

XXIV SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS

IDENTIFICAÇÃO DE ÁREAS SUSCETÍVEIS A DESLIZAMENTOS DE TERRA NO LIMITE DOS MUNICÍPIOS DE PRESIDENTE GETÚLIO, RIO DO SUL E IBIRAMA (SC), POR MEIO DE UM *ENSEMBLE* DE REDES NEURAIAS ARTIFICIAIS

*Luísa Vieira Lucchese*¹; *Guilherme Garcia de Oliveira*² & *Olavo Correa Pedrollo*¹

Em 17 de dezembro de 2020, um evento extremo de precipitação desencadeou deslizamentos de terra na zona limítrofe dos municípios de Presidente Getúlio, Ibirama e Rio do Sul, no estado de Santa Catarina, Brasil. O Serviço Geológico do Brasil (CPRM) havia divulgado, em seu portal, uma carta de suscetibilidade a movimentos de massa realizada com base em levantamentos detalhados, anteriores a este evento, para o município de Presidente Getúlio, com o objetivo de divulgar as áreas com potencial para futuros deslizamentos. Também com este objetivo, o Grupo de Pesquisas em Desastres Naturais (GPDEN) da Universidade Federal do Rio Grande do Sul realizou um mapeamento das encostas com o uso do modelo Shallow Landslide Stability (SHALSTAB) espacializado. O mapa gerado com auxílio do SHALSTAB mostrou grande conformidade com as cicatrizes que eles mapearam. No presente trabalho, apresenta-se um mapa de suscetibilidade a deslizamentos para a área de Presidente Getúlio, Ibirama e Rio do Sul (SC), gerado por meio de um *ensemble* do tipo *bagging* de cinco Redes Neurais Artificiais treinadas com diferentes separações de amostras. Nosso principal objetivo foi verificar se um mapa gerado por RNAs seria compatível com as versões análogas desenvolvidas pela CPRM e pelo GPDEN, oferecendo, neste caso, um recurso adicional que pode vir a integrar práticas comuns. Também pesquisamos o limiar para a classificação entre as classes suscetível e não suscetível, o qual afeta a área classificada como suscetível no mapa resultante, favorecendo uma ou outra classificação, sendo sua escolha importante para atender objetivos diferentes de gestão.

Palavras-Chave – Inteligência Artificial, Desastres Naturais, Santa Catarina

1. INTRODUÇÃO

Deslizamentos de terra ocorrem em regiões montanhosas, escarpadas e costeiras de todo o mundo e costumam ser um risco subestimado (Petschko *et al.*, 2014). O mapeamento de suscetibilidade a deslizamentos é um recurso utilizado para identificar as áreas em que podem ocorrer futuros deslizamentos de terra, com vistas a prevenir futuras perdas de vidas e propriedades. O objetivo de realizar este tipo de mapeamento difere do de outros tipos de pesquisa em geomorfologia porque, neste caso, a análise dos padrões relacionados às condições ambientais e climáticas não é de interesse primordial (Brenning, 2005). Os mapas de suscetibilidade, portanto, tem o objetivo de mostrar *onde* os deslizamentos de terra podem ser esperados, em vez de fornecerem uma estimativa de *quando* eles poderão ocorrer (Neuhäuser e Terhorst, 2007).

1) Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul, Av. Bento Gonçalves 9500, 91501-970, Porto Alegre, RS, Brasil.
E-mail: luisa.lucchese@ufrgs.br

2) Departamento Interdisciplinar. Universidade Federal do Rio Grande do Sul. Rodovia RS 030, 11700, km 92. Emboaba, Tramandaí, RS, Brasil.
CEP 95590-000.

Para elaboração dos mapas de suscetibilidade a deslizamentos, uma gama de diferentes métodos pode ser utilizada. Nos últimos anos, Metodologias de Inteligência Artificial (Minsky, 1961) e de Aprendizagem de Máquina (Murphy, 2012) tem sido cada vez mais utilizadas para este fim (Gheshlaghi e Feizizadeh, 2021; Dou *et al.*, 2015; Goetz *et al.*, 2015; Nhu *et al.*, 2020), em geral, obtendo bons resultados (Dou *et al.*, 2019; Xiao *et al.*, 2019). Alguns autores aplicaram metodologias de Aprendizagem de Máquina em áreas de estudo no Brasil, incluindo Bragagnolo *et al.* (2020), que trabalharam com os municípios de Porto Alegre e do Rio de Janeiro, e os presentes autores e seu grupo de pesquisa, que trabalharam com Redes Neurais Artificiais (RNAs) e as áreas das bacias hidrográficas do rio Taquari-Antas (Oliveira *et al.*, 2018) do rio Fão (Oliveira *et al.*, 2019), e do rio Rolante (Lucchese *et al.*, 2020a, 2020b, 2021).

