

ESTUDO DA SUSCETIBILIDADE A ESCORREGAMENTOS NA PORÇÃO SUDESTE DE BELO HORIZONTE: UMA ABORDAGEM BASEADA EM REGRESSÃO LOGÍSTICA

Denise de Fátima Santos da Silva ¹; Maria Giovana Parizzi ²; Allan Erlikhman Medeiros Santos ³; Elaine Aparecida Santos da Silva ⁴

Resumo – Este estudo aplicou um modelo de regressão logística para mapear a suscetibilidade a escorregamentos em Belo Horizonte, utilizando variáveis geomorfológicas, hidrológicas e geológicas. O modelo, treinado com dados históricos (2012–2022) apresentou acurácia de 79% e AUC-ROC de 0,88, demonstrando boa capacidade preditiva. A análise revelou que áreas com rochas do Grupo Sabará e elevada declividade são mais propensas a deslizamentos. Comparado a trabalhos anteriores, o modelo mostrou que a seleção criteriosa de variáveis e ajuste de hiperparâmetros podem melhorar a generalização, mesmo com número menor de preditores. O mapa final classificou a suscetibilidade em quatro níveis (Baixa, Moderada, Alta e Muito Alta), identificando regiões críticas próximas a lineamentos estruturais e encostas íngremes. A abordagem, de baixo custo e replicável, é útil para gestão de riscos, especialmente em regiões com limitações econômicas. Contudo, a taxa de falsos negativos (21%) indica a necessidade de incorporar mais dados em estudos futuros. O trabalho reforça o potencial da inteligência artificial nas geociências e destaca a importância de modelos preditivos para mitigação de desastres em áreas urbanas vulneráveis.

Abstract – This study applied a logistic regression model to map landslide susceptibility in Belo Horizonte, using geomorphological, hydrological, and geological variables. The model, trained with historical data (2012–2022), achieved an accuracy of 79% and an AUC-ROC of 0.88, demonstrating good predictive capability. The analysis revealed that areas with rocks from the Sabará Group and steep slopes are more prone to landslides. Compared to previous studies, the model showed that a careful selection of variables and hyperparameter tuning can improve generalization, even with a smaller number of predictors. The final map classified susceptibility into four levels (Low, Moderate, High, and Very High), identifying critical regions near structural lineaments and steep slopes. This low-cost and replicable approach is useful for risk management, especially in economically constrained regions. However, the false negative rate (21%) indicates the need to incorporate more data in future studies. This work reinforces the potential of artificial intelligence in geosciences and highlights the importance of predictive models for disaster mitigation in vulnerable urban areas.

Palavras-Chave – Suscetibilidade; regressão logística; Belo Horizonte.

¹ Eng., PhD, Universidade Federal de Minas Gerais, (31) 03409-4450, denisefss@yahoo.com.br

² Geól., PhD, Universidade Federal de Minas Gerais, (31) 3409-5442, mgparizzi18@gmail.com

³ Eng., PhD, Universidade Federal de Ouro Preto, (31) 3559-1590, allan.santos@ufop.edu.br

⁴ Eng., Esp., Universidade Federal de Minas Gerais, (31) 03409-4450, elainelako@gmail.com

1. INTRODUÇÃO

Áreas com registro de escorregamentos no passado são frequentemente usadas para avaliar a suscetibilidade a novos eventos, uma vez que os mesmos fatores ambientais podem desencadear futuros deslizamentos próximo a esses locais (Pourghasemi et al. 2012, Huang e Zhao 2018). O mapeamento da suscetibilidade a escorregamentos depende de um conhecimento bastante complexo dos eventos, dos fatores condicionantes e a relação entre eles. A confiabilidade desses mapas 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).

