

Modelagem de suscetibilidade à ruptura de movimentos de massa

Renata Pacheco Quevedo¹

¹ Instituto Nacional de Pesquisas Espaciais – INPE
Caixa Postal 515 – 12227-010 – São José dos Campos – SP, Brasil
renata.quevedo@inpe.br

Resumo: Os movimentos de massa são fenômenos desencadeados por precipitações extremas, terremotos ou atividades antrópicas. Segundo o Atlas Brasileiro de Desastres Naturais, os movimentos de massa são responsáveis por desastres que envolvem elevado número de mortos, e foram os responsáveis pelo segundo maior número de obtidos entre 1991 e 2012. Nesse contexto, o mapeamento de suscetibilidade, juntamente com a análise espacial, é de suma importância para que os agentes públicos locais possam evitar a ocupação de áreas propensas à ocorrência desse tipo de fenômeno e/ou instalar sistemas de alerta para locais com urbanização consolidada. O objetivo do presente trabalho foi analisar potenciais áreas de ruptura a partir de análise espacial e modelagem estatística. Foram realizadas análises exploratórias, de modo a confirmar a presença de clusters. Os atributos preditivos utilizados foram: Elevação, Declividade, Orientação da Vertente, Comprimento da Rampa, Curvatura de Perfil, Curvatura Plana, Fluxo Acumulado, Direção de Fluxo, Distância Vertical da Drenagem, Distância da Drenagem e Distância das Vias de Acesso. A modelagem de suscetibilidade à ruptura de movimentos de massa foi realizada a partir de *Random Forest*, Regressão Logística e Regressão Logística Espacial. Nos modelos sem correção de autocorrelação espacial, os atributos mais importantes foram a Declividade e a Elevação, os quais apresentaram, juntos, valor acima de 60%. Na Regressão Logística Espacial, o atributo mais importante foi a Declividade (45,71%), seguido pela Distância das Vias de Acesso (17,17%). Quanto à acurácia, todos os modelos apresentaram valores acima de 0.94, o que demonstra ótimo desempenho dos modelos. Destaca-se, ainda, que o modelo de Regressão Logística Espacial apresentou maior AUC (0.9657) entre os modelos utilizados, demonstrando a importância da correção de autocorrelação espacial para modelagem de áreas suscetíveis à ruptura de movimentos de massa.

Palavras-chave: *Random Forest*, Regressão Logística, Regressão Logística Espacial, Bacia Hidrográfica do Rio Rolante

1. Introdução

Os movimentos de massa são processos geomorfológicos naturais, caracterizados pelo deslocamento de material de encostas sob ação da gravidade, associados à dinâmica de vertentes, podendo ser causados por terremotos, degelo ou precipitações intensas (DAVIES, 2015). Estes processos estão entre os desastres que causam maior número de vítimas fatais; como exemplo, os eventos de Itajaí (2008), em Santa Catarina, e da região serrana do Rio de Janeiro (2011), foram responsáveis por um elevado número de vítimas, 135 e 917 mortes, respectivamente (CEPED UFSC, 2013).

De forma a evitar a ocupação de áreas suscetíveis a movimentos de massa, além de possibilitar a reorganização do espaço urbano e identificar áreas prioritárias para instalação de sistemas de alerta, o mapeamento de suscetibilidade apresenta-se como uma importante ferramenta de auxílio aos gestores locais para o planejamento urbano, (ADITIAN; KUBOTA; SHINOHARA, 2018). O avanço neste tipo de mapeamento acontece a partir da modelagem realizada por meio de diferentes métodos e pela busca por fatores condicionantes que descrevam de maneira adequada os movimentos de massa (STANLEY; KIRSCHBAUM, 2017; MOKHTARI; ABEDIAN, 2019).

Assume-se que a ocorrência de movimentos de massa futuros será de maneira similar às aquelas verificadas no passado, considerando-se diferentes etapas do processo: ruptura, deslocamento e deposição. A motivação se dá devido aos estudos comumente analisarem os movimentos de massa previamente ocorridos em sua totalidade, sem considerar as características diferentes em cada etapa do processo. Considera-se a hipótese de que o inventário de cicatrizes de movimentos de massa relativo às áreas de ruptura, ao ser modelado, apresentará áreas de suscetibilidade diferentes daquelas associadas ao inventário completo, possibilitando seu uso para mitigar o início do fenômeno. Nesse contexto, o presente trabalho tem como objetivo analisar potenciais áreas de ruptura a partir de análise espacial e modelagem estatística, considerando-se atributos preditivos extraídos de modelo digital de elevação e localização de vias de acesso.

2. Caracterização da Área de Estudo

A Bacia Hidrográfica do Rio Rolante (BHRR) faz parte da Região Hidrográfica do Lago Guaíba, e está localizada no estado do Rio Grande do Sul (Figura 1). A BHRR abrange uma área de 828 km², caracterizada por um desnível altimétrico próximo aos 1000 (mil) metros e

predominantemente de relevo ondulado a fortemente ondulado (QUEVEDO *et al.*, 2019). A BHRR encontra-se assentada sobre rochas basálticas da Formação Serra Geral e arenitos da Formação Botucatu. De acordo com Rossato (2011), o clima da região é caracterizado como subtropical muito úmido, o qual apresenta precipitações distribuídas ao longo do ano, com médias anuais entre 1700 e 2000 mm.

O uso e cobertura da terra na bacia apresenta características rurais, com presença de cobertura vegetal predominantemente florestal, contendo Florestas Estacional Semidecidual e Ombrófila Mista. Ademais, são encontradas atividades relacionadas a pastagens, silvicultura e áreas agrícolas, e campos nativos na porção norte da bacia (GAMEIRO *et al.*, 2019; LUERCE, 2015). A infraestrutura urbana localizada na área de estudo está relacionada às sedes municipais de Rolante e Riozinho, cuja população estimada para 2019 é de 19.485 e 4.330 habitantes, respectivamente (IBGE, 2019).