Neste trabalho, o enfoque é dado à zona limítrofe entre os municípios de Presidente Getúlio, Ibirama e Rio do Sul, no vale do rio Itajaí, no estado de Santa Catarina, Brasil. Em 17 de dezembro de 2020, um evento extremo de precipitação desencadeou deslizamentos de terra, fluxos de detritos e enxurradas, resultando um desastre natural de significativas proporções. No Geoportal do Serviço Geológico do Brasil (CPRM) está disponibilizada uma carta de suscetibilidade a movimentos de massa para o município de Presidente Getúlio – SC (CPRM, 2019). A última modificação na carta está datada de 03 de dezembro de 2020, indicando que a CPRM não teve oportunidade de reavaliá-la depois do evento do dia 17 de dezembro do mesmo ano. Os levantamentos da CPRM são realizados por municipalidade, e, das três municipalidades envolvidas no evento abordado, apenas uma, Presidente Getúlio, está disponível atualmente. Sabendo-se das metodologias confiáveis utilizadas pela CPRM para tais mapeamentos, espera-se que, para a área estudada, os mapas de suscetibilidade apresentados no presente trabalho sejam comparáveis.

Ainda, no início de 2021, O Grupo de Pesquisas em Desastres Naturais (GPDEN) da UFRGS elaborou um relatório técnico sobre este evento (Michel *et al.*, 2021), com os resultados do trabalho de campo do grupo citado. O mapeamento de estabilidade das encostas realizado pelos mesmos foi feito com o uso do modelo *Shallow Landslide Stability* (SHALSTAB) espacializado (Montgomery e Dietrich, 1994; Michel, 2013; Godoy, 2018) e destacou várias regiões, especialmente em Presidente Getúlio e Rio do Sul, na classificação “Incondicionalmente instável”. O mapa gerado com auxílio do SHALSTAB mostrou grande conformidade com as cicatrizes que eles mapearam. Modelos de Aprendizagem de Máquina, por não serem físicos (como, por exemplo, o SHALSTAB) têm caminhos distintos para chegar aos mapas de suscetibilidade a deslizamentos. A semelhança dos resultados, se confirmada, pode contribuir para respaldar os mapeamentos obtidos por ambos os meios, ou indicar situações que mereçam questionamentos, contribuindo para a análise decisória por gestores públicos.

Diferentemente de mapeamentos de estabilidade, em mapeamentos de suscetibilidade feitos com base em modelos de Aprendizagem de Máquina, a classificação em classes de suscetibilidade não é direta, pois eles são treinados com apenas duas categorias, suscetível (sobre as cicatrizes dos movimentos de massa) e não-suscetível (ausência de cicatriz). Neste caso, dependendo do limiar utilizado para classificar os resultados expedidos pelo modelo, o mapa resultante de suscetibilidade será vastamente diferente. Se utilizado um limiar muito baixo, a chance de que ocorra um deslizamento em uma região marcada como não-suscetível é diminuta, por outro lado, aumenta a chance de ocorrência do efeito “O Pastor Mentiroso e o Lobo” (*Cry Wolf*), fenômeno que acarreta descrédito ao sistema de alerta (LeClerc e Joslyn, 2015). Tal fenômeno tem mais chance de ocorrer quando uma área que não é suscetível é considerada pelo sistema de alerta em vigor como suscetível, gerando alertas falsos. Por outro lado, se o limiar for muito elevado, o modelo pode classificar áreas de grande suscetibilidade erroneamente como não-suscetíveis, o que tem implicações como perdas de vidas e prejuízos econômicos na ocasião da ocorrência de desastres naturais.

Para determinar um limiar, é comum fixá-lo em 0,5, em uma escala de 0 a 1. Outra opção é selecionar o limiar que entrega a melhor taxa de acertos, e ainda outra possibilidade seria ajustá-lo baseado em critérios de especificidade e sensibilidade. Especificidade é a capacidade de um modelo

