



Mapeamento da suscetibilidade a deslizamentos com Redes Neurais Artificiais a partir do módulo gratuito e de código aberto *r. landslide*

Lucimara Bragagnolo

Universidade Federal da Fronteira Sul, Erechim, Brasil, e-mail: lucimarabragagnolo@hotmail.com

Roberto Valmir da Silva

Universidade Federal da Fronteira Sul, Erechim, Brasil, e-mail: roberto.silva@uffs.edu.br

José Mario Vicensi Grzybowski

Universidade Federal da Fronteira Sul, Erechim, Brasil, e-mail: jose.grzybowski@uffs.edu.br

RESUMO: Este estudo tem por objetivo apresentar a funcionalidade do módulo para GRASS GIS livre e de código aberto *r. landslide* para o mapeamento da suscetibilidade a deslizamentos a partir do emprego de Redes Neurais Artificiais (RNAs). A identificação de áreas suscetíveis é dada com base em inventários de localização de eventos de deslizamento e não deslizamento e informações de fatores ambientais condicionantes. De forma a exemplificar a aplicação da ferramenta, apresentou-se um estudo de caso para a cidade de Porto Alegre. O mapa obtido a partir do módulo foi comparado com o mapa de suscetibilidade elaborado pelo Serviço Geológico do Brasil (CPRM). A RNA resultou em uma acurácia de 93,3% e o mapa gerado apresentou alto grau de concordância qualitativa e quantitativa com relação ao o mapa produzido pelo CPRM. Dessa forma, o módulo *r. landslide* pode ser considerado potencialmente útil como ferramenta de auxílio a profissionais responsáveis pela execução de estudos de gestão de riscos e mapeamento de suscetibilidade.

PALAVRAS-CHAVE: Sistemas de Informações Geográficas, Desastres Naturais, Análise de Sensibilidade.

1 INTRODUÇÃO

Deslizamentos de terra são eventos geológicos que comumente resultam em danos materiais, econômicos, sociais e ao meio ambiente. Suas consequências são acentuadas devido à crescente densidade demográfica verificada em regiões suscetíveis, à falta de planejamento adequado, e à escassez e ineficácia de medidas de prevenção e evacuação. A aplicabilidade de tais medidas pode ser melhorada quando baseada em critérios técnicos objetivos, dentre os quais destacam-se os mapeamentos de suscetibilidade a deslizamentos. No Brasil, a

fração do território que possui mapeamento de suscetibilidade é extremamente baixa, sendo o processo dificultado por limitações técnicas e de infraestrutura dos órgãos responsáveis pela gestão de riscos de desastres. Outra limitação refere-se às metodologias tradicionalmente aplicadas, como a demora na geração de resultados e, em alguns casos, alto nível de especificidade, exigindo um grau de conhecimento técnico elevado e, portanto, limitando sua aplicabilidade a centros de pesquisa, por exemplo.

Nesse contexto, o desenvolvimento de metodologias e de ferramentas que possibilitem



e facilitem a identificação de áreas suscetíveis a deslizamentos de modo eficiente e econômico é imprescindível, permitindo, assim, que as agências do governo e órgãos de planejamento do uso do solo promovam, antecipadamente, ações de prevenção e mitigação de prováveis danos (Dang et al., 2018).

De acordo com a literatura, metodologias de mineração de dados e aprendizado de máquina são consideradas apropriadas para a aplicações em grandes áreas, e especialmente se as características a serem estudadas possuem relações complexas não lineares (Tien Bui et al., 2017; Tu, 1996), como é o caso da identificação de áreas suscetíveis a deslizamentos de terra. Além disso, esses algoritmos podem ser facilmente integrados em Sistemas de Informações Geográficas (SIGs) (Chen et al., 2019; Saito et al., 2009; Tien Bui et al., 2017).

Dentre as metodologias de aprendizado de máquina e que possuem a capacidade de integração com SIGs, destacam-se as Redes Neurais Artificiais (RNAs). Uma RNA é composta por conjuntos de neurônios e de elementos de processamento interconectados. As RNAs utilizam algoritmos de aprendizado para extrair padrões de conhecimento e salvá-los em conexões ponderadas, que imita a função de um cérebro humano (Haykin, 1999; Pradhan and Lee, 2010). Eles são considerados algoritmos heurísticos no sentido de que podem aprender com a experiência por meio de amostras e, posteriormente, são aplicados para reconhecer novos dados não vistos (Kavzoglu and Mather, 2000; Zare et al., 2013).

Diferentes estudos já avaliaram a aplicação de RNAs para a identificação de áreas suscetíveis a deslizamentos, obtendo resultados satisfatórios (Biswajeet and Saro, 2007; Ermini et al., 2005; Gómez and Kavzoglu, 2005; Lee et al., 2004; Melchiorre et al., 2008; Neaupane and Achet, 2004; Pascale et al., 2013; Zare et al., 2013).

