

UTILIZAÇÃO DE TÉCNICAS DE APRENDIZADO DE MÁQUINA NA ANÁLISE DE SUSCETIBILIDADE A DESLIZAMENTOS

Denise de Fátima Santos da Silva ¹; Maria Giovana Parisi ²; Allan Erlikhman Medeiros Santos ³

Resumo – Estudos referentes à avaliação da suscetibilidade para uma determinada área são uma importante ferramenta que servem de base de apoio na gestão e nas políticas de ordenamento territorial. A suscetibilidade a deslizamentos é comumente calculada a partir de áreas onde já ocorreram deslizamentos no passado, assim, especula-se que futuros escorregamentos podem ocorrer nessas áreas. O mapeamento da susceptibilidade a deslizamentos depende de um conhecimento bastante complexo destes eventos, fatores condicionantes e a relação entre eles. A confiabilidade dos mapas de suscetibilidade a deslizamentos depende principalmente da quantidade e qualidade dos dados disponíveis, da escala de trabalho e da seleção da metodologia apropriada de análise e modelagem. Porém, um procedimento padrão para a produção de mapas de suscetibilidade não existe, e por esse motivo muitos pesquisadores usam diferentes técnicas. Este artigo apresenta uma revisão da literatura sobre os estudos de mapeamento de suscetibilidade a deslizamentos no Brasil e no mundo, apresentando os métodos e dados de entrada comumente utilizados, com enfoque nas técnicas de aprendizado de máquina. A revisão da literatura ajuda a compreender e identificar os métodos e dados de entrada comumente usados para mapeamento de suscetibilidade a deslizamentos. Além disso, este estudo pode fornecer uma referência para as futuras pesquisas e desenvolvimento da aplicação da ciência de dados e inteligência artificial no campo da geotecnia.

Abstract – Studies referring to the assessment of susceptibility for a given area are an important tool that serves as a basis for support in management and territorial planning. Landslide susceptibility is commonly calculated from areas where landslides have occurred in the past, thus, it is speculated that future landslides may occur in these areas. The mapping of landslide susceptibility depends on a very complex knowledge of these events, conditioning factors and the relationship between them. The reliability of landslide susceptibility maps mainly depends on the quantity and quality of available data, the scale of work and the selection of the appropriate analysis and modeling methodology. However, a standard procedure for producing susceptibility maps does not exist, and for this reason many researchers use different techniques. This article presents a literature review on landslide susceptibility mapping studies in Brazil and worldwide, presenting commonly used input methods and data, focusing on machine learning techniques. Literature review helps to understand and identify commonly used methods and input data for landslide susceptibility mapping. Furthermore, this study can provide a reference for future research and development of the application of data science and artificial intelligence in the field of geotechnics.

Palavras-Chave – Aprendizado de máquina, suscetibilidade, deslizamento.

¹ Doutoranda no Programa de pós-graduação em Geologia, Universidade Federal de Minas Gerais, denisefss@yahoo.com.br

² Professora Dra. da Universidade Federal de Minas Gerais, Departamento de Geologia, mgparizzi18@gmail.com

³ Professor Dr. do Centro Federal de Educação Tecnológica de Minas Gerais, DMCAx, allanerlikhman@cefetmg.br

1. INTRODUÇÃO

Os escorregamentos são geralmente definidos como uma grande variedade de fenômenos sob a influência da gravidade (Ambrosi et al., 2018). Devido ao elevado prejuízo causado às populações e estruturas expostas a este tipo de evento é fundamental a avaliação e determinação das áreas propícias à ocorrência destes eventos. Assim, estudos referentes à avaliação da suscetibilidade de uma área são uma importante ferramenta, que servem de base de apoio científico para o governo, na gestão e nas políticas de ordenamento territorial.

A suscetibilidade a escorregamentos é comumente calculada a partir de áreas onde já ocorreram escorregamentos no passado; considerando a influência de alguns fatores ambientais relacionados, especula-se que futuros escorregamentos podem ocorrer nessas áreas (Huang e Zhao 2018; Pourghasemi et al., 2012). Ercanoglu (2005) afirma que os mapas de suscetibilidade a escorregamentos têm uma importância crucial no que tange a segurança e o planejamento urbano. Entretanto, um procedimento padrão para a produção de mapas de suscetibilidade não existe, e por esse motivo muitos pesquisadores usam diferentes técnicas (Polykretis et al., 2015).

A confiabilidade dos mapas de suscetibilidade a escorregamentos depende principalmente da quantidade e qualidade dos dados disponíveis, da escala de trabalho e da seleção da metodologia apropriada de análise e modelagem (Baeza e Corominas, 2001; Ayalew et al., 2005). Atualmente, existem vários métodos de avaliação de suscetibilidade a escorregamentos. Nos últimos anos o emprego do Sistema de Informações Geográficas (SIG) tem sido muito utilizado para integrar e analisar um grande número de quantidade de dados geográficos. Os métodos utilizados podem ser divididos em métodos qualitativos, métodos semiquantitativos e métodos quantitativos.

