

Artigo de Pesquisa

Mapeamento da suscetibilidade a deslizamentos utilizando regressão logística, florestas aleatórias e redes neurais artificiais: estudo de caso em Mariana/MG, Brasil

Landslide susceptibility mapping using logistic regression, random forests, and artificial neural networks: a case study in Mariana/MG, Brazil

Mateus Oliveira Xavier ¹ e César Falcão Barella ²

- ¹ Universidade Federal de Ouro Preto, Departamento de Arquitetura e Urbanismo, Ouro Preto, Brasil. mateus.xavier@ufop.edu.br. ORCID: <https://orcid.org/0000-0002-3441-8208>
- ² Universidade Federal de Ouro Preto, Departamento de Engenharia Ambiental, Ouro Preto, Brasil. cesarbarella@ufop.edu.br. ORCID: <https://orcid.org/0000-0001-6005-9125>

Recebido: 08/05/2024; Aceito: 30/09/2024; Publicado: 05/11/2024

Resumo: O mapeamento da suscetibilidade a deslizamentos (MSD) desempenha importante papel na gestão de riscos. Este estudo avaliou as capacidades preditivas de três abordagens de aprendizado de máquina (ML) aplicadas ao MSD: regressão logística (RL), florestas aleatórias (FA) e redes neurais artificiais (RNA). O estudo foi realizado em uma localidade montanhosa de Mariana/MG, Brasil. Inicialmente, um inventário pontual com 364 deslizamentos e 364 regiões estáveis foi particionado aleatoriamente na proporção de 70% para treinamento e 30% para teste dos modelos. Nove fatores condicionantes aos deslizamentos (FCD), hierarquizados pelo ganho de informação (GI), foram considerados: declividade (GI=0,486), geomorfologia (GI=0,235), índice topográfico de umidade - TWI (GI=0,138), litologia (GI=0,077), orientação das vertentes (GI=0,067), índice de posição topográfica - TPI (GI=0,052), distância da rede de drenagem (GI=0,032), curvatura das vertentes (GI=0,029), distância das vias (GI=0,024). A avaliação da área abaixo da curva (AUC-ROC) e das taxas de eficiência da classificação na alta (TE_i^{AS}) e na baixa (TE_i^{BS}) suscetibilidade foram utilizadas para comparar os resultados das abordagens. Os resultados demonstraram que, embora FA (AUC-ROC=0,947, TE_i^{AS} =6,808, TE_i^{BS} =0,030) tenha resultados ligeiramente melhores que RL (AUC-ROC=0,936, TE_i^{AS} =5,695, TE_i^{BS} =0,050) e RNA (AUC-ROC=0,934, TE_i^{AS} =6,495, TE_i^{BS} =0,060), todas as abordagens demonstraram alta capacidade preditiva em identificar áreas suscetíveis a deslizamentos.

Palavras-chave: Aprendizado de máquina; Análise preditiva; Fatores condicionantes aos deslizamentos; Gestão de riscos.

Abstract: The landslide susceptibility mapping (LSM) plays an important role in risk management. This study evaluated the predictive capabilities of three machine learning (ML) approaches applied to LSM: logistic regression (LR), random forests (RF), and artificial neural networks (ANN). The study was conducted in a mountainous region of Mariana/MG, Brazil. Initially, a point inventory with 364 landslides and 364 stable regions was randomly partitioned in a 70% training and 30% testing ratio for the models. Nine landslide conditioning factors (LCF), ranked by information gain (IG), were considered: slope angle (IG=0.486), geomorphology (IG=0.235), topographic wetness index - TWI (IG=0.138), lithology (IG=0.077), slope orientation (IG=0.067), topographic position index - TPI (IG=0.052), distance from drainage (IG=0.032), slope curvature (IG=0.029) and the distance from roads (IG=0.024). The evaluation of the area under the curve (AUC-ROC) and the classification efficiency rates in high (ER_i^{HS}) and low (ER_i^{LS}) susceptibility were used to compare the results of the approaches. The results demonstrated that although RF (AUC-ROC=0,947, ER_i^{HS} =6,808, ER_i^{LS} =0,030) slightly outperformed LR (AUC-ROC=0,936, ER_i^{HS} =5,695, ER_i^{LS} =0,050) and ANN (AUC-ROC=0,934, ER_i^{HS} =6,495, ER_i^{LS} =0,060), all the approaches exhibited high predictive capability in identifying areas susceptible to landslides.

Keywords: Machine learning; Predictive analysis; Landslide conditioning factors; Risk management.

1. Introdução

Os deslizamentos são um dos eventos geodinâmicos mais recorrentes ao redor do mundo, causando anualmente extensos prejuízos ambientais e socioeconômicos significativos (CHEN; YU; LI, 2018; HUANG; LI, 2011; TANOLI et al., 2023; TZOUVARAS, 2021). No contexto da América Latina e Caribe, o Brasil foi o país com o maior número de registros de deslizamentos com vítimas fatais entre os anos de 2004 e 2013 (SEPÚLVEDA; PETLEY, 2015). A maioria desses incidentes está associada a precipitações intensas concentradas nos meses de verão, especialmente em áreas montanhosas e com declividade acentuada (AHRENDT; ZUQUETTE, 2003; HIRYE et al., 2023; TIAGO DAMAS et al., 2017).

A expansão urbana desordenada em áreas susceptíveis a processos geodinâmicos, somada ao baixo padrão construtivo das edificações e à falta de políticas públicas habitacionais adequadas, emergem como fatores dos elevados danos causados pelos deslizamentos no Brasil. Portanto, é de extrema importância que essas localidades disponham de ferramentas que considerem a suscetibilidade a deslizamentos, bem como avaliações de risco e perigo, para o gerenciamento eficiente e seguro do uso e cobertura da terra (FELL et al., 2008). Nesse contexto, os mapas de suscetibilidade a deslizamentos são elementos fundamentais para a prevenção e mitigação dos impactos gerados pelos deslizamentos, auxiliando planejadores, administradores locais e tomadores de decisões no planejamento de uso e cobertura da terra (KAVZOGLU; SAHIN; COLKESEN, 2014).

O mapeamento da suscetibilidade a deslizamentos (MSD) é uma metodologia de avaliação gráfica da probabilidade espacial de ocorrência desses eventos a partir das características locais da região investigada (ALEOTTI; CHOWDHURY, 1999; FELL et al., 2008). Desde os anos 1970, inúmeras metodologias vêm sendo desenvolvidas para esse propósito (KAVZOGLU; TEKE, 2022; MAURIZIO; MARIA, 2012), sendo elas usualmente classificadas em (ALEOTTI; CHOWDHURY, 1999; SOETERS; VAN WESTEN, 1996; YOUSSEF; POURGHASEMI, 2021): (I) mapeamentos geomorfológicos *in loco* (e.g. CARVALHO et al., 2013; SOBREIRA et al., 2013; ZIMMERMANN; BICHSEL; KIENHOLZ, 1986), em que, a partir da interpretação de especialistas, as classes de suscetibilidade são definidas no próprio campo, o que proporciona uma abordagem simples e direta, mas, em contrapartida, extremamente subjetiva e dependente da experiência dos especialistas (GUZZETTI et al., 1999; SOETERS; VAN WESTEN, 1996); (II) métodos heurísticos (e.g. BLAIS-STEVENSON; BEHNIA, 2016; ELMOULAT et al., 2021; RUFF; CZURDA, 2008; STANLEY; KIRSCHBAUM, 2017), cujos mapas desenvolvidos resultam da hierarquização e ponderação dos processos desencadeadores dos deslizamentos através da álgebra de mapas, sendo o resultado final vinculado à relevância atribuída a cada um desses processos (FERNANDES et al., 2001; TSAI et al., 2013); (III) abordagens determinísticas de base física (e.g. ARMAŞ et al., 2014; DO PINHO; AUGUSTO FILHO, 2022; JOVANČEVIC et al., 2018; MICHEL; KOBIYAMA; GOERL, 2014), baseadas nas relações físicas e matemáticas que definem a estabilidade das encostas, correlacionando dados geométricos com parâmetros geotécnicos de resistência por meio de simulações que integram modelos hidrológicos e de estabilidade de encostas. Apesar de proporcionarem resultados robustos, a complexidade na obtenção e espacialização dos parâmetros geotécnicos pode limitar a aplicação desses modelos a regiões restritas em área e mais homogêneas (ALEOTTI; CHOWDHURY, 1999; YILMAZ, 2009); (IV) métodos estatísticos baseados em dados, a partir da relação estatística entre inventários de deslizamentos e seus fatores condicionantes, em que a suscetibilidade é estimada com a identificação de padrões na distribuição espacial de deslizamentos passados, relacionando esses registros de maneira sistemática aos fatores condicionantes adotados pelos modelos para a previsão de novas ocorrências (CHACÓN et al., 2006; GUZZETTI et al., 1999; REICHENBACH et al., 2018).

Diversas abordagens estatísticas, bivariadas, multivariadas e, mais recentemente, de aprendizado de máquina, têm sido aplicadas no MSD em diferentes partes do mundo (e.g. ALEOTTI; CHOWDHURY, 1999; CALDERÓN-GUEVARA et al., 2022; COCO et al., 2021; EIRAS et al., 2021; MURILLO-GARCÍA; ALCÁNTARA-AYALA, 2015; NOHANI et al., 2019; PIMIENTO, 2010; PRADHAN; SEENI; KALANTAR, 2017; SANTACANA et al., 2003; SOETERS; VAN WESTEN, 1996). Algumas das metodologias estatísticas mais comumente utilizadas incluem a razão de verossimilhança, o valor informativo, pesos de evidência, funções de favorabilidade, análise discriminante, regressão logística (RL), florestas aleatórias (FA) e redes neurais artificiais (RNA) (COROMINAS et al., 2014).

Nesse contexto, conforme Barella, Sobreira e Zêzere (2019), diferentes abordagens de MSD já foram comparadas por diferentes autores (e.g. AKGUN, 2012; CHEN et al., 2023; LIU et al., 2022; MERGHADI et al., 2020; PHAM et al., 2016; WANG et al., 2021; YOUSSEF; POURGHASEMI, 2021). Comparações são importantes para identificação das vantagens e limitações de cada método, permitindo aos pesquisadores selecionarem as

abordagens mais adequadas às características e particularidades das regiões investigadas, contribuindo para o avanço das metodologias, promovendo o desenvolvimento de abordagens cada vez mais robustas e refinadas.

Nos últimos anos, têm se destacado as publicações que abordam avaliações e comparações entre métodos estatísticos de aprendizado de máquina (*machine learning* - ML) para o MSD (e.g. JENNIFER, 2022; LIU et al., 2022; OLIVEIRA et al., 2019; YI et al., 2019). Algumas das vantagens desses métodos são: embasamento estatístico objetivo, reprodutibilidade, capacidade de atualização contínua, habilidade para lidar com extensos conjuntos de dados e resultados robustos (SIDUMO; SONONO; TAKAIDZA, 2022; YOUSSEF; POURGHASEMI, 2021).

Neste trabalho, conduzimos o treinamento, a avaliação e a comparação de três técnicas estatísticas de ML – FA, RL e RNA – para a elaboração de mapas de suscetibilidade a deslizamentos em uma região montanhosa do estado de Minas Gerais, localizada no sudeste do Brasil. Para este propósito e para cada técnica utilizada, selecionamos, amostramos, classificamos e filtramos nove fatores que influenciam os deslizamentos. As amostragens foram realizadas através de um inventário de deslizamentos e áreas estáveis construído por fotointerpretação e trabalhos de campo. Ao término do estudo, avaliamos a taxa de validação das cartas de suscetibilidade produzidas pelo melhor modelo de cada técnica. Assim, o objetivo desta pesquisa concentrou-se em determinar se as técnicas de ML escolhidas são apropriadas para modelar e mapear a suscetibilidade a deslizamentos na região investigada.

2. Área de Estudo

A área de estudo, ilustrada na Figura 1 pela composição colorida do satélite Sentinel-2 em 28 de abril de 2020, está inserida na porção sudeste da Bacia do Rio Doce e ao sudeste do município de Mariana, historicamente conhecido como a primeira capital do estado de Minas Gerais, Brasil. Geograficamente, se estende entre as latitudes 20°22'S e 20°26'S e longitudes 43°13'W e 43°18'W, englobando, a noroeste, o distrito rural de Cachoeira do Brumado.

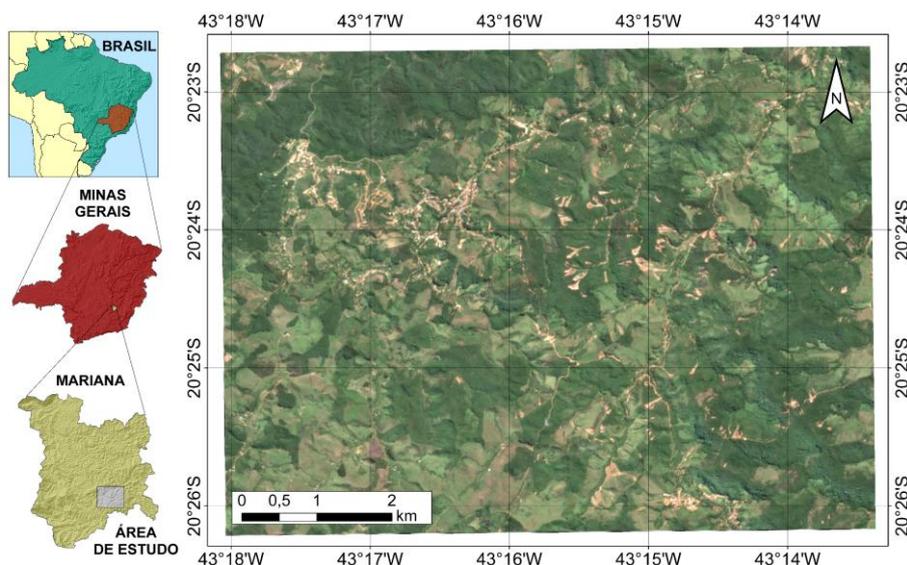


Figura 1. Composição colorida do satélite Sentinel-2 para a área de estudo em 28 de abril de 2020

O clima é majoritariamente úmido, com uma temperatura média anual de aproximadamente 20°C e pico de precipitações nos meses de verão (SOUZA et al., 2006). De acordo com o Centro Nacional de Monitoramento e Alertas de Desastres Naturais (CEMADEN, 2024), a região já foi alvo de chuvas intensas, com destaque para o primeiro trimestre de 2020, quando ocorreram intensas precipitações decorrentes da atuação da Zona de Convergência do Atlântico Sul e da passagens de frentes frias pela Bacia do Rio Doce (LOTT et al., 2021). Como consequência, foram acumulados 191 mm de precipitação entre os dias 6 e 13 de fevereiro, com um pico de 51,6 mm na madrugada do dia 13. Esse episódio levou ao desencadeamento de 364 deslizamentos simultâneos e predominantemente translacionais, cujos volumes variaram de 11 a 68.235 m³, que foram identificados por fotointerpretação e trabalhos de campo.

Geologicamente, a área é composta por solos lateríticos, derivados de rochas gnáissicas, com transições da cobertura vegetal entre o cerrado e a mata atlântica, apresentando uma diversidade de gramíneas, ciperáceas,

pastos e florestas de variadas alturas (BATISTA, 2006; SOUZA, 2004). O relevo é predominantemente montanhoso, com regiões que apresentam amplitudes e declividades acentuadas. Suas altitudes variam entre 486 e 938 metros acima do nível do mar, com uma declividade média aproximada de 21° e máxima de 68°. Por fim, a área de estudo está próxima a uma densa rede de drenagem natural, incluindo o Córrego da Cachoeira do Brumado. Em condições de chuvas intensas, essa rede hidrográfica contribui para a saturação dos solos, sendo este um importante fator desencadeador de deslizamentos na região.

3. Materiais e Métodos

Este artigo apresenta e compara três abordagens de ML para produzir cartas de suscetibilidade a deslizamentos. O processamento, treinamento e teste dos modelos foram conduzidos com o software Orange Data Mining 3.34.0 (DEMSAR et al., 2013), enquanto a manipulação de dados espaciais ocorreu no Qgis 3.12.3-București (QGIS DEVELOPMENT TEAM, 2020). O Datum SIRGAS2000 foi adotado em todas as etapas de geoprocessamento. Os dados utilizados incluíram informações coletadas em trabalhos de campo, imagens de satélite, mapa geológico em escala 1:25.000 e mapa topográfico em escala 1:10.000. A metodologia adotada no estudo é ilustrada na Figura 2.