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). Entretanto, por se tratar de um processo demorado, os métodos automatizados baseadas em técnicas de sensoriamento remoto são altamente utilizados nos últimos anos para a identificação destes eventos (Wang et al. 2021). Devido à sua capacidade notável de lidar com grandes volumes de dados e padrões complexos, as técnicas de aprendizado de máquina têm sido utilizadas recentemente na prevenção de deslizamentos para resolver com acurácia e eficiência estes problemas (Ma et al. 2021; Merghadi et al. 2020).

Deste modo, o trabalho aqui apresentado apresenta o resultado de um modelo de previsão de escorregamentos para o município de Belo Horizonte. Este modelo foi proposto utilizando a técnica de regressão logística, a partir de dados disponibilizados pelos órgãos da administração pública e registros históricos obtidos de noticiários de meios de comunicação, sobretudo portais eletrônicos.

Este estudo se justifica pelo fato da região de Belo Horizonte ser um local de grande urbanização e possuir várias áreas de risco de movimentos de massa com elevado número de ocorrências, conforme destacado nos trabalhos de Parizzi (2004), Peixoto (2004), Parizzi et al. (2004), Parizzi et al. (2010), Parizzi et al. (2011), Reis Jr. e Parizzi (2018) e Garcia et al. (2023). Além disso, a aplicabilidade do modelo proposto, mesmo com adaptações, em outras regiões, especialmente aquelas de menor poder econômico, é uma vantagem significativa, uma vez que essa técnica é considerada de baixo custo.

2. ÁREA DE ESTUDO

A capital do estado de Minas Gerais, Belo Horizonte, está localizada na região sudeste do Brasil e abrange uma área de 331,35 km² com uma população estimada de 2,3 milhões de habitantes (IBGE 2023). Segundo Silva et al. (1995) a região que abrange o Complexo Belo Horizonte que constitui cerca de 70% do território de Belo Horizonte e é limitado a sul pela Serra do Curral, sendo constituído predominantemente por gnaisses. Já a porção sudeste da área de estudo está inserida no Quadrilátero Ferrífero (QF) e caracteriza-se pela diversidade litológica expressa por uma sucessão de camadas de rochas metassedimentares. Além disso, a área apresenta depósitos terciários e quaternários ocorrem como sedimentos lacustres, aluvionares, depósitos de talus, colúvios e canga (Silva et al. 1995; Parizzi 2004; Sotero et al. 2020).

Distribuída em extensa faixa de direção geral NE-SW, com mergulho preferencial para sudeste, a área estuda abrange a sequência metassedimentar do QF, e constitui de rochas das unidades dos Grupos Itabira, Piracicaba e Sabará, conforme apresentado por Parizzi (2004). A Figura 1 apresenta a localização da área de estudo, região sudeste do município de Belo Horizonte.




Figura 1. Localização da área de estudo (adaptado de Silva 2024).

3. METODOLOGIA

Este estudo utilizou dados provenientes de quatro fontes principais: registros de deslizamentos fornecidos pela Defesa Civil de Belo Horizonte e pela Companhia Urbanizadora e de Habitação de Belo Horizonte (Urbel), eventos catalogados por Silva et al. (2023) a partir de noticiários, e bases cartográficas. As três primeiras fontes documentam ocorrências de deslizamentos no período entre 2012 e 2022. As bases cartográficas correspondem aos dados topográficos, geológicos e hidrológicos, sendo a maior parte subproduto do MDT do município de Belo Horizonte.

Para construir o modelo de regressão logística, utilizou-se 3.036 pontos formado a partir do centroide do pixel representativo, com resolução espacial de 12,5 m x 12,5 m. Além disso, uma amostra aleatória de pontos sem deslizamento, igual à quantidade de pontos com deslizamento foi gerada, para evitar um desequilíbrio de classificação e um resultado enviesado do modelo. Estes pontos gerados representam locais sem ocorrências, com restrições para corpos d'água e polígonos de ocorrência de movimento de massa com um buffer externo de 50 m. Isso totalizou um inventário composto por 6.072 pontos inventariados com registros de locais classificados como estáveis (Target = "0") e instáveis (Target = "1").

