

**USO DA CARTOGRAFIA GEOTÉCNICA DIGITAL E APRENDIZADO DE MÁQUINA NO MAPEAMENTO DE ÁREAS SUSCETÍVEIS A MOVIMENTOS GRAVITACIONAIS DE MASSA**

Thiago B. Porto<sup>1</sup>; Denise de F. S. da Silva<sup>2</sup>; Francisco H. F. do Amaral<sup>3</sup>; Maria G. Parizzi<sup>4</sup>

**Resumo** – Esta pesquisa propôs novos modelos de classificação da suscetibilidade a movimentos gravitacionais de massa por meio de técnicas de inteligência artificial (IA). A motivação principal reside no acelerado processo de urbanização e na elevada quantidade de áreas de risco existentes nos municípios. Foi desenvolvido um banco de dados integrado contendo informações sobre os fatores condicionantes de deslizamentos, além do inventário histórico de ocorrências em Belo Horizonte - MG. Cinco algoritmos de aprendizado de máquina foram utilizados: Random Forest (RF), Extremely Randomized Trees (ERT), Boosted Regression Trees (BRT), Gradient Boosted Trees (GBT) e AdaBoost (AB). Utilizou-se 15 (quinze) fatores condicionantes na modelagem. Os 5 modelos testados mostraram bom desempenho, com a RF se destacando como o mais preciso e eficaz, obtendo a maior acurácia (0,9357) e AUC-ROC (0,9884), além de alta sensibilidade (0,9558) e especificidade (0,9156). A pesquisa apresenta estratégias para o uso de IA na construção de mapas de suscetibilidade, com o intuito de minimizar a influência subjetiva dos métodos tradicionais. Embora a utilização dessas ferramentas envolva certo grau de complexidade, elas proporcionam benefícios relevantes, como a atualização constante das informações, aumento na acurácia dos mapas gerados e a possibilidade de automatizar etapas do processo. Esses progressos podem contribuir de forma expressiva para o aprimoramento da gestão de riscos geotécnicos, favorecendo a construção de ambientes urbanos mais sustentáveis.

**Abstract** – This research proposed new models for classifying susceptibility to gravitational mass movements using artificial intelligence (AI) techniques. The main motivation lies in the rapid urbanization process and the large number of risk areas present in municipalities. An integrated database was developed, containing information on landslide conditioning factors, as well as a historical inventory of occurrences in Belo Horizonte, Minas Gerais, Brazil. Five machine learning algorithms were used: Random Forest (RF), Extremely Randomized Trees (ERT), Boosted Regression Trees (BRT), Gradient Boosted Trees (GBT), and AdaBoost (AB). A total of fifteen (15) conditioning factors were used in the modeling. All five tested models showed good performance, with RF standing out as the most accurate and effective, achieving the highest accuracy (0.9357) and AUC-ROC (0.9884), as well as high sensitivity (0.9558) and specificity (0.9156). The study presents strategies for the use of AI in the development of susceptibility maps, aiming to minimize the subjective influence of traditional methods. Although the use of these tools involves a certain degree of complexity, they offer significant benefits, such as constant information updates, increased accuracy of the generated maps, and the possibility of automating process steps. These advances can significantly contribute to the improvement of geotechnical risk management, promoting the development of more sustainable urban environments.

**Palavras-Chave** – Geoprocessamento; Riscos Geológicos; Geotecnologias; Deslizamentos; IA.

<sup>1</sup> Eng. Civil, PhD, Prog. de Pós-Graduação em Geologia (PPGeol IGC UFMG), (31) 98825-8708, thiagoportoeng@gmail.com

<sup>2</sup> Eng<sup>a</sup> Geóloga, PhD, Prog. de Pós-Graduação em Geologia (PPGeol IGC UFMG), (31) 99338-9610, denisefss@yahoo.com.br

<sup>3</sup> Geógrafo, Mestre, Prog. de Pós-Graduação em Geografia (UNESP), (91) 99966-4064, helter.fernandes@unesp.br

<sup>4</sup> Geóloga, PhD, Programa de Pós-Graduação em Geologia (PPGeol IGC UFMG), (31) 3409-5424, mgparizzi18@gmail.com

## 1. INTRODUÇÃO

No Brasil as cartas geotécnicas de suscetibilidade à movimentos gravitacionais de massa são ferramentas importantes para os gestores públicos dos Municípios, Estados e União. No âmbito das cidades elas são instrumentos objetivos para auxiliar na revisão dos planos diretores municipais estabelecendo diretrizes urbanísticas voltadas para a segurança dos novos parcelamentos do solo e para o aproveitamento de agregados para a construção civil (BRASIL, 2012). Trata-se da Política Nacional de Proteção e Defesa Civil (PNPDEC) instituída pela Lei nº 12.608/2012 e aprimorada pela Lei nº 14.750/2023 (Brasil, 2023) que estabelece a obrigatoriedade do mapeamento contendo as áreas suscetíveis à ocorrência de deslizamentos para os municípios pertencentes ao cadastro nacional de áreas suscetíveis à ocorrência de deslizamentos de grande impacto, inundações bruscas ou processos geológicos ou hidrológicos, Decreto nº 10.692/2021 (BRASIL, 2021).

De acordo com a Lei nº 12.608/2012 (Brasil, 2012) a identificação e diagnóstico espacial do meio físico das áreas de riscos geológicos-geotécnicos dos municípios deve obrigatoriamente levar em conta as cartas geotécnicas, sendo estas importantes fontes de informações técnicas à elaboração, atualização e revisões de projetos de parcelamento do solo, a fim de minimizar os problemas decorrentes da implantação de loteamentos em áreas pouco favoráveis à ocupação urbana, auxiliando o poder público, portanto, na prevenção de desastres.