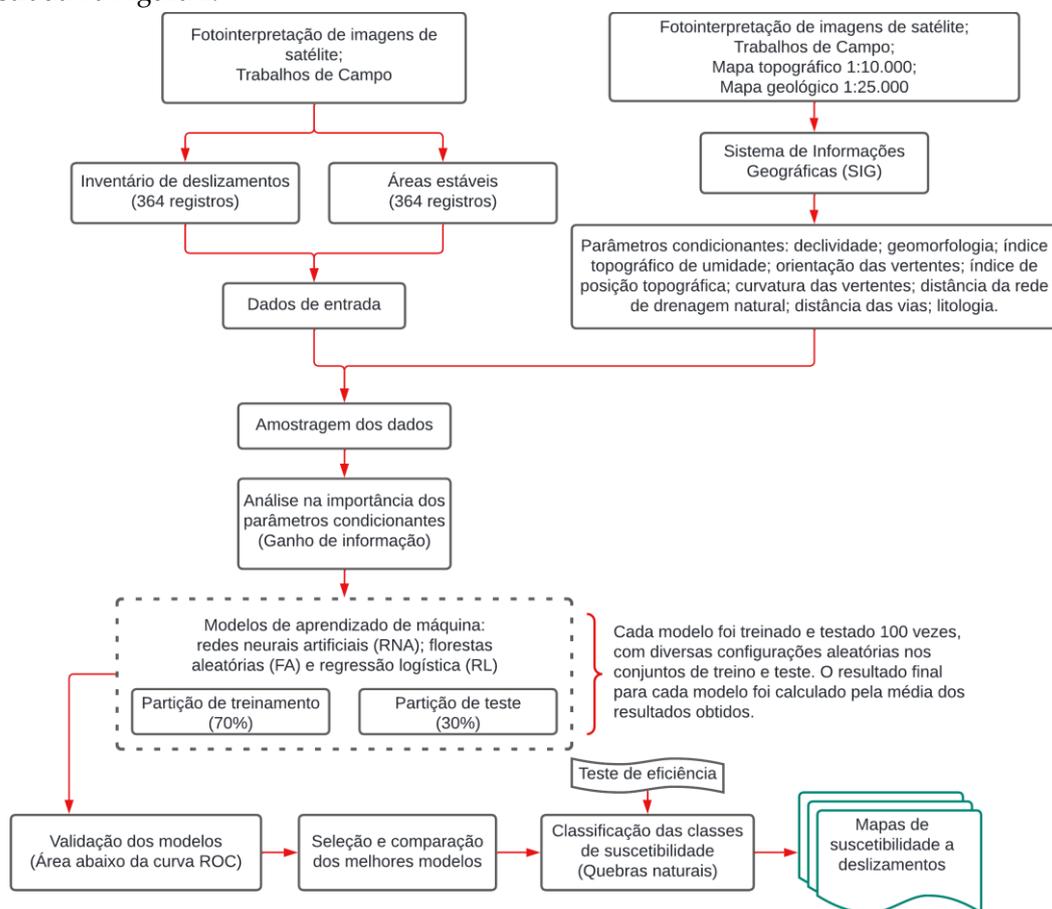


Figura 2. Fluxograma do estudo apresentando a metodologia adotada

3.1. Inventário de deslizamentos e de áreas estáveis

Para modelar a suscetibilidade a deslizamentos através de técnicas de ML, é necessário contar com um conjunto de dados de entrada que contemple registros de deslizamentos passados e de áreas consideradas estáveis (sem deslizamentos). Esse conjunto de dados deve amostrar os fatores condicionantes aos deslizamentos (FCD) para o treinamento e a testagem dos modelos (BORGA et al., 1998). Nessa situação, assumimos que novos eventos tendem a ocorrer em áreas com características semelhantes às das regiões afetadas anteriormente (ALEOTTI; CHOWDHURY, 1999; FELL et al., 2008; GUZZETTI et al., 1999).

A elaboração dos inventários de deslizamentos pode ser conduzida por meio de uma variedade de técnicas, abrangendo desde trabalhos de campo e pesquisa em registros históricos até a fotointerpretação de imagens aéreas

(GALLI et al., 2008; GUZZETTI et al., 2000). Estas metodologias podem ser aplicadas de forma isolada ou combinadas, proporcionando uma abordagem integrada na identificação dos deslizamentos. Assim, por meio de trabalhos de campo e fotointerpretação de imagens de satélite, construímos um inventário com 364 pontos de deslizamentos e 364 pontos representativos de áreas estáveis dentro da área de estudo (Figura 3). Para identificação dessas regiões, utilizamos uma composição colorida das bandas do espectro visível (vermelho, verde e azul), nível *Bottom-of-Atmosphere* (BOA), da missão Sentinel-2 da Agência Espacial Europeia (ESA), adquiridas em 28 de abril de 2020, com uma cobertura de nuvens abaixo a 4,8% e 10 m de resolução espacial. Adicionalmente, verificamos visualmente alguns deslizamentos menores identificados em campo usando as plataformas Google Earth Pro e Microsoft Bing Maps, que fornecem uma resolução espacial inferior a 1 m. Para a construção do inventário, lançamos um vetor pontual na zona de ruptura de cada uma das 364 feições de deslizamentos identificadas. Em seguida, distribuímos 364 pontos aleatoriamente nas áreas restantes da região de estudo, com a finalidade de representarem as áreas estáveis.

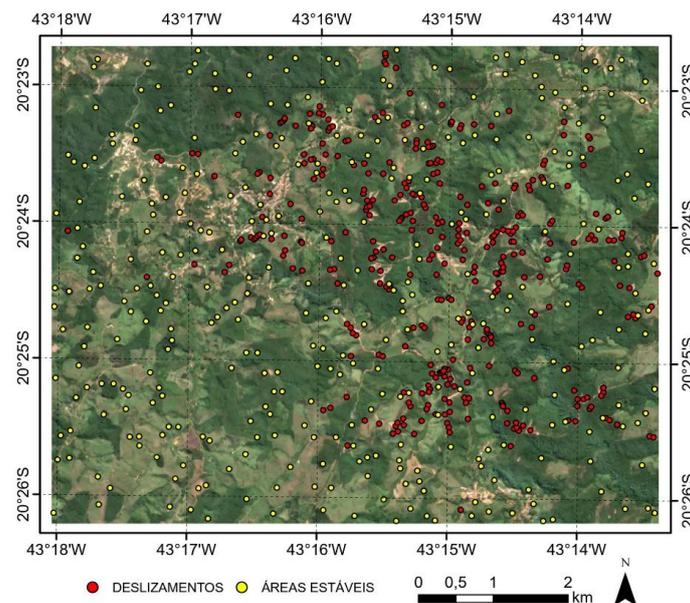


Figura 3. Inventário de deslizamentos e de áreas estáveis

Por fim, com as variáveis dependentes definidas na proporção de 1:1 (instáveis:estáveis), procedeu-se a subdivisão do conjunto de dados de entrada em um subgrupo para a construção (treino) dos modelos e outro para a validação (teste) dos resultados. Para a modelagem da suscetibilidade a deslizamentos não existe uma predefinição padrão para a categorização dos dados (YOUSSEF; POURGHASEMI, 2021). Na literatura, é comum a adoção da divisão de 70% para treinamento e 30% para teste (e.g. DAO et al., 2020; PHAM et al., 2016; SHAHABI et al., 2023), a qual foi adotada nesse trabalho. Esse procedimento configura a técnica de particionamento dos dados mais empregada nos modelos de suscetibilidade a escorregamentos baseados em dados (LIMA et al., 2022). Para garantir robustez, repetimos essa divisão de treinamento e teste 100 vezes para cada modelo, obtendo os resultados finais a partir da validação de todos resultados individuais das iterações simuladas.

3.2. Fatores Condicionantes aos Deslizamentos (FCD)

A escolha dos FCD para a modelagem da suscetibilidade é de extrema importância, pois pode impactar diretamente na precisão e confiabilidade dos resultados. Embora não haja uma diretriz específica para essa seleção, é importante que os FCD escolhidos sejam representativos das características da área de estudo e dos deslizamentos em questão (CHEN; POURGHASEMI; NAGHIBI, 2018; XU et al., 2013). Além disso, é essencial que esses fatores tenham uma escala de análise compatível com os objetivos da pesquisa (SHIRANI; PASANDI; ARABAMERI, 2018). Em nosso estudo, optamos por nove FCD (Figura 4), dos quais sete foram extraídos do modelo digital de terreno (MDT) derivado de mapa topográfico na escala de 1:10.000, abrangendo declividade, geomorfologia, índice topográfico de umidade (*Topographic Wetness Index* - TWI), orientação das vertentes, índice de posição topográfica (*Topographic Position Index* - TPI), curvatura das vertentes e distância da rede de drenagem

natural. A distância das vias de acesso foi derivada da fotointerpretação de imagens de satélite e trabalhos de campo. Por último, a litologia em escala 1:25.000 foi obtida pelos mapas geológicos produzidos por Endo et al. (2019) e Pinheiro, Magalhães e Silva (2023). Com exceção da curvatura das vertentes, que foi preparada na resolução espacial de 30 m x 30 m, todos os demais FCD foram preparados na resolução de 10 m x 10 m.

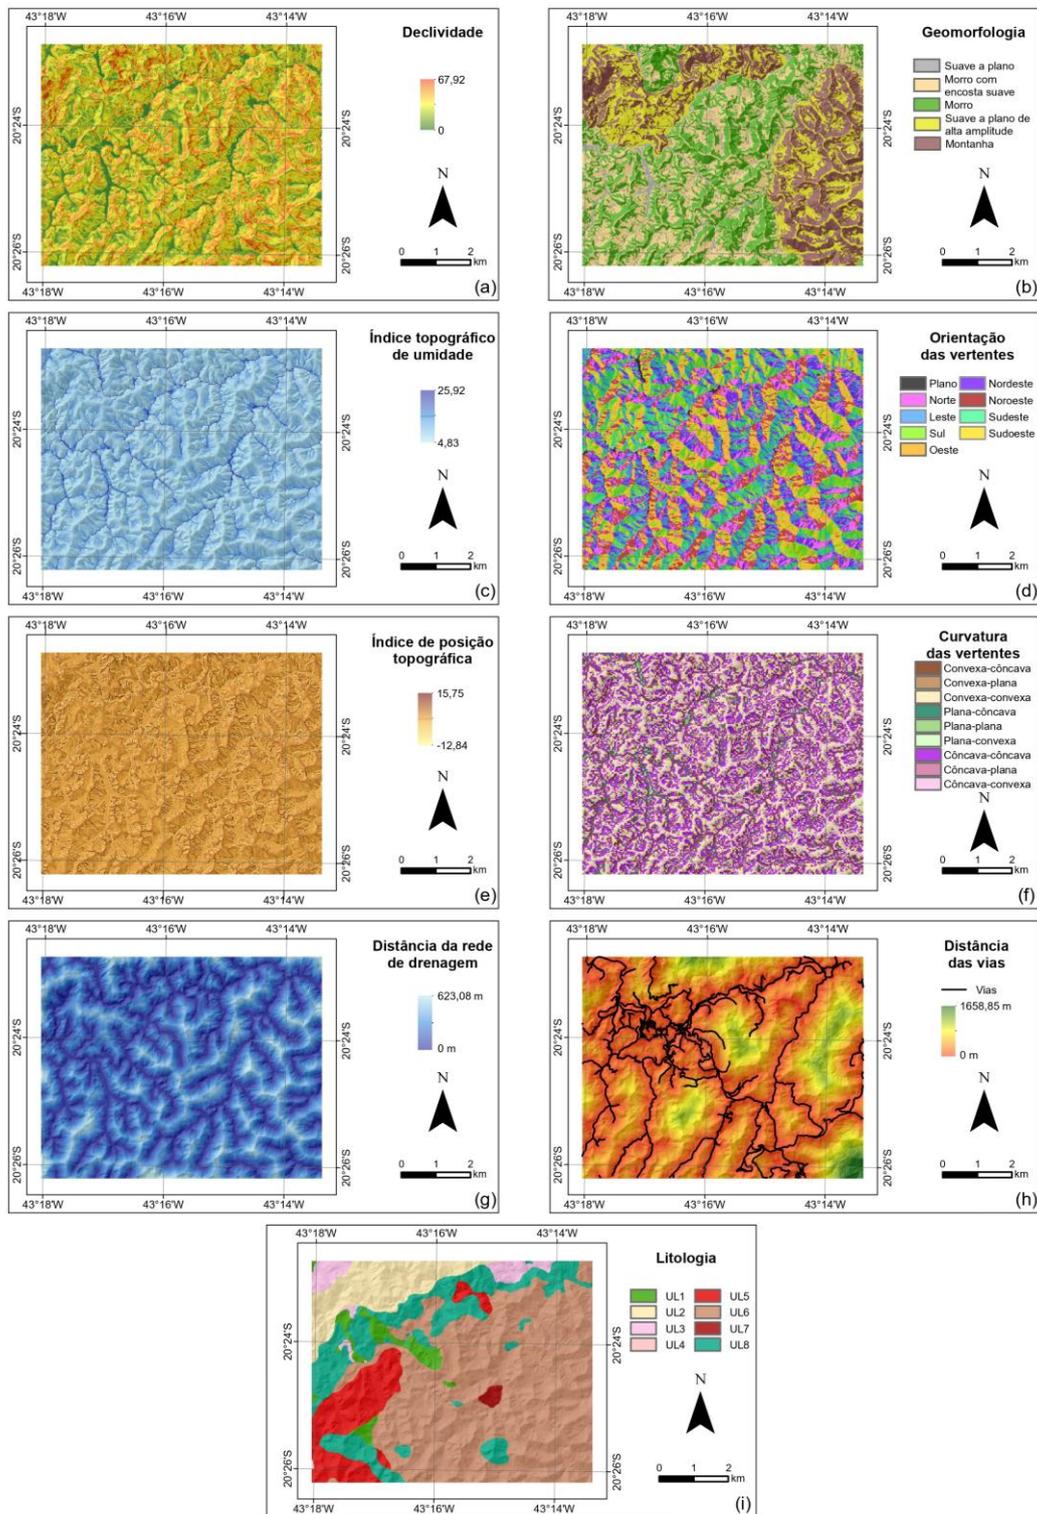


Figura 4. Fatores condicionantes a deslizamentos: (a) declividade, (b) geomorfologia, (c) índice topográfico de umidade, (d) orientação das vertentes, (e) índice de posição topográfica, (f) curvatura das vertentes, (g) distância da rede de drenagem, (h) distância das vias e (i) litologia.

3.2.1. Declividade

Em análises de estabilidade de encostas e MSD, a declividade é um dos primeiros fatores a serem considerados, devido à sua influência direta na resistência ao cisalhamento, um dos fundamentos físicos para o desencadeamento de movimentos de massa (LEE; MIN, 2001; OGILA, 2021). Conforme Guillard e Zezere (2012), a instabilidade de solos e rochas tende a aumentar à medida que a inclinação de uma encosta também aumenta. No nosso estudo, o mapa de declividade adotado abrange inclinações que variam de 0° a 67,92° (Figura 4a).

3.2.2. Geomorfologia

A geomorfologia pode revelar os processos geológicos que moldaram o terreno no passado, fornecendo pistas importantes sobre as áreas mais propensas a deslizamentos. Isso se deve ao fato de que diferentes configurações do relevo exercem diferentes influências na probabilidade de ocorrências desses eventos (ANBAZHAGAN; SAJINKUMAR, 2011). As unidades geomorfológicas da área de estudo, Figura 4b, foram classificadas a partir da declividade predominante (expressa em porcentagem) e amplitude local (diferença de elevação entre a base e o topo das unidades de terreno definidas pelo MDT invertido), conforme metodologia proposta por Souza (2015) e Souza e Sobreira (2017), e apresentada na Tabela 1. Assim, foram estabelecidas cinco classes geomorfológicas para a área de estudo: suave a plano, morro com encosta suave, morro, suave a plano de alta altitude e montanha.