Diante disso, a partir do bom desempenho resultante da aplicação de RNAs para essa

finalidade e com a disponibilidade de softwares SIGs de código aberto, torna-se interessante a integração dessas duas ferramentas para dar origem a um sistema de fácil manuseio e aplicação e que possibilite o acesso a essas tecnologias a um público mais amplo. Ainda, tal integração, em forma de pacotes SIGs, beneficia-se de uma série de ferramentas que facilitam a preparação dos dados de entrada e avaliação dos resultados, disponibilizadas por esses softwares (Beguiría et al., 2009). Em particular, entre os softwares SIGs de código aberto e livre existentes, a iniciativa GRASS GIS (Sistema de Suporte à Análise de Recursos Geográficos) tem recebido atenção considerável (Neteler et al., 2012).

O *software* GRASS GIS permite que módulos de código aberto sejam integrados com sua interface. O *software* conta com alguns módulos que trabalham com a perspectiva de deslizamentos (Beguiría et al., 2009; Filipello and Strigaro, 2017; Mergili et al., 2017; Molinari et al., 2014). Contudo, ainda não há módulos disponíveis que integrem a metodologia de redes neurais artificiais com o *software* GRASS GIS para a avaliação de áreas suscetíveis a deslizamentos. No caso do módulo a ser apresentado neste estudo, as informações requeridas podem ser facilmente obtidas a partir de bancos de dados disponíveis gratuitamente.

Ainda, embora alguns módulos citados trabalhem com a identificação da probabilidade de deslizamentos e análise de estabilidade de encostas, muitos deles exigem uma série de parâmetros específicos de entrada, que necessitam de levantamentos mais criteriosos das características das áreas de estudo e, que, em certos casos, acabam sendo generalizados ou estimados a partir de equações empíricas. Esse fato pode, também, acabar sendo um fator limitante para o estudo de regiões mais extensas.

Nesse contexto, neste artigo apresenta-se o módulo *r. landslide* para o *software* GRASS GIS. O módulo implementa o método de redes



neurais artificiais (RNAs) para a identificação de áreas suscetíveis a deslizamentos a partir da localização de pontos de deslizamentos e não deslizamentos e de parâmetros ambientais inseridos como mapas rasters. O módulo foi desenvolvido em linguagem Python utilizando as bibliotecas do *software* GRASS GIS, seguindo o ideal de código aberto do software. Após apresentar e descrever a funcionalidade e operação do módulo, foi apresentado um estudo de caso para a cidade de Porto Alegre, capital do Estado do Rio Grande do Sul, localizada no Sul do Brasil. A partir disso, foi possível realizar o levantamento de áreas suscetíveis a deslizamentos nessa região com alto grau de conformidade com o mapa previamente elaborado pelo Serviço Geológico do Brasil (CPRM).

2 METODOLOGIA

O módulo para o *software* GRASS GIS foi desenvolvido em linguagem Python e implementa o algoritmo de Redes Neurais Artificiais baseado no perceptron de múltiplas camadas (MLPs). A seguir, é brevemente apresentado o princípio de funcionamento de uma RNA e a descrição do funcionamento da respectiva ferramenta.

2.1 Redes neurais artificiais

Uma rede neural é um processador massivamente paralelo distribuído, constituído por unidades de processamento simples, que tem uma propensão natural para armazenar conhecimento experimental e disponibilizá-lo para uso. Seu funcionamento assemelha-se ao cérebro humano em dois aspectos principais: o conhecimento é adquirido pela rede neural a partir do ambiente através de um processo de aprendizado e as forças de conexão interneurônica, conhecidas como pesos sinápticos, são usadas para armazenar o

conhecimento adquirido (Haykin, 1999).

A estrutura da RNA baseada no perceptron de múltiplas camadas implementada é constituída por três camadas de neurônios: (a) camada de entrada: em que insere-se os parâmetros temáticos ambientais, utilizados para extrair as relações e padrões existentes entre eles e os locais de ocorrência de deslizamentos; (b) camada de neurônios intermediários; e (c) camada de neurônios de saída: onde, para este estudo, é apresentado o resultado final de suscetibilidade para cada pixel que engloba a área de estudo, variando de 0 (baixa suscetibilidade) a 1 (alta suscetibilidade). A Figura 1 esquematiza a estrutura de uma RNA e exemplifica parâmetros temáticos ambientais que podem ser utilizados para o estudo e mapeamento da suscetibilidade a deslizamentos.

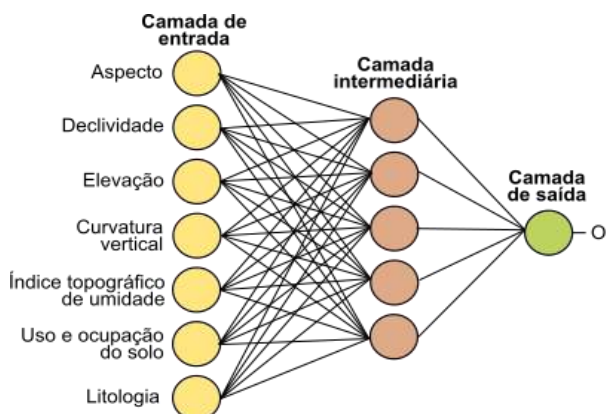


Figura 1. Arquitetura de uma RNA individual 7-5-1 (sete parâmetros de entrada, cinco neurônios na camada intermediária e um neurônio de resposta). Linhas pretas representam pesos sinápticos.