A suscetibilidade à movimentos gravitacionais de massa estão associados com vários atributos. Pourghasemi et al. (2018) organizou e catalogou dados de quase 500 pesquisas ao redor do planeta terra sobre zoneamento de áreas de risco de desastres e identificou cerca de 100 variáveis que estão correlacionadas com ocorrências geológicas-geotécnicas indesejáveis de deslizamentos de terra (solos e/ou rochas). A combinação ponderada desses fatores condicionantes possibilita avaliar o potencial de uma determinada área quanto a ocorrência ou não de sofrer movimentos gravitacionais de Massa. Nesse contexto, a precipitação destaca-se como um “gatilho” para a ocorrência desse tipo de sinistro (Porto, 2024).

Visto o exposto, considerando a relevância atual da temática, principalmente motivada pelas mudanças climáticas no Brasil, em particular, a maior ocorrência de eventos climáticos extremos, como chuvas intensas, esta pesquisa se propõe a realizar um mapeamento atualizado da suscetibilidade a deslizamentos na capital de Minas Gerais, Belo Horizonte. Para tanto, foram utilizados mapas temáticos de domínio público disponibilizados no INDE (Infraestrutura Nacional de Dados Espaciais) e histórico geoespacializado de ocorrências da Defesa Civil e Urbel. Embora o quantitativo de cicatrizes inventariadas nesta pesquisa é suficiente para uma análise estatística avançada, os dados da defesa civil são muito superficiais e as vezes os agentes públicos não tem formação técnica na área de geologia-geotecnia, o que prejudica o preenchimento adequado dos boletins de ocorrência/visita técnica (laudos de vistoria) aos moldes das diretrizes da NBR 11.682 (ABNT, 2009), em particular, seu anexo C, “Tipologia do movimento/Características”.

A metodologia adotada neste estudo alinha-se com as tendências contemporâneas de análise espacial, que privilegiam métodos automatizados e semi-automatizados capazes de processar grandes volumes de dados e identificar padrões complexos (Wang et al., 2021). Essa abordagem vem ganhando crescente adoção no Brasil, conforme demonstram estudos recentes como os de Barella et al. (2019), Oliveira et al. (2019) e Silva (2024), que aplicaram técnicas quantitativas inovadoras no mapeamento de suscetibilidade a deslizamentos.

A escolha do município de Belo Horizonte, capital do estado de Minas Gerais, como área de estudo desta pesquisa justifica-se por três fatores principais: (i) seu acelerado processo de urbanização, (ii) a significativa concentração de áreas de risco mapeadas e (iii) as características geomecânicas (geológicas-geotécnicas) peculiares do seu terreno, que potencializam processos erosivos e instabilidades. Essa combinação de fatores, associada à crescente demanda por informações geoespaciais precisas para o planejamento urbano, consolida a capital mineira como um laboratório natural para estudos de suscetibilidade a movimentos gravitacionais de massa, conforme apresentado nas pesquisas desenvolvidas por Parizzi (2004), Parizzi et al. (2006), Parizzi et al. (2010a), Parizzi et al. (2010b), Parizzi et al. (2011), Parizzi et al. (2013), Parizzi (2014), Reis Jr. e Parizzi (2018), Parizzi (2021), Parizi (2022) e Garcia et al. (2023).

## 2. CARACTERIZAÇÃO DA ÁREA ESTUDADA

Belo Horizonte, capital de Minas Gerais, integra a Região Metropolitana com 33 municípios e ocupa 331 km<sup>2</sup>, Figura 1. A cidade é cortada pelos rios Arrudas e do Onça, afluentes do rio das Velhas, e concentra cerca de 2,3 milhões de habitantes. Apesar do conhecimento fisiográfico e de uma legislação urbanística consolidada, enfrenta desafios como ocupação desordenada, mineração, poluição e desmatamento. A expansão urbana em encostas íngremes no sul e nordeste intensifica riscos ambientais, favorecendo a ocorrência de movimentos gravitacionais de massas, refletindo o dualismo entre crescimento econômico e impacto ambiental.