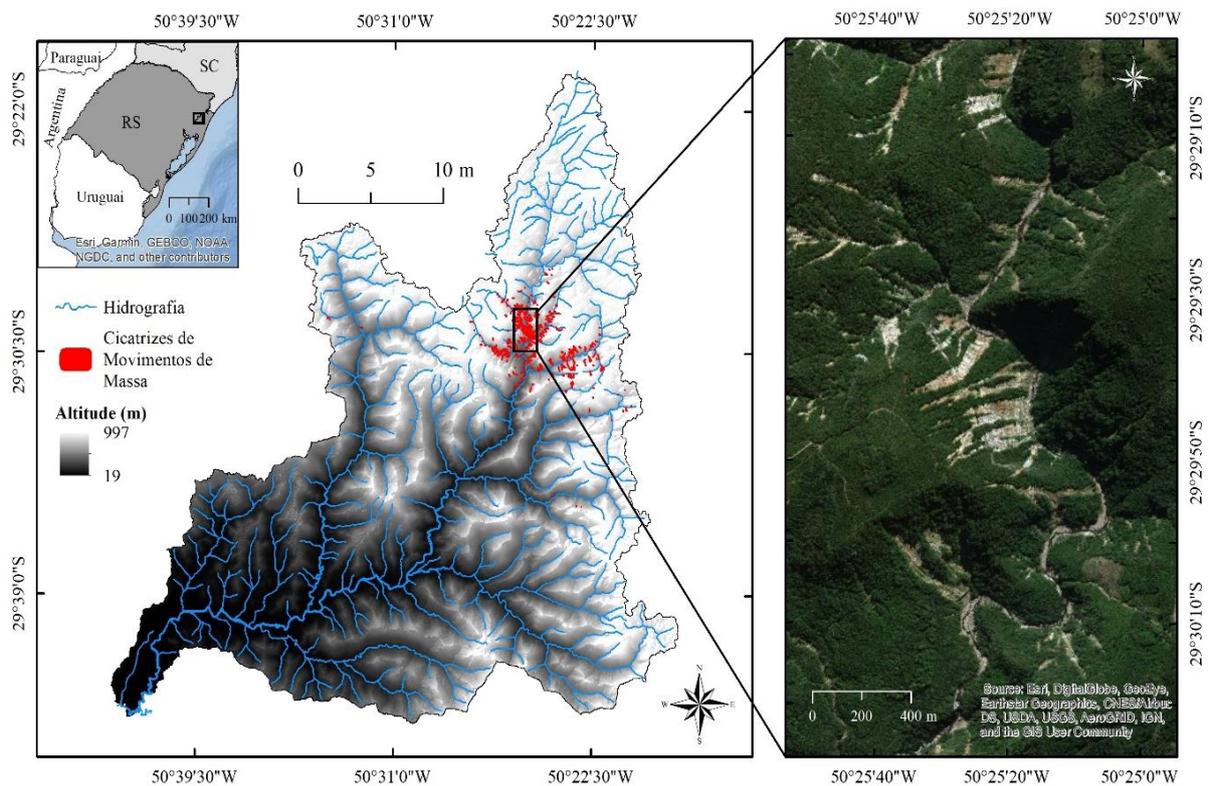


Figura 1. Localização da área de estudo.

Um evento extremo de precipitação ocorreu em 05 de janeiro de 2017, resultando em uma sequência de movimentos de massa, com deslocamento de grande quantidade de

sedimentos para o leito do Rio Mascarada, afluente do Rio Rolante, encontrado na área a montante da bacia. A duração das chuvas foi em torno de quatro horas. Dados oficiais estimaram cerca de 50 mm de chuva, enquanto medidores particulares locais estimaram valores entre 90 e 272 mm (SEMA, 2017).

3. Materiais e métodos

Este estudo foi desenvolvido a partir do uso de inventário de cicatrizes e atributos preditivos, os quais possibilitaram realizar a análise exploratória de padrões espaciais dos movimentos de massa, e a modelagem de áreas suscetíveis a ruptura por meio dos modelos *Random Forest*, Regressão Logística e Regressão Logística Espacial (Figura 2).

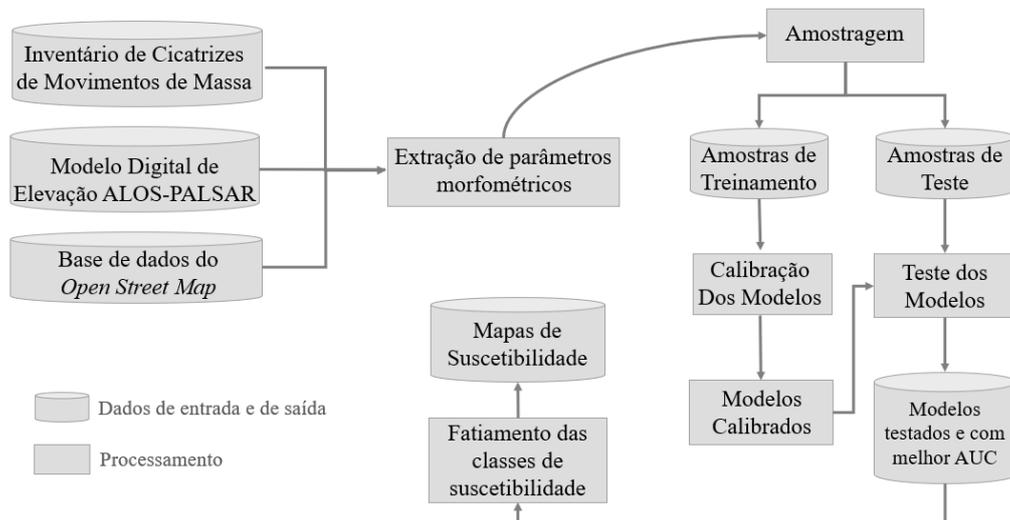


Figura 2. Fluxograma dos métodos.

3.1. Inventário de Cicatrizes de Movimentos de Massa

De modo a possibilitar a análise de suscetibilidade à ocorrência de movimentos de massa foi utilizado o inventário de Quevedo *et al.* (2019). Com enfoque nas áreas potenciais de ruptura, foram identificadas 297 cicatrizes em imagens datadas de 06 e 24 de agosto de 2017 no programa Google Earth, além de pontos coletados em campo. Após atualização deste inventário, foram extraídos pontos referentes às áreas de ruptura de cada cicatriz identificada, totalizando 423 pontos amostrais (Figura 3). A quantidade de pontos de ruptura é maior do que a quantidade de cicatrizes, pois muitas delas são compostas por duas ou mais áreas de ruptura,

cujo material se encontra na área de deslocamento, formando, assim, um conjunto de sedimentos transportados.

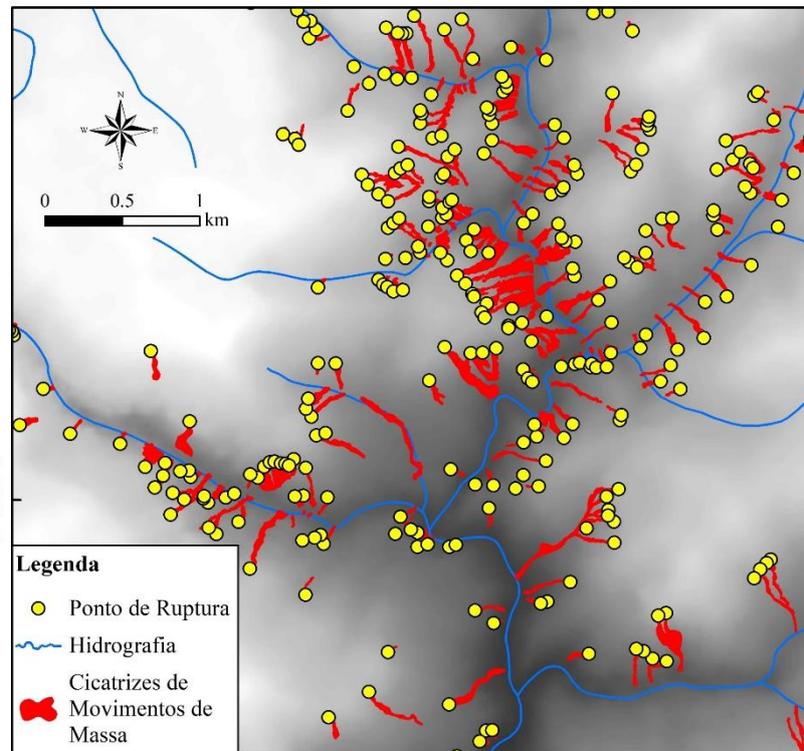


Figura 3. Amostras relacionadas às áreas de ruptura das cicatrizes.

