INSTITUTO FEDERAL
Goiás
Câmpus Goiânia

Instituto Federal de Educação, Ciência e Tecnologia de Goiás
Pró-Reitoria de Pesquisa e Pós-Graduação
Câmpus Goiânia
Mestrado Profissional em Tecnologia, Gestão e Sustentabilidade

Alessandra Cristina Pereira

Avaliação da suscetibilidade à erosão linear e seus fatores condicionantes no Cerrado goiano

Goiânia, 2026.

MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
SISTEMA INTEGRADO DE BIBLIOTECAS

TERMO DE AUTORIZAÇÃO PARA DISPONIBILIZAÇÃO NO REPOSITÓRIO DIGITAL DO IFG - ReDi IFG

Com base no disposto na Lei Federal nº 9.610/98, AUTORIZO o Instituto Federal de Educação, Ciência e Tecnologia de Goiás, a disponibilizar gratuitamente o documento no Repositório Digital (ReDi IFG), sem ressarcimento de direitos autorais, conforme permissão assinada abaixo, em formato digital para fins de leitura, download e impressão, a título de divulgação da produção técnico-científica no IFG.

Identificação da Produção Técnico-Científica

[ ] Tese	[ ] Artigo Científico
[X] Dissertação	[ ] Capítulo de Livro
[ ] Monografia – Especialização	[ ] Livro
[ ] TCC - Graduação	[ ] Trabalho Apresentado em Evento

[ ] Produto Técnico e Educacional - Tipo: _____

Nome Completo do Autor: **Alessandra Cristina Pereira**
Matrícula: **20232011280182**
Título do Trabalho: **Avaliação da suscetibilidade à erosão linear e seus fatores condicionantes no Cerrado goiano**

Autorização - Marque uma das opções

1. (X) Autorizo disponibilizar meu trabalho no Repositório Digital do IFG (acesso aberto);
2. ( ) Autorizo disponibilizar meu trabalho no Repositório Digital do IFG somente após a data ___/___/_____ (Embargo);
3. ( ) Não autorizo disponibilizar meu trabalho no Repositório Digital do IFG (acesso restrito).

Ao indicar a opção **2 ou 3**, marque a justificativa:

( ) O documento está sujeito a registro de patente.
( ) O documento pode vir a ser publicado como livro, capítulo de livro ou artigo.
( ) Outra justificativa: _____

DECLARAÇÃO DE DISTRIBUIÇÃO NÃO-EXCLUSIVA

O/A referido/a autor/a declara que:

i. o documento é seu trabalho original, detém os direitos autorais da produção técnico-científica e não infringe os direitos de qualquer outra pessoa ou entidade;
ii. obteve autorização de quaisquer materiais inclusos no documento do qual não detém os direitos de autor/a, para conceder ao Instituto Federal de Educação, Ciência e Tecnologia de Goiás os direitos requeridos e que este material cujos direitos autorais são de terceiros, estão claramente identificados e reconhecidos no texto ou conteúdo do documento entregue;
iii. cumpriu quaisquer obrigações exigidas por contrato ou acordo, caso o documento entregue seja baseado em trabalho financiado ou apoiado por outra instituição que não o Instituto Federal de Educação, Ciência e Tecnologia de Goiás.

Goiânia - GO, 11/03/2026

gov.br Documento assinado digitalmente
ALESSANDRA CRISTINA PEREIRA
Data: 10/04/2026 10:37:53-0300
Verifique em https://validar.iti.gov.br

_____
Assinatura do Autor e/ou Detentor dos Direitos Autorais

Instituto Federal de Educação, Ciência e Tecnologia de Goiás
Pró-Reitoria de Pesquisa e Pós-Graduação
Câmpus Goiânia
Mestrado Profissional em Tecnologia, Gestão e Sustentabilidade

Alessandra Cristina Pereira

Avaliação da suscetibilidade à erosão linear e seus fatores condicionantes no Cerrado goiano

Programa de Pós-Graduação *Stricto Sensu* em Tecnologia, Gestão e Sustentabilidade do Instituto Federal de Educação, Ciência e Tecnologia de Goiás - Dissertação de Mestrado Profissional. Área de Concentração: Tecnologia de Sistemas de Produção Limpa. Linha de Pesquisa: Modelagem de Sistemas.

Orientador: Prof. Dr. Édipo Henrique Cremon

Coorientador: Prof. Dr. Thiago Augusto Mendes

Goiânia, 2026.

P436a Pereira, Alessandra Cristina.
Avaliação da suscetibilidade à erosão linear e seus fatores condicionantes no cerrado goiano / Alessandra Cristina Pereira. – Goiânia: Instituto Federal de Educação, Ciência e Tecnologia de Goiás, 2026.
94f.

Orientação: Prof. Dr. Édipo Henrique Cremon.
Coorientação: Prof. Dr. Thiago Augusto Mendes.

Dissertação (mestrado) – Programa de Pós-Graduação *Stricto Sensu* em Tecnologia, Gestão e Sustentabilidade, Instituto Federal de Educação, Ciência e Tecnologia de Goiás.

1. Erosão do solo. 2. Uso da terra. 3. Planejamento territorial. I. Cremon, Édipo Henrique (orientação). II. Mendes, Thiago Augusto (coorientação). III. Instituto Federal de Educação, Ciência e Tecnologia de Goiás. IV. Título.

CDD 551.3

Ficha catalográfica elaborada pela bibliotecária Lana Cristina Dias Oliveira CRB1/ 2.631
Biblioteca Professor Jorge Félix de Souza,
Instituto Federal de Educação, Ciência e Tecnologia de Goiás, Câmpus Goiânia.

PARECER 44/2026 - GYN-CMTGS/GYN-GPPEX/CP-GOIANIA/IFG

SERVIÇO PÚBLICO FEDERAL
INSTITUTO FEDERAL DE EDUCAÇÃO CIÊNCIA E TECNOLOGIA DE GOIÁS
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
IFG CÂMPUS GOIÂNIA
MESTRADO EM TECNOLOGIA, GESTÃO E SUSTENTABILIDADE

ALESSANDRA CRISTINA PEREIRA

AVALIAÇÃO DA SUSCETIBILIDADE À EROSÃO LINEAR E SEUS FATORES CONDICIONANTES NO CERRADO GOIANO

Dissertação apresentada ao Programa de Pós-Graduação em Tecnologia, Gestão e Sustentabilidade do Instituto Federal de Educação, Ciência e Tecnologia de Goiás como requisito para a obtenção do título de Mestre.
Área de Concentração: Tecnologia de Sistemas de Produção Limpa.
Linha de Pesquisa: Modelagem de Sistemas

Aprovação em: 11 de fevereiro de 2026.

Banca examinadora:

Presidente e orientador: Prof. Dr. Édipo Henrique Cremon - PPGTGS IFG
Coorientador: Prof. Dr. Thiago Augusto Mendes - PPGTGS IFG
Avaliadora: Profa. Dra. Regina Célia Bueno da Fonseca - PPGTGS IFG
Avaliadora: Profa. Dra. Renata Pacheco Quevedo - University of Vienna, Austria

Documento assinado eletronicamente por:

- **Renata Pacheco Quevedo, Renata Pacheco Quevedo - Estudante - Ifg - Câmpus Goiânia (10870883000225)**, em 19/02/2026 07:12:39.
- **Edipo Henrique Cremon, Edipo Henrique Cremon - Docente - Ifg - Câmpus Goiânia (10870883000225)**, em 18/02/2026 17:07:59.
- **Regina Celia Bueno da Fonseca, PROFESSOR ENS BASICO TECN TECNOLOGICO**, em 15/02/2026 01:21:43.
- **Thiago Augusto Mendes, PROFESSOR ENS BASICO TECN TECNOLOGICO**, em 12/02/2026 16:13:13.

Este documento foi emitido pelo SUAP em 10/02/2026. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse https://suap.ifg.edu.br/autenticar-documento/ e forneça os dados abaixo:

Código Verificador: 744559
Código de Autenticação: 55751b0ac4

Agradecimentos

Manifesto minha consideração e sincero agradecimento a todos os docentes do Programa de Pós-Graduação em Tecnologia, Gestão e Sustentabilidade e aos diversos servidores que integram o Instituto Federal de Goiás (IFG), com especial destaque ao professor Édipo Cremon, pelos ensinamentos, pela paciência ímpar e pelo apoio contínuo ao meu percurso acadêmico, desde a graduação até o mestrado. Seu *feedback* construtivo e o encorajamento permanente foram determinantes para a manutenção do foco, da motivação e da perseverança ao longo do mestrado, com a convicção de que as lições aprendidas vão além das paredes da universidade.

Resumo

Título: Avaliação da suscetibilidade à erosão linear e seus fatores condicionantes no Cerrado goiano
Autor: Alessandra Cristina Pereira
Orientador: Dr. Édipo Henrique Cremon
Coorientador: Dr. Thiago Augusto Mendes

A erosão linear compromete ecossistemas, reduz a fertilidade do solo e afeta a produtividade agrícola, em desacordo com os Objetivos de Desenvolvimento Sustentável (ODS) da Organização das Nações Unidas (ONU). O mapeamento da suscetibilidade a erosão é essencial para estratégias de conservação do solo e planejamento territorial. Este estudo investiga a suscetibilidade à erosão linear no estado de Goiás, empregando aprendizado de máquina. Foram utilizadas 23 variáveis relacionadas a fatores condicionantes da erosão, incluindo atributos topográficos, uso e cobertura da terra, fatores antrópicos, geológicos e hidrológicos, 11 dessas extraídas do Modelo Digital de Terreno (MDT) FathomDEM. O conjunto de dados incluiu 67.078 amostras de erosão linear de ravinas e voçorocas, divididas para treinamento e teste do modelo. A predição foi realizada empregando a abordagem de classificação supervisionada por meio do algoritmo *Random Forest Ranger (RF Ranger)*, calibrado com validação cruzada *k-fold*, ($k = 10$) e avaliado por meio métrica *Areas Under the ROC Curve* (AUC). A avaliação estatística do modelo *RF Ranger* mostrou desempenho satisfatório, com AUC de 0,8657. O ranqueamento de importância destacou o *Normalized Difference Vegetation Index* (NDVI) como o fator mais influente, seguida pela pastagem e idade da pastagem, reforçando o impacto da degradação vegetal na erosão. A erosividade da chuva (fator R) e fatores topográficos associados a rugosidade e morfologia também se mostraram relevantes. O mapa preditivo indica que áreas mais suscetíveis concentram-se em cabeceiras de drenagem com alta declividade e solos mais erodíveis em contraste com as menos suscetíveis estão associadas a terrenos planos e vegetação preservada.

Palavras–chave

Processos erosivos, aprendizado de máquina, variáveis topográficas, uso do solo e cobertura da terra.

Abstract

Title: Assessment of gully erosion susceptibility and its conditioning factors in Goiás state, Cerrado brazilian
Author: Alessandra Cristina Pereira
Advisor: Dr. Édipo Henrique Cremon
Coadvisor: Dr. Thiago Augusto Mendes

Gully erosion compromises ecosystems, reduces soil fertility, and affects agricultural productivity, in disagreement with the United Nations (UN) Sustainable Development Goals (SDGs). Gully erosion susceptibility mapping is essential for soil conservation strategies and territorial planning. This study investigates gully erosion susceptibility in the state of Goiás, employing machine learning techniques. Twenty-three variables related to erosion conditioning factors were considered, including topographic attributes, land use and land cover, anthropogenic, geological, and hydrological factors, 11 of which were derived from the FathomDEM Digital Terrain Model (DTM). The dataset comprised 67,078 erosion samples, including gullies and ravines, which were partitioned for model training and testing. The prediction was conducted using a supervised classification approach based on the Random Forest Ranger algorithm (RF Ranger), calibrated through k-fold cross-validation (k = 10) and evaluated using the Areas Under the ROC Curve (AUC). The statistical assessment of the RF Ranger model indicated strong predictive performance, yielding an AUC of 0.8657. The variable importance ranking identified the Normalized Difference Vegetation Index (NDVI) as the most influential factor, followed by pasture and pasture age, reinforcing the role of vegetation alteration in erosion processes. The rainfall erosivity factor (R factor) and topographic variables related to surface roughness and terrain morphology were also relevant. The predictive map shows that areas with highest susceptibility are concentrated in drainage headwaters characterized by steep slopes and more erodible soils, whereas the lower susceptibility are associated with flat terrain and preserved vegetation.

Keywords

Erosive processes, machine learning, topographic variables, land use and land cover.

Lista de Figuras

1 Esquema ilustrativo da distribuição espacial dos principais tipos de erosão hídrica em uma vertente. A erosão laminar (*sheet erosion*) ocorre nas posições superiores, caracterizada pela remoção difusa de partículas do solo. A erosão em sulcos (*rill erosion*) desenvolve-se onde o escoamento superficial passa a se concentrar em pequenos canais. A jusante, a concentração do fluxo evolui para incisão mais profunda, originando processos de erosão linear do tipo ravina ou voçoroca (*gully erosion*) 18

2 Dados geográficos (a) Exemplo de um dado vetorial: capitais representadas como pontos, ferrovias representadas como linhas e os estados brasileiros representados como polígonos. (b) Exemplo de tabela de atributos com informações descritivas, neste caso das ferrovias 20

3 Exemplo de um dado raster: a) imagem digital, b) destaque de um grupo de *pixel*; c) valores digitais correspondentes 21

4 Exemplos de dados raster: a) contínuo, representado por um modelo digital de elevação; e b) categórico, representado por um produto de uso do solo e cobertura da terra 22

5 Extração de valores dos *pixels* para determinados pontos amostrais . 22

6 Representação: a) terreno; b) MDS em linha tracejada e MDT em linha contínua 23

7 Recorte da área ao redor de Baldwin, Alabama, EUA, comparando a diferença de elevação entre FathomDEM, FABDEM, COPDEM e o LiDAR 24

8 Localização da área de estudo. a) Brasil (cinza claro) no contexto da América do Sul; b) Estado de Goiás (cinza escuro) e a área de estudo (verde); c) Localização dos focos erosivos mapeados (Carvalho e Castro, 2023) 31

9 Desempenho dos algoritmos RF, *RF Ranger*, GBM e XGBoost, de acordo com curva *Receiver Operating Characteristic* (ROC) 35

10 Importância das variáveis para os algoritmos avaliados 36

11 Mapa de suscetibilidade à erosão linear, de acordo com o algoritmo *RF Ranger* 38

12 Localização da área de estudo: a) Brasil (cinza claro) no contexto da América do Sul; b) Estado de Goiás (cinza escuro) e a área de estudo (verde) 45

13 Importância das variáveis nos modelos RF e GBM 47

14 Mapa de suscetibilidade à erosão linear, de acordo com o desempenho do algoritmo GBM 48

15 Localização da área de estudo - Goiás, no contexto nacional à esquerda. Mapa hipsométrico de Goiás evidenciando as elevações, à direita 52
16 Fluxograma do procedimento metodológico adotados no estudo . . . 54
17 Esquematização do processo de validação cruzada do tipo *k-fold* . . . 58
18 Área de estudo com relevo sombreado ao fundo e delimitação dos blocos espaciais de 50 km × 50 km. Os números de 1 a 10 indicam a atribuição dos blocos aos *folds* espaciais: os grupos 1 a 7 foram destinados ao treinamento e validação cruzada (k-fold, $k = 7$), enquanto os grupos 8 a 10 constituíram o conjunto de teste independente para avaliação final do modelo. Foram gerados, ao todo, 170 blocos para a cobertura integral da área de estudo 59
19 Importância das variáveis para a aptidão a erosões conforme o modelo *RF Ranger* utilizando a métrica de impureza de Gini 61
20 Gráficos PDP das nove variáveis preditoras em ordem de importância 62
21 Regiões suscetíveis à erosão linear, conforme a performance do algoritmo *RF Ranger* 65
22 Municípios suscetíveis à erosão linear, segundo o percentual da área municipal (%) 67

Lista de Quadros

1 Relação entre as variáveis mais utilizadas em pesquisas sobre a suscetibilidade à erosão linear e a quantidade de estudos 26
2 Variáveis topográficas extraídas do modelo digital de terreno FABDEM . . 32
3 Variáveis extraídas diretamente do MDT FathomDEM 55

Sumário

1 Apresentação 13
1.1 Objetivos 14
1.1.1 Objetivo geral 14
1.1.2 Objetivos específicos 15
1.2 Estrutura do documento 15

2 Fundamentação teórica 17
2.1 Erosão do solo: conceitos e consequências da degradação do solo 17
2.2 Dados geográficos 19
2.2.1 Modelo Digital de Elevação 23
2.3 Variáveis geoambientais mais usuais para mapeamento de erosões lineares 24
2.4 Aprendizado de máquina 27

3 Artigo 1 - Avaliação de variáveis críticas para a ocorrência de erosões lineares utilizando algoritmos de aprendizado de máquina 29
3.1 Introdução 29
3.2 Materiais e métodos 30
3.2.1 Área de estudo 30
3.2.2 Material e métodos 32
3.3 Resultados 34
3.4 Discussão 39
3.5 Conclusão 41

4 Artigo 2 - Influência da idade e vigor das pastagens na suscetibilidade à erosão linear no Cerrado 43
4.1 Introdução 43
4.2 Material e métodos 44
4.3 Resultados 46
4.4 Discussão 48
4.5 Conclusões 49

5 Artigo 3 - Predição de áreas suscetíveis à erosão linear em Goiás 50
5.1 Introdução 50
5.2 Caracterização da área de estudo 51
5.3 Materiais e métodos 53
5.3.1 Aquisição dos dados amostrais de erosões lineares 54
5.3.2 Aquisição e processamento das variáveis 55
5.3.3 Classificação, predição e validação do modelo 57

5.4 Resultados 60
5.5 Discussões 68
5.5.1 Desempenho do modelo 68
5.5.2 Fatores condicionantes 69
5.5.3 Relevância do produto de suscetibilidade para instrumentos de gestão . 72
5.6 Conclusão 72

6 Produto técnico 74

7 Síntese dos fatores condicionantes e da modelagem preditiva da erosão linear em Goiás 75

8 Considerações finais 78

Referências 80

CAPÍTULO 1

Apresentação

A erosão linear dos solos é uma ameaça global que afeta negativamente o funcionamento dos ecossistemas e constitui um dos principais fenômenos de degradação do solo. A mitigação desses impactos, assim como a prevenção e o manejo sustentável, integram os desafios de um plano de ação global alinhado aos Objetivos de Desenvolvimento Sustentável(ODS) das Nações Unidas (United Nations, 2015).

De acordo com Lal *et al.* (2021), o manejo e a saúde do solo vêm assumindo papel central em programas de pesquisa e inovação direcionados a diversas metas dos ODS, como a meta 15.3, que estabelece a interrupção e a reversão da degradação do solo e da perda de biodiversidade até 2030. Os autores destacam, ainda, que outros ODS são influenciados pela qualidade do solo, como as metas 1 (erradicação da pobreza), 2 (fome zero e agricultura sustentável), 3 (saúde e bem-estar), 6 (água potável e saneamento), 7 (energia limpa e acessível), 9 (indústria, inovação e infraestrutura), 11 (cidades e comunidades sustentáveis), 12 (consumo e produção responsáveis), 13 (ação contra a mudança do clima) e 15 (vida terrestre). Algumas dessas metas dependem diretamente do solo para a produção de alimentos, enquanto outras sofrem influência dos processos naturais que ocorrem nesse meio.

Quando as causas e consequências dos processos erosivos são identificadas e mapeadas, torna-se possível aplicar medidas mitigadoras voltadas ao planejamento e à conservação ambiental (Poesen, 2018; Loureiro *et al.*, 2022). Dessa forma, mapas de suscetibilidade à erosão linear permitem identificar e representar espacialmente as áreas mais propensas ao desenvolvimento desse tipo de erosão. Esses mapas também auxiliam na compreensão dos fatores condicionantes da erosão, possibilitando analisar a relação entre esses fatores e a sua ocorrência (Shit *et al.*, 2015), além de servirem como suporte para a implementação de estratégias de prevenção e controle da erosão, orientando o planejamento do uso do solo.

Na literatura, estudos voltados ao mapeamento da suscetibilidade à erosão linear têm sido desenvolvidos em diferentes regiões do mundo, com destaque para a aplicação de técnicas de aprendizado de máquinas. Arabameri *et al.* (2020b), por exemplo, mapeou áreas suscetíveis à erosão nas proximidades da represa de Golestan,

na província de Golestan, Irã. No artigo de revisão de Mohebzadeh *et al.* (2022), os autores apresentam técnicas de aprendizado de máquina aplicadas ao mapeamento da suscetibilidade à erosão em países como Itália, Marrocos, Turquia, África do Sul, Índia e China. No Brasil, segundo Lana, Castro e Lana (2022), estudos com essas abordagens ainda são escassos.

Outro aspecto relevante diz respeito à escala da área de estudo. A maior parte dos mapeamentos de erosões é realizada em escala local, a exemplo de Arabameri *et al.* (2020b) e Mohebzadeh *et al.* (2022), e poucos trabalhos dispõem de uma base de dados robusta de pontos amostrais de focos erosivos abrangendo uma área extensa. No entanto, no estudo de Carvalho e Castro (2023), foram mapeados mais de 65 mil pontos de erosão linear em Goiás.

Localizado na região Centro-Oeste do Brasil, Goiás cobre 4% do território nacional, com área de 340.242,86 km², sendo o sétimo maior estado do país. Para contextualizar essa dimensão, o território goiano é maior que importantes nações europeias, como a Itália (301.340 km^2) e o Reino Unido (243.610 km^2). Além disso, sua área total é próxima à da Alemanha, que possui 357.022 km^2. Goiás apresenta localização estratégica e economia diversificada. Na agricultura, destaca-se como produtor de soja, sorgo, milho, feijão, cana-de-açúcar e algodão. No setor pecuário, figura entre os maiores produtores de gado do Brasil. Na indústria, atua na extração de diversas matérias-primas. O estado também possui importante rede de drenagem que abastece três regiões hidrográficas significativas: Araguaia–Tocantins, São Francisco e Paraná (Santos e Silva, 2025).

Dada a relevância do estado para diversos setores da economia nacional e considerando o estudo de Carvalho e Castro (2023), este trabalho parte do pressuposto de que, por meio da aplicação de técnicas de aprendizado de máquina em uma abordagem de classificação supervisionada, é possível avaliar a suscetibilidade à erosão linear e seus fatores condicionantes no Cerrado goiano, considerando o impacto dessa erosão nas atividades agrícolas e na economia.

1.1 Objetivos

O objetivo geral e os objetivos específicos do presente trabalho são apresentados a seguir.

1.1.1 Objetivo geral

Criar um modelo preditivo que permita mapear áreas suscetíveis à erosão linear, empregando aprendizado de máquina por meio de variáveis topográficas,

variáveis antrópicas e ambientais, avaliando quais delas exercem maior influência na ocorrência de erosão linear no contexto do Cerrado goiano.

1.1.2 Objetivos específicos

- Avaliar, por meio das análises estatísticas de validação, a performance do modelo preditivo, bem como cada variável, identificando aquelas que contribuem mais significativamente para a predição de áreas suscetíveis à erosão;
- Analisar a aplicabilidade do modelo preditivo no estado de Goiás; e
- Criar um mapa de suscetibilidade com a distribuição espacial das áreas de maior e menor suscetibilidade à erosões lineares no estado de Goiás.

1.2 Estrutura do documento

Esta dissertação foi organizada no formato de artigos, contemplando três estudos que compõem o núcleo da investigação sobre a suscetibilidade à erosão linear no Cerrado goiano. Esses artigos seguem uma ordem cronológica de desenvolvimento da dissertação, onde dados, variáveis e algoritmos puderam ser testados em uma área de estudo menor para ser ampliada posteriormente para todo o estado de Goiás. A estrutura distribuída em capítulos busca assegurar clareza na apresentação dos fundamentos teóricos, dos métodos aplicados e dos resultados alcançados, mantendo coerência entre as partes do trabalho.

O Capítulo 1, aborda o contexto geral da pesquisa, a justificativa, a problemática e os objetivos do estudo. Também são destacados os desafios relacionados à erosão linear e à necessidade de mapeamento da suscetibilidade a esse fenômeno.

No Capítulo 2, aborda a fundamentação teórica, contendo uma revisão bibliográfica sobre os principais conceitos relacionados à erosão linear, suas causas e impactos, bem como as abordagens metodológicas utilizadas para a sua predição. São abordadas também técnicas de aprendizado de máquina aplicadas ao estudo e as variáveis geoambientais mais usuais em estudos da suscetibilidade à erosão.

O Capítulo 3 reúne o primeiro artigo, intitulado "Avaliação de variáveis críticas para a ocorrência de erosões lineares utilizando algoritmos de aprendizado de máquina", publicado como capítulo de livro (Pereira *et al.*, 2025). Neste capítulo, são descritos os procedimentos empregados para identificar quais variáveis clássicas exercem maior influência na ocorrência de erosões lineares em área piloto, incluindo a seleção de algoritmos, o processo de modelagem e os resultados obtidos.

No Capítulo 4, apresenta-se o artigo "Influência da idade e vigor das pastagens na suscetibilidade à erosão linear no Cerrado" publicado nos anais do

XXI Simpósio Brasileiro de Sensoriamento Remoto, apresentando a abordagem da influência da idade da pastagem e do seu vigor na ocorrência de erosão.

O Capítulo 5 apresenta o terceiro artigo, "Predição de áreas suscetíveis à erosão linear em Goiás". Este capítulo amplia a escala de análise para todo o estado de Goiás, descrevendo a aquisição dos dados amostrais, o processamento das variáveis, a modelagem preditiva e a elaboração dos mapas de suscetibilidade.

O Capítulo 6, apresenta o produto técnico gerado a partir deste estudo. Esse produto técnico consiste em um mapa preditivo da suscetibilidade à erosão linear para todo o estado de Goiás, que poderá ser utilizado para subsidiar ações de gestão ambiental e planejamento territorial.

O Capítulo 7 sintetiza os fatores condicionantes identificados ao longo dos estudos e discute as contribuições conjuntas dos modelos para a compreensão da erosão linear em Goiás. A integração dos resultados dos três artigos permite articular evidências sobre os controles topográficos, ambientais e antrópicos observados.

Por fim, o Capítulo 8 apresenta as considerações finais. São retomados os principais achados, destacando-se as implicações para pesquisas futuras e para o uso de modelos preditivos em análises de suscetibilidade em larga escala. O capítulo encerra a dissertação demonstrando as contribuições metodológicas e aplicadas derivadas da investigação.

CAPÍTULO 2

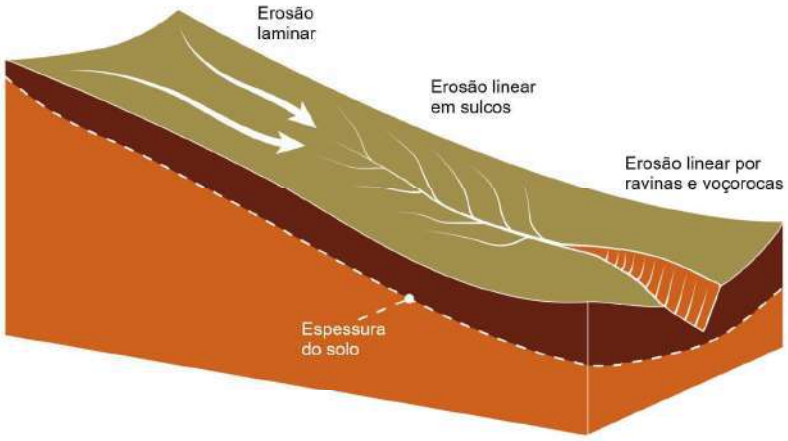
Fundamentação teórica

2.1 Erosão do solo: conceitos e consequências da degradação do solo

A erosão, em seu conceito mais amplo, é um processo geomorfológico natural de desprendimento e transporte de partículas do solo. A ocorrência envolve uma série de fatores inter-relacionados, como a dinâmica de chuvas e ventos, as características físicas, químicas e biológicas do solo, as características topográficas das encostas, a cobertura vegetal e fatores antropogênicos (Ionita *et al.*, 2015; Poesen, 2018; Goudie, 2020; Loureiro *et al.*, 2022). A erosão do solo é definida como o saldo líquido de longo prazo de todos os processos que separam e movem o solo de sua localização original (FAO, 2019).

A erosão do solo manifesta-se por meio de diferentes formas, cada qual associada a mecanismos específicos de desprendimento e transporte. A erosão laminar (*sheet erosion*) caracteriza-se pela remoção uniforme de finas camadas superficiais do solo, geralmente causada pelo impacto das gotas de chuva e pelo escoamento difuso. Quando esse escoamento se concentra, formam-se canais pequenos e transitórios, típicos da erosão linear em sulcos (*rill erosion*). Com o aumento da profundidade e largura desses canais, o processo evolui para erosão linear por ravinas e voçorocas (*gully erosion*), feições marcadas por maior capacidade de incisão e transporte sedimentar (FAO, 2019). Esses tipos representam estágios progressivos de severidade dentro da erosão hídrica (Figura 1), influenciando de maneira distinta a dinâmica hidrogeomorfológica das vertentes.

