



MACHINE LEARNING NA PREVISÃO DE DESLIZAMENTOS DEFLAGRADOS POR CHUVAS: DESEMPENHO E GENERALIZAÇÃO EM PETRÓPOLIS, RJ

Artur Nonato Vieira Cereto¹
Gean Paulo Michel²
Franciele Zanandrea³
Ivanovich Lache Salcedo⁴

RESUMO

O município de Petrópolis, RJ, devido ao seu clima, relevo e crescimento urbano desordenado, possui longo histórico de desastres, sendo notórios os deslizamentos ocorridos nos anos de 2011 e de 2022. Importantes ferramentas para a mitigação dos impactos causados por este tipo de desastre, os sistemas de alerta antecipado para deslizamentos, conhecidos como LEWS (*Landslide Early Warning Systems*), processam dados provenientes de sensores (e.g. pluviômetros, sensores de poro-pressão etc.) instalados em áreas de interesse e classificam a probabilidade de ocorrência de um deslizamento a partir das variáveis monitoradas. Esta classificação é utilizada a fim de embasar a tomada de decisão de autoridades e possibilitar a evacuação da área de risco em tempo hábil para a redução de danos. Este trabalho investigou a viabilidade de um LEWS para o município de Petrópolis, pautado em modelos de machine learning, avaliando o desempenho dos algoritmos *Support Vector Machine (SVM)*, *Multilayer Perceptron (MLP)* e *Random Forest (RF)*. Também foi avaliada a performance do modelo em termos de generalização espacial, buscando entender a necessidade de treinamento específico para cada região. Os modelos classificadores baseados em *MLP* obtiveram os melhores resultados seguidos pelos modelos baseados em *SVM* e *RF*, respectivamente. A melhor configuração de rede neural testada apresentou *recall* de 1,0, *f1-score* de 0,81 e *precision* de 0,68. Além disso, também se observou que o modelo treinado apresentou baixa generalização espacial, tendo sido observada expressiva perda de desempenho quando alimentado com dados provenientes de pluviômetro a 32,6 km, ainda dentro de Petrópolis (*recall* = 1,0, *f1-score* = 0,17 e *precision* = 0,09). Sendo assim, o uso de algoritmos de *machine-learning* apresentou potencial para a aplicação em LEWS no município de Petrópolis, no entanto ainda é necessário o aprimoramento da metodologia para a espacialização dos resultados.

Palavras-chave: Deslizamentos de terra, LEWS, Desastres, Sistemas de Alerta, Petrópolis.

INTRODUÇÃO

Estima-se que, ao redor do mundo, movimentos de massa são responsáveis pela morte de cerca de 4.500 pessoas e causam um impacto econômico na ordem de 20 bilhões

¹ Mestrando do Curso de Engenharia de Biosistemas (PGEB) da Universidade Federal Fluminense - UFF, arturcereto@id.uff.br;

² Professor orientador: Doutor, Instituto de Pesquisas Hidráulicas (IPH) - UFRGS, geanpmichel@gmail.com

³ Professor orientador: Doutor, Departamento de Eng. Agrícola e Meio Ambiente - UFF, francielez@id.uff.br

⁴ Professor orientador: Doutor, Departamento de Eng. Agrícola e Meio Ambiente, ilache@id.uff.br



de dólares. Além disso, nos últimos 50 anos a frequência destes desastres aumentou em 10 vezes, havendo maior concentração de ocorrências nas regiões tropicais do planeta, principalmente por conta de expansão desordenada da malha urbana, que leva à ocupação de encostas com alta vulnerabilidade para este tipo de fenômeno, cuja deflagração é principalmente associada a chuvas de alta intensidade (Ozturk et al., 2022).

Dentre as alternativas para a mitigação dos impactos deste tipo de desastre, os sistemas de alerta antecipado para movimentos de massa (LEWS, em inglês) se destacam pelo relativo baixo custo e facilidade de implementação quando comparados a obras de contenção de encostas, cujas complexidades podem ser muito elevadas e cujas áreas de abrangência são pontuais (Michoud et al., 2013).

Estes sistemas têm como objetivo prever a ocorrência de movimentos de massa com antecedência suficiente para a evacuação da população em risco, assim evitando mortes e reduzindo perdas materiais e, de forma geral, funcionam a partir do monitoramento de variáveis importantes (e.g. precipitação, poro-pressão do solo etc.), processamento destes dados por modelos que avaliam a probabilidade de deflagração do movimento de massa, para, assim, subsidiar a tomada de decisão por parte das autoridades responsáveis pela mobilização dos serviços de emergência. Dentre as metodologias utilizadas, a mais comum é o uso de limiares de precipitação empíricos, baseados em séries históricas (Guzzetti et al., 2020; Piciullo; Calvello; Cepeda, 2018).

Mais recentemente, LEWS baseados no emprego de algoritmos de *machine learning* vêm demonstrando grande potencial (Tehrani et al., 2022), sendo exemplos de aplicações destas técnicas: o trabalho de Kang et al. (2024) que testa, entre outros algoritmos, o *Support Vector Machine* (SVM) e *Random Forest* (RF), com entradas sobre informações geológicas e dados de precipitações e constata que, o RF obteve a melhor performance; o trabalho de Liu et al. (2022), que testam SVM, RF, *Multilayer Perceptron* (MLP) entre outros algoritmos treinados com dados espaciais, características do terreno e séries históricas de precipitação com o intuito de serem aplicados a um LEWS, tendo o algoritmo RF também apresentado melhores resultados, seguido pelo MLP; e o de Mondini et al. (2023) que faz uso de redes neurais (MLP) treinadas com dados apenas de precipitação e alcança bons resultados, além de sugerir uso de SVM.

Este trabalho investigou a possibilidade de desenvolvimento de um LEWS para o município de Petrópolis, pautado em modelos de machine learning, avaliando o desempenho dos algoritmos, *Support Vector Machine* (SVM), *Multilayer Perceptron*



(MLP) e *Random Forest (RF)*, além de ter testado a capacidade de generalização espacial de um modelo baseado em *machine learning* treinado com dados de um único pluviômetro de Petrópolis, RJ.

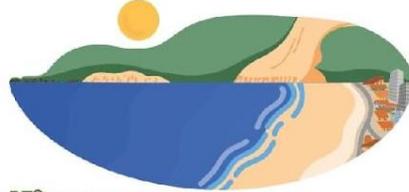
Metodologia

Área de Estudo

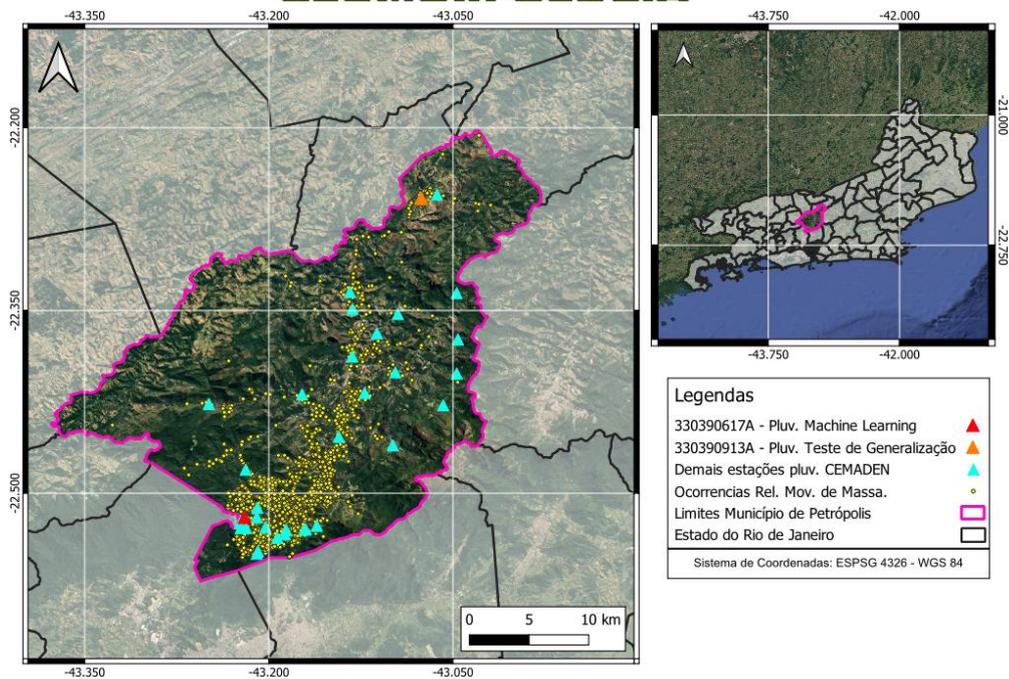
O município de Petrópolis, situado na região serrana do estado do Rio de Janeiro (que por sua vez está inserida na formação Serra do Mar) e possui 791.144 km² de área, altitude média de 840m e população de 278,881 habitantes (IBGE,2022). Seu clima é classificado como tropical de altitude e é caracterizado por pluviosidade ao longo de todo o ano, registrando média de precipitação anual de cerca de 2.000mm (Araújo et al., 2018), sendo dezembro o mês com maior incidência de chuvas, registrando média de 316,6mm (Petrópolis, 2025).

Petrópolis é uma das cidades mais afetadas por movimentos de massa no país, tendo um longo histórico desta variedade de desastres, deflagrados, principalmente, por eventos de chuva intensos. Outros fatores que afetam a sua propensão a sofrer com deslizamentos de terra é o seu relevo somado ao crescimento urbano desordenado, que leva à ocupação de áreas de risco, e o consequente desmatamento e cortes nas encostas (Guerra; Gonçalves; Lopes, 2007). Destacam-se os desastres de 1988, com 171 mortes, 2011, com 73 mortes e 2022, com 234 mortes. Sendo este último, o maior já registrado na história do município (G1, 2022).

Figura 1: Município de Petrópolis com e posicionamento dos pluviômetros e ocorrências relacionadas a movimentos de massa



15º SIMPÓSIO NACIONAL DE GEOMORFOLOGIA



Bases de Dados

Para a realização deste trabalho, foram utilizados dois bancos de dados que, subsequentemente, foram cruzados a fim de permitir o treinamento de modelos de *machine learning*. O primeiro se trata dos dados de chuva oriundos de 33 estações pluviométricas instaladas pelo Centro Nacional de Monitoramento e Alerta de Desastres (CEMADEN) em Petrópolis, das quais 24 se encontram em operação atualmente. O segundo consiste em um banco de dados com os registros de ocorrências relacionadas a movimentos de massa possui 11.043 atendimentos, distribuídos em 1018 dos 3154 dias, referentes ao período de 05 de outubro de 2015 até 23 de maio de 2024, elaborado e cedido pela Defesa Civil de Petrópolis. É necessário fazer a ressalva de que o município de Petrópolis não realiza o registro dos deslizamentos de terra em si, apenas dos atendimentos decorrentes deste tipo de desastre. Dessa maneira, foi aplicado um filtro temporal com o objetivo de aumentar a probabilidade de correspondência entre os registros e os dias de ocorrência efetiva da deflagração dos movimentos de massa, para posterior associação à chuva deflagradora.

O filtro temporal considerou: (i) que os registros analisados correspondem a atendimentos realizados pela Defesa Civil do município de Petrópolis relacionados a deslizamentos de terra, e não necessariamente aos movimentos de massa em si; (ii) que muitas dessas ocorrências foram registradas em dia com pouca ou nenhuma precipitação; e (iii) o papel central que eventos de chuva intensa desempenham na deflagração desse



tipo de desastre (Guzzetti et al., 2020; Mendes et al., 2020). Assim, foram contabilizados apenas os dias em que houve registros de atendimentos pela Defesa Civil e em que a precipitação diária foi igual ou superior a 36 mm, valor correspondente ao percentil 95 da distribuição de acumulados diários das chuvas observadas na cidade ao longo do período analisado, conforme dados obtidos da rede de pluviômetros do CEMADEN.

Após a análise dos dados das leituras dos pluviômetros do CEMADEN e com base no trabalho de Mondini et al. (2023), que constrói um LEWS baseado em dados de uma única estação pluviométrica, foi selecionada a estação pluviométrica Quitandinha/ Rua Araruama (código 330390617A, e que será identificado neste trabalho como pluviômetro base), que está situada na latitude -22,52 e longitude -43,22, dentro da área do 1º Distrito de Petrópolis, região que registra os maiores índices de chuva do município (Petrópolis, 2025), a uma distância média de 5,6 km das 11.043 ocorrências catalogadas, valor que é próximo da metade da distância média observada entre as demais estações pluviométricas do município (11,6 km). Além disso, suas leituras também demonstram integridade, com a precipitação média mensal para este pluviômetro de 167,84mm e a média anual de 1.832,35mm, além de suas leituras apresentarem desvio padrão de 0,42 mm.

A aplicação do filtro à série temporal da estação pluviométrica Quitandinha/Rua Araruama resultou na redução do número de dias com registros de ocorrência de 1.018 para 105.

Sistemas de Alerta Antecipado baseados em *machine-learning*:

Foram treinados e avaliados modelos de classificação baseados em *Multilayer Perceptron* (MLP), *Random Forest* (RF) e *Support Vector Machine* (SVM), cujas configurações específicas encontram-se detalhadas na Tabela 1. Todos os modelos foram formulados como classificadores binários, com o objetivo de prever, a partir de dados de precipitação, dias com deflagração de movimentos de massa. Em todos os casos, foi adotado o limiar de decisão padrão de 0,5, de modo que valores de probabilidade iguais ou superiores a esse valor foram classificados como positivos (ocorrência prevista), enquanto valores inferiores foram classificados como negativos.

Os modelos baseados em MLP testados possuíam arquitetura relativamente simples, composta por duas ou três camadas ocultas do tipo densa (*dense*), com 6, 8 ou 10 neurônios por camada, a depender da configuração. A camada de saída, comum a todos os modelos, utiliza uma função de ativação sigmoide. Além disso, os modelos foram compilados com o otimizador Adam (*Adaptive Moment Estimation*), função de custo,



binary crossentropy, e avaliação do desempenho durante o treinamento, foi realizada a partir da acurácia como métrica principal.

Tabela 1: Informações sobre os modelos treinados

Modelo	Hiperparâmetros
Multilayer Perceptron (MLP)	camadas ocultas = 2 ou 3, neurônios em cada camada = 6 ou 8 ou 10, epochs = 75, batch size = 32
Support Vector Machine (SVM)	kernel = 'rbf', C = 1.0, gamma = 'scale'
Random Forest (RF)	n_estimators = 100, max_depth = None

Para a construção dos conjuntos de dados que alimentam os modelos, utilizaram-se as leituras do pluviômetro previamente mencionado, integradas ao banco de dados da Defesa Civil (D.C.) do município de Petrópolis, contendo registros de ocorrências associadas a movimentos de massa.

A partir disso, para alimentar o modelo proposto foi uma composição 6 de variáveis independentes, denominada Input 1. Essas variáveis consistem nos totais de precipitação acumulada nas janelas de 24h, 48h e 72h, além de suas respectivas intensidades máximas horárias. Em relação aos dados de registros de ocorrências, foi aplicado o filtro mencionado no item anterior, tendo sido contabilizados como dias com ocorrências somente aqueles que apresentaram precipitação maior do que 36 mm.

Como etapa de pré-processamento, as variáveis de entrada foram submetidas à padronização por meio da função *StandardScaler*, da biblioteca *Scikit-learn*, de modo a centralizar as distribuições em torno de média zero e desvio padrão igual a um. Em seguida, os dados foram particionados em dois subconjuntos: treinamento (70%) e teste (30%), por meio de seleção aleatória, tendo sido verificada proporção similar entre as classes para ambos os subconjuntos.

O conjunto de treinamento foi composto por 2.207 amostras, das quais 2.136 correspondiam a dias sem registro de ocorrências e 71 a dias com registro. O conjunto de teste, por sua vez, foi constituído por 947 amostras, sendo 913 referentes a dias sem ocorrências e 34 a dias com registros. Tendo em vista o desequilíbrio entre a quantidade de dias com e sem registros de ocorrências, aplicado peso amostral inversamente proporcional à frequência das classes



A análise de desempenho dos modelos foi feita observando a sua matriz de confusão e avaliação dos valores das métricas *accuracy* (acurácia), que consiste no total de acertos (soma entre Verdadeiros Positivos (VP) e Verdadeiros Negativos (VN)) dividido pelo total de casos; *recall* (sensibilidade), que consiste na razão entre o número de verdadeiros positivos e a soma do número VP e Falsos Negativos; *precision* (precisão), que consiste na razão entre os VPs e a soma dos VPs com Falsos Positivos (FP); F1-Score, que é a média harmônica entre precisão e recall; e *False Positive Rate* (FPR), que consiste no número de Falsos Positivos dividido pelo somatório de Falsos Positivos e Verdadeiros Negativos.

Verificação da generalização do modelo

Após a identificação do modelo com melhor performance, será avaliado o seu potencial de generalização espacial. Para tal, será utilizada como entrada para o modelo selecionado a série temporal de precipitação proveniente do pluviômetro de código 330390613A, chamado neste trabalho de pluviômetro teste, situado no mesmo município a 32,6 km da estação pluviométrica cujos dados serviram para treinar o modelo. O desempenho do modelo foi então avaliado a partir de sua matriz de confusão e das métricas previamente citadas.

RESULTADOS E DISCUSSÃO

Na Tabela 2 estão dispostos os resultados das matrizes de confusão dos diferentes modelos treinados. A nomenclatura dos modelos MLP possui sufixo que representa o número de camadas e depois o número de *neurons* em cada camada (e.g. `mlp_input_1_2_10_w` significa um modelo que possui 2 camadas com 10 *neurons* em cada e usou balanceamento das classes em seu treinamento). Observou-se que os modelos baseados em MLP e SVM obtiveram e menores números de classificação de Falsos Negativos e maiores números de Falsos Positivos, enquanto o modelo baseado em RF manifestou comportamento oposto, com o menor número de classificações como Falsos Positivos e maiores números de classificações como Falsos Negativos.

Tabela 2: Matrizes de confusão dos diferentes modelos treinados para o pluviômetro base (33039017A)

Modelo	Verdadeiro Positivo (VP)	Falso Positivo (FP)	Verdadeiro Negativo (VN)	Falso Negativo (FN)
mlp_input_1_2_6_w	33	19	894	1
mlp_input_1_2_8_w	34	16	897	0
mlp_input_1_2_10_w	33	18	895	1
mlp_input_1_3_6_w	33	16	897	1
mlp_input_1_3_8_w	34	17	896	0
mlp_input_1_3_10_w	33	15	898	1
rf_input_1_w	27	9	904	7
svm_input_1_w	34	23	890	0

No contexto de LEWS, a redução do número de falsos negativos (FN) deve ser prioritária, uma vez que a não emissão de alertas diante da ocorrência efetiva de desastres pode resultar em consequências potencialmente catastróficas. No entanto, é igualmente necessário considerar que um número elevado de falsos positivos (FP), alarmes falsos, tende a comprometer a credibilidade do sistema, fenômeno conhecido na literatura como *cry wolf syndrome* (Atwood e Major, 1998; Uchida, 2011).

Na Tabela 3 estão os resultados dos cálculos das métricas utilizadas para avaliação para cada um dos algoritmos utilizados, estando apresentada a média das métricas para os modelos baseados em MLP. Considerando a necessidade de se priorizar a redução dos números de Falsos Negativos dos LEWS, os modelos baseados em MLP e SVM se demonstraram mais efetivos, apresentando *recall* de 0,98 e 1, respectivamente. Contudo foram também os modelos que apresentaram maiores valores de FPR. Já o RF se destacou pelo baixo número de Falsos Positivos, o que está representado pela métrica *Precision*, contudo apresentou o menor *recall*, o que indica maior número de Falsos Negativos, .

Tabela 3: Métricas de avaliação para cada algoritmo testado

Modelo	Accuracy	Precision	Recall	F1-Score	FPR
MLP *	0,982	0,665	0,980	0,792	0,153
RF	0,983	0,750	0,794	0,771	0,010
SVM	0,976	0,596	1	0,747	0,025

*valores médios

Assim, dentre as configurações testadas o modelo mlp_input_1_2_8_w foi escolhido para ser modelo testado quanto ao seu potencial de generalização, por ser o modelo que obteve 0 previsões FN de menor número de previsões FP (i.e. alarmes falsos).

Generalização do modelo

Na Tabela 4 estão dispostas as matrizes de confusão obtidas após o uso das entradas criadas pelas séries de dados do pluviômetro base (330390617A) e do pluviômetro teste(330390613A). É possível observar expressiva perda de desempenho quando o modelo tem como entrada os dados do segundo pluviômetro, evidenciada pelo aumento de classificações FP, cujos reflexos são visíveis nas métricas dispostas na Tabela 5, especialmente na queda acentuada da *precision* e do F1-score. Portanto, evidencia-se a baixa capacidade de generalização espacial do modelo treinado.

Tabela 4: Matriz de confusão do modelo selecionado para a entrada da estação base e da oriunda da estação teste e distância relativa entre os pluviômetros

Estação	Distância (km)	True Positive	False Positive	True Negative	False Negative
Base	0	34	16	896	0
Teste	32,6	15	147	2992	0

Tabela 5: Métricas para a avaliação da generalização do modelo

Estação	Accuracy	Precision	Recall	F1-Score	FPR
Base	0,982	0,667	1	0,800	0,019
Teste	0,953	0,093	1	0,169	0,047

CONSIDERAÇÕES FINAIS

Entre os modelos testados, o *Multilayer Perceptron* (MLP) apresentou os melhores resultados, seguido pelo *Support Vector Machine* (SVM) e pelo *Random Forest* (RF). Portanto, demonstrando potencial para sua aplicação em LEWS baseados unicamente em dados pluviométricos.

Contudo, o modelo baseado em MLP se demonstrou não generalizável. Isso reforça a necessidade de treinar múltiplos modelos, considerando a diversidade de especificidades locais, para a construção de LEWS de maior abrangência espacial e efetividade operacional.

O uso de abordagens baseadas em dados tem se mostrado uma metodologia eficaz para o desenvolvimento de LEWS, sendo a qualidade do modelo diretamente influenciada pela quantidade e qualidade dos dados disponíveis. Assim, a criação de inventários de



deslizamentos no Brasil é uma medida urgente e essencial para o aprimoramento da gestão de riscos.

AGRADECIMENTOS

Os autores agradecem a bolsa de estudos do primeiro autor deste trabalho fornecida pelo Conselho Nacional de Pesquisa e Desenvolvimento Tecnológico referente ao projeto: Desenvolvimento do Sistema de ALerta Antecipado para Deslizamentos – SALAD Projeto, processo CNPq 446162/2023–0. Também gostaríamos de agradecer à Secretaria Municipal de Proteção e Defesa Civil (SEMPDEC) de Petrópolis pelo fornecimento dos registros de ocorrências relacionadas a deslizamentos de terra.

REFERÊNCIAS

COM 178 mortos, tragédia em Petrópolis é a maior já registrada na história do município. **GI**, 22 Feb. 2022. Available at: <https://g1.globo.com/rj/rio-de-janeiro/noticia/2022/02/20/tragedia-em-petropolis-maior-registrada-na-historia-o-municipio.ghtml>. Data de acesso: Accessed on: 23 jul. 2025.

GUERRA, A. J. T.; GONÇALVES, L. F. H.; LOPES, P. B. M. EVOLUÇÃO HISTÓRICO-GEOGRÁFICA DA OCUPAÇÃO DESORDENADA E MOVIMENTOS DE MASSA NO MUNICÍPIO DE PETRÓPOLIS, NAS ÚLTIMAS DÉCADAS **Revista Brasileira de Geomorfologia**. [S.l.: S.n.].

GUZZETTI, F. *et al.* **Geographical landslide early warning systems**. **Earth-Science Reviews** Elsevier B.V., 1 jan. 2020.

KANG, J. *et al.* Research on machine learning forecasting and early warning model for rainfall-induced landslides in Yunnan province. **Scientific Reports**, v. 14, n. 1, 1 dez. 2024.

LIU, Y. *et al.* Research on a Regional Landslide Early-Warning Model Based on Machine Learning—A Case Study of Fujian Province, China. **Forests**, v. 13, n. 12, 1 dez. 2022.

MENDES, R. M. *et al.* Proposição de limiares críticos ambientais para uso em sistema de alertas de deslizamentos. **Geography Department University of Sao Paulo**, v. 40, p. 61–77, 24 dez. 2020.

MICHOUD, C. *et al.* Experiences from site-specific landslide early warning systems. **Natural Hazards and Earth System Sciences**, v. 13, n. 10, p. 2659–2673, 2013.

MONDINI, A.C.; GUZZETTI, Fausto; MELILLO, Massimo. Deep learning forecast of rainfall-induced shallow landslides. **Nature Communications**, v. 14, n. 1, 1 dez. 2023.

OZTURK, U. *et al.* How climate change and unplanned urban sprawl bring more landslides. **Nature**, v. 608, n. 7922, p. 262–265, 11 ago. 2022.

PICIULLO, L.; CALVELLO, M.; CEPEDA, J. M.. **Territorial early warning systems for rainfall-induced landslides**. **Earth-Science Reviews** Elsevier B.V., 1 abr. 2018.

(**PREFEITURA MUNICIPAL DE) PETRÓPOLIS**. *Plano de contingência para chuvas intensas: verão 2024/2025*. 3. ed. [S.l.]: Secretaria Municipal de Proteção e Defesa Civil, 2025. 03 jan. 2025.

TEHRANI, F; S. *et al.* Machine learning and landslide studies: recent advances and applications. **Natural Hazards**, v. 114, n. 2, p. 1197–1245, 1 nov. 2022.