



Mapeamento de Suscetibilidade a Movimentos de Massa a partir de Redes Neurais Artificiais Landslide Susceptibility Mapping Using Artificial Neural Networks

Renata Pacheco Quevedo¹;
Guilherme Garcia de Oliveira² & Laurindo Antonio Guasselli³

¹Universidade Federal do Rio Grande do Sul, Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Programa de Pós-Graduação em Sensoriamento Remoto, Av. Bento Gonçalves 9500, 91501-970, Porto Alegre, RS, Brasil

²Universidade Federal do Rio Grande do Sul, Departamento Interdisciplinar, Rodovia RS 030 km 92, 11.700, 95590-000, Tramandaí, RS, Brasil

³Universidade Federal do Rio Grande do Sul, Departamento de Geografia e Programa de Pós-Graduação em Geografia, Instituto de Geociências, UFRGS, Av. Bento Gonçalves 9500, 91501-970, Porto Alegre, RS, Brasil

E-mails: renatapquevedo@gmail.com; g.g.oliveira10@gmail.com; laurindo.guasselli@ufrgs.br
DOI: http://doi.org/10.11137/2020_2_128_138; Recebido: 25/04/2019 Aceito: 23/03/2020

Resumo

Os movimentos de massa são um dos principais fenômenos responsáveis por desastres naturais no Brasil. O mapeamento pode auxiliar no ordenamento territorial das áreas suscetíveis. As redes neurais artificiais se destacam na modelagem e mapeamento de suscetibilidade por sua elevada acurácia, capacidade de aprendizagem e generalização dos resultados. Assim, este estudo teve como objetivo mapear áreas suscetíveis a movimentos de massa, considerando quatro conjuntos amostrais, a partir de um modelo de RNA. Para tal, foi elaborado um inventário de cicatrizes, extraídos atributos do terreno e analisados conforme sua importância para os modelos, organizados os conjuntos amostrais conforme duas áreas amostrais e dois processos de reamostragem, realizados treinamentos, validação e teste dos modelos, e reclassificação e espacialização das áreas suscetíveis. Foram identificadas 297 cicatrizes de movimentos de massa, as quais cobriram uma área de 1,06 km². As variáveis preditivas que apresentaram maior importância foram a elevação, seguida pela declividade, fator LS e profundidade do vale. Foi observado que a restrição de área para coleta de amostras aleatórias de não ocorrência pode afetar a capacidade de generalização do modelo, enquanto a redução do conjunto amostral de treinamento diminui o tempo de processamento, sem interferir significativamente na acurácia. Pode-se concluir que as RNA se mostraram capazes de modelar as áreas suscetíveis, com acurácia no mapeamento próximas ou superiores a 0,9.

Palavras-chave: Parâmetros Morfométricos; ALOS-PALSAR; Bacia Hidrográfica do Rio Rolante

Abstract

Landslides are one of the main phenomena responsible for natural disasters in Brazil. Mapping can assess the spatial planning of susceptible areas. Artificial neural networks (ANN) stand out the susceptibility modeling and mapping by their high accuracy, as well as capacity learning and generalizing their results. Thus, this study aimed to map susceptible areas to landslides, considering four different sample sets, from an ANN model. For this, an inventory of landslides was drawn, with terrain attributes extracted and their importance to models analyzed, sample sets were organized according to two sample areas and two resampling processes, training, validation and test of the predictive models, followed by reclassification and spatialization of the susceptible areas. The were identified 297 landslides scars, covering a total area of 1.06 km². The most important predictive variables were elevation, slope, LS factor and valley depth. It was observed that the restriction of area for random sampling of non-occurrence may affect the model generalization capacity, while the reduction of the training sample set decreases the processing time, without significantly interfering with the accuracy. The ANN were able to model the susceptible areas, with mapping accuracy near or greater than 0.9.

Keywords: Morphometric Parameters; ALOS-PALSAR; Rolante River Basin

1 Introdução

Os movimentos de massa foram os desastres naturais responsáveis pelo segundo maior número de óbitos no Brasil, entre 1991 e 2012, atrás somente das enxurradas (CEPED UFSC, 2013). A fim de reduzir os impactos oriundos da ocorrência de eventos extremos, a redução de risco de desastres (RRD) busca compreender a dinâmica do fenômeno e identificar as áreas suscetíveis à sua ocorrência (Zêzere *et al.*, 2017).

O mapeamento de áreas suscetíveis a movimentos de massa é uma ferramenta auxiliar no ordenamento do território (Riffel *et al.*, 2016). Entre os modelos utilizados para simular e mapear a suscetibilidade a movimentos de massa, o uso de Redes Neurais Artificiais (RNA) se destaca devido à acurácia e à capacidade de aprendizagem e de generalização dos resultados (Kawabata & Bandibas, 2009; Pradhan & Lee, 2010).

As RNA são utilizadas para classificação, modelagem matemática, simulação e predição. São formadas por duas ou mais camadas de processamento, sendo uma de entrada, uma de saída e, as demais, caso existam, são camadas escondidas. É inspirado no processo de pensamento humano, em que os neurônios são pontos de conexão para processar a informação recebida, formando estruturas próprias (Jensen, 2005). Um dos algoritmos mais utilizados é o *Error Back-Propagation*, em que os neurônios são organizados em camadas (entrada, intermediária e saída), com pesos distintos para cada relação entre neurônios. Para que esses pesos sejam ajustados da maneira mais adequada, a modelagem conta com etapa de treinamento antes da validação cruzada e do teste (Kawabata & Bandibas, 2009).

Diversos estudos utilizam a modelagem por RNA para mapeamento de suscetibilidade a movimentos de massa e as variáveis preditivas mais comumente utilizadas são mapas geológicos e geomorfológicos e atributos do terreno, extraídos de Modelo Digital de Elevação (MDE), como elevação, declividade, curvaturas vertical e longitudinal, entre outros (Kawabata & Bandibas, 2009; Pradhan & Lee, 2010; Dou *et al.*, 2015; Aditian *et al.*, 2018).