Figura 1 – *Esquema ilustrativo da distribuição espacial dos principais tipos de erosão hídrica em uma vertente. A erosão laminar (sheet erosion) ocorre nas posições superiores, caracterizada pela remoção difusa de partículas do solo. A erosão em sulcos (rill erosion) desenvolve-se onde o escoamento superficial passa a se concentrar em pequenos canais. A jusante, a concentração do fluxo evolui para incisão mais profunda, originando processos de erosão linear do tipo ravina ou voçoroca (gully erosion)*



Fonte: adaptado de FAO (2019).

Os processos de erosão natural abordados neste trabalho são aqueles relacionados à ação da água, especialmente a erosão hídrica linear. Os sulcos erosivos são fissuras pouco profundas e alongadas que se manifestam no solo em função dos fluxos hídricos concentrados (IPT, 1989; Camapum de Carvalho *et al.*, 2006). As ravinas são geradas exclusivamente pela ação do escoamento superficial concentrado, enquanto as voçorocas são compreendidas como grandes feições formadas pelo escoamento superficial e/ou subsuperficial, podendo ou não atingir o lençol freático. Suas dimensões variam entre diferentes autores, mas a maioria descreve largura e profundidade superiores a 0,5 m (Guerra, Bezerra e Fullen, 2008; Ionita *et al.*, 2015; Poesen, 2015; Goudie, 2020). Neste trabalho, será adotada a definição internacional mais generalizada de voçoroca como incisões erosivas nas encostas com profundidade acima de 0,5 m e extensão superior a 5 m (Poesen *et al.*, 2003; Goudie, 2004).

A erosão é um processo natural e, ao mesmo tempo, um processo de degradação do solo. Quando associado a fatores antrópicos, provoca o rompimento do equilíbrio hidrogeomorfológico das vertentes e ocasiona diversos impactos negativos, como o aumento da disponibilização de sedimentos nos fundos de vales e o crescimento da suscetibilidade de áreas urbanas ou rurais, conforme afirmam Guerra,

Bezerra e Jorge (2023), Sartori *et al.* (2024). Além disso, constitui uma ameaça global que afeta o funcionamento dos ecossistemas, como a fertilidade e a ciclagem de nutrientes, o que, por sua vez, reduz a produtividade do solo, levando à diminuição da produção agrícola e à liberação de dióxido de carbono para a atmosfera, contribuindo para o agravamento do aquecimento global, segundo os autores. Dessa forma, a erosão é um dos principais fenômenos da degradação do solo, podendo causar danos sociais, econômicos e ambientais (Sartori *et al.*, 2024).

Segundo Sartori *et al.* (2024), a plataforma *Global Soil Erosion Modelling* (GloSEM)[1] estima, em cenário global, um aumento médio das taxas de erosão do solo entre 30 e 66% até as décadas de 2060–2070. Tais projeções indicam que as maiores taxas de crescimento da erosão estão previstas para regiões tropical e subtropical, como o norte da América Latina e Caribe, África Central e Sudeste, China, Indonésia, Sudeste Asiático e outros países tropicais e/ou com sistema agrícola intensivo e regime de chuvas intensas.

Diante do exposto, Loureiro *et al.* (2022) salientam que a literatura apresenta diferentes métodos de monitoramento da erosão dos solos, desde os mais convencionais, como parcelas, estacas e pinos de erosão, apresentados nos estudos de Boardman e Favis-Mortlock (2016), Hart, Mills e Li (2017), Guerra *et al.* (2020), Richter *et al.* (2020), Mendes *et al.* (2024), até os mais contemporâneos, baseados em inteligência artificial (IA) e em diversos produtos oriundos de geotecnologias, como sensoriamento remoto e modelos digitais de elevação (Alves, 2019; Fernández *et al.*, 2020; Gholami, Sahour e Hadian Amri, 2021; Silva *et al.*, 2022).

2.2 Dados geográficos

Os dados geográficos são representações digitais do espaço terrestre e de seus fenômenos, permitindo análises e interpretações em diferentes contextos científicos e de gestão territorial. Esses dados podem ser classificados em dois tipos principais: vetor e raster, cada um com características próprias que influenciam sua aplicação. O tipo vetorial representa objetos espaciais como pontos, linhas e polígonos, sendo amplamente empregado para representar feições discretas, como edificações, rios e limites administrativos. Uma das vantagens dos dados vetoriais é a possibilidade de associar as geometrias a uma tabela de atributos, na qual cada representação

[1] O GloSEM é uma plataforma de modelagem global da erosão do solo em terras aráveis, destinada ao estudo do deslocamento do solo pela erosão hídrica sob cenários de mudanças climáticas entre o ano de 2019 e o futuro (2070). Considera os sistemas agrícolas regionais, os efeitos de mitigação da agricultura de conservação e as projeções de mudanças climáticas (Borrelli *et al.*, 2022).

espacial está vinculada a dados descritivos que podem incluir valores numéricos, textos (*strings*), datas, entre outros (Figura 2). Esse tipo difere de representações típicas do *Computer-Aided Design* (CAD), pois, além das geometrias espaciais, incorpora dados descritivos que enriquecem as análises espaciais.

Figura 2 – *Dados geográficos (a) Exemplo de um dado vetorial: capitais representadas como pontos, ferrovias representadas como linhas e os estados brasileiros representados como polígonos. (b) Exemplo de tabela de atributos com informações descritivas, neste caso das ferrovias*



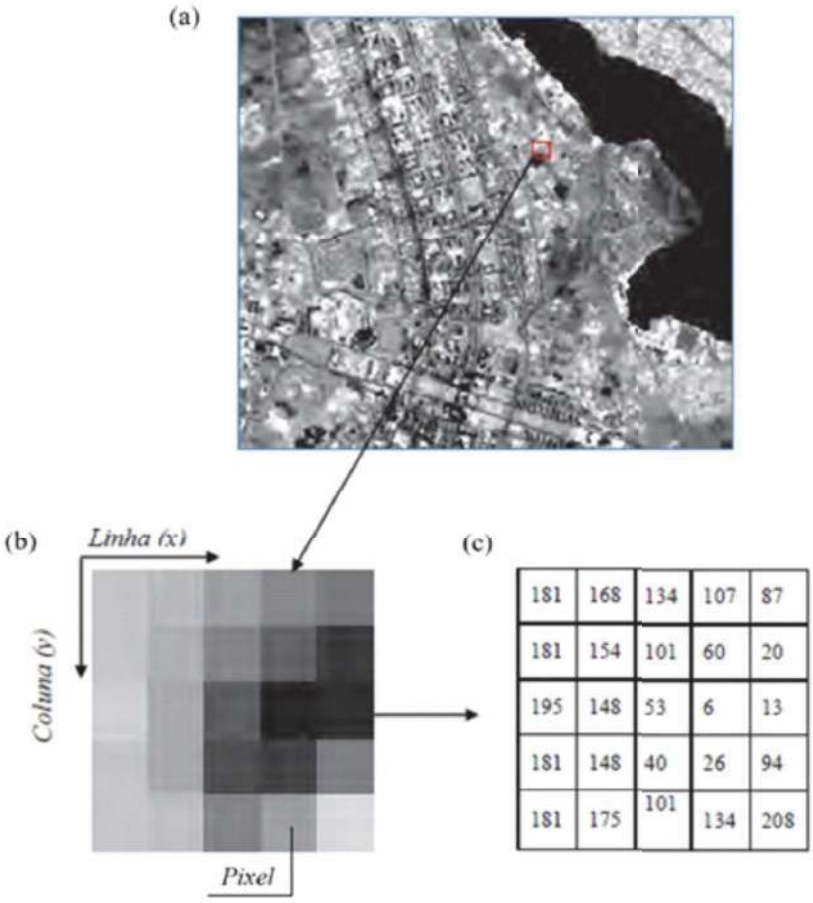
(b)

	nome	geometrias	codtrechof	posicaoinf	tipotrecho	bitola	eletrifica	entrelhas	jurisdicao
79	Estrada de Ferro Carajas - EFC	Não	NULL	Superficie	Trecho para trem	Desconhecida	Não	Simples	Desconhecida
80	Ferrovia Norte-Sul - FNS	Não	NULL	Superficie	Trecho para trem	Desconhecida	Não	Simples	Desconhecida
81	Ferrovia Norte-Sul - FNS	Não	NULL	Superficie	Trecho para trem	Desconhecida	Não	Simples	Desconhecida
82	Ferrovia Norte-Sul	Não	NULL	Superficie	Trecho para trem	Desconhecida	Desconhecido	Desconhecido	Desconhecida
83	Ferrovia Sul Atlântico - FSA	Não	NULL	Superficie	Trecho para trem	Desconhecida	Não	Simples	Federal
84	NULL	Não	NULL	Superficie	Trecho para trem	Desconhecida	Desconhecido	Desconhecido	Desconhecida
85	Ferrovias Bandeirantes	Não	NULL	Superficie	Trecho para trem	Desconhecida	Não	Simples	Federal
86	Ferrovia Sul Atlântico - FSA	Não	NULL	Superficie	Trecho para trem	Desconhecida	Não	Simples	Desconhecida
87	Ferrovia Norte-Sul - FNS	Não	NULL	Superficie	Trecho para trem	Desconhecida	Não	Simples	Propriedade particular
88	Ferrovia Norte-Sul - FNS	Não	NULL	Superficie	Trecho para trem	Desconhecida	Não	Simples	Propriedade particular
89	Ferrovia Norte-Sul - FNS	Não	NULL	Superficie	Trecho para trem	Desconhecida	Não	Simples	Propriedade particular
90	América Latina Logística	Não	1	Superficie	Trecho para trem	Larga	Não	Simples	Propriedade particular
91	América Latina Logística	Não	1	Superficie	Trecho para trem	Larga	Não	Simples	Propriedade particular
92	NULL	Não	NULL	Superficie	Trecho para trem	Desconhecida	Desconhecido	Desconhecido	Desconhecida
93	NULL	Não	NULL	Superficie	Trecho para trem	Desconhecida	Não	Simples	Desconhecida
94	Ferrovia Norte-Sul - FNS	Não	NULL	Superficie	Trecho para trem	Desconhecida	Não	Simples	Desconhecida

Fonte: elaborado pela autora (2025).

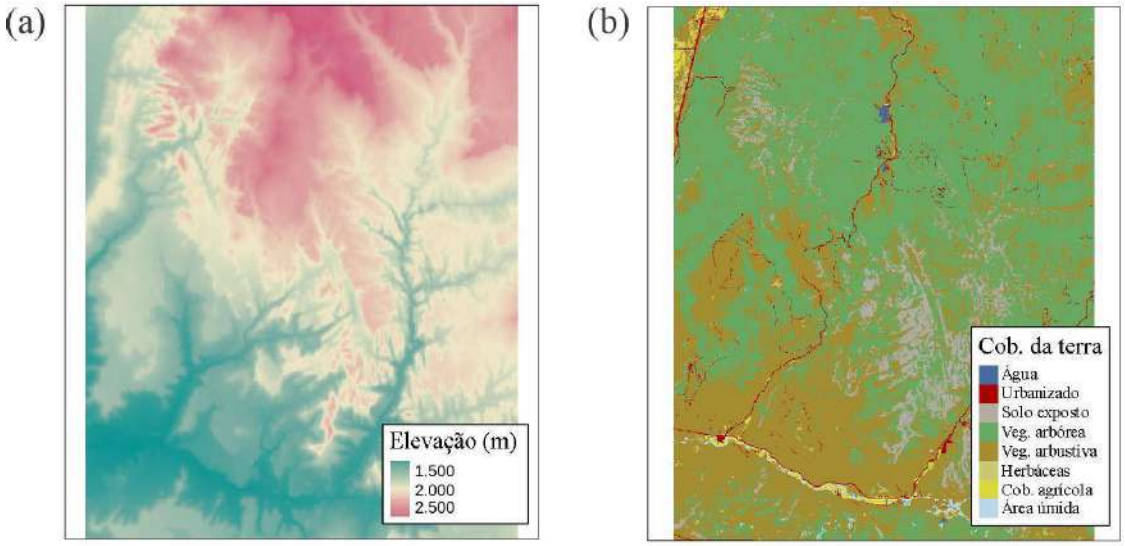
Por outro lado, o tipo raster organiza os dados espaciais em uma matriz de células (*pixels*) dispostas em linhas e colunas, em que cada *pixel* possui um valor digital que representa uma característica do fenômeno espacial. Conforme Meneses (2012), Lovelace, Nowosad e Muenchow (2019), os valores atribuídos aos *pixels* refletem as propriedades da superfície, o que torna esse tipo adequado para a representação de dados contínuos, como imagens de sensoriamento remoto e modelos digitais de elevação (Figura 3). Os dados raster também podem representar informações categóricas, como mapas de uso do solo e cobertura da terra (Lovelace, Nowosad e Muenchow, 2019), nos quais cada *pixel* recebe um valor correspondente a uma classe específica (Figura 4).

Figura 3 – *Exemplo de um dado raster: a) imagem digital, b) destaque de um grupo de pixel; c) valores digitais correspondentes*



Fonte: adaptado de Meneses (2012).

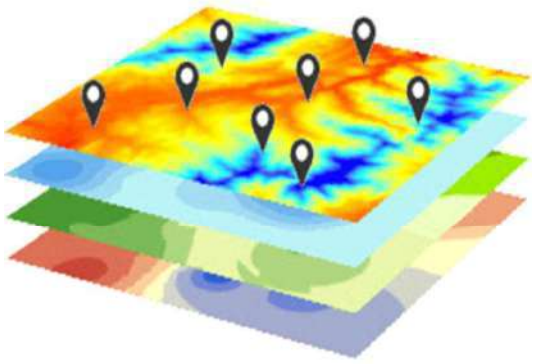
Figura 4 – *Exemplos de dados raster: a) contínuo, representado por um modelo digital de elevação; e b) categórico, representado por um produto de uso do solo e cobertura da terra*



Fonte: adaptado de Lovelace, Nowosad e Muenchow (2019).

A escolha entre os tipos vetorial e raster depende do fenômeno a ser representado e das análises a serem realizadas. Ambos os tipos podem ser integrados e são complementares em diversas aplicações de geoprocessamento. Um exemplo é a extração de valores de *pixels* para pontos amostrais, procedimento que integra dados raster e vetoriais (Figura 5). Esse processo permite obter informações pontuais a partir de diferentes camadas raster, associando os valores extraídos aos pontos amostrais de entrada (ESRI, 2017).

Figura 5 – *Extração de valores dos pixels para determinados pontos amostrais*



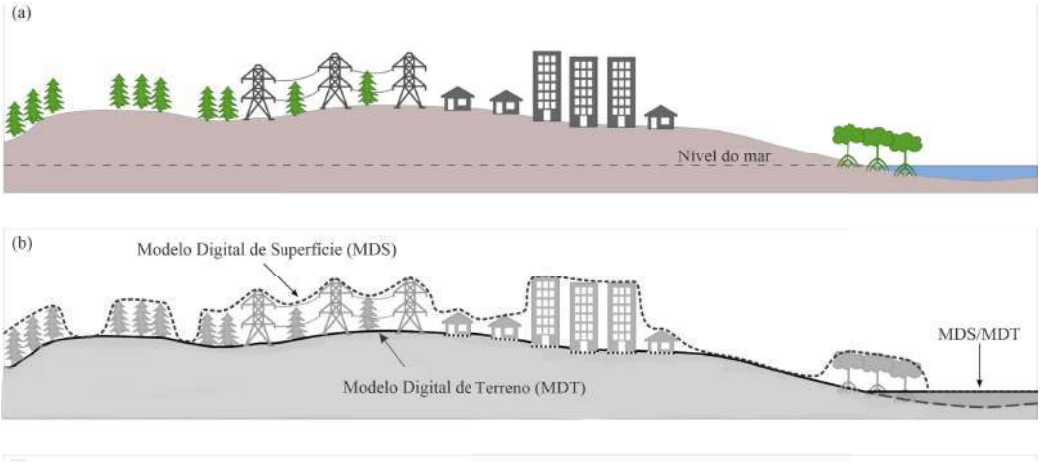
Fonte: ESRI (2017).

2.2.1 Modelo Digital de Elevação

Guth *et al.* (2021) definem o modelo digital de elevação (MDE) como uma representação digital da elevação (ou altura geométrica) de uma superfície topográfica na forma de matriz, em que cada célula (*pixel*) representa um valor altimétrico. Esses conjuntos de dados oferecem aos pesquisadores a capacidade de classificar e modelar terrenos com maior precisão e menor subjetividade em comparação com métodos tradicionais de campo (Law *et al.*, 2017). A partir de um MDE, é possível extrair variáveis morfométricas que consistem em medidas quantitativas que descrevem características do relevo de uma área específica, incluindo informações sobre declives, curvaturas, rugosidades, umidade topográfica e outras métricas da superfície terrestre (Pike, Evans e Hengl, 2009; Albuquerque *et al.*, 2020).

Além disso, o MDE pode ser subdividido em duas categorias: modelo digital de superfície (MDS), que representa as cotas da superfície da Terra, incluindo elementos acima do solo, como vegetação e objetos artificiais; e modelo digital de terreno (MDT), que representa as cotas do terreno, excluindo objetos artificiais e estruturas, como árvores e construções. A Figura 6 ilustra a representação desses modelos.

Figura 6 – *Representação: a) terreno; b) MDS em linha tracejada e MDT em linha contínua*



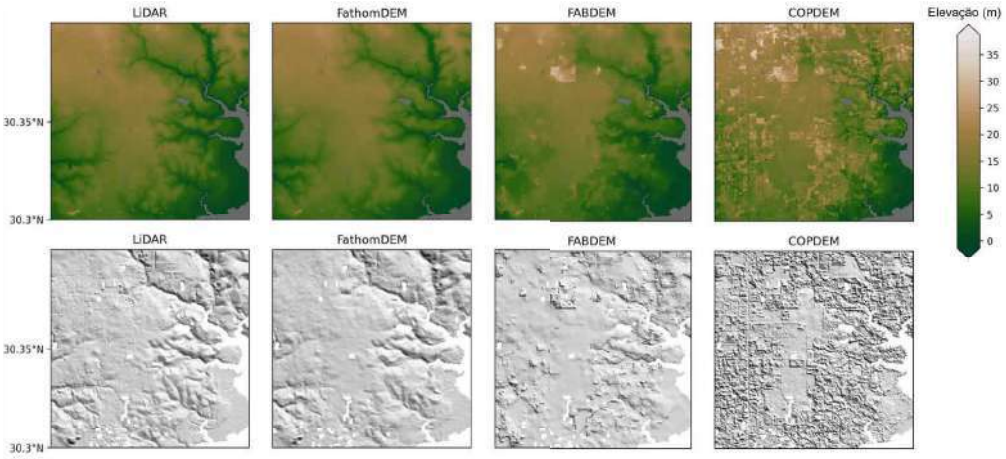
Fonte: adaptado de Guth *et al.* (2021).

Existem MDEs disponíveis em escala global com resolução de 1 segundo de arco, equivalente a aproximadamente 30 metros, como ASTER GDEM, ALOS AW3D30, SRTM, NASADEM e, mais recentemente, Copernicus GLO-30 (COP-DEM), TanDEM-X 30 e FABDEM. A qualidade desses MDEs varia consideravelmente, assim como sua adequação para diferentes tipos de aplicações. Embora COP-DEM e FABDEM se destaquem como os modelos globais MDS e MDT mais preci-

sos disponíveis atualmente, ainda há possibilidades de aperfeiçoamento (Uhe *et al.*, 2025).

Diante desse cenário, o FathomDEM (Fathom, 2025) foi produzido utilizando um modelo baseado em *Vision Transformer* e *convolutional neural network* (CNN) para remover grande parte dos vieses de altitude presentes no COPDEM, aprimorando sua precisão. A combinação dessas arquiteturas possibilita a extração de características tanto locais quanto globais, resultando em correções mais robustas e espacialmente coerentes, conforme explicam Uhe *et al.* (2025). O MDE considerado mais adequado é aquele que mais se aproxima da tecnologia *Light Detection and Ranging* (LiDAR). Na Figura 7 são ilustradas comparações entre o FathomDEM, LidarDEM, FABDEM e COPDEM. A primeira linha contém as elevações de cada MDE e a segunda linha contém os relevo sombreado, úteis para verificar se o MDE representa a superfície do terreno de forma realista.

Figura 7 – *Recorte da área ao redor de Baldwin, Alabama, EUA, comparando a diferença de elevação entre FathomDEM, FABDEM, COPDEM e o LiDAR*



Fonte: adaptado de Uhe *et al.* (2025).

2.3 Variáveis geoambientais mais usuais para mapeamento de erosões lineares

Segundo Mohebzadeh *et al.* (2022), compreender onde a erosão pode ocorrer é fundamental a seleção das variáveis que exercem maior influência no processo erosivo. Uma variedade de variáveis geoambientais está associada aos fatores que desencadeiam a erosão por voçorocas, incluindo atributos topográficos primários, obtidos diretamente das derivações do MDE, e atributos secundários, resultantes da

combinação de duas ou mais variáveis primárias ou da integração com algum índice (Moore, Grayson e Ladson, 1991).

Mohebzadeh *et al.* (2022) realizaram um levantamento na literatura, apresentando diferentes variáveis aplicadas ao mapeamento da suscetibilidade à erosão linear (Quadro 1). Essa relação permite identificar a relevância e o impacto dessas variáveis em estudos anteriores, além de subsidiar a definição das variáveis adotadas neste trabalho.

Quadro 1 – *Relação entre as variáveis mais utilizadas em pesquisas sobre a suscetibilidade à erosão linear e a quantidade de estudos*

AGRUPAMENTO	VARIÁVEIS	QUANTIDADE DE ESTUDO
Atributos topográficos primários	Elevação	17
	Declividade	17
	Curvatura horizontal (do plano)	16
	Orientação de vertente	15
	Curvatura vertical (do perfil)	12
	Índice de convergência	5
	Comprimento da vertente	4
	Área de contribuição	4
	Curvatura	1
Atributos topográficos secundários	Índice de umidade topográfica	17
	Índice de potência do fluxo	13
	Índice de rugosidade do terreno	5
	Índice de posição topográfica	5
	Textura da superfície do terreno	1
Propriedades hidrológicas	Densidade de drenagem	14
	Distância até as drenagens	13
	Precipitação	8
	Índice de capacidade de transporte	1
Fatores antropogênicos	Uso do solo e cobertura da terra	16
	Distância até a estrada	11
Propriedades da superfície do solo	Textura do solo	10
	Carbono orgânico do solo	2
	Equivalente de carbonato de cálcio	1
	Óxido de ferro	1
Outros fatores	Litologia	14
	NDVI	8
	Densidade de lineamento	2
	Cobertura vegetal fracionada	1
	Distribuição de terraço	1

Fonte: adaptado de Mohebzadeh *et al.* (2022).

Mohebzadeh *et al.* (2022) destacam variáveis relevantes para aplicação em modelos de suscetibilidade à erosão, como a elevação, que reflete a altitude do terreno, e a orientação das vertentes (*aspect*), que indica a direção da encosta. A área de contribuição (fluxo acumulado), a curvatura, a curvatura horizontal (curvatura plana), a curvatura vertical (curvatura de perfil) e o índice de convergência são citados como elementos úteis para compreender a convergência do fluxo e a acumulação de água em diferentes partes do relevo. Os autores acrescentam ainda índices específicos, como o índice de potência do fluxo (*stream power index*) e o índice de umidade topográfica, que fornecem informações sobre a concentração do fluxo e o potencial erosivo em áreas distintas. Outras variáveis topográficas, como o índice de rugosidade do terreno, o índice de posição topográfica e a textura da superfície, auxiliam na descrição da complexidade do relevo e de suas implicações no processo erosivo.

2.4 Aprendizado de máquina

Aprendizado de máquina ou *Machine Learning*, é uma das técnicas de IA empregadas para executar tarefas de aprendizado que consiste na utilização de algoritmos matemáticos e estatísticos para extrair informações de dados brutos e representá-las por meio de um modelo que será utilizado para realizar inferências ou predições a partir de novos conjuntos de dados (Escovedo e Koshiyama, 2020). Segundo (Escovedo e Koshiyama, 2020), no processo de classificação, as informações são extraídas de modo a reconhecer padrões nos dados — sejam imagens, números ou outros formatos homogêneos — permitindo a execução de tarefas automatizadas com intervenção humana mínima.

A depender do tipo de dados de entrada e dos resultados esperados, o treinamento dos algoritmos pode seguir duas abordagens principais: supervisionada e não supervisionada. Escovedo e Koshiyama (2020) esclarecem que algoritmos de aprendizagem supervisionada são utilizados para derivar modelos preditivos por meio da observação de um conjunto de dados rotulados, isto é, um conjunto cujo resultado esperado já é conhecido. Essa abordagem pode ser subdividida em aprendizagem por classificação e por regressão. No caso de classificação, o objetivo é categorizar itens ou amostras com base nas características observadas, gerando um modelo preditivo cujo resultado é categórico. No algoritmo de regressão, o objetivo é analisar variáveis e predizer um valor numérico.

No aprendizado não supervisionado, o treinamento ocorre de forma quase totalmente automatizada, sem rótulos, isto é, sem indicação prévia de classes ou valores. O algoritmo identifica estruturas internas nos dados, agrupando *pixels* ou

amostras com características similares (*clusters*) ou simplificando sua representação para melhor compreensão dos padrões.

Métodos de aprendizado de máquina supervisionado, como árvores de decisão, podem fornecer soluções que auxiliem a extração automática de informações a partir de um conjunto de dados existentes (Chagas *et al.*, 2010). O aprendizado por conjunto também denominado de métodos de *Ensemble Learning*, a exemplo do RF, combinam várias árvores de decisão para produzir melhor desempenho preditivo do que a utilização de uma única árvore de decisão. O princípio básico por trás é que um grupo de aprendizes simples se reúne para formar um aprendiz mais robusto (Breiman, 2001a). Na literatura, o modelo RF tem recebido crescente atenção devido à sua capacidade preditiva. Essa abordagem permite a análise avançada de dados geográficos e topográficos, com objetivo de aprimorar a identificação e a predição de áreas suscetíveis à erosão de forma precisa e eficiente (Rahmati *et al.*, 2017; Arabameri *et al.*, 2020a; Mohebzadeh *et al.*, 2022).

O mapeamento da suscetibilidade à erosão por ravinas e voçorocas, por meio da predição da distribuição espacial de áreas propensas à erosão linear, é fundamental para orientar estratégias de controle e mitigação voltadas à conservação do solo.

CAPÍTULO 3

Artigo 1 - Avaliação de variáveis críticas para a ocorrência de erosões lineares utilizando algoritmos de aprendizado de máquina

Texto publicado em: PEREIRA, Alessandra Cristina; CREMON, Édipo Henrique; ABREU, Laudier Lopes; CARVALHO, Hellbia Samara Moreira de. Avaliação de variáveis críticas para a ocorrência de erosões lineares utilizando algoritmos de aprendizado de máquina. In: GOMES, Raphael de Aquino; MENDES, Thiago Augusto; OLIVEIRA, Sérgio Botelho de (Ed.). *Inovação e Sustentabilidade em Goiás: Perspectivas Interdisciplinares*. Curitiba: CRV, 2025, (Coleção: ECOS, v. 1). p. 31–46. ISBN 978-65-251-7324-5.[1]

3.1 Introdução

A erosão do solo, particularmente a formação de erosão linear por ravinas e voçorocas, é uma das formas mais destrutivas de degradação do solo. Esse processo compromete a produtividade agrícola, a segurança alimentar e a capacidade do solo de armazenar água e nutrientes (Valentin, Poesen e Li, 2005; Boardman *et al.*, 2003; Sartori *et al.*, 2024), além de colocar em risco infraestruturas, como estradas e edificações. A formação de erosões lineares é influenciada pela combinação de variáveis associadas a fatores geomorfológicos, hidrológicos, antrópicos, geológicos, pedológicos e ambientais (Ionita *et al.*, 2015; Poesen, 2015; Arabameri *et al.*, 2020a).

A prevenção e o manejo sustentável são essenciais para mitigar esses impactos, alinhando-se aos Objetivos de Desenvolvimento Sustentável (ODS) (United Nations, 2015), como a meta 15.3, que visa neutralizar a degradação do solo. Os

[1]Este artigo foi publicado como capítulo de livro (Pereira *et al.*, 2025).

mapas de susceptibilidade à erosão linear permitem identificar e representar espacialmente as áreas mais propensas ao desenvolvimento desse tipo de erosão. Esses mapas também são úteis para compreender os fatores condicionantes da erosão, possibilitando a análise da relação entre esses fatores e a ocorrência da erosão (Shit *et al.*, 2015), bem como, auxiliam gestores e tomadores de decisão na implementação de estratégias de prevenção e controle da erosão, orientando o planejamento do uso do solo.