Para que a RNA possa ser aplicada para determinada região de interesse, é necessário que ela passe por uma etapa de treinamento, em que os valores dos pesos sinápticos são ajustados até atingirem um nível de aprendizado em que a RNA torna-se capaz de generalizar de forma satisfatória. Para tanto, implementou-se o algoritmo de retropropagação, que utiliza o método do gradiente descendente para atualização desses valores (Haykin, 1999). Ainda, nessa etapa, o conjunto de informações utilizado para



o aprendizado da RNA é dividido em três conjuntos: de treinamento, validação e teste. Os dois últimos são utilizados, essencialmente, para a avaliação da capacidade de generalização da rede após ela ser treinada com as informações do primeiro.

2.2 Descrição do módulo

O princípio de funcionamento do módulo baseia-se na inserção de mapas *rasters* que representam variáveis temáticas ambientais que exerçam influência sobre o desencadeamento de deslizamentos, bem como na adição de camadas vetoriais de pontos que representem locais em que houve a ocorrência e não-ocorrência desses eventos geológicos.

Mapas temáticos podem ser facilmente obtidos em bancos de dados abertos, disponíveis em órgãos públicos, como Instituto Brasileiro de Geografia e Estatística (IBGE), Instituto Nacional de Pesquisas Espaciais (INPE) e Ministério do Meio Ambiente (MMA), bem como podem ser gerados com o auxílio de ferramentas SIG.

A localização de pontos de deslizamentos pode ser adquirida em bancos de dados disponibilizados por órgãos responsáveis no gerenciamento de tais eventos, como Defesas Civis das respectivas regiões de interesse ou, ainda, por meio de identificação através de imagens aéreas. Já os pontos vetoriais de não deslizamento podem ser obtidos de forma aleatória e devem estar dispostos em áreas em que não houve registros desses eventos.

A partir da importação dos dados para o *software* GRASS GIS e inserção dessas informações no módulo, o usuário deve, então, configurar os parâmetros de construção da arquitetura da RNA (Quadro 1).

Quadro 1. Informações requeridas para treinamento da RNA, na aba *ANN parameters*.

Parâmetro	Informações
Número de neurônios da	Deve variar de 2 a x . Número máximo pode ser estimado a partir da equação

camada intermediária	$N_H \leq 2N_I + 1$ (N_H : número máx. de neurônios; N_I : número de parâmetros de entrada). (Padrão: 12)
Taxa de aprendizado	Varia de 0 a 1. É um hiper-parâmetro que controla o quanto os pesos da RNA são ajustados com relação ao gradiente de perda. (Padrão: 0,6)
Número de épocas	Número de vezes que todos os vetores de treinamento são usados uma vez para atualizar os pesos. (Padrão: 200)
Percentual de dados para validação/teste	Varia de 0 a 1. Define a quantidade de dados que serão destinados para validação e teste da RNA. (Padrão: 0,15 para cada conjunto)
Número mínimo de neurônios na camada intermediária [batch mode]*	Padrão: 2
Número máximo de neurônios na camada intermediária [batch mode]*	Se nulo, o número máximo de neurônios será calculado com base na equação $N_H \leq 2N_I + 1$ (N_H : número máx. de neurônios; N_I : número de parâmetros de entrada). (Padrão: 12)
Número de condições iniciais [batch mode]*	Quantidade de conjuntos de pesos sinápticos a serem inicializados. (Padrão: 1)

*batch mode: essa opção permite que o usuário treine diferentes arquiteturas de RNAs. A melhor rede será selecionada para prosseguir com o processo de geração do mapa de suscetibilidade para a área de interesse.

Após a fase de treinamento, o módulo ainda realiza a análise da sensibilidade das variáveis de entrada utilizadas, permitindo que o usuário identifique quais deles exerceram maior influência sobre o cálculo do grau de suscetibilidade. Para tanto, cada uma das variáveis de entrada é selecionada e perturbada enquanto as demais são mantidas constantes com seu valores médios.

2.3 Estudo de caso

2.3.1 Caracterização da área de estudo

A cidade de Porto Alegre, capital do Estado do Rio Grande do Sul, possui uma área total de 496,682 km², população de 1.409.351



habitantes e uma densidade populacional de 2.837,53 hab./km², de acordo com o censo de 2010 (IBGE. Instituto Brasileiro de Geografia e Estatística, 2017). Está a uma altitude média de 10 m acima do nível médio do mar, porém apresenta regiões com altitudes maiores que 245 m. Ainda, possui declividades variando de 0,19 a 61,72%. O regime de chuvas é considerado como bem distribuído ao longo do ano com média anual de 1.425 mm (INMET. Instituto Nacional de Meteorologia, n.d.). De acordo com De Aguiar and Hackbart (2008), houve diversos registros com precipitação acumulada superiores a 50 mm em menos de um hora em localidades do município. Ainda, entre os anos de 2005 e 2007, observaram-se intensidades de 100 mm/h. Episódios de chuva com tais características favorecem o desencadeamento de movimentos de massa e, por conta disso, torna-se imprescindível a determinação de áreas que sejam suscetíveis a esses eventos.