No restante da área da bacia, em que não houve registros de ocorrência de movimentos de massa, foram extraídos 423 pontos de maneira aleatória para compor a amostra de não ocorrência utilizando-se o programa ArcGIS 10.3. Obtidos os 846 pontos amostrais, foi realizada a divisão entre amostra de treinamento e amostra de teste, com 592 (70%) e 254 (30%) da quantidade total, respectivamente.

3.2. Análise exploratória de padrões espaciais dos movimentos de massa

A interação espacial foi analisada por técnicas de efeitos de primeira e segunda ordem: *quadrat count*, *kernel intensity estimation*, e funções G, F e K de Ripley, como o uso do programa R-Studio 1.2.5001, com sistema R-3.6.1, conforme Althuwaynee *et al.* (2017).

O *Quadrat Counts* usa uma rede grade regular para cobrir a área de estudo e calcular a intensidade de cada célula, ou seja, a quantidade de pontos observados por unidade de área. A Eq. 1 descreve a função de *Quadrat Count*, em que λ representa a intensidade, n é o número de pontos observados na região A , $|A|$ é a área da região A .

$$\lambda(x) = \frac{n}{|A|} \quad \text{Eq. 1}$$

O estimador de *Kernel* foi utilizado para se analisar a área de estudo como um todo. Este estimador identifica uma área de influência a partir da contagem dos eventos, sendo necessário definir o raio de influência e a função de interpolação. Neste trabalho, foi utilizado um raio ajustável e a função de *kernel* gaussiano (Eq. 2): em que k representa a função de interpolação (Eq. 3), τ é o tamanho do raio de influência e h , a distância entre a localização analisada e a observação (CÂMARA; CARVALHO, 2004).

$$k(h) = \frac{1}{2\pi\tau} \exp\left(-\frac{h^2}{2\tau^2}\right) \quad \text{Eq. 2}$$

$$\hat{\lambda}_\tau(u) = \sum_{h_i \leq \tau} \frac{3}{\pi\tau^2} \left(1 - \frac{h_i^2}{\tau^2}\right)^2 \quad \text{Eq. 3}$$

Os métodos de análise do vizinho mais próximo foram realizados a partir das funções F , G e K de *Ripley*. A função F (função de espaços vazios) considera a distância de pontos ao evento mais próximo (Eq. 4). Distâncias dos espaços vazios maiores do que o esperado são evidência de presença de clusters.

$$F(d) = \frac{x \mid d_{min} \leq r}{n} \quad \text{Eq. 4}$$

Em que: $F(d)$ representa a função de espaços vazios; x representa a quantidade de par de pontos em que a distância mínima (d_{min}) é menor ou igual ao raio (r) analisado; n representa o total de amostra de pontos.

Através da função G analisou-se a frequência cumulativa da distribuição de distância entre eventos analisados em uma área de estudo (Eq.5). Esta função demonstra como os eventos estão espaçados e se há evidência de interação entre eles.

$$G(w) = \frac{w_i \leq w}{N} \quad \text{Eq. 5}$$

Em que: $G(w)$ representa a função de distribuição cumulativa das distâncias entre os eventos; w é a distância analisada; w_i é a distância entre eventos e N é o número de eventos.

A função K de *Ripley* fornece uma estimativa da dependência espacial, com base nas distâncias entre eventos em toda a área de estudo (Eq. 6). Cada ponto é analisado a partir de um raio de distância, cuja contagem dos eventos é realizada. Após repetir o processo para cada ponto da área de estudo, os resultados foram somados.

$$\hat{K}(h) = \frac{R}{n^2} \sum_{i=1}^n \sum_{j=1}^n I_h(d_{ij}) \quad \text{Eq. 6}$$

Em que: R é a distância analisada; n é o número de eventos em R ; $I_h(d_{ij})$ representa a variável indicadora, a qual será igual a 1, se a distância entre os pontos i e j for menor ou igual à distância h de um evento arbitrário ($d_{ij} \leq h$).

3.3. Variáveis Preditivas

Para a extração dos parâmetros morfométricos da área de estudo utilizou-se o Modelo Digital de Elevação (MDE) do satélite ALOS (*Advanced Land Observing Satellite*), sensor PALSAR (*Phased Array type L-band Synthetic Aperture Radar*), com resolução espacial de 12,5 m (JAXA, 2019), disponibilizado a partir do website *Alaska Satellite Facility*. A partir do programa SAGA GIS foram extraídos dezoito atributos preditivos. Ademais, foram mensuradas as distâncias com relação às vias de acesso e à drenagem com o auxílio do programa ArcGIS 10.3. A localização de estradas, ruas e avenidas foi obtida a partir da base de dados do *Open Street Map*. Estes dados foram analisados, corrigidos e atualizados, e geraram o atributo preditivo de distância das vias de acesso. Os 20 atributos foram analisados conforme a matriz de correlação entre as variáveis (Figura 4), sendo eliminados aqueles com valores acima de 0.8, negativos ou positivos, resultando em total de 11 variáveis (Elevação, Declividade, Orientação da Vertente, Comprimento da Rampa, Curvatura de Perfil, Curvatura Plana, Fluxo Acumulado, Direção de Fluxo, Distância Vertical da Drenagem, Distância da Drenagem e Distância das Vias de Acesso) para análise a partir dos modelos (Figura 5).