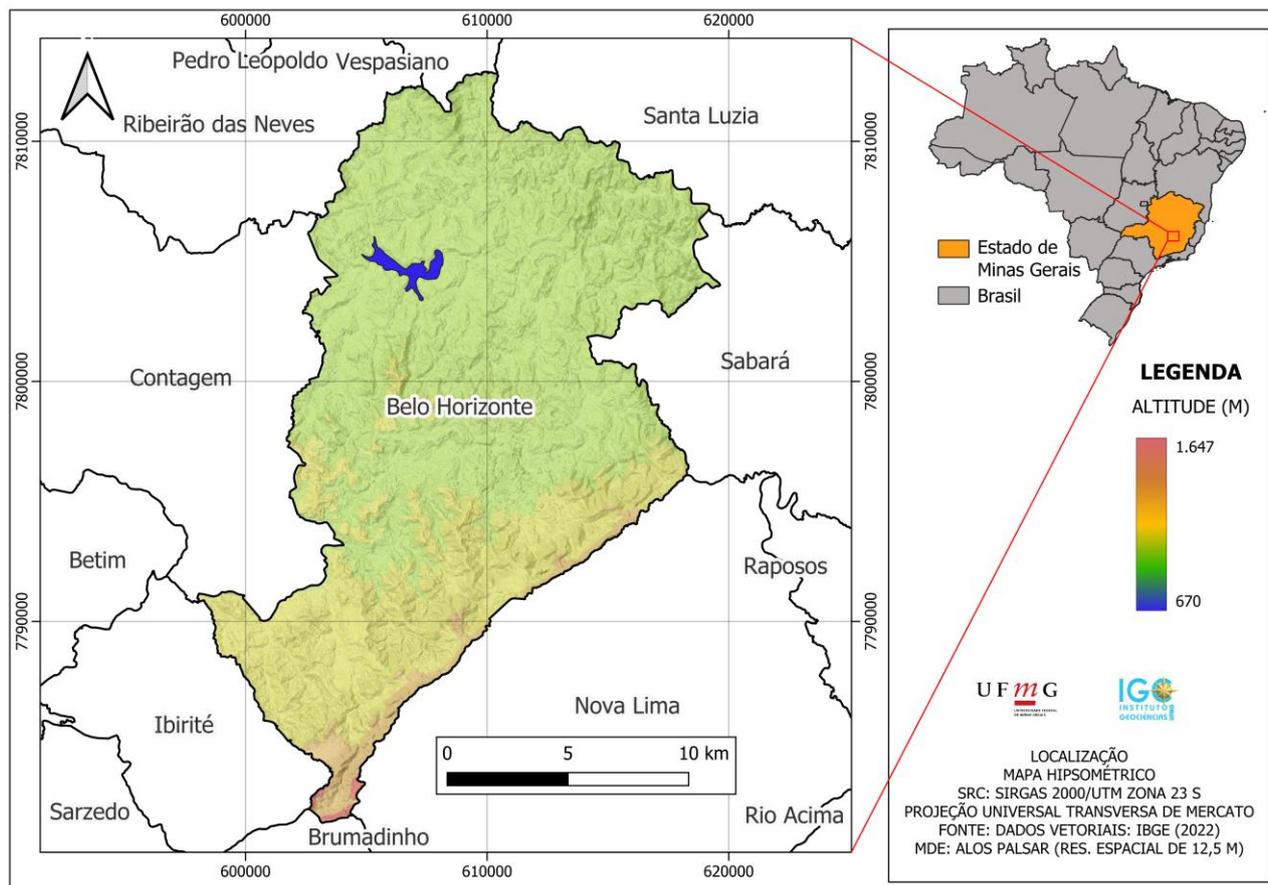


Figura 1. Localização da área de estudo. Fonte: IBGE (2022); Elaboração: Autores (2025).

### 2.1. Metodologia

A criação de um inventário do histórico das áreas atingidas por sinistros é o primeiro passo na construção de modelos de suscetibilidade baseados em algoritmos de Machine Learning (Seleem et al., 2022). A confecção do inventário de áreas atingidas foi realizada por meio da coleta de dados primários e secundários. Foram conduzidas visitas de campo para registrar coordenadas GPS e investigar fatores contribuintes entre julho e setembro de 2023. Dados históricos foram obtidos da Defesa Civil, incluindo registros de 2021, complementados por notícias e imagens de satélite para mapear ocorrências entre 2010 e 2020. No total, foram identificados 574 deslizamentos, considerados como eventos de solo devido à escassez de informações detalhadas.

No intuito de construir os conjuntos de dados de treinamento e validação necessários para o processo de modelagem foi gerado um conjunto de mesmo valor quantitativo de pontos aleatórios para a condição de não deslizamento usando o software Qgis versão 3.28 e seu recurso nativo *“gerar pontos aleatórios no interior do polígono”*. Uma vez definida em valores binários referentes

as condições de deslizamento (1) e não deslizamento (0), no ambiente de processamento do Software RStudio, dividiu-se aleatoriamente as amostras de deslizamento em dois subconjuntos; 70% foram selecionadas para o treinamento do modelo, e 30% das condições foram usados para validação do modelo. Essa abordagem de modelagem é baseada em uma classificação binária na qual desenvolve-se um modelo preditivo para distinguir entre deslizamento (1) e não deslizamento (0).

Com a coleta das amostras de ocorrência de deslizamento concluída, foi necessária a definição e confecção de uma lista de fatores que agiriam como condicionantes para o desenvolvimento da suscetibilidade a deslizamentos, geralmente esses fatores são estruturas matriciais que representam características geofísicas particulares às condições naturais e antrópicas que atuam como elementos que possuem condições de auxiliar ou dificultar a formação de áreas propensas a desabarem (Halefom et al., 2019). Tendo em vista a ausência de uma universalização quanto a definição dos fatores condicionantes devido as particularidades físico-geográficas de cada região do globo, identifica-se uma contínua demanda por analisar a maior gama de fatores físico-geográficos passíveis/capazes de influenciar os deslizamentos de terra, embora, já se tenha uma literatura significativa de revisão que apontam a recorrente adoção de alguns fatores, como "distância de drenagem, altitude, uso do solo, densidade de drenagem, lâmina d'água, precipitação e características do solo" (Halefom et al., 2019).

Ainda é relevante e oportuno se fazer uma análise de filtragem dos fatores condicionantes realmente adequados para orientar o mapeamento da suscetibilidade. Assim, esta pesquisa, baseada na literatura propõe em um nível preliminar o uso de quinze fatores condicionantes comumente observados na literatura, sendo esses: Altitude, Aspecto, Coeficiente de Escoamento Superficial (CES), Declividade, Distância das Estradas, Distância das Falhas Geológicas/Estruturais, Distância das Favelas, Distância dos Rios, Idade Geológica, Height Above the Nearest Drainage (HAND), Índice de Vegetação Melhorado (EVI), Universal Soil Loss Equation (LS-USLE), Precipitação, Standardized Precipitation Index (SPI), Topographic Wetness Index (TWI). Esses fatores, embora essenciais, apresentam distribuição espacial complexa.

Uma vez gerada a base cartográfica dos fatores condicionantes e estando disponível o inventário das áreas de deslizamento e não-deslizamento, os mesmos foram importados para o "software" RStudio versão 4.3.1. Nele, realizou-se a verificação dos fatores condicionantes utilizando da análise de multicolinearidade para seleção dos fatores condicionantes antes de modelar a suscetibilidade, visando evitar redundâncias que afetariam negativamente o desempenho preditivo dos modelos. Para isso foram empregados o Fator de Inflação de Variância ou "*Variance Inflation Factor* (VIF)" e a análise do nível de Tolerância (TOL), por serem testes eficazes para identificar e quantificar correlações entre variáveis condicionantes. Valores de VIF superiores a 5 e de TOL inferiores a 0,1 indicam a presença de multicolinearidade extrema, sendo recomendado a remoção dos fatores específicos (Hair et al., 2013). O VIF e TOL são expressos matematicamente pelas equações 1 e 2:

$$TOL = 1 - R^2 \quad (1)$$

$$VIF = 1 / TOL \quad (2)$$

Onde,  $R^2$  representa o coeficiente de determinação de uma regressão de fatores explicativos em todos os outros fatores explicativos.