Nesse contexto, propõem-se como objetivo mapear áreas suscetíveis a movimentos de massa a partir de um modelo de RNA. Para tal, foram consideradas como variáveis preditivas os atributos do terreno extraídos do MDE ALOS-PALSAR, os quais foram analisados conforme importância apresentada na modelagem, e utilizados quatro conjuntos amostrais diferentes de movimentos de massa, obtidos em função de duas áreas de referência e dois processos de reamostragem.

2 Materiais e métodos

2.1 Área de estudo

A Bacia Hidrográfica do Rio Rolante (BHRR) localiza-se no nordeste do Rio Grande do Sul (Figura 1). A área de drenagem da BHRR é de 828 km², e compreende um relevo escarpado, com altitudes entre 152 e 997 m, e declividade média de 13°. O clima é o subtropical muito úmido, com precipitação entre 1700 e 2000 mm anuais, influenciado pelo ingresso de sistemas frontais e pela orografia (Rossato, 2011).

Um evento extremo de precipitação que ocorreu em 05/01/2017 se caracterizou pela alta concentração temporal e espacial, nas cabeceiras

da BHRR, na sub-bacia do rio Mascarada. Dados oficiais subestimaram a precipitação (50 mm), devido à falta de medidores nos locais de ocorrência.

De acordo com pluviômetros particulares, instalados em áreas rurais, a precipitação variou entre 90 e 272 mm em diferentes pontos (SEMA, 2017).

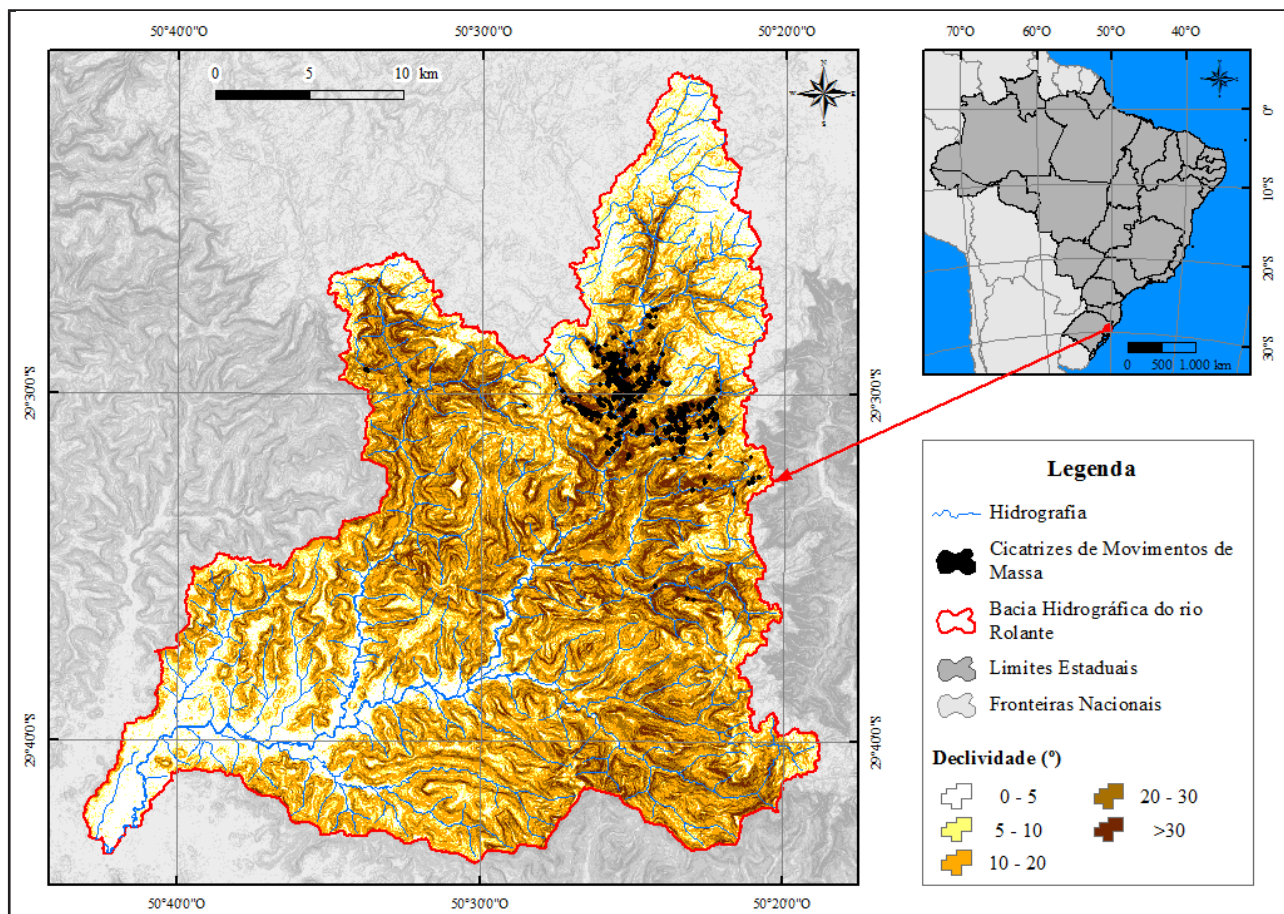


Figura 1 Localização das cicatrizes de movimentos de massa, Bacia Hidrográfica do rio Rolante, RS.

Esse evento extremo durou quatro horas, e resultou em centenas de cicatrizes de movimentos de massa. O material deslocado para o fundo do vale formou barreiras naturais no leito dos rios. Inicialmente, houve o bloqueio do fluxo e consequente aumento do nível da água a montante. Em seguida, com o rompimento das barreiras, ocorreu uma enxurrada de grandes proporções a jusante, atingindo o município de Rolante (SEMA, 2017).