Tabela 1. Classificação de unidades geomorfológica (Souza, 2015; Souza e Sobreira, 2017)

Amplitude local (m)	Declividade predominante	Classe de relevo
< 100	< 5%	Suave a plano de baixa amplitude
	5 a 10%	Rampa
	10 a 20%	Colina
	> 20%	Morrote
100 a 300	< 5%	Suave a plano *
	5 a 20%	Morro com encosta suave *
	> 20%	Morro *
> 300	< 20%	Suave a plano de alta amplitude *
	> 20%	Montanha *

* Classes geomorfológicas identificadas na área de estudo

3.2.3. Índice topográfico de umidade (TWI)

O TWI avalia o grau de umidade de determinado local a partir da topografia (POURGHASEMI et al., 2012; YESILNACAR; SÜZEN, 2006). Em locais onde o acúmulo de água é significativo, a saturação do solo tende a aumentar nos períodos chuvosos, o que pode aumentar a probabilidade de deslizamentos em locais com maiores valores do índice (JEBUR; PRADHAN; TEHRANY, 2015; NEFESLIOGLU; DUMAN; DURMAZ, 2008). Isso ocorre devido à diminuição da coesão entre os grãos do solo, resultando em uma redução na sua resistência ao cisalhamento. O índice é estabelecido a partir da Equação 1, proposta por Moore, Grayson e Ladson (1991):

$$TWI = \ln\left(\frac{A}{tg(\beta)}\right) \quad (1)$$

Onde:

- A é a área de contribuição específica da bacia hidrográfica local (m²/m)
- β é a declividade local (em graus)

Para a área de estudo, os valores do TWI variam de 4,83 a 25,92, com valores mais elevados indicando uma maior tendência ao acúmulo de água, como observado na Figura 4c.

3.2.4. Orientação das vertentes

A orientação das vertentes é um importante fator a ser considerado no MSD (CHEN; NIU; JIA, 2016; GUZZETTI et al., 2005). A direção para qual uma encosta está orientada controla alguns aspectos microclimáticos que podem influenciar direta ou indiretamente a ocorrência de deslizamentos, como exposição solar, direção dos

ventos, intensidade das chuvas, umidade do solo e desenvolvimento da vegetação (CONFORTI et al., 2014; EIRAS et al., 2021). Para a área de estudo, a orientação das vertentes, Figura 4d, foi classificada em nove classes conforme o ângulo de azimute das encostas: plano (sem indicação do azimute), norte (0° - $22,5^{\circ}$; $337,5^{\circ}$ - 360°), nordeste ($22,5^{\circ}$ - $67,5^{\circ}$), leste ($67,5^{\circ}$ - $112,5^{\circ}$), sudeste ($112,5^{\circ}$ - $157,5^{\circ}$), sul ($157,5^{\circ}$ - $202,5^{\circ}$), sudoeste ($202,5^{\circ}$ - $247,5^{\circ}$), oeste ($247,5^{\circ}$ - $292,5^{\circ}$) e noroeste ($292,5^{\circ}$ - $337,5^{\circ}$).

3.2.5. Índice de posição topográfica (TPI)

O TPI mostra a diferença entre a elevação de um ponto em relação a elevação média do seu entorno (ESLAMINEZHAD; EFTEKHARI; AKBARI, 2020; PAWLUSZEK; BORKOWSKI, 2017). A consideração do TPI no MSD surge do argumento de que, normalmente, esses eventos acontecem nas cristas das encostas (BACHRI et al., 2019; EFIONG et al., 2021), onde o TPI apresenta valores positivos, indicando elevações menores nas áreas circundantes. Por outro lado, valores negativos de TPI sugerem o oposto, indicando que as áreas ao redor do ponto analisado possuem maiores elevações (LEE; LEE; LEE, 2018). Na área de estudo, os valores de TPI variaram de -12,84 a 15,75, conforme ilustrado na Figura 4e.

3.2.6. Curvatura das vertentes

De acordo com Ullah et al. (2022), uma encosta pode apresentar três distintos tipos de curvaturas em cada um dos seus planos, tanto vertical quanto horizontal: convexa, côncava e plana. A curvatura vertical é responsável por determinar as dinâmicas de aceleração do fluxo de água ao longo da encosta, influenciando nos processos de erosão e deposição de detritos. Encostas com curvatura vertical côncava tendem a ser mais propensas a deslizamentos (GRABOWSKI et al., 2022; OHLMACHER, 2007). Por outro lado, a curvatura horizontal exerce sua influência na convergência e divergência dos fluxos de água. Áreas com curvatura horizontal côncava, ou convergente, tendem a ser mais suscetíveis a deslizamentos (GRABOWSKI et al., 2022).

No presente estudo, as curvaturas horizontais foram combinadas com as curvaturas verticais em nove diferentes combinações (DIKAU, 1990). Para uma melhor acuidade visual das curvaturas e evitar efeitos indesejados do MDT no resultado final, o mapa resultante, Figura 4f, foi elaborado na resolução espacial de 30 m x 30 m (GARCIA, 2012).

3.2.7. Distância da rede de drenagem natural

As condições hidrológicas desempenham um papel importante na inicialização dos deslizamentos (THANH; DE SMEDT, 2012). Por essa razão, vários autores têm empregado a distância em relação à rede de drenagem como um FCD (BISWAS; RAHAMAN; BARMAN, 2023; BISWAS; RANJAN, 2021; OH; LEE, 2011), dada a tendência de alguns deslizamentos ocorrerem nas proximidades da drenagem. Assim, a distância da rede de drenagem foi considerada em nosso estudo de forma ordinal, variando de 0 m a 623,08 m, conforme mostrado na figura 4g.

3.2.8. Distância das vias

Alguns autores levantam a hipótese de que deslizamentos são mais propensos a ocorrer nas proximidades de estradas ou vias, principalmente devido à alteração geométrica dos taludes (cortes e aterros) e à interferência na drenagem natural (ABU EL-MAGD; ALI; PHAM, 2021; DAHAL et al., 2008). Essa hipótese foi reforçada durante os trabalhos de campo na área de estudo, nos quais várias cicatrizes de deslizamentos foram identificadas próximas às vias. O mapa de distância das vias, representado na Figura 4h, foi elaborado de forma ordinal, abrangendo distâncias que variaram de 0 m a 1658,85 m para a área de estudo.

3.2.9. Litologia

As variações litológicas são um importante parâmetro para análises de riscos geológicos e MSD (HENRIQUES; ZÊZERE; MARQUES, 2015; POURGHASEMI; KERLE, 2016; RAHMATI et al., 2016). Características físicas, hidrológicas e mecânicas, como resistência, densidade, permeabilidade e grau de intemperismo, variam conforme a tipologia litológica (NAEMITABAR; ZANGANEH ASADI, 2021; YOUSSEF; POURGHASEMI, 2021). Para a área de estudo, foram extraídas oito unidades litológicas em escala 1:25.000, conforme Tabela 2 e Figura 4i, a partir dos trabalhos de Endo et al. (2019) e Pinheiro, Magalhães e Silva (2023).

Tabela 2. Caracterização das unidades litológicas presentes na área de estudo

Código	Litologia
UL1	Rochas metamáficas: anfibolitos, anfibólitos xistos e milonitos
UL2	Meta-arenitos e meta-arcóseos impuros
UL3	Migmatitos: metatexitos e gnaisses
UL4	Sedimentos argilo-arenosos: argilitos com níveis areno-siltosos finos
UL5	Biotita metagranitos, granidioritos e tonalitos
UL6	Gnaisses de injeção paleoproterozoicas sobre migmatitos e gnaisses arqueanos, rochas máficas e metaultramáficas
UL7	Formação ferrífera bandada
UL8	Rochas metaultramáficas: esteatitos, serpentinitos, xistos e milonitos

3.3. Hierarquização dos Fatores Condicionantes aos Deslizamentos (FCD)

No contexto dos modelos de ML para o mapeamento da suscetibilidade, a hierarquização dos FCD funciona como uma etapa importante de pré-processamento. Esta fase é direcionada à avaliação do impacto dos fatores condicionantes na precisão e confiabilidade dos modelos (SAHIN et al., 2020). O objetivo é descartar informações supérfluas ou redundantes, além de estabelecer combinações ótimas de fatores (PHAM et al., 2021).

Em nosso trabalho, realizamos o ranqueamento dos FCD utilizando o Ganho de Informação (GI), técnica altamente eficaz na seleção de variáveis influentes e amplamente adotada no âmbito do ML (LI et al., 2022; QUINLAN, 1986). Conforme Pham et al. (2017), o GI é quantificado a partir da medida da redução de entropia dos FCD e oferece uma abordagem valiosa para avaliar sua contribuição na modelagem da suscetibilidade a deslizamentos.

Nesse contexto, os nove FCD considerados no estudo foram classificados em ordem hierárquica com base no GI, de forma que quanto maior o valor adquirido, mais significativa é a contribuição do fator para a construção dos modelos.

3.4. Seleção da técnica de aprendizado de máquina para a modelagem da suscetibilidade a deslizamentos

Nós avaliamos o desempenho de três abordagens de ML na modelagem de suscetibilidade a deslizamentos, isto é, FA, RL e RNA. O número de FCD considerados em cada técnica de aprendizado variou de 4 a 9, sendo a integração realizada com base na hierarquização produzida pelo Ganho de Informação (GI). Logo, inicialmente foram incluídos apenas os quatro atributos com maior valor de GI, expandindo-se então para abranger todos os FCD disponíveis. Em nossa análise, concentramos nossa avaliação no modelo com melhor desempenho desenvolvido para cada conjunto com o mesmo número de FCD. Em outras palavras, para cada abordagem, avaliamos e comparamos o melhor modelo com 4, 5, 6, 7, 8 e 9 FCD.

3.4.1. Florestas Aleatórias (FA)

A FA é um método não paramétrico de classificação por *ensemble learning* desenvolvido por Breiman (2001). Os dados de entrada são selecionados arbitrariamente e reamostrados, na mesma proporção, em subconjuntos menores denominados árvores de decisão, através da técnica *bagging* (CRUZ; OLIVEIRA, 2021; UEHARA et al., 2020), onde a classificação final é definida pelo resultado mais frequente entre os subconjuntos criados. Para a construção do modelo, o usuário deve definir o número de árvores que irão compor a floresta e o número de atributos a serem considerados nos nós de cada árvore. Os nós representam pontos de divisão onde os dados são separados com base em determinados critérios. Cada nó pode ter zero ou mais derivações, representando as diferentes ramificações do processo de decisão. Esses procedimentos possibilitam a criação de árvores que tenham vies relativamente baixo e alta variância, contribuindo para com um melhor desempenho do modelo desenvolvido (HASTIE; TIBSHIRANI; FRIEDMAN, 2009; PHAM et al., 2019; ZHANG et al., 2017).

Neste estudo, diversos modelos foram desenvolvidos, explorando uma ampla gama de configurações. Essas variações abrangeram diferentes números de árvores, variando de 10 a 100, com um incremento de 10 árvores a cada etapa. Além disso, o número de FCD considerados nos nós de cada árvore variou de dois, representando o mínimo possível, até o máximo de FCD contidos em cada modelo.

3.4.2. Regressão Logística (RL)

A RL, introduzida por Cox (1958) e Walker e Duncan (1967), é uma abordagem de análise multivariada empregada para modelar a probabilidade de uma característica ou resultado (LEE, 2004, 2005). A abordagem estima a probabilidade binária de uma variável dependente usando uma função logística que permite transformar uma combinação linear de variáveis preditoras independentes em um valor que pode ser interpretado como uma probabilidade (MASCANZONI et al., 2018). Ao longo dos últimos anos, a RL se tornou o método estatístico mais amplamente utilizado para o MSD ao redor do mundo, devido à sua simplicidade e eficácia (CHOWDHURY, 2023; DOMÍNGUEZ-CUESTA et al., 2010; POURGHASEMI et al., 2018).

Para mitigar o overfitting e aprimorar a capacidade de generalização dos modelos de RL, são comumente empregadas técnicas de regularização, com destaque para os métodos Lasso (L1) e Ridge (L2) (ABDELRAHMAN, 2020; NG, 2004). Enquanto a regularização L1 pode zerar alguns coeficientes de regressão, removendo variáveis menos relevantes, a L2 diminui o overfitting ao reduzir o impacto dos coeficientes de variáveis altamente correlacionadas, sem necessariamente excluí-las (KOPPE; MEYER-LINDENBERG; DURSTEWITZ, 2021; MIRANDA; BOMBACINI, 2023). A intensidade da regularização é influenciada pela força de custo C , onde um valor menor implica em uma regularização mais forte e um valor maior reduz essa força.

Diversas configurações de RL foram experimentadas, variando os métodos de regularização entre L1 e L2 e ajustando o parâmetro de custo C de 0,001 a 1000.

3.4.3. Redes Neurais Artificiais (RNA)

As RNA, introduzidas por McCulloch e Pitts (1943), são uma técnica de classificação por aprendizado supervisionado inspirada na estrutura neural do cérebro humano. Elas são projetadas para reconhecer padrões e aprender com os dados de entrada por meio de um processo de treinamento (AGATONOVIC-KUSTRIN; BERESFORD, 2000; MOULOODI et al., 2021). Em nosso estudo, utilizamos uma RNA com algoritmo *multi-layer perceptron* (MLP) com *backpropagation*. O MLP opera através da alimentação dos dados em uma camada de entrada, que são então processados em uma ou mais camadas ocultas de neurônios. Essas unidades computacionais básicas imitam o funcionamento dos neurônios biológicos do cérebro humano, utilizando pesos e funções de ativação (ALALOUL; QURESHI, 2020; PARK; LEK, 2016). A correção e otimização dos pesos acontecem por meio do método de *backpropagation*, que ajusta os pesos com base no erro entre o resultado previsto e o resultado real. Esse processo iterativo permite que o MLP aprenda padrões complexos nos dados, tornando-o uma ferramenta poderosa na análise e modelagem de sistemas complexos (GARDNER; DORLING, 1998; NASKATH; SIVAKAMASUNDARI; BEGUM, 2023; ZAJMI; AHMED; JAHARADAK, 2018).

Como função de ativação, optamos pela função retificadora linear, ReLu (NAIR; HINTON, 2010; XU et al., 2015). Essa escolha se deve à sua reconhecida simplicidade e eficiência computacional, além de sua ampla utilização em treinamentos de RNA (NOLA, 2022; PAUL et al., 2023). Para ajuste nos pesos dos neurônios e minimização do erro de predição das RNA, adotamos o otimizador Adam, *Adaptive Moment Estimation* (KINGMA; BA, 2014). O otimizador Adam foi selecionado devido à sua eficiência e ao bom desempenho demonstrado em estudos de ML focados em deslizamentos (e.g. NHU et al., 2020; PANDEY et al., 2022; WANG et al., 2020; YI et al., 2022).

Para diminuir os riscos de overfitting e manter a construção de modelos mais simples, optamos por usar uma única camada oculta de neurônios nas RNA. O número de neurônios em cada modelo desenvolvido foi determinado com base no valor máximo estabelecido pela Equação 2, proposta por Hecht-Nielsen (1987), que leva em consideração tanto o número de neurônios na camada oculta (H) quanto a quantidade de FCD empregados no modelo (n).

$$H \leq 2n + 1 \quad (2)$$

Como forma de prevenção ao sobreajuste dos modelos aos dados de treinamento, implementamos a técnica de “parada antecipada”. Essa técnica, respaldada na literatura (HAYKIN, 2001; PRECHELT, 1998), possibilita a

interrupção do treinamento quando não há melhorias significativas na performance dos modelos. Adicionalmente, esta decisão se justifica como forma de redução na complexidade computacional dos modelos. Após diversos testes no subgrupo de treino, foram estabelecidos como critérios para a parada antecipada a taxa de aprendizagem $\alpha = 1$ e o número limite de iterações para os modelos igual a 500. Estes valores demonstraram eficácia e adequação, independentemente do número de FCD considerado em cada modelo.