Quanto às características geológicas, as unidades litológicas prevalentes são os depósitos eluviais e coluviais, depósitos aluvionares, Suíte Dom Feliciano e Fácies Serra do Herval. Os depósitos eluviais e coluviais caracterizam-se por depósitos quartzo-arenosos com granulometria heterogênea, amarelo-acastanhadas, subarredondadas e arredondadas. Normalmente ocorrem em regiões de alta elevação. Por sua vez, os depósitos aluvionares são sedimentos aluvionares não consolidados e constituídos por seixos, areias de granulometria fina a grossa, com percentual de cascalhos, material silto-argiloso e material orgânico. Estão relacionados com planícies de inundação, margens, barras de canal e canais fluviais. A unidade litológica de Dom Feliciano é caracterizada por metagranitoides porfíricos e granitos. Por fim, Fácies Serra do Herval é composta por sienogranitos equigranular médio a grosso, composto, de forma predominante, por k-feldspato (CPRM. Companhia de Pesquisa de Recursos Minerais, n.d.). A presença de

diversas unidades litológicas é indicativo de uma diversidade geomorfológica da área, o que induz a processos de movimentos de massa a partir de diferentes fatores.

No que se refere aos sistemas existentes para a prevenção de problemas oriundos de deslizamentos, o Serviço Geológico do Brasil desenvolveu, a partir de estudos realizados por especialistas da área, uma carta de suscetibilidade a movimentos de massa e a inundações, envolvendo todo o município de Porto Alegre (CPRM. Companhia de Pesquisa de Recursos Minerais, 2015). Os resultados da presente pesquisa foram comparados com a referida carta, com o objetivo de validar a metodologia proposta.

Ainda, Porto Alegre conta com o Programa de Fiscalização e Monitoramento Urbano Ambiental, estabelecido pelo Decreto nº 16.931/2011 (Porto Alegre, 2011). O Programa possui como finalidade o monitoramento de regiões do município de forma a evitar que sejam realizadas construções em áreas suscetíveis a deslizamentos.

2.3.2 Mapeamento da suscetibilidade a partir do módulo *r.landslide*

O mapeamento da suscetibilidade do município de Porto Alegre foi realizado com o objetivo de demonstrar a funcionalidade do módulo *r.landslide*.

A localização de eventos de deslizamentos ocorridos na cidade foram retirados do estudo realizado por Brito (2014). Já a localização dos pontos de não deslizamento foram gerados de forma aleatória com o auxílio do *software* GRASS GIS. A partir dessas informações, um banco de dados de treinamento contendo 50 registros de deslizamento e 50 registros de não-deslizamento foi produzido. O restante dos pontos de deslizamento foram utilizados para realizar a comparação entre o mapa gerado pelo módulo e o elaborado pelo CPRM (CPRM. Companhia de Pesquisa de Recursos Minerais,



2015).

Foram considerados como variáveis de entrada 7 parâmetros temáticos ambientais: aspecto, elevação, uso do solo, litologia, curvatura vertical, declividade e índice topográfico de umidade. Os mapas de aspecto, elevação, curvatura e declividade foram obtidos em formato matricial através do projeto TOPODATA (INPE. Instituto de Pesquisas Espaciais, 2008), com resolução espacial de 30 m. Já o mapa do índice topográfico de umidade foi obtido a partir do mapa de elevação, com auxílio do módulo *r.topidx*, do software GRASS GIS.

As informações de uso do solo foram extraídas em formato vetorial do Diagnóstico Ambiental do Município de Porto Alegre (Hasenack et al., 2008) e posteriormente convertidas em *raster* para possibilitar sua inserção no módulo. Por fim, camadas vetoriais foram extraídas para o parâmetro litologia a partir do banco de informações do Serviço Geológico do Brasil (CPRM. Companhia de Pesquisa de Recursos Minerais, n.d.).

Após a importação das informações de deslizamento e não-deslizamento, e dos mapas matriciais dos parâmetros ambientais da cidade de Porto Alegre para o software GRASS GIS, utilizou-se o módulo *r.landslide* para produção do mapa de suscetibilidade. Os parâmetros da RNA utilizados foram os valores pré-especificados pela ferramenta, conforme apresentado no Quadro 1.

3 RESULTADOS E DISCUSSÃO

3.1 Treinamento

Na etapa de treinamento, a rede obteve uma acurácia de 93,3%, com apenas uma ocorrência de um falso-negativo para o conjunto de teste (15 registros). Isso demonstra que a rede foi capaz de generalizar os padrões existentes no conjunto de treinamento para outro conjunto de

registros não vistos anteriormente por ela.