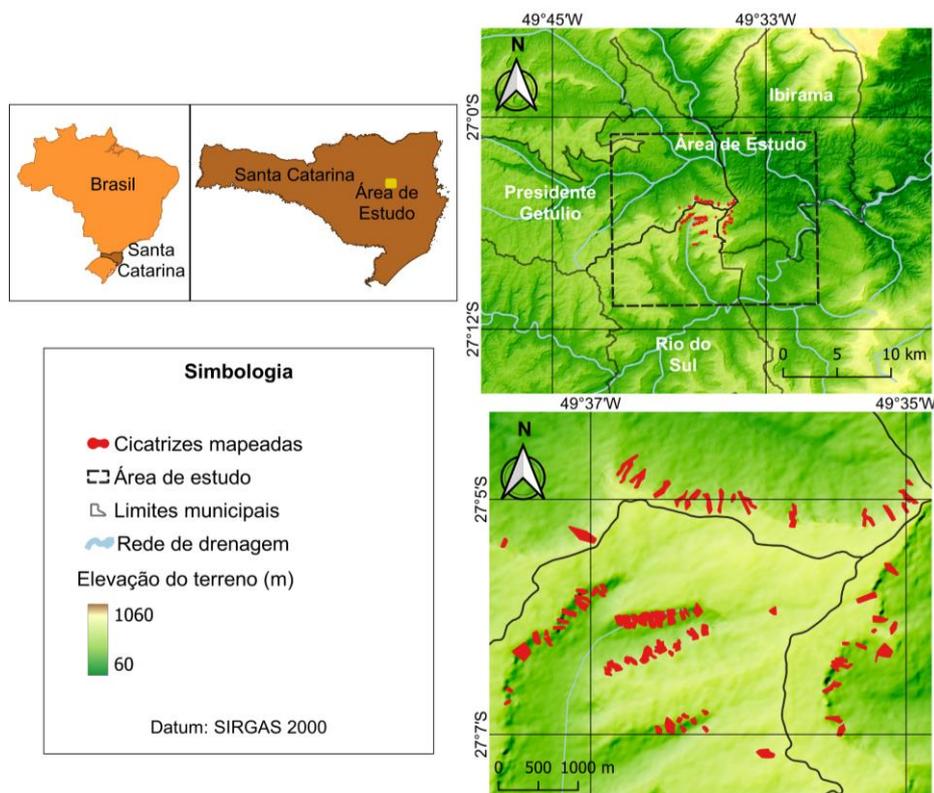
de apontar resultados negativos corretamente e ter poucos falsos positivos. Sensibilidade é a capacidade de um modelo de englobar os resultados positivos existentes na sua classificação positiva. Geralmente, para um dado modelo, ao se mover o limiar com vistas a aumentar a sensibilidade, a especificidade tende a diminuir, e vice-versa. No sentido de suscetibilidade, isto se traduz em: especificidade é a capacidade do modelo de classificar como suscetível áreas realmente suscetíveis, excluindo áreas não-suscetíveis; e sensibilidade é a capacidade de o modelo identificar as áreas suscetíveis como suscetíveis. Modelos com baixa especificidade tem mais áreas erroneamente classificadas como suscetíveis e podem gerar alertas desnecessários para a população. No entanto, modelos com baixa sensibilidade podem classificar áreas suscetíveis como seguras, acarretando a destruição de habitações e perda de vidas humanas. Por isso, um balanço equilibrado entre estas duas competências é desejável ao se pensar em zoneamento e plano-diretor, pois alguns modelos, ou mudanças no limiar classificatório, ou mesmo alguns conjuntos de dados, podem fazer o modelo pender mais para um lado ou para o outro.

No presente trabalho, apresenta-se um mapa de suscetibilidade a deslizamentos para a região de Presidente Getúlio, Ibirama e Rio do Sul no estado de Santa Catarina, Brasil, gerado por meio de um *ensemble* do tipo *bagging* de cinco Redes Neurais Artificiais treinadas com diferentes separações de amostras. Como principal objetivo, destaca-se a análise do mapa produzido por este *ensemble*, verificando a compatibilidade com os mapas análogos desenvolvidos pela CPRM e pelo GPDEN. Finalmente, discutem-se possibilidades de limiares a serem utilizados para classificação entre zonas suscetíveis e não-suscetíveis.

2. ÁREA DE ESTUDO

A área de estudo para o presente trabalho abrange uma pequena porção do estado de Santa Catarina. A área engloba o sul do município de Presidente Getúlio, o norte do município de Rio do Sul, o oeste do município de Ibirama, e o norte do município de Lontras, embora no âmbito do último não tenham sido encontradas evidências de deslizamentos de terra. Os rios e ribeirões da área são afluentes do rio Itajaí-Açu. Na Fig.1 apresenta-se a localização e a hidrografia da área de estudo.

Figura 1 – Localização da Área de Estudo e das cicatrizes do evento mapeadas



3. METODOLOGIA

3.1 Mapeamento de cicatrizes

O mapeamento de cicatrizes foi baseado nas imagens da constelação de nanossatélites PlanetScope, da empresa Planet, com resolução espacial de 3 m, do dia 30/12/2020. O mapa foi produzido a partir de interpretação visual, no software QGIS 3.18, por meio da composição colorida falsa-cor RGB432. Foram mapeadas 82 cicatrizes, com comprimento médio de 179,9 m e área média de 8259,6 m². As localizações das cicatrizes mapeadas são apresentadas na Fig. 1.

3.2 Geração dos Atributos

Foram gerados 10 atributos de terreno baseados somente no Modelo Digital de Elevação (MDE) ALOS PALSAR da Agência Espacial Japonesa (JAXA), que tem resolução de 12,5 m. Estes atributos, bem como os dados de elevação do próprio MDE, são utilizados como entrada do modelo. Como investigado em Lucchese *et al.* (2020a), tais atributos, mesmo quando altamente intercorrelacionados, trazem informações novas à RNA. Os atributos foram gerados nos softwares de Sistemas de Informação Geográfica (SIG) código-livre QGIS, SAGA GIS e com uso de ferramentas do GRASS GIS e do GDAL. São eles:

- Curvatura em Perfil: a curvatura da encosta, considerando-se somente a porção vertical;
- Curvatura Planar: a curvatura da encosta, considerando-se somente a porção horizontal;
- Declividade: a declividade da encosta, em um determinado local, de 0 a 90°;
- Distância Vertical à Rede de Drenagem: a distância vertical da superfície do terreno a um fluxo de base hipotético, em metros;
- Elevação: dados de elevação absoluta, em metros. Provenientes do MDE ALOS PALSAR;
- Fator LS: Fator Comprimento-Declividade da Equação Universal de Perda de Solo USLE;
- Índice de Umidade Topográfica: realça as áreas prováveis de acúmulo de água e corpos d'água;
- Logaritmo natural da Acumulação do Fluxo: logaritmo natural da acumulação do fluxo na região, calculado pelo método Determinístico 8;
- Orientação: a orientação da encosta, em um determinado local, de 0 a 360°;
- Profundidade de vale: a distância vertical de um ponto ao fundo do vale;
- Sombreamento: o sombreamento da encosta baseado em um Sol hipotético.

3.3 Amostragem dos dados

Dentro das cicatrizes mapeadas, todos os pixels do MDE foram amostrados como amostras de ocorrência. Na região externa às cicatrizes, utilizou-se um buffer de 5 km das cicatrizes como limite máximo em relação à aquisição de amostras de não-ocorrência, coletadas aleatoriamente e em número igual às amostras de ocorrência. Este procedimento é baseado no que foi exposto em Lucchese *et al.* (2021).

3.4 Redes Neurais Artificiais utilizadas

Utilizam-se, para o presente trabalho, Redes Neurais Artificiais (RNAs) com uma camada interna. O esquema das RNAs utilizadas está disposto na Fig. 2.

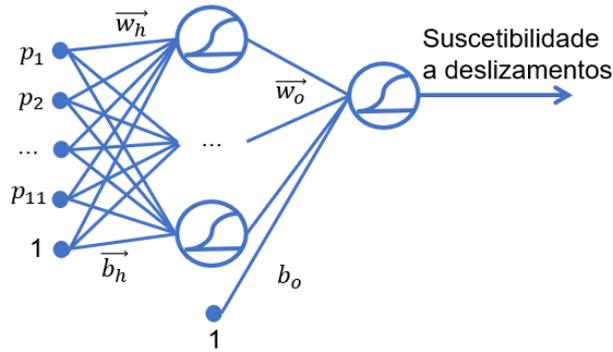
A regra delta utilizada foi:

$$\vec{w}_{k,t} = \vec{w}_{k,t-1} + \tau \vec{\delta} \vec{p}_k + mo(\vec{w}_{k,t-1} - \vec{w}_{k,t-2}) \quad (1)$$

em que o delta é definido por $\vec{\delta} = \vec{e}_k \vec{s}'_k(\eta_k)$, os erros na camada k são \vec{e}_k , e $\vec{s}'_k(\eta_k)$ é a derivada da função de ativação. Na Eq. (1), os pesos definidos para a camada k são \vec{w}_k , τ é a taxa de

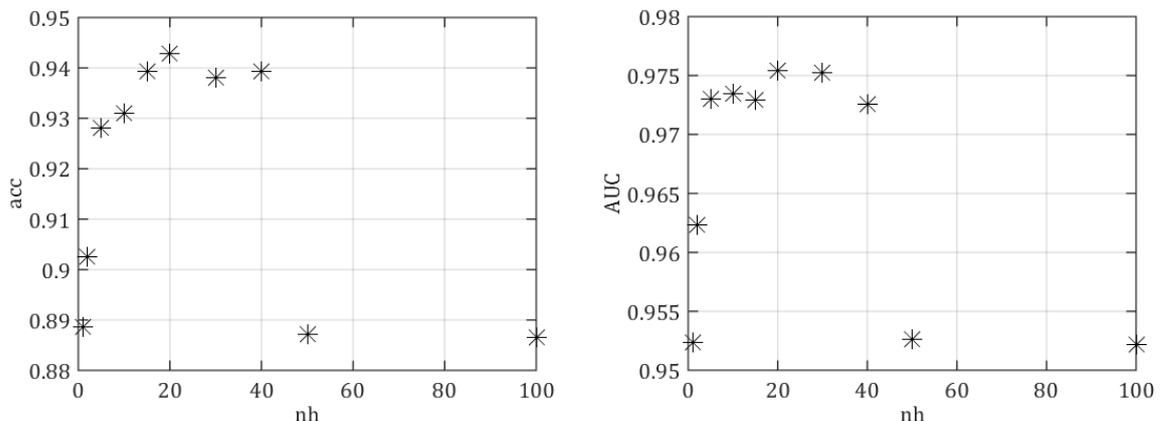
aprendizagem, \vec{p}_k são as entradas da camada k , e o subscrito t indica o ciclo atual. Um termo de momento é inserido para acelerar o treinamento, o termo mo , que vale 0 se não houve melhora no último ciclo de treinamento, e 0.96 se houve. A taxa de aprendizagem é heurísticamente variada (Vogl *et al.*, 1988), de forma a proporcionar convergência mais eficiente do treinamento, sendo inicializada com o valor $\tau = 0.00001$. Se, num dado ciclo, o erro quadrático aumenta, a mesma é reduzida pela metade, por outro lado, se o erro diminui, a taxa é aumentada em 10%. A função de ativação utilizada é do tipo sigmoide unipolar.

