ruptura e número de compras emergenciais por mês, ambos diretamente impactados pela qualidade das decisões de reposição (Chopra & Meindl, 2016).

2 PROPOSTA DO AGENTE DE IA PARA SUPRIMENTOS

O agente proposto funciona como camada de suporte à decisão que organiza o fluxo de suprimentos e reduz o tempo entre o sinal de consumo e a ação de reposição. A ideia não é automatizar tudo, mas padronizar o que é repetitivo, registrar o que hoje se perde e transformar histórico em decisões práticas. A Figura 1 ilustra o fluxo operacional.

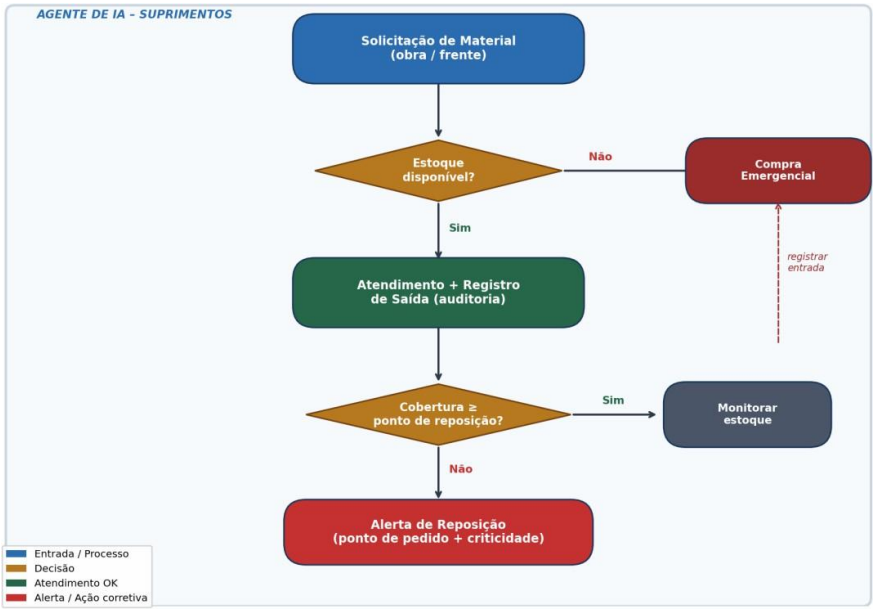


Figura 1. Fluxograma operacional do agente de IA para suprimentos.

O agente atua em três funções complementares. Na primeira, estrutura a solicitação com campos padronizados (item, quantidade, frente, prioridade e prazo) e registra auditoria completa de entradas e saídas. Isso permite medir nível de serviço de forma objetiva (Ballou, 2006). Na segunda, cruza o histórico de consumo com os parâmetros de cobertura e estima risco de ruptura por item, sugerindo prioridade de ação com justificativa: consumo recente, tendência e cobertura em dias, como identificado nos casos do arame MIG e do eletrodo 557 analisados em jan–mar/2026 (Silver et al., 1998) e apresentados no item 4 desse trabalho. Na terceira, monitora anomalias (saídas sem solicitação vinculada, entradas sem conferência e itens cujo consumo diverge do histórico), reduzindo surpresas no canteiro (Tao & Qi, 2019).

O agente de suporte à decisão usa modelos de linguagem comercial de grande porte (LLMs), em configuração híbrida com o Anthropic Claude e o Azure OpenAI. Optou-se por um agente generativo e não por um modelo estatístico treinado (como regressão, árvores de decisão, florestas aleatórias ou uma rede neural treinada) por uma razão prática: a decisão de reposição depende de ler os dados em forma de texto,

como as requisições das frentes, o histórico de movimentações e os parâmetros do ERP, e de explicar a recomendação em linguagem natural para a equipe de compras. Não há base rotulada que permita treinar um modelo supervisionado e o setor precisa de uma recomendação que o comprador entenda e consiga auditar, não apenas de um valor isolado entregue sem justificativa.

A primeira versão da solução foi prototipada em automação de fluxos (n8n) para validar a ideia do chat do comprador e depois reescrita em código e hospedada no Azure, o que manteve os dados da empresa em ambiente seguro e com custo previsível.

O agente é operado por prompts estruturados. A cada consulta, o agente recebe o extrato de movimentações do item e os parâmetros do ERP, devolvendo um diagnóstico (consumo médio, cobertura em dias, risco de ruptura ou de excesso) e a ação recomendada, sempre com a respectiva justificativa. O ajuste foi interativo: as primeiras respostas foram refinadas incorporando lead time e variabilidade de consumo, sendo validadas com o conhecimento da equipe de suprimentos.

Para chegar à recomendação, o agente aplica a lógica clássica de ponto de pedido: sinaliza a reposição quando o saldo se aproxima do consumo previsto durante o lead time somado a uma folga de segurança, ajustada à criticidade do item e limita o estoque a uma cobertura-alvo para não imobilizar o caixa da empresa. Na prática, o comprador recebe em minutos uma recomendação auditável para um item crítico, seja de obra ou de manutenção de equipamento, em vez de decidir por percepção (subjetivo).

3 MATERIAIS E MÉTODOS

Para caracterizar o problema e orientar a solução, foi analisado um conjunto de registros de movimentação de almoxarifado (entradas e saídas) de uma empresa de fundações, referente ao mês de janeiro de 2026. Os dados incluem datas, quantidades, valores, unidade de medida e centro de consumo. A análise foi feita em duas camadas: (a) visão geral do mês, como fotografia do esforço de atendimento; e (b) visão operacional, filtrando itens que não representam consumo típico do almoxarifado de obra (por exemplo, fretes e aquisições pontuais de equipamentos), para focar no que o agente precisa gerir no dia a dia.

Os materiais foram agrupados em famílias operacionais (combustíveis; lubrificantes e fluidos; metálicos e tração; EPI e uniformes; tubos e conexões; consumíveis de manutenção; limpeza e descartáveis; gases industriais; insumos de fluido estabilizante; apoio). Para cada família, calcularam-se participação em valor e em número de movimentações. A partir daí, definiu-se uma lógica de criticidade baseada em dois eixos: impacto na continuidade da frente (paralisação se faltar) e recorrência (giro). Esses eixos são os que alimentam o suporte à decisão do agente (Chopra & Meindl, 2016).

3.1 Operação do agente e refinamento dos prompts

A análise de cada item foi conduzida com o agente baseado em LLMs (Claude e Azure OpenAI), operado por prompts estruturados. A cada consulta, o agente recebe o histórico de movimentações, o saldo, os parâmetros do ERP e o lead time, e devolve consumo médio, cobertura em dias, risco de ruptura ou excesso, ponto de pedido, estoque máximo e lote de compra, com justificativa; as premissas são sinalizadas e a decisão final é validada pela equipe. O prompt foi refinado de forma iterativa. Em forma resumida:

"Você é um agente de apoio à decisão de suprimentos para obras de fundações. Com base no histórico de movimentações, saldo, parâmetros do ERP e lead time, calcule consumo médio, cobertura em dias, risco de ruptura ou excesso, ponto de pedido, estoque máximo e lote de compra; justifique em linguagem objetiva, sinalize as premissas e deixe a decisão final para validação da equipe de suprimentos."

Tabela 1. Caracterização da base mensal (janeiro/2026).