Segundo Polykretis et al. (2015) os métodos qualitativos, podem apresentar resultados com subjetividade, pois dependem muitas vezes da experiência do avaliador. Exemplos do emprego de metodologias qualitativas de avaliação a suscetibilidade à escorregamentos podem ser verificados nos trabalhos de Van Westen et al. (2003); Listo e Carvalho Vieira (2012); Castellanos Abella e Van Westen (2008) e Mezughi et al. (2012). Os métodos quantitativos são baseados em números e relações entre fatores que controlam a ocorrência de escorregamentos (Polykretis et al., 2015). Os métodos quantitativos compreendem a análise estatística, as abordagens de engenharia geotécnica (Sakellariou e Ferentinou, 2005;) e técnicas computacionais como Redes Neurais Artificiais (RNAs) (Yilmaz, 2009), Lógica Fuzzy (Akgun et al. 2012), Neuro-Fuzzy (Sezer et al. 2011) e Árvore de decisão (Nefeslioglu et al., 2010).

Os métodos estatísticos envolvem a avaliação dos fatores que acarretaram os escorregamentos no passado e, para se analisar as áreas que ainda não foram afetadas por escorregamentos, porém, a análise deve ser realizada em locais onde existam as mesmas condições de base (He e Beighley, 2008). As abordagens geotécnicas dependem dos princípios da estabilidade de taludes expressa em termos de um fator de segurança usando abordagens determinística (Cervi et al. 2010) ou probabilística (Jibson et al. 2000). As técnicas computacionais são capazes de realizar o aprendizado de máquina bem como o reconhecimento de padrões. Portanto, essas técnicas são capazes de aprender por meio de informações conhecidas os padrões a serem observados e generalizar a informação aprendida por meio de funções matemáticas (Braga et al., 2014).

A identificação de deslizamentos desempenha um papel importante na avaliação e gestão de riscos, e esta tarefa pode ser executada a partir da interpretação visual de imagens de sensoriamento remoto e superfícies topográficas (Guzzetti et al., 2012; Naidu et al., 2018; Xu, 2015). Entretanto, por se tratar de um processo demorado, os métodos automatizados ou semiautomatizados para a identificação de escorregamentos baseadas em técnicas de sensoriamento remoto são altamente procurados nos últimos anos (Wang et al., 2021).

Nos dias atuais, ainda não existe uma metodologia padronizada para a produção de mapas de suscetibilidade a deslizamentos (Guzzetti et al., 2002; Shirzadi et al., 2012; Feizizadeh et al., 2014). As técnicas de aprendizado de máquina têm sido utilizadas recentemente na prevenção de deslizamentos para resolver com acurácia e eficácia estes problemas (Ma et al., 2021; Merghadi et al., 2020). Além, disso as técnicas de aprendizado de máquina têm se mostrado consistentes

na remoção de problemas de “overfitting” (quando o modelo se ajusta muito bem ao conjunto de dados anteriormente observado, porém, se mostra ineficaz para prever novos resultados), aumentando a acurácia dos modelos (Schmidt et al., 2019).

Este trabalho tem por objetivo apresentar estudos utilizados no mapeamento de suscetibilidade a deslizamentos no mundo e no Brasil, com enfoque nas técnicas de aprendizado de máquina. A revisão da literatura ajuda a compreender e identificar os métodos e dados de entrada comumente usados para mapeamento de suscetibilidade a deslizamentos. Além disso, este estudo pode fornecer uma referência para futuras pesquisas e desenvolvimento da aplicação da ciência de dados e inteligência artificial no campo da geotecnia.

2. AVALIAÇÃO DE SUSCETIBILIDADE A DESLIZAMENTOS POR METODOLOGIAS QUANTITATIVAS

Os estudos atuais sobre identificação de deslizamentos são baseados principalmente em imagens ópticas usando métodos baseados em pixels ou orientados a objetos, sendo que o modelo digital de terreno (MDT) é frequentemente usado como dado auxiliar para tal análise (Guzzetti et al., 2012; Wang et al., 2021). Dias et al. (2021) destacam que um dos primeiros passos na análise de escorregamentos é a construção de inventários de escorregamentos. Esses inventários são criados por meio de diferentes métodos (manual, semiautomático e automático), como o registro de eventos recentes em escala regional ou local, e como primeiro passo na análise de suscetibilidade, vulnerabilidade e risco (Guzzetti et al., 2012; Dias et al., 2021).

As técnicas de aprendizado de máquina foram comprovadas ser uma ferramenta poderosa e promissora em muitas aplicações geotécnicas (Zhang et al., 2015; Ching e Phoon, 2018; Li et al., 2019; Lo e Leung, 2018), bem como na identificação de escorregamentos. Wang et al. (2021) propuseram um sistema de identificação de deslizamento capaz de identificar tanto deslizamentos antigos quanto deslizamentos recentes utilizando aprendizado de máquina e aprendizado profundo. Estes autores utilizaram regressão logística, Support Vector Machine, Random Forest, boosting e Redes Neurais Convolucionais para treinar e comparar seu desempenho.

