

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE  
GOIÁS  
CÂMPUS GOIÂNIA  
DEPARTAMENTO DE ÁREAS ACADÊMICAS III  
COORDENAÇÃO DE ENGENHARIA CARTOGRÁFICA E DE AGRIMENSURA

LAUDIER LOPES ABREU

**EXPLORANDO VARIÁVEIS TOPOGRÁFICAS NA  
ANÁLISE DE SUSCETIBILIDADE À EROSÃO  
LINEAR**

Goiânia, 2025.

## RESUMO

A erosão do solo, especialmente a erosão linear associada à formação de ravinas e voçorocas, representa uma ameaça significativa à produtividade agrícola, à estabilidade ambiental e ao desenvolvimento sustentável, contrariando diretrizes dos Objetivos de Desenvolvimento Sustentável (ODS) das Nações Unidas. Neste estudo, foi analisado a suscetibilidade à erosão por ravinas e voçorocas na região sudoeste de Goiás, utilizando um conjunto de variáveis topográficas não convencionais derivadas de um Modelo Digital de Terreno (MDT) – abordagem ainda subexplorada na literatura. Para isso, aplicou-se o algoritmo *Random Forest* para modelar a suscetibilidade, comparando a influência de variáveis topográficas tradicionais com métricas de rugosidade e complexidade do relevo menos exploradas. A metodologia empregou 5.660 amostras de erosões lineares mapeadas como polígonos, das quais foram extraídas as cabeceiras erosivas para treinamento do modelo. A validação do desempenho foi realizada por meio de amostras independentes correspondentes a 30% do total de dados. Os resultados desta pesquisa contribuirão para o avanço das técnicas de modelagem preditiva de erosão linear ao evidenciar o potencial informativo de variáveis geomorfométricas menos usuais na identificação de áreas suscetíveis à formação dessas erosões, fornecendo subsídios para estratégias mais eficazes de manejo e conservação do solo.

**Palavras-chave:** erosão linear; aprendizado de máquina; variáveis topográficas; mapas de suscetibilidade.

## **ABSTRACT**

Soil erosion, especially linear erosion associated with the formation of gullies and badlands, poses a significant threat to agricultural productivity, environmental stability, and sustainable development, contradicting the guidelines of the United Nations Sustainable Development Goals (SDGs). In this study, the susceptibility to gully and badland erosion in the southwest region of Goiás was analyzed using a set of unconventional topographic variables derived from a Digital Terrain Model (DTM)—an approach still underexplored in the literature. To achieve this, the Random Forest algorithm was applied to model susceptibility, comparing the influence of traditional topographic variables with less-explored metrics of roughness and terrain complexity. The methodology employed 5,660 mapped linear erosion samples represented as polygons, from which the erosive headwaters were extracted for model training. The performance validation was conducted using independent samples corresponding to 30% of the total dataset. The results of this research will contribute to the advancement of predictive modeling techniques for linear erosion by highlighting the informational potential of less commonly used geomorphometric variables in identifying areas susceptible to the formation of these erosions, providing support for more effective soil management and conservation strategies.

**Keywords:** linear erosion; machine learning; topographic variables; susceptibility maps.

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>8</b>
<b>2</b>	<b>OBJETIVO .....</b>	<b>11</b>
<b>3</b>	<b>METODOLOGIA .....</b>	<b>11</b>
<b>3.1</b>	<b>CARACTERIZAÇÃO DA ÁREA DE ESTUDO.....</b>	<b>11</b>
<b>4</b>	<b>AQUISIÇÃO DAS AMOSTRAS DE EROSÕES LINEARES .....</b>	<b>13</b>
<b>4.1</b>	<b>AQUISIÇÃO E PROCESSAMENTO DAS VARIÁVEIS.....</b>	<b>15</b>
<b>5</b>	<b>RESULTADOS .....</b>	<b>21</b>
<b>5.1</b>	<b>DESEMPENHO DA SELEÇÃO DE VARIÁVEIS .....</b>	<b>21</b>
<b>5.2</b>	<b>IMPORTÂNCIA DAS VARIÁVEIS .....</b>	<b>24</b>
<b>5.3</b>	<b>CENÁRIO 1.....</b>	<b>25</b>
<b>5.4</b>	<b>CENÁRIO 2 .....</b>	<b>25</b>
<b>5.5</b>	<b>CENÁRIO 3.....</b>	<b>26</b>
<b>6</b>	<b>DISCUSSÃO.....</b>	<b>27</b>
<b>7</b>	<b>CONCLUSÃO .....</b>	<b>28</b>
	<b>REFERÊNCIAS .....</b>	<b>30</b>

## 1 INTRODUÇÃO

As erosões lineares são uma fonte de degradação do solo, reduzindo a qualidade e a quantidade de solo arável, tanto em países desenvolvidos quanto em desenvolvimento (Valentin *et al.*, 2005; Boardman *et al.*, 2003). De acordo com a FAO (2015), a erosão é responsável pela perda de 25 a 40 bilhões de toneladas de solo por ano, o que reduz drasticamente a produtividade agrícola, a segurança alimentar e a capacidade de armazenamento de água e nutrientes no solo.

Esse fato pode contrastar negativamente com alguns dos objetivos propostos na cartilha dos Objetivos de Desenvolvimento Sustentável (ODS), estabelecidos pela Organização das Nações Unidas (ONU), tais como: Fome Zero e Agricultura Sustentável, Vida Terrestre, e Cidades e Comunidades Sustentáveis. Nesse contexto, mapas de suscetibilidade à erosão linear são ferramentas robustas para identificar áreas vulneráveis, planejar ações de conservação, controlar a erosão e promover o manejo sustentável do solo, mitigando os efeitos erosivos e favorecendo o desenvolvimento sustentável.

Com a evolução das técnicas de aprendizado de máquina, muitos estudos demonstraram a capacidade dos algoritmos de descobrir padrões em grandes conjuntos de dados (Zhang e Tsai, 2006). A combinação de aprendizado de máquina, sensoriamento remoto, dados geográficos e Sistemas de Informações Geográficas (SIG) permite a integração de múltiplas variáveis condicionantes, produzindo melhores resultados na predição de áreas suscetíveis à erosão por ravinas e voçorocas (Arabameri *et al.*, 2019; Arabameri *et al.*, 2020b).

Os fatores geoambientais que podem influenciar a erosão linear, incluem características geomorfológicas (topográficas), hidrológicas, litológicas, pedológicas e antropogênicas (Arabameri *et al.*, 2020a). Esses fatores são fundamentais na modelagem de processos erosivos, uma vez que afetam diretamente a dinâmica do escoamento hídrico e a capacidade erosiva da água. O entendimento desses fatores é essencial para o planejamento sustentável da conservação do solo e da água (Shit *et al.*, 2015).

Fatores geomorfológicos podem ser derivados de uma ampla gama de variáveis topográficas, que podem ser extraídas diretamente de um Modelo Digital de Elevação (MDE) em *softwares* de SIG, tais como declividade, orientação das vertentes (aspecto), curvatura e índice de posição topográfica. Essas características, frequentemente referidas na literatura como atributos ou variáveis topográficas, parâmetros de forma do terreno, informações do terreno ou atributos geomorfométricos (Pike *et al.*, 2009; Florinsky, 2016), fornecem descritores quantitativos da superfície terrestre.

Embora muitas variáveis topográficas sejam frequentemente usadas para avaliar a suscetibilidade à erosão, outras, menos exploradas, podem fornecer informações adicionais e aprimorar a qualidade dos modelos preditivos. Assim, a avaliação de variáveis menos comuns na modelagem da suscetibilidade à erosão linear, comparando sua importância com as variáveis mais frequentemente utilizadas na literatura, é uma lacuna ainda não explorada. Identificar variáveis condicionantes adicionais pode melhorar a eficácia dos modelos preditivos e contribuir para uma compreensão mais profunda dos processos erosivos.

O objetivo deste estudo é analisar o impacto de variáveis topográficas menos convencionais extraídas de um MDE na modelagem da suscetibilidade à erosão por ravinas e voçorocas, comparando sua relevância com as variáveis mais comumente utilizadas na literatura.

## **2 OBJETIVO**

- O objetivo desse estudo foi analisar o impacto de variáveis topográficas menos convencionais extraídas de um Modelo Digital de Terreno (MDT) na modelagem da suscetibilidade à erosão por ravinas e voçorocas, comparando sua relevância com as variáveis comumente utilizadas na literatura.

## **3 METODOLOGIA**

### **3.1 CARACTERIZAÇÃO DA ÁREA DE ESTUDO**

A área de pesquisa está situada na porção sudoeste do estado de Goiás, Brasil Central, abrangendo os municípios de Mineiros, Santa Rita do Araguaia, Perolândia e Portelândia, totalizando 12.002,35 km<sup>2</sup> (Figura 1). A região sudoeste do estado de Goiás apresenta uma concentração significativa de erosões lineares, que têm sido investigadas por diferentes autores e sob diferentes perspectivas (Marinho *et al.*, 2006; Nunes e Castro, 2015; Nunes e Castro, 2023; Carvalho e Castro, 2023). Contudo, ainda não foi avaliado quais variáveis, frequentemente utilizadas em mapas de suscetibilidade à erosão linear, desempenham papéis mais importantes.

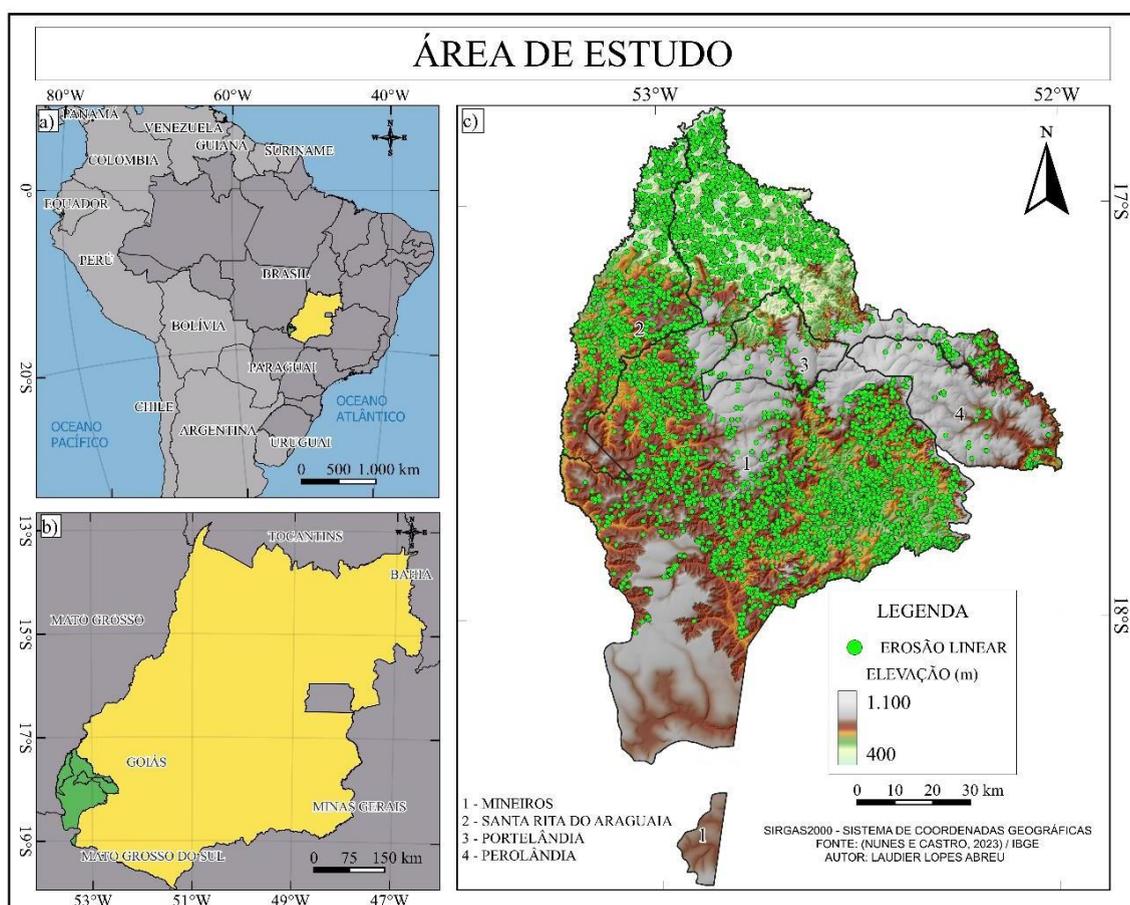
Essa região também foi selecionada devido ao mapeamento detalhado dos solos e erosões lineares, conforme Nunes e Castro (2015), Nunes e Castro (2023), que

categorizam os solos até o terceiro nível usando o Sistema Brasileiro de Classificação de Solos (SiBCS) (Santos *et al.*, 2018), em uma escala de 1:50.000, identificando predominantemente Latossolos, Argissolos e Neossolos Quartzarênicos, além de Neossolos Litólicos, Cambissolos e Gleissolos em menor proporção. O relevo é predominantemente plano, com declividades variando entre 3,45% e 8,84%, embora áreas isoladas apresentem declividades superiores a 45%.

A geologia local é composta por diversas rochas sedimentares, principalmente arenito e rochas intrusivas básicas, resultando em uma topografia escalonada. Na porção norte, predominam coberturas sedimentares fanerozoicas como arenitos, folhelhos e siltitos da Formação Aquidauana, alcançando altitudes de até 590 m. Faixas estreitas de arenitos e siltitos da Formação Corumbataí são locais de ocorrência de Neossolos próximos a cursos d'água. Nas médias encostas encontram-se Argissolos Vermelhos, enquanto nas encostas mais elevadas estão os Latossolos Vermelho-Amarelos próximos aos divisores de drenagem (IBGE, 2023).

Ao Sul, a fronteira entre estas unidades é marcada por rochas basálticas da Formação Serra Geral e folhelhos da Formação Irati, caracterizadas por maior declividade e rugosidade, com predominância de Neossolos Litólicos. Áreas intercaladas ao sul consistem em arenitos e siltitos da Formação Corumbataí. A região central é dominada por arenitos eólicos da Formação Botucatu, entre 500 e 1000 m de altitude, onde vastas extensões de Neossolos Quartzarênicos estão presentes, enquanto Latossolos Vermelhos e Vermelho-Amarelos predominam na porção oeste. No centro-leste e sul, há coberturas sedimentares fanerozoicas compostas por argilas, arenitos e depósitos de areia da Formação Cachoeirinha. Aqui, áreas predominantemente planas com encostas extensas são dominadas por Latossolos Vermelhos, com a presença de Gleissolos Háplicos próximos à rede de drenagem (Cremon *et al.*, 2021).

**Figura 1** – (a) *Localização da área de estudo no contexto nacional;* (b) *Localização no contexto estadual (Goiás);* (c) *Ampliação para os municípios com amostras de erosões lineares.*



**Fonte:** Autor (2024).

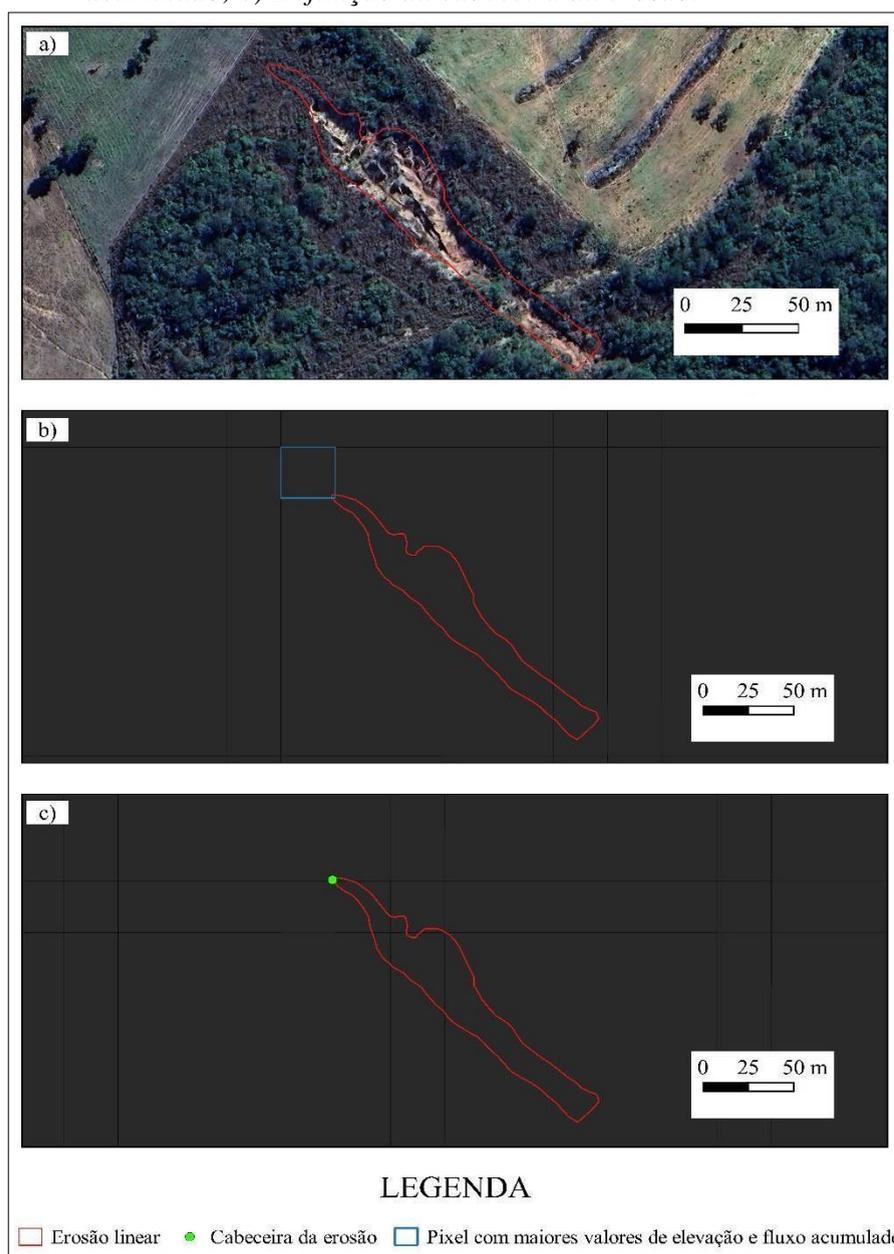
#### 4 AQUISIÇÃO DAS AMOSTRAS DE EROSÕES LINEARES

Para a área de estudo foram obtidas 5660 amostras de erosões lineares, inventariadas por interpretação visual no formato de polígonos, representando toda área do processo erosivo, com auxílio de imagens de sensoriamento remoto de sensores de melhor resolução espacial (Nunes e Castro, 2023), durante o ano de 2018.

No estudo de suscetibilidade as erosões lineares, a escolha das cabeceiras como foco de análise é fundamentada por razões geomorfológicas e hidrológicas, além de seu papel como local de início do processo erosivo (Valentin *et al.*, 2005). A cabeceira reflete de maneira direta os fatores desencadeantes da erosão, como características do solo, topográficas e padrões de escoamento superficial, sendo o ponto mais sensível à interação entre uso da terra e condições naturais.

Para tanto, foi realizada a correção geométrica dos polígonos e posteriormente, extraiu-se os vértices dessas feições corrigidas. Os vértices localizados em *pixels* com maiores valores altimétricos e de fluxo acumulado pelo método D8 (método que calcula a contribuição de fluxo de um *pixel* para o *pixel* adjacente na direção de maior declive de montante para jusante a partir do MDE) (O’Callaghan e Mark, 1984), determinando assim, os pontos de cabeceiras (Figura 2).

**Figura 2** – *Processamento para seleção da cabeceira das erosões lineares. a) Polígono do processo erosivo; b) Identificação automática do pixel com a maior elevação e fluxo acumulado; c) Definição da cabeceira da erosão.*



**Fonte:** Autor (2024).

Em função dos pontos de presença de erosão, foram definidos os pontos

de ausência e assumidos como não-erosão. Portanto, foram gerados um conjunto de pontos de ausência com distância mínima de 1000 metros em relação as amostras de ocorrência. As amostras foram classificadas com valor '0' para as ausências e valor '1' para a presença de erosão linear. É importante salientar que a distribuição desses pontos de ausência é aleatória, seu arranjo espacial influencia diretamente no resultado da modelagem efetuada.

#### 4.1 AQUISIÇÃO E PROCESSAMENTO DAS VARIÁVEIS

O estudo utilizou um amplo conjunto de variáveis topográficas como variáveis independentes para inferir locais suscetíveis a erosão linear, derivadas diretamente do *Forest And Building removed Copernicus Digital Elevation Model* (FABDEM) (Hawker *et al.*, 2022). Este Modelo Digital de Terreno (MDT) está disponível em coordenadas geográficas, com o Sistema Geodésico de Referência WGS-84 e um tamanho de *pixel* de 1 segundo de arco. O FABDEM é derivado do Modelo Digital de Superfície (MDS) Copernicus e representa os melhores dados altimétricos gratuitos disponíveis para o contexto da área de estudo (Cremon *et al.*, 2022; Bielski *et al.*, 2024). Esses dados foram reprojatados para coordenadas métricas no sistema de coordenadas Universal Transverse Mercator (UTM), zona 22 Sul, com o Sistema Geodésico de Referência SIRGAS2000, e um tamanho de *pixel* de 30 metros, utilizando a convolução cúbica spline, seguindo as recomendações de Purinton e Bookhagen (2021), no *software* QGIS (QGIS Development Team, 2024).

Em seguida, o processo de correção do MDT foi realizado para eliminar vazios (*pits*), tornando o MDT hidrologicamente consistente, utilizando o pacote TerraHidro (Rosim *et al.*, 2011), que combina algoritmos para tratar áreas planas (*flat carving*) com o método *Priority-First Search* (PFS) (Jones, 2002). Essa integração entre *flat carving* e PFS permite que o MDT mantenha as feições topográficas e assegure um fluxo de drenagem contínuo, corrigindo problemas em áreas planas ou depressões que o método simples de preenchimento de depressões (*fill sinks*) não consegue solucionar.

Ao todo, foram derivadas 64 variáveis topográficas do FABDEM (Figura 3) que foi realizada utilizando algoritmos disponíveis nos *softwares* GRASS GIS (GRASS Development Team, 2024), SAGA-GIS (Conrad *et al.*, 2015), QGIS (QGIS Development Team, 2024) e Whitebox (Lindsay, 2016), bem como nos pacotes TAK para a linguagem MATLAB (Forte e Whipple, 2019) e *SurfRough* (Trevisani *et al.*, 2023) e Terra (Hijmans, 2024) para a linguagem R. Para facilitar o entendimento e a interpretação dessas variáveis, elas foram agrupadas em categorias baseadas em suas características principais e funções geomorfométricas. Esses agrupamentos incluem: morfologia, que descreve aspectos geométricos da superfície; rugosidade, que reflete

a complexidade e irregularidade da superfície; posição topográfica relativa, que se refere à elevação de um ponto em relação aos seus arredores ou a outros locais de referência; e variáveis hidrológicas e combinadas, que integram características da superfície a processos hidrológicos, incluindo a combinação de mais de uma variável para a criação de novas variáveis (Figura 3). Apesar do esforço de categorização, algumas variáveis apresentam características que permitem seu enquadramento em mais de uma categoria, evidenciando a sobreposição de propriedades e a multifuncionalidade dessas variáveis topográficas.

**Figura 3** – Tipo de variáveis topográficas utilizadas nesse estudo e software de processamento.

Variáveis associadas a morfologia	Variáveis associadas a rugosidade	Variáveis associadas com a posição topográfica relativa	Hidrologia e/ou variáveis combinadas
Aspect <sup>WB</sup>	Average Normal Vector	Deviation from mean elevation (21) <sup>WB</sup>	Average Upslope
Aspect (Pós processada pelo método do Topodata) <sup>SG</sup>	Angular Deviation <sup>WB</sup>	Difference from mean elevation (21) <sup>WB</sup>	Flowpath Length <sup>WB</sup>
Convergence index <sup>SG</sup>	Circular Variance of Aspect <sup>WB</sup>	Elevation	Catchment area /
Convergence index (21) <sup>SG</sup>	Edge density (21) <sup>WB</sup>	Elevation percentile (21) <sup>WB</sup>	Flow accumulation <sup>SG</sup>
Gaussian curvature <sup>WB</sup>	Entropy (21) <sup>GR</sup>	Local relief (21) <sup>GR</sup>	Chi ( $\chi$ ) <sup>TAK</sup>
Geomorphons <sup>GR</sup>	Max. anisotropy in elevation deviation (ML) <sup>WB</sup>	Max Difference From Mean (ML) <sup>WB</sup>	Downslope Distance <sup>SG</sup>
Maximal curvature <sup>WB</sup>	Multiscale Roughness (21) <sup>WB</sup>	Max Downslope Elev Change <sup>WB</sup>	Downslope Index <sup>WB</sup>
Mean curvature <sup>WB</sup>	Multiscale Std Dev Normals (ML) <sup>WB</sup>	Max Elevation Deviation (ML) <sup>WB</sup>	Index for Lowlands (TCI Low) <sup>SG</sup>
Minimal curvature <sup>WB</sup>	Roughness Concentration Index (RCI) (21) <sup>QG</sup>	Mid Slope Positon <sup>SG</sup>	Ksn <sup>TAK</sup>
Multiresolution index of the ridge top flatness (ML) <sup>SG</sup>	Radial Roughness Index (RRI) (21) <sup>R</sup>	Min Downslope Elev Change <sup>WB</sup>	LS fator <sup>SG</sup>
Multiresolution Index of Valley Bottom Flatness (ML) <sup>SG</sup>	Spherical Std Dev Of Normals (21) <sup>WB</sup>	Multiscale Elevation Percentile (ML) <sup>WB</sup>	Max Branch Length <sup>WB</sup>
Negative Openness <sup>SG</sup>	Standard Deviation Of Slope (21) <sup>WB</sup>	Slope Height <sup>SG</sup>	Max upslope flowpath length <sup>WB</sup>
Plan Curvature <sup>WB</sup>	Terrain Ruggedness Index (TRI) (21) <sup>WB</sup>	Topographic Position Index (TPI) (21) <sup>SG</sup>	SAGA TWI <sup>SG</sup>
Plan Curvature (Pós processada pelo método do Topodata) <sup>SG</sup>	Terrain Surface Texture (21) <sup>SG</sup>	Valley Depth <sup>SG</sup>	Stream Power Index <sup>SG</sup>
Positive Openness <sup>SG</sup>	Topographic coherence (21) <sup>R</sup>	Vertical Distance to Channel Network (VDCN) <sup>SG</sup>	TWI <sup>SG</sup>
Profile Curvature <sup>SG</sup>	Vector Ruggedness Measure (VRM) (21) <sup>SG</sup>		
Profile Curvature (Pós processada pelo método do Topodata) <sup>SG</sup>			
Slope <sup>WB</sup>			
Tangential curvature <sup>WB</sup>			

Processado em:

-  <sup>SG</sup> SAGA GIS
-  <sup>WB</sup> WhiboxTools
-  <sup>GR</sup> GRASS GIS
-  <sup>QG</sup> QGIS
-  <sup>TAK</sup> Topographic Analysis Kit (TAK) do TopoToolbox
-  <sup>R</sup> R

(21) Baseado em um filtro de 21 pixels, i.e., 630m  
(MS) Baseado em algoritmo multiescala

**Fonte:** Autor (2024).

Devido ao grande número de variáveis testadas neste estudo para o mapeamento de suscetibilidade à ocorrência de erosão linear, foram avaliadas duas abordagens para seleção de variáveis: o *Variance Inflation Factor* (VIF) e o algoritmo *Recursive*.

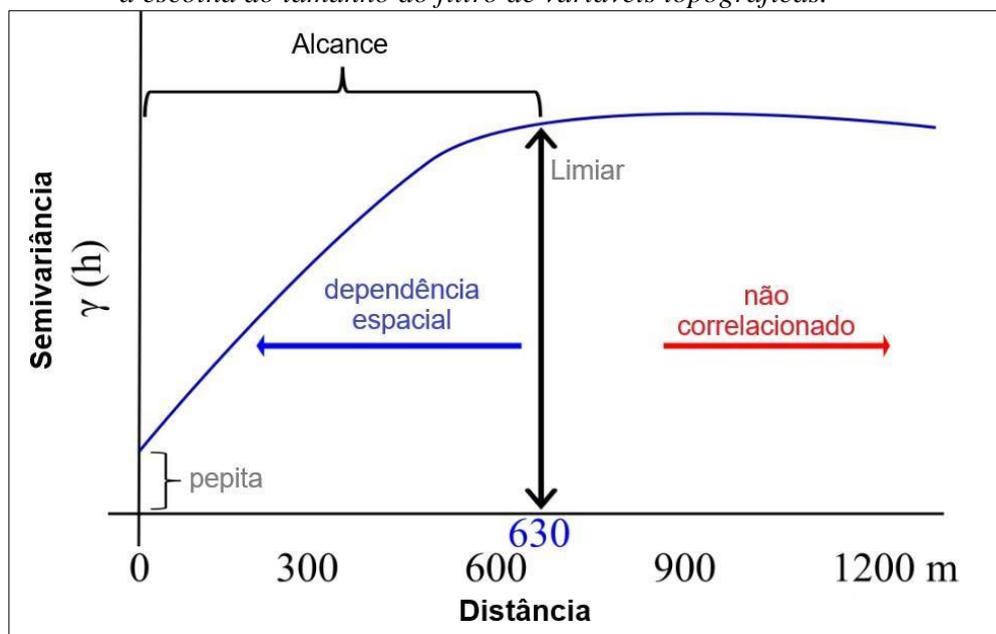
*Feature Elimination* (RFE). Inicialmente, o VIF foi utilizado para identificar e eliminar variáveis com alta colinearidade. Este método, amplamente empregado para detectar redundâncias, descarta variáveis com VIF superior a 10, assegurando que apenas preditores independentes sejam mantidos no modelo, o que contribui para sua robustez e redução de redundâncias.

O modelo inicial foi ajustado com regressão logística, incluindo todos os fatores condicionantes. Em seguida, aplicou-se um processo de seleção iterativa, onde o VIF foi calculado para cada etapa, em que variáveis com VIF abaixo de 10 foram selecionadas para o próximo estágio do modelo, enquanto aquelas com valores acima deste limite foram eliminadas para reduzir redundâncias e garantir a independência das variáveis. Esse procedimento iterativo foi repetido até que todas as variáveis restantes apresentassem  $VIF < 10$ , resultando em um conjunto de variáveis sem problemas de multicolinearidade.

Em paralelo, foi aplicada a abordagem RFE, um algoritmo empregado para selecionar as variáveis mais relevantes para a variável alvo em um modelo preditivo, seja de regressão ou classificação, aplicando um processo de seleção regressiva para encontrar a combinação ideal (Kuhn e Johnson, 2019). O RFE elimina iterativamente as variáveis menos relevantes, retendo aquelas com maior poder preditivo para o algoritmo *Random Forest*. A aplicação do RFE com validação cruzada de 10 vezes permitiu selecionar um conjunto de variáveis mais informativas e eficazes na predição da suscetibilidade as erosões lineares. A combinação dessas duas abordagens, VIF e RFE, visou minimizar redundâncias e maximizar a relevância preditiva para o fenômeno em análise.

Para as variáveis topográficas que exigem a definição de um tamanho de filtro, foi adotado um valor de 21 *pixels*, correspondendo a 630 m, com base no MDE de 30 m de resolução horizontal. Essa escolha foi fundamentada no alcance médio (distância) de dependência espacial observado nos dados topográficos da área de estudo (Figura 4), conforme a análise variográfica (Cremon *et al.*, 2021). Assim, janelas de busca com raio de 21 *pixels* foram aplicadas para extrair os variáveis topográficas que requeriam a determinação de um tamanho de filtro.

**Figura 4** – Exemplo de semivariograma utilizado na determinação da dependência espacial dos dados de elevação para a escolha do tamanho do filtro de variáveis topográficas.



Fonte: Autor (2024).

No estudo de Mohebzadeh *et al.* (2022) foi realizada uma revisão das variáveis mais comumente utilizadas em pesquisas de suscetibilidade as erosões lineares. Em relação às variáveis topográficas, 14 variáveis foram listadas, incluindo a elevação, que reflete a altitude do terreno, e a orientação das vertentes (aspecto), que indica a direção para a qual a encosta está voltada. Também foram destacados a declividade e o fator LS, o produto entre a declividade e a área de contribuição/comprimento da vertente, variável utilizada na equação universal de perda de solos (USLE). Variáveis como área de contribuição (fluxo acumulado), curvatura, curvatura horizontal (curvatura plana), curvatura vertical (curvatura de perfil) e índice de convergência também foram consideradas, sendo úteis para compreender a convergência do fluxo e a acumulação de água em diferentes partes do terreno. Índices específicos, como o índice de potência do fluxo (*stream power index*) e o índice de umidade topográfica, fornecem informações sobre o potencial de erosão e a concentração de fluxo em áreas específicas. Outras variáveis topográficas, como o índice de rugosidade do terreno, o índice de posição topográfica e a textura da superfície do terreno, ajudam a descrever a complexidade do relevo e suas implicações no processo erosivo. Essas variáveis topográficas são as mais tradicionalmente utilizadas na modelagem da suscetibilidade as erosões lineares (Mohebzadeh *et al.*, 2022).

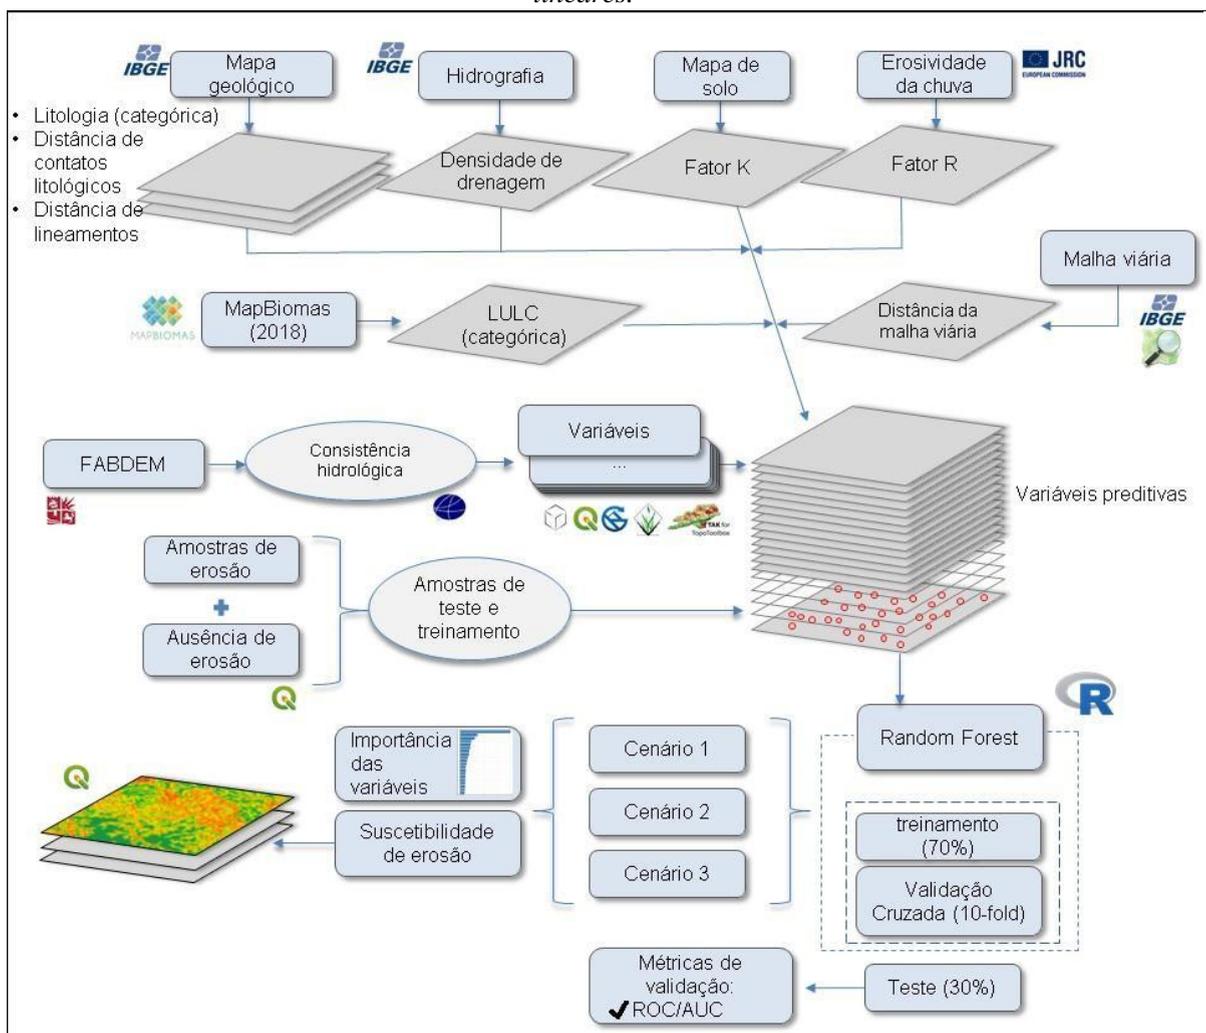
Além das variáveis topográficas, foram utilizadas variáveis associadas a fatores hidrológicos, litológicos, pedológicos, ambientais e antropogênicos. Entre as variáveis hidrológicas, foi considerada a erosividade da chuva (Fator R na USLE) (Panagos *et al.*, 2017) e a densidade de drenagem, que foi obtida a partir da rede

de hidrografia do estado de Goiás, fornecida pelo Instituto Brasileiro de Geografia e Estatística (IBGE) e refinada para a escala 1:50.000. Para o cálculo da densidade de drenagem, foi considerado o comprimento da rede de drenagem em um raio de 1 km.

Para o fator litológico, foi utilizado o mapa geológico do IBGE para a área de estudo, na escala 1:250.000 (IBGE, 2023), como uma variável categórica, além de um *raster* de distância euclidiana (mapa de proximidade) dos limites entre as litologias e dos lineamentos morfoestruturais. Para o fator pedológico, foi utilizado o mapa das classes de solo da área de estudo, na escala 1:50.000 (Nunes e Castro, 2015; Cremon *et al.*, 2021). Para cada classe, foi obtido o valor correspondente à erodibilidade do solo (Nunes e Castro, 2023), equivalente ao fator K na modelagem pela USLE.

Como variáveis ambientais e antrópicas, foram utilizados os dados de uso e cobertura do solo da coleção 9 do ano de 2018 do MapBiomas, o Índice de Vegetação por Diferença Normalizada (NDVI) deste ano, e o *raster* de distância euclidiana (mapa de proximidade) da malha viária. Os dados de uso e cobertura do solo foram tratados como variáveis categóricas. O NDVI foi obtido com base em um filtro redutor temporal de mediana para a coleção de imagens do sensor OLI/Landsat-8 do ano de 2018, que corresponde ao ano do inventário das erosões lineares, e foi processado pela plataforma do *Google Earth Engine*. Os dados da malha viária foram compilados a partir da base de arruamentos do IBGE e do projeto *Open Street Map* (OSM). Todos os dados foram compatibilizados para o mesmo tamanho de grade e sistema de referência de coordenadas (SIRGAS2000/UTM 22 Sul). O fluxograma metodológico é apresentado na Figura 5.

**Figura 5** – Fluxograma metodológico para o mapeamento de suscetibilidade as erosões lineares.



**Fonte:** Autor (2024).

Para este trabalho, foram considerados três cenários (Figura 5), primeiramente foram considerados os fatores com as variáveis topográficas mais usuais em estudos de suscetibilidade as erosões lineares (Mohebzadeh *et al.*, 2022). O segundo cenário, com as variáveis topográficas não usuais neste tipo de modelagem foi utilizado a seleção de variáveis pelo método VIF e no terceiro cenário as variáveis topográficas não usuais foram selecionadas pelo método RFE.

Para a predição de suscetibilidade as erosões lineares, foi utilizado o algoritmo *Random Forest* (RF), implementado no pacote de *machine learning caret* (Kuhn e Johnson, 2019), no *software R* via interface RStudio. O algoritmo RF foi escolhido para a predição de suscetibilidade as erosões lineares devido à sua reconhecida eficiência e desempenho superior nessa abordagem na literatura (Mohebzadeh *et al.*, 2022).

O treinamento e calibração do modelo foi conduzido com validação cruzada do tipo k-fold (k = 10), configurando a avaliação e a métrica de performance baseada

na curva ROC (*Receiver Operating Characteristic*). O ajuste dos hiperparâmetros do modelo foi realizado com a abordagem *tuning*, com 10 valores para explorar diferentes combinações de configurações do modelo. Para o treinamento, 70% do conjunto de dados foi utilizado, enquanto os 30% restantes foram reservados como amostras independentes para validação do modelo com base na métrica AUC (*area under the ROC curve*) (Kuhn e Johnson, 2019).

Adicionalmente, foi calculada a importância das variáveis para o modelo RF utilizando a função *varImp*, que se baseia na métrica de importância de Gini (Breiman, 2001). Este cálculo avaliou a contribuição de cada variável para o desempenho do modelo, permitindo identificar os fatores mais relevantes na predição. Os resultados foram apresentados graficamente para as 20 variáveis mais importantes na ocorrência de erosão linear.

## 5 RESULTADOS

### 5.1 DESEMPENHO DA SELEÇÃO DE VARIÁVEIS

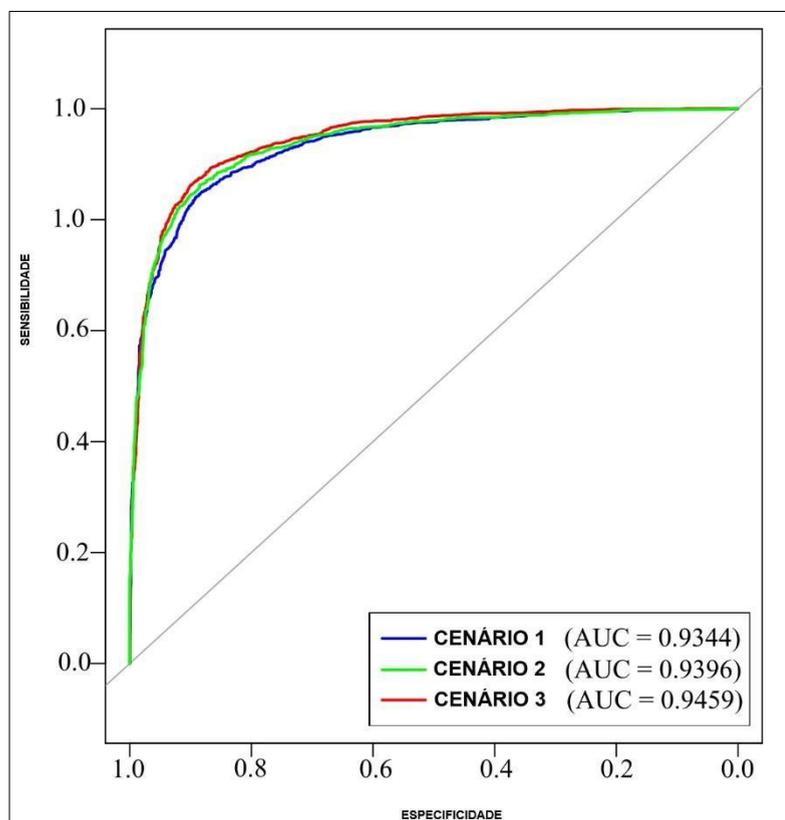
A análise dos modelos de RF foi realizada em três cenários distintos, utilizando diferentes estratégias de seleção de variáveis e ajustes de hiperparâmetros. No cenário 1, que utilizou as variáveis tradicionais, o modelo foi treinado com o melhor ajuste para o número de preditores (variáveis) a serem considerados em cada divisão nas árvores, configurado para 10. No cenário 2, em que a seleção de variáveis foi realizada pelo método VIF, o número de preditores considerados nas divisões foi melhor ajustado para 13. No cenário 3, com seleção de variáveis por RFE, esse número foi melhor ajustado para 6.

A validação dos modelos foi conduzida utilizando um conjunto de dados de teste independente das amostras de treinamento, e os valores de AUC obtidos para cada cenário foram os seguintes: no cenário 1, o AUC foi de 0,9344; no cenário 2, o AUC foi de 0,9396; e no cenário 3, o AUC alcançou 0,9459. Esses resultados demonstram um desempenho crescente à medida que a seleção de variáveis e o ajuste do modelo foram aprimorados, com o cenário 3 apresentando o melhor desempenho em termos de capacidade preditiva, conforme indicado pelo valor de AUC mais alto (Figura 6).

Os resultados indicam que o uso de variáveis topográficas não convencionais contribuiu para o aprimoramento do modelo de predição de áreas suscetíveis de erosões lineares. O cenário com variáveis selecionadas pelo método RFE apresentou o maior valor de AUC, destacando sua capacidade preditiva superior em comparação com os cenários utilizando variáveis tradicionais e o conjunto de variáveis selecionado

pelo método VIF. Esses achados sugerem que, além de explorar variáveis menos convencionais, a abordagem de seleção de variáveis via RFE foi mais eficiente em capturar as variáveis mais relevantes para a modelagem da suscetibilidade erosiva por erosão linear.

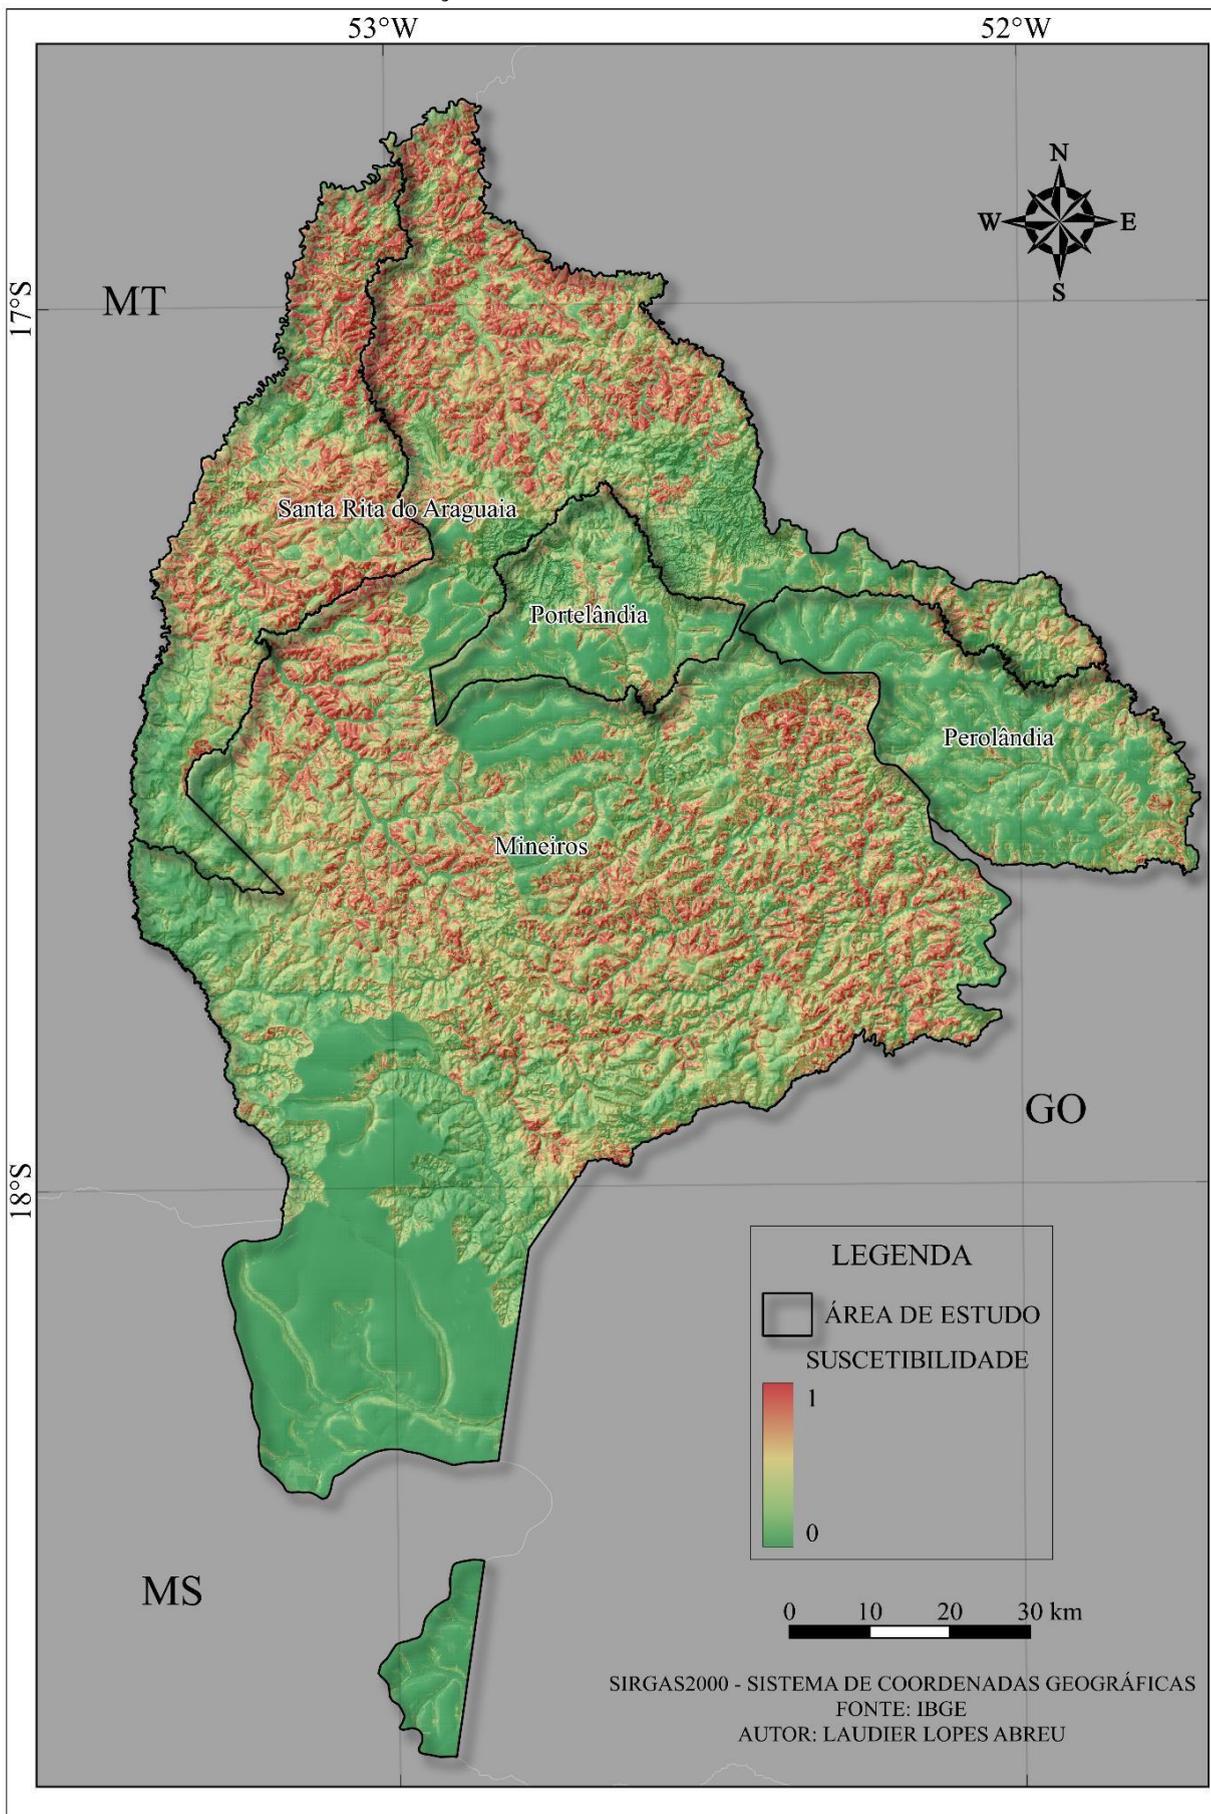
**Figura 6** – Curvas ROC (*Receiver Operating Characteristic*) para os três cenários analisados: Cenário 1, Cenário 2 e Cenário 3. As curvas ilustram a relação entre a taxa de verdadeiros positivos (*sensibilidade*) e a taxa de falsos positivos (*1 - especificidade*) para diferentes limiares de classificação.



**Fonte:** Autor (2024).

Após avaliar o desempenho das métricas de validação, o modelo mais eficaz foi utilizado para gerar o mapa de suscetibilidade à formação de erosão linear na área de estudo. O dado *raster* gerado apresenta valores que variam de 0 a 1, representando respectivamente as áreas com menor e maior propensão à formação de erosão linear (Figura 7).

**Figura 7** – Suscetibilidade as erosões lineares na área de estudo, de acordo com o desempenho do algoritmo RF no cenário 3 de seleção de variáveis.



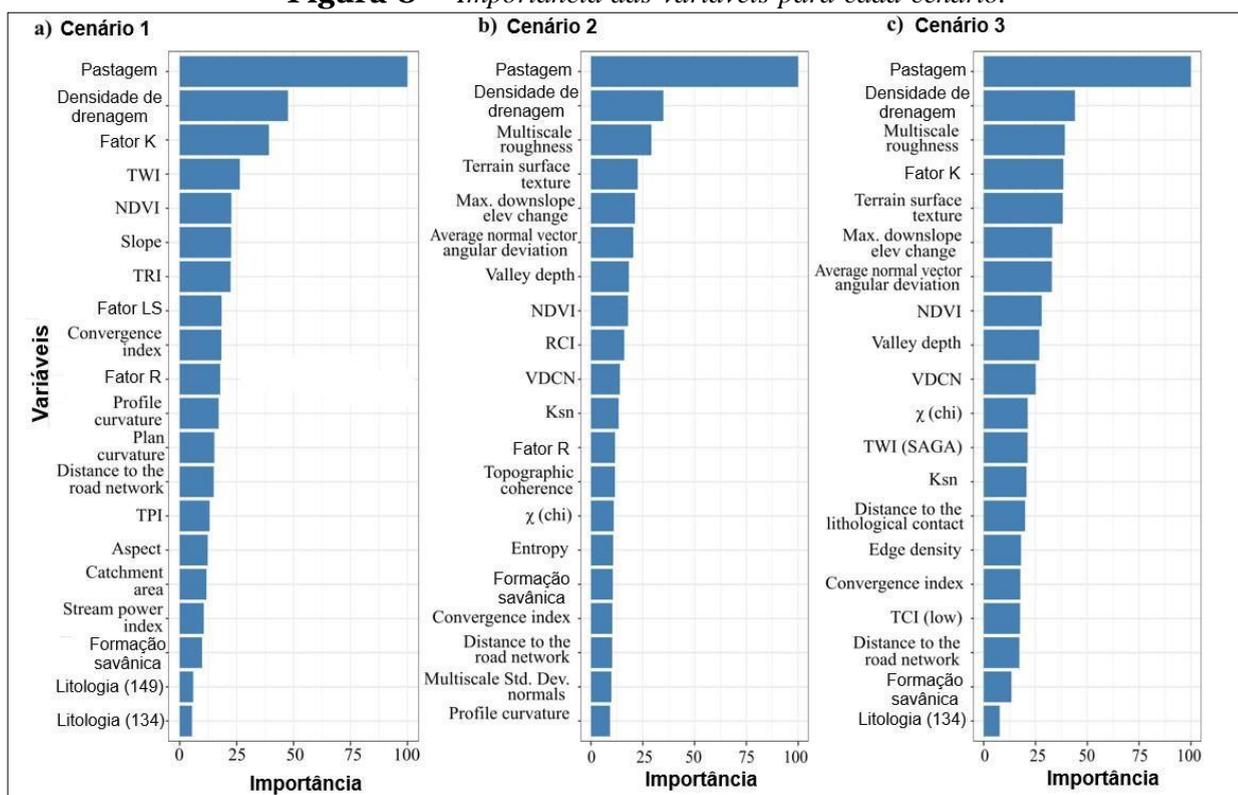
**Fonte:** Autor (2024).

As regiões com menor suscetibilidade as erosões lineares estão associadas a terrenos planos e à presença de vegetação, que protege o solo contra o impacto direto da chuva e o escoamento superficial. Em algumas áreas agrícolas, como aquelas com cultivo de soja e práticas de manejo adequadas, a ocorrência de erosão linear também é reduzida. Por outro lado, as áreas mais propensas à formação de erosões lineares estão predominantemente localizadas nas cabeceiras de drenagem, onde fatores como alta rugosidade do terreno, solos mais suscetíveis à erosão, convergência de fluxo hídrico, proximidade com o lençol freático e o uso limitado de práticas conservacionistas, principalmente em áreas de pastagem, que favorecem o desenvolvimento de processos erosivos intensos (Figura 7).

## 5.2 IMPORTÂNCIA DAS VARIÁVEIS

Nos três cenários analisados, as variáveis mais relevantes para a predição da suscetibilidade à ocorrência de erosão linear foram avaliadas pelo algoritmo RF. No cenário 1, que utilizou todas as variáveis tradicionais, incluindo aquelas com possível redundância informacional. No cenário 2, após a aplicação do método de seleção de variáveis com base no VIF, variáveis com VIF superior a 10 foram eliminadas, resultando em um conjunto de preditores mais independentes. Já no cenário 3, em que foi utilizado o algoritmo RFE com validação cruzada, a seleção iterativa das variáveis mais informativas resultou em um subconjunto de preditores com maior poder preditivo para a suscetibilidade as erosões lineares, garantindo uma maior eficiência do modelo (Figura 8).

**Figura 8** – Importância das variáveis para cada cenário.



Fonte: Autor (2024).

### 5.3 CENÁRIO 1

Na modelagem da suscetibilidade as erosões lineares no sudoeste goiano, as variáveis tradicionais mais relevantes estão associadas com características do meio físico e de uso e cobertura do solo. A pastagem foi a variável com maior importância, seguida pela *drainage density*.

O fator K, relacionado à erodibilidade do solo, também se destacou, seguido pelo *Topographic Wetness Index* (TWI) e o NDVI, que refletem a umidade do solo e a vegetação, ambos fundamentais na proteção contra a erosão. Outras variáveis topográficas, como *Slope* e *Topographic Ruggedness Index* (TRI), também desempenharam papéis importantes, pois influenciam diretamente a dinâmica da água e a capacidade do solo em gerar erosão.

Variáveis como o *Convergence Index*, *Profile Curvature*, *Plan Curvature* e o *Topographic Position Index* (TPI), representam características do relevo que afetam o escoamento superficial e a concentração de água em diferentes áreas do terreno, tiveram posições intermediárias em termos de importância. O fator R, associado à erosividade da chuva, também apresentou relevância, contribuindo para estimativas da intensidade da erosão.

As variáveis menos importantes incluíram classes categóricas de litologia, como a Formação Botucatu e a cobertura detrito-laterítica neogênica, que apresentaram menor impacto na modelagem. A proximidade da malha viária, embora relevante, teve um peso menor no modelo em comparação com as variáveis relacionadas diretamente à topografia e ao uso e cobertura do solo.

Esses resultados indicam que a interação entre fatores do meio físico, de uso e cobertura do solo e a erosividade da chuva é determinante para a modelagem de áreas suscetíveis as erosões lineares na região.

### 5.4 CENÁRIO 2

No cenário com variáveis topográficas menos convencionais usando a seleção de variáveis pelo método VIF, a variável uso e cobertura do solo – pastagem teve o maior peso, indicando a influência significativa dessa classe no desenvolvimento de áreas suscetíveis de erosões lineares. A *drainage density* foi a segunda variável mais importante, seguida pela *Multiscale Roughness* e a *Terrain Surface Texture*, que caracterizam a irregularidade e variabilidade da superfície, refletindo a interação entre o relevo e processos erosivos.

O *Maximum Downslope Elevation Change* e o *Average Normal Vector Angular Deviation* também foram relevantes, pois influenciam a direção e velocidade do fluxo de água, contribuindo para a formação de áreas de concentração de erosão.

Outras variáveis de destaque incluem a *Valley Depth* e o NDVI, este último indica a cobertura vegetal, desempenhando um papel importante na proteção contra a erosão.

O *Roughness Concentration Index* (RCI), associada a variação da declividade das encostas, e a *Vertical Distance to Channel Network* (VDCN), que reflete a posição vertical em relação aos canais de drenagem tiveram destaque entre as variáveis mais importantes.

Variáveis derivadas do pacote TAK (Forte e Whipple, 2019), como o *Ksn* e o  $\chi$  (chi), aparecem em posições intermediárias no *ranking* de importância. O *Ksn* reflete o poder erosivo dos sistemas fluviais sobre o substrato e é influenciado pela declividade e a área de contribuição. O  $\chi$  (chi), por sua vez, calcula em todos os *pixels* de uma grade a posição relativa de um ponto ao longo do perfil do sistema fluvial, mas ponderada pela área de drenagem e pela capacidade erosiva. Ele representa a energia acumulada disponível para processos erosivos ao longo do canal e é utilizado para compreender a dinâmica desses processos na paisagem, assim como da atuação de rearranjos fluviais.

Variáveis derivadas do pacote TAK (Forte e Whipple, 2019), como o *Ksn* e o  $\chi$  (chi), aparecem em posições intermediárias no *ranking* de importância. O *Ksn* reflete o poder erosivo dos sistemas fluviais, influenciado pela declividade e pela área de contribuição. Já o  $\chi$  (chi) mede a posição relativa de um ponto no perfil fluvial, ponderada pela área de drenagem, representando a energia acumulada para processos erosivos e auxiliando na análise da dinâmica fluvial e rearranjos na paisagem.

O fator R, associado à erosividade da chuva, também contribui para avaliar a suscetibilidade da área à erosão. Outras variáveis, como a *Topographic Coherence*, a entropia da elevação e o *Average Normal Vector Angular Deviation* indicam a variabilidade do relevo, representando elementos importantes na modelagem de processos erosivos.

A *Distance to the Road Network* também influenciam a suscetibilidade, seguidas pelo *Convergence Index* e a *Vertical Curvature* calculada pelo método do projeto Topodata (Valeriano e Albuquerque, 2010), que refletem o direcionamento e a concentração de fluxo hídrico.

## 5.5 CENÁRIO 3

No cenário utilizando variáveis topográficas menos convencionais e selecionadas pelo método RFE, a variável uso e cobertura do solo – pastagem apresenta a maior importância, evidenciando a relevância dessa classe para a suscetibilidade

erosiva da área. A *drainage density* aparece em seguida, como ocorreu nos demais cenários.

Assim como no cenário 2, outras variáveis importantes incluem a *Multiscale Roughness* e a *Terrain Surface Texture*, que caracterizam a variabilidade e irregularidade do relevo. O fator K, relacionado à erodibilidade do solo, demonstra a influência dos tipos de solo na formação de erosão linear, enquanto o *Maximum Downslope Elevation Change* e o *Average Normal Vector Angular Deviation* indicam a influência da inclinação e da orientação da superfície no comportamento do escoamento e na erosão.

Variáveis como o NDVI e *Valley Depth* permitem caracterizar a cobertura vegetal e a morfologia dos vales, respectivamente, fatores que desempenham papéis relevantes na proteção do solo contra a erosão. A *VDCN* e variáveis geomórficas derivadas pelo Topotoolbox, como o  $\chi$  (chi) e o *Ksn* — que aparecem em posições intermediárias de importância — refletem as interações entre o relevo e a potencial erosivo dos sistemas fluviais.

Em menor importância, aparecem o SAGA TWI e o *Convergence Index* fornecem informações sobre a concentração de água nas encostas, influenciando diretamente as áreas de saturação e erosão. Outras variáveis, como o *Terrain Classification Index for Lowlands* (TCI Low) derivado do SAGA GIS e o *Edge density*, indicam a morfologia da superfície e a rugosidade do relevo. A proximidade da malha viária e da litologia também figuram entre os fatores com influência na suscetibilidade erosiva, enquanto o uso do solo e a litologia, incluindo áreas de formação savânica e cobertura detrito-laterítica neogênica, mostram como esses elementos afetam a estabilidade e a resistência dos solos.

## 6 DISCUSSÃO

A formação de erosão linear é influenciada por fatores ambientais, topográficos e hidrológicos. Modelos de aprendizado de máquina, como *Random Forest* (RF), ajudam a identificar as variáveis mais relevantes para a suscetibilidade à erosão. Em todos os cenários analisados, a classe "Pastagem" foi a variável mais importante, refletindo o impacto do manejo do solo. O NDVI também demonstrou influência moderada, destacando a importância da cobertura vegetal na mitigação da erosão.

A densidade de drenagem foi uma das variáveis mais preditivas, indicando maior suscetibilidade em áreas com alto escoamento superficial. O estudo também revelou um aumento na importância de variáveis topográficas relacionadas à rugosidade, como *Multiscale Roughness* e *Terrain Surface Texture*, além de métricas como *Average Normal Vector Angular Deviation* e *Edge Density*.

Variáveis topográficas associadas à posição relativa, como *Max Downslope Elevation Change* e *Valley Depth*, demonstraram forte relação com a suscetibilidade

erosiva. Além disso, métricas combinadas como SAGA TWI e *TCI Low* indicaram maior risco de erosão em áreas de baixa declividade com alta umidade.

Outras variáveis intermediárias incluíram  $\chi$ ,  $\chi$  e proximidade ao contato litológico, que refletem aspectos geológicos e estruturais relevantes. A proximidade à malha viária também se mostrou moderadamente importante devido ao impacto na dinâmica do escoamento superficial. Por fim, formações savânicas exibiram papel relevante na contenção da erosão devido à sua cobertura vegetal natural.

## 7 CONCLUSÃO

Os resultados obtidos neste estudo confirmam a hipótese de que a incorporação de variáveis topográficas menos exploradas pode aprimorar significativamente os modelos preditivos de suscetibilidade às erosões lineares. Variáveis como *Multiscale Roughness* e *Terrain Surface Texture* destacaram-se como preditores de grande importância, mesmo que geralmente sejam menos exploradas em estudos de suscetibilidade à erosão, evidenciando a relevância de características topográficas mais complexas para descrever esses processos.

Entre os métodos de seleção de variáveis avaliados, o algoritmo RFE demonstrou desempenho superior ao método VIF, refletido no maior valor de AUC e na identificação de preditores mais relevantes. Essa abordagem permitiu capturar interações entre as variáveis, eliminando redundâncias identificadas por cada método e contribuindo para a robustez dos modelos gerados.

Adicionalmente, as variáveis relacionadas à rugosidade e à estrutura do relevo apresentaram uma contribuição substancial, reforçando que a variabilidade da superfície desempenha papel relevante na dinâmica dos processos erosivos. Assim, o uso de dados derivados de modelos digitais de elevação, aliado à aplicação de métodos avançados de aprendizado de máquina, confirma-se como uma estratégia eficaz para mapear áreas suscetíveis à formação de erosão linear.

Este estudo reforça a necessidade de incluir variáveis topográficas não usuais em futuras pesquisas, especialmente em regiões tropicais e subtropicais, onde o relevo e os processos hidrológicos são altamente heterogêneos. Essa abordagem aprimora a previsão de áreas suscetíveis e contribui para uma compreensão mais profunda dos mecanismos que governam a formação e o avanço das erosões lineares.

## REFERÊNCIAS

ARABAMERI, Alireza; CHEN, Wei; LOCHE, Marco; ZHAO, Xia; LI, Yang; LOMBARDO, Luigi; CERDA, Artemi; PRADHAN, Biswajeet; BUI, Dieu Tien. Comparison of machine learning models for gully erosion susceptibility mapping. **Geoscience Frontiers**, Elsevier, v. 11, n. 5, p. 1609–1620, 2020. 10

ARABAMERI, Alireza; PRADHAN, Biswajeet; BUI, Dieu Tien. Spatial modelling of gully erosion in the ardebil river watershed using three statistical-based techniques. **Catena**, Elsevier, v. 190, p. 104545, 2020. 10

ARABAMERI, Alireza; PRADHAN, Biswajeet; REZAEI, Khalil. Gully erosion zonation mapping using integrated geographically weighted regression with certainty factor and random forest models in GIS. **Journal of environmental management**, Elsevier, v. 232, p. 928–942, 2019. 10

AZAREH, Ali; RAHMATI, Omid; RAFIEI-SARDOOI, Elham; SANKEY, Joel B; LEE, Saro; SHAHABI, Himan; AHMAD, Baharin Bin. Modelling gully-erosion susceptibility in a semi-arid region, iran: Investigation of applicability of certainty factor and maximum entropy models. **Science of the Total Environment**, Elsevier, v. 655, p. 684–696, 2019. 27

BIELSKI, Conrad; LÓPEZ-VÁZQUEZ, Carlos; GROHMANN, Carlos H; GUTH, Peter L; HAWKER, Laurence; GESCH, Dean; TREVISANI, Sebastiano; HERRERA-CRUZ, Virginia; RIAZANOFF, Serge; CORSEAUX, Axel *et al.* Novel approach for ranking DEMs: Copernicus DEM improves one arc second open global topography. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 62, p. 1–22, 2024. 15

BOARDMAN, J; PARSONS, AJ; HOLLAND, R; HOLMES, PJ; WASHINGTON, R. Development of badlands and gullies in the sneeuberg, great karoo, south africa. **Catena**, Elsevier, v. 50, n. 2-4, p. 165–184, 2003. 10

BOCK, M.; BOEHNER, J.; CONRAD, O.; KOETHE, R.; RINGELER, A. Methods for creating functional soil databases and applying digital soil mapping with SAGA

GIS. In: HENGL, T.; PANAGOS, P.; JONES, A.; TOTH, G. (Ed.). **Status and prospect of soil information in south-eastern Europe: soil databases, projects and applications**. Luxemburg: Office for Official Publications of the European Communities, 2007, (Scientific and Technical Research series, EUR 22646 EN). p. 149–162. 30

BREIMAN, Leo. Random forests. **Machine learning**, Springer, v. 45, p. 5–32, 2001. 21

CARVALHO, Hellbia Samara Moreira de; CASTRO, Selma Simões de. Mapeamento e identificação de áreas críticas à erosão hídrica linear: o exemplo do bioma cerrado no estado de goiás, brasil. **Revista Brasileira de Geomorfologia**, v. 24, n. 00, 2023. Disponível em: <https://rbgeomorfologia.org.br/rbg/article/view/2373>. 11

CHAPLOT, Vincent. Impact of terrain attributes, parent material and soil types on gully erosion. **Geomorphology**, Elsevier, v. 186, p. 1–11, 2013. 30

CONRAD, Olaf; BECHTEL, Benjamin; BOCK, Michael; DIETRICH, Helge; FISCHER, Elke; GERLITZ, Lars; WEHBERG, Jan; WICHMANN, Volker; BÖHNER, Jürgen. System for automated geoscientific analyses (saga) v. 2.1. 4. **Geoscientific model development**, Copernicus GmbH, v. 8, n. 7, p. 1991–2007, 2015. 15

CREMON, Édipo Henrique; BETTIOL, Giovana Maranhão; JÚNIOR, João Paulo Magna; MACEDO, Fabio Campos. Avaliação da altimetria do mde cop-30 no centro-oeste do brasil. **Revista Brasileira de Cartografia**, v. 74, n. 3, p. 536–546, 2022. 15

CREMON, Édipo H; PEREIRA, Alessandra C; PAULA, Larissa DL de; NUNES, Elizon D. Geological and terrain attributes for predicting soil classes using pixel- and geographic object-based image analysis in the Brazilian Cerrado. **Geoderma**, Elsevier, v. 401, p. 115315, 2021. 12, 17, 19

DYBA, Krzysztof. Explanation of the influence of geomorphometric variables on the landform classification based on selected areas in poland. **Scientific Reports**, Nature Publishing Group UK London, v. 14, n. 1, p. 5447, 2024. 29

FAO. **Status of the World's Soil Resources**. Roma: ITPS, 2015. 10

FLORINSKY, Igor. **Digital terrain analysis in soil science and geology**. [S.l.]: Academic Press, 2016. 11

FORTE, Adam M; WHIPPLE, Kelin X. Criteria and tools for determining drainage divide stability. **Earth and Planetary Science Letters**, Elsevier, v. 493, p. 102–117, 2018. 31

\_. The topographic analysis kit (tak) for topotoolbox. **Earth Surface Dynamics**, Copernicus GmbH, v. 7, n. 1, p. 87–95, 2019. 15, 26

GALDINO, Sergio; SANO, Edson E; ANDRADE, Ricardo G; GREGO, Celia R; NOGUEIRA, Sandra F; BRAGANTINI, Claudio; FLOSI, Ana HG. Large-scale modeling of soil erosion with RUSLE for conservationist planning of degraded cultivated brazilian pastures. **Land degradation & development**, Wiley Online Library, v. 27, n. 3, p. 773–784, 2016. 28

GOURNELLOS, Th; EVELPIDOU, N; VASSILOPOULOS, A. Developing an erosion risk map using soft computing methods (case study at sifnos island). **Natural Hazards**, Springer, v. 31, p. 63–83, 2004. 28

GRASS Development Team. **Geographic Resources Analysis Support System (GRASS GIS) Software, Version 8.4**. USA, 2024. Disponível em: <https://grass.osgeo.org>. 15

HAWKER, Laurence; UHE, Peter; PAULO, Luntadila; SOSA, Jeison; SAVAGE, James; SAMPSON, Christopher; NEAL, Jeffrey. A 30 m global map of elevation with forests and buildings removed. **Environmental Research Letters**, IOP Publishing, v. 17, n. 2, p. 024016, 2022. 15

HIJMANS, Robert J. **terra: Spatial Data Analysis**. [s.n.], 2024. R package version 1.8-2,. Disponível em: <https://github.com/rspatial/terra>. 15

HUANG, Donghao; SU, Lin; FAN, Haoming; ZHOU, Lili; TIAN, Yulu. Identification of topographic factors for gully erosion susceptibility and their spatial modelling using machine learning in the black soil region of northeast china. **Ecological Indicators**, Elsevier, v. 143, p. 109376, 2022. 30

HUGGETT, Richard; SHUTTLEWORTH, Emma. **Fundamentals of geomorphology**. [S.l.]: Routledge, 2022. 28

IBGE. **Banco de Dados e Informações Ambientais (BDiA): Mapeamento de Recursos Naturais (MRN) - escala 1:250 000 - versão 2023 - nota metodológica**. Rio de Janeiro: IBGE, 2023. 64 p. (Coleção Ibgeana). Disponível somente em meio digital. 12, 19

IWAHASHI, Junko; PIKE, Richard J. Automated classifications of topography from DEMs by an unsupervised nested-means algorithm and a three-part geometric signature. **Geomorphology**, Elsevier, v. 86, n. 3-4, p. 409–440, 2007. 29

JONES, Richard. Algorithms for using a DEM for mapping catchment areas of stream sediment samples. **Computers & geosciences**, Elsevier, v. 28, n. 9, p. 1051–1060, 2002. 15

KO, Minjae; KANG, Heemoon; KIM, Jong ulrim; LEE, Yonghyeon; HWANG, Jie-Eun. How to measure quality of affordable 3d printing: Cultivating quantitative index in the user community. *In*: STEPHANIDIS, Constantine (Ed.). **HCI International 2016 – Posters’ Extended Abstracts**. Cham: Springer International Publishing, 2016. p. 116–121. ISBN 978-3-319-40548-3. 29

KUHN, Max; JOHNSON, Kjell. **Engenharia e seleção de recursos: uma abordagem prática para modelos preditivos**. [S.l.]: Imprensa CRC, 2019. Disponível em: <https://towardsdatascience.com/effective-feature-selection-recursive-feature-elimination-using-r-148ff998e4f7>. 17, 20, 21

LINDSAY, John B. Whitebox gat: A case study in geomorphometric analysis. **Computers & Geosciences**, Elsevier, v. 95, p. 75–84, 2016. 15

LINDSAY, John B. **WhiteboxTools User Manual**. Guelph, Canada, March 2023. Disponível em: [https://www.whiteboxgeo.com/manual/wbt\\_book/](https://www.whiteboxgeo.com/manual/wbt_book/). 28, 29

MARINHO, GV; CASTRO, SS de; CAMPOS, AB de. Hydrology and gully processes in the upper araguaia river basin, central brazil. **Zeitschrift fur Geomorphologie**, v. 145, p. 119–145, 2006. 11, 30, 31

MOHEBZADEH, Hamid; BISWAS, Asim; RUDRA, Ramesh; DAGGUPATI, Prasad. Machine learning techniques for gully erosion susceptibility mapping: a review. **Geosciences**, MDPI, v. 12, n. 12, p. 429, 2022. 18, 20

NUNES, E. D.; CASTRO, S. S. Compartimentação morfoopedológica aplicada à distribuição de padrões espaciais de processos erosivos em solos frágeis - município de mineiros, go. *In*: CASTRO, S. S.; HERNANI, L. C. (Ed.). **Solos frágeis: caracterização, manejo e sustentabilidade**. Brasília: Embrapa, 2015. p. 293–324. 11, 19, 28

NUNES, Elizon Dias; CASTRO, Selma Simões de. Análise multiescalar aplicada à avaliação de erosão hídrica linear para área tropical subúmida situada na região sudoeste do estado de goiás-brasil. **Revista Brasileira de Geomorfologia**, v. 24, n. 00, 2023. 11, 13, 19, 28, 30

O'CALLAGHAN, John F; MARK, David M. The extraction of drainage networks from digital elevation data. **Computer vision, graphics, and image processing**, Academic Press, v. 28, n. 3, p. 323–344, 1984. 14

PANAGOS, Panos; BORRELLI, Pasquale; MEUSBURGER, Katrin; YU, Bofu; KLIK, Andreas; LIM, Kyoung Jae; YANG, Jae E; NI, Jinren; MIAO, Chiyuan; CHATTOPADHYAY, Nabansu *et al.* Global rainfall erosivity assessment based on high-temporal resolution rainfall records. **Scientific reports**, Nature Publishing Group, v. 7, n. 1, p. 1–12, 2017. 18

PERRON, J Taylor; ROYDEN, Leigh. An integral approach to bedrock river profile analysis. **Earth surface processes and landforms**, Wiley Online Library, v. 38, n. 6, p. 570–576, 2013. 30

PIKE, R.J.; EVANS, I.S.; HENGL, T. Geomorphometry: A brief guide. *In*: HENGL, Tomislav; REUTER, Hannes I. (Ed.). **Geomorphometry**. Elsevier, 2009, (Developments in Soil Science, v. 33). p. 3–30. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0166248108000019>. 11

PURINTON, Benjamin; BOOKHAGEN, Bodo. Beyond vertical point accuracy: Assessing inter-pixel consistency in 30 m global dems for the arid central andes. **Frontiers in Earth Science**, Frontiers Media SA, v. 9, p. 758606, 2021. 15

QGIS Development Team. **QGIS Geographic Information System**. 2024. Open Source Geospatial Foundation Project. Disponível em: <https://qgis.org>. 15

ROSIM, Sergio; MONTEIRO, Antônio Miguel V.; RENNÓ, Camilo Daleles; OLIVEIRA, João Ricardo de F. Terrahydro - a distributed hydrological system using graph structure for unified water flow representation. *In*: **2011 IEEE International Geoscience and Remote Sensing Symposium**. [S.l.: s.n.], 2011. p. 4192–4195. 15

SAMPAIO, Tony Vinicius Moreira; AUGUSTIN, Cristina Helena Ribeiro Rocha. Índice de concentração da rugosidade: uma nova proposta metodológica para o mapeamento e quantificação da dissecação do relevo como subsídio a cartografia geomorfológica. **Revista Brasileira de Geomorfologia**, v. 15, n. 1, abr. 2014. Disponível em: <https://rbgeomorfologia.org.br/rbg/article/view/376.29>

SANTANA, Neiva Maria Pio de; CASTRO, Selma Simões de; STONE, Luis Fernando; SILVA, Silvando Carlos da. Chuvas, erosividade, erodibilidade, uso do solo e suas relações com focos erosivos lineares na alta bacia do rio Araguaia. **Sociedade & Natureza**, SciELO Brasil, v. 19, p. 103–121, 2007. 28, 31

SANTOS, H. G. dos; JACOMINE, P. K. T.; ANJOS, L. H. C. dos; OLIVEIRA, V. A. de; LUMBRERAS, J. F.; COELHO, M. R.; ALMEIDA, J. A. de; FILHO, J. C. de Araujo; OLIVEIRA, J. B. de; CUNHA, T. J. F. **Brazilian Soil Classification System**: in portuguese. 5. ed. Brasília: Embrapa, 2018. 12

SHIT, Pravat Kumar; PAIRA, Rumpa; BHUNIA, GouriSankar; MAITI, Ramkrishna. Modeling of potential gully erosion hazard using geospatial technology at garbheta block, west bengal in india. **Modeling Earth Systems and Environment**, Springer, v. 1, p. 1–16, 2015. 11

TREVISANI, Sebastiano; TEZA, Giordano; GUTH, Peter L. Hacking the topographic ruggedness index. **Geomorphology**, Elsevier, v. 439, p. 108838, 2023. 15

VALENTIN, Christian; POESEN, Jean; LI, Yong. Gully erosion: Impacts, factors and control. **Catena**, Elsevier, v. 63, n. 2-3, p. 132–153, 2005. 10, 13

VALERIANO, Márcio de Morisson; ROSSETTI, Dilce de Fátima. Análise digital do padrão de coerência da orientação de vertentes em terrenos planos. *In*: CONGRESSO DA ASSOCIAÇÃO BRASILEIRA DE ESTUDOS DO QUATERNÁRIO, 13. (ABEQUA)., 2011, Armação de Búzios, RJ São Paulo, SP. **Anais...** [S.l.]: ABEQUA, 2011. p. 1–5. Setores de Atividade: Atividades profissionais, científicas e técnicas. Acesso em: 13 nov. 2024. 29

VALERIANO, M. M.; ALBUQUERQUE, P. C. G. **TOPODATA: processamento dos dados SRTM**. 2010. Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos. 79 p. IBI: <8JMKD3MGP7W/37FCH9B>. Disponível em: <http://urlib.net/ibi/8JMKD3MGP7W/37FCH9B>. Disponível em: <http://urlib.net/ibi/8JMKD3MGP7W/37FCH9B>.26

VALIPOUR, Mahdih; MOHSENI, Neda; HOSSEINZADEH, Seyed Reza. Factors affecting topographic thresholds in gully erosion occurrence and its management using predictive machine learning models. **Earth Sciences Research Journal**, Maestría en Geofísica, Departamento de Geociencias, Facultad de Ciencias . . . , v. 25, n. 4, p. 423–432, 2021. 30

WANG, Fengjie; SAHANA, Meheub; PAHLEVANZADEH, Bahareh; PAL, Subodh Chandra; SHIT, Pravat Kumar; PIRAN, Md Jalil; JANIZADEH, Saeid; BAND, Shahab S; MOSAVI, Amir. Applying different resampling strategies in machine learning models to predict head-cut gully erosion susceptibility. **Alexandria Engineering Journal**, Elsevier, v. 60, n. 6, p. 5813–5829, 2021. 30

WHIPPLE, Kelin X.; DIBIASE, Roman A.; CROSBY, Benjamin; JOHNSON, Joel P.L. Bedrock rivers. *In*: SHRODER, John (Jack) F. (Ed.). **Treatise on Geomorphology (Second Edition)**. Second edition. Oxford: Academic Press, 2022.p. 865–903. ISBN 978-0-12-818235-2. Disponível em: <https://www.sciencedirect.com/science/article/pii/B9780128182345001012.30>

WILLETT, Sean D; MCCOY, Scott W; PERRON, J Taylor; GOREN, Liran; CHEN, Chia-Yu. Dynamic reorganization of river basins. **Science**, American Association for the Advancement of Science, v. 343, n. 6175, p. 1248765, 2014. 30

ZHANG, Du; TSAI, Jeffery JP. **Advances in machine learning applications in software engineering**. [S.l.]: Igi Global, 2006. 10.