Indicador	Valor
Período analisado	03/01/2026 a 31/01/2026
Movimentações de saída (n)	3.879
Valor total das saídas (R$)	6.686.686,11
Itens distintos movimentados (n)	1.189
Base operacional – saídas (n)	2.589
Base operacional – valor (R$)	2.888.422,93

4 RESULTADOS E ANÁLISE

4.1 Diagnóstico geral do almoxarifado

A Tabela 1 mostra que o mês analisado concentrou alto volume de movimentações. Na visão operacional (sem fretes e compras pontuais de equipamentos), mantêm-se 2.589 saídas e cerca de R$ 2,89 milhões em consumo de materiais típicos de almoxarifado de obra. Esse recorte é o mais relevante para o agente, porque representa o ciclo repetitivo onde uma pequena ruptura vira atraso. A Tabela 2 detalha a distribuição por famílias operacionais, e a Figura 2 apresenta essa distribuição graficamente.

Tabela 2. Distribuição por famílias operacionais (base operacional, janeiro/2026).

Família	Mov.	% Mov.	Saídas (R$)	% Valor
Metálicos e tração	413	16,0%	1.187.566,44	41,1%
Outros	919	35,5%	853.001,45	29,5%
Combustíveis	257	9,9%	568.391,64	19,7%
Lubrificantes/Fluidos	106	4,1%	116.122,02	4,0%
Tubos e conexões	145	5,6%	75.456,69	2,6%
EPI/Uniformes	300	11,6%	47.092,35	1,6%
Gases industriais	44	1,7%	10.972,20	0,4%
Limpeza/Descartáveis	203	7,8%	8.513,72	0,3%
Solda e corte	41	1,6%	8.399,62	0,3%
Apoio	32	1,2%	4.335,35	0,2%
Insumos p/ fluido	31	1,2%	4.314,48	0,1%

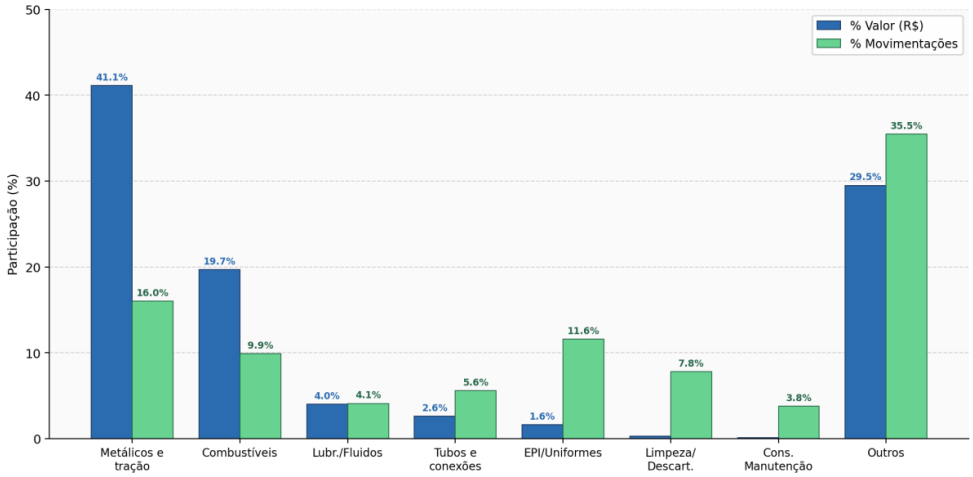


Figura 2. Distribuição das famílias operacionais por valor e por movimentações (base operacional, janeiro/2026).

Do ponto de vista de impacto na obra, três blocos merecem atenção. O primeiro é "Metálicos e tração", que responde por cerca de 41% do valor na base operacional, refletindo materiais que costumam ter criticidade elevada e prazos de reposição mais sensíveis. O segundo é "Combustíveis", com participação próxima de 20% do valor e alta recorrência, por sustentar deslocamentos e a operação de equipamentos. O terceiro é "Lubrificantes/Fluidos" e demais itens de manutenção, que, apesar de menor peso em valor, têm papel direto em evitar paradas por falhas simples (Ballou, 2006).

Quando se observa giro (movimentos), aparecem também famílias de suporte que raramente são tratadas como risco, mas param a obra quando faltam: EPI e uniformes, tubos e conexões e itens de limpeza/descartáveis. Um exemplo prático é o efeito de itens como óleos hidráulicos, graxas, filtros, eletrodos e consumíveis de solda no atendimento diário do canteiro, além de itens como desengripantes e estopa. Um caso ilustrativo: a família "Solda e corte" representa apenas 1,6% das movimentações e 0,3% do valor total, mas o arame MIG 1.2 (item 19276), pertencente a esse grupo, ficou seis meses sem entrada e chegou a 72 kg em março/2026, equivalente a 3,6 dias de cobertura. Não é o item mais caro que possa interromper a obra; é o item sem controle. Esses padrões reforçam que a decisão de reposição precisa ser orientada por dados de consumo e criticidade, e não por percepção (Chopra & Meindl, 2016).

4.2 Da análise à decisão: dois casos de correção de parâmetros

Com o histórico em mãos, o agente cruza entradas e saídas, calcula cobertura em dias e verifica se o ritmo de reposição é compatível com o consumo. Quando o saldo se aproxima do lead time sem pedido emitido, ou quando os parâmetros do ERP divergem do consumo real, sinaliza e sugere ação com justificativa. Os dois casos abaixo foram analisados em conjunto pelo setor de suprimentos com apoio de ferramentas de análise de dados.

4.2.1 Arame Solda MIG 1.2 (item 19276): estoque máximo superestimado e compra reativa

O arame MIG 1.2 não é item de canteiro: é consumível da manutenção dos equipamentos de perfuração e escavação (clamshells, trados, entre outros), feita no depósito. Mesmo assim, sua falta trava a manutenção e pode parar um equipamento, refletindo na frente de fundação. O histórico de 12 meses (abr/2025–mar/2026, extraído do ERP) revelou dois problemas. O primeiro, de processo: o ERP não tinha ponto de pedido ativo; a reposição só era disparada ao atingir o estoque mínimo cadastrado, na prática por percepção. Esse mínimo de 900 kg equivalia a ~1,5 mês para um lead time de apenas 20 dias, folga acima do necessário, e ainda assim não era respeitado: em março/2026 o saldo caiu a 72 kg (3,6 dias). O segundo era o estoque máximo de 1.800 kg, quase 3 meses parados (~R$ 9.870 imobilizados). Pelo consumo real e o lead time, o agente definiu ponto

de pedido de 606 kg (30 dias), máximo de 910 kg (1,5 mês) e lote de 304 kg. A evidência do superdimensionamento: o mínimo antigo (900 kg) estava no nível do máximo corrigido (910 kg). Com saldo de 72 kg, recomendou compra imediata de 838 kg.

Tabela 3. Diagnóstico de parâmetros do arame Solda MIG 1.2 (item 19276).

Parâmetro	No ERP (antes)	Corrigido pela IA
Consumo médio mensal	Não monitorado	607 kg/mês (20,2 kg/dia)
Estoque mínimo / PP	900 kg 🔴	606 kg (30 dias)
Estoque máximo	1.800 kg 🔴 (3,0 meses)	910 kg (1,5 mês)
Lote de compra	Não definido (inadequado)	304 kg (máx. − mín.)
Saldo em mar/2026	72 kg 🔴 (3,6 dias)	Compra imediata de 838 kg
Capital imobilizado evitado	—	~R$ 9.870 (890 kg × R$ 11,08)

Legenda: Inadequado = falha identificada no ERP; Adequado = parâmetro recalculado pela IA

4.2.2 Eletrodo 557 (ELETR NCS 7804 4,0×450mm): parâmetros descalibrados em relação ao consumo real

O eletrodo 557 é usado principalmente no depósito, em manutenção e corte, e eventualmente enviado à obra para corte, sobretudo em obras com perfis metálicos. No mesmo período (abr/2025–mar/2026), o eletrodo 557 apresentou o problema inverso: o mínimo cadastrado de 304 kg estava acima do consumo médio real de 267 kg/mês, o que gerava alertas de reposição prematuros e compras acima do necessário. O máximo de 350 kg, por sua vez, ficava abaixo do ideal de 1,5 mês de cobertura. Com o consumo diário de 8,9 kg e lead time de 20 dias, o agente recalculou o ponto de pedido correto em 180 kg e o máximo em 400 kg, reduzindo o mínimo em 124 kg e liberando cerca de R$ 2.018 em capital antes imobilizado. Os dois casos juntos demonstram que comprar com inteligência tem dois lados: evitar a ruptura e não comprar além do necessário (Chopra & Meindl, 2016).