Quanto à análise de sensibilidade, as variáveis temáticas que exerceram maior influência sobre a ocorrência de deslizamentos foram, em ordem decrescente de importância: declividade, índice topográfico de umidade, uso do solo, e elevação (Tabela 1).

Tabela 1. Análise da sensibilidade para os parâmetros de entrada para o estudo de casa de Porto Alegre.

Parâmetro	Varição da saída
Declividade	1,00
Índice topográfico de umidade	0,98
Uso do solo	0,97
Elevação	0,93
Curvatura vertical	0,64
Litologia	0,52
Aspecto	0,27

3.2 Mapa de suscetibilidade

A Figura 2 apresenta o mapa de suscetibilidade gerado a partir do módulo *r.landslide*, comparado com o mapa elaborado pelo CPRM (CPRM. Companhia de Pesquisa de Recursos Minerais, 2015). Pode-se observar um alto nível de concordância quantitativa e qualitativa, além de melhores resultados quando avalia-se a localização dos pontos de deslizamento para cada uma das classes (baixa, média e alta suscetibilidade), conforme a Figura 2 e Tabela 2.

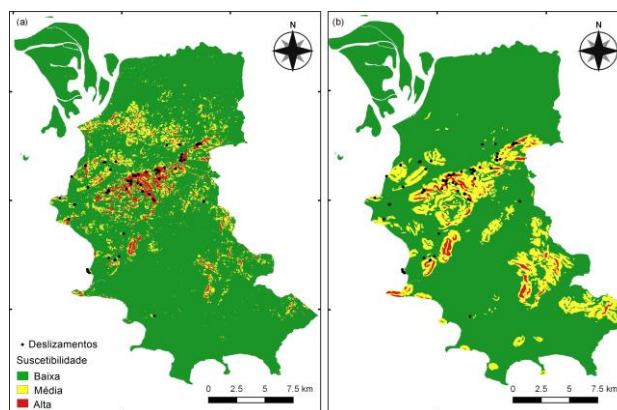


Figura 2. Mapa de suscetibilidade (a) gerado pelo módulo *r.landslide* e (b) elaborado pelo CPRM. Pontos em preto representam a localização de deslizamentos que não foram utilizados durante a etapa de treinamento da RNA.



Tabela 2. Distribuição dos pontos de deslizamentos não-vistos pelas RNA (69) entre as classes de baixa, média e alta de suscetibilidade

	RNA	CPRM
Baixa	8	12
Média	18	38
Alta	43	19

O mapa de suscetibilidade produzido pela RNA apresenta um maior número de deslizamentos localizados na classe alta (43) quando comparado com a localização desses mesmos registros no mapa elaborado pelo CPRM (19), que concentrou a maioria dos pontos em classe média de suscetibilidade (38).

3.3 Deslizamentos e fatores condicionantes

A Figura 3 apresenta como os fatores condicionantes estão distribuídos entre as classes de alta, média e baixa suscetibilidade de acordo com o mapa produzido pelo módulo *r.landslide* para o município de Porto Alegre.

Considerando os parâmetros de maior influência sobre a ocorrência de deslizamentos conforme os resultados da análise da sensibilidade (Tabela 1), pode-se constatar que as áreas de alta suscetibilidade localizam-se em áreas de maior declividade, especialmente entre 12,58% e 25,16%; regiões com índice de topográfico de umidade dentro da faixa de 3,68 a 6,71; altitudes de 87,88 m a 133,09 m e em áreas residenciais. As áreas de alta suscetibilidade também ficaram localizadas, em sua maioria, na unidade litológica de Fácies Serra do Herval, em curvaturas côncavas e em encostas orientadas para Noroeste.

De acordo com de Brito et al. (2016), a declividade é o principal fator que influencia no desencadeamento de deslizamentos em Porto Alegre, uma vez que esse fator condicionante é diretamente proporcional à velocidade do movimento e, desse modo, proporcional à capacidade de transporte de solo (Dias and Herrmann, 2002; Gómez and Kavzoglu, 2005).