Além da variável dependente, a avaliação de suscetibilidade requer informações sobre os fatores que podem explicar a ocorrência/ausência de deslizamentos. As variáveis preditivas são os fatores condicionantes de deslizamento usados como entrada para a previsão. Para a elaboração do modelo este estudo considerou um total de 6 variáveis (geomorfológicas hidrológicas e geológicas) apresentadas na Tabela 1.

Tabela 1. Visão geral das variáveis preditivas selecionadas.

Fatores	Variável	Tipo	Referência
Geomorfológicos	Elevação	Contínua	1
	Declividade	Contínua	1
	Orientação das Encostas	Categórica	1
Hidrológicos	Distância das drenagens	Contínua	1
Geológicos	Litologia	Categórica	2
	Distância dos lineamentos	Contínua	1

1 - Alos Palsar DEM (ASF, 2011) com resolução espacial de 12,5m; 2 - Prodabel (2007) com escala 1:100000.

O fluxograma (Figura 2) apresenta a metodologia relativa à aplicação da regressão logística. Nela é apresentada as várias etapas do problema, começando com a definição do problema para aprendizado de máquina como um problema binário de classificação (deslizamento/não deslizamento), seguido de seleção e aquisição de dados, e a preparação das variáveis. Em seguida, o modelo de regressão logística foi configurado, avaliado e validado.




Figura 2. Quadro esquemático ilustrando as etapas metodológicas adotadas neste estudo.

Para criação do modelo de suscetibilidade foi confeccionado um *script* em linguagem de programação Python. Após a limpeza do banco de dados e a normalização das variáveis o banco de dados foi dividido aleatoriamente em um conjunto de treinamento (70% dos dados) e um conjunto de teste (30%), estratificado por classes, para garantir que exista a mesma quantidade de amostras de deslizamento e não deslizamento em ambos os conjuntos. Além disso, foi utilizado o parâmetro “Random_state = 42” para definir uma semente fixa para a geração de números aleatórios.

O pré-processamento dos dados foi realizado mediante um “ColumnTransformer” do *Scikit-Learn*, que aplicou transformações distintas a variáveis categóricas e numéricas. As primeiras foram codificadas via “OneHotEncoder” (binarização de categorias), enquanto as últimas foram padronizadas com “StandardScaler” (média=0, desvio=1). Essa abordagem assegura a compatibilidade dos dados com algoritmos sensíveis à escala e à natureza das variáveis.

Para lidar com o desbalanceamento entre as classes do conjunto de treinamento, aplicou-se a técnica de *undersampling* através do RandomUnderSampler. O método reduz aleatoriamente amostras da classe majoritária, equilibrando-as com a classe minoritária, preservando apenas os dados de treino para evitar vazamento de informação. Para otimizar o desempenho dos modelos, realizou-se o ajuste de hiperparâmetros através do método *Grid Search* (busca em grade). Esta abordagem sistemática permite avaliar exaustivamente diversas combinações de parâmetros, identificando aquela que proporciona os melhores resultados preditivos.

A partir do *Grid Search*, um conjunto de hiperparâmetros candidatos foi escolhido, e os modelos foram construídos para cada combinação possível dos valores escolhidos. A validação cruzada com 10 partições foi utilizada para avaliar cada combinação distinta de valores dos parâmetros, a fim de analisar o desempenho de cada candidato. Dessa forma, selecionou-se a combinação de hiperparâmetros que demonstrou o melhor desempenho para o modelo final. Esta configuração otimizada foi então implementada no treinamento do modelo através de um *pipeline* de classificação, utilizando como estimador principal a Regressão Logística (LogisticRegression). Os valores específicos dos hiperparâmetros obtidos através do *Grid Search* está apresentada na Tabela 2.

Tabela 2. Parâmetros utilizados no modelo de suscetibilidade.