Tabela 4. Diagnóstico de parâmetros do Eletrodo 557 / ELETR NCS 7804 4,0×450mm.

Parâmetro	No ERP (antes)	Corrigido pela IA
Consumo médio mensal	Não monitorado	267 kg/mês (8,9 kg/dia)
Estoque mínimo / PP	304 kg (inadequado, acima do real)	180 kg (LT 20d × 8,9 kg/dia)
Estoque máximo	350 kg (inadequado, abaixo do ideal)	400 kg (1,5 mês)
Lote de compra	Não definido (inadequado)	220 kg (máx. − mín.)
Saldo atual	50 kg, crítico (5,6 dias)	Compra imediata de 350 kg
Capital liberado	—	~R$ 2.018 (124 kg × R$ 16,28)

Legenda: Inadequado = falha identificada no ERP; Adequado = parâmetro recalculado pela IA

4.3 Caso de padronização: cabo de cobre de aterramento no setor de lama

Em janeiro e fevereiro de 2026, o agente identificou uma anomalia no histórico do cabo de cobre nu 16mm para aterramento: 42 metros saíram do almoxarifado em três movimentações (R$ 385,00), sem nenhuma entrada correspondente no período. No sistema, parecia consumo normal, mas a ausência total de retorno indicava que o material não estava sendo reaproveitado entre obras. A investigação mostrou o motivo: o cabo era instalado exposto no solo, próximo a silos e equipamentos, onde ficava sujeito a danos mecânicos por tráfego de máquinas e pessoas (pisoteio), além de degradação por chuva e furtos. O resultado era um ciclo invisível de perda que o sistema jamais conseguiria detectar sem rastreabilidade de retorno.

A solução foi padronizar a instalação: cabo protegido em conduíte corrugado enterrado, caixas de inspeção identificadas interligando os pontos e terminais fixos por equipamento para facilitar a desmontagem e o reaproveitamento. O padrão seguiu a sequência real dos equipamentos no setor (silos → minicentral → bomba), tornando a execução repetível entre obras. A Tabela 5 resume o contraste entre o cenário anterior e o modelo proposto com suporte do agente.

Tabela 5. Antes e depois da padronização do cabo de cobre de aterramento, setor de lama.

Aspecto	Antes da padronização	Depois (com IA + padronização)
Instalação do cabo	Exposto no solo, próximo a silos e equipamentos	Conduíte corrugado enterrado, caixas de inspeção identificadas
Rastreabilidade	Saída registrada, zero retornos; material desaparecia do controle	Entrada, saída e retorno auditados pelo agente
Causa da perda	Danos mecânicos por tráfego de máquinas e pessoas (pisoteio), degradação por chuva e furto	Identificável: agente sinaliza quando índice de retorno cai abaixo do esperado
Critério de compra	Recorrente e sem critério; reposição sempre que o saldo zera	Baseada em consumo real e retorno; compra só quando necessário
Dado que revelou o problema	*42 m de cabo saíram em jan–fev/2026 (R$ 385); zero entradas no período*	*Agente cruzou saídas sem entrada correspondente e sinalizou ciclo de perda*

Legenda: coluna "Antes da padronização" = situação anterior ao diagnóstico; coluna "Depois (com IA + padronização)" = modelo proposto.

Esse caso ilustra uma dimensão do suporte à decisão que vai além da reposição: a IA só consegue distinguir consumo real de perda quando há rastreabilidade de retorno. A padronização operacional é, portanto, pré-requisito, não complemento. Com o padrão implantado, cada saída fica vinculada a um ponto de uso identificado, e o agente passa a monitorar o índice de retorno do material. Quando esse índice cai, o sistema sinaliza automaticamente, transformando uma perda antes invisível em informação acionável (Tao & Qi, 2019). O ganho relevante não está nos R$ 385,00 de um período, mas na rastreabilidade criada e na prevenção de perdas recorrentes entre obras.

5 DISCUSSÃO

Os resultados apontam dois problemas que se alimentam. O primeiro é a falta de previsibilidade: sem acompanhar a tendência de consumo, a decisão de comprar chega tarde, como no arame que ficou seis meses sem reposição. O segundo é a falta de rastreabilidade: sem registro confiável de entrada e retorno, não há base para ajustar parâmetro nem para separar consumo de perda, como no cabo de aterramento. O agente atua sobre os dois ao estruturar o registro, auditar as movimentações e converter o histórico em alertas justificados.

Os casos do arame e do eletrodo mostram que a recomendação pode ser tanto comprar mais quanto comprar menos, conforme o parâmetro esteja abaixo ou acima do consumo real. Já o aterramento deixa claro

um limite do método: a IA só distingue consumo de perda quando existe rastreabilidade de retorno, então a padronização operacional é pré-requisito, não complemento (Tao & Qi, 2019).

O diferencial do trabalho não está no algoritmo, mas na aplicação ao fluxo real de suprimentos da obra: requisição da frente, saldo, lead time, cobertura, criticidade, ponto de pedido, compra e rastreabilidade de retorno. A implantação foi incremental, partindo da análise de janeiro/2026 para identificar os itens de maior risco e, a partir deles, corrigir parâmetros e criar rastreabilidade onde antes havia perda invisível.

5.1 Limitações

As recomendações do agente dependem da qualidade dos dados: cadastro correto dos itens, lançamento disciplinado de entradas e saídas, lead time atualizado e validação do comprador. Os resultados dependem da qualidade dos lançamentos e não dispensam a conferência física de estoque. O agente apoia a decisão e não a substitui.

6 CONSIDERAÇÕES FINAIS

Este trabalho aplicou um agente de IA generativa como ferramenta de apoio à decisão no setor de suprimentos da Geofix Engenharia. O agente usa modelos comerciais de linguagem em configuração híbrida (Anthropic Claude e Azure OpenAI), operados por prompts estruturados sobre os dados de movimentação e os parâmetros do ERP. Ele não decide sozinho: cada recomendação vem justificada e passa pela validação da equipe de compras antes de virar parâmetro ou pedido.

Os resultados saíram de itens reais. No arame MIG 1.2, o estoque máximo caiu de 1.800 kg para 910 kg, evitando cerca de R$ 9.870 em capital imobilizado. No eletrodo 557, a recalibração do estoque mínimo de 304 kg para 180 kg liberou aproximadamente R$ 2.018. Só nesses dois itens, o ganho direto estimado chegou a R$ 11.888, sem contar a queda do risco de ruptura por falta de um ponto de pedido ativo. No cabo de cobre de aterramento, o agente expôs uma perda que o sistema vinha registrando como consumo normal; a padronização da instalação e do retorno transformou esse desperdício invisível em algo que o setor passa a acompanhar.