Figura 2 – Esquema das Redes Neurais Artificiais utilizadas no presente trabalho



As RNAs utilizadas foram desenvolvidas pelos presentes autores em plataforma MATLAB. Estas são treinadas com o método de validação cruzada e com o número de neurônios na camada interna ajustado segundo o método proposto em Lucchese *et al.* (2020a), que consiste, resumidamente, em obter a mínima complexidade do modelo de RNAs para que o fenômeno seja corretamente modelado. A análise é feita visualmente em gráficos da taxa de acertos (acc), que varia de 0,0 a 1,0, e Área sob a Curva Receiver Operating Characteristic (AUC) referentes à amostra de validação, utilizada na validação cruzada. A taxa de acertos é o número de respostas corretas sobre o total de respostas dadas pelo modelo. A curva Receiver Operating Characteristic (ROC) tem na sua abscissa a taxa de falsos positivos e na ordenada, a taxa de verdadeiros positivos. A curva é formada ao se aplicar diferentes limiares de classificação. O AUC varia de 0,5 a 1,0, sendo que valores mais próximos de 1,0 indicam modelos com maior capacidade de discriminação entre classes. Ao observar os gráficos mostrados na Fig. 3, o número resultante foi de 20 neurônios na camada interna para a região estudada.

Figura 3 – a) Taxa de acertos (acc) e b) AUC em função do número de neurônios na camada interna (nh), para a área de estudo.



Um total de 25 RNAs foram treinadas para este trabalho: 5 separações aleatórias diferentes de amostras para treinamento, validação e verificação, e, para cada uma, 5 repetições com pesos iniciais aleatórios diferentes. O modelo gerado é um *ensemble* do tipo *bagging* (média) da repetição que gerou a maior taxa de acertos na amostra de validação de cada separação de amostras.

3.5 Métricas calculadas

As principais métricas utilizadas no presente trabalho são a taxa de acertos, a sensibilidade, e a especificidade, respectivamente:

$$\text{acc} = \frac{VP + VN}{VP + VN + FP + FN} \quad (2)$$

$$\text{sens} = \frac{VP}{VP + FN} \quad (3)$$

$$\text{spec} = \frac{VN}{VN + FP} \quad (4)$$

onde VP é o número de Verdadeiros Positivos, VN é o número de Verdadeiros Negativos, FP é o número de Falsos Positivos e FN, de Falsos Negativos classificados por um dado modelo.

4. RESULTADOS

A taxa de acertos média para o ensemble de RNAs é de 94,36%, e AUC de 0.975, com limiar de classificação de 0,48 e baseados na amostra de verificação, não envolvida no treinamento, com o objetivo de evitar viés nas métricas. O mapa de suscetibilidade resultante é apresentado nas Figs. 4 e 5. Na Fig 4a, apresenta-se o mapeamento apresentado no presente trabalho, sobreposto ao feito pela CPRM no município de Presidente Getúlio. Na Fig 4b, este é sobreposto ao elaborado pelo GPDEN (Michel *et al.*, 2021), com apenas as três classificações mais instáveis extraídas do relatório técnico. Na Fig. 4c, são apresentados os três mapas sobrepostos, com o intuito de destacar os locais em interseção.

Também foram elaborados mapas de suscetibilidade considerando diferentes limiares de classificação (Fig. 5). O limiar ideal com base na taxa de acertos baseada na amostra de validação é de 0,48, muito próximo de 0,5, correspondente à Fig. 5c. Na Tab. 1, apresentam-se as métricas de taxa de acertos, sensibilidade e especificidade para cada um dos limiares, baseadas na amostra de verificação.

5. DISCUSSÃO

As cicatrizes mapeadas para o evento estudado estão em localizações compatíveis com o mapeamento de suscetibilidade apresentado. O mapeamento ainda indica a suscetibilidade de áreas mais ao sul. O levantamento da CPRM e os resultados do presente trabalho apresentam áreas suscetíveis em comum, em especial na área limítrofe de Presidente Getúlio com Rio do Sul. Nestas áreas, encontram-se cicatrizes do evento do dia 17 de dezembro de 2020. Esta região também foi identificada como incondicionalmente instável no relatório técnico do grupo GPDEN (Michel *et al.*, 2021). No relatório citado, as áreas destacadas como instáveis foram semelhantes às apresentadas no presente trabalho, e algumas áreas ao norte, dentro do município de Presidente Getúlio, apontadas pelo levantamento da CPRM como suscetíveis, não são consideradas preocupantes, tanto no relatório de Michel *et al.* (2021) quanto nos resultados do presente trabalho. Há de ser levado em conta, no entanto, que o levantamento do CPRM foi realizado antes do evento do dia 17 de dezembro de 2020.