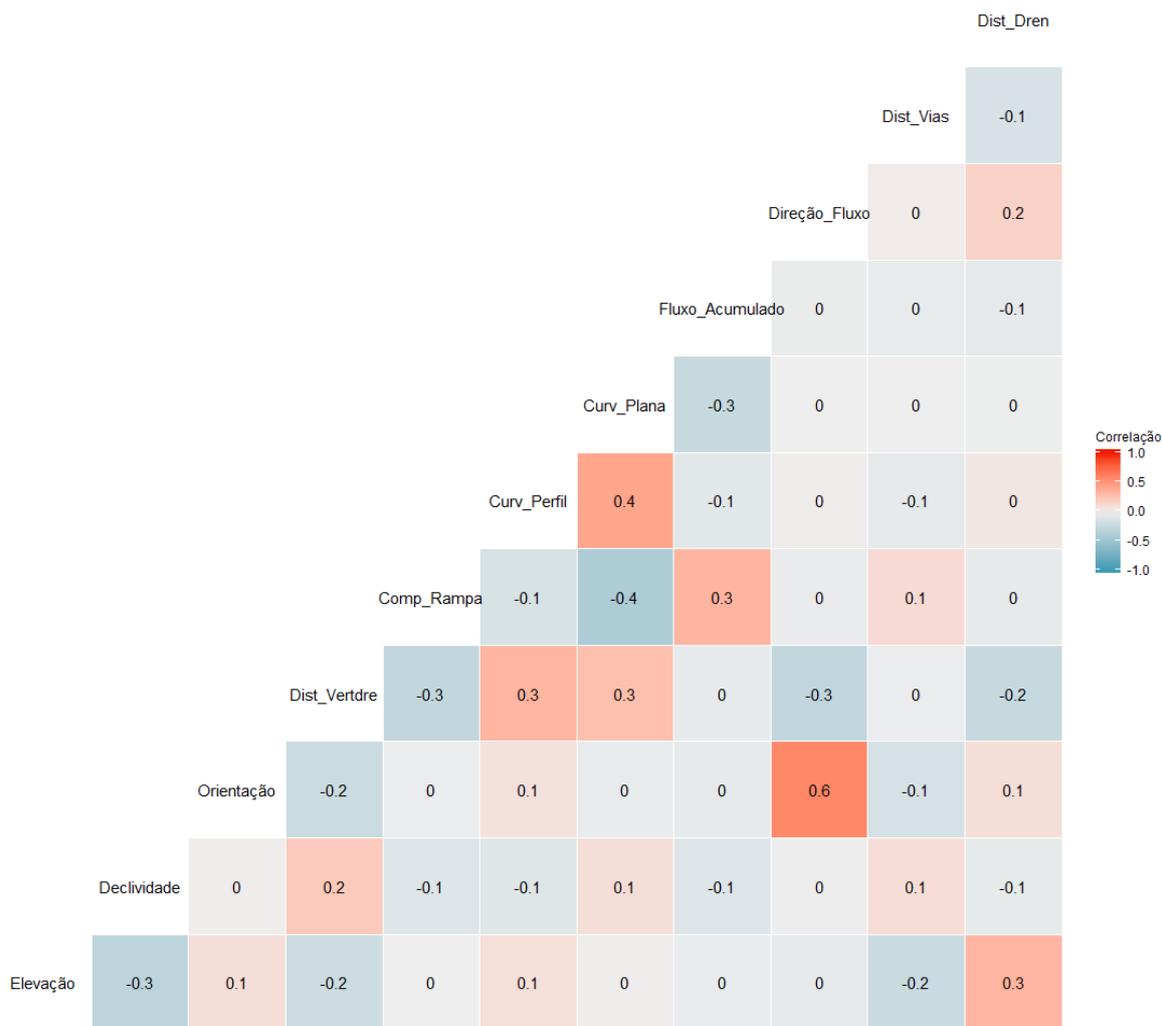


Figura 4. Matriz de correlação entre as variáveis.

A **elevação** considerou valores de altitude (Figura 5). Essa variável pode influenciar as variações de precipitação, temperatura e distribuição da vegetação e intemperismo, contribuindo indiretamente para a ocorrência de movimentos de massa (MOKHTARI; ABEDIAN, 2019). A **declividade** correspondeu ao ângulo de inclinação da encosta, o qual influencia na quantidade de material passível de transporte. O aumento da declividade diminui a estabilidade da vertente, cuja máxima instabilidade ocorre geralmente entre 30 e 40° (METEN; PRAKASHBHANDARY; YATABE, 2015). A **orientação de vertente** foi obtida com base na exposição solar. A orientação de vertente tem relação com a composição e umidade do solo, ademais da distribuição da vegetação (PAMELA *et al.*, 2017). A **distância vertical da rede de drenagem mais próxima** considerou a distância entre o curso de água mais próximo e a ocorrência de ruptura. Quanto maior o valor dessa variável, menor é a possibilidade de a ruptura resultar em movimentos de massa subsequentes (SAMIA *et al.*,

2017). O **comprimento da rampa** considerou a distância da direção de fluxo da encosta até a drenagem mais próxima, para a qual o escoamento superficial se direciona (OLIVEIRA *et al.*, 2018). As **curvaturas** estão relacionadas ao formato da encosta e medem a convergência ou divergência e a concavidade ou convexidade do terreno (GAMEIRO *et al.*, 2019). Através da identificação do tipo da curvatura é possível fazer associações com as condições de infiltração, velocidade e tendências de concentração dos escoamentos superficial e subsuperficial (LAJAS, 2016). O **fluxo acumulado** foi obtido a partir do cálculo da área de drenagem à montante de cada píxel analisado e a **direção de fluxo** avaliou o sentido do escoamento a partir desta célula, respectivamente (GAMEIRO *et al.*, 2019). A **distância da drenagem** foi obtida em metros, correspondente à distância euclidiana da amostra de ocorrência de movimentos de massa e a drenagem mais próxima. Finalmente, foram obtidas as **distâncias de vias de acesso**, as quais, assim como as modificações na cobertura da terra, podem causar alterações em vastas áreas em um curto período, conduzindo ao enfraquecimento de fatores ambientais que controlam a estabilidade das encostas (GLADE, 2003). As estradas podem desestabilizar as vertentes devido a alterações no terreno e no escoamento superficial, em que a disposição da via determinará se esta será um fator condicionante (BELÉM; OLIVEIRA; SAMPAIO, 2014; BRENNING *et al.*, 2015; PRADHAN; SEENI; KALANTAR, 2017; STANLEY; KIRSCHBAUM, 2017).

3.4. Modelagem das áreas suscetíveis a ruptura de movimentos de massa

A modelagem das áreas suscetíveis a ruptura de movimentos de massa foi realizada a partir da aplicação das técnicas de *Random Forest*, Regressão Logística e Regressão Logística Espacial. A modelagem foi executada no ambiente do programa R-Studio 1.2.5001, com sistema R-3.6.1.