O ganho que mais pesa não é o financeiro, é a qualidade da decisão: comprar na hora certa, na quantidade certa, com justificativa e rastro. A solução roda sem integração complexa com o ERP e pode crescer item a item, sustentada por um acompanhamento mensal de rupturas, compras emergenciais, cobertura de estoque, acurácia de cadastro e capital imobilizado.

REFERÊNCIAS BIBLIOGRÁFICAS

Ballou, R. H. (2006). Gerenciamento da Cadeia de Suprimentos: Logística Empresarial. Porto Alegre: Bookman.

Chopra, S.; Meindl, P. (2016). Supply Chain Management: Strategy, Planning, and Operation. 6. ed. Boston: Pearson.

Silver, E. A.; Pyke, D. F.; Peterson, R. (1998). Inventory Management and Production Planning and Scheduling. 3. ed. New York: Wiley.

Tao, F.; Qi, Q. (2019). Digital Twin and Big Data Toward Smart Manufacturing and Industry 4.0. IEEE Access, v. 7, p. 161-170.

DOI: 10.47094/COBRAMSEG2026.2/32

Utilização de Radar de Abertura Sintética Interferométrico (InSAR) como Auxílio ao Monitoramento de Taludes em Zonas de Instabilidade Geológico-Geotécnica no Município de Ilhéus - Bahia - Brasil

Daniel Miranda Ramos de Araújo
Mestrando, Universidade Estadual de Santa Cruz, Ilhéus - BA, Brasil, dmraraujo.ppgeca@uesc.br

Cleverson Alves de Lima
Docente, Universidade Estadual de Santa Cruz, Ilhéus - BA, Brasil, clalima@uesc.br

Ronaldo Lima Gomes
Docente, Universidade Estadual de Santa Cruz, Ilhéus - BA, Brasil, rlgomes@uesc.br

Getúlio Fonseca Domingues
Docente, Universidade Federal de Minas Gerais, Belo Horizonte - MG, Brasil, getulio.floresta@gmail.com

Sarah Silva Sousa
Mestranda, Universidade Estadual de Santa Cruz, Ilhéus - BA, Brasil, sssousa.ppgeca@uesc.br

RESUMO: A gestão do espaço urbano, visando ao mapeamento e mitigação de riscos, demanda a observação de variáveis múltiplas e inter-relacionadas, pleiteando esforços multidisciplinares, para aquisição de recursos em tempo real e grande volume. Neste contexto, tecnologias para sensoriamento remoto orbital, como radares embarcados em satélites, apresentam-se como ferramentas valiosas, permitindo a automatização de processos de rotina e adoção de estratégias atenuadoras da subjetividade inerente aos procedimentos de mapeamento de riscos visuais, com operadores humanos em campo. Aliadas aos ensaios geológico-geotécnicos de estabilidade, estas ferramentas permitem uma compreensão multicritério do comportamento de taludes, especialmente em áreas de alta vulnerabilidade, com presença de assentamentos humanos informais. Desta maneira, propõe-se o emprego de análises de estabilidade geotécnica e interferometria com o Radar de Abertura Sintética (SAR) da constelação Sentinel-1, para o mapeamento preditivo de riscos geológico-geotécnicos no município de Ilhéus-BA, afim de subsidiar estratégias de prevenção e defesa civil. Na etapa atual, da pesquisa em desenvolvimento, realizou-se o processamento de séries temporais InSAR, pela técnica de *Small Baseline Subset* (SBAS-InSAR), com imagens SLC, obtidas no modo interferométrico (IW) do Sentinel-1, entre 2020 e 2025, correspondentes à zona urbana, enfatizando-se áreas afetadas morfodinamicamente, para verificação da capacidade preditiva dos sistemas InSAR, na identificação prévia e monitoramento de riscos em áreas vulneráveis.

PALAVRAS-CHAVE: Sensoriamento Remoto, Movimentos de Massa, Mapeamento de Riscos, Defesa Civil, Interferometria SBAS, Estabilidade de Encostas.

ABSTRACT: Urban space management for risk mapping and mitigation requires the assessment of multiple and interrelated variables, demanding multidisciplinary efforts to acquire large volumes of data in near real time. In this context, orbital remote sensing technologies, such as satellite-borne radar systems, have emerged as valuable tools, enabling the automation of routine processes and reducing the subjectivity inherent in visual risk-mapping procedures conducted by human field operators. When combined with geological–geotechnical stability analyses, these tools provide a multicriteria understanding of slope behavior, particularly in highly vulnerable areas characterized by the presence of informal settlements. In this regard, the present study proposes the integration of geotechnical stability analyses and Synthetic Aperture Radar (SAR) interferometry from the Sentinel-1 constellation for predictive geological–geotechnical risk mapping in the municipality of Ilhéus, aiming to support disaster prevention and disaster risk management strategies. At the current stage of

this ongoing research, InSAR time-series processing has been performed using the Small Baseline Subset (SBAS-InSAR) technique based on Single Look Complex (SLC) images acquired in Interferometric Wide Swath (IW) mode between 2020 and 2025. The dataset covers the urban area of the municipality, with emphasis on morphodynamically active sectors, in order to evaluate the predictive capability of InSAR systems for the early detection and monitoring of risks in vulnerable areas.

KEYWORDS: Remote Sensing, Landslides, Geohazard Risk Mapping, Disaster Risk Management, SBAS-InSAR, Slope Stability.

1 INTRODUÇÃO

O desenvolvimento e a expansão urbana evidenciam-se como notáveis fenômenos contemporâneos, mobilizando populações diversas a concentrarem-se em torno dos principais centros consumidores. Este agrupamento, todavia, em especial nas nações subdesenvolvidas ou em desenvolvimento, é frequentemente empreendido de maneira desordenada, notavelmente, em assentamentos irregulares, marcados por reduzida infraestrutura e situados, indevidamente, em encostas de acentuada declividade, tornando-se vulneráveis às frequentes deflagrações de movimentos gravitacionais de massa, sobretudo nas estações de pluviosidade elevada (ASSIS, 2017; ARAÚJO *et al.*, 2021).

Evidencia-se, desta maneira, a contundente necessidade de procedimentos de gerenciamento do espaço citadino, a fim de se garantir a segurança dessas aglomerações, em consonância com a Política Nacional de Proteção e Defesa Civil (PNPDEC), instituída pela Lei Federal n° 12608 de 2012, que visa à promoção de estratégias integradas para identificar e "combater a ocupação de áreas ambientalmente vulneráveis e de risco e promover a realocação da população residente nessas áreas" (BRASIL, 2012).

Verifica-se, contudo, que os processos de ocupação no ambiente urbano, afetados pela escassez de recursos econômicos populacional, direcionam o fluxo de crescimento para zonas periféricas aos grandes centros, muitas delas situadas em áreas non aedificandi, em especial, aquelas cuja classe de declividade do terreno ultrapassa o limite máximo de 30%, preconizado pela Lei Federal n° 6766, para garantia da estabilidade morfodinâmica do terreno e, consequentemente, de suas edificações (BRASIL, 1979).

Com efeito, demanda-se a implementação de medidas preditivas que visem ao monitoramento e controle dos processos geológicos-geotécnicos causadores de instabilidade dinâmica nestes terrenos ocupados. Tal metodologia possui elevada complexidade, em virtude das diversas variáveis inerentes ao processo de modelagem do relevo e composição terrestre. Neste contexto, apresentam-se as geotecnologias de sensoriamento remoto, que permitem a aquisição de dados de relevo de áreas suscetíveis a movimentos de massa, em grande volume, com boa resolução temporal e baixo custo relativo (ARAÚJO *et al.*, 2023; PRADO, 2023). Entre estas aplicações, destaca-se o Radar de Abertura Sintética (SAR), cujo movimento em relação a um alvo terrestre possibilita sua detecção em tomadas múltiplas, a partir de diferentes posições do sensor, simulando uma abertura fictícia, muito maior que as dimensões reais da antena do dispositivo, a qual pode ser embarcada em aeronave (sensoriamento suborbital) ou satélite (sensoriamento orbital) (COUTINHO, 2023; SILVA, 2020).