A alteração do limiar classificatório tem implicações na área considerada suscetível no mapa e nas métricas de taxa de acertos, sensibilidade e especificidade. Limiares mais baixos fazem que uma área maior na região de estudo seja considerada suscetível, e maximizam a sensibilidade, porém, minimizam a especificidade, aumentando a chance de alertas falsos. Por outro lado, limiares mais altos maximizam a especificidade ao diminuir o número de falsos positivos, mas diminuem largamente a sensibilidade do modelo, excluindo do mapeamento áreas comprovadamente suscetíveis, resultando poucas áreas no mapa marcadas como suscetíveis. Como esperado, ao adotar-se um meio-termo, não somente se obtém balanceamento dos efeitos, como também se maximiza a taxa de acertos geral da classificação. Porém, para alguns casos, em que uma das métricas deva ser preferida em relação à outra, a mudança de limiar classificatório pode ser de grande utilidade.

Figura 4 – Cicatrizes de deslizamentos de terra mapeadas no presente trabalho e mapa de suscetibilidade gerado pelo ensemble de RNAs, sobreposto (50% de transparência) a mapas de suscetibilidade e estabilidade a movimentos de massa gerados por outros autores, sendo a) sobreposto ao mapa disponibilizado pela CPRM; b) Sobreposto ao mapa de Michel *et al.* (2021), somente as três categorias mais instáveis do mesmo; c) mapas de Michel *et al.* (2021), da CPRM, e relativo ao presente trabalho.

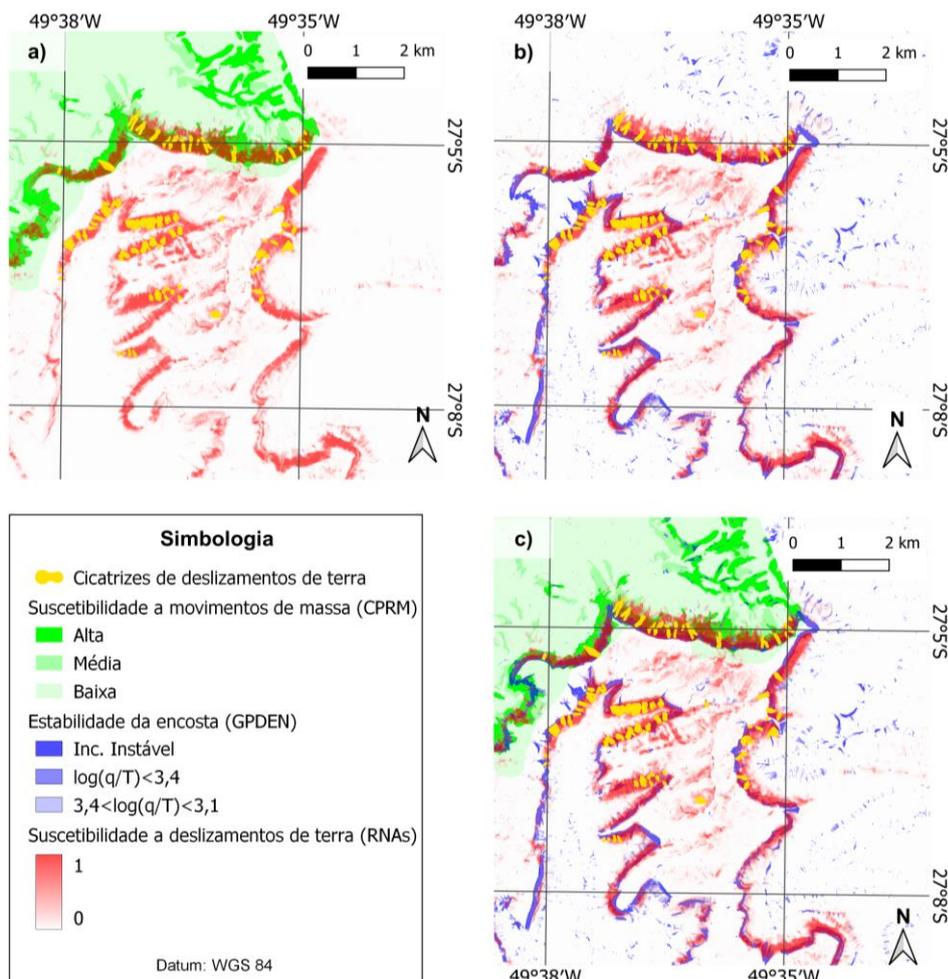


Figura 5 – Mapas de suscetibilidade para os limiares de classificação a) 0,05; b) 0,25 c) 0,50; d) 0,75; e e) 0,95.