2.2 Métodos

O estudo envolveu seis etapas (Figura 2): i) extração de parâmetros morfométricos do MDE ALOS-PALSAR; ii) pré-processamento e organização dos conjuntos amostrais; iii)

treinamento e calibração das RNA; iv) validação cruzada; v) teste dos modelos, e; vi) reclassificação dos níveis de suscetibilidade em SIG.

Foi utilizado o MDE do satélite ALOS (*Advanced Land Observing Satellite*), sensor PALSAR (*Phased Array type L-band Synthetic Aperture Radar*), disponibilizado a partir do *website Alaska Satellite Facility*, com resolução espacial de 12,5 m. Foram utilizados os softwares *SAGA-GIS* e *ArcGIS*, para extrair sete atributos morfométricos do MDE: elevação (ELV); declividade (DCL); curvatura horizontal (CVH); curvatura vertical (CVV); relevo sombreado (RLS); fator LS (LS); profundidade do vale (PRV).

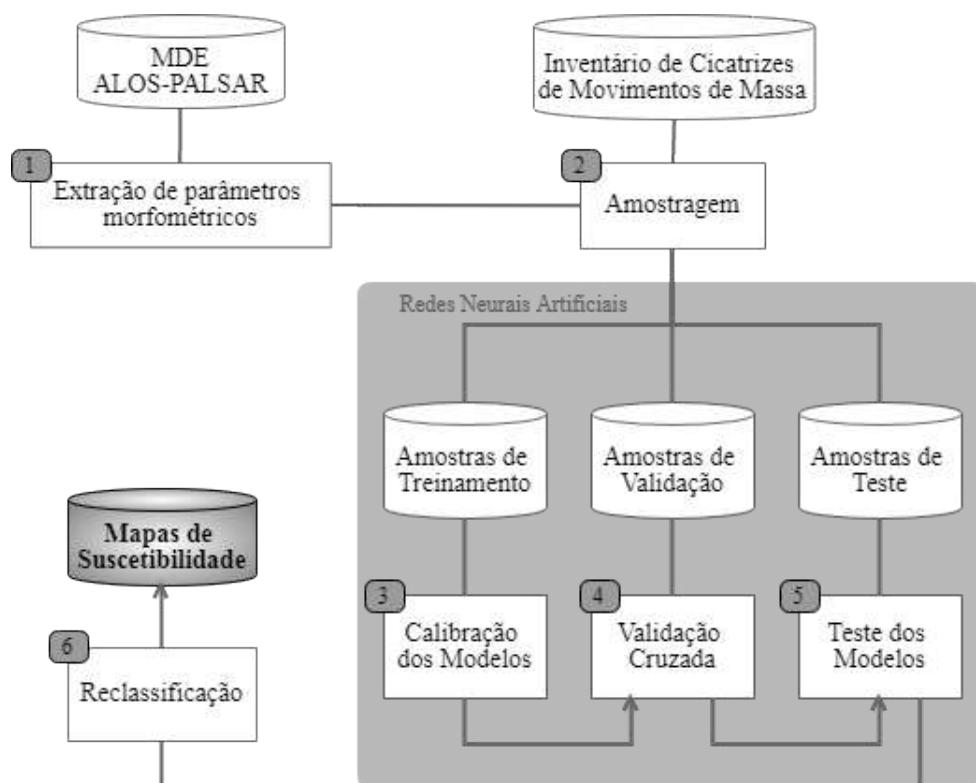


Figura 2 Fluxograma da metodologia.

A ELV considera valores de altitude, a qual pode influenciar as variações de precipitação, temperatura, distribuição da vegetação e intemperismo, contribuindo indiretamente para a ocorrência de movimentos de massa (Mokhtari & Abedian, 2019). Altitudes intermediárias tendem a ser cobertas por colúvio, o que as torna mais suscetíveis a movimentos de massa (Dai & Lee, 2002). Conforme Pourghasemi *et al.* (2020), a ELV é considerada como um indicador primário de suscetibilidade, a partir do qual são derivados fatores secundários de influência. A DCL corresponde 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 *et al.*, 2015). As curvaturas (CVH e CVV) 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 RLS é obtido a partir de simulação de iluminação natural da área, em que o ângulo formado entre os feixes de luz e a superfície determina as áreas iluminadas ou sombreadas (Gameiro *et al.*, 2019). Desta forma, o RLS apresenta o padrão do relevo, como formato dos vales e localização de lineamentos estruturais (Quevedo *et al.*, 2019). O fator LS (*Slope Length and Steepness Factor*) representa o efeito do comprimento (L) e da inclinação (S) da encosta quanto à erosão do solo. Trata-se de um fator topográfico utilizado na Equação Universal de Perdas do Solo (Wischmeier & Smith, 1978). A PRV representa o desnível altimétrico entre as linhas de cumeada e a rede de drenagem, a qual tende a ser diretamente proporcional à suscetibilidade (Meinhardt *et al.*, 2015; Oliveira *et al.*, 2019).

O inventário de cicatrizes é importante para a

modelagem de movimentos de massa, pois fornece informações sobre os padrões do terreno que influenciaram na ocorrência do fenômeno. Registros de eventos passados têm sido obtidos por análise de imagens aéreas ou orbitais e auxílio de coleta de campo (Garcia-Urquia & Yamagishi, 2017; Aditian *et al.*, 2018; Le *et al.*, 2018). Neste estudo, o inventário foi elaborado a partir da interpretação e delimitação das cicatrizes, em imagens de agosto de 2017, disponíveis no *Google Earth*, e de trabalhos de campo para validação. Os polígonos foram convertidos para pontos, de modo que cada pixel do MDE represente uma amostra do modelo.

O conjunto amostral foi estabelecido por pontos localizados no interior das cicatrizes (Classe=1) e igual número de pontos externos (Classe=0). Foram consideradas duas áreas para coleta de amostras de não ocorrência a partir de pontos aleatórios externos às cicatrizes (Figura 3). A área 1 é restritiva (125 km²) e concentrada na área com cicatrizes, enquanto a área 2 é mais abrangente (386 km²).

Visando reduzir o tempo de processamento, foi testada uma técnica de reamostragem dos dados para obter conjuntos representativos de menor tamanho para calibração. Esse processo foi realizado a partir de cada variável, sendo reordenados os valores dos atributos e coletada uma amostra de treinamento a cada x amostras, seguindo uma distribuição uniforme. Foram testados dois valores de x (50 e 80), resultando em dois conjuntos para cada área amostral.

O modelo RNA foi escrito no *software MATLAB*, e o treinamento realizado pelo método retropropagativo com múltiplas camadas (Rumelhart *et al.*, 1986), com a Regra Delta para atualizar os pesos sinápticos da rede (Widrow & Hoff, 1960). Os

valores das variáveis preditivas foram escalonados a partir de transformações lineares. A função de ativação nas camadas foi a sigmoideal. Uma série de validação cruzada paralela à série de treinamento foi utilizada para evitar o superajustamento do modelo.

Foram testadas dezoito configurações de modelo para cada área e conjunto amostral, variando o conjunto de atributos: do modelo mais completo, com todos os atributos, até os mais compactos, em que atributos menos importantes eram excluídos de forma automática, a partir do *Relative Contribution Index* (Oliveira *et al.*, 2015). Para cada configuração, foram testados diferentes números de neurônios na camada oculta da rede. Como a inicialização dos pesos é aleatória, foram executadas 15 iterações em cada configuração. Em cada iteração, foi definido um número máximo de 20.000 ciclos de aprendizagem para interrupção, caso o modelo não atinja o limiar de convergência.

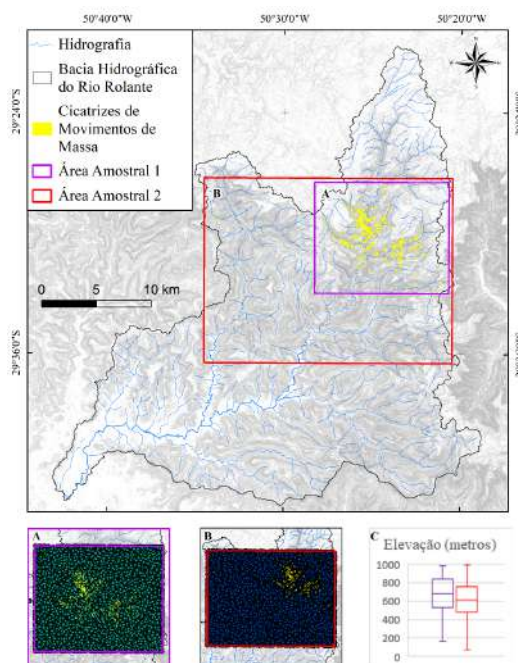


Figura 3 Áreas amostrais e variação da elevação: A. Área amostral 1; B. Área amostral 2. C Gráficos de Caixa (*boxplot*) para o atributo Elevação para cada área amostral, conforme cores em A e B.

Para validação, o índice de acurácia foi calculado por meio da *Area Under the ROC Curve* (AUC). A curva ROC é uma representação bidimensional do desempenho do modelo. Uma vez que o modelo esteve ajustado, as amostras de teste foram preditas no intervalo entre 0 e 1. As amostras foram divididas em vários grupos de duas classes por meio de limiares, para cada divisão foram calculadas a Taxa de Verdadeiros Positivos e a Taxa de Falsos Positivos, formando a curva ROC (Fawcett, 2006).

3 Resultados e discussões

No inventário, foram identificadas 297 cicatrizes relativas ao evento de 05/01/2017, com

área total de 1,06 km² (Figura 4). A maior cicatriz apresentou 4,0 ha, e a maior parte das cicatrizes apresentou largura inferior a 15 m e comprimento na ordem de 200 m. O conjunto amostral resultou em 39.318 amostras correspondentes a pixels do MDE, 50% representando áreas de ocorrência (1), e 50% locais de não ocorrência (0). Na modelagem, as amostras foram divididas em três séries, sendo a quantidade relativa ao método de reamostragem: treinamento (21% dos dados para $x=50$, e 14% para $x=80$), validação cruzada (44% e 46%, respectivamente) e teste (35% e 40%, respectivamente).

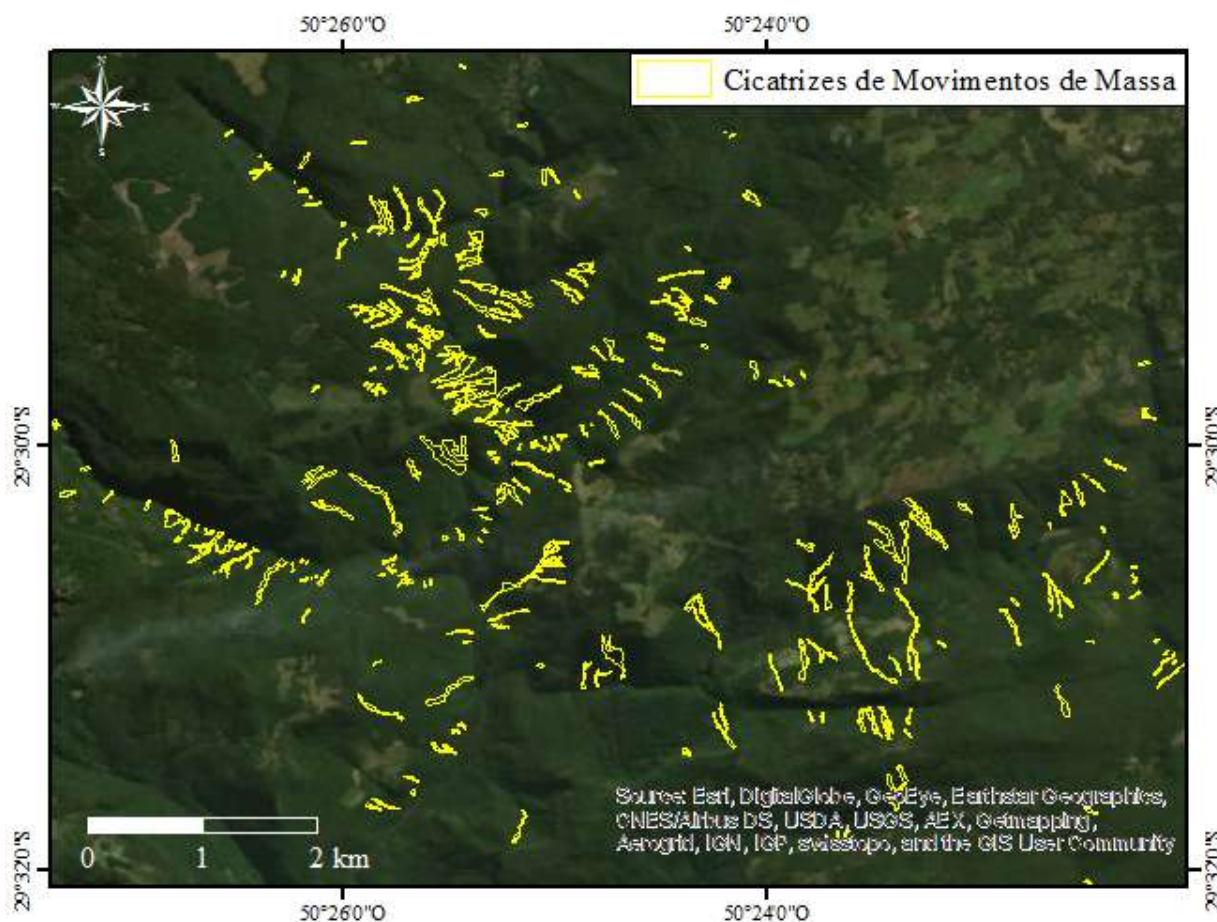


Figura 4 Inventário de Cicatrizes de Movimentos de Massa.

A Figura 5 apresenta gráficos do tipo *box-plot* com a distribuição dos valores de cada atributo do terreno, para os pontos de ocorrência e de não ocorrência de movimentos de massa. Os valores

das CVH, CVV e RLS se sobrepõem quanto à ocorrência e não ocorrência, e demonstra que esses parâmetros não são bons para identificar áreas suscetíveis, o mesmo foi demonstrado por Gameiro

et al. (2019). A ELV foi um atributo adequado para a área amostral 1, uma vez que os dados não se sobrepõem e a identificação de áreas suscetíveis é facilitada. Contudo, os dados de elevação da área 2 se sobrepõem, dificultando, assim, a identificação

de um limiar entre ocorrência e não ocorrência de movimentos de massa. Isso se dá pela abrangência da área 2, em que foram coletados valores com maior variabilidade. Os demais atributos, DCL, FLS e PRV, realçam essa diferença entre os dados.

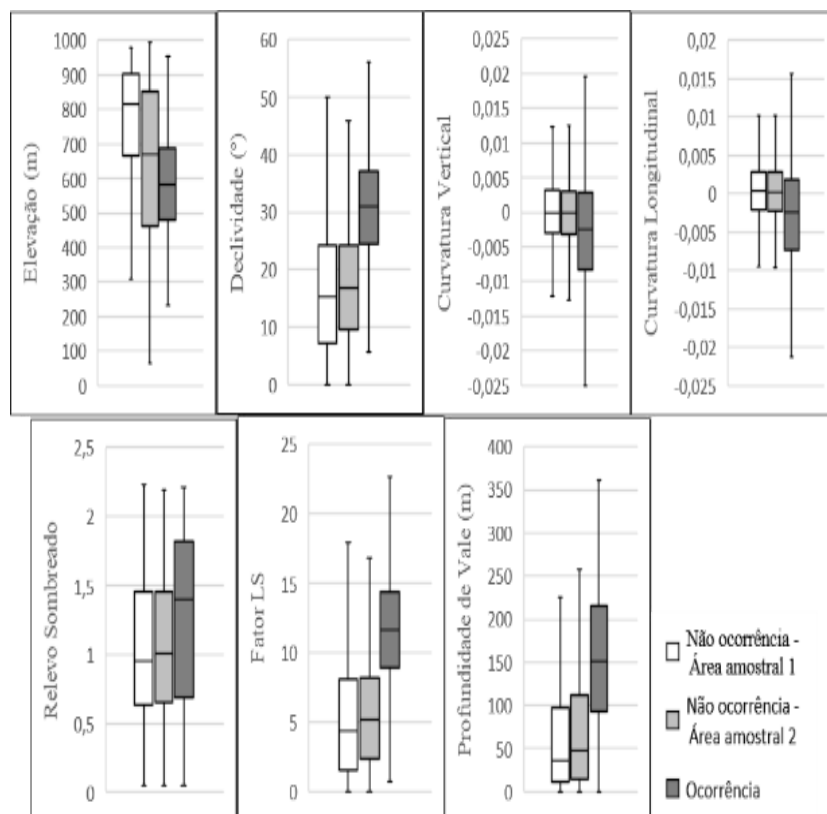


Figura 5 Gráficos da distribuição dos valores mínimos, médios e máximos dos atributos do terreno em áreas de ocorrência e de não ocorrência de movimentos de massa.