A tecnologia de radar orbital consolidou-se como importante mecanismo de monitoramento de estruturas geotécnicas, pela facilidade de aquisição de dados em diversas plataformas (algumas delas de uso gratuito), pela mensuração independente das condições climáticas e de iluminação (com monitoramento ativo automático e contínuo) e pela diminuição da necessidade de emprego de equipamentos de campo para modelagem do terreno (CLEMENTE, 2023; PARADELLA et al., 2021). O pareamento de imagens SAR, com seus dados de amplitude e fase (formato Single Look Complex ou SLC) possibilita, conforme Paradella et al. (2021), a elaboração de um interferograma, uma imagem complexa em que cada pixel possui uma fase, dada pela diferença entre as fases dos pixels correlatos nas imagens originais do par interferométrico. Esta técnica é referenciada na literatura como Interferometria SAR (InSAR). Conforme descrito por Souza (2022), o Radar de Abertura Sintética Interferométrico (InSAR) permite a "detecção precisa em deslocamento superficial-estrutural, com elevada densidade de pontos de observação e alta resolução temporal."

Portanto, este projeto propõe avaliar a utilização do InSAR como mecanismo aplicado ao monitoramento de taludes ocupados na Zona Urbana do município de Ilhéus, Bahia, Brasil, a fim de se identificar, preditivamente, áreas suscetíveis à instabilidade geológico-geotécnica, possibilitando a adoção de estratégias para a garantia da segurança dos seus habitantes. Almeja-se aplicar o processamento

interferométrico diferencial em *Small Baseline Subset* (SBAS-InSAR), para construção de séries temporais pretéritas aos eventos morfodinâmicos, com vistas à verificação de deslocamentos capazes de predizer a iminência de ruptura nestas áreas.

2 METODOLOGIA

Esta pesquisa apresenta-se em fase de desenvolvimento, atualmente, na transição entre a obtenção da pilha de interferogramas (281 imagens) e o processamento SBAS-InSAR em nuvem, via OpenSARLab. A Figura 1, a seguir, descreve o processo metodológico completo que se planeja empreender, o qual encontra-se descrito até a etapa presente, nos tópicos adiante.

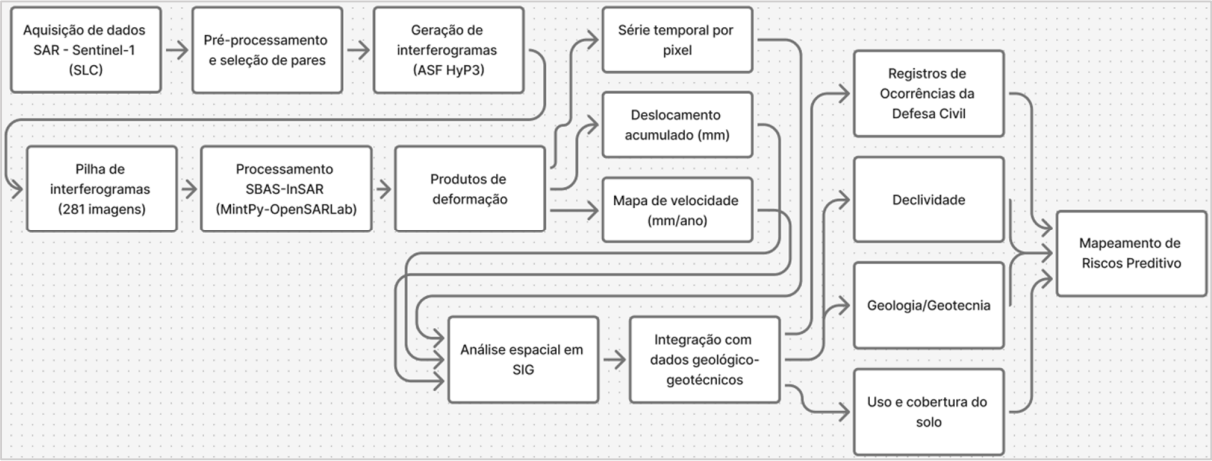


Figura 1. Fluxograma Sintético da Metodologia Proposta. Fonte: Autores.

2.1 Consulta ao Histórico de Dados Municipais

Coletou-se, junto à Defesa Civil Municipal de Ilhéus (COMDEC), o histórico das principais áreas de ocupação afetadas por ocorrências de natureza geomorfodinâmica, em especial os movimentos gravitacionais de massa, a fim de se identificar os principais taludes da zona urbana onde ocorreram movimentos de massa. Posteriormente, estes pontos serão utilizados como referência posicional comparativa, nos mapas de deslocamento oriundos do processamento por SBAS-InSAR. A seguinte Figura 2 ilustra um dos documentos elaborados pela COMDEC de Ilhéus, utilizados como referência para o mapeamento das ocorrências.

DEFESA CIVIL
PREFEITURA MUNICIPAL DE ILHÉUS
COMDEC

Coordenação Municipal de Defesa Civil

Tabela 2: Registro de ocorrências de movimentos de massa, sucedidos na área urbana de Ilhéus – BA, nos períodos de Janeiro de 2002 a agosto de 2018. Complementação até 2022.

DATA	LOCAL DA OCORRÊNCIA	SÓCIO-ECONÔMICAS
07/01/2002	Deslizamento – Rua da Horta	Destruiu paredes e alguns objetos domésticos
07/01/2002	Deslizamento, Desabamento	Destruiu paredes do quarto e da cozinha
07/01/2002	Soterramento – Rua José Carolino Av. Principal	Derrubou paredes da casa

Figura 2. Registro de Ocorrências Fornecido pela Defesa Civil de Ilhéus. Fonte: COMDEC (2024).

2.2 Aquisição de Imagens SAR e Pré-processamento de Dados Interferométricos

2.2.1 Seleção da Cena SLC de Referência para o SBAS

As imagens interferométricas da região de pesquisa, contemplando a Zona Urbana Central de Ilhéus, foram selecionadas, com distribuição temporal entre os anos de 2020 a 2025, sendo obtidas por meio do radar SAR embarcado no satélite Sentinel-1, pertencente ao Programa Espacial Copernicus, da Agência Espacial Europeia (ESA), o qual opera na Banda-C do espectro eletromagnético, com tempo de revisita de 12 dias e resolução espacial de 5x20 metros. Os arquivos foram obtidos, de forma gratuita, na plataforma ASF Data Search Vertex, uma parceria da NASA com a University of Alaska Fairbanks (UAF).

O filtro de busca foi ajustado para o formato *Single Look Complex* (SLC), no modo *Interferometric Wide Swath* (IW), que contém os correspondentes registros de fase do sinal retroespalhado. Desta forma, selecionou-se a cena "S1A_IW_SLC__1SDV_20251224T081209_20251224T081235_062454_07D319_E12E", de órbita descendente e polarização VV+VH, como referência para a composição da baseline SBAS-InSAR, conforme evidenciado na Figura 3, adiante.