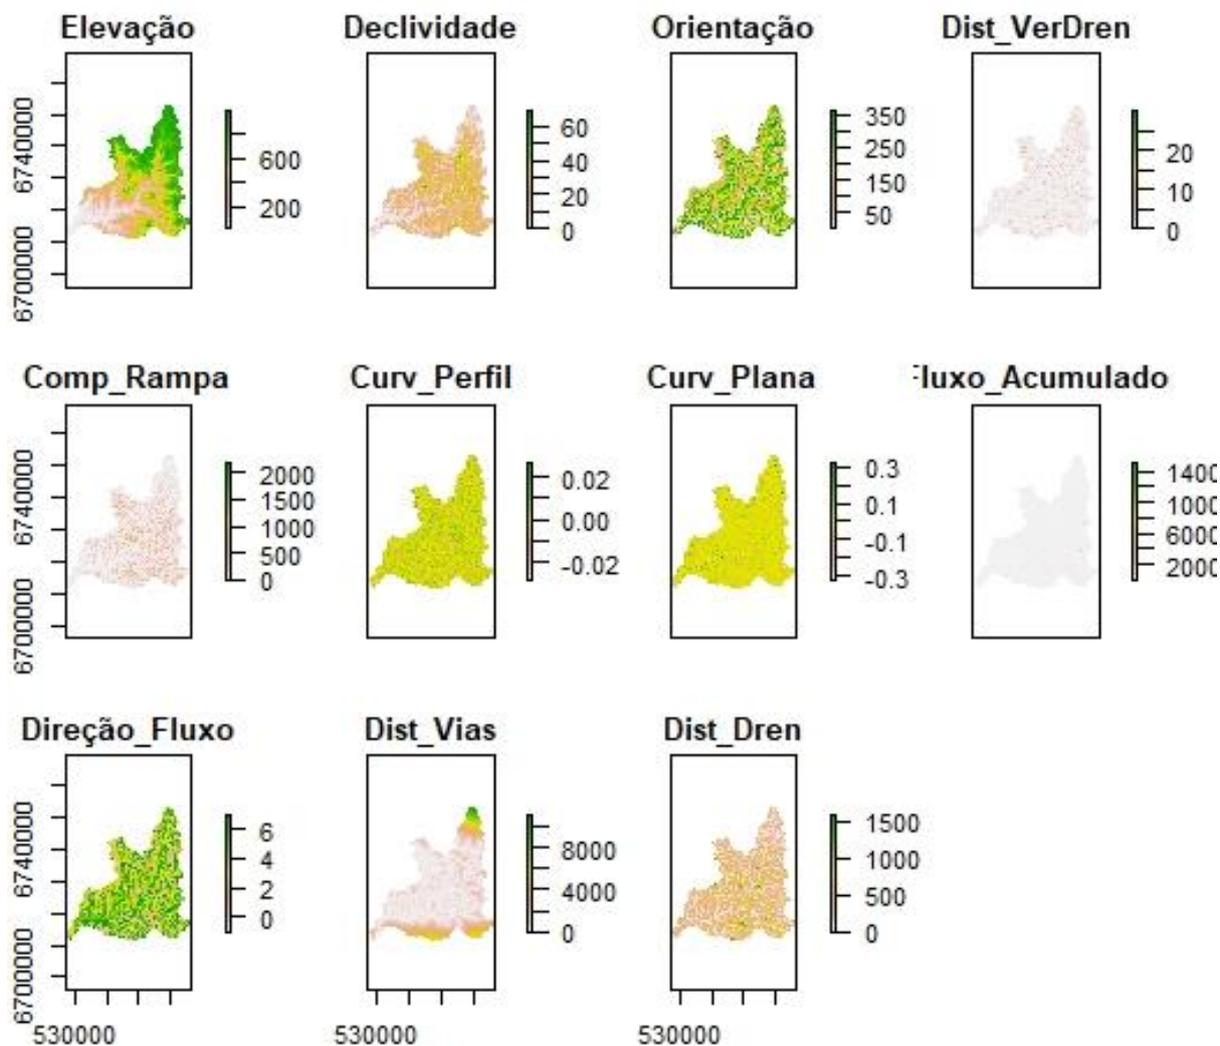


Figura 5. Variáveis preditivas utilizadas no processo de modelagem.

3.4.1. *Random Forest*

O modelo *Random Forest* é um método *ensemble learning*, ou seja, realiza suas previsões baseadas em diferentes modelos individuais, o que o torna menos tendencioso e menos sensível aos dados de entrada. O *Random Forest* seleciona de maneira aleatória percentuais dos dados de entrada e os separa em subconjuntos, para os quais são construídas árvores de decisão. O valor estimado é referente à média da previsão das árvores. Apesar de utilizar o mesmo princípio fundamental das Árvores de Decisão, o *Random Forest* reduz a correlação entre as árvores no processo de separação dos nós. É gerado um modelo de regressão para estimar a relevância dos atributos do terreno (BREIMAN, 2001). O número de árvores utilizado foi de 500 e o índice de Gini Impurity (ΔI) foi selecionado como critério para partição dos nós das árvores (Equação 1).

$$\Delta I = G(\tau) - p_l G(\tau_l) - p_r G(\tau_r) \quad \text{Eq. 7}$$

Em que: ΔI quantifica a diminuição do índice de Gini, após a divisão (impureza Gini); p_l é a probabilidade das predições das classes para o nó esquerdo τ_l e p_r é a probabilidade das predições das classes para o nó direito (τ_r); $G(\tau_r)$ é o valor do índice de Gini para o nó direito (τ_r) e $G(\tau_l)$ é o valor do índice de Gini para o nó esquerdo;

3.4.2. Regressão Logística

O modelo de Regressão Logística é um método estatístico multivariado, em que a variável dependente é dicotômica, ou seja, binária - como presença ou ausência de áreas de ruptura de movimentos de massa. É um método simples e robusto, que admite variáveis independentes categóricas e/ou contínuas. Como vantagem, não é sensível a possíveis dependências condicionais entre os atributos preditivos (MELO, 2018). A relação de dependência entre as variáveis dependente e independentes é expressa conforme a Eq. 8.

$$Pr = \frac{1}{1+e^{-Z}} \quad \text{Eq. 8}$$

Em que: Pr é a probabilidade de ocorrência do fenômeno em análise; Z se refere à combinação linear, conforme Eq. 9. O valor de Z varia entre $-\infty$ e $+\infty$, resultando em probabilidades (Pr) com variação entre 0 e 1.

$$Z = B_0 + B_1X_1 + B_2X_2 + \dots + B_nX_n \quad \text{Eq. 9}$$

Em que: B_0 é uma constante; B_i é o coeficiente estimado, sendo i referente à cada variável independente analisada; n é a quantidade de variáveis preditivas X .

3.4.3. Regressão Logística Espacial

No modelo de Regressão Logística, a presença de autocorrelação espacial viola a premissa básica de que as variáveis preditivas são independentes entre si. Diferentes métodos são aplicados para solucionar este problema, seja de maneira prévia à modelagem ou com a inclusão de parâmetros de correção no modelo. Neste trabalho, a correção se baseou no estudo

de Hu e Lo (2007), em que se acrescentam as coordenadas das amostras para calibração do modelo.

3.5. Análise de Desempenho dos Modelos

O desempenho dos modelos foi analisado a partir do valor de AUC (*Area Under the ROC Curve*), cujos valores variam entre 0 e 1. Valores entre 0.9 e 1 representam ótima performance do modelo; valores entre 0.8 e 0.9, performance aceitável; AUCs entre 0.7 e 0.8 representam modelos medianos e abaixo deste intervalo, pode-se considerar como um modelo com baixa performance (MOKHTARI; ABEDIAN, 2019).

4. Resultados

4.1. Análise Exploratória

A análise exploratória permitiu identificar a presença de cluster na área de estudo, em que um círculo com raio de aproximadamente 2,5 km abrange cerca de 80% dos eventos analisados (Figura 6A). O método do vizinho mais próximo possibilitou a identificação dos eventos mais isolados (Figura 6B). Constatou-se um elevado grau de agrupamento dos eventos em ambas as análises, os quais se concentraram na área a montante da BHRR.

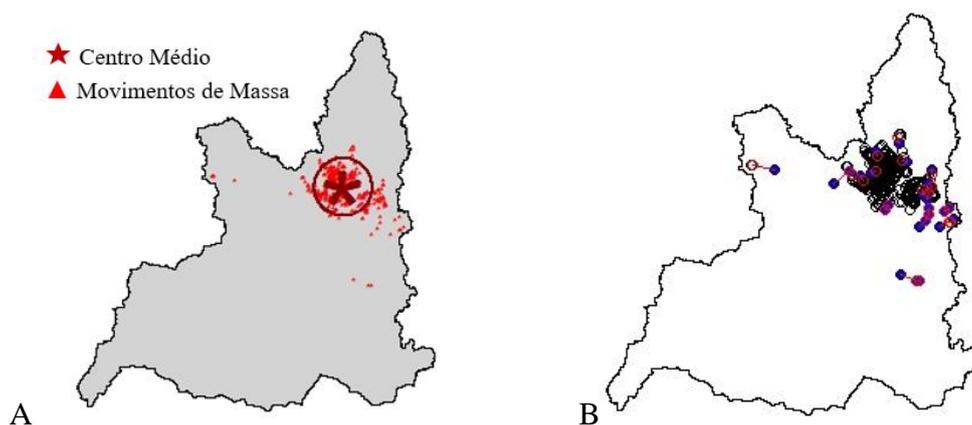


Figura 6. Concentração de eventos de ruptura de movimentos de massa. A) Centro médio de ocorrência de movimentos de massa; B) Eventos mais isolados.