Técnicas de aprendizado de máquina supervisionado permitem que algoritmos identifiquem padrões em grandes conjuntos de dados, gerando resultados mais eficazes na predição de áreas suscetíveis à erosão linear (Rahmati *et al.*, 2017; Arabameri, Pradhan e Rezaei, 2019; Arabameri *et al.*, 2020b; Mohebzadeh *et al.*, 2022). A região sudoeste do estado de Goiás é caracterizada por uma grande quantidade de erosões lineares, que têm sido pesquisadas por diferentes abordagens (Nunes e Castro, 2015; Nunes e Castro, 2023; Carvalho e Castro, 2023). Portanto, o objetivo deste trabalho é avaliar quais variáveis são mais importantes para a ocorrência de erosões lineares, utilizando algoritmos de aprendizado de máquina.

3.2 Materiais e métodos

3.2.1 Área de estudo

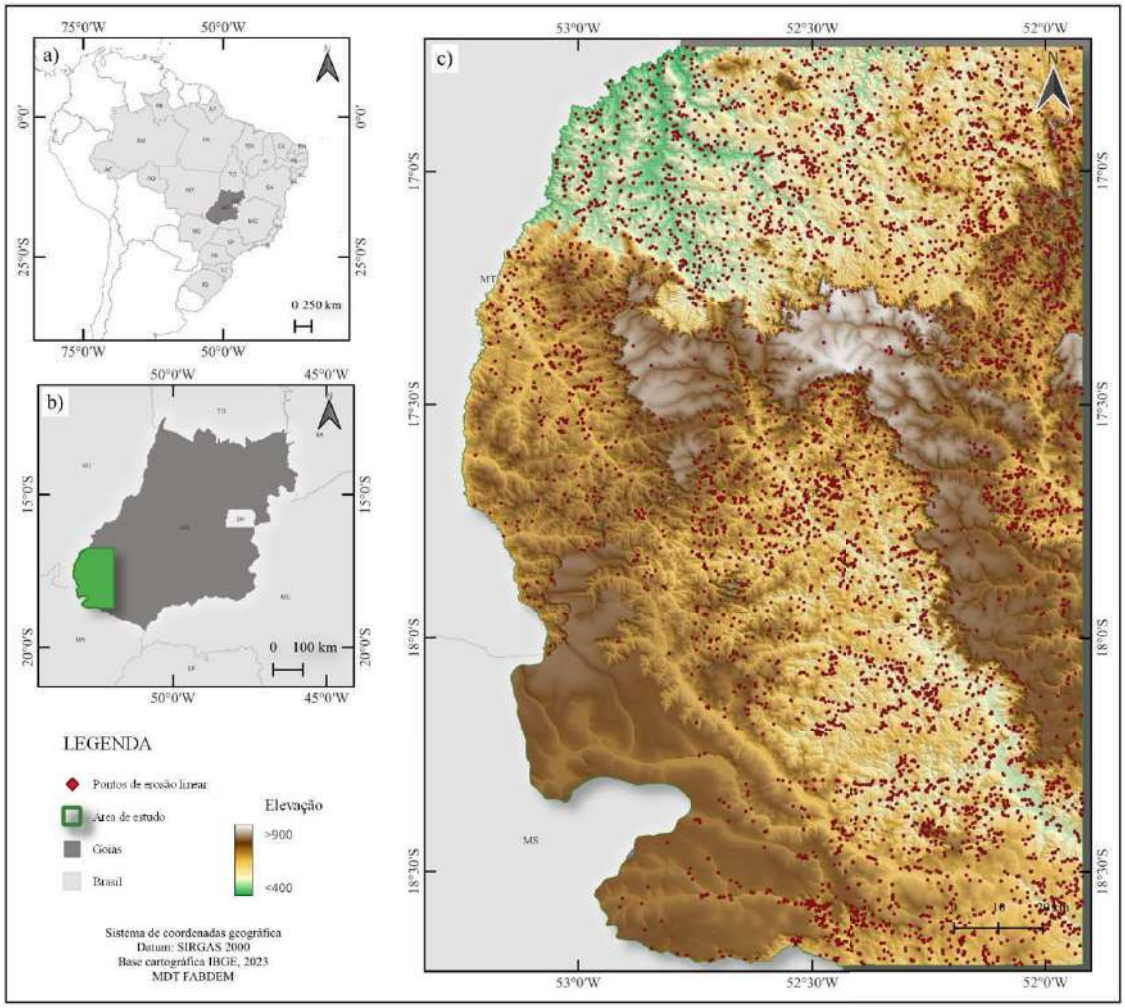
A área de estudo inclui parte da porção sudoeste do estado de Goiás, na região centro-oeste do Brasil, mais precisamente na região de Mineiros, totalizando uma área de 26.552,75 km² (Figura 8). Esta região foi escolhida porque possui mapeamento de solos de referência na escala de 1:50.000 (Nunes e Castro, 2015; Cremon *et al.*, 2021).

A geologia da região é composta por uma diversidade de rochas sedimentares (IBGE, 2023), como arenitos e rochas intrusivas básicas, o que resulta em uma topografia com feições escalonadas. Na área ao norte, predominam depósitos sedimentares fanerozoicos, incluindo arenitos, folhelhos e siltitos da Formação Aquidauana, com elevações que podem chegar a 590 metros. Em áreas estreitas próximas aos cursos d'água, observa-se a presença de arenitos e siltitos da Formação Corumbataí, onde também ocorrem Neossolos. Nas encostas, são frequentes os Argissolos Vermelhos, enquanto as áreas mais elevadas, próximas aos divisores de drenagem, abrigam Latossolos Vermelho-Amarelos.

A transição para o sul é marcada pela presença de rochas basálticas da Formação Serra Geral e folhelhos da Formação Irati, áreas que se destacam por relevos mais acidentados, onde os Neossolos Litólicos são dominantes. No setor

central, prevalecem arenitos eólicos da Formação Botucatu, em altitudes que variam entre 500 e 1.000 metros, constituindo extensas áreas de Neossolos Quartzarênicos, enquanto Latossolos Vermelhos e Vermelho-Amarelos ocupam a parte oeste. Na região centro-leste e ao sul, ocorrem depósitos sedimentares fanerozoicos formados por argilas, arenitos e camadas arenosas da Formação Cachoeirinha. Nessas áreas, predomina uma topografia plana, com Latossolos Vermelhos são abundantes nas encostas, enquanto Gleissolos Háplicos se encontram nas proximidades da rede de drenagem (Cremon *et al.*, 2021).

Figura 8 – *Localização da área de estudo. a) Brasil (cinza claro) no contexto da América do Sul; b) Estado de Goiás (cinza escuro) e a área de estudo (verde); c) Localização dos focos erosivos mapeados (Carvalho e Castro, 2023)*



Fonte: elaborado pela autora (2025).

3.2.2 Material e métodos

Para a análise da suscetibilidade à ocorrência de erosão linear na região sudoeste do estado de Goiás, foram obtidas 5.978 amostras pontuais que indicam a presença de voçorocas e ravinas, mapeadas no ano de 2018 (Carvalho e Castro, 2023). Para garantir a representatividade dos dados de ausência e minimizar a influência de áreas próximas, evitando, assim, correlações espaciais indesejadas, em complementação foram geradas aleatoriamente 5.978 amostras de ausência de erosão linear, garantindo que houvesse uma distância mínima de 2 km entre cada uma delas.

A modelagem incluiu um total de 25 variáveis frequentemente associadas aos fatores que desencadeiam a erosão por voçorocas, conforme relatado na literatura (Mohebzadeh *et al.*, 2022). Dentre essas variáveis, 15 foram extraídas do modelo digital de terreno FABDEM (Neal *et al.*, 2023) (Quadro 2), utilizando os *softwares* SAGA GIS (Conrad *et al.*, 2015) e Whitebox (Lindsay, 2016). Foram consideradas três variáveis ligadas à geologia, que incluem uma variável categórica de litologia e dois produtos raster que representam a distância euclidiana em relação ao contato litológico e aos lineamentos geológicos.

Quadro 2 – *Variáveis topográficas extraídas do modelo digital de terreno FABDEM*

Área de contribuição (m)	Elevação (m)	Índice de umidade topográfica (TWI) (adimensional)
Curvatura horizontal (m^{-1})	Fator LS (adimensional)	Índice de umidade topográfica do SAGA (SAGA TWI) (adimensional)
Curvatura vertical (m^{-1})	Índice de convergência (adimensional)	Orientação de vertentes (°)
Declividade (°)	Índice de posição topográfica (IPT) (adimensional)	Índice de potência do fluxo (adimensional)
Distância vertical da rede de drenagem (VDCN) (m)	Índice de rugosidade do terreno (TRI) (m)	Textura do terreno (adimensional)

Fonte: elaborado pela autora (2025).

Para o cálculo do fator LS, correspondente à variável topográfica da Equação Universal de Perda de Solos (USLE), foram testados diferentes métodos disponíveis no *software* SAGA GIS. Entre os métodos analisados, destacam-se as abordagens

propostas por Moore, Grayson e Ladson (1991), Desmet e Govers (1996), Boehner e Selige (2006). A partir dos testes preliminares realizados, o método desenvolvido por Boehner e Selige (2006) demonstrou uma melhor capacidade preditiva em relação aos outros métodos avaliados, o que justificou sua escolha para o cálculo do fator LS nesta pesquisa.

No que diz respeito às variáveis hidrológicas, foram incluídos a erosividade da chuva, expressa pelo fator R da Equação Universal de Perda de Solos (USLE), com base em dados disponíveis para a região (Panagos *et al.*, 2017), e a densidade da rede de drenagem, considerando um raio de 1 km. Quanto às propriedades pedológicas, a erodibilidade do solo foi considerada, representada pelo fator K da USLE, também referente à área em análise (Nunes e Castro, 2023).

Para as variáveis antrópicas e de uso do solo, foram consideradas a distância euclidiana em relação à malha viária e, como variáveis categóricas, mapa geológico do IBGE (IBGE, 2023) e mapa de uso do solo e cobertura da terra (*land use and land cover* - LULC) do MapBiomas, coleção 9 (Souza Júnior *et al.*, 2020), correspondente ao ano de 2018. Este ano coincide com o período em que o mapeamento das feições erosivas foi realizado. Além disso, foi incluído o NDVI, calculado a partir da mediana da coleção de imagens do sensor MSI/Sentinel-2 para o mesmo ano.

A predição foi realizada utilizando algoritmos de classificação supervisionada baseados em *ensemble* de árvores de decisão, implementados no pacote de aprendizado de máquina *caret* (Kunh *et al.*, 2021), no *software R* pela interface do *RStudio*. Foram testados quatro algoritmos: *Gradient Boosting Machine* (GBM), *eXtreme Gradient Boosting* (XGBoost), RF e uma variação otimizada do RF denominada *RF Ranger*, uma implementação eficiente e rápida para dados de alta dimensionalidade (Wright, Wager e Probst, 2020).

Os algoritmos GBM e XGBoost são métodos baseados em *boosting*, na qual múltiplas árvores de decisão são combinadas sequencialmente para melhorar o desempenho preditivo. No *boosting*, cada árvore aprende com os erros da árvore anterior, ajustando gradualmente o modelo para reduzir os erros residuais ao longo das iterações (Friedman, 2001). Por outro lado, os algoritmos RF e *RF Ranger* utilizam o método de *bagging* (ou agregação), em que várias árvores de decisão são geradas de forma independente a partir de diferentes amostras do conjunto de dados, e suas predições são combinadas para formar a predição final. Assim, a utilização de algoritmos tanto de *boosting* quanto de *bagging* permitiu comparar as performances desses métodos de ensemble para predição de áreas suscetíveis à erosão linear, considerando diferentes abordagens de combinação de árvores de decisão.

Estes algoritmos foram aplicados seguindo a validação cruzada do tipo *k-fold*, com $k = 10$, para o treinamento e calibração do modelo. Para aferir a con-

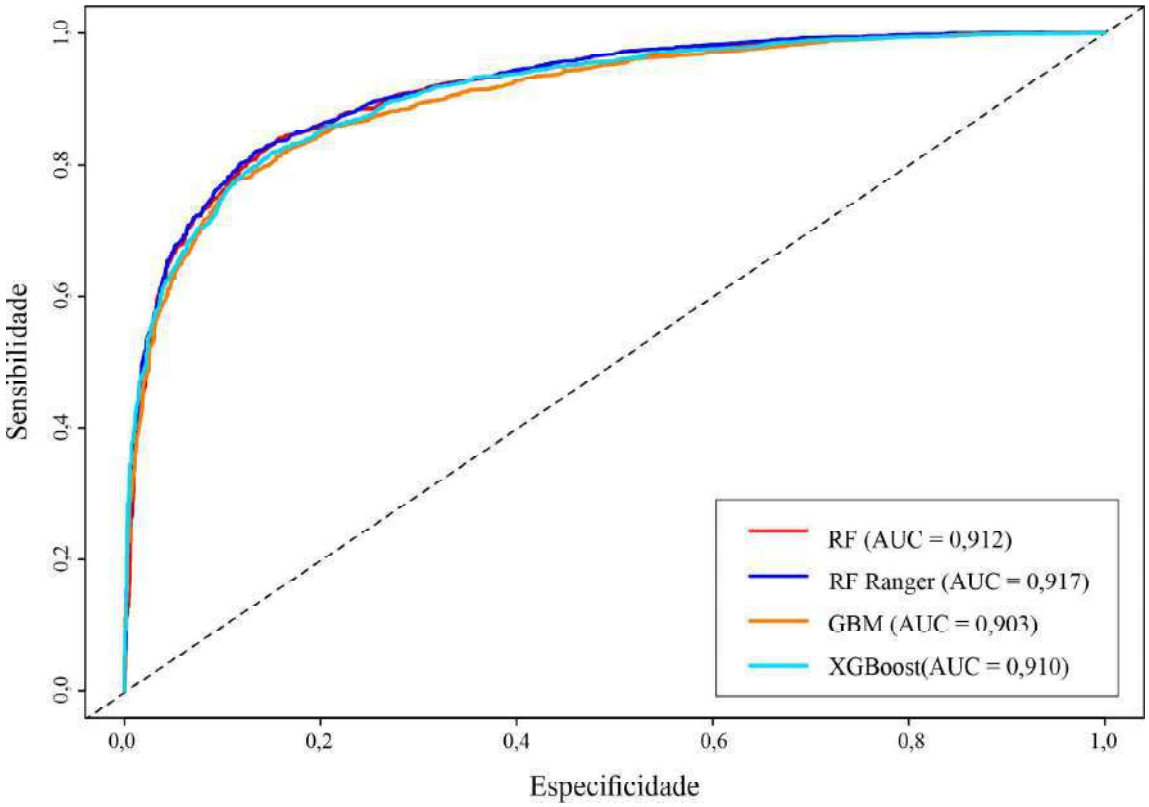
fiabilidade dos resultados da classificação foram utilizadas amostras independentes (30%) do treinamento (teste) e avaliadas pela métrica de performance AUC.

Para a avaliação de quais variáveis foram mais importantes para a ocorrência de erosões lineares, foram utilizadas métricas para cada algoritmo, normalizados em valores entre 0 e 100, permitindo assim a comparação relativas entre eles. O algoritmo RF utiliza o critério de impureza de Gini para quantificar a redução de impurezas em cada nó da árvore de decisão, estabelecendo também um ranqueamento da importância das variáveis preditoras (Breiman, 2001b). Os classificadores GBM e XGBoost, por sua vez, baseia-se em uma métrica denominada ganho, que representa a contribuição de cada variável preditora para o modelo, baseada na melhoria (ganho total) das divisões geradas por essa variável (Kuhn, 2008; Kunh *et al.*, 2021). Por fim, foi utilizado o *software* (QGIS Development Team, 2024), para elaboração do produto cartográficos compatível para a escala 1:50.000.

3.3 Resultados

Os modelos de aprendizado de máquina avaliados apresentam bons desempenhos na predição de áreas suscetíveis à erosão linear, conforme evidenciado pelas AUCs próximas a 1.0 (Figura 9). O modelo *RF Ranger* obteve o maior valor de AUC de 0,9166, indicando uma boa capacidade de discriminação entre as classes e superando ligeiramente os demais modelos. O modelo RF tradicional obteve AUC de 0,9124, seguido pelo XGBoost, com AUC de 0,9099, demonstrando que ambos possuem alta performance e comparabilidade (Figura 9). Por fim, o modelo GBM alcançou AUC de 0,9032, ainda apresentando um desempenho alto, mas um pouco inferior aos outros métodos. Esses resultados mostram que todos os modelos tiveram bons desempenhos, mas o *RF Ranger* e o RF se destacam em termos de eficácia na identificação das áreas suscetíveis à erosão linear.

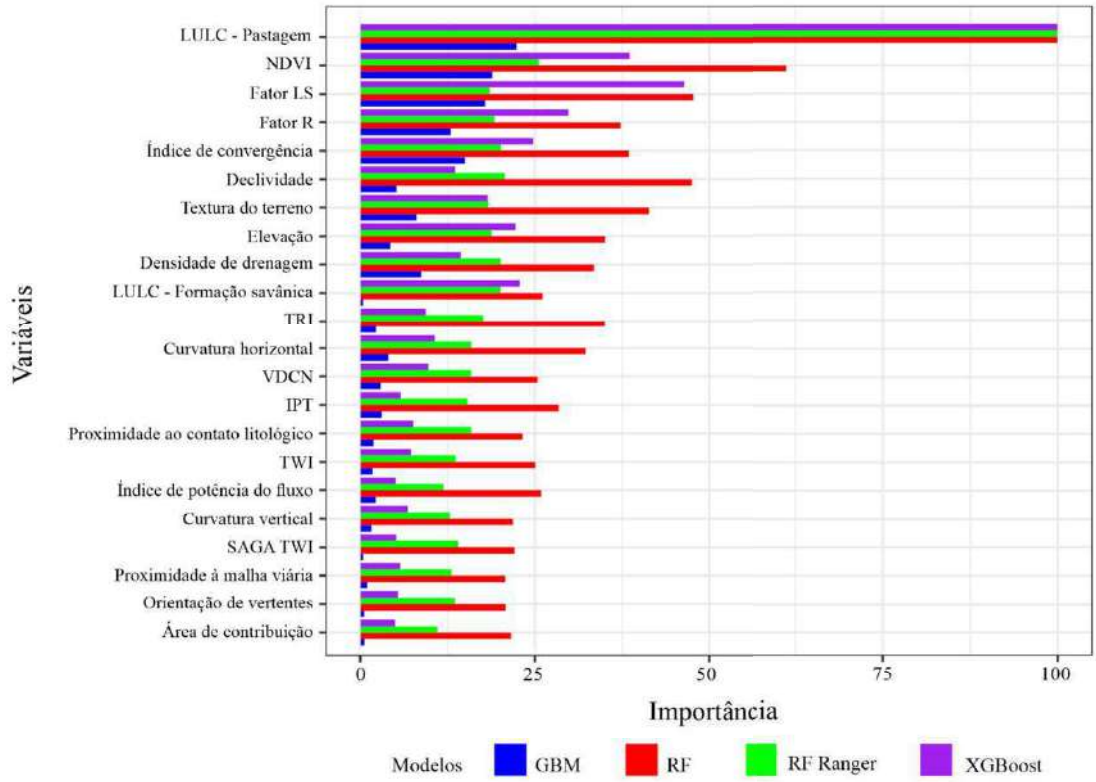
Figura 9 – *Desempenho dos algoritmos RF, RF Ranger, GBM e XGBoost, de acordo com curva Receiver Operating Characteristic (ROC)*



Fonte: elaborado pela autora (2025).

Os resultados apresentados destacam a importância de variáveis relacionadas ao uso do solo e cobertura da terra e à vegetação (Figura 10), como a variável "LULC - Pastagem", que aparece no topo da lista com uma importância de 100% em todos os modelos. O "NDVI" também se destaca nos modelos, sugerindo que a saúde da vegetação influencia na susceptibilidade à erosão linear.

Figura 10 – *Importância das variáveis para os algoritmos avaliados*



Fonte: elaborado pela autora (2025).

Outros fatores topográficos e climáticos, como o "Fator LS", "Declividade" e o "Fator R", também estão entre as variáveis mais importantes, principalmente nos modelos de RF e XGBoost. Observa-se que modelos distintos atribuem níveis variados de importância a determinadas variáveis. Por exemplo, enquanto o "Fator LS" e a "Declividade" apresentam maior relevância no RF e no *RF Ranger*, o "Fator R" se destaca no XGBoost. Essa variação reflete as diferenças entre os algoritmos quanto ao modo como processam e priorizam as variáveis. Esse comportamento reforça a necessidade de avaliar múltiplos modelos para obter uma visão ampla dos fatores que contribuem para a suscetibilidade à erosão.

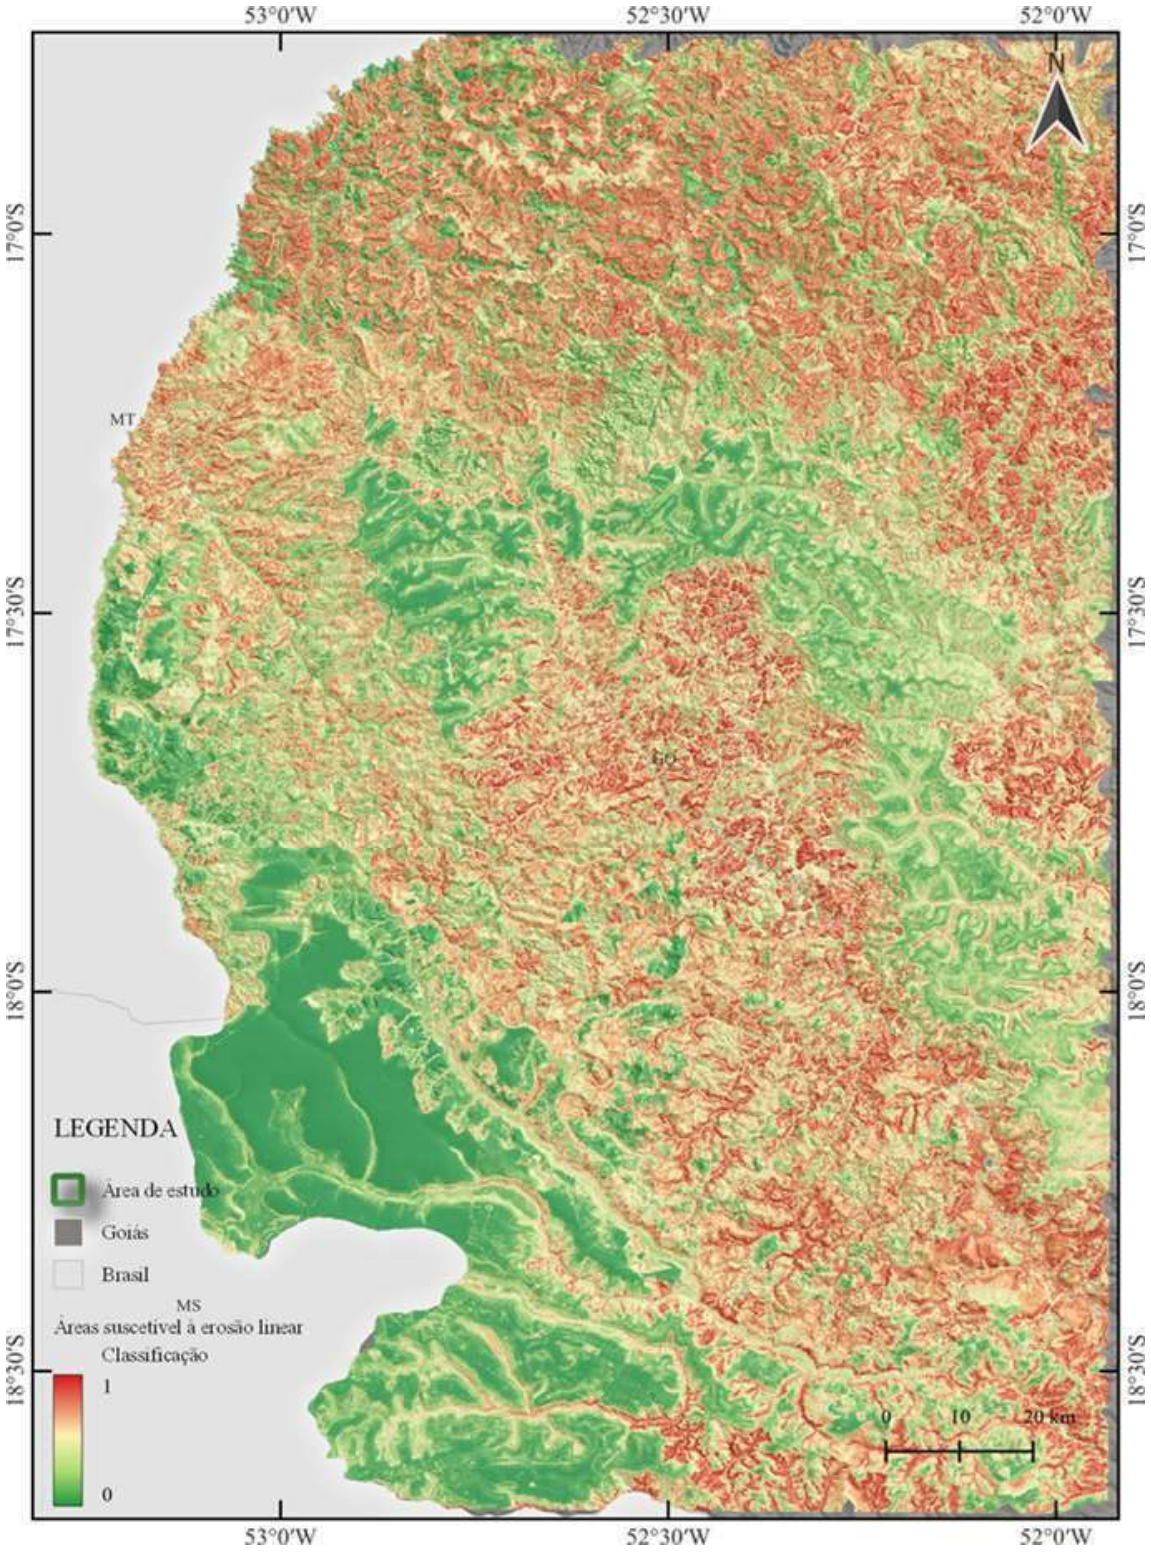
O "Índice de Convergência" e a "Curvatura Horizontal" destacaram-se como variáveis importantes nos modelos, sugerindo que a convergência de fluxo hídrico e a configuração da superfície exercem influência sobre os processos erosivos. A "Textura do Terreno" e o "TRI" também figuraram entre as variáveis topográficas mais relevantes, reforçando o papel dos aspectos de rugosidade topográfica na suscetibilidade à erosão linear. A "Densidade de Drenagem", que também apresentou importância elevada, contribui ao indicar a influência da rede de drenagem na

organização do fluxo hídrico, em que áreas com maior densidade de canais podem concentrar o escoamento, aumentando a ocorrência de erosão localizada.

Variáveis como “Proximidade ao Contato Litológico”, “Proximidade de Lineamentos” e “Proximidade à Malha Viária” apresentaram importância moderada em todos os modelos. Após a avaliação do desempenho das métricas de validação, o modelo com melhor resultado foi utilizado para gerar o mapa de suscetibilidade à erosão linear da área de estudo.

As áreas menos suscetíveis à erosão linear estão associadas a topografias planas e à presença de vegetação natural, que protege o solo do impacto direto da chuva e do escoamento superficial. Em algumas áreas agrícolas com plantio de soja, onde há práticas de manejo adequadas, a ocorrência de erosão linear também é reduzida. Em contraste, as áreas mais suscetíveis encontram-se predominantemente nas cabeceiras de drenagem, onde fatores como alta declividade, solos mais erodíveis, convergência de fluxo hídrico e menor adoção de práticas conservacionistas favorecem o desenvolvimento de processos erosivos intensos. O dado raster gerado, indica valores variando entre 0 (menor suscetibilidade) a 1 (maior suscetibilidade) (Figura 11).

Figura 11 – *Mapa de suscetibilidade à erosão linear, de acordo com o algoritmo RF Ranger*



Fonte: elaborado pela autora (2025).

3.4 Discussão

Os resultados dos algoritmos revelam variações entre os desempenhos de classificadores baseados em *bagging* e *boosting*. No presente estudo, o *RF Ranger*, um classificador baseado em *bagging*, obteve o maior valor de AUC (0,9166), superando ligeiramente o *Random Forest* tradicional (AUC de 0,9124) e os algoritmos baseados em *boosting*, o XGBoost (AUC de 0,9099) e o GBM (AUC de 0,9032). No entanto, o melhor desempenho de classificadores baseados em *bagging* neste caso não representa uma regra geral. Em alguns estudos, algoritmos de *boosting* apresentaram AUC mais elevados em relação ao RF (Arabameri *et al.*, 2021; Hasanuzzaman e Shit, 2024). A literatura evidencia que o RF tem sido consistentemente uma ferramenta preditiva poderosa em estudos de suscetibilidade à erosão linear, servindo como parâmetro de comparação para outras abordagens (Mohebzadeh *et al.*, 2022). Esses resultados reforçam que ambas abordagens, *bagging* e *boosting*, podem oferecer desempenho robusto e comparável dependendo do contexto do estudo e conjunto de dados.