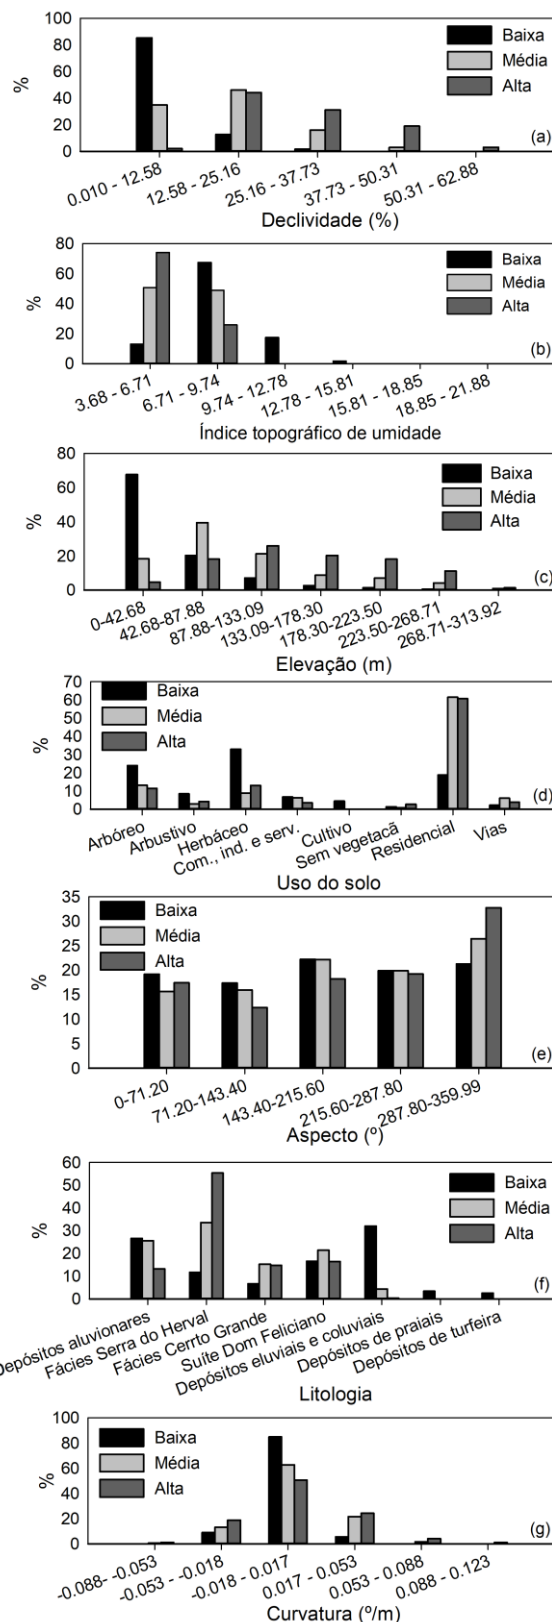


Figura 3. Distribuição dos fatores condicionantes entre as baixa, média e alta para o mapa de suscetibilidade de Porto Alegre produzido pelo módulo *r.landslide*



No que se refere ao índice topográfico de umidade, os resultados obtidos assemelham-se com os de outros estudos (Hong et al., 2015; Pourghasemi et al., 2012), em que há maior frequência de deslizamentos para as classes mais baixas de valores desse índice.

Referente à elevação, outro parâmetro considerado de influência (Tabela 1), constatou-se que áreas de maior altitude apresentam maior suscetibilidade. Contudo, para alguns autores, a relação existente entre elevação e ocorrência de deslizamento ainda não é considerada clara (Gómez and Kavzoglu, 2005). Porém, esse fator exerce influência sobre outros parâmetros biofísicos, bem como sobre as atividades antropogênicas, que podem, então, afetar a estabilidade de encostas. Tal fato ainda pode estar correlacionado ao uso e ocupação do solo da região, em que as ocupações e interferências antrópicas ocorrem até determinadas altitudes, por exemplo. A elevada suscetibilidade em áreas classificadas como residenciais mostra-se como uma evidência dessa relação.

Em se tratando do parâmetro aspecto, pode-se considerar que sua relação com eventos de deslizamento é similar com o que foi discutido acerca da elevação como parâmetro que exerce influência sobre características secundárias, ou seja, sua conformação desencadeia outros fatores que podem afetar a estabilidade geotécnica de um local. Diferentes orientações de encostas recebem, por exemplo, diferentes características climáticas, como direção do vento, radiação solar e quantidade de precipitação, resultando em distintos graus de intemperismo. Contudo, por meio da análise de sensibilidade, constatou-se que esse fator não exerce grande influência sobre os deslizamentos dessa região.

Quanto à litologia, aproximadamente 60% das áreas de alta suscetibilidade localizaram-se na Fácies Serra do Herval. Essa unidade litológica apresenta características graníticas e zonas de falha com rochas bastante fraturadas e camadas rasas de regolitos, o que favorece a

ocorrência de deslizamentos a partir de diferenças bruscas de condutividade hidráulica, o que dificulta o fluxo vertical de água. Isso favorece a saturação do solo, resultando no aumento da poropressão positiva e redução do fator de segurança da encosta (de Brito et al., 2016; Fernandes et al., 2001).

Por fim, áreas de maior suscetibilidade ficaram localizadas em regiões com curvatura vertical côncava, o que corrobora com Chen et al. (2017), que coloca que é esperado que deslizamentos de terra ocorram em encostas com curvatura côncava, uma vez que essa característica é capaz de resultar na sobrecarga de uma inclinação por meio do volume de água concentrada e da tensão de cisalhamento resultante.

4 CONSIDERAÇÕES FINAIS

Neste estudo apresentou-se a funcionalidade e aplicação do módulo gratuito e de código aberto para GRASS GIS *r.landslide* para a identificação de áreas suscetíveis a deslizamentos a partir de Redes Neurais Artificiais.

A partir do estudo de caso para a cidade de Porto Alegre, pode-se verificar que a ferramenta é capaz de obter resultados satisfatórios, gerando mapas de suscetibilidade com alto grau de confiabilidade, sendo considerada potencialmente útil como ferramenta de auxílio a profissionais responsáveis pela execução de estudos de gestão de riscos e mapeamento de suscetibilidade.