3.5. Avaliação de desempenho

Para cada uma das abordagens de ML aplicadas, FA, RL e ANN, foram avaliados os melhores modelos. A avaliação do desempenho dos modelos considerou métricas amplamente utilizadas em estudos relacionados ao ML e geociências. Isso envolveu a utilização de gráficos da curva ROC (*Receiver Operating Characteristic*) e matrizes de confusão. A curva ROC correlaciona a taxa de verdadeiros positivos (sensibilidade) com a taxa de falsos positivos ($1 - \text{especificidade}$) em diferentes configurações de limiar, oferecendo um índice estatístico de desempenho global do modelo através da área abaixo da curva ROC (AUC-ROC) (BEGUERÍA, 2006; CHUNG; FABBRI, 2003). Além disso, a partir da matriz de confusão, foram extraídas métricas de desempenho, como acurácia, precisão, sensibilidade, especificidade e F1-Score, calculadas conforme as Equações 3 – 7 (e.g. BUI et al., 2020; EIRAS et al., 2021; JIAO et al., 2019; SINGH et al., 2023; SOLANKI; GUPTA; JOSHI, 2022). Ao final dos cálculos, os melhores modelos foram selecionados com base nos valores obtidos de acurácia, AUC-ROC (que compreende tanto a sensibilidade quanto a especificidade) e F1-Score (que compreende tanto a precisão quanto a sensibilidade).

$$\text{acurácia} = (VP + VN) \div (VP + VN + FP + FN) \quad (3)$$

$$\text{precisão} = VP \div (VP + FP) \quad (4)$$

$$\text{sensibilidade} = VP \div (VP + FN) \quad (5)$$

$$\text{especificidade} = VN \div (VN + FP) \quad (6)$$

$$F1 - \text{Score} = \frac{2 * \text{precisão} * \text{sensibilidade}}{\text{precisão} + \text{sensibilidade}} \quad (7)$$

Onde:

- VP = Verdadeiros positivos;
- VN = Verdadeiros negativos;
- FP = Falsos positivos;
- FN = Falsos negativos.

Para cada uma das três técnicas de ML adotadas, considerando todas as possíveis configurações dos algoritmos de ML e as variações dos dados de entrada (tópico 3.4), selecionamos o melhor modelo desenvolvido por cada algoritmo e calculamos o índice de suscetibilidade a deslizamentos para a área de estudo. Posteriormente, os mapas de suscetibilidade resultantes foram reclassificados em três zonas distintas de suscetibilidade, utilizando o método de classificação de quebras naturais (Jenks), que foram qualificados em categorias de baixa, média e alta suscetibilidade. Finalmente, avaliamos a eficiência das classificações dos mapas de suscetibilidade com base na densidade de áreas de deslizamentos presentes nas categorias de alta e baixa suscetibilidade. Nesse contexto, utilizamos os valores de significância da taxa de eficiência (TE), Equação 8 e Tabela 3, proposta por Chung e Fabbri (2003) e adaptada por Guzzetti et al. (2006) para regiões complexas e com grande incidência de deslizamentos.

$$TE_i = \frac{(S \cap C_i)}{C_i} \div \frac{S}{\Omega} \quad (8)$$

Onde:

- TE_i = Taxa de eficiência da classe i ;
- Ω = Área de estudo total;
- S = Área ocupada por todos os deslizamentos em toda a área Ω ;
- C_i = Área da classe i .

Tabela 3. Significância da taxa de eficiência nos níveis de suscetibilidade.

Eficiência da classificação		Taxa de eficiência	
		Chung e Fabbri (2003)	Guzzetti et al. (2006)
Alta suscetibilidade	Muito significativa	$TE_i > 6$	$TE_i > 1,5$
	Significativa	$3 < TE_i \leq 6$	-
	Não significativa	$0,2 \leq TE_i \leq 3$	$0,5 \leq TE_i \leq 1,5$
Baixa suscetibilidade	Não significativa	$0,2 \leq TE_i \leq 3$	$0,5 \leq TE_i \leq 1,5$
	Significativa	$0,1 \leq TE_i < 0,2$	-
	Muito significativa	$TE_i < 0,1$	$TE_i < 0,5$

4. Resultados

4.1. Hierarquização dos Fatores Condicionantes aos Deslizamentos (FCD)

Verifica-se na Figura 5 a importância de cada FCD conforme o valor total de GI. Observa-se que a declividade é o fator de maior relevância (GI = 0,486), seguida por geomorfologia (GI = 0,235), TWI (GI = 0,138), litologia (GI = 0,077), orientação das vertentes (GI = 0,067), TPI (GI = 0,052), distância da rede de drenagem (GI = 0,032), curvatura das vertentes (GI = 0,029) e, por fim, distância das vias (GI = 0,024).

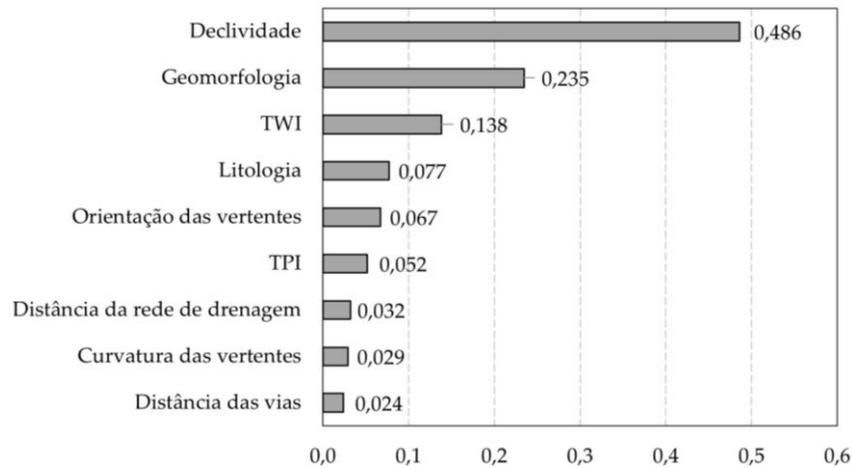


Figura 5. Importância dos FCD de acordo com os valores de GI

4.2. Construção dos modelos de suscetibilidade a deslizamentos

De acordo com a Tabela 4, verificam-se os modelos de FA que demonstraram os melhores desempenhos, considerando a variação no número de FCD utilizados, que variou de quatro a nove. Adicionalmente, na Tabela 4 é destacado o melhor modelo de FA encontrado (FA-6) considerando os valores de acurácia, AUC-ROC e F1-Score.

Tabela 4. Melhores modelos de FA desenvolvidos

Configurações	Modelos					
	FA-1	FA-2	FA-3	FA-4	FA-5	FA-6
Número de FCD	4	5	6	7	8	9
Número de árvores de decisão	100	70	90	100	100	90
Número de FCD nos nós	4	5	6	5	6	3
AUC-ROC	0,922	0,923	0,940	0,941	0,942	0,947
Acurácia	0,850	0,851	0,867	0,873	0,872	0,878
Precisão	0,846	0,844	0,861	0,865	0,862	0,858
Sensibilidade	0,855	0,859	0,875	0,882	0,886	0,906
Especificidade	0,845	0,842	0,859	0,863	0,858	0,850
F1-Score	0,850	0,852	0,868	0,874	0,874	0,881

Dentre os modelos de RL avaliados, considerando a variação de 4 a 9 FCD, aqueles que apresentaram os melhores resultados foram construídos com a regularização L2 e C=0,01, sendo estes apresentados na Tabela 5. Ademais, a Tabela 5 enfatiza o melhor modelo de RL identificado (RL-4) com base nos valores de acurácia, AUC-ROC e F1-Score.

Tabela 5. Melhores modelos de RL desenvolvidos

Configurações	Modelos					
	RL-1	RL-2	RL-3	RL-4	RL-5	RL-6
Número de FCD	4	5	6	7	8	9
Regularização adotada	L2	L2	L2	L2	L2	L2
Força da regularização	0,1	0,1	0,1	0,1	0,1	0,1
AUC-ROC	0,929	0,931	0,935	0,936	0,935	0,935
Acurácia	0,874	0,874	0,875	0,885	0,884	0,882
Precisão	0,852	0,851	0,852	0,862	0,860	0,859
Sensibilidade	0,906	0,906	0,908	0,915	0,916	0,914
Especificidade	0,843	0,842	0,843	0,854	0,851	0,850
F1-Score	0,878	0,878	0,879	0,888	0,887	0,886

Conforme a Tabela 6, verificam-se os modelos de RNA que demonstraram os melhores desempenhos, considerando a variação no número de FCD utilizados, que variou de quatro a nove. Embora o modelo RNA-3 tenha obtido a maior AUC-ROC, seus valores de acurácia e F1-Score foram ligeiramente inferiores aos encontrados pelo modelo RNA-1. Isso sugere que ambos os modelos poderiam ser aplicados na modelagem da suscetibilidade a deslizamentos, pois apresentam boas métricas estatísticas. Todavia, optamos por selecionar o modelo RNA-3 para a comparação com as demais abordagens adotadas no estudo, uma vez que a AUC-ROC é uma das métricas mais amplamente adotadas para a seleção dos melhores modelos de ML, como demonstrado por outros autores (e.g. POURGHASEMI; RAHMATI, 2018; SARFRAZ et al., 2022).

Tabela 6. Melhores modelos de RNA desenvolvidos

Configurações	Modelos					
	RNA-1	RNA-2	RNA-3	RNA-4	RNA-5	RNA-6
Número de FCD	4	5	6	7	8	9
Número de neurônios na camada oculta	9	11	13	15	17	19
Função de ativação	ReLU	ReLU	ReLU	ReLU	ReLU	ReLU
Otimizador	Adam	Adam	Adam	Adam	Adam	Adam
Taxa de aprendizagem α	1	1	1	1	1	1
Limite de iterações	500	500	500	500	500	500
AUC-ROC	0,931	0,928	0,934	0,932	0,931	0,930
Acurácia	0,865	0,855	0,864	0,862	0,862	0,863
Precisão	0,851	0,841	0,853	0,850	0,846	0,850
Sensibilidade	0,886	0,876	0,881	0,879	0,885	0,881
Especificidade	0,845	0,834	0,848	0,845	0,840	0,845
F1-Score	0,868	0,858	0,867	0,864	0,865	0,866

Para comparação dos resultados, as Figura 6, 7 e 8 apresentam os mapas de suscetibilidade gerados pelo modelo mais eficaz identificado em cada abordagem de ML empregada (FA-6, RL-4 e RNA-3).

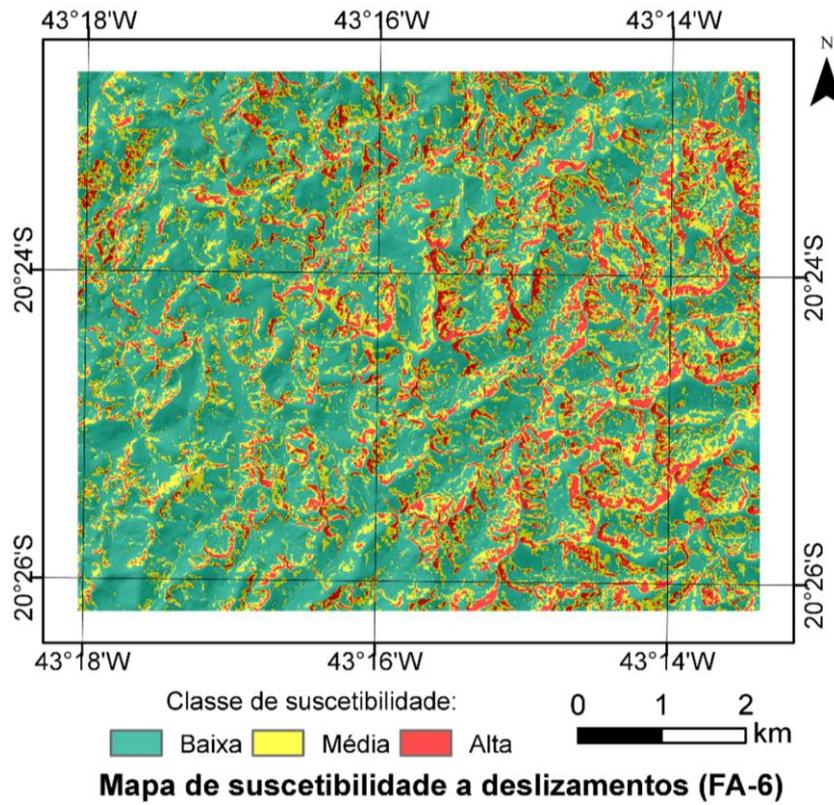


Figura 6. Mapa de suscetibilidade a deslizamentos do modelo FA-6

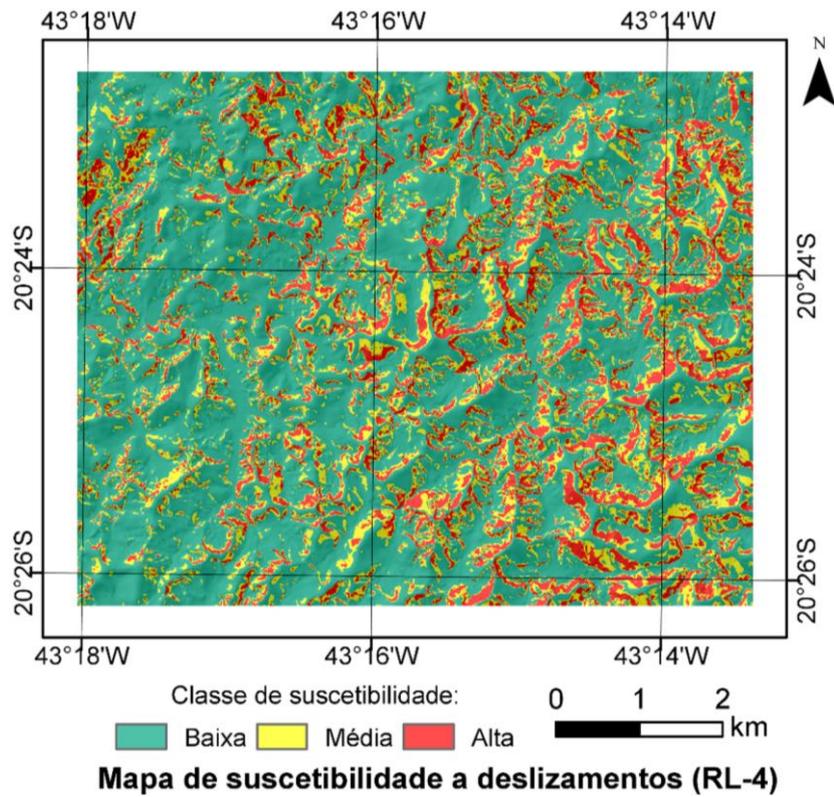


Figura 7. Mapa de suscetibilidade a deslizamentos do modelo RL-4

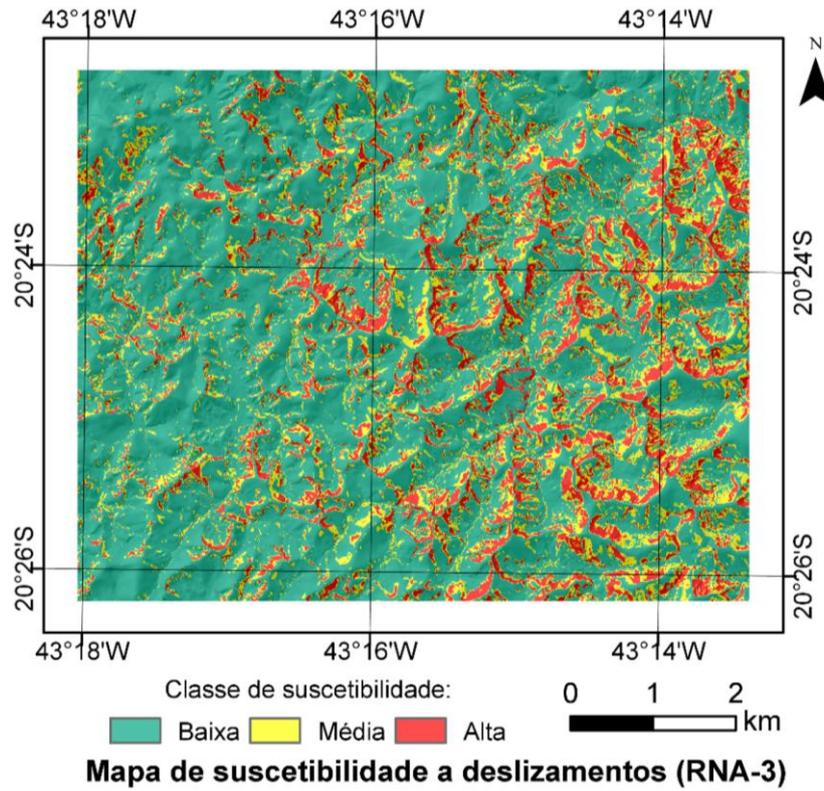


Figura 8. Mapa de suscetibilidade a deslizamentos do modelos RNA-3

Independentemente do método de ML empregado, todos modelos de suscetibilidade evidenciaram elevados valores da AUC-ROC (FA-6 = 0,947), RL-4 = 0,936) e RNA-3 = 0,934), conforme apresentado pela Figura 9.