Foi contabilizada a quantidade de eventos por *quadrat*, a partir do uso do método *quadrat count*, para o qual foi criado um *raster* com uma resolução arbitrária igual a 500 m,

com extensão correspondente à da BHRR. A aplicação do *quadrat count* produziu clusters concentrando até 30 eventos em um só píxel (Figura 7). A densidade *Kernel* produziu cluster na região norte da BHRR, caracterizando-se pela alta concentração de eventos (Figura 8).

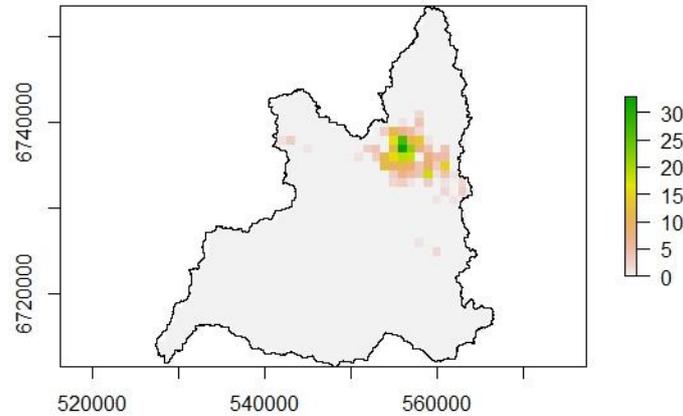


Figura 7. *Quadrat counts* aplicado aos eventos de movimentos de massa.

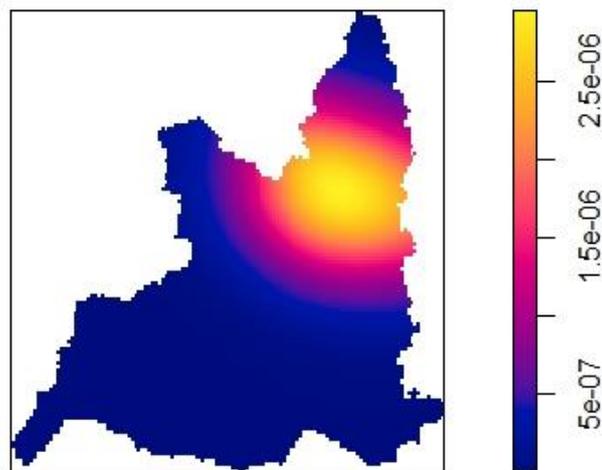


Figura 8. Estimativa de densidade *Kernel*.

Foram realizadas análises a partir das funções G de vizinho mais próximo e função F de espaços vazios (Figura 9). Na função G, a distância que cobre a distribuição do cluster é cerca de 700 m. Após esta distância a distribuição passa a ser aleatória. Enquanto na função F, a qual considera as distancias de espaços, a distância é maior, o que sugere a existência de cluster.

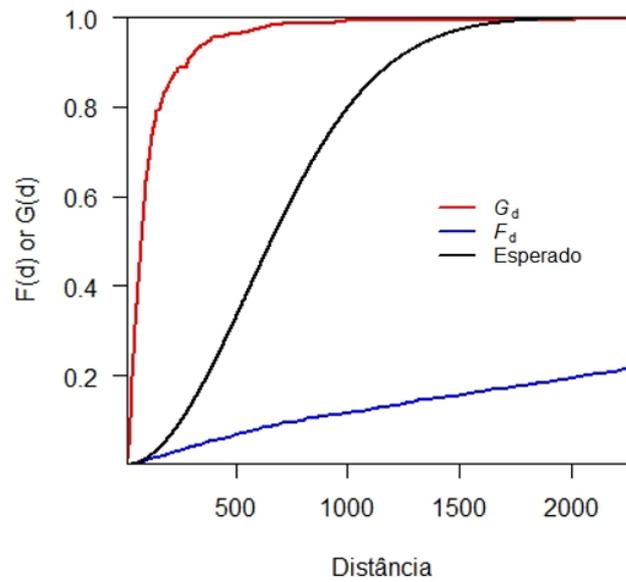


Figura 9. Funções F e G .

O teste K de *Ripley* foi realizado para confirmar os testes anteriores. O K de *Ripley* demonstrou que a distância que cobre o cluster é menor que 4000 m e distâncias maiores resultaram em incremento acelerado do valor de K , já que a aleatoriedade é alcançada após um elevado aumento da distância.

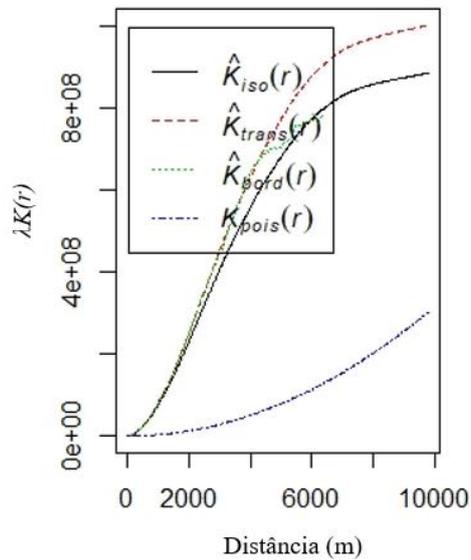


Figura 10. Função K de *Ripley*.

A análise exploratória foi utilizada para confirmar a existência de clusters, indicativo de autocorrelação espacial. A autocorrelação espacial pode ser corrigida antes do processo de modelagem ou a partir dos modelos utilizados. Na aplicação do *Random Forest*, a correção da autocorrelação espacial não foi realizada. A regressão logística foi analisada com e sem correção.

4.2. Aplicação dos Modelos *Random Forest*, Regressão Logística com e sem correção

O modelo *Random Forest* foi composto por 500 árvores e apresentou um RMSE igual a 0.2980117 para uma separação de seis variáveis por nó (parâmetro *mtry*). As variáveis mais importantes foram a Declividade, a Elevação e a Distância Vertical da Drenagem, com valores de 55,18%, 25,78% e 6,80% (Tabela 1). A Declividade apresenta uma importância maior do que 50% e, juntamente com a Elevação, a importância atinge valor acima de 80%.

Tabela 1. Importância das variáveis preditivas conforme o modelo analisado

Variáveis Preditivas	Modelo utilizado		
	<i>Random Forest</i>	Regressão Logística	Regressão Logística Espacial
Elevação	25,78%	22,31%	8,22%
Declividade	55,18%	42,63%	45,71%
Orientação da Vertente	0,32%	4,97%	1,53%
Comprimento da Rampa	0,34%	2,05%	5,72%
Curvatura de Perfil	0,03%	0,04%	2,85%
Curvatura Plana	0,83%	3,63%	2,36%
Fluxo Acumulado	1,21%	4,07%	4,57%
Direção de Fluxo	0,00%	1,01%	7,53%
Distância Vertical da Drenagem	6,80%	6,81%	2,62%
Distância da Drenagem	2,63%	7,84%	1,72%
Distância das Vias de Acesso	6,88%	4,65%	17,17%

No modelo de Regressão Logística sem correção da autocorrelação espacial, as variáveis de maior importância seguiram sendo a Declividade, com 55,18% e Elevação, com 22,31%. Houve um aumento da influência da distância vertical da drenagem, alcançando um percentual de 6,81%. Os demais atributos apresentaram valores inferiores a 8%.