De forma complementar, utilizou-se também o método não paramétrico do coeficiente de correlação de *Spearman* para determinar a força/peso (importância) da associação monotônica em pares de conjuntos e as condições de interesse para todos os quinze fatores condicionantes, adotados nesta pesquisa. O coeficiente de correlação de *Spearman*, varia de -1 a +1, indicando a força e direção da correlação. Valores próximos de 0 sugerem uma relação fraca entre os fatores e as dimensões em questão. Enquanto, coeficientes com valores acima de 0,7 sugerem a existência de correlação extrema (Tien Bui et al., 2016). A análise foi conduzida no RStudio através da função "*cor ()*", selecionando o método *spearman*.

A técnica de seleção de características "*One-R*" foi utilizada para avaliar a relevância de cada fator condicionante na predição de deslizamento. Este método é conhecido por sua simplicidade e eficácia na avaliação de características com base nas taxas de erro associadas

(Garcia-Laencina et al., 2010). No algoritmo One-R, o mérito médio (MA) de cada fator é calculado com base em regras específicas e nas taxas de erro obtidas durante o processo. Além de aumentar a qualidade dos dados de entrada, o One-R melhora a precisão da modelagem, garantindo que apenas as características mais relevantes sejam selecionadas para a análise preditiva.

Essa pesquisa, elegeu 5 (cinco) algoritmos de alta performance testados em diferentes contextos geofísicos, contudo ainda pouco explorados para deslizamentos de terra em áreas densamente povoadas. Esses modelos foram: o *Boosted Regression Trees* (BRT) que combina árvores de regressão para prever variáveis dependentes, destacando-se por sua robustez e capacidade de lidar com dados ausentes; *Gradient Boosted Trees* (GBT) que é um algoritmo de aprendizado de máquina baseado em “*boosting*”, onde cada árvore subsequente corrige erros das anteriores, usando gradiente descendente para minimizar a função de perda; *AdaBoost* (AB) uma técnica de aprendizado de conjunto que aprimora a precisão de modelos ao combinar classificadores fracos, ajustando os pesos das instâncias durante o treinamento (cada novo classificador foca em exemplos que os anteriores classificaram incorretamente, resultando em um modelo final robusto); *Extremely Randomized Trees* (ERT) que utiliza uma abordagem aleatória para escolher pontos de divisão nos nós das árvores, aumentando a aleatoriedade em comparação ao Random Forest, resultando em um modelo que reduz a variância sem aumentar significativamente o viés; *Random Forest* (RF) uma técnica de aprendizado de máquina que utiliza múltiplas árvores de decisão para formar um modelo robusto, aplicando uma votação para determinar as previsões finais. A principal vantagem do RF é a redução do sobreajuste, obtida por meio da aleatorização nas amostras de treinamento e características em cada árvore. Cada um dos cinco algoritmos foi empregado para projeto modelos geoespaciais das áreas com maior e menor suscetibilidade a deslizamentos em Belo Horizonte - MG.

Por fim, foi necessário se realizar uma avaliação de desempenho. Aqui, foram empregadas duas abordagens distintas de avaliação, categorizadas com base em métricas independentes e dependentes de um ponto de corte específico (Darabi et al., 2020). As métricas dependentes de corte incluíram: Acurácia (AC), F1-Recall, Estatística de Habilidade Verdadeira (TSS), Taxa de Classificação Incorreta (MR), Sensibilidade (Se), Especificidade (Sp), Valor de Predição Positiva (PPV), Valor de Predição Negativa (NPV) e Kappa. Essas métricas foram calculadas a partir da matriz de contingência, proporcionando uma visão abrangente do desempenho dos modelos tanto na capacidade de classificação correta quanto na identificação de falsos positivos e negativos.

Além disso, a Característica de Operação do Receptor (ROC) foi utilizada como métrica independente de corte, estimando a taxa de predição dos modelos com base nos 30% dos dados separados para validação (Rahmati et al., 2019). A Área Sob a Curva (AUC) da curva ROC foi calculada para cada modelo, sendo uma medida fundamental para avaliar a capacidade discriminatória dos modelos. Valores de AUC próximos a 1 indicam um bom desempenho na previsão da suscetibilidade a escorregamentos, enquanto valores abaixo de 0,5 refletem modelos com desempenho aleatório (Fratini et al., 2010).

### 3. RESULTADOS E DISCUSSÕES

A pesquisa utilizou uma filtragem sintética para avaliar a adequabilidade dos fatores condicionantes da suscetibilidade a deslizamentos, empregando análise de multicolinearidade com métricas tradicionais (VIF e TOL), coeficiente de correlação de Spearman e o algoritmo One-R. Os resultados mostraram que nenhuma das quinze variáveis apresentaram problemas de multicolinearidade, com os valores de VIF variando de 1,08 a 3,91 e TOL de 0,25 a 0,92. Além disso, o coeficiente de correlação de Spearman confirmou a ausência de multicolinearidade extrema entre os fatores, embora alguns, como altitude, declividade, CES e HAND, apresentaram valores acima de 0,6, sugerindo um potencial de correlação. Esses métodos reforçaram a adequação dos fatores selecionados para o modelo de suscetibilidade a deslizamentos para o município de Belo Horizonte.

Apresenta-se na Figura 2, a avaliação da multicolinearidade realizada nesta pesquisa.

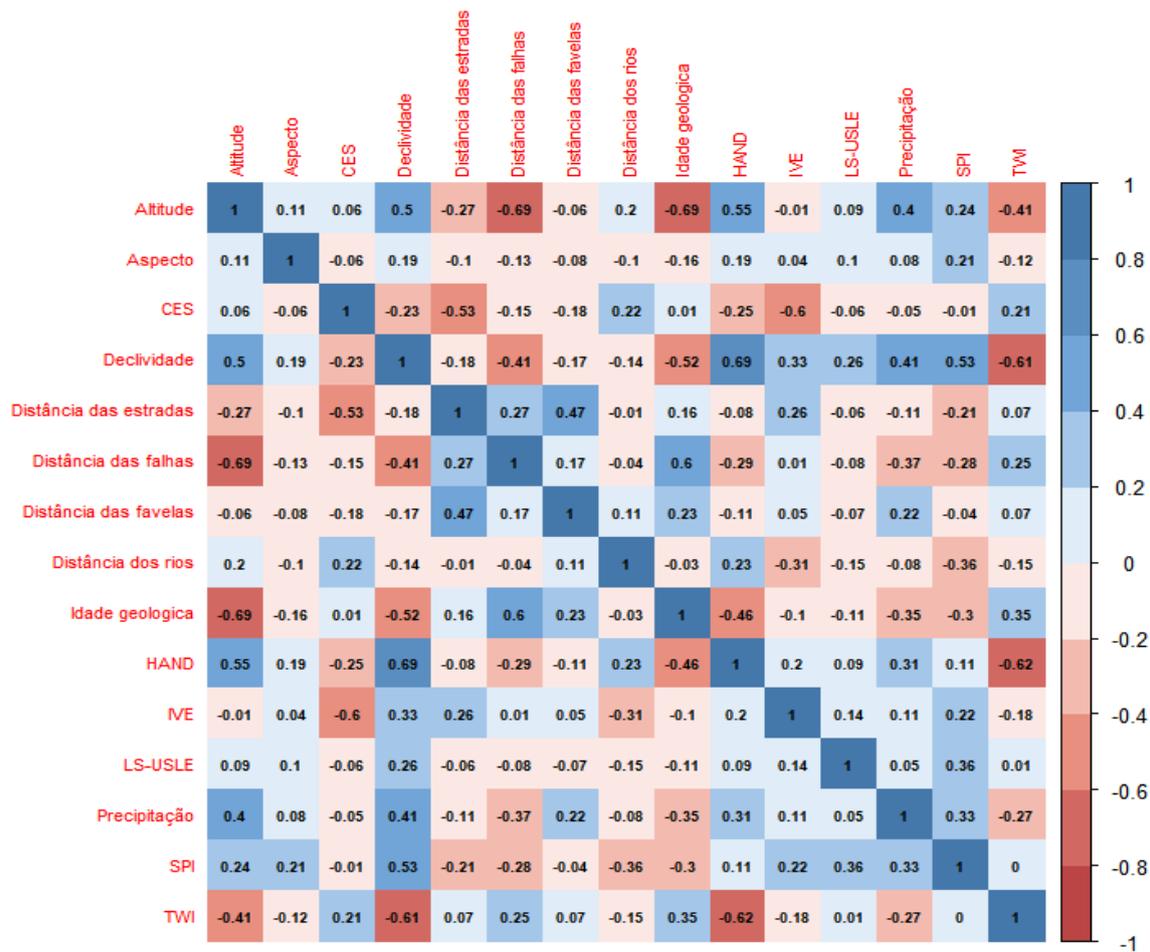


Figura 2. Avaliação da multicolinearidade pelo coeficiente de correlação de Spearman. Fonte: autores (2025)

Quanto aos resultados da análise sobre capacidade de inferência dos fatores para condicionar o processo de deslizamento, identificou-se que os valores derivados da aplicação da técnica One-R, com validação cruzada de 10 vezes, apontam que a declividade tem o maior potencial condicionante (86,329%) entre os fatores que influenciam o processo de deslizamento, seguida pela elevação (76,350%), Distância das falhas (74,403%), Idade geológica (72,844%), TWI (72,458%), HAND (71,513%), CES (67,909%), Precipitação (62,879%), IVE (62,112%), Aspecto (59,544%), LS-USLE (58,596%), Distância das favelas (56,134%), Distância dos rios (56,034%), Distância das estradas (53,662%), enquanto o SPI apresenta o menor potencial condicionante (50,142%). Contudo, todos os fatores demonstraram relevantes para o processo de suscetibilidade ao movimento gravitacional, visto que nenhum obteve valores inferiores a 20%, que foi o limite mínimo estabelecido nessa pesquisa.

A avaliação dos modelos preditivos de *Machine Learning* foi realizada utilizando diversas métricas estatísticas derivadas de matrizes de contingência binária, como Acurácia (AC), Sensibilidade (Se), Especificidade (Sp), AUC-ROC, TSS e Kappa. Os cinco modelos testados — Random Forest (RF), Extremely Randomized Trees (ERT), Boosted Regression Trees (BRT), Gradient Boosted Trees (GBT) e AdaBoost (AB) — mostraram bom desempenho, com a RF se destacando como o mais preciso e eficaz. A RF obteve a maior acurácia (0,9357) e AUC-ROC (0,9884), além de alta sensibilidade (0,9558) e especificidade (0,9156), refletindo um ótimo equilíbrio entre verdadeiros positivos e negativos, conforme apontado por estudos como o de Silva (2024), que destacam a RF como um dos modelos mais robustos em problemas espaciais complexos.

O ERT apresentou acurácia de 0,9246 e AUC-ROC de 0,9815, com destaque para sua alta sensibilidade e especificidade, valores que também são frequentemente observados em aplicações de modelagem de riscos geoespaciais (Jin et al., 2019). O BRT, com acurácia de

0,9135 e AUC-ROC de 0,9778, também demonstrou bom desempenho, o que reforça as conclusões de Friedman (2001) sobre o poder do “*boosting*” para melhorar a precisão dos modelos preditivos. O AdaBoost, com acurácia de 0,9157 e AUC-ROC de 0,9709, apresentou um equilíbrio entre precisão e capacidade preditiva, embora, como em estudos de Liu et al. (2019), tenha ficado ligeiramente atrás da RF e do ERT.

Por último, o GBT, embora com a menor acurácia (0,898), apresentou AUC-ROC de 0,9702, destacando-se na identificação de negativos, o que é relevante em contextos em que a minimização de falsos positivos é fundamental (Li et al., 2020). Em resumo, conforme demonstrado na Figura 3, todos os modelos demonstraram alta capacidade preditiva, com a RF liderando a eficiência, seguida de perto pelo ERT e BRT. Esses resultados são consistentes com a literatura existente, que reafirma a eficácia da RF em tarefas de predição geoespacial, enquanto os demais modelos, embora com desempenhos inferiores, ainda apresentam boas características para diferentes contextos de modelagem.

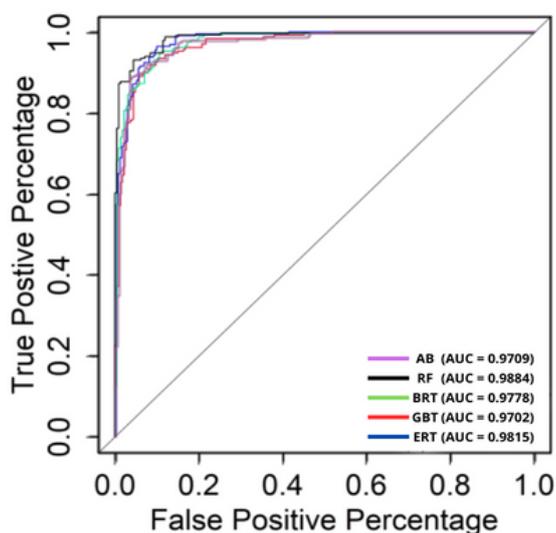


Figura 3. Resultado da avaliação da precisão com base na AUC para os cinco modelos estudados na pesquisa. Fonte: autores (2025)

Nesta pesquisa cada algoritmo estimou diferentes níveis de suscetibilidade, buscando padronizar em intervalos fixos, se categorizou a área de estudo em cinco níveis de suscetibilidade: muito baixa, baixa, moderada, alta e muito alta; com variações significativas nas coberturas de área correspondentes. Para o algoritmo *AdaBoost*, as áreas de suscetibilidade muito baixa, baixa, moderada, alta e muito alta foram estimadas em 26,7021 km<sup>2</sup> (8,10%), 54,1953 km<sup>2</sup> (16,44%), 73,6524 km<sup>2</sup> (22,34%), 75,6972 km<sup>2</sup> (22,96%) e 99,3492 km<sup>2</sup> (30,16%), respectivamente. Observa-se que uma porção considerável da área de estudo, 37,58%, está associada a zonas de suscetibilidade alta e muito alta, sugerindo um risco significativo de deslizamentos em áreas críticas.

No modelo BRT, as áreas de suscetibilidade muito baixa, baixa, moderada, alta e muito alta foram estimadas em 39,7179 km<sup>2</sup> (12,05%), 53,9586 km<sup>2</sup> (16,37%), 55,1376 km<sup>2</sup> (16,73%), 59,0211 km<sup>2</sup> (17,91%) e 121,761 km<sup>2</sup> (36,94%), respectivamente. A predominância de áreas de alta e muito alta suscetibilidade, totalizando 54,85%, destaca a importância de intervenções preventivas em uma vasta área da região de estudo. O algoritmo ERT apresentou as áreas de suscetibilidade muito baixa, baixa, moderada, alta e muito alta em 44,9055 km<sup>2</sup> (13,63%), 44,9793 km<sup>2</sup> (13,65%), 47,7099 km<sup>2</sup> (14,48%), 55,9998 km<sup>2</sup> (17,00%) e 136,0017 km<sup>2</sup> (41,24%), respectivamente. Este modelo identifica uma maior proporção de áreas com suscetibilidade muito alta, totalizando 41,24%, indicando zonas de alto risco que necessitam de monitoramento contínuo e estratégias de mitigação eficazes.

Apresenta-se na Figura 4 os cinco mapas de suscetibilidade a movimentos gravitacionais de massa desenvolvidos nesta pesquisa para o município de Belo Horizonte – MG.

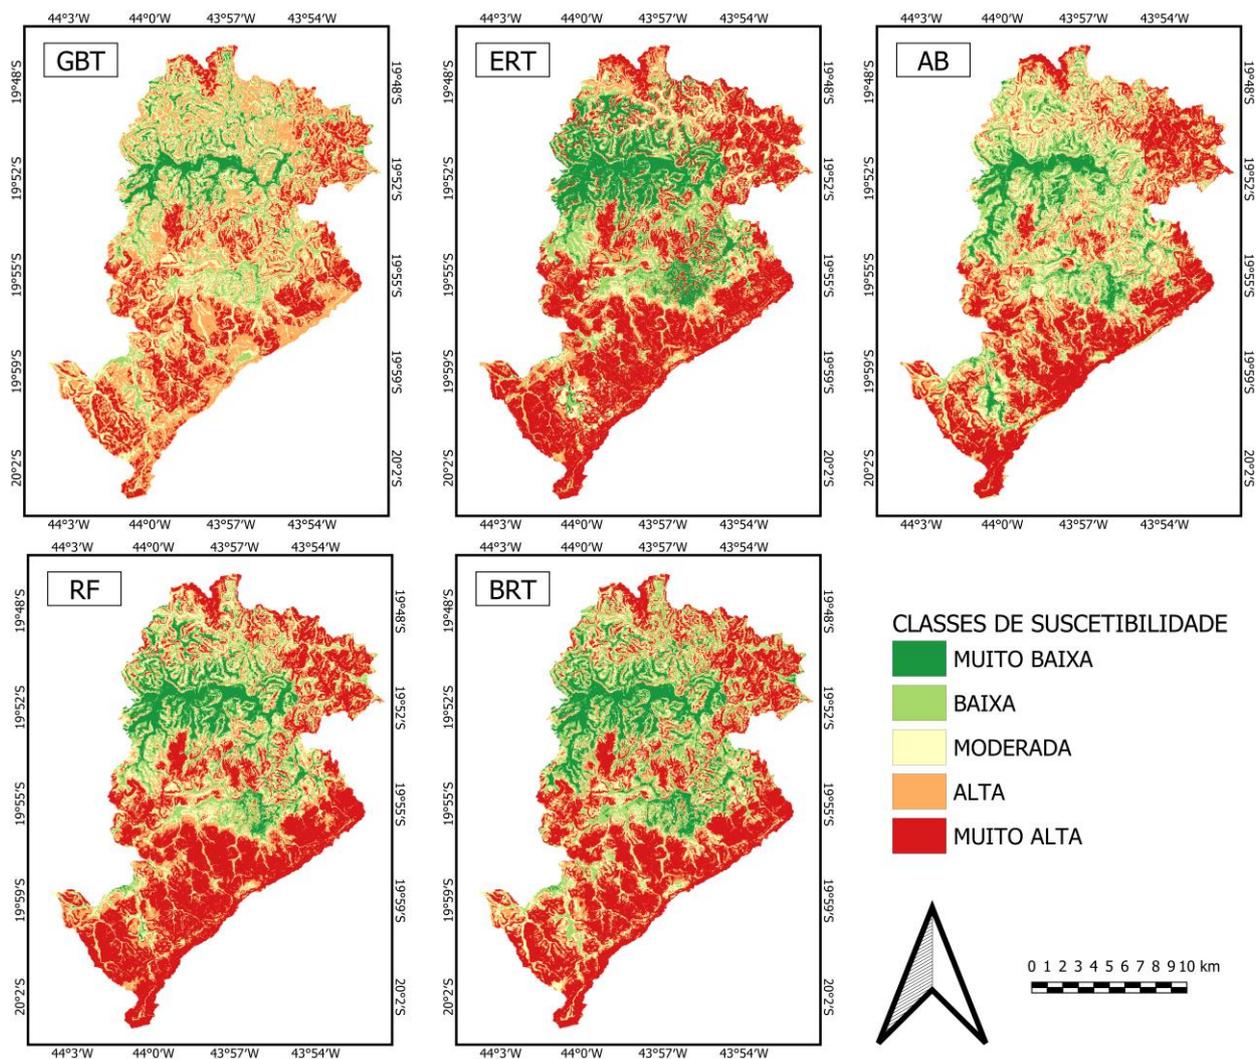


Figura 4. Mapas de suscetibilidade a deslizamentos desenvolvidos para Belo Horizonte usando diferentes modelos de *Machine Learning*: GBT, ERT, AB, RF e BRT. Fonte: autores (2025).

Para o modelo GBT, as áreas de suscetibilidade muito baixa, baixa, moderada, alta e muito alta foram calculadas em 18,5076 km<sup>2</sup> (5,62%), 44,2431 km<sup>2</sup> (13,43%), 65,8206 km<sup>2</sup> (19,98%), 77,3937 km<sup>2</sup> (23,48%) e 123,6312 km<sup>2</sup> (37,50%), respectivamente. Observa-se que 60,98% da área total é classificada como de alta a muito alta suscetibilidade, o que reforça a necessidade de políticas robustas de gestão de risco para minimizar os impactos dos deslizamentos de terra.

O modelo Random Forest (RF) estimou as áreas de suscetibilidade muito baixa, baixa, moderada, alta e muito alta em 34,1856 km<sup>2</sup> (10,37%), 44,3484 km<sup>2</sup> (13,46%), 55,3995 km<sup>2</sup> (16,81%), 65,97 km<sup>2</sup> (20,02%) e 129,6927 km<sup>2</sup> (39,34%), respectivamente. Com 59,36% da área classificada como de alta e muito alta suscetibilidade, este modelo destaca a necessidade de uma abordagem preventiva proativa para mitigar os riscos associados a deslizamentos de terra.

#### 4. CONCLUSÕES

Considerando que o diferencial desta pesquisa reside na abordagem integrada de filtragem sintética para seleção de variáveis e na avaliação comparativa de diferentes algoritmos de aprendizado de máquina, possibilitando uma análise mais robusta da suscetibilidade a deslizamentos, a categorização das áreas em cinco níveis/classes de suscetibilidade permitiu identificar zonas críticas, com até 60,98% da área de estudo estando classificada como sendo de alta e muito alta suscetibilidade. Os resultados também indicam uma boa eficácia dos modelos de *Machine Learning* na previsão da suscetibilidade a deslizamentos em áreas densamente povoadas, com destaque para o algoritmo Random Forest, que apresentou a maior acurácia

(0,9357) e AUC-ROC (0,9884). A análise dos fatores condicionantes revelou que a declividade é o principal fator de influência, seguida pela elevação e distância das falhas geológicas.

Apesar dos resultados positivos, algumas limitações devem ser consideradas, dentre essas, a dependência de dados de entrada com teor de qualidade da informação gerada. Além disso, a sensibilidade dos modelos pode variar conforme a escala e o contexto geográfico, o que reforça a necessidade de estudos complementares para aprimorar a aplicabilidade para escalas de maior detalhamento.

Finalmente, esta pesquisa poderá ser aprimorada com a inclusão de um maior banco de dados de cicatrizes de movimentos gravitacionais de massa, inclusive com a descrição das características físicas das ocorrências registradas. Reitera-se aqui a necessidade de uma contínua atualização das cartas geotécnicas de suscetibilidade à deslizamentos para subsidiar a atualização de Planos Municipais de Redução de Risco (PMRR), em consonância com a Política Nacional de Proteção e Defesa Civil (PNPDEC).

## AGRADECIMENTOS

Os autores agradecem ao grupo de pesquisa PLANGEA e ao PPGeol IGC UFMG pelo suporte técnico e acadêmico ao longo do desenvolvimento deste trabalho. A troca de conhecimento, o acesso a infraestrutura computacional e as discussões promovidas pelo grupo/programa foram fundamentais para a realização deste estudo.

## REFERÊNCIAS

- ABNT (2009) NBR 11.682, *Estabilidade de Encostas*. Rio de Janeiro - RJ.
- BARELLA, C. F. et al. (2019) "A comparative analysis of statistical landslide susceptibility mapping in the southeast region of Minas Gerais state, Brazil". *Bull Eng Geol Environ* 78, 3205–3221.
- Brasil (2012) Lei Nº 12.608, de 10 de abril de 2012.
- Brasil (2021) Decreto Nº 10.692, de 3 de maio de 2021.
- Brasil (2023) Lei Nº 14.750, de 12 de dezembro de 2023.
- DARABI, H. et al. (2020) "Urban flood risk mapping using data-driven geospatial techniques". *Hydrology Research*, 51.1: 127-142.
- FRATTINI, P. et al. (2010) "Techniques for evaluating the performance of landslide susceptibility models". *Eng. Geol*, 111: 62–72.
- FRIEDMAN, J. H. (2001) *Greedy function approximation: A gradient boosting machine*. *Annals of Statistics*, 29(5), 1189-1232.
- GARCIA, L. C. et al. (2023) "Gestão de risco, vulnerabilidade ambiental e a questão climática na gestão metropolitana". *Cadernos Metrópole*, 25(58), 875–897.
- GARCÍA-LAENCINA, P. J. et al. (2010) "Pattern classification with missing data: a review". *Neural Computing and Applications*, 19, 263-282.
- HAIR, J. F. et al. (2013) *Multivariate Data Analysis: Pearson New International Edition*. 7th ed. Pearson Education Limited.
- HALEFOM, A. et al. (2019) "GIS-based MCDA model to assess erosion sensitivity in Gumara watershed, Blue Nile, Basin Ethiopia". *Asian J Appl Sci*, v. 12, p. 61-70.
- JIN, X. et al. (2019) "Mapping landslide susceptibility at the Three Gorges Reservoir, China, using gradient boosting decision tree, random forest, and information value models". *Landslides*, 16(2), 321-332.
- LI, W. et al. (2020) "Application of gradient boosting decision tree and random forest in landslide susceptibility mapping". *Geomatics, Natural Hazards and Risk*, 11(1), 446-468.

- LIU, P. et al. (2019) "Landslide susceptibility mapping using ensemble methods: A case study in the Three Gorges Reservoir area, China". *Journal of Mountain Science*, 16(3), 573-588.
- OLIVEIRA, G. G. et al. (2019) "Random Forest and artificial neural networks in landslide susceptibility modeling: a case study of the Fão River Basin, Southern Brazil". *Nat Hazards* 99, 1049–1073.
- PARIZZI, M. G. (2004) Condicionantes e mecanismos de ruptura em taludes da região metropolitana de Belo Horizonte, MG. 211p. Tese (Doutorado em Evolução Crustal e Recursos Naturais) - Departamento de Geologia da Escola de Minas da Universidade Federal de Ouro Preto, Ouro Preto.
- PARIZZI, M. G. (2014) Desastres Naturais e Induzidos e o Risco Urbano. *GEONOMOS*, v. 22, n. 1, p. 1-9.
- PARIZZI, M. G. (2021) "Riscos geológicos e hidrológicos no município de Belo Horizonte, MG". *Revista Brasileira de Geologia de Engenharia e Ambiental (RBGEA)*, v. 11, p. 145-161.
- PARIZZI, M. G. (2022) Panorama dos desastres climatológicos, hidrológicos, meteorológicos e geológicos durante o período de 2010 - 2019. *Derbyana*, v. 43, p. 01-18.
- PARIZZI, M. G. et al. (2006) A aplicação do GPR na análise de estabilidade de taludes. *GEOTECNIA (LISBOA)*, Portugal, v. 106, p. 23-56, 2006.
- PARIZZI, M. G. et al. (2010a) Mapa de unidade geotécnicas da Região Metropolitana de Belo Horizonte. RMBH. 21p. In Programa Diretor de Desenvolvimento Integrado da RMBH: Relatório de Geoprocessamento.
- PARIZZI, M. G. et al. (2010b). Correlações entre chuvas e movimentos de massa no município de Belo Horizonte, MG. *Geografias (UFMG)*, v. 06, n.2, p. 49-68.
- PARIZZI, M. G. et al. (2011) Processos de movimentos de massa em Belo Horizonte, MG. *GEOGRAFIAS (UFMG)*, v. 7, n.1, p. 58-87.
- PARIZZI, M. G. et al. (2013) Retroanálise de escorregamento de talude na área de risco do Taquaril, Belo Horizonte, MG. *GEONOMOS*, p. 2-39.
- PORTO, T. B. (2024) Mapeamento de Suscetibilidade à Deslizamentos nos Municípios de Belo Horizonte, Contagem, Nova Lima e Sabará. Relatório Técnico de Atividades da Residência Pós-Doutoral. Programa de Pós-Graduação em Geologia do Instituto de Geociências da Universidade Federal de Minas Gerais (IGC UFMG). Supervisão: Maria Giovana Parizzi. Belo Horizonte, Minas Gerais, Brasil.
- POURGHASEMI, H. R. et al. (2018). "Analysis and evaluation of landslide susceptibility: a review on articles published during 2005–2016". *Arabian Journal of Geosciences*, 11 (9).
- RAHMATI, O. et al. (2019) "PMT: new analytical framework for automated evaluation of geo-environmental modelling approaches". *Sci. Total Environ*, 664: 296–311.
- REIS JUNIOR, W.; PARIZZI, M. G. (2018) Caracterização das unidades geotécnicas da porção leste da Região Metropolitana de Belo Horizonte – MG. *Revista Geonomos*, vol. 26, no. 2, pp. 23-30.
- SELEEM, O. Et al. (2022) "Towards urban flood susceptibility mapping using data-driven models in Berlin, Germany". *Geomatics, Natural Hazards and Risk*, 13(1): 1640-1662.
- SILVA, D. F. S. (2024) Proposta metodológica para a avaliação de suscetibilidade a escorregamentos: contribuições do aprendizado de máquina no município de Belo Horizonte, MG. 2024. 405 f. Tese (Doutorado em Geologia) – Instituto de Geociências da Universidade Federal de Minas Gerais, Belo Horizonte.
- TIEN BUI, D. et al. (2016) "GIS-based modeling of rainfall-induced landslides using data mining-based functional trees classifier with AdaBoost, Bagging, and MultiBoost ensemble frameworks". *Environmental Earth Sciences*, 75, 1-22.
- WANG, H. et al. (2021) "Landslide identification using machine learning". *Geosci. Front.* v.12, 351–364.