O código para o módulo pode ser baixado gratuitamente em <https://github.com/UFFSEnvModelling/r.landslide> (Bragagnolo et al., 2019).

REFERÊNCIAS

De Aguiar, A.A., and Hackbart, E. (2008) Primeira metade do século XX teve anos muito secos,



- MetSul Meteorologia.
- Beguería, S., W. J. Van Asch, T., Malet, J.P., and Gröndahl, S. (2009) A GIS-based numerical model for simulating the kinematics of mud and debris flows over complex terrain, *Natural Hazards and Earth System Science*, Vol. 9, n. 6, p. 1897–1909.
- Biswajeet, P., and Saro, L. (2007) Utilization of Optical Remote Sensing Data and GIS Tools for Regional Landslide Hazard Analysis Using an Artificial Neural Network Model, *Earth Science Frontiers*, Vol. 14, n. 6, p. 143–151.
- Bragagnolo, L., da Silva, R.V., and Grzybowski, J.M. (2019) r Landslide, *GitHub repository*.
- Brito, M.M. de. (2014) Geoprocessamento aplicado ao mapeamento da suscetibilidade a escorregamentos no município de Porto Alegre, RS, Universidade Federal do Rio Grande do Sul.
- de Brito, M.M., Weber, E.J., Krigger, V.S., and Leitzke, F.P. (2016) Análise dos fatores condicionantes de movimentos de massa no município de Porto Alegre a partir de registros históricos, *Revista Brasileira de Cartografia*, Vol. 68, n. 1, p. 1853–1872.
- Chen, W., Panahi, M., Tsangaratos, P., Shahabi, H., Ilia, I., Panahi, S., Li, S., Jaafari, A., and Ahmad, B. Bin. (2019) Applying population-based evolutionary algorithms and a neuro-fuzzy system for modeling landslide susceptibility, *Catena*, Elsevier, Vol. 172, n. August 2018, p. 212–231.
- Chen, W., Reza, H., Kornejady, A., and Zhang, N. (2017) Landslide spatial modeling: Introducing new ensembles of ANN, MaxEnt, and SVM machine learning techniques, *Geoderma*, Elsevier, Vol. 305, n. May, p. 314–327.
- CPRM. Companhia de Pesquisa de Recursos Minerais. (n.d.). GeoSGB. Unidades litoestratigráficas.
- CPRM. Companhia de Pesquisa de Recursos Minerais. (2015) Carta de suscetibilidade a movimentos gravitacionais de massa e inundações. Município de Porto Alegre - RS., <<http://rigeo.cprm.gov.br/xmlui/bitstream/handle/doc/15106/CS-PortoAlegre.pdf?sequence=1>>.
- Dang, V.H., Dieu, T.B., Tran, X.L., and Hoang, N.D. (2018) Enhancing the accuracy of rainfall-induced landslide prediction along mountain roads with a GIS-based random forest classifier, *Bulletin of Engineering Geology and the Environment*, Bulletin of Engineering Geology and the Environment, p. 1–15.
- Dias, F.P., and Herrmann, M.L. de P. (2002) Suscetibilidade a Deslizamentos: Estudo de Caso no Bairro Saco Grande, Florianópolis-SC, *Caminhos de Geografia*, Vol. 3, n. 6, p. 57–73.
- Ermini, L., Catani, F., and Casagli, N. (2005) Artificial Neural Networks applied to landslide susceptibility assessment, *Geomorphology*, n. 66, p. 327–343.
- Fernandes, N.F., Guimarães, R.F., Gomes, R.A.T., Vieira, B.C., Montgomery, D.R., and Greenberg, H. (2001) Condicionantes Geomorfológicos dos Deslizamentos nas Encostas: Avaliação de Metodologias e Aplicação de Modelo de Previsão de Áreas Susceptíveis, *Revista Brasileira de Geomorfologia*, Vol. 2, n. 1.
- Filipello, A., and Strigaro, D. (2017) Addon r.shalstab - A Model for Shallow Landslide Susceptibility, *GRASS GIS Manual, Open Source Geospatial Foundation*, <<https://grass.osgeo.org/grass74/manuals/addons/r.shalstab.html>> (Nov. 23, 2018).
- Gómez, H., and Kavzoglu, T. (2005) Assessment of shallow landslide susceptibility using artificial neural networks in Jabonosa River Basin, Venezuela, *Engineering Geology*, Vol. 78, n. 1–2, p. 11–27.
- Hasenack, H., Weber, E., and Marcuzzo, S. (2008) *Diagnóstico Ambiental de Porto Alegre: Geologia, Solos, Drenagem, Vegetação e Ocupação*, Secretaria Municipal do Meio Ambiente, 2008, Porto Alegre.
- Haykin, S. (1999) *Neural Networks: A Comprehensive Foundation*, Prentice-Hall, Inc., New Jersey.
- Hong, H., Pradhan, B., Xu, C., and Tien Bui, D. (2015) Spatial prediction of landslide hazard at the Yihuang area (China) using two-class kernel logistic regression, alternating decision tree and support vector machines, *Catena*, Elsevier B.V., Vol. 133, n. October, p. 266–281.
- IBGE. Instituto Brasileiro de Geografia e Estatística. (2017) Porto Alegre, *Brasil em Síntese*, <<https://cidades.ibge.gov.br/brasil/rs/porto-alegre/panorama>>.
- INMET. Instituto Nacional de Meteorologia. (n.d.). Normais climatológicas do Brasil, <<http://www.inmet.gov.br/portal/index.php?r=clima/normaisclimatologicas>> (May 3, 2018).
- INPE. Instituto de Pesquisas Espaciais. (2008) TOPODATA. Banco de dados geomorfométricos do Brasil, <<http://www.dsr.inpe.br/topodata/acesso.php>>.
- Kavzoglu, T., and Mather, P.M. (2000) Using feature selection techniques to produce smaller neural networks with better generalisation capabilities.
- Lee, S., Ryu, J.-H., Won, J.-S., and Park, H.-J. (2004) Determination and application of the weights for landslide susceptibility mapping using an artificial neural network, *Engineering Geology*, Vol. 71, n. 3–4, p. 289–302.
- Melchiorre, C., Matteucci, M., Azzoni, A., and Zanchi, A. (2008) Artificial neural networks and cluster analysis in landslide susceptibility zonation, *Geomorphology*, Vol. 94, p. 379–400.