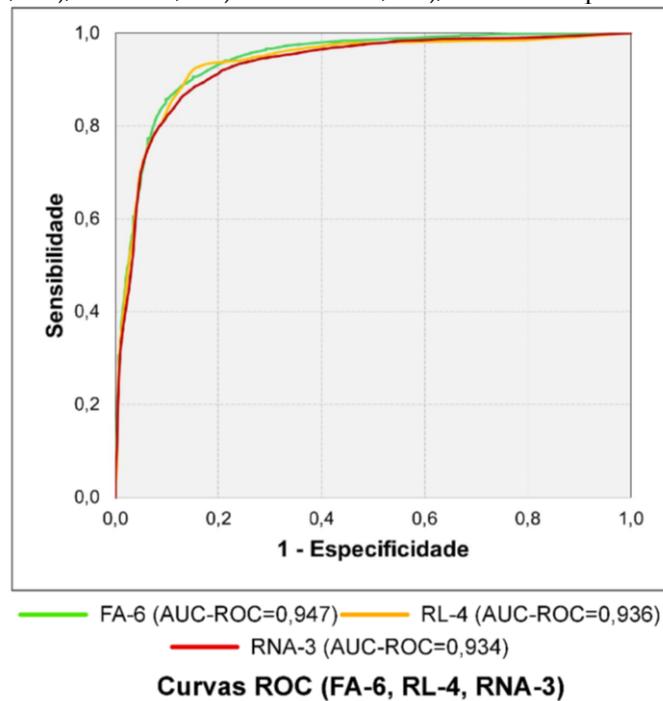


Figura 9. Curvas ROC dos modelos FA-6, RL-4 e RNA-3

Os percentuais de área atribuídos a cada classe de suscetibilidade (alta, média e baixa) e as taxas de eficiência calculadas para as classes de alta (TE_i^{AS}) e baixa (TE_i^{BS}) suscetibilidade de cada modelo são detalhados na Tabela 7.

Tabela 7. Área (%) para cada classe de suscetibilidade a deslizamentos mapeada

Modelo	Classe de suscetibilidade			Taxa de eficiência da classificação (TE_i)	
	Baixa	Média	Alta	Baixa Suscetibilidade (TE_i^{BS})	Alta Suscetibilidade (TE_i^{AS})
FA-6	65,606%	19,526%	14,868%	0,030	6,808
RL-4	65,099%	19,497%	15,404%	0,050	5,695
RNA-3	69,325%	17,321%	13,354%	0,060	6,495

5. Discussões

O sucesso da modelagem da suscetibilidade a deslizamentos depende diretamente da seleção da técnica estatística mais adequada (FELICÍSIMO et al., 2013). Embora vários estudos tenham comparado diferentes abordagens de ML, ainda não há um consenso definitivo sobre qual técnica é a mais eficaz. A seleção da abordagem mais adequada depende da compreensão do processo investigado, assim como da disponibilidade e qualidade dos dados. Portanto, é crucial realizar comparações entre diferentes técnicas metodológicas para determinar as mais apropriadas ao MSD nos diferentes contextos. As análises conduzidas em nosso trabalho, comparando as técnicas de FA, RL e RNA para o mapeamento da suscetibilidade, contribuem para esse entendimento, complementando pesquisas anteriores que investigaram diferentes abordagens de ML, como os estudos conduzidos por Akgun (2012), Chen et al. (2023), Liu et al. (2022) e Pham et al. (2016).

Pham et al. (2021) indicam a avaliação da importância dos FCD para o aprimoramento da capacidade de generalização dos modelos de MSD. Em nossa pesquisa, ao utilizar o índice GI para essa finalidade, constatamos que a declividade foi o fator mais significativo para a modelagem da suscetibilidade na região investigada. Apesar desta constatação estar alinhada a outros estudos conduzidos em regiões montanhosas, como os realizados por Kumar et al. (2023) e Youssef e Pourghasemi (2021), que evidenciaram a importância da declividade na predisposição a deslizamentos, é importante considerar que a declividade nem sempre é o principal FCD. Como destacado por Micheletti et al. (2014), os FCD são influenciados pelas características intrínsecas do terreno e pela natureza local dos deslizamentos. Assim, a relevância de um determinado fator pode variar dependendo da área de estudo.

Embora a remoção de FCD irrelevantes seja uma etapa importante para a modelagem da suscetibilidade, conforme indicado por Merghadi et al. (2020), nossa pesquisa não identificou grandes variações nos resultados obtidos em virtude desse processo. Uma pequena variação da AUC-ROC foi observada entre os melhores modelos produzidos, alternando-se o número de FCD considerados, para cada técnica de ML adotada: 2,5% para a técnica de FA, 0,7% para RL e 0,6% para RNA (Tabela 8). Isso sugere que qualquer um dos modelos de melhor desempenho para cada técnica de ML adotada produziria resultados satisfatórios. No entanto, para efeitos de comparação, optamos por utilizar os modelos que alcançaram os maiores valores de AUC-ROC, que foram os modelos FA-6 (AUC-ROC=0,947), RL-4 (AUC-ROC=0,936) e RNA-3 (AUC-ROC=0,934), construídos com os nove, sete e seis FCD mais importantes, respectivamente. Nossos resultados apontam a eficácia dos três modelos, com valores de AUC-ROC próximos aos encontrados nos modelos de ML avaliados por Youssef e Pourghasemi (2021), que variaram de 0,890 para a técnica *quadratic discriminant analysis* a 0,951 para a FA, e superiores aos avaliados por Pourghasemi e Rahmati (2018), que variaram de 0,624 para a técnica *generalized linear model* a 0,837 para a FA.

Tabela 8. Variação da AUC-ROC observa nos melhores modelos de cada técnica de ML adotada

Técnica de aprendizado de máquina	Modelo com maior valor de AUC-ROC	Modelo com menor valor de AUC-ROC	Variação da AUC-ROC
FA	0,947	0,922	2,5%
RL	0,936	0,929	0,7%
RNA	0,934	0,928	0,6%

As demais métricas estatísticas analisadas para os modelos FA-6 (acurácia=0,878, precisão=0,858, sensibilidade=0,906, especificidade=0,906 e F1-score=0,881), RL-4 (acurácia=0,885, precisão=0,862, sensibilidade=0,915, especificidade=0,854 e F1-score=0,888) e RNA-3 (acurácia=0,864, precisão=0,853, sensibilidade=0,881, especificidade=0,848 e F1-score=0,867) evidenciam que todas as abordagens de ML utilizadas foram capazes de identificar de forma adequada e sensível as áreas suscetíveis aos deslizamentos, além de discriminar adequadamente as áreas não suscetíveis. Os valores encontrados para as métricas analisadas são semelhantes aos de estudos passados e que também demonstraram bons desempenhos nos modelos de ML analisados (SHAHZAD; DING; ABBAS, 2022; WANG et al., 2021; ZHANG et al., 2022).

Adicionalmente, consideramos a Taxa de Eficiência (TE) para avaliação dos modelos. Para a classificação de baixa suscetibilidade, os resultados de TE para o melhor modelo de cada técnica de ML (FA-6=0,03, RL-4=0,05 e RNA-3=0,06) demonstraram uma eficiência muito significativa, mantendo-se dentro dos limites definidos por Chung e Fabbri (2003) e Guzzetti et al. (2006). Ademais, os resultados indicam que o modelo FA-6 apresentou o menor número de áreas com a presença de deslizamentos na faixa de baixa suscetibilidade. Em relação à classificação de alta suscetibilidade, os resultados de TE (FA-6=6,808, RL-4=5,695 e RNA-3=6,495) indicam que os modelos FA-6 e RNA-3 alcançaram uma eficiência muito significativa, enquanto o modelo RL-4 alcançou uma eficiência significativa, de acordo com os critérios estabelecidos por Chung e Fabbri (2003). No entanto, ao considerar os limites adaptados por Guzzetti (2006) para áreas complexas com um histórico significativo de deslizamentos, como é o caso da região estudada, todos os três modelos demonstraram uma eficiência muito significativa. É digno de nota que, para a classificação de alta suscetibilidade, o modelo FA-6 apresentou o maior valor de TE, indicando que a área delimitada como de alta suscetibilidade por este modelo abrangeu uma extensão maior de deslizamentos em comparação com os modelos RNA-3 e RL-4.

Considerando todas as métricas de avaliação adotadas, as três metodologias de ML utilizadas para modelar a suscetibilidade a deslizamentos na área de estudo demonstram uma notável compatibilidade de eficiência, tornando difícil determinar qual técnica foi superior. Do ponto de vista prático, qualquer um dos três modelos de MSD produzidos seria capaz de cumprir seu objetivo principal: prever áreas propensas a deslizamentos futuros e fornecer apoio na tomada de decisões para prevenir e mitigar esses eventos. Todavia, como o modelo FA-6 apresentou as melhores métricas de AUC-ROC e TE para as classes de alta e baixa suscetibilidade, nós optamos por selecioná-lo para representar a suscetibilidade a deslizamentos da área estudo.

6. Conclusão

O mapeamento da suscetibilidade a deslizamentos desempenha um importante papel na gestão de riscos naturais. Com a crescente incidência de deslizamentos em diversas regiões do mundo, em especial nas regiões montanhosas do Brasil, torna-se cada vez mais imperativo desenvolver abordagens eficazes para identificar áreas suscetíveis a estes eventos. Nesse contexto, as técnicas de aprendizado de máquina emergem como ferramentas promissoras, capazes de fornecer *insights* valiosos para a previsão e mitigação de deslizamentos. Assim, a presente pesquisa chegou as seguintes conclusões:

- (1) O índice de Ganho de Informação indicou de forma satisfatória a ordem de influência dos fatores condicionantes na modelagem da suscetibilidade a deslizamentos, sendo a declividade o fator mais importante, seguido pela geomorfologia, TWI, litologia, orientação das vertentes, TPI, distância da rede de drenagem, curvatura das vertentes e distância das vias;
- (2) Os melhores modelos produzidos por cada técnica estatística variaram a quantidade de fatores condicionantes considerados, evidenciando uma relação estreita entre o algoritmo de aprendizado de máquina e as peculiaridades da área de estudo;
- (3) As abordagens de Florestas Aleatórias, Regressão Logística e Redes Neurais Artificiais demonstraram bons desempenhos para a previsão espacial de escorregamentos na região estudada. Embora os resultados demonstrem compatibilidade estatística entre as três abordagens, o modelo de Florestas Aleatórias FA-6, que empregou todos os fatores condicionantes disponíveis no treinamento, apresentou elevada AUC-ROC (0,947) e Taxa de Eficiência muito significativa para as classes de alta e baixa suscetibilidade ($TE_i^{AS} = 0,03$ e $TE_i^{AS} = 6,808$). Este modelo também apresentou uma acurácia de 87,8%, precisão de 85,8%, sensibilidade de 90,6%, especificidade de 90,6% e F1-score de 88,1%, que reforçam sua capacidade em prever com pertinência áreas suscetíveis a deslizamentos;

- (4) As abordagens de aprendizado de máquina para o mapeamento de susceptibilidade a escorregamentos tem demonstrado alta capacidade preditiva, configurando ser uma confiável e robusta alternativa para a produção cartográfica, auxiliando engenheiros e tomadores de decisões na prevenção e mitigação de deslizamentos, especialmente em áreas de difícil acesso, como regiões montanhosas;
- (5) O desenvolvimento e aprimoramento de metodologias estatísticas para o mapeamento da suscetibilidade a deslizamentos, com destaque para as técnicas de aprendizado de máquina, ainda estão em ascensão no contexto internacional, em especial no Brasil. Nesse cenário, estes estudos desempenham um papel crucial ao proporcionar discussões valiosas e contribuir significativamente para o avanço da ciência.

Contribuições dos Autores: Conceitualização, M.O.X. e C.F.B.; metodologia, M.O.X.; validação, M.O.X.; análise formal, M.O.X.; investigação, M.O.X.; curadoria de dados, M.O.X.; redação—preparação do rascunho original, M.O.X. e C.F.B.; redação—revisão e edição, M.O.X. e C.F.B.; visualização, M.O.X.; supervisão, C.F.B.; administração do projeto, C.F.B. Todos os autores leram e concordaram com a versão publicada do manuscrito.

Financiamento: Esta pesquisa não recebeu nenhum financiamento externo.

Agradecimentos: Os autores gostariam de expressar sua sincera gratidão à Agência Espacial Europeia por fornecer dados gratuitos do Sentinel-2 e à Universidade Federal de Ouro Preto (UFOP) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) do Governo Federal do Brasil pelo apoio.

Conflito de Interesse: Os autores declaram não haver conflitos de interesse.

Referências

1. ABDELRAHMAN, M.M. **Instance-based Label Smoothing for Better Classifier Calibration**. Dissertação (Mestrado em Ciência da Computação) – Institute of Computer Science, University of Tartu, Tartu. 2020. 68p.
2. ABU EL-MAGD, S.A., ALI, S.A., PHAM, Q.B. Spatial modeling and susceptibility zonation of landslides using random forest, naïve bayes and K-nearest neighbor in a complicated terrain. **Earth Science Informatics**, V. 14, p. 1227–1243, 2021. DOI: 10.1007/s12145-021-00653-y
3. AGATONOVIC-KUSTRIN, S., BERESFORD, R. Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. **Journal of Pharmaceutical and Biomedical Analysis**, V. 22, p. 717–727, 2000. DOI: 10.1016/S0731-7085(99)00272-1
4. AHRENDT, A., ZUQUETTE, L.V. Triggering factors of landslides in Campos do Jordão city, Brazil. **Bulletin of Engineering Geology and the Environment**, V. 62, p. 231–244, 2003. DOI: 10.1007/s10064-003-0191-8
5. AKGUN, A. A comparison of landslide susceptibility maps produced by logistic regression, multi-criteria decision, and likelihood ratio methods: A case study at İzmir, Turkey. **Landslides**, V. 9, 93–106, 2012. DOI: 10.1007/s10346-011-0283-7
6. ALALOUL, W.S., QURESHI, A.H. Data Processing Using Artificial Neural Networks. In: HARKUT, D.G. (Ed.). **Dynamic Data Assimilation - Beating the Uncertainties**. 1ª Ed. Londres: IntechOpen. 2020. DOI: 10.5772/intechopen.91935
7. ALEOTTI, P., CHOWDHURY, R. Landslide hazard assessment: summary review and new perspectives. **Bulletin of Engineering Geology and the Environment**, V. 58, p. 21–44, 1999. DOI: 10.1007/s100640050066
8. ANBAZHAGAN, S., SAJINKUMAR, K.S. Geoinformatics in Terrain Analysis and Landslide Susceptibility Mapping in Part of Western Ghats, India. In: ANBAZHAGAN, S., SUBRAMANIAN, S.K., YANG, X. (Eds.). **Geoinformatics in Applied Geomorphology**. 1ª Ed. Boca Raton: CRC Press, 2011. p. 291–315.
9. ARMAŞ, I., VARTOLOMEI, F., STROIA, F., BRAŞOVEANU, L. Landslide susceptibility deterministic approach using geographic information systems: Application to Breaza town, Romania. **Natural Hazards**, V. 70, p. 995–1017, 2014. DOI: 10.1007/s11069-013-0857-x
10. BACHRI, S., SUMARMI, YUDHA IRAWAN, L., UTAYA, S., DWITRI NURDIANSYAH, F., ERFIKA NURJANAH, A., WAHYU NING TYAS, L., AMRI ADILLAH, A., SETIA PURNAMA, D. Landslide Susceptibility Mapping (LSM) in Kelud Volcano Using Spatial Multi-Criteria Evaluation. **IOP Conference Series: Earth and Environmental Science**. V. 273, 26p., 2019. DOI: 10.1088/1755-1315/273/1/012014