Parâmetro	Valor utilizado	Significado
C	= 10	controla a intensidade da regularização para prevenção de <i>overfitting</i>
classifier__penalty	= 'l2'	regularização de norma euclidiana
classifier__solver	= 'lbfgs'	(“Limited-memory Broyden-Fletcher-Goldfarb-Shanno”) para ajuste dos pesos do modelo durante o treinamento

Após a classificação por regressão logística, o desempenho do modelo foi avaliado mediante matriz de confusão, métricas de acurácia e Kappa de Cohen, e análise da curva ROC. As probabilidades de suscetibilidade resultantes foram classificadas em quatro níveis: Muito Alta, Alta, Média e Baixa, utilizando o método de quebras naturais, como realizado no trabalho de Pourghasemi et al. (2013).

4. RESULTADOS E DISCUSSÕES

Para investigar os dados mais detalhadamente em relação a variáveis correlacionadas, a fim de evitar informações redundantes, foi calculada uma matriz de correlação, como pode ser observado na Figura 3.




Figura 3. Matriz de correlação das variáveis numéricas utilizadas no estudo.

Para apresentar a distribuição dos dados utilizados na modelagem, a Figura 4 mostra o *boxplot* e os gráficos de barras com a distribuição dos valores de cada atributo do terreno para a área estudada. Os gráficos consideram todo o conjunto amostral, que é dividido em duas categorias: ocorrência e não ocorrência de escorregamentos.




Figura 4. Análise exploratória das variáveis. Onde: 0: Depósito aluvial, 1: Canga, 2: Depósito de tálus, 3: Grupo Sabará, 4: Formação Barreiro, 5: Formação Taboões, 6: Formação Fecho do Funil, 7: Formação Cercadinho, 8: Formação Cauê, 9: Formação Gandarela Indiviso, 10: Itabiritos da Formação Gandarela, 11: Dolomitos da Formação Gandarela, 12: Gnaisses e migmatitos do Complexo Belo Horizonte, 13: Gnaisses de granulação grossa do Complexo Belo Horizonte, 14: Gnaisses miloníticos do Complexo Belo Horizonte, 15: Rochas básicas ou metabásicas, 16: Rochas metaultrabásicas, 17: Granitoide do Grupo Sabará.

Os dados indicam que as áreas propensas a escorregamentos tendem a apresentar menores elevações, encostas mais íngremes, em comparação com as áreas sem escorregamentos. A dispersão dos valores (desvio padrão) é geralmente maior nas áreas sem escorregamentos, indicando maior variabilidade nas características do terreno. As orientações NW-N-NE são os mais frequentes tanto nas áreas com quanto sem escorregamentos, sugerindo que esse atributo pode ser comum independentemente da ocorrência de escorregamentos.

As rochas do Grupo Sabará são a litologia mais dominante, especialmente nas áreas propensas a escorregamentos. As litologias lateríticas e a Formação Gandarela também se destacam, embora esta última seja mais comum em áreas sem escorregamentos. A litologia parece ter uma associação mais forte com a ocorrência de escorregamentos, com certas litologias do Grupo Sabará apresentando uma maior frequência de deslizamentos.

Após o treinamento do modelo, foi realizada uma avaliação completa utilizando a matriz de confusão e a confecção da curva ROC conforme demonstrado na Figura 5. A matriz de confusão revelou um desempenho equilibrado, com recall de 79% para ambas as classes, indicando que o modelo não apresenta viés significativo. Contudo, os 21% de falsos negativos (100 casos) merecem atenção, especialmente se subestimar áreas de risco for crítico. A acurácia global (79%) demonstrou a eficácia do modelo.




Figura 5. Curva ROC do modelo de regressão logística.