Eiras et al. (2021) utilizaram estatística multivariada (análise discriminante) para desenvolver um modelo de suscetibilidade a deslizamentos por meio da análise da influência dos seguintes fatores topográficos: declividade, orientação das vertentes, curvatura do perfil e índice de umidade topográfica (TWI). A fim de mapear a suscetibilidade de ocorrências de cavidades ferríferas no Quadrilátero Ferrífero, Nola e Bacellar (2021) aplicaram análise de multicritério por meio de AHP com padronização de variáveis por Lógica Fuzzy. Amatya et al. (2019) usaram o agrupamento K-means para obter o Índice de Vegetação de Diferença Normalizada (NDVI).

Van Den Eeckhaut et al. (2012) utilizaram a técnica de Support Vector Machine (SVM) para identificar deslizamentos. Catani et al. (2013) produziram mapas de suscetibilidade a deslizamentos utilizando algoritmos de random forest (RF). Por meio desta técnica Catani et al. (2013) estimaram a importância relativa dos parâmetros de entrada individuais e selecionaram a configuração ótima para um modelo de classificação.

Segundo Ma e Mei, (2020) a regressão logística (LR) tem uma longa tradição de aplicação na avaliação da suscetibilidade a deslizamentos, como pode ser visto em Lee e Pradhan (2007). Outros estudos que aplicaram LR para avaliação de suscetibilidade ou riscos a deslizamentos podem ser encontrados em Chen e Wang (2007) e Raja et al. (2017). Outra técnica que tem se destacado recentemente no campo de avaliação da suscetibilidade são as redes neurais artificiais (Yilmaz, 2009; Bui et al., 2019; Lucchese et al., 2021).

As redes neurais convolucionais (CNN) estão sendo muito utilizadas para resolver problemas de classificação de imagens, por exemplo, as CNNs podem completar a classificação de imagens de satélite sem exigir qualquer pré-processamento ou processo de extração de características (Maggiori et al., 2016). Além disso, as CNNs estão revolucionando a detecção de objetos e padrões de reconhecimento (Maggiori et al., 2017) e a automatização de extrações de dados de deslizamento a partir de imagens (Yu et al., 2017).

Dentre as técnicas de aprendizado de máquina, não há consenso sobre qual fornece a melhor resultado. Portanto, os pesquisadores ainda avaliam e comparam a confiabilidade entre esses diferentes métodos para produzir mapas de suscetibilidade a deslizamentos, como pode ser visto nos trabalhos de Polykretis e Chalkias (2018). Ainda, pode-se citar Li et al. (2015) que utilizaram random forest (RF) e SVM para identificar deslizamentos na área das Três Gargantas da China; Ghorbanzadeh et al. (2019) que avaliaram o desempenho de redes neurais artificiais (ANN), SVM, RF e redes neurais convolucionais (CNN) na detecção áreas de deslizamentos no Nepal e Oliveira et al. (2019) que aplicaram modelos de RF e ANN para a identificação de áreas suscetíveis a deslizamentos na Bacia do Rio Fão, Sul do Brasil.

Embora as técnicas de análise de suscetibilidade sejam cada vez mais robustas, métodos simples podem produzir modelos com boas capacidades preditivas (Eiras et al. 2021). Além disso, a qualidade dos resultados preditivos produzidos pelos algoritmos é correlacionada com a qualidade dos dados de entrada, como enfatizado por Ma e Mei (2020).

3. FATORES CONDICIONANTES ADOTADOS COMO VARIÁVEIS EM MAPAS DE SUSCETIBILIDADES UTILIZANDO APRENDIZADO DE MÁQUINA

Em geral, quando não há informações geotécnicas detalhadas disponíveis para toda a área de estudo, as abordagens quantitativas são utilizadas, de modo que os modelos são criados a partir do reconhecimento de padrões por meio de computação (Aleotti e Chowdhury, 1999). Para isso, podem ser usadas abordagens estatísticas para comparar a distribuição espacial de deslizamentos a fatores condicionantes (por exemplo, fatores morfológicos e geológicos) identificando os fatores mais decisivos para indicar áreas potencialmente instáveis, assim como os algoritmos de aprendizado de máquina, que podem ser capazes de aprender e criar cenários de suscetibilidade (Lees, 1996; Dias et al., 2021).