- Mergili, M., Fischer, J.T., Krenn, J., and Pudasaini, S.P. (2017) R.avaflow v1, an advanced open-source computational framework for the propagation and interaction of two-phase mass flows, *Geoscientific Model Development*, Vol. 10, n. 2, p. 553–569.
- Molinari, M.E., Cannata, M., and Meisina, C. (2014) r.massmov: An open-source landslide model for dynamic early warning systems, *Natural Hazards*, Vol. 70, n. 2, p. 1153–1179.
- Neaupane, K.M., and Achet, S.H. (2004) Use of backpropagation neural network for landslide monitoring: A case study in the higher Himalaya, *Engineering Geology*, Vol. 74, n. 3–4, p. 213–226.
- Neteler, M., Bowman, M.H., Landa, M., and Metz, M. (2012) GRASS GIS: A multi-purpose open source GIS, *Environmental Modelling and Software*, Elsevier Ltd, Vol. 31, , p. 124–130.
- Pascale, S., Parisi, S., Mancini, A., Schiattarella, M., Conforti, M., Sole, A., Murgante, B., and Sdao, F. (2013) Landslide susceptibility mapping using artificial neural network in the urban area of Senise and San Costantino Albanese (Basilicata, Southern Italy), *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, Vol. 7974 LNCS, n. PART 4, p. 473–488.
- Porto Alegre. (2011) DECRETO Nº 16.931, de 26 janeiro de 2011. Institui o Programa de Fiscalização e Monitoramento Urbano Ambiental do Município de Porto alegre e revoga o Decreto nº 15.243, de 4 de julho de 2006.
- Pourghasemi, H.R., Mohammady, M., and Pradhan, B. (2012) Landslide susceptibility mapping using index of entropy and conditional probability models in GIS: Safarood Basin, Iran, *Catena*, Elsevier B.V., Vol. 97, , p. 71–84.
- Pradhan, B., and Lee, S. (2010) Landslide susceptibility assessment and factor effect analysis: backpropagation artificial neural networks and their comparison with frequency ratio and bivariate logistic regression modelling, *Environmental Modelling and Software*, Elsevier Ltd, Vol. 25, n. 6, p. 747–759.
- Saito, H., Nakayama, D., and Matsuyama, H. (2009) Comparison of landslide susceptibility based on a decision-tree model and actual landslide occurrence: The Akaishi Mountains, Japan, *Geomorphology*, Elsevier B.V., Vol. 109, n. 3–4, p. 108–121.
- Tien Bui, D., Tuan, T.A., Hoang, N.-D., Thanh, N.Q., Nguyen, D.B., Van Liem, N., and Pradhan, B. (2017) Spatial prediction of rainfall-induced landslides for the Lao Cai area (Vietnam) using a hybrid intelligent approach of least squares support vector machines inference model and artificial bee colony optimization, *Landslides*, Landslides, Vol. 14, n. 2, p. 447–458.
- Tu, J. V. (1996) Advantages and disadvantages of using artificial neural networks versus logistic regression for predicting medical outcomes, *Journal of Clinical Epidemiology*, Vol. 49, n. 11, p. 1225–1231.
- Zare, M., Pourghasemi, H.R., Vafakhah, M., and Pradhan, B. (2013) Landslide susceptibility mapping at Vaz Watershed (Iran) using an artificial neural network model: A comparison between multilayer perceptron (MLP) and radial basic function (RBF) algorithms, *Arabian Journal of Geosciences*, Vol. 6, n. 8, p. 2873–2888.