11. BARELLA, C.F., SOBREIRA, F.G., ZÊZERE, J.L. A comparative analysis of statistical landslide susceptibility mapping in the southeast region of Minas Gerais state, Brazil. **Bulletin of Engineering Geology and the Environment**. V. 78, p. 3205–3221, 2019. DOI: 10.1007/s10064-018-1341-3
12. BATISTA, P. **Avaliação geotécnica de misturas de um solo laterítico com cimento e bentonita para uso em cortinas verticais**. Dissertação (Mestrado em Geotecnia) – Programa de Pós-Graduação em Geotecnia, Universidade Federal de Ouro Preto, Ouro Preto. 2006. 100p.
13. BEGUERÍA, S. Validation and evaluation of predictive models in hazard assessment and risk management. **Natural Hazards**. V. 37, p. 315–329, 2006. DOI: 10.1007/s11069-005-5182-6
14. BISWAS, B., RAHAMAN, A., BARMAN, J. Comparative Assessment of FR and AHP Models for Landslide Susceptibility Mapping for Sikkim, India and Preparation of Suitable Mitigation Techniques. **Journal of the Geological Society of India**. V. 99, p. 791–801, 2023. DOI: 10.1007/s12594-023-2386-x
15. BISWAS, B., RANJAN, R. Landslide susceptibility mapping using integrated approach of multi-criteria and geospatial techniques at Nilgiris district of India. **Arabian Journal of Geosciences**. V. 14, 17p., 2021. DOI: 10.1007/s12517-021-07341-7
16. BLAIS-STEVENSON, A., BEHNIA, P. Debris flow susceptibility mapping using a qualitative heuristic method and Flow-R along the Yukon Alaska Highway Corridor, Canada. **Natural Hazards and Earth System Sciences**. V. 16, p. 449–462, 2016. DOI: 10.5194/nhess-16-449-2016
17. BORGA, M., DALLA FONTANA, G., DA ROS, D., MARCHI, L. Shallow landslide hazard assessment using a physically based model and digital elevation data. **Environmental Geology**. V. 35, p. 81–88, 1998. DOI: 10.1007/s002540050295
18. BUI, D.T., TSANGARATOS, P., NGUYEN, V.T., LIEM, N. VAN, TRINH, P.T. Comparing the prediction performance of a Deep Learning Neural Network model with conventional machine learning models in landslide susceptibility assessment. **Catena**. V. 188, 14p., 2020. DOI: 10.1016/j.catena.2019.104426
19. CALDERÓN-GUEVARA, W., SÁNCHEZ-SILVA, M., NITESCU, B., VILLARRAGA, D.F. Comparative review of data-driven landslide susceptibility models: case study in the Eastern Andes mountain range of Colombia. **Natural Hazards**. V. 113, p. 1105–1132, 2022. DOI: 10.1007/s11069-022-05339-2
20. CARVALHO, T.R.R. DE, SOBREIRA, F.G., BARELLA, C.F., PEDROSA, M.A.F. Aptidão urbana na bacia hidrográfica do Rio Maracujá, município de Ouro Preto, MG. In: 14º Congresso Brasileiro de Geologia de Engenharia e Ambiental, 2013, Rio de Janeiro. **Anais...** Rio de Janeiro: ABGE. 2013.
21. CEMADEN, 2024. **Mapa Interativo da Rede Observacional para Monitoramento de Risco de Desastres Naturais**. Disponível em <<http://www.cemaden.gov.br/mapainterativo>>. Acesso em: 26-03-24.
22. CHACÓN, J., IRIGARAY, C., FERNÁNDEZ, T., EL HAMDOUNI, R. Engineering geology maps: Landslides and geographical information systems. **Bulletin of Engineering Geology and the Environment**. V. 65. p. 341–411, 2006. DOI: 10.1007/s10064-006-0064-z
23. CHEN, C., SHEN, Z., WENG, Y., YOU, S., LIN, J., LI, S., WANG, K. Modeling Landslide Susceptibility in Forest-Covered Areas in Lin'an, China, Using Logistical Regression, a Decision Tree, and Random Forests. **Remote Sensing**. V. 15, 19p., 2023. DOI: 10.3390/rs15184378
24. CHEN, F., YU, B., LI, B. A practical trial of landslide detection from single-temporal Landsat8 images using contour-based proposals and random forest: a case study of national Nepal. **Landslides**. V. 15, p. 453–464, 2018. DOI: 10.1007/s10346-017-0884-x
25. CHEN, T., NIU, R., JIA, X. A comparison of information value and logistic regression models in landslide susceptibility mapping by using GIS. **Environmental Earth Sciences**. V. 75, n. 867, 16p., 2016. DOI: 10.1007/s12665-016-5317-y

26. CHEN, W., POURGHASEMI, H.R., NAGHIBI, S.A. Prioritization of landslide conditioning factors and its spatial modeling in Shangnan County, China using GIS-based data mining algorithms. **Bulletin of Engineering Geology and the Environment**. V. 77, p. 611–629, 2018. DOI: 10.1007/s10064-017-1004-9
27. CHOWDHURY, M.S. A review on landslide susceptibility mapping research in Bangladesh. **Heliyon**. V. 9, 22p., 2023. DOI: 10.1016/j.heliyon.2023.e17972
28. CHUNG, C.-J.F., FABRI, A.G. Validation of Spatial Prediction Models for Landslide Hazard Mapping, **Natural Hazards**. V. 30, p. 451-472, 2003. DOI: 10.1023/B:NHAZ.0000007172.62651.2b
29. COCO, L., MACRINI, D., PIACENTINI, T., BUCCOLINI, M. Landslide susceptibility mapping by comparing gis-based bivariate methods: A focus on the geomorphological implication of the statistical results. **Remote Sensing**. V. 13, 29p. 2021. DOI: 10.3390/rs13214280
30. CONFORTI, M., PASCALE, S., ROBUSTELLI, G., SDAO, F. Evaluation of prediction capability of the artificial neural networks for mapping landslide susceptibility in the Turbolo River catchment (northern Calabria, Italy). **Catena**. V. 113, p. 236–250, 2014. DOI: 10.1016/j.catena.2013.08.006
31. COROMINAS, J., VAN WESTEN, C., FRATTINI, P., CASCINI, L., MALET, J.P., FOTOPOULOU, S., CATANI, F., VAN DEN ECKHAUT, M., MAVROULI, O., AGLIARDI, F., PITILAKIS, K., WINTER, M.G., PASTOR, M., FERLISI, S., TOFANI, V., HERVÁS, J., SMITH, J.T. Recommendations for the quantitative analysis of landslide risk. **Bulletin of Engineering Geology and the Environment**. V. 73, p. 209–263, 2014. DOI: 10.1007/s10064-013-0538-8
32. COX, D.R. The Regression Analysis of Binary Sequences. **Journal of the Royal Statistical Society: Series B (Methodological)**. V. 20, p. 215–232, 1958. DOI: 10.1111/j.2517-6161.1958.tb00292.x
33. CRUZ, U.R.X.DA, OLIVEIRA, L.P.DE. Comparativo entre os métodos de classificação MaxVer e Random Forest utilizando imagem Sentinel-2B. **Cadernos do Leste**. V. 21, p. 1–19, 2021. DOI: 10.29327/248949.21.21-2
34. DAHAL, R.K., HASEGAWA, S., NONOMURA, A., YAMANAKA, M., MASUDA, T., NISHINO, K. GIS-based weights-of-evidence modelling of rainfall-induced landslides in small catchments for landslide susceptibility mapping. **Environmental Geology**. V. 54, p. 311–324, 2008. DOI: 10.1007/s00254-007-0818-3
35. DAO, D. VAN, JAAFARI, A., BAYAT, M., MAFI-GHOLAMI, D., QI, C., MOAYEDI, H., PHONG, T. VAN, LY, H.B., LE, T.T., TRINH, P.T., LUU, C., QUOC, N.K., THANH, B.N., PHAM, B.T. A spatially explicit deep learning neural network model for the prediction of landslide susceptibility. **Catena**. V. 188, 13p., 2020. DOI: 10.1016/j.catena.2019.104451
36. DEMSAR, J., CURK, T., ERJAVE, A., GORUP, C., HOCEVAR, T., MILUTINOVIC, M., MOZINA, M., POLAJNAR, M., TOPLAK, M., STARIC, A., STAJDOHAR, M., UMEK, L., ZAGAR, L., ZBONTAR, J., ZITNIK, M., ZUPAN, B. Orange: Data Mining Toolbox in Python. **Journal of Machine Learning Research**. V. 14, p. 2349–2353, 2013.
37. DIKAU, R. Derivatives from detailed geoscientific maps using computer methods. **Zeitschrift für Geomorphologie**. V. 2, n. 80, p. 45–55, 1990.
38. DO PINHO, T.M., AUGUSTO FILHO, O. Landslide susceptibility mapping using the infinite slope, SHALSTAB, SINMAP, and TRIGRS models in Serra do Mar, Brazil. **Journal of Mountain Science**. V. 19, p. 1018–1036, 2022. DOI: 10.1007/s11629-021-7057-z
39. DOMÍNGUEZ-CUESTA, M.J., JIMÉNEZ-SÁNCHEZ, M., COLUBI, A., GONZÁLEZ-RODRÍGUEZ, G. Modelling shallow landslide susceptibility: A new approach in logistic regression by using favourability assessment. **International Journal of Earth Sciences**. V. 99, p. 661–674, 2010. DOI: 10.1007/s00531-008-0414-0
40. EFIONG, J., ENI, D.I., OBIEFUNA, J.N., ETU, S.J. Geospatial modelling of landslide susceptibility in Cross River State of Nigeria. **Scientific African**. V. 14, 14p., 2021. DOI: 10.1016/j.sciaf.2021.e01032
41. EIRAS, C.G.S., SOUZA, J.R.G. DE, FREITAS, R.D.A. DE, BARELLA, C.F., PEREIRA, T.M. Discriminant analysis as an efficient method for landslide susceptibility assessment in cities with the scarcity of predisposition data. **Natural Hazards**. V. 107, p. 1427–1442, 2021. DOI: 10.1007/s11069-021-04638-4

42. ELMOULAT, M., BRAHIM, L.A., ELMAHSANI, A., ABDELOUAFI, A., MASTERE, M. Mass movements susceptibility mapping by using heuristic approach. Case study: province of Tétouan (North of Morocco). **Geoenvironmental Disasters**. V. 8, n. 20, 19p., 2021. DOI: 10.1186/s40677-021-00192-0
43. ENDO, I., GALBIATTI, H.F., DELGADO, C.E.R., OLIVEIRA, M.M.F. DE, ZAPPAROLI, A. DE C., MOURA, L.G.B. DE, PERES, G.G., OLIVEIRA, A.H. DE, ZAVAGLIA, G., DANDERFER, F.A., GOMES, C.J.S., CARNEIRO, M.A., NALINI JR., H.A., CASTRO, P. DE T.A., SUITA, M.T. DE F., TAZAVA, E., LANA, C. DE C., MARTINS-NETO, M.A., MARTINS, M. DE S., FERREIRA, F.F.A., FRANCO, A.P., ALMEIDA, L.G., ROSSI, D.Q., ANGELI, G., MADEIRA, T.J.A., PIASSA, L.R.A., MARIANO, D.F., CARLOS, D.U. **Mapa Geológico do Quadrilátero Ferrífero, Minas Gerais, Brasil**. Ouro Preto: Departamento de Geologia, Escola de Minas - UFOP - Centro de Estudos Avançados do Quadrilátero Ferrífero, 2019.
44. ESLAMINEZHAD, S.A., EFTEKHARI, M., AKBARI, M. GIS-Based Flood Risk Zoning Based On Data-Driven Models. **Journal of Hydraulic Structures**. V. 6, p. 75–98, 2020. DOI: 10.22055/jhs.2021.36629.1163
45. FELICÍSIMO, Á.M., CUARTERO, A., REMONDO, J., QUIRÓS, E. Mapping landslide susceptibility with logistic regression, multiple adaptive regression splines, classification and regression trees, and maximum entropy methods: A comparative study. **Landslides**. V. 10, p. 175–189, 2013. DOI: 10.1007/s10346-012-0320-1
46. FELL, R., COROMINAS, J., BONNARD, C., CASCINI, L., LEROI, E., SAVAGE, W.Z. Guidelines for landslide susceptibility, hazard and risk zoning for land use planning. **Engineering Geology**. 102, 85–98, 2008. DOI: 10.1016/j.enggeo.2008.03.022
47. FERNANDES, N.F., GUIMARÃES, R.F., GOMES, R.A.T., VIEIRA, B.C., MONTGOMERY, D.R., GREENBERG, H. Condicionantes Geomorfológicas dos Deslizamentos nas Encostas: Avaliação de Metodologias e Aplicação de Modelo de Previsão de Áreas Susceptíveis. **Revista Brasileira de Geomorfologia**. V. 2, p. 51–71, 2001. DOI: 10.20502/rbg.v2i1.8
48. GALLI, M., ARDIZZONE, F., CARDINALI, M., GUZZETTI, F., REICHENBACH, P. Comparing landslide inventory maps. **Geomorphology**. V. 94, p. 268–289, 2008. DOI: 10.1016/j.geomorph.2006.09.023
49. GARCIA, R.A.C. Metodologias de avaliação da perigosidade e risco associado a movimentos de vertente: aplicação na bacia do rio Alenquer. Tese (Doutorado em Geografia). Universidade de Lisboa, Lisboa. 2012. 437p.
50. GARDNER, M.W., DORLING, S.R. Artificial neural networks (the multilayer perceptron) - a review of applications in the atmospheric sciences. **Atmospheric Environment**. V. 32, p. 2627–2636, 1998. DOI: 10.1016/S1352-2310(97)00447-0
51. GRABOWSKI, D., LASKOWICZ, I., MAŁKA, A., RUBINKIEWICZ, J. Geoenvironmental conditioning of landsliding in river valleys of lowland regions and its significance in landslide susceptibility assessment: A case study in the Lower Vistula Valley, Northern Poland. **Geomorphology**. V. 419, 24p., 2022. DOI: 10.1016/j.geomorph.2022.108490
52. GUILLARD, C., ZEZE, J. Landslide susceptibility assessment and validation in the framework of municipal planning in Portugal: The case of Loures municipality. **Environmental Management**. V. 50, p. 721–735, 2012. DOI: 10.1007/s00267-012-9921-7
53. GUZZETTI, F., CARDINALI, M., REICHENBACH, P., CARRARA, A. Comparing landslide maps: A case study in the upper Tiber River basin, central Italy. **Environmental Management**. V. 25, p. 247–263, 2000. DOI: 10.1007/s002679910020
54. GUZZETTI, F., CARRARA, A., CARDINALI, M., REICHENBACH, P. Landslide hazard evaluation: a review of current techniques and their application in a multi-scale study, Central Italy. **Geomorphology**. V. 31, p. 181–216, 1999. DOI: 10.1016/S0169-555X(99)00078-1
55. GUZZETTI, F., REICHENBACH, P., ARDIZZONE, F., CARDINALI, M., GALLI, M. Estimating the quality of landslide susceptibility models. **Geomorphology**. V. 81, p. 166–184, 2006. DOI: 10.1016/j.geomorph.2006.04.007
56. GUZZETTI, F., REICHENBACH, P., CARDINALI, M., GALLI, M., ARDIZZONE, F. Probabilistic landslide hazard assessment at the basin scale. **Geomorphology**. V. 72, p. 272–299, 2005. DOI: 10.1016/j.geomorph.2005.06.002
57. HASTIE, T., TIBSHIRANI, R., FRIEDMAN, J. **The Elements of Statistical Learning: Data Mining, Inference, and Prediction**. 2ª Ed. Nova York: Springer, 2009. 758p. DOI: 10.1007/978-0-387-84858-7