Nos dias atuais, não existe uma diretriz universal estipulada para a determinação dos fatores condicionantes, sendo que estes fatores variam em relação à área de estudo e suas localizações geográficas, com cada região apresentando fatores particulares que causam deslizamentos (Westen et al., 2003; Kavzoglu et al., 2014; Ma e Mei, 2020). Ma e Mei (2020) explicam que para selecionar os fatores de entrada apropriados (fatores condicionantes) um método eficaz envolve classificar a importância das variáveis de entrada. Isto é feito de modo que a partir do cálculo de uma pontuação para cada fator, esses algoritmos podem avaliar e classificar as contribuições dos fatores condicionantes de deslizamento, e os fatores com contribuições mais baixas são removidas sequencialmente.

Ma e Mei (2020) citam em seu estudo alguns dos métodos de aprendizado de máquina supervisionados mais utilizados para classificar os fatores condicionantes, tais como: regressão logística (Akgun, 2012), redes neurais artificiais (Pham et al., 2016), árvores de decisão (Tsangaratos e Ilija, 2015) e Support Vector Machine (Hong et al., 2016). Ainda, segundo Ma e Mei (2020) métodos de aprendizado não supervisionados, como a técnica de cluster, podem avaliar os fatores ponderando a importância relativa de cada fator condicionante (Melchiorre et al., 2008).

De acordo com vários estudos, os fatores predisponentes comuns de deslizamentos podem ser divididos em duas categorias, sendo elas: (i) fatores internos, que estão relacionados à geologia e topografia, como a elevação, curvatura do vertical e horizontal, declividade, distância dos lineamentos, orientação das vertentes, distância dos rios, relevo e litologia; e (ii) fatores externos que geralmente causam deslizamentos, como chuvas, distância das estradas e a intensidade sísmica (Ma et al.2020).

A declividade está relacionada aos processos de erosão superficiais e subsuperficiais, assim como a curvatura horizontal e vertical, sendo úteis na avaliação da velocidade e sentido do fluxo d'água, além do transporte de sedimentos (Wilson e Gallant, 2000; Summerfield, 2014; Nola e Bacellar, 2021). A orientação das vertentes indica a orientação azimutal da encosta (Eiras et al., 2021), e de acordo com Conforti et al. (2014), este parâmetro controla alguns aspectos como exposição ao sol, ventos, intensidade das chuvas e umidade do solo; também pode influenciar a distribuição da vegetação.

Os índices TWI (Topographic Wetness Index) e NDVI (Normalised Difference Vegetation Index) são muito utilizados na predição da suscetibilidade. O primeiro pode indicar o efeito da topografia que reflete na distribuição espacial da umidade do solo e da saturação da superfície do terreno (Beven e Kirkby, 1979; Qin et al., 2011) e o segundo é utilizado para identificar os diferentes tipos de vegetação (Jensen, 2009).

A intensidade de lineamentos pode ser utilizada para avaliar a infiltração de água em alguns litotipos, como por exemplo aqueles que se comportam como maciços fraturados (Singhal e Gupta, 2010; Florinsky, 2016, Nola e Bacellar, 2021). E o HAND (Height Above Nearest Drainage) que pode ser utilizado para mapear a profundidade da zona de saturação temporária no contato entre litologias diferentes (Dias e Bacellar, 2021; Nola e Bacellar, 2021). Segundo Eiras et al. (2021) os dados geológicos para a maioria das cidades do interior do Brasil ainda são escassos e às vezes inexistentes. Devido a isso, a metodologia oficial do Serviço Geológico do Brasil para produzir mapas de suscetibilidade utiliza essencialmente fatores topográficos (Bitar, 2014; Eiras et al. 2021).

A precipitação é o gatilho mais comum e frequente de deslizamentos em todo o mundo e os sistemas de alerta de deslizamento são frequentemente baseados na suposição de que existe uma quantidade crítica de chuva e, quando atingido ou ultrapassado, desencadeia deslizamentos (Kirschbaum e Stanley, 2018; Segoni et al. 2018; Ma e Mei, 2020). Muitos autores aplicaram as técnicas de aprendizado de máquina para determinar os limites de chuvas para deslizamentos. Vallet et al. (2013) e Omadlao et al. (2019) utilizaram Support Vector Machine (SVM) para determinar os limites de chuva para deslizamentos rasos. Pradhan et al. (2018) estimaram a probabilidade de deslizamentos serem desencadeados a partir dos limites de precipitação usando uma matriz de perigo. Segno et al. (2014) integraram os resultados de limiares estatísticos de chuva e avaliaram a previsão de deslizamentos em escala regional.

4. ESTUDOS DE MAPEAMENTO DE SUSCETIBILIDADE NO BRASIL

Entre os anos de 1995 e 2019 o CEPED-UFSC (2020) registrou um total de 64.429 desastres no Brasil. A alta frequência de deslizamentos no Brasil se deve principalmente às características naturais, tais como geomorfologia, clima tropical e chuvas frequentes (IBGE, 2019). Ao passo que, eventos geo-hidrológicos se concentram principalmente no período chuvoso, entre os meses de outubro e março.