O modelo apresentou alto poder discriminativo, com uma AUC-ROC de 0,88, indicando excelente capacidade de distinguir entre as classes. Essa métrica reforça os resultados observados na matriz de confusão, que mostrou um recall equilibrado de 79% para ambas as classes, sem viés evidente. O Kappa de Cohen ($K = 0,56$) indica uma concordância moderada entre as previsões do modelo e os dados reais, considerando a possibilidade de acerto ao acaso. Esse valor reforça que o modelo tem desempenho superior a um classificador aleatório. Recomenda-se investigar técnicas para reduzir erros, como ajuste de limiares ou inclusão de variáveis adicionais. A Tabela 3 sumariza as métricas de avaliação do modelo.

Tabela 3. Métricas de avaliação para o modelo.

Métricas	Precisão	Recall	F1-score	Quantidade
Não ocorrência	0,68	0,79	0,73	275
Ocorrência	0,87	0,79	0,83	484
Acurácia (teste)		0,80		759
Acurácia (treino)		0,78		759
Índice Kappa			0,56	
ROC (AUC)			0,88	

Neste trabalho foi analisado a mesma área de estudo e mesma técnica utilizada para modelagem da suscetibilidade a ocorrência de deslizamentos de Silva (2024), porém, com modificações que impactaram o treinamento e os resultados do modelo. Enquanto Silva (2024)

usou parâmetros menos regularizados ($C=1000$, $\text{fit_intercept}=\text{False}$) e mais iterações ($\text{max_iter}=1500$), aumentando o risco de overfitting, o modelo aqui proposto adotou regularização mais forte ($C=10$), incluiu intercepto ($\text{fit_intercept}=\text{True}$) e menos iterações ($\text{max_iter}=1000$), resultando em convergência mais estável. Essa abordagem gerou um modelo ligeiramente mais generalizável, com maior acurácia em teste (80% vs. 78,5%) e AUC superior (0,88 vs. 0,87).

Embora Silva (2024) utilizasse mais variáveis (10 vs. 6), o modelo aqui analisado obteve desempenho similar, mostrando que a seleção criteriosa de preditores e a regularização adequada são mais relevantes que a quantidade de variáveis. O Índice Kappa (0,56 vs. 0,55) e o F1-score para a classe "Ocorrência" (0,83 vs. 0,82) foram ligeiramente melhores, indicando equilíbrio entre precisão e recall. Ambos os modelos, no entanto, mantêm concordância moderada, sugerindo espaço para melhorias. Assim, os resultados demonstraram que, em problemas de classificação de deslizamentos, simplificar o modelo com variáveis mais relevantes e ajustar a regularização é mais eficaz que incluir muitos preditores sem otimização.

Finalmente, para determinar os intervalos das classes de suscetibilidade, o classificador Natural Break foi utilizado, o que resultou na representação de suscetibilidade a deslizamentos por 4 classes: Muito alta, Alta, Moderada e Baixa. O mapa de classificação da suscetibilidade do modelo estudado pode ser visualizado na Figura 6.




Figura 6. Mapa de suscetibilidade a deslizamentos.

No domínio das rochas metassedimentares do QF, os pontos de maior suscetibilidade estão frequentemente associados às rochas do Grupo Sabará. Regiões com suscetibilidade moderada a alta geralmente estão próximas aos lineamentos estruturais. A região da Serra do Curral também apresenta baixos valores de suscetibilidade a deslizamentos, uma vez que os eventos predominantes nessa região são quedas de blocos, influenciadas pela orientação das descontinuidades em direção ao município de Nova Lima.

No entanto, localmente, ainda podem ocorrer episódios de enxurradas e deslocamento de detritos. Estas movimentações podem ocorrer devido à alta declividade da face da escarpa da Serra do Curral no lado de Belo Horizonte, onde os fluxos de água pluvial escorrem em alta velocidade, perpendicularmente ao alinhamento da serra.

5. CONCLUSÕES

Este estudo demonstrou a eficácia da regressão logística como ferramenta para o mapeamento de suscetibilidade a escorregamentos em Belo Horizonte, utilizando um conjunto de variáveis geomorfológicas, hidrológicas e geológicas. O modelo apresentou desempenho satisfatório, com uma acurácia de 79% e AUC-ROC de 0,88, indicando boa capacidade preditiva. A análise comparativa com o trabalho de Silva (2024) evidenciou que a seleção criteriosa de variáveis e a otimização dos hiperparâmetros podem gerar resultados satisfatórios, mesmo com um número menor de preditores.

Os resultados destacaram a influência significativa da litologia (especialmente o Grupo Sabará) e da declividade na ocorrência de deslizamentos, corroborando estudos anteriores na região. Além disso, o mapa de suscetibilidade gerado permitiu identificar áreas críticas, principalmente em encostas íngremes e próximas a lineamentos estruturais, fornecendo subsídios para políticas públicas de prevenção e gestão de riscos.

A metodologia adotada, mostrou-se viável para aplicação em outras regiões, especialmente em locais com limitações de recursos. Contudo, a presença de falsos negativos (21%) reforça a necessidade de aprimoramentos futuros, como a inclusão de variáveis adicionais e verificação de campo.

Por fim, este trabalho contribui para o avanço da aplicação de inteligência artificial nas geociências, incentivando novas pesquisas que integrem dados multidisciplinares para melhorar a previsão e mitigação de desastres naturais. A continuidade desse tipo de estudo é essencial para reduzir os impactos socioeconômicos dos escorregamentos em áreas urbanas vulneráveis.

AGRADECIMENTOS

Os autores agradecem a CAPES pelo fomento à pesquisa, ao Instituto de Geociências da Universidade Federal de Minas Gerais e o PPG em Geologia pelo suporte oferecido.

REFERÊNCIAS

- ALASKA SATELLITE FACILITY (ASF). 2011. Alaska Satellite Facility. ALOS PALSAR DEM. Available at: <https://search.asf.alaska.edu> (accessed 12 Oct. 2020).
- 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
- BAEZA, C., COROMINAS, J. 2001. Assessment of shallow landslide susceptibility by means of multivariate statistical techniques. *Earth Surf Proc Landf* 26:1251–1263.
- GARCIA, L. C., VIANA, J. N. L., & LIMA, C. M. S. (2023). Gestão de risco, vulnerabilidade ambiental e a questão climática na gestão metropolitana. *Cadernos Metrópole*, 25(58), 875–897.
- GUZZETTI, F., MONDINI, A.C., CARDINALI, M., FIORUCCI, F., SANTANGELO, M., CHANG, K. (2012). Landslide inventory maps: New tools for an old problem. *Earth-Science Reviews*, 112(1–2): 42–66.
- HUANG, Y., ZHAO, L. 2018. Review on landslide susceptibility mapping using support vector machines. *CATENA* 165:520–529.
- IBGE. 2023. Coordenação Técnica do Censo Demográfico. Censo Demográfico 2022: população e domicílios: primeiros resultados (Série Censo Demográfico; v. 1). Rio de Janeiro: IBGE.
- MA, Z., MEI, G. PICCIALLI, F. Machine learning for landslides prevention: a survey. *Neural Comput & Applic* 33, 10881–10907 (2021).

- 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.*, 207 (2020), Article 103225.
- NAIDU S, SAJINKUMAR KS, OOMMEN T, ANUJA VJ, SAMUEL RINU A, MURALEEDHARAN C (2018) Early warning system for shallow landslides using rainfall threshold and slope stability analysis. *Geosci Front*.
- PARIZZI, M.G. 2004. Condicionantes e Mecanismos de ruptura de taludes da região metropolitana de Belo Horizonte. Universidade Federal de Ouro Preto, UFOP. Tese de doutorado, 213 p.
- PARIZZI, M.G; SOBREIRA, F.G; GALVÃO, T.C.B.; TIMBÓ ELMIRO, M.A. 2004. Chuvas e deslizamentos de taludes em Belo Horizonte, MG. In Simpósio brasileiro de desastres naturais. Florianópolis: GEDN/UFSC. p. 29-43.
- PARIZZI, M.G., SEBASTIÃO, C.S., VIANA, C.S., PFLUEGER, M.C., CAMPOS, L.C., CAJAZEIRO, J.M.D., TOMICH, R.S., GUIMARÃES, R.N., ABREU, M.L., SOBREIRA, F.G. & REIS, R. 2010, 'Correlações entre chuvas e movimentos de massa no município de Belo Horizonte, MG', *Revista Geografias*, vol. 6, no. 2, pp. 49-68.
- PARIZZI, M. G., SOBREIRA, F. G., GALVÃO, T. C. B., ARANHA, P. R. A., ELMIRO, M. A. T. B., ELDER, A. B. Processos de movimentos de massa em Belo Horizonte, MG. *Geografias*, v. 07, p. 58-87, 2011.
- PARIZZI, M. G. Riscos geológicos e hidrológicos no município de Belo Horizonte, MG. *Revista Brasileira de Geologia de Engenharia e Ambiental (RBGEA)*, v. 11, p. 145-161, 2021.
- 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.
- POURGHASEMI, H., PRADHAN, B., GOKCEOGLU, C., & MOEZZI, K. D. (2013). A comparative assessment of prediction capabilities of Dempster–Shafer and Weights-of-evidence models in landslide susceptibility mapping using GIS. *Geomatics, Natural Hazards and Risk*, 4(2), 93–118.
- PREFEITURA MUNICIPAL DE BELO HORIZONTE. Base InterGeo da Empresa de Informática e Informação do Município de BH (PRODABEL). PRODABEL, 2007.
- PEIXOTO, R. P. Geoprocessamento Aplicado no Levantamento de Áreas de Risco Geológico em Zonas de Especial Interesse Social (ZEIS) Estudo de Caso: Vila Novo Ouro Preto - Belo Horizonte. Belo Horizonte. IGC/UFM. 2004. Monografia (Especialização em Geoprocessamento). 66 p.
- REIS JUNIOR, W E PARIZZI, M. G. Caracterização das unidades geotécnicas da porção leste da Região Metropolitana de Belo Horizonte – MG. *Geonomos*, 26(2), 23-30, 2018.
- SILVA, A. S., CARVALHO, E. T, FANTINEL, L. M., ROMANO, A. W., VIANA, C. S. 1995. Estudos Geológicos, Hidrogeológicos, Geotécnicos e Geoambientais Integrados no Município de Belo Horizonte. Convênio: PMBH, SMP, FUNDEP/ UFMG. 490p. (Relatório Final).
- SILVA, D.F.S., PARISI, M.G., SILVA, E.A.S., SILVA, G.A.R. 2023. Natural Disasters in the Metropolitan Region of Belo Horizonte: A Summary of Events Occurred in the Rainfall Period of 2019/2020. *Anuário do Instituto de Geociências*, 46:48923.
- SILVA, D. F. S. Proposta metodológica para a avaliação de suscetibilidade a escorregamentos: contribuições do aprendizado de máquina no município de Belo Horizonte, MG. 2024. 405 f., Tese (Doutorado em Geologia) – Universidade Federal de Minas Gerais, Instituto de Geociências, Belo Horizonte, 2024.
- SOTERO, M. P.; TOLENTINO, E. J. T.; OLIVEIRA, S. A. M.; SANT'ANA, L. P. Insumos minerais para a construção civil na região metropolitana de Belo Horizonte, estado de Minas Gerais. Belo Horizonte: CPRM, 2020. Escala 1:200.000.
- WANG, H.; ZHANG, L.; YIN, K.; LUO, H.; LI, J. Landslide identification using machine learning. *Geosci. Front.* 2021, 12, 351–364.