58. HAYKIN, S. **Redes neurais: princípios e prática [translation]**. Trans. Paulo Martins Engel. 2ªEd. Porto Alegre: Bookman, 2001. 898p.
59. HECHT-NIELSEN, R. Kolmogorov's Mapping Neural Network Existence Theorem. In: IEEE First Annual International Conference on Neural Networks, 1987, San Diego, California. **Proceedings...** Nova York: IEEE press. 1987. p. 11–14.
60. HENRIQUES, C., ZÊZERE, J.L., MARQUES, F., 2015. The role of the lithological setting on the landslide pattern and distribution. **Engineering Geology**. V. 189, p. 17–31. DOI: 10.1016/j.enggeo.2015.01.025
61. HIRYE, M.C.M., ALVES, D.S., FILARDO, A.S., MCPHEARSON, T., WAGNER, F. Assessing Landslide Drivers in Social–Ecological–Technological Systems: The Case of Metropolitan Region of São Paulo, Brazil. **Remote Sensing**. V. 15, 26p., 2023. DOI: 10.3390/rs15123048
62. HUANG, R., LI, W. Formation, distribution and risk control of landslides in China. **Journal of Rock Mechanics and Geotechnical Engineering**. V. 3, p. 97–116, 2011. DOI: 10.3724/sp.j.1235.2011.00097
63. JEBUR, M.N., PRADHAN, B., TEHRANY, M.S. Manifestation of LiDAR-derived parameters in the spatial prediction of landslides using novel ensemble evidential belief functions and support vector machine models in GIS. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**. V. 8, n. 2, p. 674–690, 2015. DOI: 10.1109/JSTARS.2014.2341276
64. JENNIFER, J.J. Feature elimination and comparison of machine learning algorithms in landslide susceptibility mapping. **Environmental Earth Sciences**. V. 81, n. 489, 23p., 2022. DOI: 10.1007/s12665-022-10620-5
65. JIAO, Y., ZHAO, D., DING, Y., LIU, Y., XU, Q., QIU, Y., LIU, C., LIU, Z., ZHA, Z., LI, R. Performance evaluation for four GIS-based models purposed to predict and map landslide susceptibility: A case study at a World Heritage site in Southwest China. **Catena**. V. 183, 15p., 2019. DOI: 10.1016/j.catena.2019.104221
66. JOVANČEVIC, S.D., NAGAI, O., SASSA, K., ARBANAS, Ž. TXT-tool 3.385-1.2 deterministic landslide susceptibility analyses using LS-rapid software. In: SASSA, K. TIWARI, B., LIU, K., MCSAVENEY, M., STROM, A., SETIAWAN, H. (Eds.). **Landslide Dynamics: ISDR-ICL Landslide Interactive Teaching Tools. Volume 2: Testing, Risk Management and Country Practices**. Springer International Publishing, 2018. p. 169–179. Doi: 10.1007/978-3-319-57777-7_7
67. KAVZOGLU, T., SAHIN, E.K., COLKESEN, I. Landslide susceptibility mapping using GIS-based multi-criteria decision analysis, support vector machines, and logistic regression. **Landslides**. V. 11, p. 425–439, 2014. DOI: 10.1007/s10346-013-0391-7
68. KAVZOGLU, T., TEKE, A. Ensemble Conditioning Factor Selection with Markov Chain Framework for Shallow Landslide Susceptibility Mapping in Lake Sapanca Basin and its Vicinity, Turkey. **Baltic Journal of Modern Computing**. V. 10, p. 224–240, 2022. DOI: 10.22364/bjmc.2022.10.2.09
69. KINGMA, D.P., BA, J.L. Adam: A Method for Stochastic Optimization. **ArXiv preprint**. 15p., 2014. DOI: 10.48550/arXiv.1412.6980
70. KOPPE, G., MEYER-LINDENBERG, A., DURSTEWITZ, D. Deep learning for small and big data in psychiatry. **Neuropsychopharmacology**. V. 46, p. 176–190, 2021. DOI: 10.1038/s41386-020-0767-z
71. KUMAR, C., WALTON, G., SANTI, P., LUZA, C. An Ensemble Approach of Feature Selection and Machine Learning Models for Regional Landslide Susceptibility Mapping in the Arid Mountainous Terrain of Southern Peru. **Remote Sensing**. V. 15, 34p., 2023. DOI: 10.3390/rs15051376
72. LEE, S. Application of logistic regression model and its validation for landslide susceptibility mapping using GIS and remote sensing data. **International Journal of Remote Sensing**. V. 26, p. 1477–1491, 2005. DOI: 10.1080/01431160412331331012
73. LEE, S. Application of likelihood ratio and logistic regression models to landslide susceptibility mapping using GIS. **Environmental Management**. V. 34, p. 223–232, 2004. DOI: 10.1007/s00267-003-0077-3

74. LEE, S., MIN, K. Statistical analysis of landslide susceptibility at Yongin, Korea. **Environmental Geology**. V. 40, p. 1095–1113, 2001. DOI: 10.1007/s002540100310
75. LEE, SUNMIN, LEE, M.J., LEE, SARO. Spatial prediction of urban landslide susceptibility based on topographic factors using boosted trees. **Environmental Earth Sciences**. V. 77, n. 656, 22p., 2018. DOI: 10.1007/s12665-018-7778-7
76. LI, X., CHONG, J., LU, Y., LI, Z. Application of information gain in the selection of factors for regional slope stability evaluation. **Bulletin of Engineering Geology and the Environment**. V. 81, 15p., 2022. DOI: 10.1007/s10064-022-02970-y
77. LIMA, P., STEGER, S., GLADE, T., MURILLO-GARCIA, F.G. Literature Review and Bibliometric Analysis on Data-Driven Assessment of Landslide Susceptibility. **Journal of Mountain Science**. V. 19, p. 1670-1698, 2022. DOI: 10.1007/s11629-021-7254-9
78. LIU, R., YANG, X., XU, C., WEI, L., ZENG, X. Comparative Study of Convolutional Neural Network and Conventional Machine Learning Methods for Landslide Susceptibility Mapping. **Remote Sensing**. V. 14, 31p., 2022. DOI: 10.3390/rs14020321
79. LOTT, B.A., MAGALHÃES, M.E.O.C., CUNHA, D.M., PANQUESTOR, E.K., DA SILVA, R.V. Chuvas na Bacia Hidrográfica do Rio Doce – MG/ES no primeiro trimestre de 2020, in: **Sociedade, Tecnologia e Meio Ambiente: avanços, retrocessos e novas perspectivas**. Editora Científica Digital, pp. 110–126. 2021. DOI: 10.37885/210906068
80. MASCANZONI, E., PEREGO, A., MARCHI, N., SCARABEL, L., PANOZZO, S., FERRERO, A., ACUTIS, M., SATTIN, M. Epidemiology and agronomic predictors of herbicide resistance in rice at a large scale. **Agronomy for Sustainable Development**. V. 38, n. 68, 10p., 2018. DOI: 10.1007/s13593-018-0548-9
81. MAURIZIO, L., MARIA, D. A multi temporal kernel density estimation approach for new triggered landslides forecasting and susceptibility assessment. **Disaster Advances**. V. 5, p. 100–108, 2012.
82. MCCULLOCH, W.S., PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**. V. 5, p. 115–133, 1943. DOI: 10.1007/BF02478259
83. MERGHADI, A., YUNUS, A.P., DOU, J., WHITELEY, J., THAIPHAM, B., BUI, D.T., AVTAR, R., ABDERRAHMANE, B. Machine learning methods for landslide susceptibility studies: A comparative overview of algorithm performance. **Earth-Science Reviews**. V. 207, 47p., 2020. DOI: 10.1016/j.earscirev.2020.103225
84. MICHEL, G.P., KOBAYAMA, M., GOERL, R.F. Comparative analysis of SHALSTAB and SINMAP for landslide susceptibility mapping in the Cunha River basin, southern Brazil. **Journal of Soils and Sediments**. V. 14, p. 1266–1277, 2014. DOI: 10.1007/s11368-014-0886-4
85. MICHELETTI, N., FORESTI, L., ROBERT, S., LEUENBERGER, M., PEDRAZZINI, A., JABOYEDOFF, M., KANEVSKI, M. Machine Learning Feature Selection Methods for Landslide Susceptibility Mapping. **Mathematical Geosciences**. V. 46, p. 33–57, 2014. DOI: 10.1007/s11004-013-9511-0
86. MIRANDA, C.E.B., BOMBACINI, M.R. Aplicação da Regressão Logística Binária para Manutenção Preditiva em Máquinas de Ressonância Magnética. In: XIII Congresso Brasileiro de Engenharia de Produção, 2023. **Anais...** APREPRO, 2023. 12p.
87. MOORE, I.D., GRAYSON, R.B., LADSON, A.R. Digital terrain modelling: A review of hydrological, geomorphological, and biological applications. **Hydrological Processes**. V. 5, p. 3–30, 1991. DOI: 10.1002/hyp.3360050103
88. MOULOODI, S., RAHMANPANA, H., GOHARI, S., BURVILL, C., TSE, K.M., DAVIES, H.M.S. What can artificial intelligence and machine learning tell us? A review of applications to equine biomechanical research. **Journal of the Mechanical Behavior of Biomedical Materials**. V. 123, 13p., 2021. DOI: 10.1016/j.jmbbm.2021.104728
89. MURILLO-GARCÍA, F.G., ALCÁNTARA-AYALA, I. Landslide susceptibility analysis and mapping using statistical multivariate techniques: Pahuatlán, Puebla, Mexico. In: WU, W. (Ed.). **Recent Advances in Modeling Landslides and Debris Flows**. Springer Series in Geomechanics and Geoenvironment. Springer, Cham, 2015. p. 179–194, 2015. DOI: 10.1007/978-3-319-11053-0_16

90. NAEMITABAR, M., ZANGANEH ASADI, M. Landslide zonation and assessment of Farizi watershed in northeastern Iran using data mining techniques. **Natural Hazards**. V. 108, p. 2423–2453, 2021. DOI: 10.1007/s11069-021-04805-7
91. NAIR, V., HINTON, G.E. Rectified Linear Units Improve Restricted Boltzmann Machines, In: 27th International Conference on Machine Learning (ICML), 2010, Haifa, Israel. **Anais...** 2010, p. 807–814.
92. NASKATH, J., SIVAKAMASUNDARI, G., BEGUM, A.A.S. A Study on Different Deep Learning Algorithms Used in Deep Neural Nets: MLP SOM and DBN. **Wireless Personal Communications**. V. 128, p. 2913–2936, 2023. DOI: 10.1007/s11277-022-10079-4
93. NEFESLIOGLU, H.A., DUMAN, T.Y., DURMAZ, S. Landslide susceptibility mapping for a part of tectonic Kelkit Valley (Eastern Black Sea region of Turkey). **Geomorphology**. V. 94, p. 401–418, 2008. DOI: 10.1016/j.geomorph.2006.10.036
94. NG, A.Y. Feature selection, L 1 vs. L 2 regularization, and rotational invariance. In: 21th International Conference on Machine Learning, 2004, Banff, Alberta, Canada. **Proceedings...** Nova York: Association for Computing Machinery, 2004. 8p. DOI: 10.1145/1015330.1015435
95. NHU, V.H., HOANG, N.D., NGUYEN, H., NGO, P.T.T., THANH BUI, T., HOA, P.V., SAMUI, P., TIEN BUI, D. Effectiveness assessment of Keras based deep learning with different robust optimization algorithms for shallow landslide susceptibility mapping at tropical area. **Catena**. V. 188, 13p., 2020. DOI: 10.1016/j.catena.2020.104458
96. NOHANI, E., MOHARRAMI, M., SHARAFI, S., KHOSRAVI, K., PRADHAN, B., PHAM, B.T., LEE, S., MELESSE, A.M. Landslide susceptibility mapping using different GIS-Based bivariate models. **Water**. V. 11, 22p., 2019. DOI: 10.3390/w11071402
97. NOLA, I.T. DE S. Análise multicritério e aprendizado de máquina aplicados na predição do potencial espeleológico da região do Parque Nacional Serra do Gandarela, Quadrilátero Ferrífero/MG. Tese (Doutorado em Geotecnia). Programa de Pós-Graduação em Geotecnia, Universidade Federal de Ouro Preto, Ouro Preto. 2022. 138p.
98. OGILA, W.A.M. Analysis and assessment of slope instability along international mountainous road in North Africa. **Natural Hazards**. V. 106, p. 2479–2517, 2021. DOI: 10.1007/s11069-021-04552-9
99. OH, H.J., LEE, S. Landslide susceptibility mapping on Panaon Island, Philippines using a geographic information system. **Environmental Earth Sciences**. V. 62, p. 935–951, 2011. DOI: 10.1007/s12665-010-0579-2
100. OHLMACHER, G.C. Plan curvature and landslide probability in regions dominated by earth flows and earth slides. **Engineering Geology**. V. 91, p. 117–134, 2007. DOI: 10.1016/j.enggeo.2007.01.005
101. OLIVEIRA, G.G. DE, RUIZ, L.F.C., GUASSELLI, L.A., HAETINGER, C. Random forest and artificial neural networks in landslide susceptibility modeling: a case study of the Fão River Basin, Southern Brazil. **Natural Hazards**. V. 99, p. 1049–1073, 2019. DOI: 10.1007/s11069-019-03795-x
102. PANDEY, V.H.R., KAINTHOLA, A., SHARMA, V., SRIVASTAV, A., JAYAL, T., SINGH, T.N. Deep learning models for large-scale slope instability examination in Western Uttarakhand, India. **Environmental Earth Sciences**. V. 81, n. 487, 18p., 2022. DOI: 10.1007/s12665-022-10590-8
103. PARK, Y.S., LEK, S. Artificial Neural Networks: Multilayer Perceptron for Ecological Modeling. In: JØRGENSEN, S.E. **Developments in Environmental Modelling**. Elsevier B.V., 2016. p. 123–140. DOI: 10.1016/B978-0-444-63623-2.00007-4
104. PAUL, S.G., BISWAS, A.A., SAHA, A., ZULFIKER, M.S., RITU, N.A., ZAHAN, I., RAHMAN, M., ISLAM, M.A. A real-time application-based convolutional neural network approach for tomato leaf disease classification. **Array**. V. 19, 14p., 2023. DOI: 10.1016/j.array.2023.100313
105. PAWLUSZEK, K., BORKOWSKI, A. Impact of DEM-derived factors and analytical hierarchy process on landslide susceptibility mapping in the region of Rożnów Lake, Poland. **Natural Hazards**. V. 86, p. 919–952, 2017. DOI: 10.1007/s11069-016-2725-y