No Brasil, os inventários de deslizamentos geralmente são criados manualmente, por meio de interpretação visual de imagens sem considerar padrões e diretrizes comuns, e sua base metodológica não é abordada com frequência nas publicações (Dias et al., 2021a). Dias et al. (2021b) em seu estudo, apresentam uma análise bibliográfica de alguns mapeamentos de suscetibilidade a deslizamentos no Brasil. Estes autores, ainda, afirmam que as diretrizes para o inventário de deslizamentos são cruciais e podem influenciar a precisão das análises subsequentes baseadas nesses inventários.

Segundo Dias et al. (2021) o número de publicações relacionadas ao mapeamento de suscetibilidade a escorregamentos no Brasil aumentou significativamente desde 2015. As técnicas quantitativas, amplamente utilizadas na Europa, ainda são pouco difundidas no Brasil (Reichenbach et al., 2018). No estado de Minas Gerais, ainda, são poucos os estudos que apresentam modelos com análises de suscetibilidade com abordagens quantitativas, como os estudos apresentados em Barella et al. (2019), Eiras et al. (2021), Nola e Bacellar (2021) e Rosa et al. (2021).

5. CONCLUSÕES

Os mapas de suscetibilidade a deslizamento têm uma importância crucial no que tange a segurança e o planejamento urbano. O mapeamento da suscetibilidade a deslizamentos

depende de um conhecimento bastante complexo destes eventos, fatores condicionantes e a relação entre eles.

A aplicação de técnicas de aprendizado de máquina nas geociências tem sido bem sucedida nos últimos anos, sobretudo na área da geotecnia. O número de pesquisas para análise da suscetibilidade aplicando técnicas de aprendizado de máquinas aumentou na última década e a tendência é aumentar cada vez mais devido à capacidade de aquisição e processamento de dados disponibilizados além da disponibilidade de ferramentas para aplicações.

Dentre as técnicas de aprendizado de máquinas aplicadas para construção de mapas de suscetibilidade destacam-se as redes neurais artificiais, redes neurais convolucionais, regressão logística, árvores de decisão, random forest e support vector machine. Já, em relação aos parâmetros de entrada destacam-se, a geologia e fatores topográficos, como a declividade, orientação das encostas e elevação. Sendo que a maior parte dos estudos utilizou um inventário de deslizamentos como variável “targed”, ou seja, a variável que queremos prever na análise de suscetibilidade.

Por fim, por meio da revisão da literatura, foi possível compreender e identificar os métodos e variáveis de entrada comumente usados para mapeamento de suscetibilidade a deslizamentos no Brasil e no mundo. Além de poder identificar as grandes possibilidades de futuras pesquisas de aprendizado de máquina nesta importante área. Assim, verifica-se a utilidade das técnicas de aprendizado de máquina na geociência computacional e o potencial de fornecer análises com a demanda crescente de banco de dados.

REFERÊNCIAS

Akgun, A. A comparison of landslide susceptibility maps produced by logistic regression, multi-criteria decision, and likelihood ratio methods: A case study at zmir, Turkey, *Landslides* 9 (2012) 93–106. doi:10.1007/s10346-011-0283-7.

Aleotti, P.; Chowdhury, R. Landslide hazard assessment: Summary review and new perspectives. *Bull. Eng. Geol. Environ.* 1999, 58, 21–44.

Amatya PM, Kirschbaum D, Stanley T (2019) Use of very highresolution optical data for landslide mapping and susceptibility analysis along the karnali highway, Nepal. *Remote Sens* 11:2284.

Ayalew, L., Yamagishi, H., Maruib, H., Takami, K. 2005. Landslides in Sado Island of Japan: Part II. GIS-based susceptibility mapping with comparisons of results from two methods and verifications. *Eng Geol* 81(4):432–445

Barella, C.F.; Sobreira, F.G.; Zêzere, J.L. A comparative analysis of statistical landslide susceptibility mapping in the southeast region of Minas Gerais state, Brazil. *Bull. Eng. Geol. Environ.* 2019, 78, 3205–3221.

Baeza, C., Corominas, J. 2001. Assessment of shallow landslide susceptibility by means of multivariate statistical techniques. *Earth Surf Proc Landf* 26:1251–1263.

Beven, K. J., Kirkby, M. J. (1979) A physically based, variable contributing area model of basin hydrology. *HydrolSciJor* 24(1):43–69

Bitar O. Y. (2014). Cartas de suscetibilidade a movimentos gravitacionais de massa e inundações – 1: 25.000: nota técnica explicativa. IPT; CPRM.

Bui DT, Moayedi H, Kalantar B, Osouli A, Gör M, Pradhan B, Rashid ASA (2019) Harris hawks optimization: a novel swarm intelligence technique for spatial assessment of landslide susceptibility. *Sensors* 19(16):3590

Castellanos Abella, E. A., Van Westen, C. J. 2008. Qualitative landslide susceptibility assessment by multicriteria analysis: a case study from San Antonio del Sur, Guantanamo, Cuba. *Geomorphology* 94(3–4):453–466.

Catani, F., Lagomarsino, D., Segoni, S., Tofani, V. Landslide susceptibility estimation by random forests technique: Sensitivity and scaling issues, *Natural Hazards and Earth System Sciences* 13 (2013) 2815–2831. doi:10.5194/nhess-13-2815-2013.

CEPED-UFSC 2020, Relatório de danos materiais e prejuízos decorrentes de desastres naturais no Brasil: 1995 – 2019 / Banco Mundial. Global Facility for Disaster Reduction and Recovery. Fundação de Amparo à Pesquisa e Extensão Universitária. Centro de Estudos e Pesquisas em Engenharia e Defesa Civil. [Organização Rafael Schadeck] – 2. ed. – Florianópolis: FAPEU.

Chen Z, Wang J (2007) Landslide hazard mapping using logistic regression model in Mackenzie Valley Canada *Nat Hazards* 42(1):75–89

Ching, J., Phoon, K.K., 2018. Constructing site-specific multivariate probability distribution model using Bayesian machine learning. *J. Eng. Mech.* 145 (1), 04018126

Conforti, M., Pascale, S., Robustelli, G., Sdao, F. (2014) Evaluation of prediction capability of the artificial neural networks for mapping landslide susceptibility in the Turbolo River catchment (northern Calabria, Italy). *CATENA* 113:236–250

Dias, J. C. S., Bacellar, L. A. P. A hydrogeological conceptual model for the groundwater dynamics in the ferricretes of Capão Xavier, Iron Quadrangle, Southeastern Brazil, *CATENA*, v. 207, 2021, 105663. <https://doi.org/10.1016/j.catena.2021.105663>.

Dias, H.C.; Hölbling, D.; Grohmann, C.H. 2021a. Landslide Inventory Mapping in Brazil: Status and challenges. In *Proceedings of the XIII Internacional Symposium on Landslides*, Cartagena, Colombia, 22–26 February.

Dias, H.C.; Hölbling, D.; Grohmann, C.H. 2021b. Landslide Susceptibility Mapping in Brazil: A Review. *Geosciences* 2021, 11, 425. <https://doi.org/10.3390/geosciences11100425>

Eiras, C. G. S., Souza, J. R. G., Freitas, R. D. A., Barella. C, F., Pereira, T. M. Discriminant analysis as an efficient method for landslide susceptibility assessment in cities with the scarcity of predisposition data. *Natural Hazards* 107, 1427–1442 (2021).

Ercanoglu, M. 2005. Landslide susceptibility assessment of SE Bartin (West Black Sea region, Turkey) by artificial neural networks. *Nat Hazards Earth Syst Sci* 5:979–992.

Feizizadeh, B., Jankowski, P., Blaschke, T., 2014. A GIS based spatially-explicit sensitivity and uncertainty analysis approach for multi-criteria decision analysis, *Computers and Geosciences* 84, 81-95

Florinsky, I.V. 2016. *Digital terrain analysis in soil science and geology*. Academic Press, London, 486 p.

Ghorbanzadeh, O., Blaschke, T., Gholamnia, K., Meena, S.R., Tiede, D., Aryal, J., 2019. Evaluation of different machine learning methods and deep-learning convolutional neural networks for landslide detection. *Rem. Sens.* 11 (2), 196

Guzzetti, F., Malamud, B.D., Turcotte, D.L., Reichenbach, P., 2002. Power-law correlations of landslide areas in central Italy. *Earth Planet Science Letters* 195(3), 169-183.

Guzzetti, F., Mondini, A.C., Cardinali, M., Fiorucci, F., Santangelo, M., Chang, K.T., 2012. Landslide inventory maps: New tools for an old problem. *Earth Sci. Rev.* 112 (1–2), 42–66