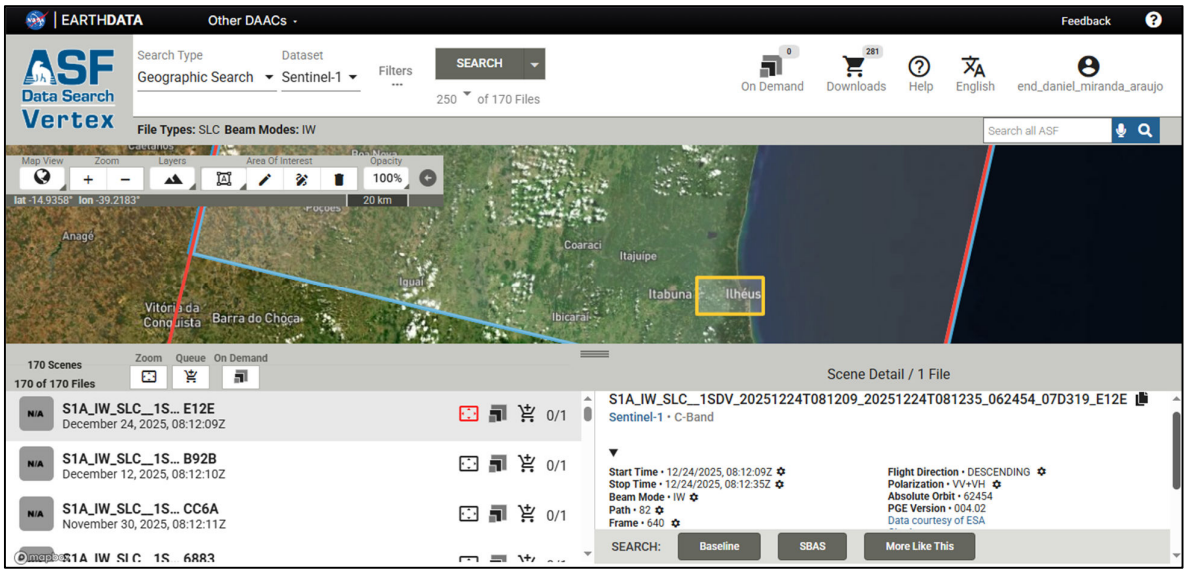


Figura 3. Seleção de Imagens SLC em Modo IW do Sentinel-1 no ASF Data Search Vertex. Fonte: Autores.

2.2.2 Construção do Grafo Interferométrico

Utilizou-se a cena SLC selecionada como referência na pesquisa SBAS, para elaboração do Grafo Interferométrico, com a combinação das cenas em pares, formando-se a rede *Small Baseline Subset* (SBAS), com pequenos baselines temporais e espaciais, conforme evidenciado na Figura 4, a seguir.

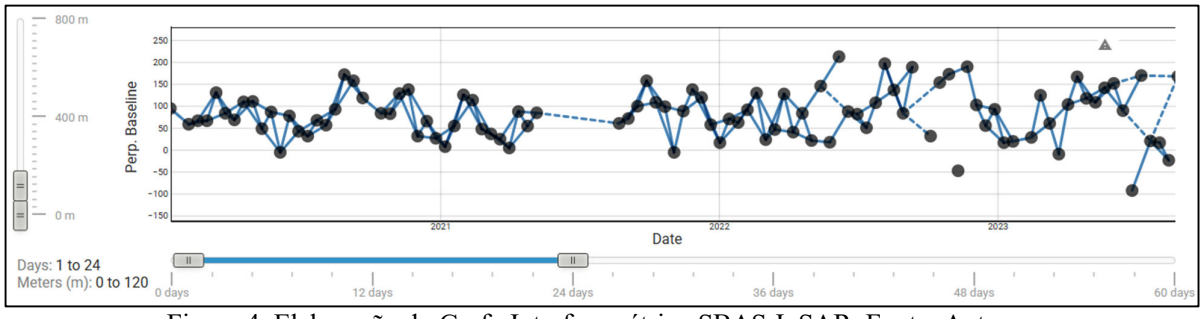


Figura 4. Elaboração do Grafo Interferométrico SBAS-InSAR. Fonte: Autores.

Para compensar a perda de coerência provocada pela presença de vegetação abundante e dos numerosos recursos hídricos especificou-se uma variação na baseline temporal de até 24 dias, entre as cenas

interferométricas (pontos), na construção dos pares (com adição de alguns pares customizados de até 36 dias), além de baseline perpendicular inferior a 120 m, a fim de se minimizar, igualmente, a descorrelação geométrica entre as aquisições. Desta maneira, os filtros SBAS aplicados possibilitaram a obtenção de 281 pares de conexões entre as cenas.

2.3 Geração da Pilha de Interferogramas no HyP3

Cada par interferométrico obtido foi processado na plataforma em nuvem *Hybrid Pluggable Processing Pipeline* (HyP3), para a composição do *stack* (pilha) interferométrico, resultando na formação de 281 interferogramas, para aplicação do SBAS-InSAR, conforme indicado na Figura 5, adiante, correspondente ao resumo do processamento InSAR GAMMA, sob demanda, dos pares interferométricos, no HyP3 do ASF. Foram aplicados filtros para o corregistro de dados (alinhamento geométrico preciso entre imagens), cálculo da diferença de fase, ajuste de coerência, filtragem interferométrica e correção da máscara d'água.

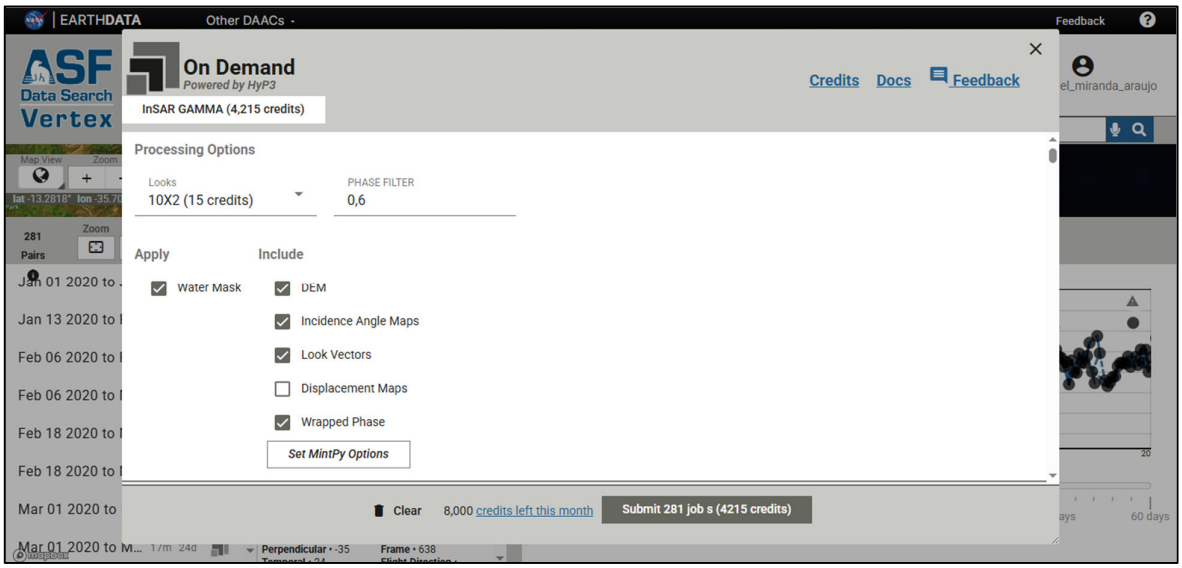


Figura 5. Resumo dos Filtros Aplicados ao Processamento InSAR GAMMA no HyP3. Fonte: Autores.