106. PHAM, B.T., BUI, D.T., DHOLAKIA, M.B., PRAKASH, I., PHAM, H.V., MEHMOOD, K., LE, H.Q. A novel ensemble classifier of rotation forest and Naïve Bayer for landslide susceptibility assessment at the Luc Yen district, Yen Bai Province (Viet Nam) using GIS. **Geomatics, Natural Hazards and Risk**. V. 8, p. 649–671, 2017. DOI: 10.1080/19475705.2016.1255667
107. PHAM, B.T., PRADHAN, B., TIEN BUI, D., PRAKASH, I., DHOLAKIA, M.B. A comparative study of different machine learning methods for landslide susceptibility assessment: A case study of Uttarakhand area (India). **Environmental Modelling and Software**. V. 84, p. 240–250, 2016. DOI: 10.1016/j.envsoft.2016.07.005
108. PHAM, B.T., SHIRZADI, A., SHAHABI, H., OMIDVAR, E., SINGH, S.K., SAHANA, M., ASL, D.T., AHMAD, B. BIN, QUOC, N.K., LEE, S. Landslide susceptibility assessment by novel hybrid machine learning algorithms. **Sustainability**. V. 11, 25p., 2019. DOI: 10.3390/su11164386
109. PHAM, B.T., VAN DAO, D., ACHARYA, T.D., VAN PHONG, T., COSTACHE, R., VAN LE, H., NGUYEN, H.B.T., PRAKASH, I. Performance assessment of artificial neural network using chi-square and backward elimination feature selection methods for landslide susceptibility analysis. **Environmental Earth Sciences**. V. 80, n. 686, 13p., 2021. DOI: 10.1007/s12665-021-09998-5
110. PIMIENTO, E. **Shallow Landslide Susceptibility Modelling and Validation**. Dissertação (Mestrado em Ciência da Informação Geográfica). Department of Physical Geography and Ecosystem Analysis Centre for Geographical Information Systems, Lund University, Lund, Sweden. 2010. 104p.
111. PINHEIRO, M.A.P., MAGALHÃES, J.R., SILVA, M.A. DA, 2023. **Carta geológica: SF.23-X-B-I-3-SE (em revisão)**. Programa Geologia, Mineração e Transformação Mineral: Ação Levantamentos Geológicos e Integração Geológica Regional. Serviço Geológico do Brasil – SGB, 2023. 1:25.000
112. POURGHASEMI, H.R., KERLE, N. Random forests and evidential belief function-based landslide susceptibility assessment in Western Mazandaran Province, Iran. **Environmental Earth Sciences**. V. 75, p. 1–17, 2016. DOI: 10.1007/s12665-015-4950-1
113. POURGHASEMI, H.R., PRADHAN, B., GOKCEOGLU, C., DEYLAMI MOEZZI, K. Landslide susceptibility mapping using a spatial multi criteria evaluation model at haraz watershed, Iran. In: PRADHAN, B., BUCHROITHNER, M. (Ed.). **Terrigenous Mass Movements: Detection, Modelling, Early Warning and Mitigation Using Geoinformation Technology**. Berlin: Springer, 2012. p. 23–49. DOI: 10.1007/978-3-642-25495-6_2
114. POURGHASEMI, H.R., RAHMATI, O. Prediction of the landslide susceptibility: Which algorithm, which precision? **Catena**. V. 162, p. 177–192, 2018. DOI: 10.1016/j.catena.2017.11.022
115. POURGHASEMI, H.R., TEIMOORI YANSARI, Z., PANAGOS, P., PRADHAN, B. Analysis and evaluation of landslide susceptibility: a review on articles published during 2005–2016 (periods of 2005–2012 and 2013–2016). **Arabian Journal of Geosciences**. V. 11, 12p., 2018. DOI: 10.1007/s12517-018-3531-5
116. PRADHAN, B., SEENI, M.I., KALANTAR, B. Performance evaluation and sensitivity analysis of expert-based, statistical, machine learning, and hybrid models for producing landslide susceptibility maps. In: PRADHAN, B. (Ed.). **Laser Scanning Applications in Landslide Assessment**. Berlin: Springer, 2017. p. 193–232. DOI: 10.1007/978-3-319-55342-9_11
117. PRECHELT, L. Early Stopping - But When? In: ORR, G.B., MÜLLER, K.-R. (Eds.). **Neural Networks: Tricks of the Trade**. Berlin, Heidelberg, New York, Barcelona, Hong Kong, London, Milan, Paris, Singapore, Tokyo: Springer, 1998. p. 55–69. DOI: 10.1007/978-3-642-35289-8_5
118. QGIS DEVELOPMENT TEAM. **QGIS Geographic Information System (versão 3.12.3)**. 2020. Disponível em: <<http://qgis.osgeo.org>>.
119. QUINLAN. Induction of Decision Trees. **Machine Learning**. V. 1, p. 81–106, 1986. DOI: 10.1007/BF00116251
120. RAHMATI, O., HAGHIZADEH, A., POURGHASEMI, H.R., NOORMOHAMADI, F. Gully erosion susceptibility mapping: the role of GIS-based bivariate statistical models and their comparison. **Natural Hazards**. V. 82, p. 1231–1258, 2016. DOI: 10.1007/s11069-016-2239-7

121. REICHENBACH, P., ROSSI, M., MALAMUD, B.D., MIHIR, M., GUZZETTI, F. A review of statistically-based landslide susceptibility models. **Earth-Science Reviews**. V. 180, p. 60–91, 2018. DOI: 10.1016/j.earscirev.2018.03.001
122. RUFF, M., CZURDA, K. Landslide susceptibility analysis with a heuristic approach in the Eastern Alps (Vorarlberg, Austria). **Geomorphology**. V. 94, p. 314–324, 2008. DOI: 10.1016/j.geomorph.2006.10.032
123. SAHIN, E.K., COLKESEN, I., ACMALI, S.S., AKGUN, A., AYDINOGLU, A.C. Developing comprehensive geocomputation tools for landslide susceptibility mapping: LSM tool pack. **Computers & Geosciences**. V. 144, 16p., 2020. DOI: 10.1016/j.cageo.2020.104592
124. SANTACANA, N., BAEZA, B., COROMINAS, J., DE PAZ, A., MARTURIÁ, J. A GIS-Based Multivariate Statistical Analysis for Shallow Landslide Susceptibility Mapping in La Pobla de Lillet Area (Eastern Pyrenees, Spain). **Natural Hazards**. V. 30, p. 281–295, 2003. DOI: 10.1023/B:NHAZ.0000007169.28860.80
125. SARFRAZ, Y., BASHARAT, M., RIAZ, M.T., AKRAM, M.S., XU, C., AHMED, K.S., SHAHZAD, A., AL-ANSARI, N., LINH, N.T.T. Application of statistical and machine learning techniques for landslide susceptibility mapping in the Himalayan road corridors. **Open Geosciences**. V. 14, p. 1606–1635, 2022. DOI: 10.1515/geo-2022-0424
126. SEPÚLVEDA, S.A., PETLEY, D.N. Regional trends and controlling factors of fatal landslides in Latin America and the Caribbean. **Natural Hazards and Earth System Sciences**. V. 15, p. 1821–1833, 2015. DOI: 10.5194/nhess-15-1821-2015
127. SHAHABI, H., AHMADI, R., ALIZADEH, M., HASHIM, M., AL-ANSARI, N., SHIRZADI, A., WOLF, I.D., ARIFFIN, E.H. Landslide Susceptibility Mapping in a Mountainous Area Using Machine Learning Algorithms. **Remote Sensing**. V. 15, 18p., 2023. DOI: 10.3390/rs15123112
128. SHAHZAD, N., DING, X., ABBAS, S. A Comparative Assessment of Machine Learning Models for Landslide Susceptibility Mapping in the Rugged Terrain of Northern Pakistan. **Applied Sciences**. V. 12, 23p., 2022. DOI: 10.3390/app12052280
129. SHIRANI, K., PASANDI, M., ARABAMERI, A. Landslide susceptibility assessment by Dempster–Shafer and Index of Entropy models, Sarkhoun basin, Southwestern Iran. **Natural Hazards**. V. 93, p. 1379–1418, 2018. DOI: 10.1007/s11069-018-3356-2
130. SIDUMO, B., SONONO, E., TAKAIDZA, I. An approach to multi-class imbalanced problem in ecology using machine learning. **Ecological Informatics**. V. 71, 8p., 2022. DOI: 10.1016/j.ecoinf.2022.101822
131. SINGH, A., ASHULI, A., NIRAJ, K.C., DHIMAN, N., DUBEY, C.S., SHUKLA, D.P. Evaluating causative factors for landslide susceptibility along the Imphal-Jiribam railway corridor in the North-Eastern part of India using a GIS-based statistical approach. **Environmental Science and Pollution Research**. 18p. 2023. DOI: 10.1007/s11356-023-28966-z
132. SOBREIRA, F.G., SOUZA, L.A. DE, BARELLA, C.F., PEDROSA, M.A.F., CARVALHO, T.R. DE, SILVA, N. DE L. Elaboração de Cartas Geotécnicas de Aptidão à Urbanização Frente aos Desastres Naturais no Município de Ouro Preto, MG: Carta de Aptidão à Urbanização da Bacia do Rio Maracujá Escala 1:25000. Ouro Preto: 2013. UFOP.
133. SOETERS, R., VAN WESTEN, C.J. Slope instability recognition, analysis and zonation. In: A.K. TURNER, R.L. SHUSTER (Eds.). **Landslides: Investigation and Mitigation**. Idaho: Transportation Research Board, National Research Council, 1996. p. 129–177.
134. SOLANKI, A., GUPTA, V., JOSHI, M. Application of machine learning algorithms in landslide susceptibility mapping, Kali Valley, Kumaun Himalaya, India. **Geocarto International**. V. 37, p. 16846–16871, 2022. DOI: 10.1080/10106049.2022.2120546
135. SOUZA, L.A. DE. Cartografia geoambiental e cartografia geotécnica progressiva em diferentes escalas: aplicação na bacia hidrográfica do Ribeirão do Carmo, município de Ouro Preto e Mariana, Minas Gerais. Tese (Doutorado em Geotecnia). Programa de Pós-Graduação em Geotecnia, Universidade Federal de Ouro Preto, Ouro Preto. 2015. 461p.

- 136.SOUZA, L.A. DE. **Diagnóstico do meio físico como contribuição ao ordenamento territorial do município de Mariana – MG**. Dissertação (Mestrado em Geotecnia). Programa de Pós-Graduação em Geotecnia, Universidade Federal de Ouro Preto, Ouro Preto. 2004. 182p.
- 137.SOUZA, L.A. DE., SOBREIRA F.G. Proposta de unidades geomorfológicas como suporte ao planejamento urbano e ordenamento territorial. **Revista Brasileira de Geomorfologia**. V. 18, n. 4, 703-717, 2017. DOI: <https://doi.org/10.20502/rbg.v18i4.1235>
- 138.SOUZA, M.A.A. DE, SOUZA, L.A. DE, COELHO, G.L.L.M., MELO, A.L. DE. Levantamento malacológico e mapeamento das áreas de risco para transmissão da esquistossomose mansoni no Município de Mariana, Minas Gerais, Brasil. **Revista de Ciências Médicas e Biológicas**. V. 5, p. 132–139, 2006.
- 139.STANLEY, T., KIRSCHBAUM, D.B. A heuristic approach to global landslide susceptibility mapping. **Natural Hazards**. V. 87, p. 145–164, 2017. DOI: 10.1007/s11069-017-2757-y
- 140.TANOLI, J.I., JEHANGIR, A., QASIM, M., REHMAN, M. UR, SHAH, S.T.H., ALI, M., JADOON ISHTIAQ AHMAD KHAN. Application of bivariate statistical techniques for landslide susceptibility mapping: A case study in Kaghan Valley, NW Pakistan. **Geological Journal**. V. 58, p. 4576–4595, 2023.
- 141.THANH, L.N., DE SMEDT, F. Application of an analytical hierarchical process approach for landslide susceptibility mapping in A Luoi district, Thua Thien Hue Province, Vietnam. **Environmental Earth Sciences**. V. 66, p. 1739–1752, 2012. DOI: 10.1007/s12665-011-1397-x
- 142.TIAGO DAMAS, M., BIANCA CARVALHO, V., NELSON FERREIRA, F., CHISATO, O., DAVID R., M. Application of the SHALSTAB model for the identification of areas susceptible to landslides: Brazilian case studies. **Revista de Geomorfologie**. V. 19, p. 136–144, 2017. DOI: 10.21094/rg.2017.015
- 143.TSAI, F., LAI, J.S., CHEN, W.W., LIN, T.H. Analysis of topographic and vegetative factors with data mining for landslide verification. **Ecological Engineering**. V. 61, p. 669–677, 2013. DOI: 10.1016/j.ecoleng.2013.07.070
- 144.TZOUVARAS, M. Statistical time-series analysis of interferometric coherence from sentinel-1 sensors for landslide detection and early warning. **Sensors**. V. 21, 19p., 2021. DOI: 10.3390/s21206799
- 145.UEHARA, T.D.T., PASSOS CORRÊA, S.P.L., QUEVEDO, R.P., KÖRTING, T.S., DUTRA, L.V., RENNÓ, C.D. Landslide scars detection using remote sensing and pattern recognition techniques: Comparison among artificial neural networks, gaussian maximum likelihood, random forest, and support vector machine classifiers. **Revista Brasileira de Cartografia**. V. 72, p. 665–680, 2020. DOI: 10.14393/rbcv72n4-54037
- 146.ULLAH, I., ASLAM, B., SHAH, S.H.I.A., TARIQ, A., QIN, S., MAJEED, M., HAVENITH, H.B. An Integrated Approach of Machine Learning, Remote Sensing, and GIS Data for the Landslide Susceptibility Mapping. **Land**. V. 11, 20p., 2022. DOI: 10.3390/land11081265
- 147.WALKER, S.H., DUNCAN, D.B. Estimation of the Probability of an Event as a Function of Several Independent Variables. **Biometrika**. V. 54, p. 167–179, 1967.
- 148.WANG, H., ZHANG, L., YIN, K., LUO, H., LI, J. Landslide identification using machine learning. **Geoscience Frontiers**. V. 12, p. 351–364, 2021. DOI: 10.1016/j.gsf.2020.02.012
- 149.WANG, Y., FANG, Z., WANG, M., PENG, L., HONG, H. Comparative study of landslide susceptibility mapping with different recurrent neural networks. **Computers & Geosciences**. V. 138, 18p., 2020. DOI: 10.1016/j.cageo.2020.104445
- 150.XU, B., WANG, N., CHEN, T., LI, M. Empirical Evaluation of Rectified Activations in Convolutional Network. **ArXiv preprint**. 5p., 2015. DOI: 10.48550/arXiv.1505.00853
- 151.XU, C., XU, X., DAI, F., WU, Z., HE, H., SHI, F., WU, X., XU, S. Application of an incomplete landslide inventory, logistic regression model and its validation for landslide susceptibility mapping related to the May 12, 2008 Wenchuan earthquake of China. **Natural Hazards**. V. 68, p. 883–900, 2013. DOI: 10.1007/s11069-013-0661-7

152. YESILNACAR, E., SÜZEN, M.L. A land-cover classification for landslide susceptibility mapping by using feature components. **International Journal of Remote Sensing**. V. 27, p. 253–275, 2006. DOI: 10.1080/0143116050030042
153. YI, Y., ZHANG, W., XU, X., ZHANG, Z., WU, X. Evaluation of neural network models for landslide susceptibility assessment. **International Journal of Digital Earth**. V. 15, p. 934–953, 2022. DOI: 10.1080/17538947.2022.2062467
154. YI, Y., ZHANG, Z., ZHANG, W., XU, C. Comparison of Different Machine Learning Models For Landslide Susceptibility Mapping. In: International Geoscience and Remote Sensing Symposium, 2019, Yokohama, Japão. **Proceedings...** Nova York: IEEE Press. 2019. p. 9318–9321. DOI: 10.1109/IGARSS.2019.8898208
155. YILMAZ, I. A case study from Koyulhisar (Sivas-Turkey) for landslide susceptibility mapping by artificial neural networks. **Bulletin of Engineering Geology and the Environment**. V. 68, p. 297–306, 2009. DOI: 10.1007/s10064-009-0185-2
156. YOUSSEF, A.M., POURGHASEMI, H.R. Landslide susceptibility mapping using machine learning algorithms and comparison of their performance at Abha Basin, Asir Region, Saudi Arabia. **Geoscience Frontiers**. V. 12, p. 639–655, 2021. DOI: 10.1016/j.gsf.2020.05.010
157. ZAJMI, L., AHMED, F.Y.H., JAHARADAK, A.A. Concepts, Methods, and Performances of Particle Swarm Optimization, Backpropagation, and Neural Networks. **Applied Computational Intelligence and Soft Computing**. V. 2018, 7p., 2018. DOI: 10.1155/2018/9547212
158. ZHANG, K., WU, X., NIU, R., YANG, K., ZHAO, L. The assessment of landslide susceptibility mapping using random forest and decision tree methods in the Three Gorges Reservoir area, China. **Environmental Earth Sciences**. V. 76, n. 405, 20p., 2017. DOI: 10.1007/s12665-017-6731-5
159. ZHANG, S., BAI, L., LI, Y., LI, W., XIE, M. Comparing Convolutional Neural Network and Machine Learning Models in Landslide Susceptibility Mapping: A Case Study in Wenchuan County. **Frontiers in Environmental Science**. V. 10, 12p., 2022. DOI: 10.3389/fenvs.2022.886841
160. ZIMMERMANN, M., BICHSEL, M., KIENHOLZ, H. Mountain Hazards Mapping in the Khumbu Himal, Nepal. **Mountain Research and Development**. V. 6, n. 1, p. 29–40, 1986. DOI: 10.2307/3673338



Esta obra está licenciada com uma Licença Creative Commons Atribuição 4.0 Internacional (<http://creativecommons.org/licenses/by/4.0/>) – CC BY. Esta licença permite que outros distribuam, remixem, adaptem e criem a partir do seu trabalho, mesmo para fins comerciais, desde que lhe atribuam o devido crédito pela criação original.