O grau de importância das variáveis (Tabela 1) mostra que a ELV apresentou maior peso nos 4 modelos selecionados para análise (a melhor configuração de RNA para cada área amostral e intervalo de reamostragem, conforme índice AUC). Situação semelhante foi demonstrada em Kawabata & Bandibas (2009), onde a retirada deste parâmetro reduziu a acurácia de 94% para 72%. As cicatrizes de movimentos de massa na BHRR são espacialmente concentradas, o que faz com que o padrão altimétrico da linha de escarpa apresente reduzida variação, com valores entre 480m e 700m (Figura 5). Devido a este padrão altimétrico, as RNA

definiram a importância da ELV como elevada, algo similar foi verificado em Oliveira *et al.* (2019).

O segundo atributo mais importante variou entre DCL, FLS e PRV. As variáveis CVH, CVV e RLS apresentaram pouca importância, devido à sobreposição de valores quanto a ocorrência e não ocorrência (Pradhan & Lee, 2010). Os resultados reforçam as análises de Dou *et al.* (2015) e Oliveira *et al.* (2015) sobre a importância da pré-seleção das variáveis explicativas para utilização nos modelos de RNA, a fim de eliminar variáveis redundantes e altamente correlacionadas, e identificar os principais fatores condicionantes.

Importância relativa dos atributos de entrada nas RNA				
	Área 1 $x=50$	Área 1 $x=80$	Área 2 $x=50$	Área 2 $x=80$
Elevação	37%	34%	32%	38%
Declividade	17%	24%	18%	19%
Curvatura Vertical	02%	02%	03%	02%
Curvatura Longitudinal	04%	06%	05%	06%
Relevo Sombreado	06%	02%	10%	08%
Fator LS	20%	21%	13%	05%
Profundidade de Vale	14%	11%	19%	21%

Tabela 1 Importância das variáveis preditivas em cada modelo de RNA selecionado.

Os índices de acurácia (AUC) para as séries de treinamento, validação cruzada e teste das RNA (Tabela 2), consideraram a melhor configuração obtida para cada combinação de variáveis preditivas. Estudos consideram uma boa acurácia em torno de 80% (Pradhan & Lee, 2010; Dou *et*

al., 2015), os valores de AUC obtidos neste estudo, independentemente do conjunto de atributos usados e da complexidade da RNA, foram próximos a 0,9, indicando um excelente grau de acerto no mapeamento de suscetibilidade a movimentos de massa.

Área	Amostragem	Modelo	AUC			Nº. Neurônios
			Calibração	Teste	Geral	
1	50	5	0,898	0,890	0,890	11
	80	2	0,879	0,880	0,879	05
2	50	6	0,926	0,919	0,920	13
	80	5	0,937	0,920	0,920	11

Tabela 2 Acurácia dos modelos para os diferentes conjuntos amostrais.

A área 1 apresentou acurácia menor quando comparada à área 2, que é mais abrangente. Algo semelhante foi verificado em Quevedo *et al.* (2019), em que a área menor apresentou restrição quanto à representatividade das variáveis explicativas. Quanto ao método de reamostragem, não há um padrão, uma vez que para a área 1, o método que apresentou o melhor desempenho foi aquele que considerava $x=50$, enquanto na área 2 foi a reamostragem mais restritiva ($x=80$) que obteve o melhor resultado. Isso permite destacar que a redução do conjunto amostral de treinamento não afeta a acurácia, desde que o processo de reamostragem resulte em amostras de treinamento representativas do conjunto inicial.

As quatro melhores configurações de RNA, de acordo com a maior AUC, foram especializadas para análise visual dos mapas de suscetibilidade (Figura 6). Os mapas resultantes foram classificados em cinco graus de suscetibilidade a movimentos de massa, considerando o intervalo de 0 a 1.

O melhor modelo referente à área 1, reamostragem 80 (Figura 6B), não representou de maneira adequada as áreas suscetíveis a movimentos de massa, apesar de apresentar uma AUC de 0,88. O mapa apresenta áreas suscetíveis em fundo de vale, incoerente com o tipo de fenômeno estudado, demonstrando, assim, uma baixa capacidade de generalização. É possível que isto tenha acontecido

porque a área amostral considerada foi mais restritiva (área 1) e a amostra de treinamento do modelo foi menor ($x=80$).

Os mapas da área 2, mais abrangente, apresentaram AUC acima de 0,9 e elevada capacidade de generalização. Não mapearam fundos de vale e abrangeram de maneira adequada as cicatrizes. O modelo com melhor AUC foi o da reamostragem

80 (Figura 6D), porém, este se aproxima do modelo de reamostragem 50 tanto em AUC quanto aos elementos visuais do mapa de suscetibilidade. Nem sempre os modelos que apresentam melhor AUC são os modelos mais adequados. É necessária uma análise visual dos resultados para selecionar aqueles que apresentam melhor mapeamento de áreas suscetíveis a movimentos de massa.