Sobre as variáveis mais preditivas, os resultados apontam que variáveis relacionadas ao uso do solo e a cobertura da terra destacaram-se na modelagem da suscetibilidade à erosão linear. A classe "Pastagem" mostrou-se especialmente relevante, provavelmente devido ao impacto do manejo e da compactação do solo, fatores que podem elevar a suscetibilidade do solo à erosão (Galdino *et al.*, 2016; Nunes e Castro, 2023). Áreas convertidas em pastagens apresentam numerosos trilheiros de gado, cercas de divisa e estradas vicinais sem medidas preventivas de controle de enxurrada tem favorecido o surgimento de erosões (Santana *et al.*, 2007; Nunes e Castro, 2015). Em três modelos (RF, *RF Ranger*, GBM), a segunda variável mais importante foi o "NDVI", que indica a densidade e a saúde da vegetação. Esse resultado reforça a importância da cobertura vegetal para a proteção contra a erosão, pois vegetações densas e saudáveis tendem a diminuir a exposição do solo às forças erosivas.

A erosividade das chuvas, dado pelo "Fator R", indica que tanto o clima quanto o uso do solo têm papéis importantes na predisposição à erosão linear, pois a intensidade e a frequência das chuvas podem aumentar o impacto das gotas d'água sobre o solo exposto, facilitando o desprendimento de partículas e o transporte de sedimentos em áreas suscetíveis (Santana *et al.*, 2007).

Do ponto de vista geomorfológico, o "Fator LS" e a "Declividade" são conhecidos por afetarem o transporte de sedimentos e a formação de sulcos erosivos (Boehner e Selige, 2006), principalmente em áreas de pastagem, onde a cobertura da terra é reduzida (Galdino *et al.*, 2016). Esses fatores contribuem para que essas variáveis sejam importantes nos modelos preditivos de erosão. A convergência de

fluxo hídrico, representada pelo índice de convergência e pela curvatura horizontal, também exerce influência na erosão, intensificando seu impacto em áreas mais suscetíveis (Chaplot, 2013). No sudoeste goiano, as condições topográficas que canalizam o fluxo hídrico tendem a intensificar os processos erosivos (Nunes e Castro, 2023).

As erosões lineares estão fortemente associadas aos cursos d'água e ao lençol freático. Entre as variáveis topográficas, a VDCN tem sido apontada como uma das mais importantes na criação de produtos de suscetibilidade à voçorocas (Huang *et al.*, 2022). Em áreas onde o lençol freático é mais raso e apresenta menor altura em relação à rede de drenagem (VDCN), o processo de exfiltração - em que a água subterrânea é forçada a emergir para a superfície devido a pressões hidráulicas - pode amplificar as condições favoráveis para o desenvolvimento de voçorocas (Marinho, Castro e Campos, 2006). Outra variável topográfica de destaque é o IPT, uma vez que erosões lineares, como voçorocas, tendem a se formar em áreas com valores negativos de IPT, indicando que elas ocorrem geralmente em áreas de menor elevação em relação ao entorno (Garosi *et al.*, 2019). Essa condição topográfica favorece o acúmulo e o escoamento concentrado de água, que, ao longo do tempo, intensifica a erosão do solo.

Fatores associados a valores baixos de IPT, ao acúmulo de água superficial e subterrânea, à menor resistência à erosão em solos erodíveis e à presença de fluxos convergentes de água potencializam a formação e o aprofundamento de sulcos erosivos. Em tais áreas, o processo de erosão linear tende a ser mais intenso, especialmente em solos de baixa coesão e em regiões com alto índice pluviométrico. O Fator K, ou fator de erodibilidade dos solos, é uma medida associada à capacidade do solo em resistir aos processos erosivos. Em geral, solos com características como os Neossolos Quartzarênicos, os Argissolos e os Latossolos com textura média a arenosa, apresentam uma baixa coesão e menor resistência à erosão (Nunes e Castro, 2015; Nunes e Castro, 2023), especialmente em relação à erosão linear. Essas classes de solo são predominantemente arenosas, o que facilita a infiltração de água em profundidade e, ao mesmo tempo, reduz a retenção de partículas na superfície, permitindo que elas sejam facilmente transportadas por enxurradas e fluxos concentrados. Essa fragilidade estrutural do solo, associada a fatores geomorfológicos como a declividade e a convergência de fluxo, contribui para a formação e intensificação de sulcos e voçorocas, particularmente em áreas sujeitas a intensas precipitações e ao uso intensivo para pastagem ou agricultura (Santana *et al.*, 2007).

A importância moderada das variáveis "Proximidade ao Contato Litológico", "Proximidade de Lineamentos" e "Proximidade à Malha Viária" nos modelos

de suscetibilidade à erosão pode estar relacionada a características geológicas e estruturais que influenciam o equilíbrio hidrológico e o comportamento erosivo em algumas regiões. A presença de lineamentos estruturais, falhas geológicas e contatos litológicos frequentemente define áreas de fragilidade no relevo, que podem favorecer o fluxo de água, tanto superficial quanto subsuperficial, contribuindo para a formação de erosões lineares e processos de *piping* (Marinho, Castro e Campos, 2006). Essas descontinuidades litológicas em encostas facilitam o desenvolvimento de caminhos preferenciais para o escoamento de água, promovendo a saturação e até o colapso do solo em alguns casos. Quanto a proximidade à malha viária, ao alterar a dinâmica do escoamento de água e fragmentar a paisagem, pode gerar áreas suscetíveis a processos erosivos ao redor das estradas, especialmente em estradas mal planejadas como é relatado na área de estudo (Santana *et al.*, 2007). Dessa forma, esses fatores geológicos e de infraestrutura contribuem para ajustes locais na suscetibilidade à erosão, influenciando modelos em regiões específicas, onde a interação entre estrutura geológica e escoamento favorece a degradação do solo e o desenvolvimento de ravinas e voçorocas.

3.5 Conclusão

No contexto do Cerrado, a identificação de variáveis críticas associadas à erosão linear é uma ferramente útil para o planejamento sustentável do uso do solo. Este estudo demonstrou a eficácia de algoritmos de aprendizado de máquina na identificação de áreas suscetíveis à erosão linear, evidenciando especialmente a relevância das variáveis de uso do solo e cobertura do terra, fatores topográficos e hidrológicos. Entre os modelos avaliados, algoritmos de árvore de decisão baseados em *bagging* apresentaram melhor desempenho, superando ligeiramente outros modelos com algoritmos de *boosting*.

Dentre as variáveis mais influentes para predizer a suscetibilidade à erosão linear no sudoeste goiano, destacam-se a pastagem e o NDVI, indicando que o papel da cobertura vegetal na proteção contra erosão. Adicionalmente, condições topográficas com maiores declividades, rugosidade topográfica e convergência de fluxo hídrico, comuns em zonas de cabeceira de drenagem, intensificam essa suscetibilidade. Enquanto características do solo, como a textura arenosa, aumentam sua suscetibilidade à erosão. Essa combinação de fatores reforça a complexidade dos processos de erosão no Cerrado, destacando a necessidade de considerar múltiplos aspectos na modelagem da suscetibilidade.

Os resultados deste estudo sugerem que a utilização de múltiplos modelos preditivos pode fornecer uma análise dos fatores que contribuem para a erosão linear.

Ao identificar áreas de alta suscetibilidade e os fatores desencadeadores, é oferecido subsídios para o planejamento e a implementação de estratégias de manejo ambiental no Cerrado, auxiliando na preservação do solo e na mitigação dos impactos da erosão.

CAPÍTULO 4

Artigo 2 - Influência da idade e vigor das pastagens na suscetibilidade à erosão linear no Cerrado

Texto parcialmente publicado em: PEREIRA, A. C.; CREMON, É. H.; ABREU, L. L.; SANTOS, D. A. R.; CARVALHO, H. S. M. Influência da idade e vigor das pastagens na suscetibilidade à erosão linear no Cerrado. In: XXI Simpósio Brasileiro de Sensoriamento Remoto, 2025, Salvador, BA. *Anais...* São José dos Campos: INPE, 2025. p. 1083-1086. Internet. ISBN 978-65-89159-04-9. IBI: <8JMKD2USPQW34M/4E3EFHB>. Disponível em: <http://urlib.net/ibi/8JMKD2USPQW34M/4E3EFHB>.

4.1 Introdução

A erosão linear do solo, manifestada como ravinas e voçorocas, configura uma grave ameaça ambiental que compromete a fertilidade do solo e a produtividade agrícola (Boardman *et al.*, 2003; Valentin, Poesen e Li, 2005). Este fenômeno causa danos particularmente severos aos ecossistemas e às atividades antrópicas, representando um risco significativo para a sustentabilidade ambiental e a segurança alimentar global (Borrelli *et al.*, 2017). A predição eficaz de áreas suscetíveis a esse processo constitui, portanto, um instrumento para o planejamento de estratégias eficazes de conservação e mitigação.

A ocorrência de erosão linear associa-se a uma complexa interação de fatores geoambientais, como clima, geomorfologia, hidrologia, pedologia, uso do solo e cobertura da terra (Arabameri *et al.*, 2020a). No bioma Cerrado, onde o desmatamento e a conversão de terras para pastagens foram e são intensos, pesquisas realizadas no estado de Goiás identificaram que essas áreas desempenham um papel importante na suscetibilidade à formação de processos erosivos (Galdino *et al.*, 2016).

Contudo, persiste uma lacuna acerca do impacto específico da qualificação dessas pastagens na análise da suscetibilidade à erosão linear.

Nas últimas décadas, a modelagem preditiva de erosão foi substancialmente aprimorada pela adoção de técnicas de aprendizado de máquina. Esses algoritmos permitem analisar a complexa relação entre múltiplos fatores condicionantes, gerando modelos de suscetibilidade com desempenho superior aos métodos tradicionais (Rahmati *et al.*, 2017; Arabameri *et al.*, 2020a). Estudos demonstram que métodos como RF podem mapear áreas de risco com alta eficiência (Mohebzadeh *et al.*, 2022). No entanto, a seleção de variáveis preditoras nesses modelos frequentemente privilegia parâmetros físicos de aquisição imediata, como declividade, negligenciando a influência dinâmica do manejo da terra.

Variáveis relacionadas à história de uso do solo e cobertura da terra, como a idade e o vigor da pastagem, são raramente consideradas, apesar de seu efeito direto na infiltração da água e na cobertura vegetal protetora. Esta omissão pode restringir a eficácia e a capacidade de generalização dos modelos existentes. Para enfrentar esta limitação, o presente estudo propõe a inclusão sistemática dessas variáveis dinâmicas de manejo. O objetivo principal é avaliar se a incorporação da idade da pastagem (tempo em cada área possui cobertura de pasto) e classes de vigor de pastagem melhora o desempenho preditivo de algoritmos de aprendizado de máquina na predição da suscetibilidade à erosão linear.

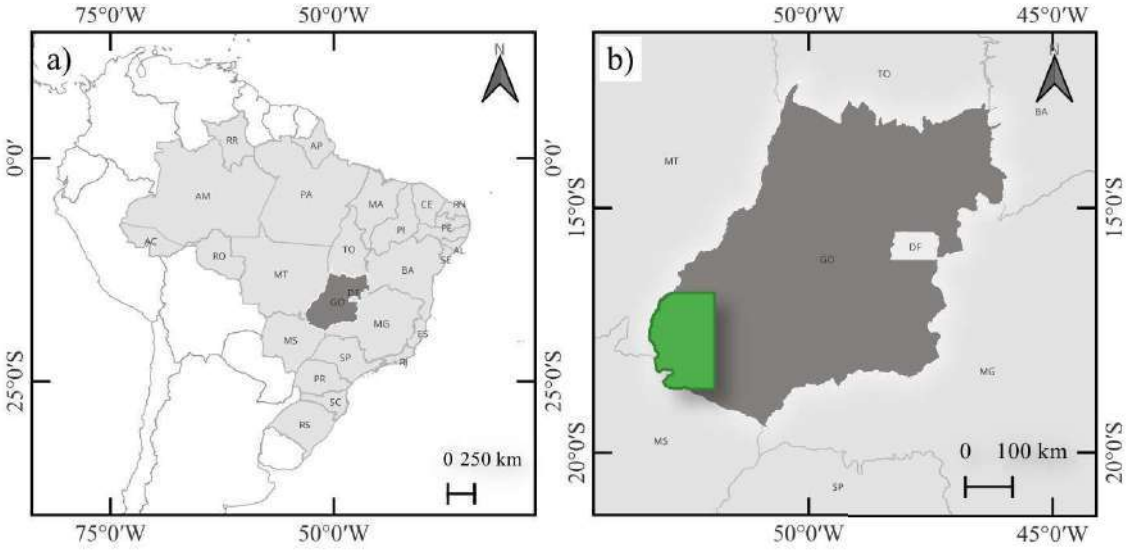
4.2 Material e métodos

A área de estudo compreende parte da porção sudoeste do estado de Goiás, totalizando uma área de 26.552,75 km² (Figura 12). A partir dos dados fornecido por (Carvalho e Castro, 2023), foram selecionadas 5.978 amostras correspondentes à presença de voçorocas e ravinas, complementadas pela mesma quantidade de amostras (5.978) classificadas como ausência de voçorocas e ravinas. Tais amostras de ausência, foram geradas aleatoriamente com distância de 2 km entre si e para garantir a representatividade dos dados de ausência, essa distância mínima foi definida com o objetivo de reduzir a influência de áreas adjacentes, evitando correlações espaciais indesejadas.

No estudo, foram utilizadas 24 variáveis comumente associadas aos fatores desencadeantes de erosão por voçorocas (Mohebzadeh *et al.*, 2022), além de duas variáveis específicas relacionadas à pastagem. Adicionalmente, foram utilizados dados categóricos do módulo de Condição de Vigor da Pastagem - Versão 2, derivados do mapa de pastagem da Coleção 9 do MapBiomas (Parente *et al.*, 2019a; Souza Júnior *et al.*, 2020). Este produto classifica o vigor da vegetação em áreas

de pastagem com base na tendência de vigor vegetativo, dividido em três classes distintas: (a) vigor baixo; (b) vigor médio; e (c) vigor alto. Por fim, foi criado um produto que indica a idade de cada *pixel* da coleção anual de uso do solo e cobertura da terra do MapBiomas, considerando a classe pastagem para o período de 1985 a 2018.

Figura 12 – *Localização da área de estudo: a) Brasil (cinza claro) no contexto da América do Sul; b) Estado de Goiás (cinza escuro) e a área de estudo (verde)*



Fonte: elaborado pela autora (2026).

Assim, foram elaborados dois conjuntos de dados: um com todas as variáveis processadas, denominado *Dataset 1*, e outro sem a inclusão das variáveis de idade e vigor das pastagens, denominado *Dataset 2*. A intenção foi avaliar se a inclusão dessas variáveis sobre as pastagens melhora o desempenho preditivo para produtos de suscetibilidade à erosão linear.

Para o treinamento dos modelos, 70% das amostras (presença e ausência) foram utilizadas, empregando-se validação cruzada do tipo *k-fold* com k igual a 10. Dois algoritmos de aprendizado de máquina baseados em árvores de decisão com técnicas de *ensemble* foram aplicados: o RF e o *Gradient Boosting Machine* (GBM), disponíveis no pacote *caret* do *R* (Kuhn, 2008). Ambos os métodos se destacam por sua capacidade de capturar relações não-lineares e complexas entre os fatores condicionantes, uma característica essencial para representar a multicausalidade inerente à formação de voçorocas (Naceur *et al.*, 2024). Adicionalmente, sua robustez frente a dados com ruído e a capacidade de fornecer estimativas de importância das

variáveis os tornam particularmente adequados para investigar o papel de novos preditores, como os propostos neste estudo.

A validação foi realizada com os 30% das amostras restantes, empregando-se a métrica AUC, permitindo avaliar o desempenho de discriminação do modelo na identificação das áreas suscetíveis à erosão linear. Para avaliar quais variáveis foram mais importantes no mapeamento de áreas suscetíveis à erosão linear, utilizou-se o pacote *caret*, aplicando métricas específicas para cada algoritmo e normalizando os valores entre 0 e 100 (Kuhn, 2008). Na etapa final, para a geração de produtos cartográficos das áreas preditas como suscetíveis à erosão linear, foi empregado o software QGIS. Todos os dados foram processados com resolução espacial de 30 metros e em coordenadas métricas.

4.3 Resultados

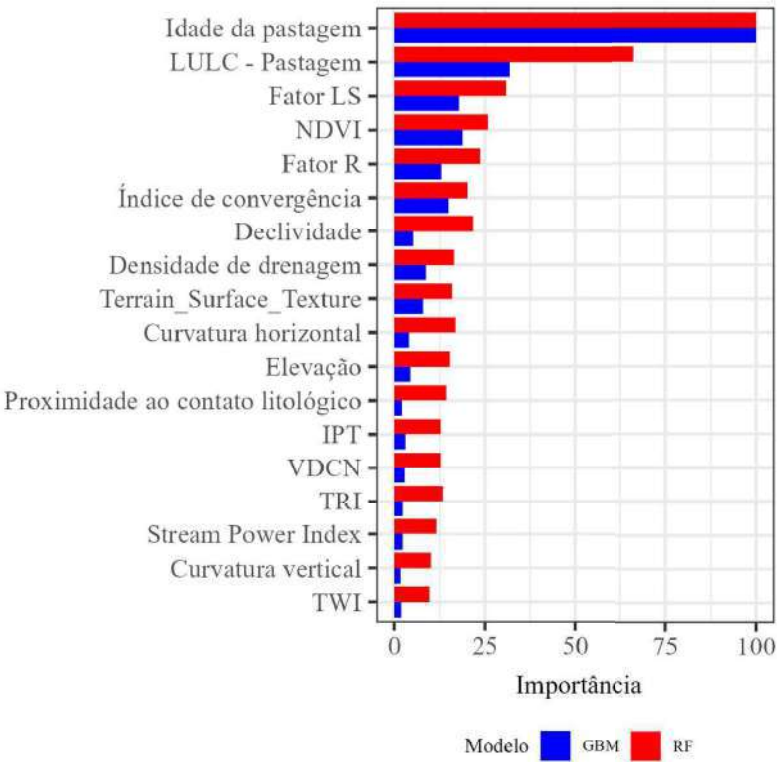
Os resultados da análise preditiva utilizando o algoritmo RF indicaram um desempenho elevado para ambos os conjuntos de dados. No *Dataset 1*, que inclui todas as variáveis processadas, o valor da AUC alcançou 0,916, evidenciando a capacidade de discriminação entre áreas suscetíveis e não suscetíveis à erosão linear. No entanto, ao utilizar o *Dataset 2*, que exclui as variáveis de idade e vigor das pastagens, o AUC foi ligeiramente reduzido para 0,910, indicando que a inclusão dessas variáveis teve um impacto positivo, embora sutil, no desempenho do modelo. Por outro lado, ao aplicar o algoritmo GBM, os resultados mostraram uma performance um pouco melhor. No *Dataset 1*, o AUC atingiu 0,930, refletindo uma discriminação ainda mais acentuada nas predições de suscetibilidade à erosão. Novamente, ao avaliar o *Dataset 2*, o AUC apresentou uma leve diminuição, caindo para 0,926. Esses resultados sugerem que, embora a remoção das variáveis relacionadas à idade e vigor das pastagens tenha resultado em uma leve diminuição no desempenho preditivo, ambos os algoritmos se mantiveram assertivos, destacando a relevância das variáveis incluídas na modelagem.

Na modelagem utilizando os algoritmos RF e GBM, algumas variáveis destacaram-se em relação à sua importância (Figura 13). Considerando a modelagem com o *Dataset 1*, a variável "Idade da pastagem" mostrou-se a mais relevante, sendo o principal fator em ambos os modelos. Isso indica que a idade das pastagens pode influenciar a resposta do sistema modelado, possivelmente refletindo padrões de uso e degradação da área estudada. Outra variável importante foi "LULC - Pastagem", sugerindo que o uso do solo e a cobertura da terra associados às pastagens exercem impacto nos processos modelados. Variáveis relacionadas as condicionantes topográficas, como "Fator LS" e "Declividade", também foram

importantes, apontando a relevância das características físicas do relevo para a compreensão das dinâmicas ambientais envolvidas. Adicionalmente, o NDVI, um índice que reflete a vegetação e sua saúde, obteve alta importância, indicando que a condição da cobertura vegetal é um fator relevante na suscetibilidade à erosão linear.

Outros fatores relacionados ao relevo, como o "Índice de Convergência" e a "Curvatura Horizontal", destacaram-se, sugerindo que a convergência de fluxo hídrico e a configuração da superfície influenciam processos locais. A densidade de drenagem, a textura do terreno e a elevação também figuraram entre as variáveis mais importantes, reforçando que os aspectos topográficos e hidrológicos na suscetibilidade à erosão linear. A importância da "Proximidade ao contato litológico" aponta para uma possível relação entre o tipo de material geológico com a ocorrência das erosões. O dado de vigor das pastagens não apareceu entre as 20 variáveis mais relevantes.

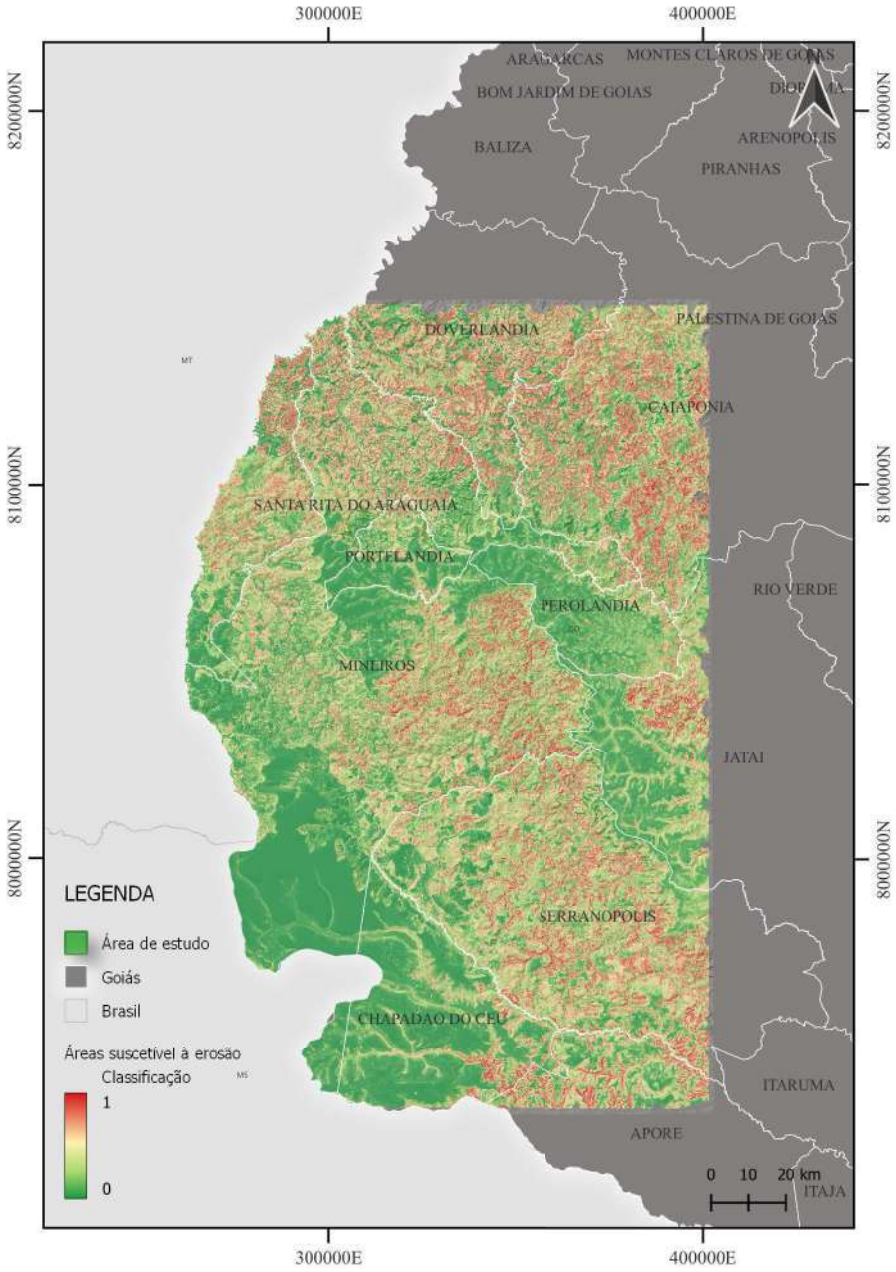
Figura 13 – *Importância das variáveis nos modelos RF e GBM*



Fonte: elaborado pela autora (2026).

O mapa de suscetibilidade gerado indica valores variando de 0 (menor suscetibilidade) a 1 (maior suscetibilidade), de acordo como o GBM que apresentou o melhor desempenho na modelagem (Figura 14).

Figura 14 – *Mapa de suscetibilidade à erosão linear, de acordo com o desempenho do algoritmo GBM*



Fonte: elaborado pela autora (2026).

4.4 Discussão

Embora o melhor desempenho do classificador GBM, baseado em *boosting*, sobre o classificador RF, baseado em *bagging*, seja documentado na literatura para tarefas de regressão (Singhal *et al.*, 2018), isso não representa uma regra absoluta. Em certos estudos, algoritmos baseados em *bagging*, como o RF, demonstram re-

sultados superiores aos métodos de *boosting* (Mosavi *et al.*, 2021). Atualmente, o RF tem se mostrado uma ferramenta preditiva robusta em trabalhos de suscetibilidade à erosão linear, servindo como algoritmo de comparação em relação à outras abordagens (Mohebzadeh *et al.*, 2022).

Os resultados destacam que variáveis associadas ao uso do solo e cobertura da terra se sobressaíram na modelagem de suscetibilidade à erosão linear. A idade da pastagem, em especial, revelou-se uma variável promissora, possivelmente devido ao impacto do manejo e da compactação do solo ao longo do tempo, que pode aumentar sua suscetibilidade à erosão (Galdino *et al.*, 2016).

Do ponto de vista topográfico, declividades elevadas e o fator LS são conhecidos por influenciar a capacidade de transporte de sedimentos e a formação de sulcos (Boehner e Selige, 2006), sobretudo em áreas de pastagem, onde o solo é mais exposto (Galdino *et al.*, 2016), o que ajuda a justificar essas variáveis como especialmente importantes nos modelos preditivos. O padrão de convergência do fluxo hídrico, associado às variáveis de índice de convergência e curvatura horizontal, pode agravar a erosão em áreas suscetíveis (Chaplot, 2013). A presença de variáveis climáticas, como o "Fator R", indica que características climáticas, junto ao uso e ocupação do solo, desempenham um papel relevante na predisposição à erosão linear.

O fato de o vigor da pastagem não ter sido classificado entre as 20 variáveis mais importantes sugere que esta variável não está capturando adequadamente características associadas a processos erosivos ou indica que, embora a cobertura vegetal tenha um papel protetor, outros fatores relacionados à cobertura da terra e à topografia são mais relevantes para a modelagem da suscetibilidade à erosão linear em áreas de pastagem.

4.5 Conclusões

A análise realizada neste estudo demonstrou a eficácia dos algoritmos RF e GBM na predição da suscetibilidade à erosão linear, bem como, evidencia a importância das variáveis de uso do solo e cobertura da terra na modelagem. A idade das pastagens se destacou como uma variável significativa, refletindo como o manejo e a compactação do solo ao longo do tempo podem influenciar a suscetibilidade à erosão. Esta informação pode ser utilizada em investigações futuras para compreender melhor as dinâmicas que afetam a erosão em áreas agrícolas e de pastagem.

CAPÍTULO 5

Artigo 3 - Predição de áreas suscetíveis à erosão linear em Goiás

5.1 Introdução

A erosão do solo é amplamente reconhecida como uma das principais formas de degradação da terra, afetando a produtividade agrícola, a qualidade da água e a provisão de serviços ecossistêmicos (FAO, 2019; Chen *et al.*, 2025). Estudos recentes em ambientes savânicos, como o Cerrado brasileiro, indicam que as taxas de perda de solo podem ser elevadas e tender a se intensificar sob cenários de mudança climática e manejo inadequado, o que reforça a necessidade de compreender e gerir os processos erosivos (Schwamback *et al.*, 2024). Nesse contexto, a erosão linear por ravinas e voçorocas representa um estágio avançado de degradação, associado a cortes profundos no relevo, instabilidade das encostas e danos à infraestrutura rural e urbana, sendo reconhecida como uma das formas mais severas de erosão hídrica em diferentes regiões do mundo (FAO, 2019; Chen *et al.*, 2025).

O Cerrado destaca-se como um dos principais *hotspots* de biodiversidade globais (Damasco *et al.*, 2018), além de constituir uma fronteira agropecuária intensamente transformada, onde a conversão de cobertura nativa em pastagens e agricultura mecanizada tem sido sistematicamente documentada (Souza Júnior *et al.*, 2020). A expansão agropecuária sobre a vegetação nativa, associada a solos naturalmente frágeis em certas regiões, a um relevo favorável e a padrões climáticos com estação chuvosa bem definida, cria um ambiente propenso à intensificação de processos erosivos lineares (Nunes e Castro, 2023).