- Hong, H., Pradhan, B., Tien Bui, D., Xu, C., Youssef, D. A., Chen, W. Comparison of four kernel functions used in support vector machines for landslide susceptibility mapping: a case study at Suichuan area (China), *Geomatics, Natural Hazards and Risk* 8 (2016) 544–569. doi:10.1080/19475705.2016.1250112.
- Huang, Y., Zhao, L. 2018. Review on landslide susceptibility mapping using support vector machines. *CATENA* 165:520–529.
- IBGE. Suscetibilidade a Deslizamentos do Brasil: Primeira Aproximação; Technical Report; Instituto Brasileiro de Geografia e Estatística: Rio de Janeiro, Brazil, 2019.
- Kavzoglu, T., Sahin, E., Colkesen, I. An assessment of multivariate and bivariate approaches in landslide susceptibility mapping: a case study of duzkoy district, *Natural Hazards* 76 (2014) 471–496. doi:10.1007/s11069-014-1506-8.
- Kirschbaum, D., Stanley, T. Satellite-based assessment of rainfall-triggered landslide hazard for situational awareness, *Earth's Future* 6 (2018) 505–523. doi:10.1002/2017EF000715.
- Lee, S., Pradhan, B. Landslide hazard mapping at Selangor, Malaysia using frequency ratio and logistic regression models, *Landslides* 4 (2007) 33–41. doi:10.1007/s10346-006-0047-y.
- Lees, B.G. Neural network applications in the geosciences: An introduction. *Comput. Geosci.* 1996, 22, 955–957.
- Li, X.J., Cheng, X.W., Chen, W.T., Chen, G., Liu, S.W., 2015. Identification of forested landslides using Lidar data, object-based image analysis, and machine learning algorithms. *Rem. Sens.* 7 (8), 9705–9726
- Li, X.Y., Zhang, L.M., Xiao, T., Zhang, S., Chen, C., 2019. Learning failure modes of soil slopes using monitoring data. *Probabilist. Eng. Mech.* 56, 50–57.
- Listo, F. D. L. R., Carvalho, V. B. 2012. Mapping of risk and susceptibility of shallow-landslide in the city of São Paulo, Brazil. *Geomorphology* 169–170:30–44
- Lo, M.K., Leung, A.Y., 2018. Bayesian updating of subsurface spatial variability for improved prediction of braced excavation response. *Can. Geotech. J.* <https://doi.org/10.1139/cgj-2018-0409>.
- Lucchese, L.V.; de Oliveira, G.G.; Pedrollo, O.C. Investigation of the influence of nonoccurrence sampling on landslide susceptibility assessment using Artificial Neural Networks. *Catena* 2021, 198, 105067.
- Ma, Z., Mei, G. (2020): Machine Learning for Landslides Prevention: A Survey. TechRxiv. Preprint. <https://doi.org/10.36227/techrxiv.12546098.v1>
- Ma, Z., Mei, G. & Piccialli, F. Machine learning for landslides prevention: a survey. *Neural Comput & Applic* 33, 10881–10907 (2021). <https://doi.org/10.1007/s00521-020-05529-8>
- Maggiori, E., Tarabalka, Y., Charpiat, G., Alliez, P. Convolutional neural networks for largescale remote sensing image classification, *IEEE Transactions on Geoscience and Remote Sensing* 55 (2016) 645–657. doi:10.1109/TGRS.2016.2612821
- Maggiori, E., Tarabalka, Y., Charpiat, G., Alliez, P. High-resolution aerial image labeling with convolutional neural networks, *IEEE Transactions on Geoscience and Remote Sensing* 55 (12) (2017) 7092–7103

- Melchiorre, C., Matteucci, M., Azzoni, A., Zanchi, A. Artificial neural networks and cluster analysis in landslide susceptibility zonation, *Geomorphology* 94 (2008) 379–400.
- Merghadi, A.; Yunus, A.P.; Dou, J.; Whiteley, J.; ThaiPham, B.; Bui, D.T.; Avtar, R.; Abderrahmane, B. Machine learning methods for landslide susceptibility studies: A comparative overview of algorithm performance. *Earth-Sci. Rev.* 2020, 207, 103225.
- Mezughi, T. H., Akhir, J. M., Rafek, A. G., Abdullah, I. 2012. Analytical Hierarchy process method for mapping landslide susceptibility to an area along the E-W highway (Gerik-Jeli), Malaysia. *Asian J Earth Sci* 5(1):13–24.
- Naidu, S., Sajinkumar, K.S., Oommen, T., Anuja, V.J., Samuel, R.A., Muraleedharan, C., 2018. Early warning system for shallow landslides using rainfall threshold and slope stability analysis. *Geosci. Front.* 9 (6), 1871–1882.
- Nola, I.T.S., Bacellar, L.A.P., 2021. Multi-criteria analysis for mapping susceptibility to iron formation caves development in the Gandarela mountain range (MG), southeast Brazil. *International Journal of Speleology*, 50(2), 173-187.
- Oliveira, G.G.; Ruiz, L.F.C.; Guasselli, L.A.; Haetinger, C. Random Forest and artificial neural networks in landslide susceptibility modeling: A case study of the Fão River Basin, Southern Brazil. *Nat. Hazards* 2019, 99, 1049–1073.
- Omadlao, Z., Tuguinay, N., Saturay, R.J.: Machine learningbased prediction system for rainfall-induced landslides in Benguet First Engineering District (2019). 10.31219/osf.io/csx6r
- Pham, B., Tien Bui, D., Prakash, I. Dholakia, M. Hybrid integration of multilayer perceptron neural networks and machine learning ensembles for landslide susceptibility assessment at himalayan area (India) using GIS, *Catena* 149 (2016) 52–63. doi:10.1016/j.catena.2016.09.007.
- Pradhan, A., Lee, S. R., Kim, Y. T. (2018) A shallow slide prediction model combining rainfall threshold warnings and shallow slide susceptibility in Busan, Korea. *Landslides*. <https://doi.org/10.1007/s10346-018-1112-z>
- Polykretis, C., Ferentinou, M., Chalkias, C. A comparative study of landslide susceptibility mapping using landslide susceptibility index and artificial neural networks in the Krios River and Krathis River catchments (northern Peloponnesus, Greece). *Bull Eng Geol Environ.* 2015. 74: 27.
- Pourghasemi, H. R., Mohammady, M., Pradhan, B. 2012. Landslide susceptibility mapping using index of entropy and conditional probability models in GIS: safarood Basin, Iran. *Catena* 97:71–84.
- Polykretis C, Chalkias C (2018) Comparison and evaluation of landslide susceptibility maps obtained from weight of evidence, logistic regression, and artificial neural network models. *Nat Hazards* 93(1):249–274
- Qin, C. Z., Zhu, A. X., Pei, T., Li, B.L., Scholten, T., Behrens, T., Zhou, C. H. (2011) An approach to computing topographic wetness index based on maximum downslope gradient. *Precision Agric* 12(1):32–43
- Raja NB, Çiçek I, Türkoğlu N, Aydın O, Kawasaki A (2017) Landslide susceptibility mapping of the Sera River Basin using logistic regression model. *Nat Hazards* 85:1323–1346
- Reichenbach P, Rossi M, Malamud BD, Mihir M, Guzzetti F (2018) A review of statisticallybased landslide susceptibility models. *Earth-Sci Rev* 180:60–91

- Rosa, M.L.; Sobreira, F.G.; Barella, C.F. Landslide susceptibility mapping using the statistical method of Information Value: A study case in Ribeirão dos Macacos basin, Minas Gerais, Brazil. *An. Acad. Bras. Ciências* 2021, 93.
- Sakellariou, M. G., Ferentinou, M. 2005. A study of slope stability prediction using neural networks. *Geotech Geol Eng* 23(4):419–445.
- Schmidt, J.; Marques, M.R.; Botti, S.; Marques, M.A. Recent advances and applications of machine learning in solid-state materials science. *NPJ Comput. Mater.* 2019, 5, 83.
- Segoni, S., Lagomarsino, D., Fanti, R., Moretti, S., Casagli, N. Integration of rainfall thresholds and susceptibility maps in the Emilia Romagna (Italy) regional-scale landslide warning system, *Landslides* 12 (2014) 773–785. doi:10.1007/s10346-014-0502-0.
- Shirzadi, A., Lee, S., Oh, H. J., Chapi, K., 2012. A GIS-based logistic regression model in rockfall susceptibility mapping along a mountainous road: Salavat Abad case study, Kurdistan, Iran. *Natural Hazards* 64(2), 1639-1656.
- Singhal, B. B. S., Gupta, R. P. 2010. Applied hydrogeology of fractured rocks. Springer Science & Business Media, London, 401 p.
- Summerfield, M. A. 2014. *Global Geomorphology*. Taylor & Francis Group, Routledge, 560p.
- Tsangaratos, P., Iliá, I. Landslide susceptibility mapping using a modified decision tree classifier in the xanthi perfection, Greece, *Landslides* (2015) 305–320.
- Vallet, A., Varron, D., Bertrand, C., Mudry, J.N. Hydrogeological threshold using effective rainfall and support vector machine (SVM) applied to a deep-seated unstable slope (Schilienne, French Alps), 2013
- Van Den Eeckhaut, M., Kerle, N., Poesen, J., Hervás, J., 2012. Object-oriented identification of forested landslides with derivatives of single pulse LIDAR data. *Geomorphology* 173, 30–42
- Van Westen, C. J., Rengers, N., Soeters, R. 2003. Use of geomorphological information in indirect landslide susceptibility assessment. *Nat Hazards* 30:399–419.
- Wang, H., Zhang, L., Yin, K., Luo, H., Li, J., 2021. Landslide identification using machine learning. *Geosci. Front.* 12 (1), 351–364.
- Wilson, J.P., Gallant, J.C. 2000. *Terrain analysis: principles and applications*. John Wiley & Sons, 479 p.
- Westen, C., Rengers, N., Soeters, R. Use of geomorphological information in indirect landslide susceptibility assessment, *Natural Hazards* 30 (2003) 399–419.
- Xu, C., 2015. Preparation of earthquake-triggered landslide inventory maps using remote sensing and GIS technologies: principles and case studies. *Geosci. Front.* 6 (6), 825–836
- Yu, H., Ma, Y., Wang, L., Zhai, Y., Wang, X. A landslide intelligent detection method based on CNN and RSGR (2017) 40–44.
- Yilmaz, I. 2009. A case study from Koyulhisar (Sivas-Turkey) for landslide susceptibility mapping by artificial neural networks. *Bull Eng Geol Environ* 68(3):297–306.
- Zhang, W., Goh, A.T., Zhang, Y., Chen, Y., Xiao, Y., 2015. Assessment of soil liquefaction based on capacity energy concept and multivariate adaptive regression splines. *Eng. Geol.* 188, 29–37