A Regressão Logística Espacial apresentou maior importância para a Declividade (45,71%) e para a Distância das Vias de Acesso (17,17%), variável esta que não havia apresentado alta influência nos demais modelos. A elevação obteve 8,22% de importância e variáveis como Orientação de Vertente, Curvaturas de Perfil e Plana, Distância Vertical da Drenagem e Distância da Drenagem, somadas, apresentaram uma importância de 11,08%.

As acurácias (AUC) obtidas para os modelos foram satisfatórias, com valores acima de 0,90 (Tabela 2). Os modelos sem correção de autocorrelação espacial resultaram em valores similares, 0,94 para ambos. Enquanto o modelo de Regressão Logística Espacial obteve uma acurácia maior, AUC= 0,9657.

Tabela 2. Acurácia (AUC) dos modelos *Random Forest*, Regressão Logística e Regressão Logística Espacial.

	<i>Random Forest</i>	Regressão Logística	Regressão Logística Espacial
Avaliação de Desempenho a partir de AUC	0,9408	0,9404	0,9657

Os mapas de suscetibilidade à ruptura de movimentos de massa resultante de cada modelo são apresentados na Figura 11. Os modelos sem abordagem espacial, *Random Forest* e Regressão Logística, apresentaram mapas de suscetibilidade similares, em que as áreas de alta e muito alta suscetibilidade estão concentradas no norte da BHRR. A Regressão Logística Espacial apresentou áreas de média e alta suscetibilidade de maneira mais dispersa.

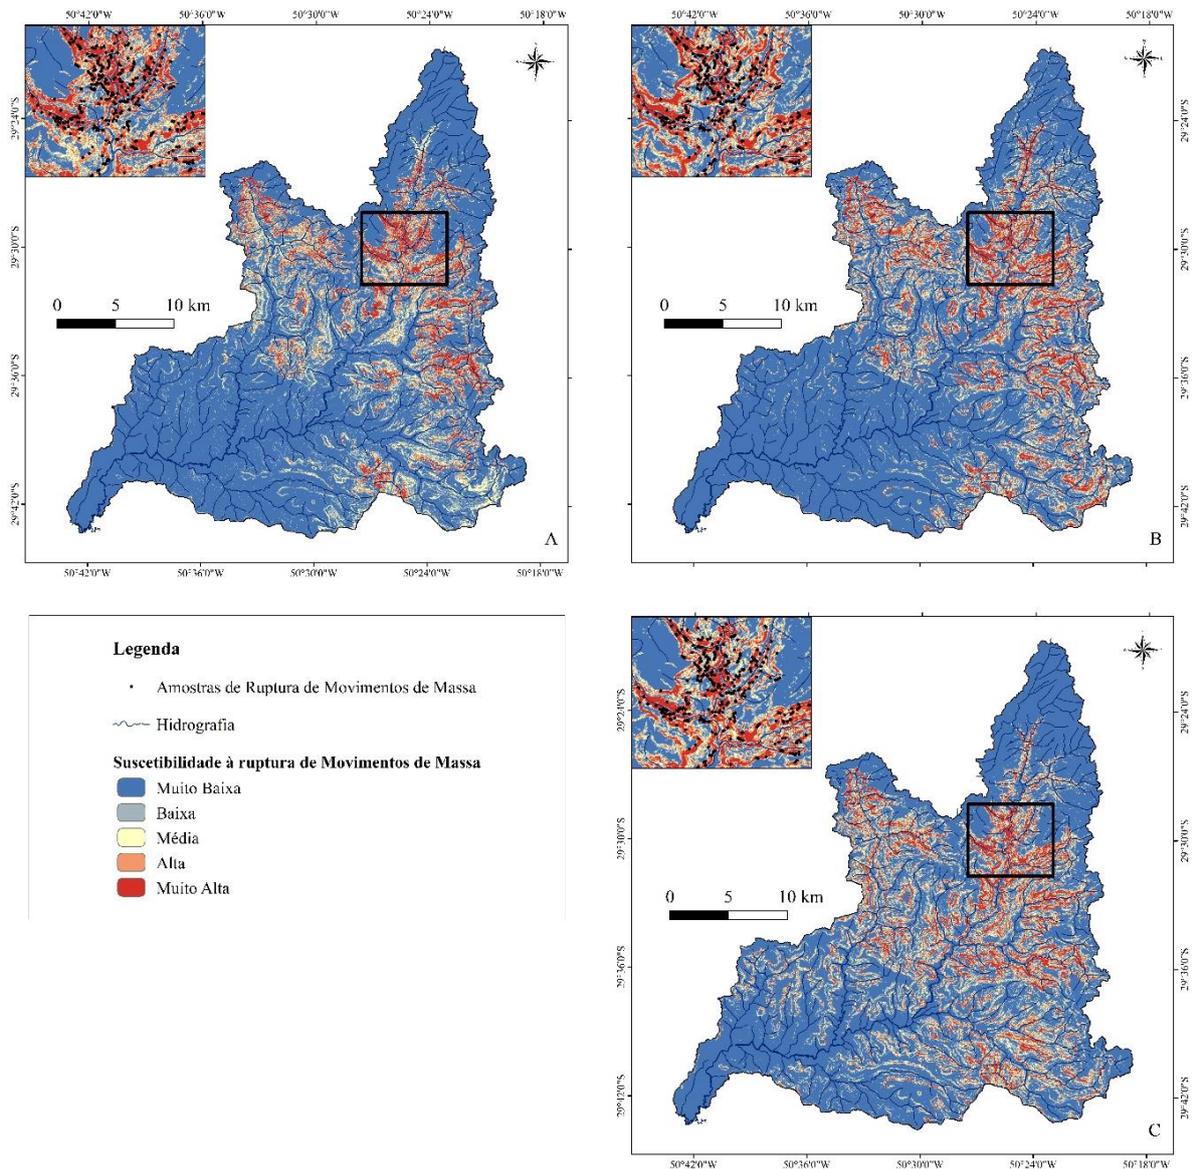


Figura 11. Mapas de suscetibilidade à ruptura de movimentos de massa resultantes dos modelos: A) *Random Forest*; B) Regressão Logística; C) Regressão Logística Espacial.

Considerações Gerais

A análise exploratória foi utilizada para confirmar a existência de clusters, indicando autocorrelação espacial. Estudos de suscetibilidade a movimentos de massa costumam ignorar a autocorrelação espacial e não realizam sua correção, pois fenômenos relacionados ao deslocamento de material iniciados por eventos de precipitação intensa tendem a ser altamente concentrados.

A correção da autocorrelação espacial a partir de Regressão Logística aumentou a performance da modelagem, com incremento no valor da acurácia.

O presente estudo foi importante para se avaliar a influência causada pela correlação espacial no desempenho dos modelos a partir da comparação de modelos espacial e não-espacial.

O *Geographical Random Forest* e outros tipos de correção de autocorrelação espacial aplicados à Regressão Logística devem ser testados, de modo a avaliar o desempenho de modelos espaciais para mapeamento de suscetibilidade a ruptura de movimentos de massa.