2.4 Perspectiva das Etapas Subsequentes da Pesquisa

Utilizando o *stack* de 281 interferogramas gerados por meio do HyP3, após a liberação de acesso pela NASA e ASF à plataforma OpenScienceLab, pretende-se executar a inversão temporal SBAS-InSAR, em ambiente OpenSARLab utilizando o software MintPy, para o processamento em nuvem destas imagens e a consequente obtenção de séries temporais de deformação e mapas de velocidade (mm/ano) e deslocamento acumulado (mm) das áreas investigadas.

Concomitantemente, planeja-se o prosseguimento do fluxo metodológico com a Modelagem SIG/GIS e Análises de Estabilidade, para correlação com dados geológico-geotécnicos e verificação das condições de segurança dos taludes afetados, em período anterior aos eventos geomorfodinâmicos, em conformidade com as preconizações da norma brasileira NBR 11682:2009. Desta forma, pretende-se atestar a capacidade da Interferometria InSAR, como ferramenta para o Mapeamento Preditivo de Riscos Geológico-geotécnicos.

3 RESULTADOS PARCIAIS E DISCUSSÃO PRELIMINAR

O processamento das imagens SLC, na plataforma HyP3, em combinações de pares interferométricos, selecionados para o grafo SBAS-InSAR, resultou em 281 interferogramas, a exemplo do indicado na Figura 6, a seguir, elaborado a partir do pareamento das imagens S1A_IW_SLC__1SDV_20250907 (cena primária) e S1A_IW_SLC__1SDV_20251001 (cena secundária). As duas grandes manchas de ênfase azulada correspondem às sedes urbanas dos municípios de Ilhéus (leste) e Itabuna (oeste), no Estado da Bahia, Brasil.

A grande área escura ao leste corresponde ao Oceano Atlântico, enquanto a mancha escura ao norte evidencia a Lagoa Encantada, na Zona Norte Ilheense.

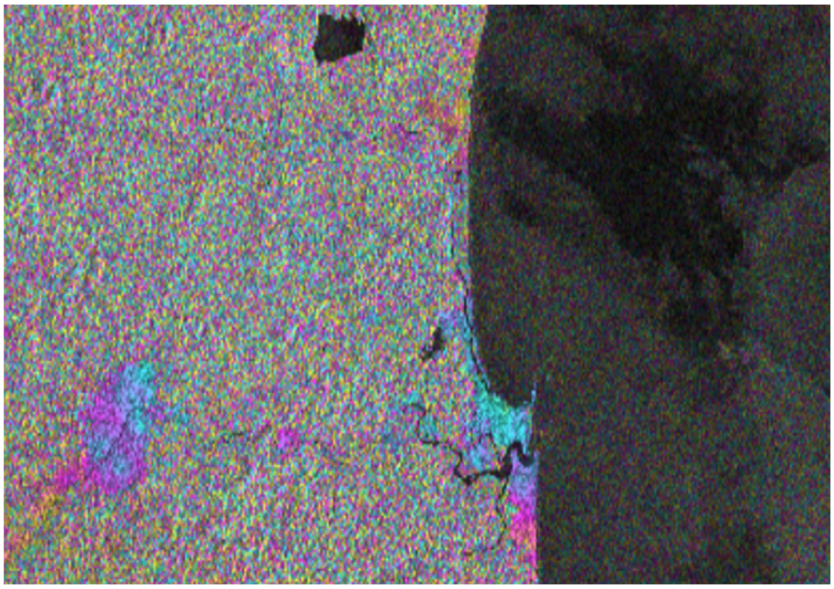


Figura 6. Interferograma gerado no Hyp3 a partir de Par Interferométrico. Fonte: Autores.

No entanto, conforme relatado na literatura técnica, a geração de interferogramas com base em um único par interferométrico resulta em considerável nível de ruído e baixa coerência espacial, originando um produto com significativa degradação da qualidade da informação interferométrica. A Figura 7, a seguir, destaca o recorte de um interferograma sobre a área Central da Sede Urbana de Ilhéus. Observa-se a presença de padrões altamente irregulares e granulação acentuada (speckle), sem franjas interferométricas evidentes, indicando baixa coerência interferométrica e confiabilidade muito reduzida para estimativas de deslocamento, condições associadas, principalmente, com a presença de áreas extensas de vegetação remanescente da Mata Atlântica, além da ocorrência de corpos d'água superficiais extensos. Esses elementos favorecem a decorrelação geométrica do sinal de radar, provocando anomalias interferométricas tipicamente observadas em ambientes tropicais úmidos e zonas urbanas costeiras. Ressalta-se que a qualidade dos interferogramas gerados seria ainda mais diminuta, caso os filtros de pré-processamento do ASF HyP3 não houvessem sido aplicados.

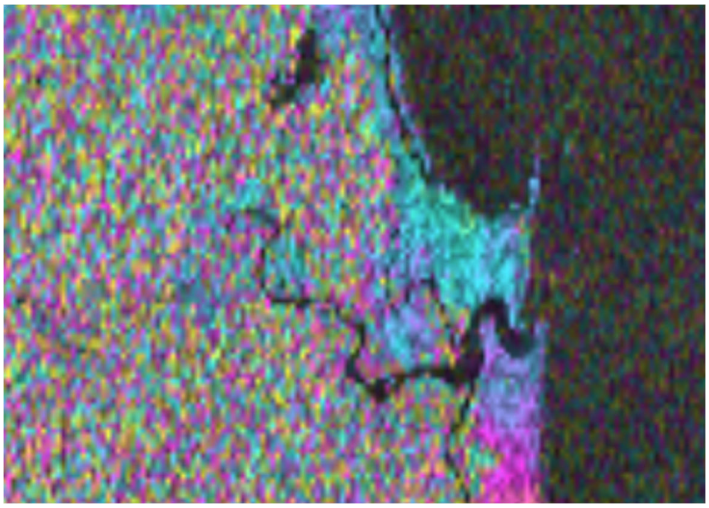


Figura 7. Interferograma da Zona Urbana Central de Ilhéus. Fonte: Autores.

A análise de deslocamentos do terreno, em nível milimétrico, portanto, tanto em velocidade como em deslocamento acumulado, apenas tornar-se-á possível, com a consequente aplicação de ferramentas para

avaliação das deformações em série temporal, com a compilação dos 281 interferogramas através da técnica de SBAS-InSAR, para obtenção do Mapa de Velocidades Médias de Deslocamento(em mm/ano), bem como o Mapa de Deslocamento Acumulado (em mm), o que corresponde à próxima etapa desta pesquisa, ainda em fase de desenvolvimento e pendente da aprovação de acesso ao OpenSARLab, o ambiente de processamento especializado do OpenScienceLab, desenvolvido pela ASF, da NASA. A Figura 8, adiante, extraída do OpenSARLab, ilustra exemplos de produtos obtidos pelo processamento de interferogramas por SBAS-InSAR, para refinamento analítico das movimentações progressivas do terreno que possam evidenciar, previamente, os taludes em que se verificou posterior colapso.

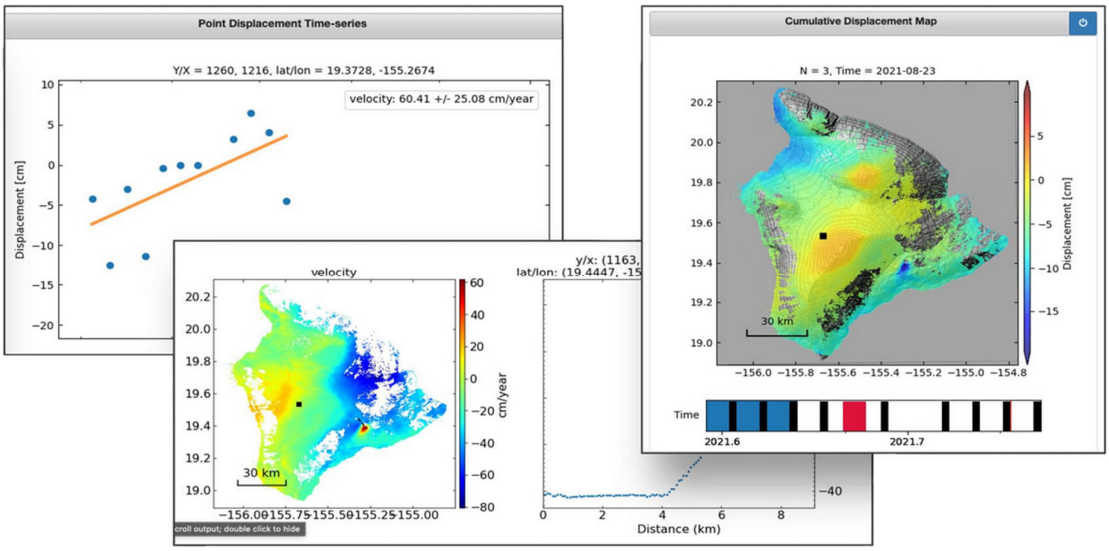


Figura 8. Exemplos de Resultados Obtidos via OpenSARLab. Fonte: NASA (2026)

5 CONCLUSÕES PARCIAIS

Esta pesquisa, cujo fluxo metodológico ainda se encontra em execução, apresentou resultados parciais satisfatórios, em conformidade aos esperados, para a etapa atual. Empreendeu-se a seleção de imagens SLC, em modo IW, efetuando-se a montagem do grafo de pares interferométricos e o pré-processamento na plataforma ASF HyP3, com geração de 281 interferogramas de baixa coerência espacial, com elevado nível de ruído e acentuado *speckle* (granulação), visto que se configura pendente a fase de Interferometria SBAS.

Foram realizadas, portanto, etapas de processamento prévio necessárias para o passo seguinte, de processamento SBAS-InSAR, no OpenSARLab, do Alaska Satellite Facility (ASF), para a geração dos mapas de velocidade (em mm/ano) e deslocamento acumulado (em mm) do terreno, relativos à Zona Urbana Central do Município de Ilhéus, Bahia, Brasil.

Pretende-se, desta maneira, estabelecer correlações quantitativas entre os deslocamentos aferidos por interferometria, e os correspondentes fatores de segurança, oriundos das Análises de Estabilidade (previstas), dos taludes avaliados, na condição mais adversa de saturação do solo. Complementarmente, almeja-se, como implicações da pesquisa, que seja atestada a viabilidade e capacidade preditiva da Interferometria SAR (InSAR), como mecanismo eficaz para auxílio ao monitoramento de taludes, em zonas de ocupação urbana. Contribuir-se-á, desta maneira, como incentivo ao aperfeiçoamento tecnológico dos setores competentes, na definição de estratégias de prevenção e gerenciamento de riscos geológicos-geotécnicos, tanto no cenário nacional, como no município de Ilhéus, possibilitando a identificação antecipada de processos de instabilização geológico-geotécnica que possam culminar em ruptura, subsidiando, portanto, a priorização de estratégias mitigadoras.

REFERÊNCIAS BIBLIOGRÁFICAS

ABNT - Associação Brasileira de Normas Técnicas (2009). NBR 11682. *Estabilidade de encostas*. Rio de Janeiro.

Araújo, D.M.R., Lima, C.A., Assis, L.E., Marques, E.A.G., Menezes, S.J.M.C., Carvalho, T.G. (2021) Avaliação da estabilidade de taludes em áreas de expansão urbana do município de Rio Piracicaba - MG, Brasil. *Revista de Engenharia Civil IMED*, 8 (2), p. 50–68.

Araújo, G.R.M.B., Corsi, A.C., Macedo, E.S., Futai, M.M. (2023) Application of digital technologies in landslide prediction, mapping and monitoring. *Soils and Rocks*, 46 (4), Special Issue: COBRAE 2022.

Assis, L.E. (2017) *Avaliação geológico-geotécnica em áreas de susceptibilidade a movimentos de massa em Rio Piracicaba (MG).* Dissertação de Mestrado, Universidade Federal de Viçosa, Viçosa, MG, Brasil, 175p.

Brasil (1979) *Lei nº 6766, de 19 de dezembro de 1979. Parcelamento do solo urbano.* Brasília, DF, Brasil.

Brasil (2012) *Lei nº 12608, de 10 de abril de 2012. Política Nacional de Proteção e Defesa Civil (PNPDEC)*. Brasília, DF, Brasil.

Clemente, B.M. (2023) *Aplicabilidade e confiabilidade do monitoramento de deslocamento em barragem de mineração por radar orbital InSAR.* Dissertação de Mestrado, Programa de Pós-Graduação em Geotecnia, Universidade de Brasília, Brasília, DF, Brasil, 103 p.

COMDEC – Coordenação Municipal de Defesa Civil de Ilhéus. (2024) *Registro de ocorrências de movimentos de massa sucedidos na área urbana de Ilhéus-BA*. *Banco de Dados Institucional*. Ilhéus, BA, Brasil.

Coutinho, R.Q., Alves, J.S., Moreira, H.B.A.F., Pontes, J.I., Aragão Júnior, W.R. (2023) Applicability of the InSAR technique for slope monitoring. *Soils and Rocks*, 46 (4), Special Issue: COBRAE 2022.

NASA Earth Science Data Systems (2026) *Open Science Lab (OpenSARLab)*. Disponível em: <https://www.earthdata.nasa.gov/data/tools/opensciencelab>. Acesso em: 05 mar. 2026.

Paradella, W.R., Mura, J.C., Gama, F.F. (2021) *Monitoramento DInSAR para mineração e geotecnia*, 1ª ed., Oficina de Textos, São Paulo, SP, Brasil.

Prado, P.A.A. (2023) *Uso de sensoriamento remoto para zoneamento de áreas susceptíveis à ocorrência de subsidência do solo e deslizamento de encostas.* Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Civil, Universidade Federal de Pernambuco, Recife, PE, Brasil.

Santos, F.F.L. (2020) *Condutividade elétrica aparente do solo determinada pelo método da resistividade utilizando diferentes frequências.* Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Agrícola, Universidade Federal de Viçosa, Viçosa, MG, Brasil.

Silva, G.P. (2020) *Metodologia de qualidade de produtos de sensoriamento remoto por radar e sua importância no mapeamento geológico-geotécnico.* Tese de Doutorado, Programa de Pós-Graduação em Engenharia Civil, Universidade Federal de Pernambuco, Recife, PE, Brasil.

Souza, W.O. (2022) *InSAR para avaliação de subsidência do solo devido a ações antrópicas sobre os recursos hídricos subterrâneos e sobre o solo na planície do Recife, Brasil.* Tese de Doutorado, Universidade Federal de Pernambuco, Recife, PE, Brasil.



contato@editoraomnisscientia.com.br
https://editoraomnisscientia.com.br/
@editora_omnis_scientia
https://www.facebook.com/omnis.scientia.9
+55 87 99920-5762



contato@editoraomnisscientia.com.br
https://editoraomnisscientia.com.br/
@editora_omnis_scientia
https://www.facebook.com/omnis.scientia.9
+55 87 99920-5762