A ocorrência de erosão linear é um processo complexo, controlado pela interação de múltiplos fatores condicionantes, como topografia, litologia, solos, uso do solo e cobertura da terra e características climáticas (Poesen, 2018). Nos últimos anos, o mapeamento da suscetibilidade à erosão linear tem incorporado técnicas de IA e de aprendizado de máquina, que permitem integrar diversos preditores e capturar relações não lineares entre fatores condicionantes e a ocorrência de ravinas e

voçorocas. Estudos vêm comparando o desempenho de modelos como *Random Forest*, *Support Vector Machines* e redes neurais para a predição da suscetibilidade à erosão linear em diferentes ambientes, reportando elevada capacidade discriminatória e ajuste entre as áreas mapeadas e as ocorrências observadas (Rahmati *et al.*, 2017; Arabameri *et al.*, 2020a; Pal *et al.*, 2020; Mohebzadeh *et al.*, 2022).

Considerando o estudo de Carvalho e Castro (2023), no qual foram mapeados mais de 65 mil pontos de erosão linear em Goiás, o mapeamento da suscetibilidade à erosão linear em escala regional para todo o estado constitui uma oportunidade ímpar de estudo. Apesar dos avanços metodológicos, ainda há uma lacuna na aplicação de modelos preditivos de IA que integrem uma quantidade tão grande de amostras, associadas a variáveis antrópicas, ambientais e topográficas, para explicar a distribuição espacial de ravinas e voçorocas em escala regional. A identificação dos fatores de maior influência nesse contexto permanece pouco explorada, o que limita a eficiência de ações de controle e prevenção.

Diante desse cenário, este trabalho tem como objetivo desenvolver e aplicar um modelo preditivo baseado em técnicas de IA para mapear áreas suscetíveis à erosão linear por ravinas e voçorocas no estado de Goiás. O estudo busca integrar um conjunto abrangente de variáveis preditoras para: (i) identificar os fatores que exercem maior influência na ocorrência dessas feições erosivas; (ii) avaliar a performance do modelo por meio de métricas estatísticas de validação; e (iii) produzir um mapa de suscetibilidade que indique a distribuição espacial das áreas de maior e menor suscetibilidade à erosão linear, servindo como ferramenta para o planejamento ambiental regional.

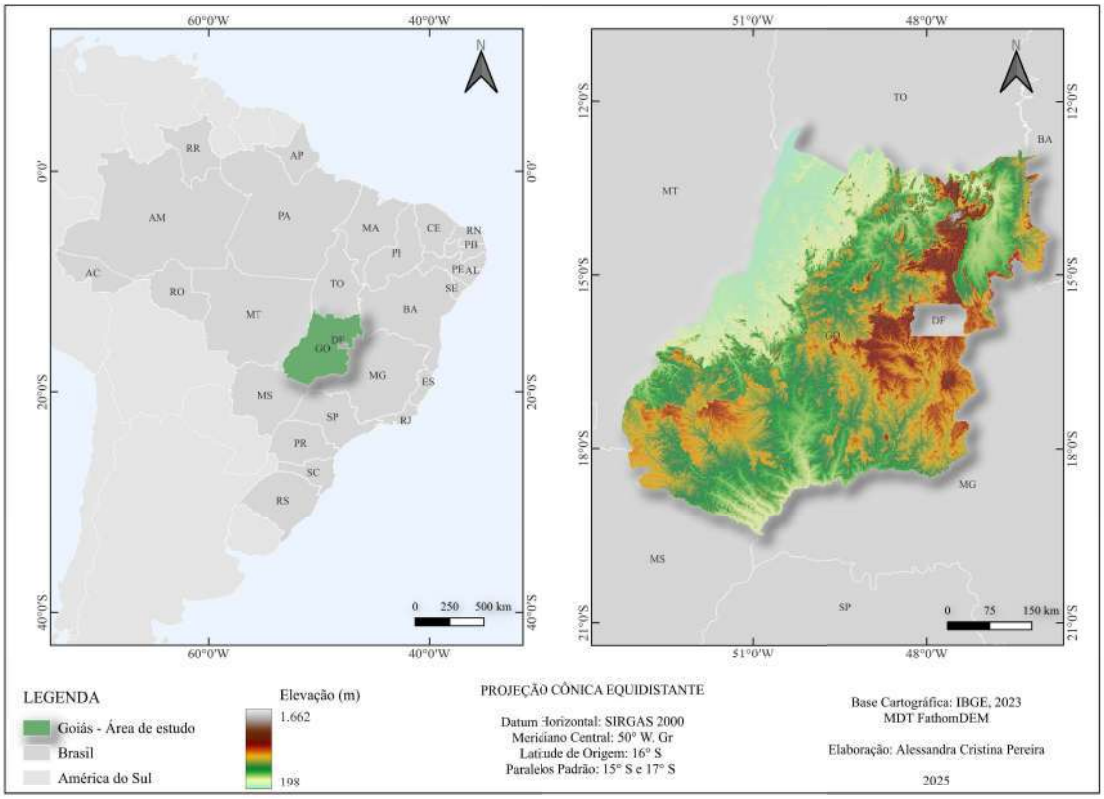
5.2 Caracterização da área de estudo

Goiás, localizado na região Centro-Oeste do Brasil, possui área de 340.242,86 km², sendo o sétimo estado do país em extensão territorial, e 246 municípios (IBGE, 2024) (Figura 15). Quanto à hidrografia, o estado apresenta particularidades, com uma densa rede de drenagem composta por rios de médio e grande porte. Em seu território, nascem drenagens que alimentam três importantes bacias hidrográficas brasileiras: Araguaia–Tocantins, São Francisco e Paraná. Os principais tipos de solo encontrados no estado incluem Argissolo, Cambissolo, Chernossolo, Gleissolo, Latossolo, Neossolo, Nitossolo, Organossolo, Planossolo e Plintossolo, sendo o Latossolo o grupo predominante. A fertilidade natural dos Latossolos varia de baixa a alta, dependendo do relevo e da rocha de origem. No sudoeste de Goiás, destacam-se os Latossolos Vermelhos, que cobrem 42,8% da área total. Embora apresentem fertili-

dade natural baixa, o relevo de baixa declividade e a grande espessura desses solos favorecem a agricultura mecanizada (Santos e Silva, 2025).

Segundo Santos e Silva (2025), o estado apresenta variação altimétrica expressiva, com altitudes entre 182 e 1.676 m. Aproximadamente 92,5% de Goiás possui topografia plana ou levemente ondulada, enquanto apenas 7,5% apresenta relevo mais acidentado. O estudo destaca que predominam ondulações que se suavizam nas margens de grandes rios, como o Araguaia, favorecendo atividades agrícolas e pecuárias e permitindo amplo aproveitamento do solo. À medida que se afasta dos leitos dos rios, as elevações aumentam gradualmente até atingir altitudes mais elevadas, como na Serra do Pouso Alto, ponto mais alto do estado situado na Chapada dos Veadeiros, com cerca de 1.600 m de altitude. Quanto ao clima, predomina o tipo tropical, caracterizado por verões chuvosos e invernos secos (Santos e Silva, 2025).

Figura 15 – *Localização da área de estudo - Goiás, no contexto nacional à esquerda. Mapa hipsométrico de Goiás evidenciando as elevações, à direita*



Fonte: elaborado pela autora (2026).

A maior parte do território goiano, aproximadamente 70%, é caracterizada pelo Cerrado, enquanto apenas uma pequena área apresenta predominância de formações florestais, conhecida como Mato Grosso Goiano. Considerado o segundo

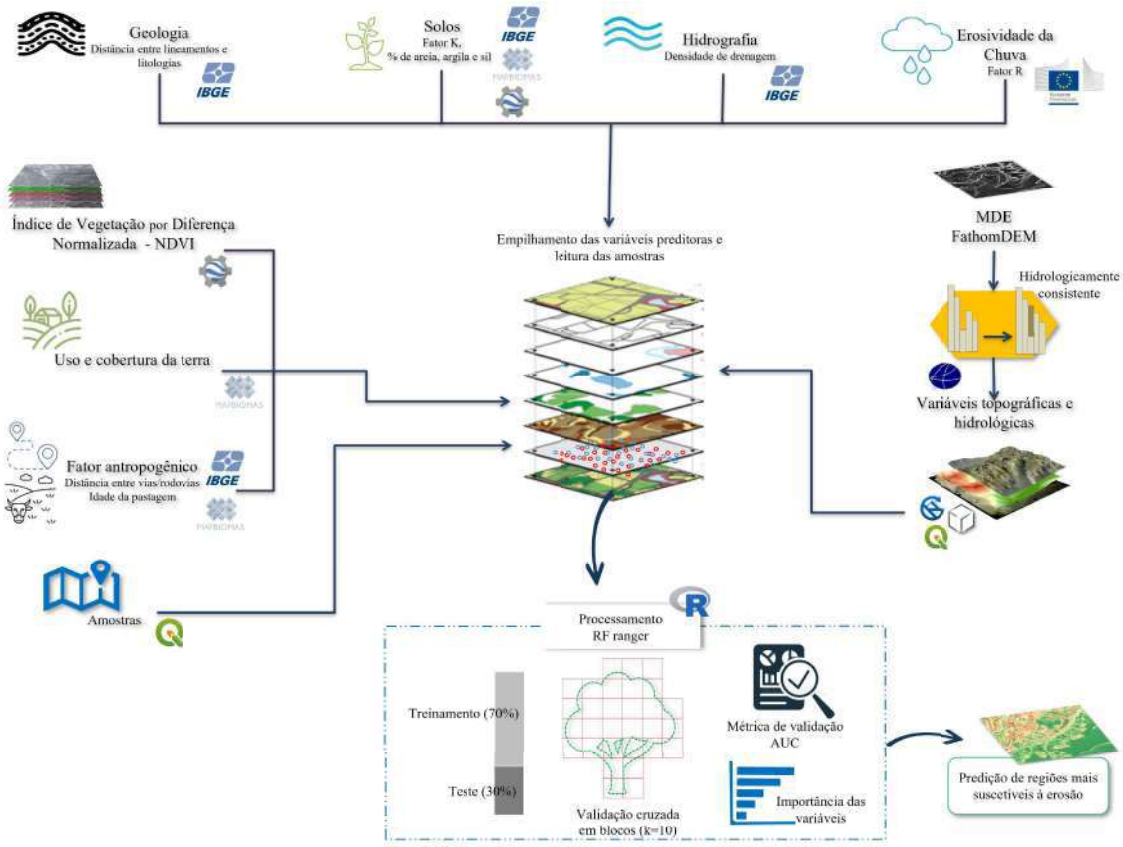
maior bioma do Brasil e da América do Sul, o Cerrado abriga cerca de um terço da biodiversidade nacional e 5% da flora e fauna mundiais (Santos e Silva, 2025).

Ainda de acordo com Santos e Silva (2025), até o final da década de 1960, os solos do Cerrado, sobretudo no Centro-Oeste, eram considerados inadequados para a agricultura devido à baixa fertilidade natural. Nos anos seguintes, em função do avanço tecnológico, das pesquisas científicas e da correção adequada dos solos, o setor agrícola no estado passou por forte expansão, tanto no cultivo de culturas anuais quanto na pecuária. Como resultado, o agronegócio goiano ganhou destaque no cenário nacional e internacional. Segundo dados do 2º trimestre de 2025 (GOIAS, 2025), Goiás consolidou-se como o 2º maior produtor de soja, em toneladas, no Brasil e alcançou a 3ª posição na produção de milho. Na pecuária de corte, o estado ocupa o 3º lugar no *ranking* nacional em participação no abate de bovinos e na exportação de carne bovina, atrás de Mato Grosso e São Paulo. Destaca-se também a pecuária leiteira, na 6ª posição do *ranking* nacional, consolidando Goiás como um dos principais polos agropecuários do país.

5.3 Materiais e métodos

Iniciou-se com a aquisição dos pontos de erosão linear, seguida da obtenção e do processamento dos dados referentes às variáveis antropogênicas, uso do solo e cobertura da terra, geologia, solo, hidrografia, erosividade da chuva e variáveis topográficas e hidrológicas. A predição foi realizada empregando a abordagem de classificação supervisionada, utilizando o algoritmo de aprendizado de máquina *RF Ranger*, com parte amostral para o treinamento e calibração do modelo (validação-cruzada) e parte como amostras independentes para teste, ou seja, não utilizadas no treinamento. Em seguida, o modelo foi submetido às métricas de validação. Por fim, elaborou-se o mapa de suscetibilidade. Na Figura 16 é possível analisar todo o fluxo do estudo e as fontes dos bancos de dados de entrada utilizados para a modelagem.

Figura 16 – *Fluxograma do procedimento metodológico adotados no estudo*



Fonte: elaborado pela autora (2026).

5.3.1 Aquisição dos dados amostrais de erosões lineares

Para a análise da suscetibilidade à ocorrência de erosão linear, foram obtidas do inventário de Carvalho e Castro (2023) 67.078 amostras pontuais que indicam a presença de voçorocas e ravinas mapeadas no ano de 2018. Para assegurar a representatividade dos dados de ausência e reduzir o impacto de regiões próximas, evitando correlações espaciais indesejáveis, foi gerado aleatoriamente o mesmo total de amostras (67.078) a um raio mínimo de 2 km dos pontos de ocorrência de erosões. Tais amostras são denominadas pseudoausências, correspondendo às reais ausências de erosões. Em modelagens de distribuição de espécies na ecologia, é comum a utilização de pontos de pseudoausência quando se conhece a presença espacial de um fenômeno ou alvo a ser predito, mas a ausência é desconhecida (Zurell *et al.*, 2020). As amostras foram classificadas como '1' para presença de erosões e '0' para as pseudoausências.

5.3.2 Aquisição e processamento das variáveis

Foram definidas na modelagem, 23 variáveis relacionadas aos fatores erosivos. A seleção considerou variáveis tradicionais (Mohebzadeh *et al.*, 2022) e variáveis não usuais para o contexto da área de estudo (Abreu *et al.*, 2025). Dentre essas, 10 foram extraídas diretamente do MDT FathomDEM (Uhe *et al.*, 2025), considerado como o melhor MDT global disponível no momento (Guth *et al.*, 2025), associadas à morfologia do terreno, à rugosidade, à posição topográfica relativa e a variáveis hidrológicas (Quadro 3).

Quadro 3 – *Variáveis extraídas diretamente do MDT FathomDEM*

Variáveis	**Relação**
Average Normal Vector Angular Deviation (°)	Rugosidade
Deviation from Mean Elevation (m)	Posição topográfica relativa
Height Above the Nearest Drainage (HAND) (m)	Posição topográfica relativa
Mean Curvature (m^{-1})	Morfologia do terreno
Multiscale Roughness (adimensional)	Rugosidade
Slope (°)	Morfologia do terreno
Terrain Surface Texture (adimensional)	Rugosidade
Topographic Wetness Index (TWI) (adimensional)	Hidrologia
Valley Depth (m)	Posição topográfica relativa
Vertical Distance to Channel Network (VDCN) (m)	Posição topográfica relativa

Fonte: elaborado pela autora (2026).

Os dados categóricos de uso do solo e cobertura da terra (*land use and land cover* - LULC), extraídos do MapBiomas Coleção 10 para o ano de 2018, foram utilizados para extrair as variáveis ambientais e antrópicas (Souza Júnior *et al.*, 2020). Esse ano corresponde ao período em que o mapeamento das feições erosivas foi realizado (Carvalho e Castro, 2023). Como incremento aos dados categóricos, empregou-se o produto de idade da pastagem - Versão 2, proveniente do mapa de pastagem da Coleção 9 do MapBiomas. Esse produto indica a idade de cada *pixel* da coleção anual de uso do solo e cobertura da terra, considerando-se a classe pastagem para o período de 1985 a 2018 (Parente *et al.*, 2019b; Souza Júnior *et al.*, 2020).

O NDVI e o raster de distância euclidiana (mapa de proximidade) da malha viária também foram considerados como variáveis ambientais e antrópicas. O NDVI foi obtido com base em um filtro redutor temporal de mediana aplicado à coleção de imagens do sensor OLI/Landsat-8 do ano de 2018, que corresponde ao ano do inventário das ravinas e voçorocas, e foi processado na plataforma *Google Earth Engine*. Quanto aos dados da malha viária, estes foram compilados a partir da base de arruamentos do Instituto Brasileiro de Geografia e Estatística (IBGE).

A partir do mapa geológico do IBGE, na escala 1:250.000 (IBGE, 2023), geraram-se variáveis numéricas contínuas de proximidade aos contatos geológicos e aos lineamentos. Para o fator de erodibilidade do solo, obteve-se ao mapa de solo na escala 1:250.000, fornecido pelo IBGE (IBGE, 2023), considerando a segunda ordem das classes. Para cada classe, foi atribuído o valor correspondente à erodibilidade do solo equivalente ao fator K, obtido nos estudos de Mannigel *et al.* (2008), Marques *et al.* (2019), Rosa, Cherem e Siame (2023), Nunes e Castro (2023). Ademais, os dados de teor percentual de argila, areia e silte na camada de 0–30 cm do solo foram extraídos do MapBiomas Solos, Coleção 2.1, e processados na plataforma *Google Earth Engine* (Horst *et al.*, 2025).

Quanto às variáveis hidrológicas, foram consideradas a erosividade da chuva (Fator R), extraída da base de dados do *Global Rainfall Erosivity Database* (GloREDa) (Panagos *et al.*, 2017), e a densidade de drenagem obtida a partir da rede hidrográfica do estado de Goiás, fornecida pelo IBGE e refinada para a escala 1:50.000. Para o cálculo da densidade de drenagem, adotou-se o comprimento da rede de drenagem em um raio de 1 km.

Em seguida, realizou-se o processo de correção do MDT FathomDEM para eliminação dos vazios (fossos), tornando-o hidrologicamente consistente, utilizando o *software* TerraHidro. Essa correção é necessária, pois trata problemas em áreas planas ou com depressões, mantendo as feições topográficas e assegurando o fluxo de drenagem contínuo, uma vez que combina o método *flat carving* para as áreas planas com o método *Priority-First Search* (PFS) (Jones, 2002). Por fim, por meio de algoritmos disponíveis nos *softwares SAGA GIS*, *Whitebox* e *QGIS*, extraíram-se as variáveis topográficas e hidrológicas. Neste trabalho, optou-se por adotar o nome das variáveis geomorfométricas em inglês, conforme disponível na maioria dos softwares e na literatura.

De acordo com as recomendações de IBGE (2019), o sistema de referência de coordenadas foi personalizado para o estado de Goiás com a projeção cônica equidistante, utilizando o QGIS (QGIS Development Team, 2024). Trata-se de um sistema cartográfico que minimiza as distorções de área em grandes extensões territoriais, sendo útil quando há necessidade de cálculo de distâncias. Todos

os dados foram compatibilizados para o mesmo tamanho de grade e sistema de referência de coordenadas.

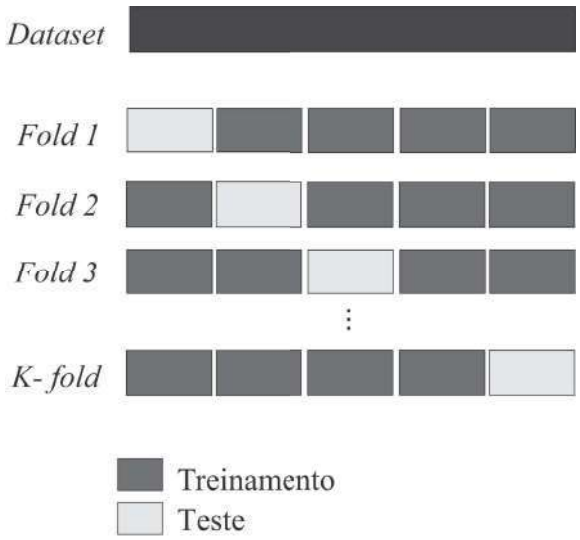
5.3.3 Classificação, predição e validação do modelo

A predição foi realizada no *software* R, por meio da interface do *RStudio*, utilizando o algoritmo de classificação supervisionada *Random Forest* (RF) na variação otimizada *RF Ranger*, uma implementação eficiente para dados extensos e de múltiplas variáveis (Wright, Wager e Probst, 2020). Antes do treinamento, os dados de entrada foram convertidos para objetos pelo pacote *sf*, padronizados quanto aos níveis da variável resposta e submetidos à remoção de registros com valores ausentes. O uso do solo e cobertura da terra (*MapBiomas LULC*) foi tratada como variável categórica (*factor*) para garantir sua correta interpretação pelo algoritmo de aprendizado.

Na calibração do modelo, usualmente 70% das amostras são utilizadas para treino e 30% das amostras para teste. Ainda na parte de treinamento, é possível trabalhar com métricas associadas a validação cruzada (*cross-validation*). Esta é uma abordagem amplamente utilizada para estimar o erro de teste associado ao ajuste de um determinado método de aprendizagem estatística em um conjunto de observações. É útil na calibração e pré-avaliação do modelo e ajuda a garantir que este não esteja superajustado (*overfitting*) (Kuhn, 2008).

Existem diversas estratégias de validação de modelos preditivos, sendo as mais comuns o *Holdout*, o *Leave-One-Out Cross-Validation* (LOOCV) e a validação cruzada *k-fold*. Enquanto o *Holdout* particiona os dados em apenas dois conjuntos (treinamento e validação), podendo gerar resultados instáveis em cenários de escassez de dados, a abordagem *k-fold* mitiga essa variabilidade. O método *k-fold* consiste em subdividir aleatoriamente o conjunto amostral em k partições (*folds*) mutuamente exclusivas; a cada iteração, $k-1$ partes são utilizadas para o ajuste do modelo e a parte remanescente para a validação. Esse processo é repetido k vezes, de modo que cada observação integre o conjunto de validação exatamente uma vez (Maleki *et al.*, 2020). A estimativa final de desempenho é obtida pela média das métricas calculadas em cada ciclo, aumentando a confiabilidade da generalização do classificador.

Figura 17 – *Esquematização do processo de validação cruzada do tipo k-fold*

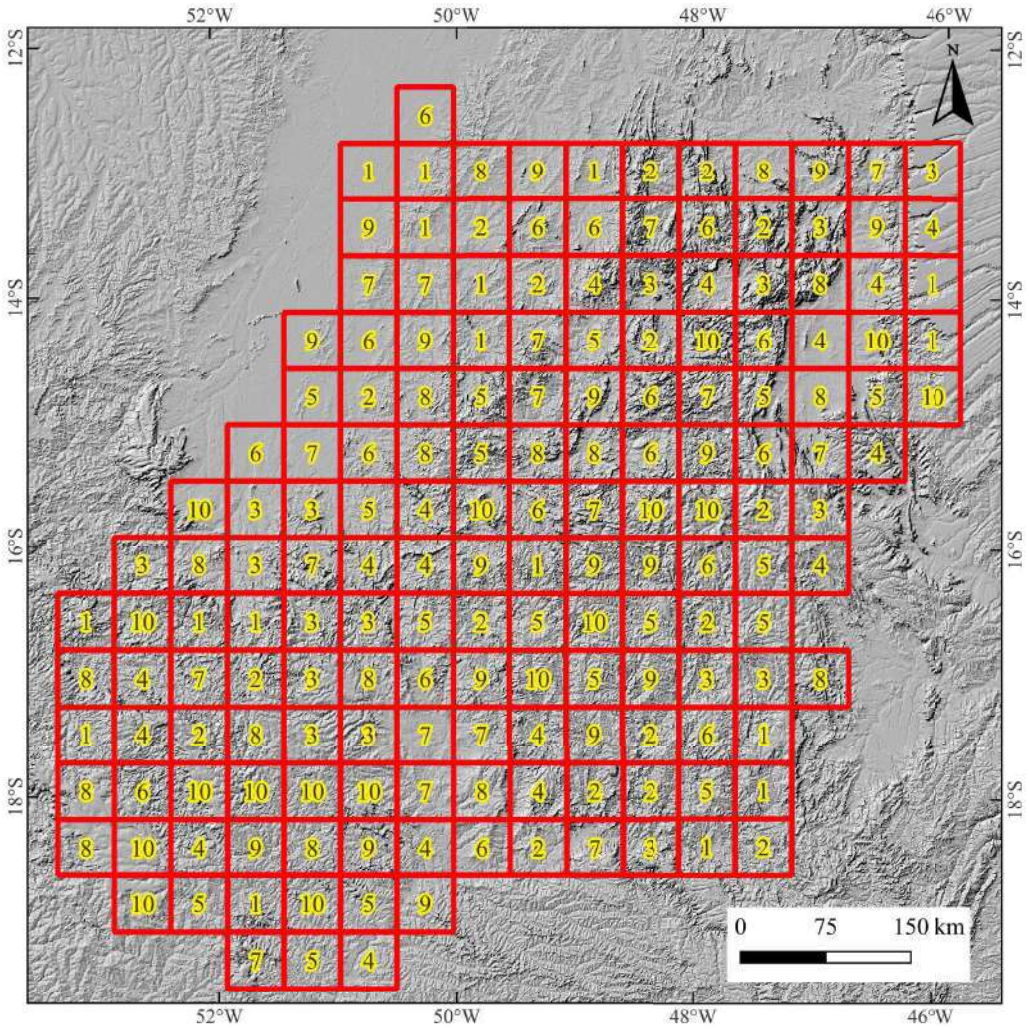


Fonte: elaborado pela autora (2026).

Neste estudo, adotou-se um protocolo de validação cruzada espacial em blocos para mitigar os efeitos da autocorrelação espacial (Valavi *et al.*, 2019). Inicialmente, a área de estudo foi segmentada em blocos espaciais de 50 km × 50 km utilizando o pacote *blockCV* (Figura 18). O conjunto total de blocos foi dividido em uma proporção de 70% para o desenvolvimento do modelo (treinamento e validação interna) e 30% para o teste independente final.

Para a etapa de desenvolvimento, aplicou-se a validação cruzada espacial com $k = 7$ sobre os blocos selecionados (7 blocos). Através da função *cv_spatial*, as amostras foram alocadas em 7 conjuntos espaciais independentes, garantindo que o modelo fosse avaliado sob diferentes configurações geográficas. Após o ajuste e a validação interna, a capacidade preditiva final do classificador foi mensurada utilizando-se os 30% dos blocos restantes (3 blocos), os quais foram mantidos isolados durante todo o processo de treinamento. O desempenho foi quantificado pela métrica AUC, aplicada sobre esse conjunto de teste independente.

Figura 18 – *Área de estudo com relevo sombreado ao fundo e delimitação dos blocos espaciais de 50 km × 50 km. Os números de 1 a 10 indicam a atribuição dos blocos aos folds espaciais: os grupos 1 a 7 foram destinados ao treinamento e validação cruzada (k-fold, $k = 7$), enquanto os grupos 8 a 10 constituíram o conjunto de teste independente para avaliação final do modelo. Foram gerados, ao todo, 170 blocos para a cobertura integral da área de estudo*



Fonte: elaborado pela autora (2026).

Adicionalmente, para avaliar a importância das variáveis preditivas, o algoritmo RF emprega o critério de impureza de Gini para quantificar a redução de impurezas em cada nó da árvore de decisão. A função *importance* do algoritmo estabelece um ranqueamento da relevância das variáveis preditoras (Breiman, 2001b). Para viabilizar a comparação relativa entre as variáveis, os valores foram normalizados no intervalo de 0 a 100. Gráficos de dependência parcial ou *Partial Dependence Plot* (PDP), foram utilizados para examinar como as variáveis mais relevantes influ-

enciam a resposta predita. Por fim, a predição das áreas com maior suscetibilidade à erosão linear resultou na elaboração de um produto cartográfico compatível com a escala 1:50.000, desenvolvido no software QGIS (QGIS Development Team, 2024).

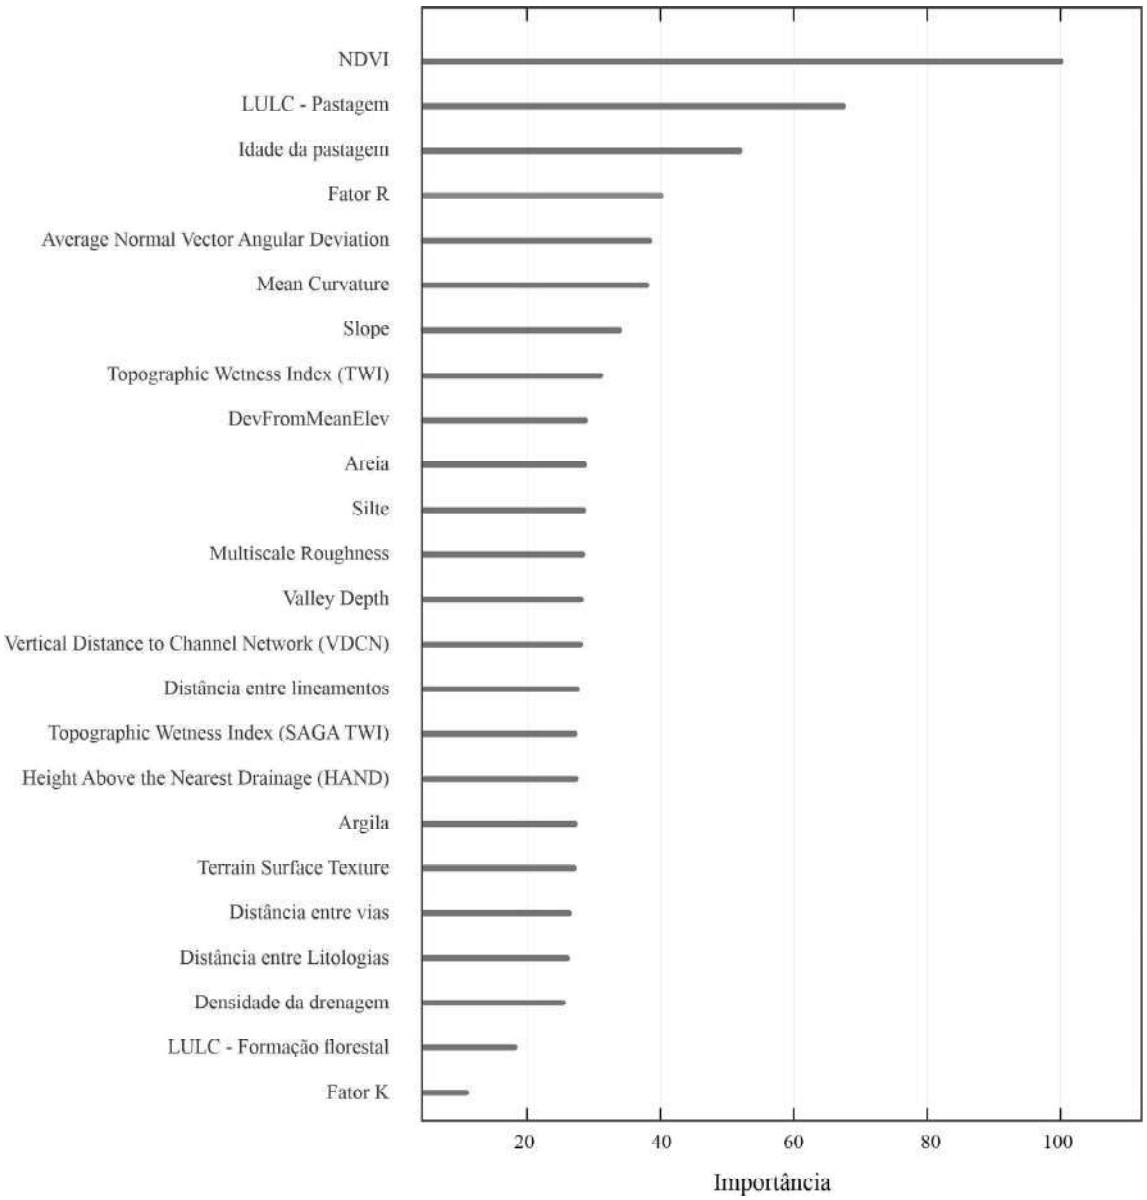
Posteriormente, realizou-se uma análise das áreas dos municípios goianos com maior percentual de território suscetível à erosão linear. Para esse procedimento, consideraram-se as áreas com valores superiores a 80% de suscetibilidade, conforme predição do modelo RF, em relação à área total de cada município. A partir da avaliação dessa proporção no âmbito municipal, foi possível identificar os territórios que apresentam maior ou menor suscetibilidade aos processos erosivos.

5.4 Resultados

O modelo *RF Ranger* apresentou desempenho consistente na métrica de validação sobre o conjunto de teste, com valor de AUC igual a 0,8657. O ranqueamento das variáveis mais relevantes para a ocorrência de erosões lineares, destaca-se o 'NDVI' no topo da lista, com importância de 100%. Em seguida aparecem 'LULC - Pastagem' e 'Idade da pastagem', indicando que a cobertura da terra e o estado da vegetação influenciam diretamente a suscetibilidade à erosão linear. O 'Fator R', índice que representa o potencial da precipitação em causar erosão no solo, ocupa a quarta posição, demonstrando relação com as variáveis mencionadas.

As demais variáveis, relacionadas à rugosidade, morfologia, posição topográfica relativa, além de índices hidrológicos e atributos do solo, mantiveram-se em níveis semelhantes no ranqueamento, variando entre 30 e 40%. As variáveis 'LULC - Formação florestal' e erodibilidade do solo ('Fator K') apresentaram menor potencial de impacto relacionados aos processos erosivos.

Figura 19 – *Importância das variáveis para a aptidão a erosões conforme o modelo RF Ranger utilizando a métrica de impureza de Gini*

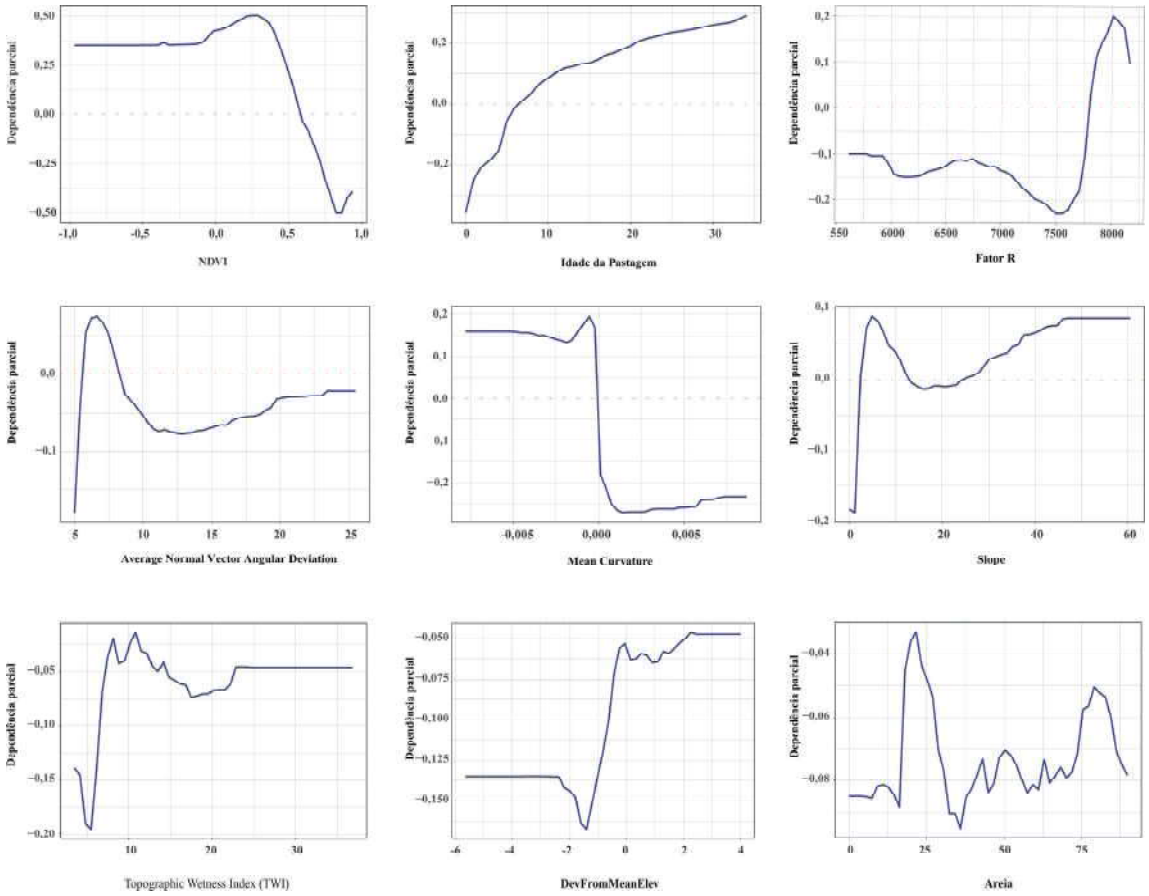


Fonte: elaborado pela autora (2026).

Segundo Greenwell (2017), identificado um subconjunto de características importantes, é necessário avaliar a relação entre essas variáveis e a variável resposta. Para esse fim, os gráficos de PDP ilustram o efeito entre a resposta esperada e um conjunto específico de características de entrada. O eixo X representa os valores da variável analisada, enquanto o eixo Y indica o valor estimado da função de dependência parcial. Valores mais altos no eixo Y indica efeito mais favorável e valores mais baixos indica efeito menos favorável à variável resposta. A linha interna na área do gráfico expressa a relação entre a variável resposta e a variável em

avaliação (Figura 20).

Figura 20 – *Gráficos PDP das nove variáveis preditoras em ordem de importância*



Fonte: elaborado pela autora (2026).

Considerando as primeiras variáveis mais relevantes, a variável LULC - Pastagem, classifica o tipo de superfície associado ao uso do solo e cobertura da terra, portanto, é uma variável categórica. As demais são numéricas e cada uma apresenta um gráfico PDP distinto em relação à predição de áreas suscetíveis à erosão linear. Para valores baixos de NDVI (-1 a 0), observa-se que a função associada à predição de erosões exibe um comportamento positivo e linear com leve ascensão em torno de 0,25 (eixo X). Em contrapartida, para valores altos de NDVI (0,25 a 0,80), a função decresce significamente, para valores negativos (até -0,50). Isso indica que áreas com pouca ou nenhuma cobertura vegetal são mais propensas à formação de erosões. De modo semelhante, o gráfico PDP da idade da pastagem indica comportamento crescente e positivo em relação à função de predição de ocorrência de erosão, com tendência quase linear à medida que a idade da pastagem (em anos) aumenta. Para o Fator R, a função de dependência apresenta valores negativos até aproximadamente 7500 MJ mm ha^{-1} h^{-1} com crescimento acentuado com valores positivos na faixa

entre 7750 e 8000 MJ mm ha^{-1} h^{-1}, o que permite inferir que valores mais elevados sugerem maior potencial erosivo.

A análise morfométrica do relevo contribui para a compreensão das paisagens. A variável *Average Normal Vector Angular Deviation* indica a distribuição espacial do desvio angular médio do vetor normal, expresso em graus. A DPD apresenta um comportamento negativo em direção ao positivo, indicando que valores muito baixos dessa variável são menos favoráveis para áreas propensas à erosão. A curva passa de um efeito extremamente negativo para positivo atingindo um valor máximo de cerca de 7,5°. Em seguida, houve um declínio contínuo, seguido de um leve aumento em torno de 20°, mas o efeito permaneceu negativo, estabilizando-se após aproximadamente 22°. Em outras palavras, a topografia local tende a ser mais irregular conforme o desvio é positivo e mais plana ou uniforme quando negativo.

Quanto a variável *Mean Curvature*, medida em unidades de m^{-1}, exibe valores negativos que normalmente sinalizam regiões côncavas, como vales ou depressões. Nesses casos, o gráfico PDP (-0,0075 a 0,000) pode indicar uma tendência de crescimento à erosão. Em seguida, há uma queda abrupta negativa com valores próximos a zero, o que sugere terrenos planos. Por outro lado, valores positivos (a partir de 0,005) indicam áreas convexas, como cumes ou encostas arredondadas, que nesses casos, o gráfico PDP pode indicar uma tendência de redução na variável de interesse, como uma umidade do solo mais baixa ou um risco de acúmulo de material menor. A variável *Slope* representa a inclinação, e o gráfico DPD mostra no geral uma tendência crescente, indicando que à medida que a inclinação aumenta, a probabilidade ou severidade do fenômeno da erosão também se intensifica, pois a água tende a fluir mais rapidamente em terrenos inclinados (Florinsky, 2016).

A variável *Topographic Wetness Index* (TWI) mede a variação da umidade do solo em relação ao relevo, sendo sua unidade adimensional. A resposta da DPD é totalmente negativo com três padrões claros: até aproximadamente 7, tem o efeito menos favorável à variável resposta, o que indica área com solo com pouca umidade, mais drenados. Em seguida, entre 8 e 13 a curva sobe rapidamente, passando de -0,20 para valores próximos de –0,05, tornando a condição mais favorável a erosões, com um leve declínio posteriormente e a partir de 20 mantêm em estabilidade. Sobre a função de predição de erosão sugere que, à medida que o índice aumenta, também cresce a probabilidade de saturação hídrica no local, ou seja, vales ou ambientes hidromórficos. A DPD da variável *DevFromMeanElev* refere-se ao desvio em relação à elevação média. O valor negativo (-6 a -2) sugere que o ponto está abaixo da média, como em vales ou depressões, porém estável, e com queda em seguida, indicando regiões menos favoráveis a erosão. Entre –1,5 e 0 ocorre a maior mudança de toda a curva, apresentando uma transição do vale, sugerindo uma meia encosta. Em

seguida, os valores positivos e crescente indicam que o ponto está acima da média (cristas, superfícies altas), o que significa que há uma maior tendência à erosão nessas áreas no gráfico.

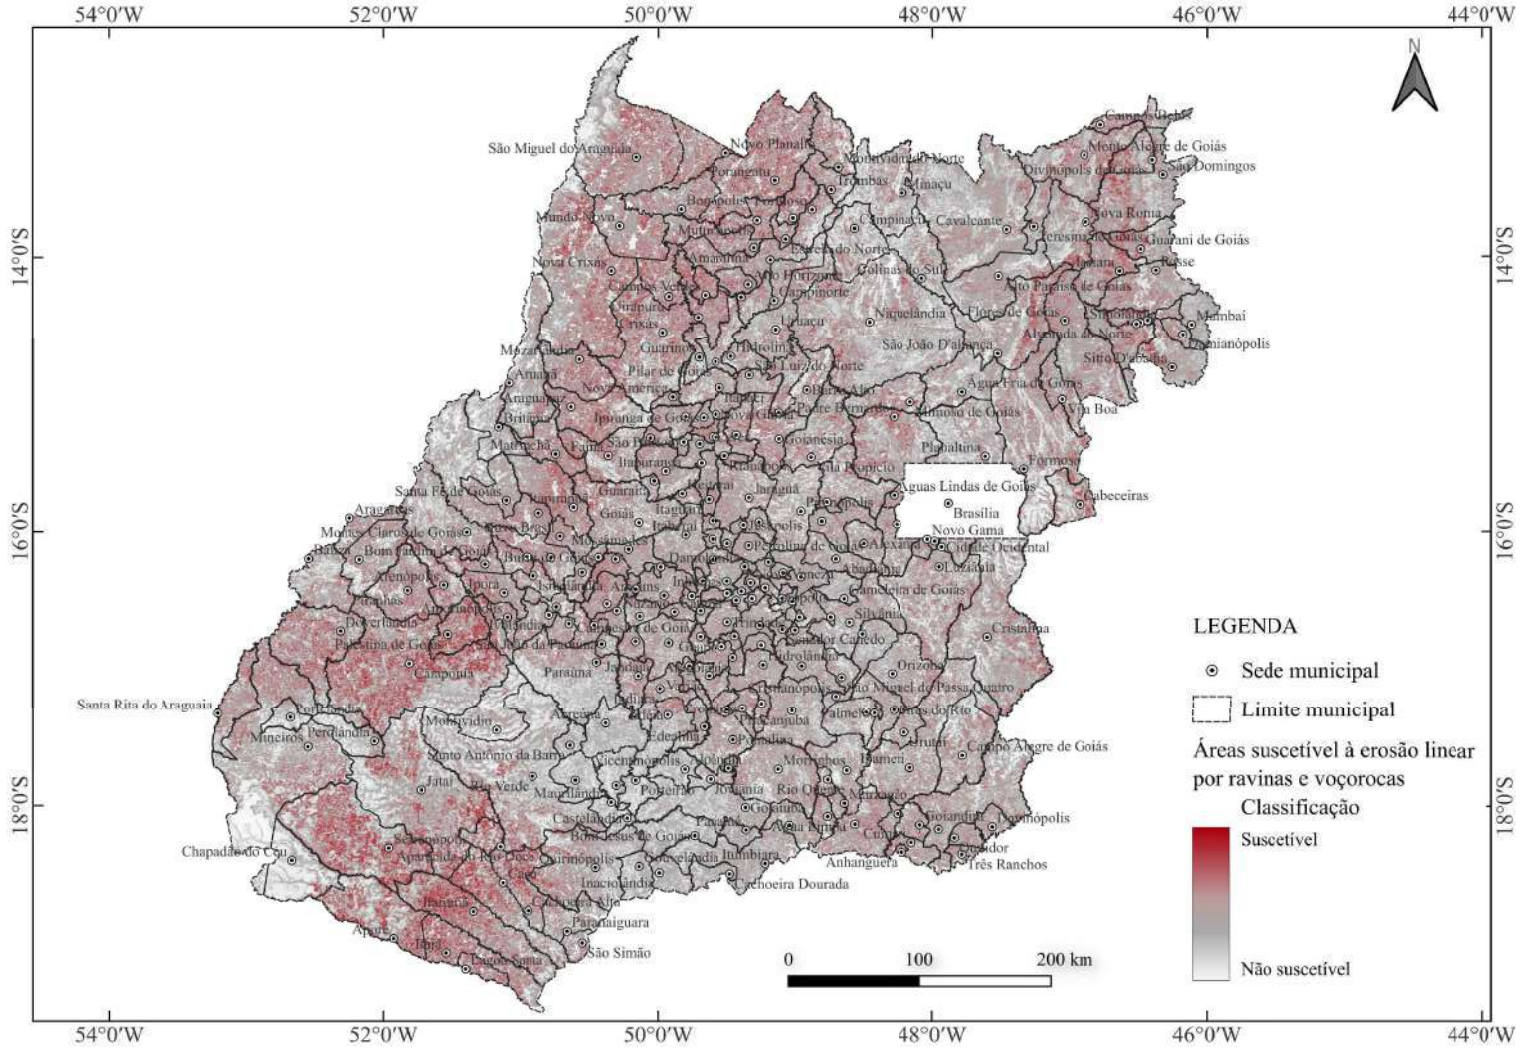
O efeito da DPD da areia é totalmente negativo, mas apresenta variações importantes ao longo do gradiente granulométrico. Até 20%, o efeito é negativo moderado e estável, indicando baixo percentual de areia. Há um pico pronunciado entre 20 e 30% o que indica grande aumento da dependência parcial, apesar de ainda negativo, este é o ponto de maior favorabilidade à erosão. Em seguida há uma queda abrupta e em seguida em recuperação leve ascendente após 50%, que sugere um comportamento moderado e texturas intermediárias de areia.

A Figura 21 apresenta o mapa de suscetibilidade à erosão linear para o estado de Goiás. O dado raster gerado indica valores variando de 0 (menor suscetibilidade) a 1 (maior suscetibilidade). A análise visual evidencia elevada heterogeneidade espacial, com a porção sudoeste concentrando manchas de alta suscetibilidade, abrangendo municípios como Lagoa Santa, Serranópolis, Itarumã, Caiapônia e Palestina de Goiás.

A região noroeste, correspondente ao Vale do Araguaia, apresenta áreas com alta suscetibilidade à erosão linear que contrastam com o relevo predominantemente plano da bacia no médio curso do rio Araguaia, a exemplo dos municípios de Santa Terezinha de Goiás e Nova Crixás. Essa configuração espacial indica que a declividade não atua como condicionante isolado. Observam-se ainda zonas de elevada suscetibilidade nas bordas de planaltos do nordeste e no sul do estado. No sul goiano e nas imediações do Distrito Federal, a suscetibilidade manifesta-se em padrões lineares e dendríticos, acompanhando a rede de drenagem e as bordas escarpadas dos planaltos. Em contraste, as regiões norte e os topos planos das chapadas apresentam baixa probabilidade de ocorrência dos processos erosivos, como observado nos municípios de Minaçu, Niquelândia e Cavalcante.

Considerando áreas com probabilidade superior a 80% de ocorrência de processos erosivos, verificou-se que, dos 246 municípios goianos, 17 apresentam mais de 10% de sua área territorial classificada como suscetível à erosão linear (Tabela 1). O estudo indica que Palestina de Goiás, localizada na região sudoeste do estado, apresenta o maior percentual de área suscetível, com 22,60% do território municipal enquadrado nessa classe. A Figura 22 espacializa os municípios de Goiás em função do percentual de área suscetível à erosão linear.

Figura 21 – *Regiões suscetíveis à erosão linear, conforme a performance do algoritmo RF Ranger*



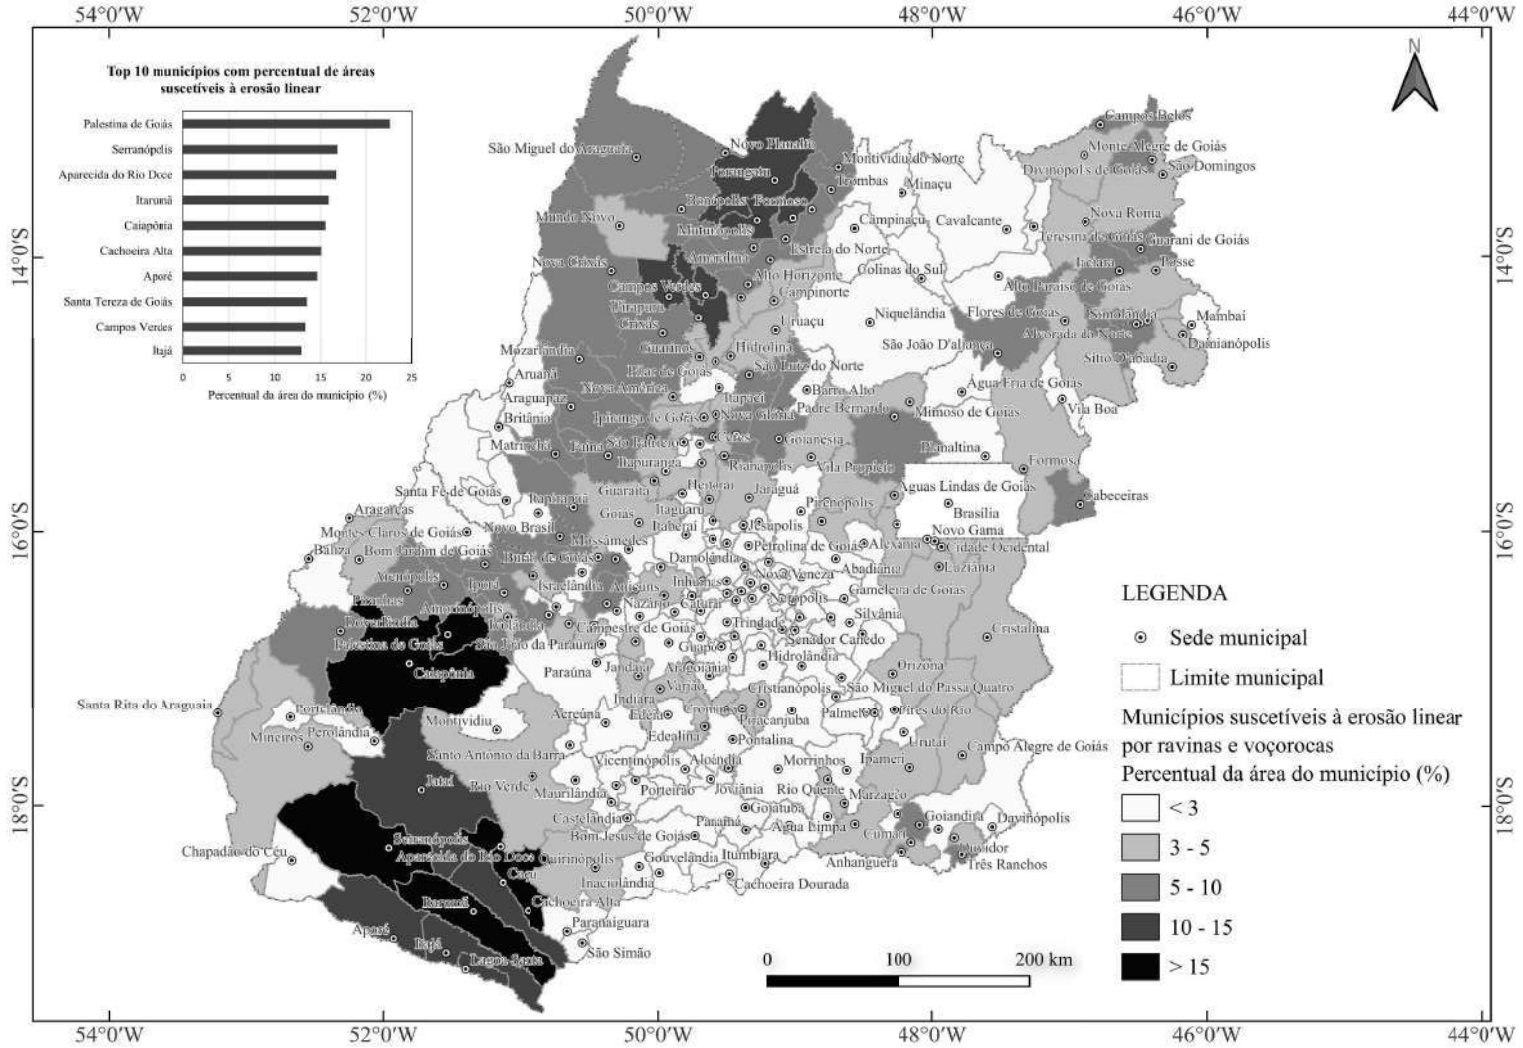
Fonte: elaborado pela autora (2026).

Tabela 1 – *Área percentual dos municípios com maior susceptibilidade para processos erosivos lineares em Goiás, classificadas por meio do algoritmo RF*

MUNICÍPIOS	ÁREAS MUNICÍPIOS (ha)	ÁREAS CLASSIFICAÇÃO (ha)	ÁREA CLASSIFICADA POR MUNICÍPIO (%)
PALESTINA DE GOIAS	131804,68	29789,94	22,60
SERRANOPOLIS	552177,35	92866,57	16,82
APARECIDA DO RIO DOCE	60325,41	10061,61	16,68
ITARUMA	343736,56	54522,01	15,86
CAIAPONIA	862796,10	133934,32	15,52
CACHOEIRA ALTA	165722,44	25012,96	15,09
APORE	289921,70	42364,24	14,61
SANTA TEREZA DE GOIAS	78954,36	10634,22	13,47
CAMPOS VERDES	44312,48	5914,39	13,35
ITAJA	208275,50	26878,17	12,91
CACU	225431,75	28785,60	12,77
MUTUNOPOLIS	95507,74	11840,81	12,40
PORANGATU	482528,32	56683,78	11,75
UIRAPURU	115427,24	13234,48	11,47
LAGOA SANTA	46328,84	4814,09	10,39
JATAI	717881,50	72620,21	10,12
SANTA TEREZINHA DE GOIAS	120659,22	12197,07	10,11

Fonte: elaborado pela autora (2026).

Figura 22 – *Municípios suscetíveis à erosão linear, segundo o percentual da área municipal (%)*



Fonte: elaborado pela autora (2026).

5.5 Discussões

5.5.1 Desempenho do modelo

O algoritmo *RF Ranger* utiliza o método de *bagging* (agregação), no qual várias árvores de decisão são geradas de forma independente a partir de diferentes amostras do conjunto de dados, e suas predições são combinadas para formar o resultado final. A AUC de 0,8657 (sendo 1 o valor ideal) demonstra a capacidade preditiva do modelo na identificação de áreas suscetíveis à erosão linear.

A literatura indica que o RF tem sido empregado de forma consistente em estudos de suscetibilidade à erosão linear, servindo como parâmetro de comparação para outras abordagens (Mohebzadeh *et al.*, 2022; Naceur *et al.*, 2024). Esses resultados reforçam que técnicas de *bagging* apresentam desempenho robusto, adequado a distintos contextos e conjuntos de dados. Além disso, valores de AUC semelhantes têm sido reportados em aplicações internacionais, frequentemente variando entre 0,85 e 0,90 em estudos conduzidos em bacias de menor extensão (Naceur *et al.*, 2024).

Em trabalhos comparativos, modelos RF alcançaram desempenhos próximos ou superiores a algoritmos de *boosting*, dependendo da complexidade ambiental e da qualidade do inventário de erosão (Arabameri, Pradhan e Rezaei, 2019; Rahmati *et al.*, 2017). Assim, o desempenho observado neste estudo é compatível com o estado da arte e destaca a aderência do RF à modelagem regional de suscetibilidade em áreas ambientalmente heterogêneas, como o território goiano.

Contudo, a interpretação desse desempenho deve considerar a escala geográfica da análise. Enquanto estudos conduzidos em microbacias ou áreas locais frequentemente reportam valores de AUC superiores a 0,90 ou até 0,95, favorecidos pela homogeneidade ambiental restrita (Arabameri, Pradhan e Rezaei, 2019; Ghorbanzadeh *et al.*, 2020; El Bouzekraoui *et al.*, 2024), modelagens em escala regional ou estadual enfrentam uma heterogeneidade geomorfológica significativamente maior. Nesse contexto, métricas de validação entre 0,85 e 0,90, como a obtida neste estudo, observado em pesquisas em áreas extensas internacionalmente (Olivier, Wiel e Clercq, 2023).

Adicionalmente, a robustez do modelo é substanciada pela magnitude do inventário de pontos (Carvalho e Castro, 2023). A vasta maioria dos trabalhos indexados na literatura baseia-se em conjuntos de dados amostrais variando de algumas centenas a poucos milhares de pontos (i.e., $N < 2000$). A aplicação do RF *ranger* sobre um volume massivo de dados (*Big Data*) confere uma estabilidade estatística superior ao mapeamento, indicando que a AUC de 0,8657 reflete a captura efetiva de padrões regionais complexos do bioma Cerrado, mitigando os riscos de

sobreajuste (*overfitting*) comuns em amostras reduzidas.

A aplicação do modelo em todo o estado de Goiás representa uma inovação metodológica, uma vez que a maioria dos estudos de suscetibilidade à erosão linear concentra-se em áreas restritas, como bacias hidrográficas ou municípios específicos (Mohebzadeh *et al.*, 2022; Naceur *et al.*, 2024). Trabalhos em larga escala são raros, sobretudo em regiões tropicais, onde a heterogeneidade ambiental e a complexidade dos fatores condicionantes tornam o mapeamento mais desafiador (Lana, Castro e Lana, 2022).

5.5.2 Fatores condicionantes

A ocorrência de erosão linear, conforme descrito por Ionita *et al.* (2015), Poesen (2018), Goudie (2020), Loureiro *et al.* (2022), envolve múltiplos fatores inter-relacionados. A avaliação combinada, sobretudo das três variáveis de maior importância, indica que áreas com cobertura contínua de pastagens ao longo dos anos e com NDVI associado a menor vigor vegetativo tendem a apresentar maior suscetibilidade à erosão.

O fator R é um indicador que expressa a capacidade da precipitação em promover erosão no solo. Trata-se de um componente da Equação Universal de Perda de Solo, calculado com base em séries históricas de precipitação, considerando a intensidade máxima e a energia cinética das chuvas. A exposição da superfície terrestre a esse fator exerce influência direta sobre a erosão hídrica (Panagos *et al.*, 2017).

O *Average Normal Vector Angular Deviation* (desvio angular médio do vetor normal), *Multiscale Roughness* (rugosidade multiescala) e *Terrain Surface Texture* (textura da superfície do terreno) reforçam o papel dos aspectos de rugosidade topográfica na suscetibilidade à erosão linear. Terrenos mais rugosos mantêm maior capacidade de retenção e de infiltração superficial de água quando comparados a terrenos com menor rugosidade (Lindsay e Newman, 2018).

A *Mean Curvature* (curvatura média) sugere que a convergência de fluxo hídrico e a configuração da superfície exercem influência sobre os processos erosivos (Chaplot, 2013). As características do relevo que orientam o escoamento superficial favorecem o aumento da ocorrência de erosão, como observado no sudoeste goiano por Nunes e Castro (2023).

A declividade (*Slope*) favorece a formação de erosão linear ao aumentar a energia do escoamento superficial, intensificando a remoção de solo e a concentração do fluxo nos canais, o que leva ao início e ao aprofundamento de ravinas e voçorocas (Ciccolini *et al.*, 2024). Declives acentuados promovem fluxo de água mais rápido, gerando maior tensão de cisalhamento na superfície, desprendendo partículas e

transportando-as encosta abaixo, contribuindo para o avanço da erosão linear (Ghosh *et al.*, 2022).

O índice de umidade topográfica é uma métrica geomorfométrica que expressa a tendência de acumulação de água no terreno, combinando a área de contribuição e a declividade local. Ele indica o potencial de umidade do solo associado à forma do relevo e não a quantidade de água presente em um dado momento. Essa métrica é útil para identificar áreas com maior potencial de umidade e compreender a dinâmica hídrica na paisagem, como no TWI e SAGA TWI - variação extraída no *software System for Automated Geoscientific Analyses* (SAGA), utilizado para evidenciar planície (Wilson e Gallant, 2000; Kopecký, Macek e Wild, 2021).

Fatores relacionados à posição topográfica relativa, como *DevFromMeanElev* (desvio da elevação média, ou Índice de Posição Topográfica – TPI), HAND (altura acima da drenagem mais próxima), *Valley Depth* (profundidade do vale) e VDCN (distância vertical à rede de canais), refletem a localização de um ponto em relação ao relevo circundante e à rede de drenagem, influenciando diretamente a acumulação de água, nível freático e a concentração do escoamento superficial, condições que controlam os processos erosivos lineares.

Especificamente, valores de *DevFromMeanElev* (TPI) próximos de zero ou ligeiramente positivos (Figura 20) tendem a ocorrer em encostas indicativas de locais onde a água pluvial pode convergir, o que favorece o início e o desenvolvimento de ravinas e voçorocas. Por sua vez, valores baixos de HAND ou VDCN (isto é, pontos situados próximos aos canais de drenagem) implicam maior convergência de fluxos, proximidade com o lençol freático e maior umidade do solo nas encostas, elevando o potencial de incisão de sulcos e voçorocas. Em áreas onde o lençol freático está próximo à superfície, a exfiltração intensifica a erosão, promovendo o desenvolvimento de erosões lineares (Marinho, Castro e Campos, 2006). Por fim, vales profundamente entalhados (ou seja, com maior profundidade de vale) concentram os fluxos hídricos e aumentam a energia erosiva, acelerando os processos de erosão linear (Arabameri *et al.*, 2020b). Outros estudos corroboram a importância dessas métricas topográficas como condicionantes da suscetibilidade a ravinas e voçorocas, o que justifica sua inclusão como preditores (Arabameri *et al.*, 2020b; Bernini *et al.*, 2021).

A densidade de drenagem destaca a influência da rede hidrográfica na organização do fluxo hídrico, em que áreas com maior densidade de canais podem concentrar o escoamento, aumentando a erosão localizada. Trata-se de um parâmetro clássico utilizado na geomorfologia, calculado pela relação entre o comprimento total dos rios e a área da bacia hidrográfica, refletindo o equilíbrio entre processos

erosivos e a resistência dos materiais superficiais. Esse indicador é influenciado por fatores como clima, cobertura vegetal, litologia e características do solo (Huggett e Shuttleworth, 2022). Além disso, a densidade de drenagem está diretamente associada à eficiência do escoamento superficial, o que impacta a suscetibilidade das rochas à erosão (Gournellos, Evelpidou e Vassilopoulos, 2004).

A textura do solo influencia diretamente a suscetibilidade ao ravinamento, sobretudo pelas frações areia e silte, que reduzem a coesão e facilitam o destacamento das partículas pelo escoamento concentrado. Estudos indicam que teores elevados de silte aumentam a erodibilidade e estão associados a maiores taxas de recuo de cabeceiras (Zijl, Ellis e Rozanov, 2014; Zhang *et al.*, 2022). A fração areia exerce papel duplo no contexto erosivo: areias finas pouco coesas tendem a favorecer o aprofundamento de sulcos e a expansão de ravinas e voçorocas, enquanto areias mais grossas e bem drenadas podem reduzir o escoamento superficial e, em alguns contextos, limitar o início da erosão linear (Liu *et al.*, 2025). Perfis arenosos finos, especialmente quando sobrepostos a horizontes menos permeáveis, apresentam altas taxas de erosão (Nzereogu *et al.*, 2023), como ocorre em solos com horizonte textural (Bt), a exemplo dos Argissolos no contexto brasileiro.

A proximidade ao contato litológico indica influências geológicas e estruturais que favorecem o fluxo de água e processos como o *piping*, o que pode levar ao colapso do solo. Esses contatos criam descontinuidades que favorecem o encharcamento, contribuindo para a formação de voçorocas em áreas suscetíveis (Marinho, Castro e Campos, 2006). A proximidade de vias de acesso apresenta efeito moderado na suscetibilidade à formação de voçorocas, pois a alteração da dinâmica do escoamento superficial e a fragmentação da paisagem nas imediações das estradas podem gerar condições favoráveis à erosão. Estradas mal planejadas podem aumentar o escoamento superficial, concentrando o fluxo em áreas adjacentes e intensificando a erosão (Santana *et al.*, 2007).

O Fator K de erodibilidade do solo, apresentou menor potencial de impacto nos processos erosivos em comparação à outros fatores condicionantes. Segundo (Carvalho e Castro, 2023) regiões de alta erodibilidade se situa em área continua na microrregião Sudoeste Goiano, onde predominam os Neossolos Quartzarênicos sobre arenitos, além de alguns fragmentos no extremo noroeste e extremo nordeste, o que corrobora com a classificação no modelo preditivo.

Quanto ao mapa preditivo, regiões mais suscetíveis concentram-se nas cabeceiras de drenagem, onde fatores como alta declividade, solos mais erodíveis, convergência do fluxo hídrico e a presença de sistemas agrossilvipastoris com práticas menos conservacionistas favorecem o desenvolvimento de processos erosivos intensos. Em contrapartida, áreas menos suscetíveis à erosão linear estão associadas

a topografias planas e à presença de vegetação natural, que protege o solo do impacto direto da chuva e do escoamento superficial. Em algumas áreas agrícolas com plantio de soja, onde há práticas de manejo adequadas, a ocorrência de erosão linear é baixa.

5.5.3 Relevância do produto de suscetibilidade para instrumentos de gestão

A disponibilidade de um mapa de suscetibilidade à erosão linear em escala estadual para Goiás amplia a capacidade de planejamento territorial e de priorização de áreas de intervenção. No Cerrado, aplicações anteriores de mapeamento de potencial de erosão linear já demonstram a utilidade desses produtos em diagnósticos regionais e no apoio à gestão do uso do solo em Goiás (Maranhão *et al.*, 2017), em consonância com o produto técnico gerado neste estudo.

Quando vinculado a instrumentos econômicos, o mapa estadual permite direcionar programas de Pagamento por Serviços Ambientais (PSA), alocando recursos para propriedades situadas em áreas de alta suscetibilidade que adotam práticas conservacionistas. Revisões sobre programas de PSA no Brasil indicam que esses esquemas podem incentivar a conservação do solo e da água, desde que haja critérios espaciais definidos e monitoramento adequado (Mamedes *et al.*, 2023). Experiências em sistemas agrícolas do Centro-Oeste mostram que PSA voltados à melhoria do manejo favorecem a provisão de serviços ecossistêmicos e reduzem impactos erosivos (Oliveira *et al.*, 2023).

Nesse contexto, o mapa de suscetibilidade permite identificar áreas com alto potencial erosivo onde produtores já utilizam terraceamento e manejo adequado de pastagens, que poderiam receber prioridade em programas de PSA e em linhas de crédito rural com condições diferenciadas, fortalecendo a adoção dessas práticas (Silva *et al.*, 2025). Este trabalho indica que áreas suscetíveis à erosão linear com práticas conservacionistas podem ser priorizadas em políticas de incentivo, incluindo crédito direcionado à conservação, reforçando a convergência entre modelagem preditiva, PSA e instrumentos financeiros como eixo estratégico para a mitigação da erosão linear em Goiás.

5.6 Conclusão

A integração de variáveis topográficas, ambientais e antrópicas permitiu desenvolver um modelo preditivo capaz de representar, de forma consistente, os condicionantes da erosão linear no estado de Goiás. O uso de uma base geoespacial abrangente demonstrou que a combinação entre atributos físicos do terreno e

informações sobre cobertura e manejo favorece a compreensão da dinâmica de ravinas e voçorocas, atendendo aos objetivos do estudo.

A avaliação estatística do modelo *RF Ranger* mostrou desempenho satisfatório, com AUC de 0,8657, indicando boa capacidade de discriminação entre áreas suscetíveis e não suscetíveis. Esse resultado confirma a adequação do método adotado e atende ao segundo objetivo ao evidenciar que o modelo possui robustez para aplicações em escala regional. A análise da importância das variáveis evidenciou o papel das características de cobertura da terra, geomorfológicas e hidrológicas, que refletem a organização do uso da terra, do relevo e dos fluxos superficiais. O NDVI destacou-se como a variável mais influente, reforçando a relação entre vigor vegetativo, manejo de pastagens e formação de feições erosivas. Essa constatação subsidia interpretações sobre a influência de fatores ligados ao uso da terra e contribui para aprimorar futuros estudos voltados ao monitoramento ambiental.

Por fim, o mapa de suscetibilidade produzido indica padrões espaciais que podem apoiar o planejamento ambiental e orientar intervenções preventivas. O produto gerado pode servir de referência para decisões voltadas à conservação do solo, ao ordenamento do território e à definição de políticas públicas direcionadas a áreas mais sensíveis à erosão linear no território goiano.

CAPÍTULO 6

Produto técnico

Um mapa temático indicando as áreas com maior e menor suscetibilidade à erosão linear por ravinas e voçorocas é o produto técnico, de acordo com as definições do Grupo de Trabalho de Produção Técnica da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e está disponível no repositório https://doi.org/10.5281/zenodo.17783560, bem como o produto resultado do modelo RF Ranger.

CAPÍTULO 7

Síntese dos fatores condicionantes e da modelagem preditiva da erosão linear em Goiás

A erosão linear representa uma das formas mais impactantes de degradação do solo, interferindo no equilíbrio hidrogeomorfológico das encostas, na produtividade agrícola e na manutenção dos serviços ecossistêmicos. No Cerrado Goiano, tais processos ocorrem em um contexto de intensas transformações no uso da terra e expansão agropecuária, demandando o desenvolvimento de metodologias robustas para compreensão dos condicionantes e para a predição espacial da suscetibilidade. Esta dissertação buscou atender a essa necessidade por meio de três investigações complementares, cujo encadeamento permite avançar na avaliação dos fatores associados à ocorrência de ravinas e voçorocas, assim como na aplicação de técnicas de aprendizado de máquina para a construção de modelos preditivos em diferentes escalas de análise.

O primeiro artigo, já publicado como capítulo de livro (Pereira *et al.*, 2025), avaliou um amplo conjunto de variáveis frequentemente utilizadas em estudos de suscetibilidade à erosão linear, incorporando atributos topográficos primários e secundários, variáveis hidrológicas, pedológicas, geológicas e antrópicas, conforme sistematizado por Mohebzadeh *et al.* (2022). Essa etapa forneceu uma análise comparativa entre algoritmos de ensemble baseados em *bagging* e *boosting*, destacando o desempenho consistente do RF e do *RF Ranger*, resultado compatível com trabalhos como Rahmati *et al.* (2017), Arabameri *et al.* (2020a) e Mohebzadeh *et al.* (2022). Observou-se que variáveis relacionadas ao uso do solo e cobertura da terra, especialmente pastagem, além de NDVI, fator LS, declividade e erosividade da chuva (Fator R), exerceram influência marcante na modelagem. A etapa demonstrou ainda que a convergência de fluxo e a rugosidade topográfica desempenham papel relevante no favorecimento dos processos erosivos.

O segundo artigo examinou o papel da idade das pastagens, uma variável até

então não explorada em estudos de suscetibilidade, embora fortemente relacionada às condições de manejo. Os resultados mostraram que a idade da pastagem exerce uma influência significativa sobre a ocorrência de erosão linear. Pastagens antigas tendem a apresentar degradação estrutural mais avançada, compactação progressiva, perda da capacidade de infiltração e maior frequência de trilheiros de gado, elementos já documentados em estudos de Santana *et al.* (2007), Nunes e Castro (2015) e Nunes e Castro (2023). Esses fatores favorecem o escoamento superficial concentrado, ampliando a predisposição à formação de sulcos erosivos. Em contrapartida, o estudo demonstrou que o vigor da pastagem, derivado dos dados do MapBiomas Pastagem, não contribuiu para a modelagem preditiva, reforçando que a idade do uso pecuário, por si só, captura melhor os processos associados à degradação do solo na área avaliada.

O terceiro artigo ampliou a escala de aplicação e testou o modelo preditivo em todo o estado de Goiás, com base em mais de 65 mil focos erosivos identificados por Carvalho e Castro (2023). O uso desse conjunto extenso de amostras possibilitou avaliar a aplicabilidade de técnicas de aprendizado de máquina em nível regional, atendendo a uma lacuna apontada por Lana, Castro e Lana (2022), já que estudos com grande representatividade espacial ainda são limitados no país. Nessa nova modelagem, ainda houve maior avanço metodológico ao usar a abordagem de validação cruzada por blocos para reduzir o viés causado pela autocorrelação espacial. Adicionalmente, foram utilizados gráficos PDP para auxiliar na melhor interpretação do efeito das variáveis preditoras sobre o fenômeno estudado. O modelo final integrou variáveis topográficas derivadas do FathomDEM, um MDT de melhor qualidade em relação ao FABDEM (Uhe *et al.*, 2025; Guth *et al.*, 2025), variáveis hidrológicas, pedológicas, geológicas e de uso da terra, resultando em um mapa preditivo que representa padrões coerentes de suscetibilidade no território goiano. As áreas mais suscetíveis foram concentradas em cabeceiras de drenagem, encostas íngremes, setores com maior convergência de fluxo e regiões amplamente convertidas em pastagens.

Ao integrar os resultados dos três artigos, esta dissertação contribui em três frentes principais. A primeira reside na confirmação da relevância de atributos topográficos e de variáveis antrópicas como componentes chave da suscetibilidade à erosão linear. A segunda demonstra que a idade da pastagem é um indicador funcional para identificar áreas com maior risco de erosão linear, reforçando a relação entre o histórico de uso agropecuário e a degradação da estrutura física do solo. A terceira contribuição consiste na demonstração da viabilidade de modelos preditivos em larga escala, alimentados por bases de dados extensas e por MDEs globais recentes, com potencial de aplicação em práticas de planejamento territorial

e mitigação de impactos.

Os resultados reforçam a importância de abordagens multiescalares, do uso de grandes bases geoespaciais e da integração entre fatores físicos e antrópicos para compreender a erosão linear em ambientes tropicais sazonais. O conjunto metodológico consolidado na dissertação fornece subsídios técnicos para ações de gestão ambiental e representa um avanço relevante nas aplicações de aprendizado de máquina voltadas ao mapeamento de áreas suscetíveis à erosão linear no Cerrado Goiano.

CAPÍTULO 8

Considerações finais

Os resultados deste estudo demonstram que o modelo preditivo desenvolvido cumpriu o objetivo geral ao mapear áreas suscetíveis à erosão linear no Cerrado goiano com base em variáveis topográficas, ambientais e antrópicas. A aplicação de algoritmos de aprendizado de máquina permitiu identificar padrões associados à ocorrência de erosões, destacando o papel combinado do relevo, da cobertura da terra e do manejo das pastagens na formação dessas feições.

A análise das variáveis relacionadas ao meio físico e antrópico evidenciou que atributos topográficos, fatores hidrológicos, classes de uso da terra e indicadores de vegetação influenciam de forma distinta a suscetibilidade à erosão linear. O destaque das áreas de pastagem, aliado ao comportamento de variáveis como NDVI, declividade e fator LS, atende ao primeiro objetivo específico e reforça a necessidade de integrar informações ambientais e de manejo em avaliações de suscetibilidade erosiva.

No que se refere à aplicabilidade da modelagem, verificou-se que a área modelo apresentou desempenho consistente, o que favoreceu a ampliação da predição para todo o estado de Goiás. O modelo manteve estabilidade na fase de validação, cumprindo o segundo objetivo específico e indicando potencial para análises em escalas amplas. Ainda assim, recomenda-se cautela ao interpretar resultados em regiões com dinâmicas ambientais distintas da área piloto.

A avaliação estatística dos algoritmos indicou boa capacidade preditiva, destacando métodos de *ensemble* de árvores de decisão. A análise de importância das variáveis permitiu identificar fatores que contribuíram de maneira mais expressiva para a classificação, atendendo ao terceiro objetivo específico. Contudo, a variabilidade espacial dos processos erosivos pode limitar a extrapolação de alguns padrões, sobretudo em áreas com menor densidade de pontos observados.

O mapa de suscetibilidade sintetiza as áreas de maior e menor propensão à erosão linear no estado, cumprindo o quarto objetivo específico. Esse produto técnico pode auxiliar na tomada de decisões em planejamento ambiental, gestão territorial e formulação de políticas públicas. Como exemplo, áreas suscetíveis à

erosão linear em que produtores rurais adotam práticas conservacionistas de solo podem ser priorizadas em programas de incentivo, incluindo acesso facilitado a linhas de crédito voltadas à conservação e recuperação ambiental.

Entre as limitações do estudo, destacam-se a dependência da qualidade dos dados de entrada, a resolução espacial dos modelos digitais de elevação e a heterogeneidade temporal das variáveis antrópicas. Pesquisas futuras podem incorporar dados multitemporais de uso do solo e cobertura da terra, modelos altimétricos de melhor qualidade e técnicas de aprendizagem profunda para ampliar a capacidade de detecção de padrões complexos.

Recomenda-se o fortalecimento do monitoramento sistemático das erosões lineares em Goiás e no Brasil, a integração de dados de campo em campanhas periódicas e a exploração de cenários preditivos baseados em mudanças no uso do solo e nas condições climáticas. Esses aperfeiçoamentos podem ampliar a utilidade dos modelos em iniciativas de conservação do solo e em ações governamentais voltadas ao desenvolvimento sustentável.

Referências

ABREU, Laudier Lopes; PEREIRA, Alessandra Cristina; ALVES, Fabio Corrêa; RABELO, Max Well de Oliveira; NUNES, Elizon Dias; CREMON, Édipo Henrique. Exploring topographic variables in gully erosion susceptibility mapping in Central Brazil. **Boletín de la Sociedad Geológica Mexicana**, v. 77, n. 3, p. A121025, 2025. Disponível em: `http://dx.doi.org/10.18268/BSGM2025v77n3a121025`. 55

ALBUQUERQUE, Anesmar; JúNIOR, Osmar de Carvalho; GUIMARãES, Renato; GOMES, Roberto; HERMUCHE, Potira. Assessment of gully development using geomorphic change detection between pre- and post-urbanization scenarios. **Environmental Earth Sciences**, v. 79, 05 2020. 23

ALVES, Hudo S. Loureiro. **DIAGNÓSTICO DE EROSÃO POR VOÇOROCAS: Experimentos com Geotecnologias e Solos na Bacia do Alto Rio Piraí - Rio Claro-RJ - GULLY EROSION DIAGNOSIS: Experiments with Geotechnologies and Soils in the Upper rio Piraí Basin - Rio Claro-RJ**. Tese (Doutorado), 07 2019. 19

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. 28, 29, 43, 44, 51, 75

ARABAMERI, Alireza; NALIVAN, Omid Asadi; PAL, Subodh Chandra; CHAKRABORTTY, Rabin; SAHA, Asish; LEE, Saro; PRADHAN, Biswajeet; BUI, Dieu Tien. Novel machine learning approaches for modelling the gully erosion susceptibility. **Remote Sensing**, MDPI, v. 12, n. 17, p. 2833, 2020. 13, 14, 30, 70

ARABAMERI, Alireza; PAL, Subodh Chandra; COSTACHE, Romulus; SAHA, Asish; REZAIE, Fatemeh; DANESH, Amir Seyed; PRADHAN, Biswajeet; LEE, Saro; HOANG, Nhat-Duc. Prediction of gully erosion susceptibility mapping using

novel ensemble machine learning algorithms. **Geomatics, Natural Hazards and Risk**, Taylor & Francis, v. 12, n. 1, p. 469–498, 2021. 39

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. 30, 68

BERNINI, Alice; BOSINO, Alberto; BOTHA, Greg A; MAERKER, Michael. Evaluation of gully erosion susceptibility using a maximum entropy model in the upper mkhomazi river basin in south africa. **ISPRS International Journal of Geo-Information**, MDPI, v. 10, n. 11, p. 729, 2021. 70

BOARDMAN, John; FAVIS-MORTLOCK, David. Boardman, j. and favis-mortlock, d.t. (2016). the use of erosion pins in geomorphology. chapter 3.5.3 in cook, s.j., clarke, l.e. and nield, j.m. (eds) geomorphological techniques (online edition). british society for geomorphology, london, uk. issn: 2047-0371. *In*: _____. [S.l.: s.n.], 2016. ISBN 2047-0371. 19

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. 29, 43

BOEHNER, J.; SELIGE, T. Spatial prediction of soil attributes using terrain analysis and climate regionalisation. *In*: BOEHNER, J.; MCCLOY, K. R.; STROBL, J. (Ed.). **SAGA - Analysis and Modelling Applications**. [S.l.]: Goettinger Geographische Abhandlungen, 2006. v. 115, p. 13–27. 33, 39, 49

BORRELLI, Pasquale; BALLABIO, Cristiano; YANG JAE E.AND ROBINSON, David A.; PANAGOS, Panos. Glosem: High-resolution global estimates of present and future soil displacement in croplands by water erosion. **Scientific Data**, v. 9, p. 2052–4463, 2022. Disponível em: `https://doi.org/10.1038/s41597-022-01489-x`. 19

BORRELLI, Pasquale; ROBINSON, David A; FLEISCHER, Larissa R; LUGATO, Emanuele; BALLABIO, Cristiano; ALEWELL, Christine; MEUSBURGER, Katrin; MODUGNO, Sirio; SCHÜTT, Brigitta; FERRO, Vito *et al.* An assessment of the global impact of 21st century land use change on soil erosion. **Nature communications**, Nature Publishing Group UK London, v. 8, n. 1, p. 2013, 2017. 43

BREIMAN, Leo. Random forests. **Machine Learning**, v. 45, p. 5 – 32, 2001. 28

_____. _____. **Machine learning**, Springer, v. 45, p. 5–32, 2001. 34, 59

Camapum de Carvalho, José; SALES, Maurício Martines; SOUZA, Newton Moreira; MELO, Maria Tereza Silva. **Processos erosivos no centro-oeste brasileiro**. [S.l.]: Finatec, 2006. 18

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, dez. 2023. Disponível em: https://rbgeomorfologia.org.br/rbg/article/view/2373. 8, 14, 30, 31, 32, 44, 51, 54, 55, 68, 71, 76

CHAGAS, César da Silva; FILHO, Elpídio Inácio Fernandes; VIEIRA, Carlos Antônio Oliveira; SCHAEFER, Carlos Ernesto Gonçalves Reynaud; JúNIOR, Waldir de Carvalho. Atributos topográficos e dados do landsat7 no mapeamento digital de solos com uso de redes neurais. **Pesquisa Agropecuária Brasileira**, Embrapa Secretaria de Pesquisa e Desenvolvimento; Pesquisa Agropecuária Brasileira, v. 45, n. 5, p. 497–507, May 2010. ISSN 0100-204X. Disponível em: https://doi.org/10.1590/S0100-204X2010000500009. 28

CHAPLOT, Vincent. Impact of terrain attributes, parent material and soil types on gully erosion. **Geomorphology**, Elsevier, v. 186, p. 1–11, 2013. 40, 49, 69

CHEN, Yixian; De Geeter, Sofie; POESEN, Jean; MATTHEWS, Francis; CAMPFORTS, Benjamin; BORRELLI, Pasquale; PANAGOS, Panos; VANMAERCKE, Matthias. Global patterns of gully occurrence and their sensitivity to environmental changes. **International Soil and Water Conservation Research**, 2025. ISSN 2095-6339. Disponível em: https://www.sciencedirect.com/science/article/pii/S209563392500111X. 50

CICCOLINI, Ugo; BUFALINI, Margherita; MATERAZZI, Marco; DRAMIS, Francesco. Gully erosion development in drainage basins: A new morphometric approach. **Land**, MDPI, v. 13, n. 6, p. 792, 2024. 69

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. 32

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. 30, 31

DAMASCO, Gabriel; FONTES, Clarissa; FRANÇOSO, Renata; HAIDAR, Ricardo. The cerrado biome: a forgotten biodiversity hotspot. **Frontiers for Young Minds**, Frontiers Media SA, v. 6, 2018. 50

DESMET, Philippe JJ; GOVERS, Gerard. A GIS procedure for automatically calculating the USLE LS factor on topographically complex landscape units. **Journal of soil and water conservation**, Soil and Water Conservation Society, v. 51, n. 5, p. 427–433, 1996. 33

El Bouzekraoui, Meryem; ELALOUI, Abdenbi; KRIMISSA, Samira; ABDELRAHMAN, Kamal; KAHAL, Ali Y; HAJJI, Sonia; ISMAILI, Maryem; MONDAL, Biraj Kanti; NAMOUS, Mustapha. Performance assessment of individual and ensemble learning models for gully erosion susceptibility mapping in a mountainous and semi-arid region. **Land**, MDPI, v. 13, n. 12, p. 2110, 2024. 68

ESCOVEDO, Tatiana; KOSHIYAMA, Adriano. **Introdução a Data Science: Algoritmos de Machine Learning e métodos de análises**. [S.l.: s.n.], 2020. 27

ESRI. Arcgis blog: How to extract raster values at point locations? 2017. Disponível em: `https://www.esri.com/arcgis-blog/products/arcgis-pro/analytics/how-to-extract-raster-values-at-point-locations/`. 22

FAO. **Soil erosion: the greatest challenge to sustainable soil management**. Rome: Food and Agriculture Organization of the United Nations, 2019. 100 p. Licence: CC BY-NC-SA 3.0 IGO. Disponível em: `https://openknowledge.fao.org/server/api/core/bitstreams/a268e967-a373-4a56-adac-ae1d7ab3567f/content`. 17, 18, 50

FATHOM, United Kingdom. **FathomDEM v1-0 Americas**. Zenodo, fev. 2025. Disponível em: `https://doi.org/10.5281/zenodo.14523356`. 24

FERNáNDEZ, Tomás; PéREZ-GARCíA, José Luis; GóMEZ-LóPEZ, José Miguel; CARDENAL, Javier; CALERO, Julio; SáNCHEZ-GóMEZ, Mario; DELGADO, Jorge; TOVAR-PESCADOR, Joaquín. Multitemporal analysis of gully erosion in olive groves by means of digital elevation models obtained with aerial photogrammetric and lidar data. **ISPRS International Journal of Geo-Information**, v. 9, n. 4, 2020. ISSN 2220-9964. Disponível em: `https://www.mdpi.com/2220-9964/9/4/260`. 19

FLORINSKY, Igor V. Digital terrain analysis in soil science and geology. **Institute of Mathematical Problems of Biology Russian Academy of Sciences**, Pushchino, Russia, 2016. 63

FRIEDMAN, Jerome. Greedy function approximation: A gradient boosting machine. **The Annals of Statistics**, v. 29, 11 2001. 33

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. 39, 43, 49

GAROSI, Younes; SHEKLABADI, Mohsen; CONOSCENTI, Christian; POURGHASEMI, Hamid Reza; OOST, Kristof Van. Assessing the performance of gis-based machine learning models with different accuracy measures for determining susceptibility to gully erosion. **Science of the Total Environment**, Elsevier, v. 664, p. 1117–1132, 2019. 40

GHOLAMI, Vahid; SAHOUR, Hossein; Hadian Amri, Mohammad Ali. Soil erosion modeling using erosion pins and artificial neural networks. **CATENA**, v. 196, p. 104902, 2021. ISSN 0341-8162. Disponível em: `https://www.sciencedirect.com/science/article/pii/S0341816220304525`. 19

GHORBANZADEH, Omid; SHAHABI, Hejar; MIRCHOOLI, Fahimeh; KAMRAN, Khalil Valizadeh; LIM, Samsung; ARYAL, Jagannath; JARIHANI, Ben; BLASCHKE, Thomas. Gully erosion susceptibility mapping (gesm) using machine learning methods optimized by the multi-collinearity analysis and k-fold cross-validation. **Geomatics, Natural Hazards and Risk**, Taylor & Francis, v. 11, n. 1, p. 1653–1678, 2020. 68

GHOSH, Sandipan; GUCHHAIT, Sanat Kumar; ILLAHI, Rahman Ashiq; BERA, Subhankar; ROY, Suvendu. Geomorphic character and dynamics of gully morphology, erosion and management in laterite terrain: few observations from dwarka–brahmani interfluve, eastern india. **Geology, Ecology, and Landscapes**, Taylor & Francis, v. 6, n. 3, p. 188–216, 2022. 70

GOIAS. **Agro em Dados**, SEAPA - Secretaria de Estado de Agricultura Pecuária e Abastecimento, n. outubro, p. p. 1–37, 2025. Disponível em: `https://goias.gov.br/agricultura/agro-em-dados-outubro-2025/`. 53

GOUDIE, AS. **Encyclopedia of geomorphology**. [S.l.]: Routledge, 2004. 18

GOUDIE, Andrew. Human impact. *In*: _____. [S.l.: s.n.], 2020. p. 57–72. ISBN 978-3-030-38956-7. 17, 18, 69

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. 71

GREENWELL, Brandon M. pdp: An r package for constructing partial dependence plots. **The R Journal**, v. 9, p. 421–436, 2017. ISSN 2073-4859. Https://doi.org/10.32614/RJ-2017-016. 61

GUERRA, Antonio; BEZERRA, José Rodrigues; FULLEN, Michael. Urban gullies in São Luis city, Maranhão state, Brazil. p. 58–59, 06 2008. 18

GUERRA, Antonio José Teixeira; BEZERRA, José Fernando Rodrigues; JORGE, Maria do Carmo Oliveira. Recuperação de voçorocas e de áreas degradadas, no brasil e no mundo - estudo de caso da voçoroca do sacavém - são luís – ma. **Revista Brasileira de Geomorfologia**, v. 24, n. 00, jul. 2023. Disponível em: `https://rbgeomorfologia.org.br/rbg/article/view/2306`. 19

GUERRA, Antonio Jose Teixeira; JORGE, Maria do Carmo Oliveira; RANGEL, Luana de Almeida; BEZERRA, José Fernando Rodrigues; LOUREIRO, Hugo alves soares; GARRITANO, Fabrizio do Nascimento. Soil erosion, different approaches and techniques applied to gullies and trail erosion. **William Morris Davis - Revista de Geomorfologia**, v. 1, n. 1, p. 75–117, ago. 2020. Disponível em: `//williammorrisdavis.uvanet.br/index.php/revistageomorfologia/article/view/16`. 19

GUTH, Peter L; NIEKERK, Adriaan Van; GROHMANN, Carlos H; MULLER, Jan-Peter; HAWKER, Laurence; FLORINSKY, Igor V; GESCH, Dean; REUTER, Hannes I; HERRERA-CRUZ, Virginia; RIAZANOFF, Serge *et al.* Digital elevation models: Terminology and definitions. **Remote Sensing**, Multidisciplinary Digital Publishing Institute, v. 13, n. 18, p. 3581, 2021. 23

GUTH, Peter L; TREVISANI, Sebastiano; GROHMANN, Carlos H; LINDSAY, John B; REUTER, Hannes I. Benchmarking elevation plus land surface parameters finds fathomdem and copernicus dem win as best global dems. **Remote Sensing**, MDPI, v. 17, n. 23, p. 3919, 2025. 55, 76

HART, Evan; MILLS, Hugh; LI, Peter. Measuring erosion rates on exposed limestone residuum using erosion pins: a 10-year record. **Physical Geography**, v. 38, 06 2017. 19

HASANUZZAMAN, Md; SHIT, Pravat. Assessment of gully erosion susceptibility using four data-driven models ahp, fr, rf and xgboosting machine learning algorithms. **Natural Hazards Research**, Elsevier, 2024. 39

HORST, Taciara Zborowski; SAMUEL-ROSA, Alessandro; SILVA, Barbara Costa; SILVA, Wallace Vieira da; CARDOSO, Marcos Vinicius Souza; ANJOS, Marcos Alexandre dos; PRETTO, Ana Caroline; SANTOS, Erli Pinto dos; DIAS, Mariana; ROSA, Eduardo Reis; WEBER, Eliseu; SOUZA, Deorgia Tayane Mendes de; ROCHA, Anderson Sandro da; AZEVEDO, Tasso; SHIMBO, Julia; ROSA, Marcos; Ferreira Júnior, Laerte Guimarães. **MapBiomas Soil Brazil - Algorithm Theoretical Basis Document (ATBD) - Collection 2.1 (Beta)**. MapBiomas Data, 2025. Disponível em: `https://doi.org/10.58053/MapBiomas/CDXGQD`. 56

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. 40

HUGGETT, Richard; SHUTTLEWORTH, Emma. **Fundamentals of geomorphology**. [S.l.]: Routledge, 2022. 71

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **MANUAIS TÉCNICOS EM GEOCIÊNCIAS: Acesso e Usos de Dados Geoespaciais**. Rio de Janeiro, RJ: Nome da Editora, 2019. 139 p. Disponível em: `https://biblioteca.ibge.gov.br/visualizacao/livros/liv101675.pdf`. 56

_____. **Banco de Dados e Informações Ambientais (BDiA)**. 2023. Disponível em: `https://bdiaweb.ibge.gov.br/`. 30, 33, 56

_____. **Cidades e Estados**. 2024. Disponível em: `https://cidades.ibge.gov.br/brasil/go/panorama`. Acesso em: 10 out 2025. 51

IONITA, Ion; FULLEN, Michael; ZGŁOBICKI, Wojciech; POESEN, J. Gully erosion as a natural and human-induced hazard. **Natural Hazards**, v. 79, p. 1–5, 11 2015. 17, 18, 29, 69

IPT. **Controle de erosão: bases conceituais e técnicas; diretrizes para o planejamento urbano e regional; orientações para o controle de boçorocas urbanas**. São Paulo: IPT, 1989. 18

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. 56

KOPECKý, Martin; MACEK, Martin; WILD, Jan. Topographic wetness index calculation guidelines based on measured soil moisture and plant species composi-

tion. **Science of The Total Environment**, v. 757, p. 143785, 2021. ISSN 0048-9697. Disponível em: https://www.sciencedirect.com/science/article/pii/S0048969720373162. 70

KUHN, Max. Building predictive models in r using the caret package. **Journal of Statistical Software**, v. 28, n. 5, p. 1–26, 2008. Disponível em: https://www.jstatsoft.org/index.php/jss/article/view/v028i05. 34, 45, 46, 57

KUNH, Max; WING, Jed; WESTON, Steve; WILLIAMS, Andre; KEEFER, Chris; ENGELHARDT, Allan; COOPER, Tony; MAYER, Zachary; KENKEL, Brenton; CORE, Team R; BENESTY, Michael; LESCARBEAU, Reynald; ZIEM, Andrew; SCRUCCA, Luca; TANG, Yuan; CANDAN, Can; HUNT, Tyler. **Caret: classification and regression training. R package (version 6.0-90)**. [S.l.: s.n.], 2021. Disponível em: https://cran.r-project.org/web/packages/caret/index.html. 33, 34

LAL, Rattan; BOUMA, Johan; BREVIK, Eric; DAWSON, Lorna; FIELD, Damien J.; GLASER, Bruno; HATANO, Ryusuke; HARTEMINK, Alfred E.; KOSAKI, Takashi; LASCELLES, Bruce; MONGER, Curtis; MUGGLER, Cristine; NDZANA, Georges Martial; NORRA, Stefan; PAN, Xicai; PARADELO, Remigio; REYES-SáNCHEZ, Laura Bertha; SANDéN, Taru; SINGH, Bal Ram; SPIEGEL, Heide; YANAI, Junta; ZHANG, Jiabao. Soils and sustainable development goals of the united nations: An international union of soil sciences perspective. **Geoderma Regional**, v. 25, p. e00398, 2021. ISSN 2352-0094. Disponível em: https://www.sciencedirect.com/science/article/pii/S2352009421000432. 13

LANA, Julio Cesar; CASTRO, Paulo de Tarso Amorim; LANA, Cláudio Eduardo. Assessing gully erosion susceptibility and its conditioning factors in southeastern brazil using machine learning algorithms and bivariate statistical methods: A regional approach. **Geomorphology**, Elsevier, v. 402, p. 108159, 2022. 14, 69, 76

LAW, W. Boone; SLACK, Michael J.; OSTENDORF, Bertram; LEWIS, Megan M. Digital terrain analysis reveals new insights into the topographic context of australian aboriginal stone arrangements. **Archaeological Prospection**, v. 24, n. 2, p. 169–179, 2017. Disponível em: https://onlinelibrary.wiley.com/doi/abs/10.1002/arp.1567. 23

LINDSAY, John B. Whitebox GAT: A case study in geomorphometric analysis. **Computers & Geosciences**, Elsevier, v. 95, p. 75–84, 2016. 32

LINDSAY, John B.; NEWMAN, Daniel R. Hyper-scale analysis of surface roughness. **PeerJ Preprints 6:e27110v1**, v. 1, 2018. 69

LIU, Chenxin; ZHANG, Zizhao; CHENG, Lilong; WANG, Yamei; LIU, Xinyu; LAI, Runsen; LYV, Qianli. Effects of soil particle size on rainfall-induced erosion of near-horizontal layered slopes. **PLoS One**, Public Library of Science San Francisco, CA USA, v. 20, n. 9, p. e0331153, 2025. 71

LOUREIRO, Hugo alves S.; GUERRA, Antonio José Texeira; FERNANDO BEZERRA, José Fernando Rodrigues; PEREIRA, Leonardo; GARRITANO, Fabrizio. 9. monitoramento da erosÃo hÍdrica no brasil: Dos mÉtodos manuais aos digitais. *In*: _____. [S.l.: s.n.], 2022. 13, 17, 19, 69

LOVELACE, Robin; NOWOSAD, Jakub; MUENCHOW, Jannes. **Geocomputation with R**. Chapman and Hall/CRC, 2019. Disponível em: `https://bookdown.org/robinlovelace/geocompr/`. 20, 22

MALEKI, Farhad; MUTHUKRISHNAN, Nikesh; OVENS, Katie; REINHOLD, Caroline; FORGHANI, Reza. Machine learning algorithm validation: From essentials to advanced applications and implications for regulatory certification and deployment. **Neuroimaging Clinics of North America**, v. 30, n. 4, p. 433–445, 2020. ISSN 1052-5149. Machine Learning and Other Artificial Intelligence Applications. Disponível em: `https://www.sciencedirect.com/science/article/pii/S1052514920300599`. 57

MAMEDES, Ingrid; GUERRA, Angélica; RODRIGUES, Dulce B.B.; GARCIA, Letícia Couto; GODOI, Raquel de Faria; OLIVEIRA, Paulo Tarso S. Brazilian payment for environmental services programs emphasize water-related services. **International Soil and Water Conservation Research**, v. 11, n. 2, p. 276–289, 2023. ISSN 2095-6339. Disponível em: `https://www.sciencedirect.com/science/article/pii/S2095633923000011`. 72

MANNIGEL, Anny; PASSOS, Morel; MORETI, Dolorice; DA, Luciano; MEDEIROS, Rosa. Fator erodibilidade e tolerância de perda dos solos do estado de são paulo. **Acta Scientiarum. Agronomy**, v. 24, 04 2008. 56

MARANHÃO, Deyvid Diego Carvalho; AGUADO, Oscar Ivan de Oro; PEREIRA, Marcos Gervasio; ARAÚJO, Adelson Paulo; CASTRO, Selma Simões de; JÚNIOR, Laerte Guimarães Ferreira. Analysis of potential for linear erosion in the cerrado biome using morphopedology. **Revista Brasileira de Ciência do Solo**, SciELO Brasil, v. 41, p. e0160427, 2017. 72

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. 40, 41, 70, 71

MARQUES, Valter S.; CEDDIA, Marcos B.; ANTUNES, Mauro A. H.; CARVALHO, Daniel F.; ANACHE, Jamil A. A.; RODRIGUES, Dulce B. B.; OLIVEIRA, Paulo Tarso S. Usle k-factor method selection for a tropical catchment. **Sustainability**, v. 11, n. 7, 2019. ISSN 2071-1050. Disponível em: https://www.mdpi.com/2071-1050/11/7/1840. 56

MENDES, Thiago Augusto; REBOLLEDO, Juan Félix Rodriguez; PEREIRA, Sávio Aparecido dos Santos; OLIVEIRA, Marcus Vinicius Miguel de; FORMIGA, Klebber Teodomiro Martins. Development of a device for monitoring erosion in the field. **Micromachines**, v. 15, n. 7, 2024. ISSN 2072-666X. Disponível em: https://www.mdpi.com/2072-666X/15/7/880. 19

MENESES, Paulo Roberto. Formato das imagens de sensoriamento remoto. *In*: (ORG.), Paulo Roberto Meneses e Tati de Almeida (Ed.). [S.l.: s.n.], 2012, (Introdução ao processamento de imagens de sensoriamento remoto). p. 77–81. 20, 21

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. 14, 24, 25, 26, 27, 28, 30, 32, 39, 44, 49, 51, 55, 68, 69, 75

MOORE, Ian Donald; GRAYSON, RB; LADSON, AR. Digital terrain modelling: a review of hydrological, geomorphological, and biological applications. **Hydrological processes**, Wiley Online Library, v. 5, n. 1, p. 3–30, 1991. 25, 33

MOSAVI, Amirhosein; HOSSEINI, Farzaneh Sajedi; CHOUBIN, Bahram; GOODARZI, Massoud; DINEVA, Adrienn A; SARDOOI, Elham Rafiei. Ensemble boosting and bagging based machine learning models for groundwater potential prediction. **Water Resources Management**, Springer, v. 35, p. 23–37, 2021. 49

NACEUR, Hassan Ait; ABDO, Hazem Ghassan; IGMOULLAN, Brahim; NAMOUS, Mustapha; ALSHEHRI, Fahad; ALBANAI, Jasem A. Implementation of random forest, adaptive boosting, and gradient boosting decision trees algorithms for gully erosion susceptibility mapping using remote sensing and gis. **Environmental Earth Sciences**, Springer, v. 83, n. 3, p. 121, 2024. 45, 68, 69

NEAL, J.; HAWKER, L.; UHE, P.; PAULO, L.; SOSA, J.; SAVAGE, J.; SAMPSON, C. **FABDEM V1-2**. January 17 2023. Version 1-2. Disponível em: https://doi.org/10.5523/bris.s5hqmjcdj8yo2ibzi9b4ew3sn. 32

NUNES, Elizon Dias; CASTRO, Selma Simões de. Compartimentação morfopedológica 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. 30, 39, 40, 76

_____. 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, out. 2023. Disponível em: https://rbgeomorfologia.org.br/rbg/article/view/2368. 30, 33, 39, 40, 50, 56, 69, 76

NZEREOGU, Stella Kosi; IGWE, Ogbonnaya; EMEH, Chukwuebuka Odinaka; UKOR, Kelechi Paulinus; ECHEZONA, Pearl Elochukwu. Comparative analysis of the expansion rate and soil erodibility factor of some gullies in nnewi and nnobi, southeastern nigeria. **Scientific Reports**, Nature Publishing Group UK London, v. 13, n. 1, p. 15293, 2023. 71

OLIVEIRA, Franciele DE Kássia DE; SANTOS, Carolina Emilia Dos; SIQUEIRA, Mariana N; PASSOS, Haihani S; MORAIS, Alessandro R. Evaluating the impacts of payment for ecosystem services (water supplies) in an agricultural system of the brazilian cerrado. **Anais da Academia Brasileira de Ciências**, SciELO Brasil, v. 95, n. 2, p. e20220054, 2023. 72

OLIVIER, George; WIEL, Marco J Van De; CLERCQ, Willem P de. Predicting gully erosion susceptibility in south africa by integrating literature directives with regional spatial data. **Earth Surface Processes and Landforms**, Wiley Online Library, v. 48, n. 14, p. 2661–2681, 2023. 68

PAL, Subodh Chandra; ARABAMERI, Alireza; BLASCHKE, Thomas; CHOWDHURI, Indrajit; SAHA, Asish; CHAKRABORTTY, Rabin; LEE, Saro; BAND, Shahab S. Ensemble of machine-learning methods for predicting gully erosion susceptibility. **Remote Sensing**, MDPI, v. 12, n. 22, p. 3675, 2020. 51

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. 33, 56, 69

PARENTE, Leandro; MESQUITA, Vinícius; MIZIARA, Fausto; BAUMANN, Luis; FERREIRA, Laerte. Assessing the pasturelands and livestock dynamics in brazil, from 1985 to 2017: A novel approach based on high spatial resolution imagery and google earth engine cloud computing. **Remote Sensing of Environment**, Elsevier, v. 232, p. 111301, 2019. 44

PARENTE, Leandro; MESQUITA, Vinícius; MIZIARA, Fausto; BAUMANN, Luis; FERREIRA, Laerte. Assessing the pasturelands and livestock dynamics in brazil, from 1985 to 2017: A novel approach based on high spatial resolution imagery and google earth engine cloud computing. **Remote Sensing of Environment**, v. 232, p. 111301, 2019. ISSN 0034-4257. Disponível em: `https://www.sciencedirect.com/science/article/pii/S0034425719303207`. 55

PEREIRA, Alessandra Cristina; CREMON Édipo Henrique; ABREU, Laudier Lopes; CARVALHO, Hellbia Samara Moreira de. Avaliação de variáveis críticas para a ocorrência de erosões lineares utilizando algoritmos de aprendizado de máquina. *In*: GOMES, Raphael de Aquino; MENDES, Thiago Augusto; OLIVEIRA, Sérgio Botelho de (Ed.). **Inovação e Sustentabilidade em Goiás: Perspectivas Interdisciplinares**. Curitiba: CRV, 2025, (Coleção: ECOS, v. 1). p. 31–46. ISBN 978-65-251-7324-5. 12 p. 15, 29, 75

PIKE, R.J.; EVANS, I.S.; HENGL, T. Chapter 1 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`. 23

POESEN, J. Soil erosion hazard and mitigation in the euro-mediterranean region: Do we need more research? **Hungarian Geographical Bulletin**, v. 64, p. 293–299, 12 2015. 18, 29

POESEN, Jean. Soil erosion in the Anthropocene: Research needs. **Earth surface processes and landforms**, Wiley Online Library, v. 43, n. 1, p. 64–84, 2018. 13, 17, 50, 69

POESEN, Jean; NACHTERGAELE, Jeroen; VERSTRAETEN, Gert; VALENTIN, Christian. Gully erosion and environmental change: importance and research needs. **Catena**, Elsevier, v. 50, n. 2-4, p. 91–133, 2003. 18

QGIS Development Team. **QGIS Geographic Information System**. 2024. Open Source Geospatial Foundation Project. Disponível em: https://qgis.org. 34, 56, 60

RAHMATI, Omid; TAHMASEBIPOUR, Nasser; HAGHIZADEH, Ali; POURGHASEMI, Hamid Reza; FEIZIZADEH, Bakhtiar. Evaluation of different machine learning models for predicting and mapping the susceptibility of gully erosion. **Geomorphology**, Elsevier, v. 298, p. 118–137, 2017. 28, 30, 44, 51, 68, 75

RICHTER, Daniel; EPPES, Martha; AUSTIN, Jason; BACON, Allan; BILLINGS, Sharon; BRECHEISEN, Zachary; FERGUSON, Terry; MARKEWITZ, Daniel; PACHON, Julio; SCHROEDER, Paul; WADE, Anna. Soil production and the soil geomorphology legacy of grove karl gilbert. **Soil Science Society of America Journal**, v. 84, 02 2020. 19

ROSA, Lucas Espíndola; CHEREM, Luis Felipe Soares; SIAME, Lionel. O papel de fatores naturais e antrópicos na variabilidade da perda de solos no estado de goiás entre 1985 e 2018. **Sociedade Natureza**, v. 35, 2023. 56

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. 39, 40, 41, 71, 76

SANTOS, Lorenna Rodrigues de Oliveira; SILVA, Rejane Moreira da. **Goiás em dados 2024**. Goiânia: IMB, 2025. Disponível em: https://goias.gov.br/imb/wp-content/uploads/sites/29/2025/02/Goias_em_dados_2024.pdf. 14, 52, 53

SARTORI, Martina; FERRARI, Emanuele; M'BAREK, Robert; PHILIPPIDIS, George; BOYSEN-URBAN, Kirsten; BORRELLI, Pasquale; MONTANARELLA, Luca; PANAGOS, Panos. Remaining loyal to our soil: A prospective integrated assessment of soil erosion on global food security. **Ecological Economics**, p. 108103, 2024. ISSN 0921-8009. Disponível em: https://www.sciencedirect.com/science/article/pii/S092180092300366X. 19, 29

SCHWAMBACK, Dimaghi; BRANDÃO, Abderraman R Amorim; BERTOTTO, Luis Eduardo; BERNDTSSON, Ronny; ZHANG, Linus; WENDLAND, Edson; PERSSON, Magnus. Quantifying soil loss in the brazilian savanna ecosystem: current rates and anticipated impact of climate changes. **Land Degradation & Development**, Wiley Online Library, v. 35, n. 18, p. 5786–5803, 2024. 50

SHIT, Pravat Kumar; PAIRA, Rumpa; BHUNIA, GouriSankar; MAITI, Ramkrishna. Modeling of potential gully erosion hazard using geo-spatial technology at garbheta block, west bengal in india. **Modeling Earth Systems and Environment**, Springer, v. 1, p. 1–16, 2015. 13, 30

SILVA, João Edson Costa Ferreira; PONS, Nívea; CALçADO, Samara; LACERDA, Camila. DelimitaÇÃo de voÇorocas por meio de geobia (geographic object based image analysis) e mineraÇÃo de dados, utilizando produtos cartogrÁficos de aeronaves remotamente pilotadas (arp). **Boletim Paranaense de Geociências**, v. 80, 11 2022. 19

SILVA, Luiza Maria Affonso Lopes; SANTANA, Rodrigo Nobre; MENEZES, Sady Júnior Martins da Costa de; DOMINGUES, Getúlio Fonseca; RIBEIRO, Carlos Antonio Alvares Soares; ROSA, Alexandre Rosa dos Santos. Pagamento por serviços ambientais e práticas conservacionistas do solo: estudo de caso em uma propriedade rural inserida na sub-bacia hidrográfica do rio turvo-mg. **Ciência Florestal**, SciELO Brasil, v. 35, p. e85863, 2025. 72

SINGHAL, Yash; JAIN, Ayushi; BATRA, Shrey; VARSHNEY, Yash; RATHI, Megha. Review of bagging and boosting classification performance on unbalanced binary classification. *In*: IEEE. **2018 IEEE 8th International Advance Computing Conference (IACC)**. [S.l.], 2018. p. 338–343. 48

Souza Júnior, Carlos M.; SHIMBO, Julia Z.; ROSA, Marcos R.; PARENTE, Leandro L.; ALENCAR, Ane A.; RUDORFF, Bernardo F. T.; HASENACK, Heinrich; MATSUMOTO, Marcelo; FERREIRA, Laerte G.; SOUZA-FILHO, Pedro W. M.; OLIVEIRA, Sergio W. de; ROCHA, Washington F.; FONSECA, Antônio V.; MARQUES, Camila B.; DINIZ, Cesar G.; COSTA, Diego; MONTEIRO, Dyeden; ROSA, Eduardo R.; VéLEZ-MARTIN, Eduardo; WEBER, Eliseu J.; LENTI, Felipe E. B.; PATERNOST, Fernando F.; PAREYN, Frans G. C.; SIQUEIRA, João V.; VIERA, José L.; NETO, Luiz C. Ferreira; SARAIVA, Marciano M.; SALES, Marcio H.; SALGADO, Moises P. G.; VASCONCELOS, Rodrigo; GALANO, Soltan; MESQUITA, Vinicius V.; AZEVEDO, Tasso. Reconstructing three decades of land use and land cover changes in brazilian biomes with landsat archive and earth engine. **Remote Sensing**, v. 12, n. 17, 2020. ISSN 2072-4292. Disponível em: https://www.mdpi.com/2072-4292/12/17/2735. 33, 44, 50, 55

UHE, Peter; LUCAS, Chris; HAWKER, Laurence; BRINE, Malcolm; WILKINSON, Hamish; COOPER, Anthony; SAOULIS, Alex A; SAVAGE, James; SAMPSON, Christopher. Fathomdem: an improved global terrain map using a hybrid vision transformer model. **Environmental Research Letters**, IOP Publishing, v. 20,

n. 3, p. 034002, feb 2025. Disponível em: https://doi.org/10.1088/1748-9326/ada972. 24, 55, 76

United Nations. General Assembly, **Transforming our world: the 2030 Agenda for Sustainable Development**. 2015. 16301 p. Disponível em: https://sdgs.un.org/2030agenda. 13, 29

VALAVI, Roozbeh; ELITH, Jane; LAHOZ-MONFORT, José J.; GUILLERA-ARROITA, Gurutzeta. blockcv: An r package for generating spatially or environmentally separated folds for k-fold cross-validation of species distribution models. **Methods in Ecology and Evolution**, v. 10, n. 2, p. 225–232, 2019. 58

VALENTIN, Christian; POESEN, Jean; LI, Yong. Gully erosion: Impacts, factors and control. **Catena**, Elsevier, v. 63, n. 2-3, p. 132–153, 2005. 29, 43

WILSON, John; GALLANT, John. soil. *In*: _____. [S.l.: s.n.], 2000. v. 479, p. 1–27. 70

WRIGHT, Marvin N; WAGER, Stefan; PROBST, Philipp. Ranger: A fast implementation of random forests. **R package version 0.12**, v. 1, 2020. 33, 57

ZHANG, Xingyi; QI, Jiarui; XU, Jinzhong; ZHOU, Pengchong; CHEN, Zhuoxin; WANG, Lixin; GUO, Mingming. Root distribution and soil properties of gully heads and their effects on headcut migration in the mollisols region of northeast china. **Land**, MDPI, v. 11, n. 2, p. 184, 2022. 71

ZIJL, George M Van; ELLIS, Freddie; ROZANOV, Andrei. Understanding the combined effect of soil properties on gully erosion using quantile regression. **South African Journal of Plant and Soil**, Taylor & Francis, v. 31, n. 3, p. 163–172, 2014. 71

ZURELL, Damaris; FRANKLIN, Janet; KöNIG, Christian; BOUCHET, Phil J.; DORMANN, Carsten F.; ELITH, Jane; FANDOS, Guillermo; FENG, Xiao; GUILLERA-ARROITA, Gurutzeta; GUISAN, Antoine; LAHOZ-MONFORT, José J.; LEITãO, Pedro J.; PARK, Daniel S.; PETERSON, A. Townsend; RAPACCIUOLO, Giovanni; SCHMATZ, Dirk R.; SCHRöDER, Boris; SERRA-DIAZ, Josep M.; THUILLER, Wilfried; YATES, Katherine L.; ZIMMERMANN, Niklaus E.; MEROW, Cory. A standard protocol for reporting species distribution models. **Ecography**, v. 43, n. 9, p. 1261–1277, 2020. Disponível em: https://nsojournals.onlinelibrary.wiley.com/doi/abs/10.1111/ecog.04960. 54