Referências

- ADITIAN, A.; KUBOTA, T.; SHINOHARA, Y. Comparison of GIS-based landslide susceptibility models using frequency ratio, logistic regression, and artificial neural network in a tertiary region of Ambon, Indonesia. *Geomorphology*, v. 318, p. 101–111, 2018
- ALTHUWAYNEE, O. F.; MUSAKWA, W.; GUMBO, T.; REIS, S. Applicability of R Statistics in Analyzing Landslides Spatial Patterns in Northern Turkey. In: 2nd International Conference on Knowledge Engineering and Applications. P. 221 -225. 2017.
- BELÉM, R., A.; OLIVEIRA, C. V.; SAMPAIO, R. A. Características físicas do solo e suscetibilidade a deslizamentos de talude na Avenida Sidney Chaves, Montes Claros/MG. *Caminhos de Geografia*, v. 15, n. 51, p. 52-59, 2014.
- BREIMAN, L. Random Forests. *Machine Learning*, The Netherlands, v. 45, p. 5–32, 2001.
- BREIMAN, L. Random Forests. *Machine Learning*, The Netherlands, v. 45, p. 5–32, 2001.
- BRENNING, A.; SCHWINN, M.; RUIZ-PÁEZ, A. P.; MUENCHOW, J. Landslide susceptibility near highways is increased by 1 order of magnitude in the Andes of southern Ecuador, Loja province. *Natural Hazards and Earth System Sciences*, v. 15, p. 45-57, 2015.
- CÂMARA, G.; CARVALHO, M. Análise Espacial de Eventos. In: Suzana Fucks; Marília Sa Carvalho; Gilberto Câmara; Antônio Miguel Monteiro. (Org.). *Análise Espacial de Dados Geográficos*. Brasília: EMPRAPA, 2004, v., p. 55-78.
- CEPED UFSC. Atlas Brasileiro de Desastres Naturais - 1991 a 2012. Volume Brasil. Florianópolis, 2013.
- CHUDÝ, F.; SLÁMOVÁ, M.; TOMAŠTÍK, J.; PROKEŠOVÁ, R.; MOKROŠ, M. Identification of Micro-Scale Landforms of Landslides Using Precise Digital Elevation Models. *Geosciences*, 2019, v. 9(3), v. 117, p. 1-19.
- DAVIES, T. Landslide hazards, risks and disasters: Introduction, In: *Landslides hazards, risks and disasters*, Edited by John F. Shroder and Tim Davies, Elsevier Inc. 2015.
- GAMEIRO, S.; QUEVEDO, R. P.; OLIVEIRA, G. G.; RUIZ, L. F. C.; GUASSELLI, L. A. Análise e correlação de atributos morfométricos e sua influência nos movimentos de massa ocorridos na Bacia Hidrográfica do Rio Rolante, RS. In: XIX Simpósio Brasileiro de Sensoriamento Remoto, 2019, Santos. *Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto*, São José dos Campos: INPE, 2019.

GLADE, T. Landslide occurrence as a response to land use change: a review of evidence from New Zealand, *Catena*, v. 51, p. 297-314, 2003.

HU, Z; LO, C. P. Modeling urban growth in Atlanta using logistic regression. *Computers, Environment and Urban Systems*, v. 31, p. 667-688, 2007.

IBGE. População estimada: IBGE, Diretoria de Pesquisas, Coordenação de População e Indicadores Sociais, Estimativas da população residente com data de referência 1º de julho de 2019.

JAXA. Japan Aerospace Exploration Agency. Earth Observation Research Center. About ALOS-PALSAR. Disp. em: <https://www.eorc.jaxa.jp/ALOS/en/about/palsar.htm>. Acessado em: 20 de outubro de 2019.

LAJAS, S. M. A. Integração de métodos estatístico e determinístico para a avaliação da suscetibilidade a deslizamentos superficiais. 2016. 170 p. Dissertação (Mestrado em Geografia Física e Ordenamento do Território) – Instituto de Geografia e Ordenamento do Território, Universidade de Lisboa, Lisboa, 2016.

LUERCE, T. D. Geoturismo na bacia hidrográfica do rio Rolante/RS: Um estudo acerca das Quedas d'água. 2015. 181 p. Dissertação (Mestrado em Geografia) - Programa de Pós-Graduação em Geografia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2015.

MELO, R. S. R. A. Modelação de deslizamentos superficiais e escoadas de detritos com métodos estatísticos e determinísticos. 2018, 357 p. Tese (Doutorado em Geografia, especialidade de Geografia Física) - Instituto de Geografia e Ordenamento do Território, Universidade de Lisboa, Lisboa, 2018.

MELO, R.; ZÊZERE, J. L. Avaliação da suscetibilidade à rutura e propagação de fluxos de detritos na bacia hidrográfica do Rio Zêzere (Serra Da Estrela, Portugal). *Revista Brasileira de Geomorfologia*, São Paulo, v. 18, n. 1, p. 81–106, jan./mar. 2017.

METEN, M.; PRAKASHBHANDARY, N.; YATABE, R. Effect of Landslide Factor Combinations on the Prediction Accuracy of Landslide Susceptibility Maps in the Blue Nile Gorge of Central Ethiopia. *Geoenvironmental Disasters*, v. 2: 9, p. 1 – 17, dec. 2015.

MOKHTARI, M.; ABEDIAN, S. Spatial prediction of landslide susceptibility in Taleghan basin, Iran. *Stochastic Environmental Research and Risk Assessment*, v. 33, p. 1297-1325, junho 2019.

OLIVEIRA, G. G.; GUASSELLI, L. A.; QUEVEDO, R. P.; RUIZ, L. F. C.; BRESSANI, L. A.; RIFFEL, E. S. Identificação e análise de áreas suscetíveis a fluxos de detritos na bacia hidrográfica do Rio Taquari-Antas, RS. *Pesquisas em Geociências*, Porto Alegre, v. 45, n. 2, p. 1–25, 2018.

PAMELA; YUKNI, A.; IMAM, S. A.; KARTIKO, R., D. The Selective Causative Factors on Landslide Susceptibility Assessment: Case Study Takengon, Aceh, Indonesia. In: *International Symposium on Earth Hazard and Disaster Mitigation (ISEDMD)*. 2017.

PERSICHILLO, M. G.; BORDONI, M.; MEISINA, C. The role of land use changes in the distribution of shallow landslides. *Science of the Total Environment*, v. 574, p. 924-937, 2017.

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. *Laser Scanning Applications in Landslide Assessment*, p. 19-232, 2017.

QUEVEDO, R. P.; GUASSELLI, L. A.; OLIVEIRA, G. G.; RUIZ, L. F. C. Modelagem de áreas suscetíveis a movimentos de massa: avaliação comparativa de técnicas de amostragem, aprendizado de máquina e modelos digitais de elevação. *Geociências (São Paulo. Online)*, 2019.

ROSSATO, M. S. Os Climas do Rio Grande do Sul: variabilidade, tendências e tipologia. 2011. 253 p. Tese (Doutorado em Geografia) – Programa de Pós-Graduação em Geografia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2011.

SAMIA, J.; TEMME, A.; BREGT, A.; WALLINGA, K.; GUZZETTI, F.; ARDIZZONE, F.; ROSSI, M. Characterization and quantification of path dependency in landslide susceptibility. *Geomorphology*, v. 292, p. 16-24. Setembro, 2017

SEMA. Diagnóstico Preliminar: Descritivo dos eventos ocorridos no dia 5 de janeiro de 2017 entre as regiões dos municípios de São Francisco de Paula e Rolante/RS. Porto Alegre: Secretaria do Ambiente e Desenvolvimento Sustentável, 2017. 26 p.

STANLEY, T.; KIRSCHBAUM, D. B. A heuristic approach to global landslide susceptibility mapping. *Natural Hazards*, Fevereiro, 2017.