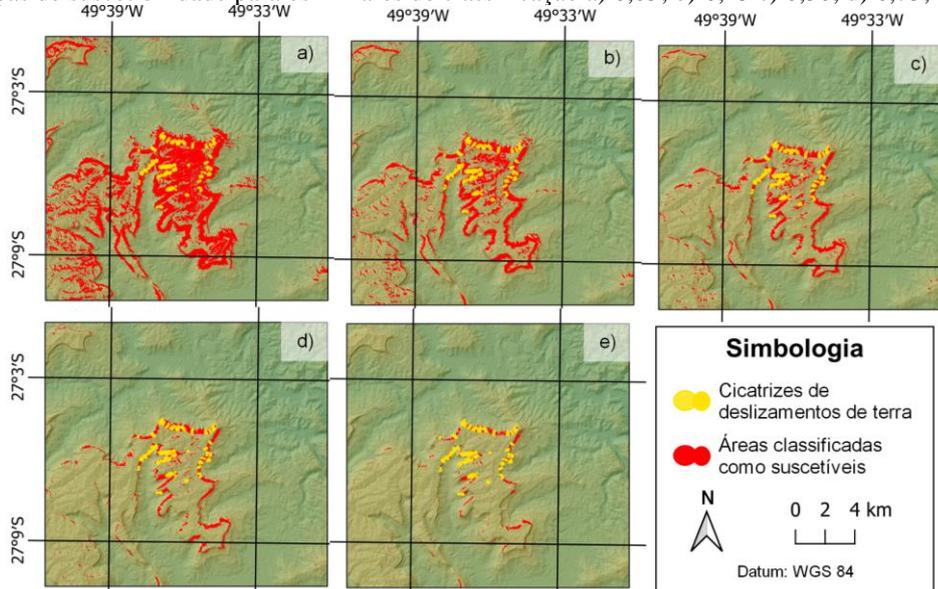


Tabela 1 – Taxa de acertos, sensibilidade e especificidade para cinco limiares selecionados.

Limiar	Taxa de acertos	Sensibilidade	Especificidade
0,05	90,74%	0,9918	0,8230
0,25	93,44%	0,9835	0,8853
0,50	94,12%	0,9643	0,9182
0,75	92,95%	0,9144	0,9445
0,95	84,57%	0,7198	0,9715

6. CONCLUSÃO

Apresentamos o mapeamento de suscetibilidade em parte dos municípios de Presidente Getúlio, de Rio do Sul e de Ibirama, realizado por meio de um *ensemble* de Redes Neurais Artificiais desenvolvidas e treinadas com o método de validação cruzada. Considera-se, baseado nas métricas obtidas e mapas gerados, que o modelo obteve bom desempenho. Ao ser comparado com outros mapas com funções e objetivos semelhantes, realizados independentemente do presente trabalho, os mapeamentos respaldam-se mutuamente ao apontarem muitas áreas em comum como suscetíveis.

Demonstra-se também a possibilidade de utilização de diferentes limiares para realizar a classificação do mapa final. Com ajustes nos limiares, pode-se obter mapas com maior sensibilidade, ou com maior especificidade, mas com prejuízos à métrica concorrente e à taxa de acertos global. Portanto, ao se ajustar o limiar de classificação, deve-se considerar também os efeitos consequentes apresentados, de forma que cada escolha tem suas implicações em um *trade off* a ser considerado pelos futuros gestores.

Os resultados obtidos demonstram que modelos de RNAs baseados em dados provenientes de Sensoriamento Remoto podem ser utilizados na área estudada como fonte de mapeamentos de suscetibilidade, obtendo-se resultados satisfatórios e condizentes com mapas gerados baseados em outras fontes de dados e metodologias. Assim, reafirma-se a opção de metodologias de Aprendizagem de Máquina como ferramentas eficazes para geração de mapeamentos de suscetibilidade a deslizamentos de terra e espera-se que, no futuro, este tipo de metodologia possa integrar práticas comuns para esta finalidade.

REFERÊNCIAS

- BRAGAGNOLO, L.; SILVA, R. V.; GRZYBOWSKI, J. M. V. (2020). “*Artificial neural network ensembles applied to the mapping of landslide susceptibility.*” *Catena*, 184, 104240.
- BRENNING, A. (2005). “*Spatial prediction models for landslide hazards: review, comparison and evaluation*” *Nat. Hazards Earth Syst. Sci.*, 5, pp. 853–862,
- DOU, J.; YAMAGISHI, H.; POURGHASEMI, H. R.; YUNUS, A. P.; SONG, X.; XU, Y.; ZHU, Z. (2015). “*An integrated artificial neural network model for the landslide susceptibility assessment of Osado Island, Japan*”. *Natural Hazards*, 78(3), 1749–1776.
- DOU, J.; YUNUS, A. P.; TIEN BUI, D.; SAHANA, M.; CHEN, C.W.; ZHU, Z.; WANG, W.; PHAM, B. T. (2019). “*Evaluating GIS-Based Multiple Statistical Models and Data Mining for Earthquake and Rainfall-Induced Landslide Susceptibility Using the LiDAR DEM.*” *Remote Sensing*, 11(6), pp. 638.