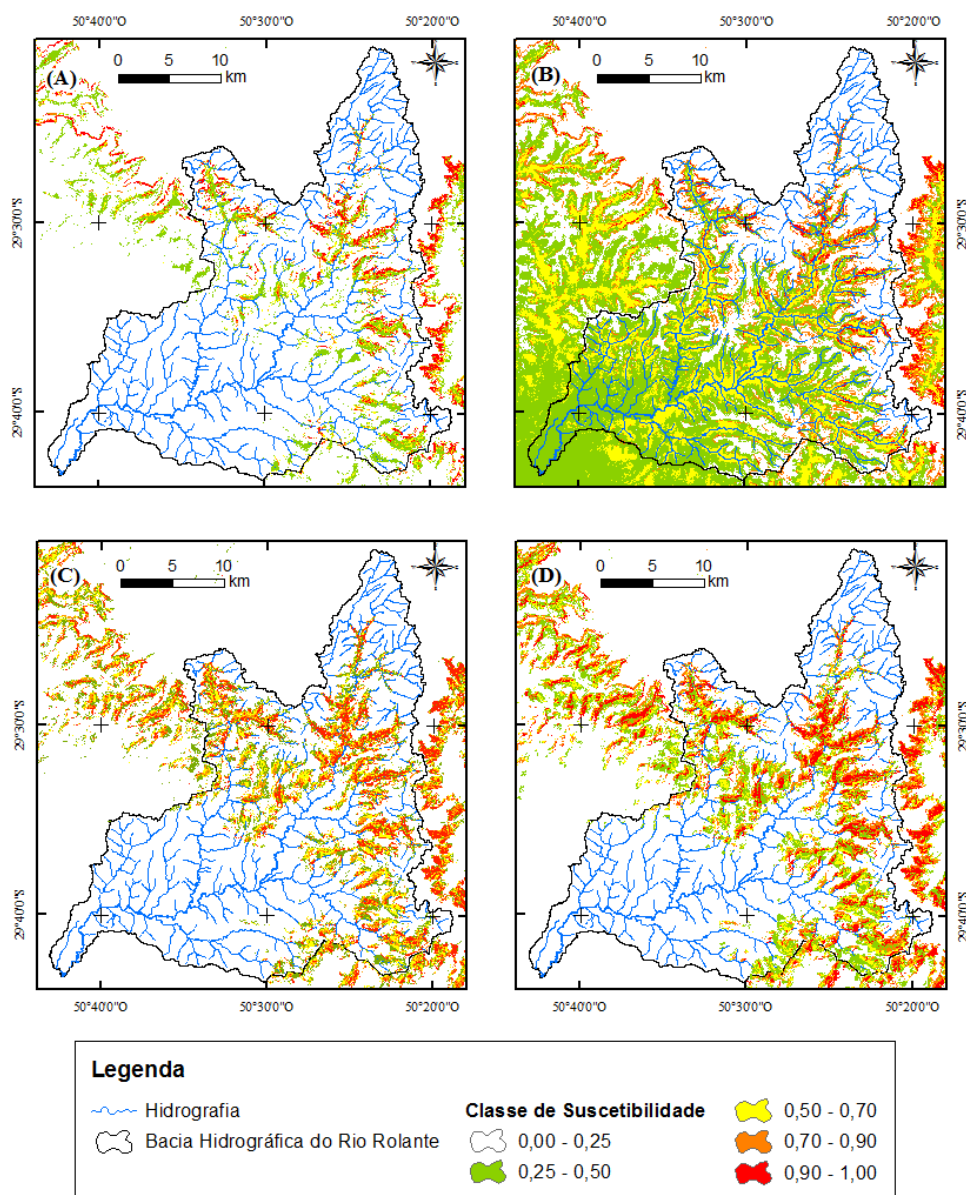


Figura 6. Mapas de suscetibilidade com maiores AUC: A. Mapa de suscetibilidade para área amostral 1, reamostragem por $x=50$; B. Mapa de suscetibilidade para área amostral 1, reamostragem por $x=80$; C. Mapa de suscetibilidade para área amostral 2, reamostragem por $x=50$; D. Mapa de suscetibilidade para área amostral 2, reamostragem por $x=80$.

4 Conclusões

O inventário de cicatrizes de movimentos de massa é de suma importância e permitiu a obtenção de amostras de ocorrências do fenômeno. As diferentes áreas de coletas de amostras de não ocorrência permitiram verificar como a restrição da área amostral pode influenciar no desempenho do modelo, assim como na sua capacidade de generalização.

O método de redução do conjunto amostral a partir do reordenamento das variáveis e coleta de dados a partir de x amostras demonstrou-se eficiente, pois possibilita um processamento com menor esforço amostral, sem perder a representatividade dos dados iniciais. Em ambas as reduções ($x=50$ e $x=80$), os resultados foram satisfatórios, não havendo predominância de melhor valor para x .

Os diferentes conjuntos amostrais utilizados neste estudo demonstraram que a ELV foi o fator com maior importância na modelagem a partir de RNA, com valores de importância acima de 30% para todos os modelos. Entretanto, atributos morfométricos comumente usados como CVH, CVV e RLS apresentaram importância menor ou igual a 10%, o que demonstra que a busca por outras variáveis com melhor desempenho pode vir a substituir o uso destas.

Por fim, uso de RNA para mapeamento de suscetibilidade a movimentos de massa se apresentou adequado devido à elevada acurácia dos modelos. Neste estudo, as RNA se mostraram capazes de modelar as áreas suscetíveis, com acurácia próximas ou superiores a 0,9.

5 Agradecimentos

O presente trabalho foi realizado com apoio:

i) da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001; ii) da Fundação de Amparo à Pesquisa do Estado do Rio Grande do Sul – FAPERGS, com apoio financeiro via Edital 01/2017 – ARD, processo 17/2551-0000894-4.

6 Referências

- Aditian, A.; Kubota, T. & Shinohara, Y. 2018. Comparison of GIS-based landslide susceptibility models using frequency ratio, logistic regression, and artificial neural network in a tertiary region of Ambon, Indonesia. *Geomorphology*, 318: 101-111.
- CEPED UFSC. 2013. *Atlas Brasileiro de Desastres Naturais – 1991 a 2012. Volume Brasil*. Centro Universitário de Estudos e Pesquisas sobre Desastres, Universidade Federal de Santa Catarina. 2ed. rev. amp. Florianópolis, CEPED UFSC, 127 p.
- Dai, F.C. & Lee, C.F. 2002. Landslide characteristics and slope instability modeling using GIS, Lantau Island, Hong Kong. *Geomorphology*, 42: 213-228.
- Dou, J.; Yamagashi, H.; Pourghasemi, H.R.; Yunus, A.P.; Song, X.; Xu, Y. & Zhu, Z. 2015. An integrated artificial neural network model for landslide susceptibility assessment of Osado Island, Japan. *Natural Hazards*, 78: 1749-1776.
- Fawcett, T. 2006. An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8): 861–874.
- Garcia-Urquia, E. & Yamagishi, H. 2017. Landslide Susceptibility Mapping Based on Aerial Photograph Interpretation Inventory for Tegucigalpa, Honduras: An Application of the Matrix Method. In: YAMAGASHI, H. & BHANDARY, N.P. (ed.). *GIS Landslide*. Springer, Tokyo, p. 163-181.
- Gameiro, S.; Quevedo, R.P.; Oliveira, G.G.; Ruiz, L.F.C. & Guasselli, L.A. 2019. Análise e correlação de atributos morfométricos e sua influência nos movimentos de massa ocorridos na Bacia do Rio Rolante, RS. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO XIX, Santos, 2019. Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto, Santos, INPE, v. 17, p. 2880-2883.
- Jensen, J.R. 2005. *Introductory digital image processing: a remote sensing perspective*. 3 ed., New Jersey, Prentice-Hall, 526p.

- Kawabata, D. & Bandibas, J. 2009. Landslide susceptibility mapping using geological data, a DEM from ASTER images and an Artificial Neural Network (ANN). *Geomorphology*, 113: 97-109.
- Lajas, S.M.A. 2016. *Integração de métodos estatístico e determinístico para a avaliação da suscetibilidade a deslizamentos superficiais*. Instituto de Geografia e Ordenamento do Território, Universidade de Lisboa, Dissertação de Mestrado, 170p.
- Le, Q.H.; Nguyen, T.H.V.; Do, M.D.; Le, T.C.H.; Pham, V.S.; Nguyen, H.K. & Luu, T.B. 2018. TXT-tool 1.084-3.1: Landslide Susceptibility Mapping at a Regional Scale in Vietnam. In: SASSA, K.; GUZZETTI, F.; YAMAGASHI, H.; ARBANAS, Z.; CASAGLI, N.; MCSAVENEY, M. & DANG, K. (ed.). *Landslide Dynamics: ISDR-ICL Landslide Interactive Teaching Tools*. Springer, p. 161-174.
- Meinhardt, M.; Fink, M. & Tünschel, H. 2015. Landslide susceptibility analysis in central Vietnam based on an incomplete landslide inventory: Comparison of a new method to calculate weighting factors by means of bivariate statistics. *Geomorphology*, 234: 80-97.
- Meten, M.; Prakashbhandary, N. & Yatabe, R. 2015. Effect of Landslide Factor Combinations on the Prediction Accuracy of Landslide Susceptibility Maps in the Blue Nile Gorge of Central Ethiopia. *Geoenvironmental Disasters*, 2(9): 1- 17.
- Mokhtari, M. & Abedian, S. 2019. Spatial prediction of landslide susceptibility in Taleghan basin, Iran. *Stochastic Environmental Research and Risk Assessment*, 33: 1297-1325.
- Oliveira, G.G.; Pedrollo, O.C. & Castro, N.M. 2015. Simplifying artificial neural network models of river basin behaviour by an automated procedure for input variable selection. *Engineering Applications of Artificial Intelligence*, 40: 47-61.
- Oliveira, G.G.; Ruiz, L.F.C.; Guasselli, L.A. & Haetinger, C. 2019. Random forest and artificial neural networks in landslide susceptibility modeling: a case study of the Fão River Basin, Southern Brazil. *Natural Hazards*, 99(2): 1049-1073.
- Pradhan, B. & Lee, S. 2010. Regional landslide susceptibility analysis using backpropagation neural network model at Cameron Highland, Malaysia. *Landslides*, 7: 13-30.
- Pourghasemi, H.R.; Kornejady, A.; Kerle, N. & Shabani, F. 2020. Investigating the effects of different landslide positioning techniques, landslide partitioning approaches, and presence-absence balances on landslide susceptibility mapping. *Catena*, 187: 104364.
- Quevedo, R.P.; Guasselli, L.A.; Oliveira, G.G. & Ruizm L.F.C. 2019. Modelagem de áreas suscetíveis a movimentos de massa: avaliação comparativa de técnicas de amostragem, aprendizado de máquina e modelos digitais de elevação. *Geociências*, 39(3): 781-795.
- Riffel, E.S.; Ruiz, L.F.C. & Guasselli, L.A. 2016. Mapeamento de suscetibilidade a deslizamentos a partir de Mineração de Dados e do modelo SHALSTAB. *Revista Brasileira de Cartografia*, Especial Movimentos de Massa e Processos Erosivos, 68(9): 1805-1818.
- Rossato, M.S. 2011. *Os Climas do Rio Grande do Sul: variabilidade, tendências e tipologia*. Programa de Pós-Graduação em Geografia, Universidade Federal do Rio Grande do Sul. Tese de Doutorado, 253p.
- Rumelhart, D.E.; Hinton, G.E. & Williams, R.J. 1986. Learning representations by back-propagating errors. *Nature*, 323: 533-536.
- SEMA. 2017. *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*. Secretaria do Ambiente e Desenvolvimento Sustentável, Porto Alegre, 26p.
- Widrow, B. & Hoff, M.E. 1960. Adaptive Switching Circuits. In: 1960 IRE WESCON CONVENTION RECORD, New York, 1960, IRE Part, p. 96-104.
- Wischmeier, E.H. & Smith, D.D. 1978. *Predicting rainfall erosion lossess: a guide to conservation planning*. Washington D.C., USDA, Agriculture Research Service. 58p.
- Zêzere, J.L.; Pereira, S.; Melo, R.; Oliveira, S.C. & Garcia, R.A.C. 2017. Mapping landslide susceptibility using data-driven methods. *Science of the Total Environment*, 589: 250-267.