- GHESHLAGHI, H.; FEIZIZADEH, B. (2021). “GIS-based ensemble modelling of fuzzy system and bivariate statistics as a tool to improve the accuracy of landslide susceptibility mapping.” *Natural Hazards* 107, pp. 1981-2014
- GODOY J.V.; BIEHL A.; MELO C.M.; MICHEL G.P. (2018) “Implementação do modelo SHALSTAB em ferramentas para ArcGis e Qgis” in *Anais do Encontro Nacional de Desastres*, Porto Alegre, Jul. 2018.
- GOETZ, J. N.; BRENNING, A.; PETSCHKO, H.; LEOPOLD, P. (2015). “Evaluating machine learning and statistical prediction techniques for landslide susceptibility modeling”. *Computers and Geosciences*, 81, pp. 1–11.
- LECLERC, J.; JOSLYN, S. (2015). “The cry wolf effect and weather-related decision making”. *Risk Analysis*, 35(3), pp. 385–395.
- LUCCHESI, L. V.; DE OLIVEIRA, G. G.; PEDROLLO, O. C. (2020a). “Attribute selection using correlations and principal components for artificial neural networks employment for landslide susceptibility assessment”. *Environmental Monitoring and Assessment*, 192(2), pp. 129.
- LUCCHESI, L. V.; DE OLIVEIRA, G. G.; PEDROLLO, O. C. (2020b). “Investigation of the influence of nonoccurrence sampling on Landslide Susceptibility Assessment using Artificial Neural Networks.” *Catena* 198, 105067.
- LUCCHESI, L.V.; DE OLIVEIRA, G. G.; PEDROLLO, O. C. (2021). “Mamdani fuzzy inference systems and artificial neural networks for landslide susceptibility mapping”. *Natural Hazards* 106, pp. 2381–2405.
- MICHEL, G. P. (2013) *Modelagem de estabilidade de encostas com consideração do efeito da vegetação*. Departamento de Engenharia Sanitária e Ambiental, Universidade Federal de Santa Catarina. 152p.
- MICHEL, G.P.; SCHWARZ, H.; ABATTI, B.H.; PAUL, L.R.; SILVA, M.A.; ZANANDREA, F.; SALVADOR, C.G.; CENSI, G.; BIEHL, A.; KOBAYAMA, M. (2021) *Relatório técnico dos desastres de dezembro de 2020 nos municípios de Presidente Getúlio, Ibirama e Rio do Sul -SC*. GPDEN/IPH/UFRGS, 53 p.
- MINSKY, M. (1961). “Steps Toward Artificial Intelligence.” *Proceedings of the Institute of Radio Engineers*. 49 (1), pp. 8-30.
- MONTGOMERY, D. R.; DIETRICH, W. E. (1994) “A physically based model for the topographic control on shallow landsliding”. *Water Resources Research*, 30 (4), pp. 1153-1171

- MURPHY, K. P. (2012). *Machine Learning A Probabilistic Perspective*. Massachusetts Institute of Technology. 1067p.
- NEUHÄUSER, B.; TERHORST, B. (2007). “Landslide susceptibility assessment using “weights-of-evidence” applied to a study area at the Jurassic escarpment (SW-Germany).” *Geomorphology*, 86(1–2), pp. 12–24.
- NHU, V. H.; SHIRZADI, A.; SHAHABI, H.; CHEN, W.; CLAGUE, J. J.; GEERTSEMA, M.; JAAFARI, A.; AVAND, M.; MIRAKI, S.; TALEBPOUR, D.; PHAM, B. T.; AHMAD, B. B.; LEE, S. (2020). “Shallow Landslide Susceptibility Mapping by Random Forest Base Classifier and Its Ensembles in a Semi-Arid Region of Iran.” *Forests*, 11(4), pp. 421.
- 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, pp. 1049–1073
- OLIVEIRA, G. G.; GUASELLI, L. A.; QUEVEDO, R. P.; RUIZ, L. F. C.; BRESSANI, L. A.; RIFFEL, E. S. (2018). “Identificação e análise de áreas suscetíveis a fluxos de detritos na bacia hidrográfica do Rio Taquari-Antas, RS”. *Pesquisas Em Geociências (Online)*, 45, pp. 1–25.
- PETSCHKO, H.; BRENNING, A.; BELL, R.; GOETZ, J.; GLADE, T. (2014). “Assessing the quality of landslide susceptibility maps - Case study Lower Austria.” *Natural Hazards and Earth System Sciences*, 14(1), pp. 95–118.
- SERVIÇO GEOLÓGICO DO BRASIL – SGB - CPRM (2019) *Cartas de Suscetibilidade a Movimentos Gravitacionais de Massa e Inundações*. Disponível em <http://geoportal.cprm.gov.br>
- VOGL, T. P.; MANGIS, J. K.; RIGLER, A. K.; ZINK, W. T.; ALKON, D. L. (1988). “Accelerating the convergence of the back-propagation method”. *Biological Cybernetics*, 59(4–5), pp. 257–263.
- XIAO, T.; YIN, K.; YAO, T.; LIU, S. (2019). “Spatial prediction of landslide susceptibility using GIS-based statistical and machine learning models in Wanzhou County, Three Gorges Reservoir, China”. *Acta Geochimica*, 38(5), pp. 654–669.

AGRADECIMENTOS

Este trabalho foi realizado com o apoio do Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq.