



UNIVERSIDADE DE BRASÍLIA
INSTITUTO DE CIÊNCIAS HUMANAS
DEPARTAMENTO DE GEOGRAFIA
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA

**MAPEAMENTO DE ÁREAS SUSCEPTÍVEIS AOS PROCESSOS EROSIVOS A
PARTIR DA APLICAÇÃO DE ALGORITMOS DE APRENDIZAGEM DE MÁQUINA,
UTILIZANDO ÍNDICES MORFOMÉTRICOS**

Argélia Saiaka Luiz

Orientador Prof. Dr. Renato Fontes Guimarães

Co-orientadora: Potira Hermuche

Brasília, abril de 2024

UNIVERSIDADE DE BRASÍLIA
INSTITUTO DE CIÊNCIAS HUMANAS
DEPARTAMENTO DE GEOGRAFIA
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA

**MAPEAMENTO DE ÁREAS SUSCEPTÍVEIS AOS PROCESSOS EROSIVOS A
PARTIR DA APLICAÇÃO DE ALGORITMOS DE APRENDIZAGEM DE MÁQUINA,
UTILIZANDO ÍNDICES MORFOMÉTRICOS**

Argélia Saiaka Luiz

Orientador Prof. Dr. Renato Fontes Guimarães

Co-orientadora: Potira Hermuche

Tese de doutorado
apresentada ao Departamento
de Geografia da Universidade
de Brasília como requisito para
a obtenção do título de
Doutora em Geografia.

Brasília, abril de 2024

FICHA CATALOGRÁFICA

LUIZ, ARGÉLICA SAIKA

MAPEAMENTO DE ÁREAS SUSCEPTÍVEIS AOS PROCESSOS EROSIVOS A PARTIR DA APLICAÇÃO DE ALGORITMOS DE APRENDIZAGEM DE MÁQUINA, UTILIZANDO ÍNDICES MORFOMÉTRICOS. 113 páginas.

Tese de doutorado – Departamento de Geografia, Instituto de Ciências Humanas - Universidade de Brasília – UnB, 2023.

1. Processos erosivos lineares; - 2. *Forest Based*;

É concedida à Universidade de Brasília permissão para reproduzir cópias desta monografia e emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. A autora reserva outros direitos de publicação e nenhuma parte desta tese pode ser reproduzida sem a autorização por escrito da autora.

Argélica Saiaka Luiz

Abril de 2024

UNIVERSIDADE DE BRASÍLIA
INSTITUTO DE CIÊNCIAS HUMANAS
DEPARTAMENTO DE GEOGRAFIA
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA

**MAPEAMENTO DE ÁREAS SUSCEPTÍVEIS AOS PROCESSOS EROSIVOS A
PARTIR DA APLICAÇÃO DE ALGORITMOS DE APRENDIZAGEM DE MÁQUINA,
UTILIZANDO ÍNDICES MORFOMÉTRICOS**

Argélia Saiaka Luiz

Tese de doutorado apresentada ao Departamento de Geografia da Universidade de Brasília
como requisito para a obtenção do título de doutora em Geografia

Aprovado por:

Prof. Dr. Renato Fontes Guimarães
(Orientador)

Prof. Dr. Antônio Jose Teixeira Guerra
(Membro externo)

Prof. Dr. Leonardo Jose Cordeiro Santos
(Membro externo)

Prof. Dr. Edilson De Souza Bias
(Membro externo)

Brasília-DF, abril de 2024

SUMÁRIO

1. INTRODUÇÃO	1
2. REFERENCIAL TEÓRICO	3
2.1. Processos erosivos	3
2.2. Índices morfométricos no estudo de processos erosivos	8
2.3. Identificação de áreas úmidas como subsídio ao mapeamento de processos erosivos lineares	14
2.4. Algoritmos de aprendizado de máquina	16
3. MATERIAL E MÉTODOS	20
3.1. Área de estudo	20
3.2. Etapas metodológicas	26
3.3. Elaboração e tratamento do modelo digital	26
3.4. Definição dos parâmetros para os mapeamentos	29
3.5. Parâmetros que definem áreas úmidas	31
3.6. Mapeamento das áreas úmidas e áreas susceptíveis a processos erosivos lineares	31
3.7. Validação do modelo	41
4. RESULTADOS E DISCUSSÃO	44
4.1. Mapeamento das áreas úmidas	44
4.2. Mapeamento dos processos erosivos	48
4.3. Mapeamento dos processos erosivos lineares inserindo parâmetros das áreas úmidas	55
4.4. Mapeamento de áreas susceptíveis ao desenvolvimento de processos erosivos na área teste com resolução de 0,5 metros	59
4.5. Mapeamento de áreas susceptíveis ao desenvolvimento de processos erosivos em toda a área urbana no Distrito Federal	62
5. DISCUSSÃO	66
6. CONCLUSÃO	68
7. REFERÊNCIAS BIBLIOGRÁFICAS	70

LISTA DE FIGURAS

Figura 1 – Exemplos de processos erosivos lineares no Distrito Federal. O shapefile em vermelho são os processos mapeados por meio de interpretação visual. Os pontos A, B e C representam processos localizados próximos ao perímetro urbano e a vias pavimentadas.	6
Figura 2 - Esquema dos conceitos de Modelos Digitais de Terreno e de Superfície.	9
Figura 3 - Modo de funcionamento do <i>Random Forest</i> . Fonte: ESRI, 2023.	18
Figura 4 – Modo de funcionamento do <i>Gradient Boosting</i> . Fonte: ESRI, 2023.	19
Figura 5 - Área referente ao aerolevantamento realizado em 2016 pela Companhia Imobiliária de Brasília (Terracap). Fonte: GEOPORTAL, 2023.	21
Figura 6 – Mapa Pedológico do Distrito Federal. Fonte: Sistema de Informações Ambientais – SISDIA (2024).	23
Figura 7 – Mapa de localização da área teste.	25
Figura 8 – Fluxograma geral de processamento dos dados.	26
Figura 9 - Comparação do esquema de funcionamento do filtro Perona-Malik com uma filtragem Gaussiana. (a) dados originais; (b;c) filtragem Gaussiana; (d;e) filtragem Perona-Malik. Fonte: Passalacqua, 2015.	28
Figura 10 – MDT original (A) e MDT filtrado (B).	29
Figura 11 – Gráficos de perfil do relevo referente ao MDT original e após a filtragem utilizando o Filtro Perona Malik (PM).	29
Figura 12 - Gráfico da frequência de uso das variáveis nos trabalhos pesquisados.	30
Figura 13 – Treinamento a partir de pontos dentro da área ou cicatriz (A) e a partir de uma média/mediana (B).	32
Figura 14 – Amostras mapeadas com geometria de polígonos convertida em pontos para o treinamento dos algoritmos <i>Gradient Boosting</i> e <i>Forest Based</i>	33
Figura 15 – Exemplo de amostras para treinamento de áreas úmidas e áreas não úmidas.	34
Figura 16 – Exemplo de amostras do que representa processos erosivos lineares e o que não representa.	35
Figura 17 – Fluxograma de processamento dos testes para elaboração do mapeamento das áreas úmidas e dos processos erosivos lineares.	38
Figura 18 – Parâmetros gerados a partir de MDT com resolução de 3 metros – Curvatura em planta, TWI e DTW.	39
Figura 19 - Parâmetros gerados a partir de MDT com resolução de 3 metros - curvatura tangente (Tang_C), fluxo acumulado (FA), TPI, CTIN, TRI, LS e P.	40
Figura 20 – Detalhe da comparação entre os algoritmos FB e GB, sem a aplicação do filtro Perona Malik e com a aplicação do filtro no MDT.	48
Figura 21 – Localização do exemplo na área teste.	49
Figura 22 – Evolução temporal de um processo erosivo linear entre os anos de 1975 e 2016.	49
Figura 23 – Análise do Fator P na área exemplificada.	50
Figura 24 – Detalhe da comparação entre os algoritmos FB (A e C) e GB (B e D), com e sem a aplicação do filtro Perona Malik no MDT para predição de áreas suscetíveis ao desenvolvimento de processos erosivos lineares (áreas escuras).	55
Figura 25 – Exemplo de processo erosivo linear que tem início fora de uma área úmida e se desenvolve para seu interior.	56
Figura 26 – Detalhe da comparação entre o mapeamento com e sem a inserção dos parâmetros de áreas úmidas, considerando apenas o algoritmo GB, com aplicação do filtro PM.	58

Figura 27 - Comparação entre os dados processados com base no MDT com resolução de 3 metros (A) e 0,5 metros (B).	60
Figura 28 – Fluxograma de crescimento da acurácia nas etapas de processamento no mapeamento das áreas suscetíveis à processos erosivos lineares.	61
Figura 29 – Gráfico dos valores de F1 e Acurácia dos diversos níveis de processamento.	61
Figura 30 - Variáveis de mapeamento das áreas úmidas a partir de MDT com resolução de 1 metro e filtro Perona Malik: (A) Curvatura em planta; (B) TWI; (C) DTW; (D) Abrangência da área.	63
Figura 31 - Parâmetros gerados a partir de MDT com resolução de 1 metro e filtro Perona Malik (A) Curvatura tangente; (B) TRI; (C) Fluxo acumulado; (D) LS; (E) TPI; (F) P; (G) CTIN; (H) Abrangência da área.	64
Figura 32 – Mapa de previsão de áreas susceptíveis a processos erosivos lineares da área urbana do Distrito Federal.	65

LISTA DE TABELAS

Tabela 1 – Exemplo da importância das variáveis no modelo de acordo com o índice de Gini.	41
Tabela 2 – Exemplo de diagnóstico dos parâmetros utilizados.	42
Tabela 3 – Exemplo de resultado estatístico do modelo.	43
Tabela 4 – Importância de cada variável nos modelos	44
Tabela 5 – Diagnóstico dos parâmetros utilizados na aplicação do algoritmo Forest-Based sem aplicação do filtro Perona Malik.	45
Tabela 6 – Diagnóstico dos parâmetros utilizados na aplicação do algoritmo Forest-Based com aplicação do filtro Perona Malik.	45
Tabela 7 – Diagnóstico dos parâmetros utilizados na aplicação do algoritmo Gradient Boosting sem aplicação do filtro Perona Malik.	45
Tabela 8 – Diagnóstico dos parâmetros utilizados na aplicação do algoritmo Gradient Boosting com aplicação do filtro Perona Malik.	45
Tabela 9 – Estatísticas do processamento da Área Úmida utilizando o algoritmo <i>Forest Based</i> no MDT original (treinamento)	46
Tabela 10 – Estatísticas do processamento da Área Úmida utilizando o algoritmo <i>Forest Based</i> no MDT original (validação).	46
Tabela 11 – Estatísticas do processamento da Área Úmida utilizando o algoritmo <i>Forest Based</i> no MDT com filtro Perona Malik (validação).	47
Tabela 12 - Estatísticas do processamento da Área Úmida utilizando o algoritmo <i>Gradient Boosting</i> no MDT sem filtro Perona Malik (validação).	47
Tabela 13 – Estatísticas do processamento da Área Úmida utilizando o algoritmo <i>Gradient Boosting</i> no MDT com filtro Perona Malik (validação).	47
Tabela 14 – Síntese comparativa das estatísticas geradas com utilização do FB e GB para o mapeamento das Áreas Úmidas no MDT com aplicação do filtro Perona Malik.	48
Tabela 15 - Importância de cada variável nos modelos.	51
Tabela 16 – Diagnóstico dos parâmetros utilizados na aplicação do algoritmo <i>Forest Based</i> sem considerar o filtro Perona Malik.	52
Tabela 17 - Diagnóstico dos parâmetros utilizados na utilização do algoritmo <i>Forest Based</i> com aplicação do filtro Perona Malik.	52
Tabela 18 - Diagnóstico dos parâmetros utilizados na utilização do algoritmo <i>Gradient Boosting</i> sem aplicação do filtro Perona Malik.	52
Tabela 19 - Diagnóstico dos parâmetros utilizados na utilização do algoritmo <i>Gradient Boosting</i> com aplicação do filtro Perona Malik.	53
Tabela 20 - Estatísticas do processamento das áreas suscetíveis a processos erosivos lineares utilizando o algoritmo <i>Forest Based</i> no MDT sem filtro Perona Malik (treinamento).	54
Tabela 21 - Estatísticas do processamento das áreas suscetíveis a processos erosivos lineares utilizando o algoritmo <i>Forest Based</i> no MDT sem filtro Perona Malik (validação).	54
Tabela 22 - Estatísticas do processamento das áreas suscetíveis a processos erosivos lineares utilizando o algoritmo <i>Forest Based</i> no MDT com o filtro Perona Malik (treinamento).	54
Tabela 23 - Estatísticas do processamento das áreas suscetíveis a processos erosivos lineares utilizando o algoritmo <i>Forest Based</i> no MDT com o filtro Perona Malik (validação).	54
Tabela 24 - Estatísticas do processamento das áreas suscetíveis a processos erosivos lineares utilizando o algoritmo <i>Gradiente Boosting</i> no MDT sem filtro Perona Malik (treinamento).	54

Tabela 25 - Estatísticas do processamento das áreas suscetíveis a processos erosivos lineares utilizando o algoritmo <i>Gradiente Boosting</i> no MDT sem filtro Perona Malik (validação).	54
Tabela 26 - Estatísticas do processamento das áreas suscetíveis a processos erosivos lineares utilizando o algoritmo <i>Gradiente Boosting</i> no MDT com filtro Perona Malik (treinamento).	54
Tabela 27 - Estatísticas do processamento das áreas suscetíveis a processos erosivos lineares utilizando o algoritmo <i>Gradiente Boosting</i> no MDT com filtro Perona Malik (validação).	54
Tabela 28 – Estatísticas dos dados de validação para o teste utilizando os parâmetros de áreas úmidas.	57
Tabela 29 – Comparação entre as estatísticas do mapeamento com e sem a inserção dos parâmetros de áreas úmidas, considerando o algoritmo GB com aplicação do filtro PM.	57
Tabela 30 – Percentual de pixels classificados como classe 1 (processos erosivos lineares) e resultado estatístico <i>do F1 Score</i>	59
Tabela 31 – Estatísticas dos dados de validação no mapeamento das áreas suscetíveis a processos erosivos lineares com utilização do MDT com resolução de 0,5m, aplicando o filtro PM e o algoritmo GB.	60

LISTA DE ABREVIATURAS E SIGLAS

AM - Aprendizado de Máquina
ANN - *Artificial Neural Networks*
CTI - *Composite Topographic Index*
CTIN - *Normalized Composite Topographic Index*
DF - Distrito Federal
DTW – *Depth to Water index*
FA - Fluxo Acumulado
FP – Falso Positivo
GB - *Gradient Boosting*
GDF - Governo do Distrito Federal
IUT - Índice de Umidade Topográfica
LiDAR - *Ligth Detection and Ranging*
LS - *Length Slope fator*
MDS - Modelo Digital de Superfície
MDT - Modelo Digital de terreno
NDVI - *Normalized Difference Vegetation Index*
PC – *Plant Curvature*
PM - Perona Malik
RF - *Random Forest*
RMSE - *Root Mean Square Error*
SIG - Sistemas de Informações Geográficas
SISDIA - Sistema de Informações Ambientais
SRTM - *Shuttle Radar Topography Mission*
SVM - *Support Vector Machines*
TANG_C - Curvatura Tangente
TPI - *Topographic Position Index*
TRI - *Terrain Ruggedness Index*
TWI - *Topographic Wetness Index*
VP - Verdadeiro Positivo

RESUMO

Os processos erosivos são fenômenos naturais que causam a remoção e o transporte de solo, tendo como fatores naturais o clima, o relevo, a vegetação, a geologia e o solo. No entanto, a interferência humana tem contribuído significativamente na intensificação desses fenômenos. Em particular nas cidades, o processo de urbanização altera o comportamento do escoamento superficial devido a convergência do fluxo d'água e da impermeabilização do solo causada pela implantação de estruturas urbanas. Nesse contexto, o presente trabalho tem como objetivo delimitar as áreas susceptíveis a ocorrência de processos erosivos, nas áreas urbanas do Distrito Federal, a partir de parâmetros morfométricos, derivados de um Modelo Digital de Terreno (MDT) na escala de detalhe, utilizados na modelagem de algoritmos de aprendizado de máquina. A metodologia foi dividida nas seguintes etapas: a) obtenção e definição dos parâmetros morfométricos; b) mapeamento de feições ocasionadas pelos processos erosivos; c) treinamento de amostras; d) aplicação dos modelos de aprendizado de máquina (*Forest Based* e *Gradiente Boosting*), e) validação. Os resultados obtidos demonstram que os modelos utilizados apresentam eficácia em relação à predição. Ambos os modelos tiveram melhor desempenho quando foi acrescentado os parâmetros que definem as áreas úmidas. Na comparação dos resultados, o modelo *Gradient Boosting* obteve maior grau de acerto, delimitando uma área susceptível menor, além de ter maior velocidade de processamento. O mapeamento obtido fornece uma visão holística das áreas de vulnerabilidade, servindo de subsídio para orientar as tomadas de decisão no planejamento urbano, prevenindo prejuízos sociais e econômicos.

Palavras-chave: Aprendizagem de Máquina, *Gradient Boosting*, Área úmida, Processos erosivos lineares.

ABSTRACT

Erosive processes are natural phenomena that cause the removal and transportation of soil, with climate, topography, vegetation, geology, and soil being the natural factors involved. However, human interference contributes significantly to the intensification of these phenomena. In the cities, the urbanization process changes the behavior of surface runoff due to the convergence of water flow and soil waterproofing caused by the implementation of urban structures. In this context, the present work aims to delimit the areas susceptible to the occurrence of erosive processes, in the urban areas of the Federal District, based on morphometric parameters, derived from a Digital Terrain Model (MDT) at the detail scale, using modeling of machine learning algorithms. The methodology was divided into the following steps: a) Obtaining and defining morphometric parameters; b) mapping of features caused by erosion processes; c) training; d) application of two supervised Machine learning methods, Forest Based, and Gradient Boosting), e) validation. The results demonstrate that the models are effective in relation to prediction. Both models performed better when included parameters that define wetlands. When comparing the results, the Gradient Boosting method achieved a greater degree of accuracy, even delimiting a smaller susceptible area, with faster processing. The mapping obtained provides a holistic view of vulnerable areas, serving as a basis to guide decision-making in urban planning, preventing social and economic losses.

Keywords: Machine Learning, Gradient Boosting, Wetland, Gullies

1. INTRODUÇÃO

A formação de processos erosivos, tanto no meio rural quanto no urbano, é um fenômeno complexo que resulta da interação de diversos fatores naturais e antropogênicos. No meio rural, a erosão do solo é frequentemente causada pela remoção da cobertura vegetal, seja através do desmatamento para a agricultura ou da exploração inadequada dos recursos naturais (CASTILLO E GÓMEZ, 2016). Já no meio urbano, a impermeabilização do solo devido à expansão urbana descontrolada, o excesso de pavimentação e a remoção de vegetação são alguns dos principais fatores que intensificam os processos erosivos (MARÇAL, 2003; ARABAMERI *et al.*, 2020).

O processo de implementação ou ampliação das manchas urbanas ocasiona um aumento da impermeabilização do solo, que pode ser parcial ou total, resultando na dificuldade de infiltração da água da chuva e, conseqüentemente, um aumento do escoamento superficial concentrado nas vias e nos sistemas de drenagem. Além disso, esse processo pode alterar a superfície topográfica da área, modificando a dinâmica hidrológica com o desenvolvimento de processos de concentração de fluxos (ODEMERHO E SADA, 1984; KERTZAMN *et al.*, 1995; BURKARD E KOSTASCHUK, 1997; ARCHIBOLD *et al.*, 2003; CARVALHO JUNIOR *et al.*, 2010; LIMA E FERNANDES, 2020).

Como os ambientes urbanos são, em sua maioria, impermeabilizados, existe uma tendência dos fluxos de água, das chuvas principalmente, serem canalizados para as vias e sistemas de águas pluviais, fazendo com que a não dissipação desses possibilite o aumento de sua velocidade e conseqüente ampliação do potencial erosivo (BOUCHNAK *et al.*, 2009; ADEDIJI *et al.*, 2013). No caso desses processos se desenvolverem rapidamente, existe a possibilidade de risco à população e prejuízos financeiros com a perda de infraestrutura já implementada (BERTHIER *et al.*, 2004; BIGARELLA *et al.*, 2007; CUNHA E GUERRA, 2010; GUERRA *et al.*, 2020; KOCAMAN *et al.*, 2020).

Após o processo erosivo consolidado, os sedimentos podem ser carregados pelo escoamento superficial até corpos hídricos podendo comprometer a qualidade da água e quase sempre desencadear impactos negativos para o funcionamento hidrológico das bacias hidrográficas (MENESES *et al.*, 2015; GUERRA *et al.*, 2023).

Deste modo, é de fundamental importância desenvolver procedimentos que identifiquem as áreas susceptíveis à ocorrência dos processos erosivos resultantes de alterações antrópicas na morfologia do terreno ou, de processos naturais, principalmente em áreas urbanas ou próximo a elas. A modelagem matemática, a partir de modelos hidrológicamente consistidos, tem contribuído para o desenvolvimento de metodologias de identificação (YANG *et al.*, 2019; WU E CHEN, 2020; GHOLAMI *et al.*, 2021).

Corroborando isso, modelos digitais que caracterizam a superfície topográfica e a superfície das estruturas urbanas têm tido um avanço em seu detalhamento e precisão. Este tipo de modelagem, em conjunto com os Sistemas de Informação Geográfica (SIG), tem possibilitado o desenvolvimento de produtos que auxiliam não somente na identificação das áreas mais susceptíveis a estes processos, mas também na identificação de quais áreas possuem o maior grau de susceptibilidade para sua ocorrência (PASSO, 2017; DIETRICH *et al.*, 1993; MONTGOMERY E DIETRICH, 1994; GUIMARÃES *et al.*, 2003; CARVALHO JUNIOR *et al.*, 2010; ALBUQUERQUE *et al.*, 2020, TREPEKLI *et al.*, 2022; RECLA E SCHIMITT, 2024).

Deste modo, o objetivo dessa pesquisa é definir as áreas susceptíveis a ocorrência de processo erosivos, nas áreas urbanas e periurbanas, que se encontram numa posição de transição entre espaços estritamente rurais e áreas urbanas, do Distrito Federal, a partir de parâmetros morfométricos, derivados de um Modelo Digital de Terreno (MDT) na escala de detalhe, utilizando algoritmos de aprendizagem de máquina.

Como objetivos específicos têm-se:

- - Identificar as áreas úmidas como subsídio ao mapeamento das áreas susceptíveis a ocorrência de processos erosivos lineares;

- - Identificar os índices morfométricos de maior importância para entrada nos modelos;
- - Aplicação e comparação de resultados entre os métodos de aprendizagem de máquina *Forest Based* e *Gradient Boosting*.

2. REFERENCIAL TEÓRICO

2.1. Processos erosivos

O ciclo hidrológico envolve a movimentação contínua da água sobre e abaixo da superfície terrestre, desempenhando um papel crucial na manutenção dos ecossistemas e na disponibilidade de recursos hídricos. Dentro desse ciclo, a água pode se mover de várias formas, incluindo o escoamento superficial, subsuperficial e subterrâneo e cada um desses processos tem características e impactos distintos no meio ambiente e na sociedade (XIE *et al.*, 2003; FURMAN, 2008; POISSON *et al.*, 2019).

De acordo com Guerra e Jorge (2012), Li *et al.* (2015) e Kuffour *et al.* (2020), o escoamento superficial ocorre quando a água da chuva não é absorvida pelo solo e flui sobre a superfície terrestre, sofrendo influência da intensidade da precipitação, permeabilidade do solo, cobertura vegetal e topografia do terreno (GUERRA, 1990). O escoamento subsuperficial refere-se ao movimento da água que infiltra no solo e se desloca através da zona não saturada, ocorrendo de forma menos visível e em ritmos mais lentos. Por fim, o escoamento subterrâneo envolve o movimento da água através da zona saturada do solo, essencial para a recarga de lençóis freáticos e abastecimento de água para poços e nascentes.

Nesse sentido, o escoamento superficial contribui diretamente para a erosão do solo, removendo a camada superficial em áreas com pouca vegetação e alta precipitação (MA *et al.*, 2023). O escoamento subsuperficial pode causar erosão interna, enfraquecendo o solo e levando a deslizamentos. Já o escoamento subterrâneo afeta a estabilidade do solo e rochas, influenciando a formação de cavernas e sumidouros (SILVA *et al.*, 2019).

Entende-se erosão como todo processo de desgaste da superfície do terreno que acarrete a remoção, transporte e depósito de solo por meio de agentes como a água e vento (DREGNE, 1987; NEARING *et al.*, 1990; LAL, 2001; GUERRA, 2003; BIGARELLA, *et al.*, 2007; WU E CHEN, 2020; HITOURI *et al.*, 2022; LANA, 2023).

A erosão é um importante processo natural de modelamento do relevo que atua em quase toda a superfície terrestre, sendo a água um dos principais agentes deflagradores, como agente desagregador e de transporte das partículas do solo (WILLIAMS, 1990; LAL, 1998; GUERRA, 2011), podendo ser acelerada devido à ação antrópica associada à processos de desmatamento e cultivo inadequados e/ou implementação de estrutura urbana sem o devido planejamento (POLOVINA *et al.*, 2021; REHM *et al.*, 2021; MOISA *et al.*, 2022; FONSECA *et al.*, 2022).

O processo de urbanização de uma área causa o aumento de superfícies impermeáveis, como estradas pavimentadas, casas/edifícios e estacionamentos, que reduzem a infiltração de água da chuva e aumentam o escoamento superficial (GURNELL *et al.*, 2007; TANIGUCHI *et al.*, 2018), alterando o sistema hidrológico de diferentes maneiras, como: (1) modificando a rede de drenagem; (2) diminuindo a recarga das águas subterrâneas; (3) diminuindo o intervalo de latência entre o início da precipitação e os picos mais altos do escoamento; (4) aumentando o volume total de fluxo do sistema de águas pluviais e; (5) diminuindo o tempo médio de permanência do fluxo no sistema (RAN *et al.*, 2018; WU *et al.*, 2023). Deste modo, a concentração de escoamento num curto espaço de tempo e em áreas concentradas a partir do processo de impermeabilização é um dos fatores que pode acelerar os processos erosivos nas áreas urbanas (PALIAGA *et al.*, 2019; SESTRAS *et al.*, 2021).

Nesse contexto, é importante enfatizar o papel das bacias hidrográficas, que consistem em áreas delimitadas por divisores de água, nas quais toda a precipitação se acumula e drena para um único ponto de saída, o exutório. Assim, a forma de uma bacia hidrográfica influencia o comportamento hidrológico, incluindo a velocidade e o volume de escoamento, podendo

apresentar diferentes configurações, cada uma com características distintas que influenciam nessa dinâmica (GREGORY, 1976).

Devido ao tempo de concentração menor nas bacias arredondadas, onde a água de todas as partes chega ao ponto de saída quase simultaneamente, o risco de erosão na drenagem principal é maior (TREMARIN *et al.*, 2010). Já as bacias de formato elíptico concentram a água por um período mais longo, uma vez que a água das extremidades mais distantes leva mais tempo para alcançar o ponto de saída, resultando em um escoamento mais distribuído ao longo do tempo (MACEDO *et al.*, 2019). As bacias com padrão radial e ramificado, formadas por sub bacias que convergem a água para o curso principal das bacias, geram o escoamento concentrado e rápido, o que pode aumentar o potencial erosivo em bacias com esse formato (SILVA *et al.*, 2019).

Além disso, a erosão hídrica pode ocorrer basicamente de duas maneiras: erosão laminar e erosão linear. A erosão laminar é aquela em formato de lençol, em que as partículas soltas do solo são removidas por meio de uma lâmina na superfície. Esta erosão ocorre de forma muito homogênea, normalmente, e especialmente em grandes áreas agrícolas, tendo como principal consequência o empobrecimento do solo devido à retirada de nutrientes. Já a erosão linear se caracteriza pela concentração de fluxo e aumento da profundidade do fluxo da água que pode ocasionar a formação de canais de escoamento caracterizados por sulcos, ravinas e voçorocas (PIZZUTO E MECKELNBURG, 1989; DUBE *et al.*, 2020)

O regime pluviométrico sazonal característico na região do Distrito Federal (DF) faz com que este processo mereça procedimentos de monitoramento, uma vez que possui grandes concentrações no período de verão, em locais específicos, podendo atingir alta intensidade em um curto espaço de tempo (somados ao uso e cobertura da terra e às características dos solos). Esta combinação faz com que ocorra uma sobrecarga no sistema de águas pluviais, que poderá ocasionar uma concentração de fluxo de água, resultando na deflagração de processos erosivos lineares, como ilustra a Figura 1.




Figura 1 – Exemplos de processos erosivos lineares no Distrito Federal. O shapefile em vermelho são os processos mapeados por meio de interpretação visual. Os pontos A, B e C representam processos localizados próximos ao perímetro urbano e a vias pavimentadas.

Esse processo é intensificado em áreas com declives acentuados, onde a água pode adquirir maior velocidade e energia, aumentando sua capacidade de entalhamento. Fatores como intensidade e duração da chuva, capacidade de infiltração do solo e existência de vegetação influenciam na formação desse tipo de erosão (DUBE *et al.*,2020; MOHAMMED *et al.*,2020).

Assim, a cobertura vegetal é importante fator de proteção contra os processos erosivos de várias maneiras: por meio de retenção da água, proteção contra ação direta da chuva, redução da velocidade do vento,

melhoria da estrutura do solo, estabilização de encostas e produção de matéria orgânica (PREITI *et al.*,2022).

Segundo Jeong e Dorn (2019) e Zhang *et al.* (2021), a erosão linear pode ser agravada pelo desmatamento, processo de urbanização, construção de estradas e práticas agrícolas tradicionais, que não utilizam ou aplicam as técnicas conservacionistas, que aumentam a taxa de escoamento superficial e diminuem a capacidade de retenção de água pelo solo. O vento pode transportar partículas de solo e sedimentos causando a erosão das superfícies expostas, o que ocorre geralmente em regiões de áreas secas e áridas com baixo índice pluviométrico e solos pouco coesos (JARRAH *et al.*,2020).

Desse modo, a gravidade e a ação antrópica desempenham influência direta nos processos erosivos. A primeira influencia principalmente nas encostas íngremes, enquanto a segunda se desencadeia de diversas maneiras, como pelo processo de urbanização, agricultura intensiva, mineração e desmatamento (MERRITT *et al.*, 2003; BORRELLI *et al.*,2020; BORRELLI *et al.*,2021; MHASKE *et al.*,2021).

No que diz respeito aos solos, a sua natureza tem atuação direta nos processos de suscetibilidade à erosão. Solos arenosos, com partículas maiores, são mais suscetíveis à erosão devido à sua capacidade de infiltração, que facilita o arraste de partículas soltas. Entretanto, solos com alta permeabilidade permitem que a água se infiltre rapidamente, diminuindo a quantidade disponível na superfície e reduzindo o escoamento superficial (PREITI *et al.*,2022).

Segundo Dur *et al.* (2022), a erosão do solo é um problema ambiental significativo que afeta a produtividade agrícola, a qualidade da água, as infraestruturas urbanas e causa impactos socioambientais. Para mitigar os impactos da erosão e preservar a integridade do solo, diversas práticas conservacionistas são implementadas em todo o mundo, visando reduzir a velocidade de escoamento da água, aumentar a infiltração no solo e proteger a superfície do solo contra o impacto direto das chuvas (BIAS *et al.*, 2012).

Alguns exemplos podem ser citados, como: (a) o terraceamento, que consiste em terraços construídos em terrenos inclinados para diminuir o

escoamento superficial e promover a infiltração de água, sendo eficaz em áreas montanhosas e encostas íngremes (MARIA E FILHO, 2007); (b) a técnica de cobertura vegetal, que envolve plantar culturas de cobertura que protegem o solo (SHARMA *et al.*, 2018); (c) as faixas de vegetação permanente, que são áreas ao longo das margens dos campos agrícolas, atuando como barreiras para sedimentos e reduzindo o escoamento (FILIZOLA *et al.*, 2008a); (d) as barragens de retenção, que capturam e armazenam água de escoamento, permitindo infiltração lenta no solo, controlando a erosão e recarregando aquíferos (HINDERSHA *al.*, 2018) e; (e) a recuperação de áreas degradadas, que inclui a revegetação e estabilização de áreas erodidas, com o plantio de árvores e arbustos nativos, aplicação de cobertura morta e construção de terraços (YIRDAW *et al.*, 2017).

Deste modo, as práticas conservacionistas são essenciais para a preservação dos solos com o intuito de garantir a sustentabilidade agrícola e ambiental. A implementação dessas práticas, ajuda a proteger o solo contra a erosão, melhora a qualidade da água, aumenta a produtividade agrícola e conserva a biodiversidade (ADIMASSU *et al.*, 2017).

2.2. Índices morfométricos no estudo de processos erosivos

Entender os processos de mudanças morfológicas do terreno ajuda na compreensão e na identificação das áreas com maior concentração de fluxos. Nesse sentido, o desenvolvimento de metodologias para a construção de modelos numéricos do terreno que representem com maior acurácia as feições da superfície do terreno é fundamental para obtenção de parâmetros morfométricos.

Os modelos numéricos do terreno se dividem em: MDT – Modelo Digital de Terreno, que é uma projeção gráfica de computador tridimensional de dados de elevação usadas para representar a superfície do terreno (MITÁŠOVÁ E HOFIERKA, 1993) e; MDS – Modelo Digital de Superfície, que caracteriza a elevação das estruturas ou elementos dispostos sobre o terreno (SHARMA *et al.*, 2021) (Figura 2). Existem, ainda, outras denominações para os modelos que representam a superfície do terreno, MNE - Modelo Numérico de

Elevação e MDE – Modelo Digital de Elevação (BUARQUE *et al.*, 2008; MESA-MINGORANCE E ARIZA-LÓPEZ, 2020; GUTH *et al.*, 2021).




Figura 2 - Esquema dos conceitos de Modelos Digitais de Terreno e de Superfície.

Com a difusão do uso de modelos digitais e o aumento da qualidade desse parâmetro, os SIGs avançaram muito em relação aos estudos voltados para as ciências naturais (RUHOFF *et al.*, 2011), possibilitando a previsão e a compreensão de dinâmicas topográficas que alteram a paisagem (DIGIACOMO *et al.*, 2020; KOCAMAN *et al.*, 2020; BROŽOVÁ *et al.*, 2021; CONFORTI *et al.*, 2021; ZHANG *et al.*, 2021; TREPEKLI *et al.*, 2022) especialmente no que diz respeito à modelagem hidrológica, por meio de simulações de redes de fluxos e delimitação de bacias hidrográficas.

Nesse sentido, o desenvolvimento de métodos de mapeamento a laser possibilita mapear o relevo, de forma precisa, com resolução espacial centimétrica. Entretanto, esse grau de detalhamento pode acarretar o mapeamento de artefatos que não representam a superfície e/ou o terreno, como por exemplo, linhas de transmissão de energia. Desse modo, o desenvolvimento de modelos digitais hidrológicamente consistentes para caracterização de processos erosivos se torna essencial.

O LiDAR (*Ligth Detection and Ranging*) é um exemplo desse método e utiliza pulsos de luz a laser para medir a distância entre o sensor e qualquer objeto que compõe a superfície, medindo o tempo que um pulso de energia transmitida leva para retornar ao sensor, sendo calculada a distância entre o alvo e o sensor. A superfície é gerada a partir do cálculo dessas distâncias em

uma nuvem de pontos. Dependendo da frequência, o sinal emitido poderá penetrar na vegetação e atingir o solo, possibilitando o mapeamento da superfície sem a presença das árvores.

Após a aquisição da nuvem de pontos com as informações sobre a elevação é possível separar os objetos que compõem a superfície (como a vegetação, edificações, vias, corpos d'água, entre outros) por meio de classificação, filtrando o MDT (FILIN, 2001; WEINACKER *et al.*, 2004; YUNFEI *et al.*, 2008). Assim, em comparação com os sistemas tradicionais de levantamento e mapeamento, incluindo sistemas fotogramétricos, a tecnologia LiDAR oferece uma alternativa rápida e precisa para mapear grandes áreas em alta resolução (SHAN E SAMPATH, 2005; MENG *et al.*, 2009; MENG *et al.*, 2010).

Por definição, esses modelos são representações numéricas em que as áreas de escoamento superficial são priorizadas para melhor representação e sua correta definição. Dessa forma, alguns procedimentos matemáticos são necessários para que artefatos e/ou dados espúrios não sejam considerados na hora da modelagem, como demonstrados por (O'CALLAGHAN E MARK, 1984; MARTAZA E GARBRECHT, 1995; HELLWEGGER *et al.*, 1997; TURCOTTE *et al.*, 2001; LINDSAY E CREED, 2005).

Devido ao fato das pesquisas em torno da deposição e transporte de sedimentos para subsidiar a gestão urbana ganhar destaque com o uso de ferramentas de SIG como instrumento poderoso (EMTEHANI *et al.*, 2021; GHUNOWA; *et al.*, 2021; LEU *et al.*, 2021), os índices morfométricos calculados com base em MDT e MDS têm sido usados de maneira expressiva nas últimas três décadas para avaliar diferentes fenômenos da dinâmica terrestre em diferentes contextos geomorfológicos como os de Lima e Fernandes (2020), López-Tapia *et al.* (2021), Sur *et al.* (2022) e Bosino *et al.* (2022), que estudaram respectivamente fluxos de detritos, identificação de áreas úmidas e escorregamentos no Rio de Janeiro, Illinois e Himalayan, além de Rickenmann e Zimmermann (1993), Bovis e Jakob (1999), De Scally *et al.* (2001), Chen e Yu, (2011) e Rogelis e Werner (2014), que trabalharam com dinâmica de sedimentos, fluxo de detritos, avalanches de neve e mudanças topográficas na Itália, Suíça, Columbia Britânica, Taiwan e Bogotá.

Deste modo, a topografia e suas derivadas influenciam diretamente os fluxos de água, assumindo função essencial, já que condiciona esses fluxos de materiais e energia na paisagem (MOORE *et al.*, 1991) e controla a variação de umidade, degradação e os processos erosivos do solo (MOORE E BURCH, 1986; MOORE *et al.*, 1988).

Os índices morfométricos são divididos em dois grupos: primários e secundários. Os primeiros são compostos por características básicas como a declividade, aspecto (direção da vertente), curvatura do terreno e fluxo acumulado. Estes são parâmetros básicos para os estudos relacionados a processos erosivos derivados da urbanização e são amplamente utilizados (BEVEN E KIRKBY, 1979; O'LOUGHLIN, 1986; ZEVENBERGEN E THORNE, 1987; BEVEN *et al.*, 1993; MITÁŠOVÁ E HOFIERKA, 1993; MOORE *et al.*, 1993; MONTGOMERY, 1994; JUNGRIUS *et al.*, 2002; NYSSSEN *et al.*, 2002; SCHMIDT *et al.*, 2003; HENRIQUE *et al.*, 2013; IMWANGANA *et al.*, 2014; ALBUQUERQUE *et al.*, 2020; REHM *et al.*, 2021).

Os secundários são o resultado de cálculos feitos a partir da combinação de dois ou mais índices primários e possuem características mais complexas (BALOQUE E CAPOANE, 2021). Um dos principais índices secundários utilizados na análise de áreas urbanas é resultado da combinação da área de contribuição específica ortogonal com a linha de fluxo e a declividade, chamado de Índice de Umidade Topográfica (IUT) ou *Topographic Wetness Index* (TWI), que reproduz o escoamento superficial de um ponto e a declividade local (BEVEN E KIRBY, 1979). Este índice identifica áreas com acúmulo de água provisório ou permanente, representando a distribuição das zonas de saturação de água no solo e o balanço entre o acúmulo de água e condições de drenagem em escala local (LANG *et al.*, 2013; ALLAN, 2016; HU *et al.*, 2017; ASHIQ *et al.*, 2022).

O índice TWI (BEVEN E KIRKBY, 1979; O'LOUGHLIN, 1986), amplamente aplicado à saturação do solo, executa uma operação de divisão expressa por:

$$TWI = \ln(A/\tan S) \quad (\text{Equação 1})$$

Onde: A – área de contribuição; S – Declividade

O índice P indica a potência erosiva (intensidade do fluxo) ou a capacidade de incisão do escoamento (MOORE *et al.*, 1988), que estabelece uma relação multiplicativa definida como:

$$P = A \tan(S) \quad (\text{Equação 2})$$

O Índice de Profundidade da Água (*Depth to Water index* – DTW), desenvolvido por Murphy *et al.* (2007), é um índice de umidade do solo baseado na suposição de que os solos mais próximos das águas superficiais em termos de distância e elevação, provavelmente estarão mais saturados de água.

Já o Índice Morfométrico Composto (*Composite Topographic Index* - CTI) está relacionado aos processos de formação e distribuição espacial das propriedades do solo (MOORE *et al.*, 1991) e foi desenvolvido para pesquisas envolvendo a sequência de solos ao longo das encostas em áreas de declive (MOORE *et al.*, 1993). Ele fornece informações sobre susceptibilidade hidrológica e a capacidade de retenção de água de determinada área, levando em consideração a inclinação, declividade e orientação do terreno (KOPEĆ *et al.*, 2013). Este adiciona a curvatura em planta (*Plant Curvature* - PC) na expressão multiplicativa como demonstrado na seguinte equação (THORNE *et al.*, 1986; ZEVENBERGEN E THORNE, 1987):

$$CTI = A \times S \times PC \quad (\text{Equação 3})$$

Onde: PC – curvatura em planta.

A curvatura em planta mede a curvatura ao longo da linha de contorno. A PC usada no ArcGIS Pro utiliza as Equações de Zevenbergen e Thorne (RANA, 2006) e representa o grau de convergência (côncavo) ou divergência (convexa) do terreno, onde o perfil convergente concentra e acelera o fluxo (MOORE E BURCH, 1986; MITÁŠOVÁ E HOFIERKA, 1993). De acordo com Momm *et al.* (2013), uma normalização dos valores de CTI é desconsiderar a curvatura em planta negativa (cumes) e aplicar uma função logarítmica apenas aos pixels que contêm valores de CTI positivos, que são locais possíveis para iniciação de ravinas (ALBUQUERQUE *et al.*, 2020).

Dessa forma, propõe-se um CTI normalizado (CTIN) com base na seguinte equação:

$$CTIN = \ln(\text{abs}(CTI)) \times b \quad (\text{Equação 4})$$

Onde: $b = CTI / \text{abs}(CTI)$.

O termo “b” estabelece diferentes sinais para as áreas côncavas (+ 1) e áreas convexas (– 1).

O Fator topográfico (*Length Slope fator* - LS) mede dados das vertentes como o comprimento de rampa e a declividade. Dentre os vários métodos de obtenção, o escolhido foi o desenvolvido por Moore e Burch, (1986), que apresenta valores próximos aos obtidos por medidas em campo (HRABALÍKOVÁ; JANEČEK, 2017).

O índice de posição topográfica (*Topographic Position Index* - TPI) - tem como objetivo comparar a elevação de cada pixel em um MDT ou MDS com a elevação média da vizinhança a partir de um valor específico de distância, utilizando uma janela móvel, ou seja, é uma métrica que descreve a posição relativa de um local dentro do terreno circundante. Indica que os pontos com valores positivos são mais altos que sua área circundante e os pontos com valores negativos indicam local mais baixo que sua área circundante, o que torna possível a identificação de áreas com possibilidade de acúmulo de água (WEISS, 2001; DE REU *et al.*, 2013).

O Índice de Robustez do Terreno - *Terrain Ruggedness Index* (TRI), desenvolvido por RILEY *et al.*, (1999), calcula a mudança na altura de uma encosta a partir da diferença de elevação entre células adjacentes de um Modelo Digital de Elevação. A ferramenta mede a diferença nos valores de elevação de uma célula central e oito células vizinhas ao seu redor. Em seguida, é realizado o somatório das oito diferenças de elevação elevadas ao quadrado. Finalmente é extraída a raiz quadrada. O valor encontrado é uma medida TRI para a célula central.

A curvatura tangencial mede a curvatura tangente à linha de contorno. É descrita como contorno normal e é aplicada para caracterizar a convergência topográfica e a divergência do fluxo.

2.3. Identificação de áreas úmidas como subsídio ao mapeamento de processos erosivos lineares

Áreas úmidas são definidas como terras de transição entre ecossistemas terrestres e aquáticos onde o lençol freático está geralmente na superfície ou perto dela ou a terra é coberta por águas rasas (LIVINGTSON, 1986). Incluem também corpos de água permanentes, regiões que possuem regime intermitente de presença de água e áreas onde a água está abaixo de uma vegetação de densa cobertura, como turfeiras ou manguezais (CHATZIANTONIOU *et al.*, 2017).

Essas áreas são importantes devido às suas características naturais, oferecendo uma série de mecanismos (HAMMER, 2020) como a atuação da vegetação como barreira natural, ajudando a estabilizar o solo por meio de suas raízes, e na absorção de água, diminuindo o volume que flui sobre o solo (REDDY *et al.*, 2022; IKEDA-CASTRILLON *et al.*, 2022). Além disso, são capazes de reter sedimentos transportados pela água, evitando que sejam levados para corpos d'água ou áreas mais baixas. Essas áreas também possuem capacidade de filtrar impurezas melhorando a qualidade da água que flui para corpos d'água adjacentes (SHAHID *et al.*, 2020; GONÇALVES E DA COSTA, 2022).

Outras funções importantes decorrentes disso são a preservação dos padrões dos rios, na estabilização do fluxo de água, no reabastecimento dos aquíferos e na continuidade de existência de água de determinada bacia (BORGES E DA COSTA, 2022).

Mas apesar das áreas úmidas consistirem em importantes regiões para prevenção de processos erosivos, essas são compostas, além das áreas mais planas com acúmulo de água, pelas cabeceiras de drenagem e diversas áreas sensíveis com declividade mais acentuada, especialmente em suas bordas, que podem apresentar condições morfométricas favoráveis à deflagração de processos erosivos, especialmente em consequência de alterações na quantidade de água no sistema, como a presença de áreas com características urbanas (ALIKHANI *et al.*, 2021; SAQUIB *et al.*, 2022, MAO *et al.*, 2023)

Deste modo, a identificação de áreas úmidas utilizando como parâmetro os limiares mínimo e máximo de cada uma das variáveis associadas a esses ambientes (como declividade, altimetria, curvatura do terreno, entre outros), por meio do processamento de índices morfométricos, tem a capacidade de ampliar a sensibilidade e percepção no mapeamento de áreas propensas ao desenvolvimento de processos erosivos lineares (WHITLOW, 1992; DUKU *et al.*, 2021; ARABAMERI *et al.*, 2019; CHIROL *et al.*, 2022). A susceptibilidade de processos erosivos em áreas úmidas (especialmente em suas bordas), quando analisadas em contexto urbano, pode ser aumentada, considerando que o fluxo de águas é canalizado devido ao processo de impermeabilização e a construção de vias, aumentando o poder do escoamento.

Portanto, devido à importância das áreas úmidas nos mais diversos contextos, e neste caso, como subsídio à compreensão da localização das áreas propensas ao desenvolvimento de processos erosivos em áreas urbanas e periurbanas, a identificação de sua localização e distribuição é fundamental (HU *et al.*, 2017b). Mas esse tipo de estimativa é limitado, principalmente em grandes escalas, devido às imprecisões dos modelos hidrológicos aplicados para esse fim (ZHU E GONG, 2014). Nesse sentido, as técnicas de sensoriamento remoto voltadas a segmentação de imagens e classificação orientada a objetos mostram melhorias significativas de precisão em relação às técnicas de classificação tradicionais (FROHN *et al.*, 2011; Allan, 2016).

Vários estudos a partir da década de 1980 obtiveram bons resultados na delimitação de áreas úmidas (GUO *et al.*, 2017) utilizando imagens ópticas multiespectrais e hiperespectrais, de radar, sensores laser, além de métodos como o mapeamento orientado a objetos, classificação não supervisionadas e supervisionada (OZESMI E BAUER, 2002; HENDERSON E LEWIS, 2008; ADAM *et al.*, 2010; DRONOVA, 2015; GALLANT, 2015). De acordo com Chust *et al.* (2008), Chadwick (2011), Rapinel *et al.* (2015), Zhang *et al.* (2021), Bian *et al.* (2021), entre outros, a melhor alternativa para uma fonte precisa de dados morfométricos para o mapeamento de áreas úmidas tomando a topografia como elemento fundamental para o movimento da água é o uso de MDS e MDT derivados de sensores laser, como o LiDAR, de alta precisão.

Desse modo, os avanços relacionados a esse tipo de técnica de representação do relevo e superfície demonstram precisão e qualidade quanto a informações sobre terreno, vegetação e estruturas artificiais, além de representar topografia e as redes hidrográficas (WILSON E GALLANT, 1996; WILSON, 2012; ALGANCI *et al.*, 2018). Com a necessidade da delimitação de grandes áreas úmidas, os índices morfométricos passaram a fazer parte da modelagem hidrológica com o intuito de representarem a heterogeneidade topográfica nesses ambientes (BEVEN E KIRKBY, 1979; BHAT *et al.*, 2022) e auxiliarem na identificação da distribuição espacial das áreas úmidas, agregando informações geomorfológicas das bacias hidrográficas (INFASCELLI *et al.*, 2013; POLIDORI E HAGE, 2020)

2.4. Algoritmos de aprendizado de máquina

Aprendizado de Máquina (AM) é uma área da inteligência artificial que consiste no desenvolvimento de técnicas em ambiente computacional sobre o aprendizado e construção de sistemas capazes de adquirir conhecimento de forma automática (MAHESH, 2020; MÖLLER, 2023). Um sistema de aprendizado é um programa computacional que toma decisões baseado em experiências anteriores bem sucedidas e esses possuem características singulares e comuns que permitem sua classificação quanto à linguagem de descrição, modo, modelos e forma de aprendizado utilizado (MAHESH, 2020).

As técnicas de AM possuem dois tipos de aprendizado: o supervisionado, que possui uma Figura de indução externa que demonstra o conhecimento do ambiente por amostras na forma de entrada e saída que se deseja, e o não supervisionado, que não possui influência externa e não apresenta exemplos rotulados, onde o algoritmo aprende a agrupar as entradas submetidas segundo uma medida de qualidade (ALLOGHANI *et al.*, 2020; JIANG *et al.*, 2020a).

Dentro do AM, existem tarefas descritivas e tarefas preditivas. Em tarefas descritivas, o algoritmo se desenvolve na busca da descrição de dados, agrupando-os de maneira que os semelhantes fiquem em um mesmo grupo (MAHESH, 2020). Nessas, a função mais comum é a análise exploratória de dados, que elabora a exploração de dados por meio de técnicas estatísticas e

visuais, ajudando a identificar a distribuição dos dados, detectar discrepâncias, entender a explicação entre as variáveis e destacar tendências ou padrões (JIANG *et al.*, 2020b).

As tarefas preditivas podem ser divididas em tarefas de classificação e regressão. Em tarefas de classificação busca-se atribuir categorias predefinidas dos dados e nas de regressão objetiva-se prever o valor de uma variável numérica, dadas outras variáveis. Assim, em vez de encontrar uma classe associada, como na classificação, o algoritmo tenta aprender uma função matemática que relaciona as variáveis de entrada ao dado de saída (NASTESKI, 2017).

A regressão é uma técnica de aprendizado de máquina usada para prever valores numéricos contínuos e ajustar um modelo a um conjunto de dados de treinamento com recursos de entrada e valores de destino correspondentes. Assim, os modelos de regressão capturam os relacionamentos nos dados e fazem previsões com base nos padrões aprendidos (DREISEITL, 2002).

Entre os algoritmos e modelos capazes de aprender a partir de dados, permitindo que computadores tomem decisões ou façam previsões sem serem explicitamente programados, um dos mais importantes é o Floresta Aleatória (*Random Forest*), além das Redes Neurais Artificiais (*Artificial Neural Networks* - ANN) e Máquinas de Vetores de Suporte (*Support Vector Machines* - SVM), todos com ampla aplicabilidade nas mais diversas áreas do conhecimento (NOBLE, 2006; KROGH, 2008; TALUKDAR *et al.*, 2020; DENG *et al.*, 2021).

Apesar da imensa quantidade de trabalhos que utilizam algoritmos de aprendizagem de máquina, diversos autores já comprovaram a eficiência de duas técnicas específicas utilizadas com maior frequência para mapeamento de processos erosivos: o *Random Forest* e o *Gradient Boosting* que são baseados no método ensemble que consiste na combinação dos resultados obtidos por um conjunto de classificadores (GANAIE *et al.*, 2022). Muitos artigos foram elaborados a partir desses algoritmos, como por exemplo: Soleimanpour *et al.* (2021), no Irã; Azedou *et al.* (2021), que testaram modelos para mapeamento de processos erosivos em Marrocos; Rahmati *et al.* (2017); Chen *et al.* (2021), com estudos sobre modelos de susceptibilidade à erosão em áreas de agricultura em regiões semiáridas; Pal *et al.* (2020) e Band *et al.*

(2020), que utilizaram técnicas de AM a partir de dados do ALOS/PALSAR; entre outros.

O *Random Forest* foi proposto por Leo Breiman em 2001 (BREIMAN, 2001) como uma extensão do algoritmo Árvore de Decisão (*Decision Tree*), baseado na combinação de várias árvores de decisão em um único modelo. O RF é um modelo de aprendizagem supervisionado, o que torna necessário a escolha de uma variável a ser prevista, para que a partir daí, o algoritmo crie múltiplas árvores de decisão e cada árvore retorna uma resposta, tendo como resultado obtido por cada árvore uma média feita a partir de cada resposta apresentada (KLUSOWSKI, 2018) (Figura 3).

O modelo RF aplica uma técnica em que cada árvore de decisão é criada em paralelo usando uma parte gerada aleatoriamente dos dados originais (de treinamento), gerando sua própria previsão e vota em um resultado. O modelo considera os votos de todas as árvores de decisão para prever ou classificar o resultado de uma amostra desconhecida. Isto é importante, pois árvores individuais podem ter problemas com o ajuste excessivo de um modelo; entretanto, combinar múltiplas árvores em uma floresta para predição resolve o problema de sobreajuste (*overfitting*) associado a uma única árvore. Este modelo requer menos parâmetros e é mais intuitivo.




Figura 3 - Modo de funcionamento do *Random Forest*. Fonte: ESRI, 2023.

O RF é um algoritmo que pode ser usado tanto para tarefas de regressão quanto para tarefas de classificação, uma vez que é uma técnica complexa que se adapta a diferentes tipos de problemas. Durante a classificação das árvores cada amostra aleatória é selecionada para determinar a melhor divisão dos dados, o que permite lidar com um grande número de variáveis (LIAW E WIENER, 2002; PARMAR *et al.*, 2019; PROBST *et al.*, 2019).

Existem ainda outras técnicas de aprendizado de máquina amplamente utilizadas, como o *Gradient Boosting* (GB) que tem como função resolver problemas de regressão e classificação nas quais o procedimento de aprendizado ajusta-se consecutivamente a novos modelos para fornecer uma estimativa mais precisa da variável de resposta (ALI *et al.*, 2023).

O GB tem como objetivo construir uma nova base de aprendizes para minimizar a função de perda, na qual inicialmente um modelo simples é criado e, posteriormente, os modelos subsequentes são adicionados em etapas sequenciais, onde cada novo modelo é treinado para prever os erros do modelo anterior, ou seja, cada preditor é treinado para corrigir o erro residual de seu predecessor. Depois que as árvores são treinadas, elas podem ser usadas para previsão simplesmente adicionando os resultados de todas as árvores (Gaussian, Laplace, Huber e Quantile) e resposta categórica (Binomial e Adaboost) (FRIEDMAN, 2001; FRIEDMAN, 2002; GUELMAN, 2012; NATEKIN E KNOLL, 2013; BENTÉJAC *et al.*, 2019; VELTHOEN *et al.*, 2021).

O GB usa conjuntos de dados originais (de treinamento) de árvores fracas (em vermelho) e segue construindo sequencialmente de árvores de decisão em que cada árvore subsequente corrige os erros das árvores anteriores (em verde), de modo que o modelo se torna uma previsão forte (Figura 4). Este modelo proporciona maior controle sobre os hiperparâmetros e é mais complexo.




Figura 4 – Modo de funcionamento do *Gradient Boosting*. Fonte: ESRI, 2023

A avaliação do desempenho dos modelos, realizada após o treinamento, ocorre por meio de métricas apropriadas para os problemas estabelecidos. Para problemas de regressão, métricas comuns incluem o erro

médio quadrático (RMSE) e o coeficiente de determinação (R^2). Para problemas de classificação, métricas como a acurácia, a precisão e o F1-score são frequentemente utilizadas.

3. MATERIAL E MÉTODOS

3.1. *Área de estudo*

A cidade de Brasília, Distrito Federal (DF), é considerada a terceira maior cidade do Brasil (CENSO, 2020), com aproximadamente três milhões de habitantes distribuídas em diversas áreas do território do DF. Essa ocupação de forma desordenada, ocorrida principalmente nas últimas décadas, carece de uma infraestrutura capaz de minimizar os impactos negativos provocados pelas alterações do fluxo superficial. Consequentemente isso acarreta novos pontos de inundações, aumento dos processos erosivos, perda de solo, dentre outros. Esses fatores comprometem a qualidade estrutural, ambiental e de vida da população. A área de estudo compreende a região contemplada pelo aerolevante elaborado pela Companhia Imobiliária de Brasília (Terracap) do Governo do Distrito Federal, que abrange especialmente as áreas urbanas do DF, com exceção das áreas referentes a pequenos núcleos urbanos (Figura 5).




Figura 5 - Área referente ao aerolevantamento realizado em 2016 pela Companhia Imobiliária de Brasília (Terracap). Fonte: GEOPORTAL, 2023.

A geomorfologia do DF é composta por diferentes formas de relevo, distribuídas entre chapadas, planaltos e vales (NEVES *et al.*, 2017), caracterizados por regiões aplainadas, corrugadas e áreas de dissecação intermediárias, apresentando altitudes que variam entre 750m a 1350m (PINTO, 1986; CODEPLAN, 2021).

A área de estudo contemplada pelo aerolevantamento é composta basicamente por áreas urbanas e planas de planaltos, compostas predominantemente por Latossolos, que ocupam 54,50% da região do DF, divididos em latossolos vermelhos e latossolos vermelho-amarelos. O DF também é coberto por Cambissolos nas áreas de declividade mais acentuada (30,98%), Chernossolos (0,08 %), Plintossolos (0,40%), Neossolos Quartzarênicos (0,51%), Nitossolos (1,36%) e Argissolos (2,89%) (REATTO *et al.*, 2004). A distribuição espacial desses solos pode ser observada na Figura 6.

Assim, a área de estudo é composta basicamente por Latossolos que, a partir de declividades de 8%, apresentam probabilidade de desenvolver processos erosivos, de acordo com o Sistema Brasileiro de Classificação dos Solos – SIBCS (EMABRAPA, 2018). Esse solo caracteriza-se por ser altamente intemperizado e quimicamente pobre, com baixos níveis de matéria orgânica e nutriente. Além disso, possui uma textura predominantemente argilosa, mas com argila de baixa atividade, resultando em menor capacidade de retenção de água e nutrientes. Essas condições favorecem a dispersão das partículas do solo quando submetidas à ação das chuvas intensas (HOLANDA, 2022) e práticas agrícolas inadequadas, como o cultivo em monocultura e a ausência de cobertura vegetal, que potencializam ainda mais o risco de erosão ao deixar o solo desprotegido e exposto aos agentes erosivos (ARAUJO *et al.*, 2011).




Figura 6 – Mapa Pedológico do Distrito Federal. Fonte: Sistema de Informações Ambientais – SISDIA (2024).

O clima na região é classificado como tropical de altitude, com características típicas do Planalto Central brasileiro. Apresenta duas estações bem definidas: uma chuvosa e uma seca (CARDOSO *et al.*, 2014). A vegetação predominante é o Cerrado, que apresenta fitofisionomia florestal savânica e campestre, composto por uma variedade de espécies de plantas adaptadas às condições específicas desse bioma (MARIMON JUNIOR e HARIDASAN, 2005).

Dentro da área de estudo, foi selecionada uma área teste para processamento dos dados e posterior

ampliação para toda a área de estudo. Essa área abrange parte das bacias hidrográficas do Córrego Taboquinha, Ribeirão Taboca e Córrego Mato Grande, localizadas na zona central do DF (Figura 7). Essa área foi escolhida porque contempla outros tipos de solo, é mais declivosa e possui interface entre a área urbana e rural, ou seja, todos esses aspectos estão representados na área urbana total do Distrito Federal.




Figura 7 – Mapa de localização da área teste.

3.2. *Etapas metodológicas*

Primeiramente a metodologia foi desenvolvida na área teste com resoluções espacial de 3 e 0,5 m. Foram mapeadas as áreas úmidas e as áreas suscetíveis ao desenvolvimento de processos erosivos lineares. Com base nos melhores resultados metodológicos obtidos, os processamentos foram aplicados a todo o conjunto de dados do Distrito Federal para a elaboração do mapa final, identificando as áreas suscetíveis ao desenvolvimento de processos erosivos lineares. Cada etapa da metodologia está descrita detalhadamente no fluxograma da Figura 8.




Figura 8 – Fluxograma geral de processamento dos dados.

3.3. *Elaboração e tratamento do modelo digital*

Inicialmente foi elaborado um MDT com resolução de 0,5 metro da área de estudo a partir dos pontos do aerolevantamento a laser com o sensor LIDAR disponibilizado em 2016 pelo Governo do Distrito Federal – GDF (TERRACAP,

2016) com escala 1:500 e resolução espacial de 10 x 10 cm (GEOPORTAL, 2023). O MDT reproduz o relevo de forma mais apropriada que o MDS para a determinação dos parâmetros morfométricos porque: a) todo o relevo da vegetação é eliminado e, conseqüentemente, isso garante o fluxo de escoamento e drenagem de forma gravitacional e; b) o relevo referente às edificações são eliminados, porém, o arruamento foi preservado, permitindo que o parâmetro morfométrico fluxo acumulado seja calculado seguindo esse trajeto, retratando as interferências antrópicas.

Devido a nuvem de pontos gerada ser muito densa em função da altíssima resolução espacial, o resultado da interpolação gera microtopografias que podem ocasionar dados errôneos da superfície e por este motivo utilizou-se o filtro Perona Malik para suavização, minimizando as feições que interferem na continuidade do fluxo de escoamento.

O filtro Perona-Malik, desenvolvido por Passalacqua *et al.*, (2010), é uma técnica não linear de imagens que reduz o ruído e preserva as bordas e detalhes importantes da imagem, o que o difere dos filtros lineares tradicionais, como a filtragem Gaussiana (Figura 8), uma vez que a filtragem não linear leva em consideração a estrutura local da imagem (PASSALACQUA *et al.*, 2010). Esse filtro baseia-se no princípio de difusão anisotrópica, ou seja, a difusão do filtro ocorre de maneira direcionada, levando em consideração as propriedades locais da imagem.




Figura 9 - Comparação do esquema de funcionamento do filtro Perona-Malik com uma filtragem Gaussiana. (a) dados originais; (b;c) filtragem Gaussiana; (d;e) filtragem Perona-Malik. Fonte: Passalacqua, 2015.

Desse modo, o filtro Perona-Malik usa o gradiente da imagem para estimar a direção e a intensidade do fluxo de difusão em cada ponto da imagem (DENG *et al.*, 2019). Nesse tipo de difusão as bordas e os detalhes da imagem são preservados mesmo com a suavização do ruído (TORKAMANI-AZAR e TAIT, 1996; WANG *et al.*, 2018), como as bordas das elevações e os detalhes da topografia. Para que o filtro se torne adequado a esse tipo de arquivo matricial, que representa a topografia em larga escala, os filtros precisam ser adaptados de acordo com a resolução espacial e a precisão dos dados (GUAN *et al.*, 2013; O'NEIL *et al.*, 2019).

A Figura 10 apresenta o MDT original e o MDT filtrado da mesma área mostrando que as diferenças entre os MDTs não são perceptíveis. Entretanto, quando se traçam os perfis, pode ser observado, não só a suavização, mas também a identificação do fundo de vale, permitindo que água superficial percorra o caminho gravitacional até o fundo do vale (Figura 11).




Figura 10 – MDT original (A) e MDT filtrado (B).




Figura 11 – Gráficos de perfil do relevo referente ao MDT original e após a filtragem utilizando o Filtro Perona Malik (PM).

O produto final será um MDT consistido hidrologicamente para que o escoamento superficial possa fluir de forma gravitacional sem a interferência dos micros relevos e vegetação, porém considerando as feições antrópicas.

3.4. Definição dos parâmetros para os mapeamentos

Para a definição dos parâmetros a serem utilizados na identificação das áreas susceptíveis ao desenvolvimento de processos erosivos lineares foi elaborada extensa pesquisa bibliográfica para identificação do estado da arte nas pesquisas atuais utilizando parâmetros morfométricos e hidrológicos elegendo os que possuem maior potencial para predição de processos erosivos. Para tanto, foi feita uma seleção de artigos científicos, identificando os parâmetros mais utilizados e que fornecem os melhores resultados.

A tabela 1 (Anexo 1) apresenta os parâmetros utilizados identificados em 36 artigos científicos recentes e contabiliza, na última linha, o número total de utilização nas pesquisas. Indica também a conclusão de cada autor quanto ao melhor método de aprendizado de máquina aplicado e quais os parâmetros mais importantes para a elaboração do mapa de susceptibilidade. Dos artigos pesquisados, apenas 1 utiliza modelos digitais de elevação de alta resolução (1 metro). Isso demonstra a dificuldade de se obter um modelo digital hidrologicamente consistido, devido ao micro relevo encontrado em levantamentos de detalhe.

De acordo com os trabalhos pesquisados, a variável mais utilizada é a altitude, seguida da declividade e o TWI. Os trabalhos indicam o uso da densidade de drenagem, solos, litologia e o uso e cobertura da terra, mas no presente contexto essas variáveis se apresentam muito uniformes por se tratar de uma área urbana, plana e predominantemente composta por latossolos (Figura 12).




Figura 12 - Gráfico da frequência de uso das variáveis nos trabalhos pesquisados

Com base na literatura consultada e em testes de desempenho e colinearidade, foram escolhidos apenas os parâmetros morfométricos para serem utilizados nos algoritmos de aprendizado de máquina na identificação de áreas propensas a processos erosivos. Esses parâmetros incluem o Índice de Posição Topográfica (TPI), o Índice de Robustez do Terreno (TRI), o Fator

Topográfico (LS), a Curvatura Tangente, o Índice Potencial de Erosão (P), o Fluxo Acumulado e o Índice Topográfico Composto Normalizado (CTIN).

3.5. Parâmetros que definem áreas úmidas

Processos erosivos podem estender-se para áreas úmidas, especialmente em eventos de fluxo da água de alta energia, alterando a rede de drenagem potencializada por influências antrópicas. Em particular, ravinas também podem ocorrer em porções mais baixa da paisagem com declividades inferiores a 3% (AMARE *et al.*, 2019; BILLI e DRAMIS, 2003), incluindo erosão da rede de drenagem que passa por áreas úmidas, bem como os processos erosivos causados por enchentes sazonais ou eventos extremos de precipitação. Com intuito de avaliar o comportamento dos processos erosivos dessas porções da paisagem, foi elaborado o mapeamento das áreas úmidas na área de estudo, demonstrado a seguir.

A delimitação das áreas úmidas foi realizada utilizando-se os índices secundários TWI, DTW e a curvatura em planta, com base nos parâmetros definidos por pesquisadores da Universidade da Virgínia, que realizaram a delimitação de áreas úmidas utilizando a ferramenta Archydro no software ArcGis Pro. De acordo com o manual do software, os índices foram definidos após diversos testes utilizando o modelo intitulado *Wetland Identification Model* (O'NEIL *et al.*, 2019). Assim, o modelo foi calibrado levando em consideração esses índices, que apresentaram melhor desempenho na delimitação de áreas úmidas.

3.6. Mapeamento das áreas úmidas e áreas susceptíveis a processos erosivos lineares

Na presente pesquisa optou-se por realizar testes metodológicos com base no algoritmo *Random Forest* modificado, chamado *Forest - Based - FB*, além do *Gradient Boosting* com o objetivo de identificar qual modelo apresentava melhor capacidade de mapeamento, considerando os algoritmos mais utilizados nos trabalhos encontrados na pesquisa bibliográfica (anexo 1). O mapeamento das áreas foi realizado no software ArcGis Pro. Os dados foram processados na ferramenta *Forest-Based and Boosted Classification and Regression* do ArcGis PRO.

Para realizar a classificação, inicialmente foi necessário treinar o modelo para a previsão, definindo a área denominada de “verdade terrestre”. Esse modelo constrói uma relação entre as variáveis fornecidas, nesse caso os mapas dos parâmetros morfométricos, com as áreas previstas com as mesmas características. São separados uma porção da área correspondente a verdade terrestre, que não fazem parte do treinamento, para posterior validação do modelo.

O treinamento pode ser feito a partir da identificação dos parâmetros de cada pixel de áreas úmidas ou cicatrizes referente aos processos erosivos ou também a partir da média ou mediana dos valores de cada parâmetro dentro de cada área ou cicatriz (Figura 13).




Figura 13 – Treinamento a partir de pontos dentro da área ou cicatriz (A) e a partir de uma média/mediana (B).

Esse treinamento permite que o dado de entrada seja um arquivo vetorial de polígono ou ponto. Quando é utilizado um polígono, ocorre a sua conversão para um conjunto de centroides que correspondem a cada célula raster que estiver dentro do polígono. O valor de cada célula é extraído e a ferramenta fará uma busca detalhada para encontrar as variáveis explicativas em cada localização de ponto, como mostra a Figura 14. A partir do treinamento o algoritmo identificará as células de cada cicatriz que foram classificadas de acordo com o conjunto de parâmetros definidos. Esse procedimento permite verificar se o mapeamento das cicatrizes necessita de revisão.



Figura 14 – Amostras mapeadas com geometria de polígonos convertida em pontos para o treinamento dos algoritmos *Gradient Boosting* e *Forest Based*.

O arquivo vetorial que contém as informações rotuladas dos dados para previsão de áreas úmidas e cicatrizes resultantes de processos erosivos é gerado a partir de amostras de áreas úmidas/cicatrizes, designadas com o código de classe 1, e de áreas não úmidas/não cicatrizes, com a classe 0, conforme ilustrado na Figura 15 e Figura 16. Este arquivo é então empregado como entrada para representar as duas categorias nos modelos utilizados para treinamento e previsão.




Figura 15 – Exemplo de amostras para treinamento de áreas úmidas e áreas não úmidas.




Figura 16 – Exemplo de amostras do que representa processos erosivos lineares e o que não representa.

O mapeamento para a identificação das áreas foi elaborado a partir da análise visual das características das feições existentes, como forma, largura, tonalidade, textura, ramificações, extensão, direção, disposição, localização, umidade do solo, vegetação e conexão (CUNHA e COSTA, 2020) no aerolevantamento disponível de 2016. Da mesma forma foram mapeadas as incisões erosivas em áreas paralelas ou adjacentes às áreas urbanas e à malha viária do Distrito Federal, considerando as duas margens das rodovias, com um buffer de até 200 metros, a depender da região.

Essa interpretação visual foi atualizada a partir de imagens mais recentes disponíveis no *Google Earth Pro*, no qual foram criados polígonos que posteriormente foram convertidos em arquivos vetoriais no *software* ArcGis 10.8. Após o mapeamento foram feitas campanhas de campo para validação das informações mapeadas relacionadas principalmente às áreas de cicatrizes.

A partir dessas amostras, foram feitos os seguintes processamentos com a ferramenta *Forest - Based and Boosted Classification and Regression*, aplicados na área teste, para a definição das áreas úmidas e das áreas susceptíveis a processos erosivos, demonstrados no fluxograma da Figura 17, descritos a seguir.

- O Teste 1 corresponde a elaboração do mapeamento das áreas úmidas: MDT com resolução de 3 metros com e sem a aplicação do filtro Perona Malik; utilizando três variáveis (curvatura em planta, TWI e DTW) e aplicando os dois algoritmos (FB e GB). A Figura 18, mostra os três parâmetros utilizados;
- O Teste 2 corresponde a elaboração do Mapeamento dos processos erosivos lineares: MDT com resolução de 3 metros com e sem filtro; utilizando sete variáveis (curvatura tangente, fluxo acumulado, TPI, CTIN, TRI, LS e P) e aplicando os dois algoritmos (FB e GB) A Figura 19 mostra os três parâmetros utilizados.
- Como forma de identificar a importância das áreas úmidas no mapeamento dos processos erosivos lineares, foi realizado o Teste 3 utilizando o MDT com resolução de 3 metros com e sem a aplicação do filtro Perona Malik; todas as variáveis (TWI, DTW e curvatura em planta utilizadas no mapeamento das áreas úmidas, além das variáveis anteriormente utilizadas no mapeamento dos processos erosivos lineares - TPI, TRI, LS, curvatura tangente (Tang_C), P, fluxo acumulado (FA) e CTIN), aplicando os dois algoritmos (FB e GB). Finalmente, a partir da identificação do teste que fornece o melhor resultado, esse foi utilizado para calcular as áreas susceptíveis a ocorrência de processos erosivos para todo o Distrito Federal.



Teste 1**Teste 2****Teste 3**

Figura 17 – Fluxograma de processamento dos testes para elaboração do mapeamento das áreas úmidas e dos processos erosivos lineares.




Figura 18 – Parâmetros gerados a partir de MDT com resolução de 3 metros – Curvatura em planta, TWI e DTW.




Figura 19 - Parâmetros gerados a partir de MDT com resolução de 3 metros - curvatura tangente (Tang_C), fluxo acumulado (FA), TPI, CTIN, TRI, LS e P

3.7. Validação do modelo

A maioria dos programas fornece como resultado da aplicação dos algoritmos uma série de informações que auxiliam na avaliação do desempenho do modelo. Um fator importante é revelar qual a importância que cada parâmetro (altitude, índice morfométrico etc.) tem no desempenho do modelo e isso é realizado a partir de um ranking proveniente do coeficiente de Gini, que calcula o número de vezes que um parâmetro é responsável por uma divisão, ou seja, uma decisão, dividido pelo número de árvores.

Essa informação é fundamental para avaliar quais parâmetros são significativos para criação do modelo. Parâmetros com baixíssimo valor do coeficiente de Gini, não são necessários e, se incluídos no processamento, podem ainda diminuir o desempenho do modelo. A Tabela 1 mostra um exemplo em que os valores na coluna “Importância” são iguais à soma dos coeficientes de Gini de todas as árvores para cada variável listada, e o da coluna “%” refere-se as respectivas porcentagens relativa à soma total dos coeficientes de Gini.

Tabela 1 – Exemplo da importância das variáveis no modelo de acordo com o índice de Gini.

Variável	Importância	%
TRI	59,41	18
P	56,56	17
FA	47,48	15
Tang_C	42,87	13
LS	42,23	13
CTIN	38,43	12
TPI	38,36	12

O diagnóstico de intervalo explicativo auxilia na avaliação dos valores usados para treinamento, validação e previsão orientando se são suficientes para produzir um bom modelo. Os dados de treinamento devem ser representativos dos dados que você está modelando. Por padrão, 10% dos dados de treinamento são excluídos aleatoriamente, resultando em um subconjunto de treinamento e um subconjunto de validação. Portanto, é necessário avaliar se o mínimo e máximo dos valores do parâmetro na amostra de treinamento abrangem o mínimo e o máximo do total de valores dos

parâmetros. Isso revela o quanto a sua amostra estará ajustada para efetuar o treinamento.

A tabela 2 mostra um exemplo de valores mínimo e máximo desses subconjuntos. A variável P apresenta os valores de Mínimo e Máximo na Predição de -53,37 e 50,36, porém os valores do intervalo de treinamento possuem os valores de Mínimo e Máximo de -0,14 e 0,03. Ao subtrair os valores de máximos e mínimos, a razão entre os intervalos será $(50,37 - (-53,37)) / (0,03 - (-0,14))$ igual a 609,21, o que demonstra que apesar da validação realizada com os dados de treinamento ser 1, o modelo não foi treinado com uma amostra apropriada para esse parâmetro específico.

Tabela 2 – Exemplo de diagnóstico dos parâmetros utilizados.

Parâmetro	Treinamento		Validação		Predição		Razão entre os intervalos		
	Mín	Máx	Mín	Máx	Mín	Máx	Treina mento	Validação	Predição
Área de Contribuição (FA)	-7,59	2,28	-6,82	0,66	-21,66	18,12	1,00	0,76	4,03
TPI	1,31	8,92	1,44	7,57	-3,18	16,61	1,00	0,81	2,60
P	-0,14	0,03	-0,16	0,03	-53,37	50,36	0,90	1,00	609,21
CTIN	0,00	0,09	0,00	0,09	-0,00	0,86	1,00	0,99	9,35
CTang	-0,69	7,10	0,82	6,30	-0,69	13,30	1,00	0,70	1,80
LS	-7,60	6,34	-2,92	5,93	-7,60	13,39	1,00	0,64	1,51
TRI	0,00	41,12	0,82	35,36	0,00	87,90	1,00	0,84	2,14

Os métodos estatísticos mais utilizados para identificação de desempenho dos modelos FB e GB são o Precision (precisão) e Recall (sensitividade). A precisão (verdadeiro positivo) retrata se todos os pixels rotulados como áreas úmidas/áreas susceptíveis realmente são, e é expressa pela seguinte expressão:

$$\text{Precisão} = \text{VP} / \text{VP} + \text{FP}$$

Onde VP – Verdadeiro Positivo, FP – Falso Positivo.

A sensibilidade (falso negativo) retrata se de todos os pontos que realmente são susceptíveis, quantos foram rotulados como tal, ou seja, o quão frequente é classificado como úmida/área susceptível. Quanto menor o valor da sensibilidade, mais falso negativo existe no processamento. Essa é dada pela expressão:

$$\text{Sensitividade (recall)} = VP / VP + FN$$

Onde FN – Falso Negativo.

Acurácia é o número de vezes que uma classe é identificada corretamente levando-se em conta o número total de observações dessa classe. A acurácia considera o quanto uma classe de interesse é acertadamente predita e como as outras classes são corretamente identificadas como não sendo essa classe de interesse. A acurácia é calculada da seguinte forma:

$$\text{Acurácia (Accuracy)} = (VP + VN) / (VP + VN + FN + FP)$$

O F1-Score indica o grau de acerto do modelo levando-se em conta a precisão e sensibilidade:

$$\text{F1-Score} = 2 \times \frac{\text{Precisão} \times \text{Sensitividade}}{\text{Precisão} + \text{Sensitividade}}$$

A Tabela 3 mostra um exemplo de resultado das métricas estatísticas, indicando o grau de acerto do modelo. O coeficiente de correlação de Matthews (MCC) utiliza as categorias de verdadeiros negativos, verdadeiros positivos, falsos negativos e falsos positivos (VILELA JUNIOR *et al.*, 2022). O valor do índice próximo a 1 indica que o modelo acertou de forma homogênea nas duas categorias analisadas.

Tabela 3 – Exemplo de resultado estatístico do modelo.

Classe	F1-Score	MCC	Sensitividade	Acurácia
0	0,97	0,93	1,00	0,96
1	0,96	0,93	0,92	0,96

Dado o exposto, após análise das estatísticas dos testes feitos, os melhores resultados (em termos de processamento) foram aplicados ao MDT com resolução de 0,5 metro para a área teste e, posteriormente, devido as limitações do programa ArcGis foi elaborada o MDT com resolução de 1 metro para toda a área de estudo (área abrangida pelo levantamento aerofotogramétrico das áreas urbanas de todo o DF), resultando em um mapa final de áreas susceptíveis a processos erosivos lineares.

4. RESULTADOS E DISCUSSÃO

4.1. Mapeamento das áreas úmidas

Iniciando com o Teste 1 do fluxograma da Figura 17, no que diz respeito à importância das três variáveis selecionadas para análise das áreas úmidas (TWI, DW e curvatura em planta), os testes feitos com o algoritmo *Forest Based*, independentemente de ter sido aplicado o filtro Perona Malik ou não ao MDT, indicam que todas apresentam a mesma relevância, com 33% cada. Já quando as mesmas variáveis são utilizadas no modelo *Gradiente Boosting*, nota-se uma relevância maior para a curvatura em planta na detecção das áreas úmidas (Tabela 4).

Tabela 4 – Importância de cada variável nos modelos

Variável	FB		GB	
	MDT original	MDT PM	MDT original	MDT PM
Curvatura	33%	33%	37%	37%
TWI	33%	33%	33%	31%
DTW	33%	33%	30%	32%

Esse fato se deve pela importância que os índices morfométricos primários apresentam na análise da paisagem, sendo parâmetros básicos na compartimentação da paisagem e, nesse caso, a curvatura em planta, sendo a segunda derivada do relevo, apresenta-se fundamental na determinação das áreas úmidas no contexto da topografia. Deste modo, no processamento pelo GB, a curvatura apresentou-se sempre no topo da hierarquia da árvore, demonstrando a importância da variável.

Quando analisadas as amostras utilizadas no treinamento em todos os testes, os valores mínimo e máximo na etapa de treinamento estavam dentro do intervalo da predição, mantendo um valor de validação próximo de 1, indicando que o modelo, em todas as situações, foi treinado com uma amostra apropriada para todos os parâmetros utilizados (Tabela 5 a tabela 8).

Tabela 5 – Diagnóstico dos parâmetros utilizados na aplicação do algoritmo Forest-Based sem aplicação do filtro Perona Malik.

Variável	Treinamento		Validação		Predição		Divisão		
	Mín	Máx	Mín	Máx	Mín	Máx	Treina mento	Validação	Predi ção
CURV	-0,43	0,23	-0,31	0,17	-0,65	0,45	1,00	0,73	1,65+
DTW	0,00	68,57	0,00	69,29	0,00	101,99	0,99	1,00	1,49+
TWI	0,77	19,98	0,99	18,56	-0,24	22,84	1,00	0,91	1,20+

Tabela 6 – Diagnóstico dos parâmetros utilizados na aplicação do algoritmo Forest-Based com aplicação do filtro Perona Malik.

Variável	Treinamento		Validação		Predição		Divisão		
	Mín	Máx	Mín	Máx	Mín	Máx	Treina mento	Validação	Predi ção
CURV	-0,36	0,18	-0,17	0,10	-0,53	0,28	1,00	0,50	1,49+
DTW	0,86	19,99	1,32	19,61	-0,29	21,88	1,00	0,96	1,16+
TWI	0,00	73,48	0,00	71,97	-0,00	105,03	1,00	0,98	1,43+

Tabela 7 – Diagnóstico dos parâmetros utilizados na aplicação do algoritmo Gradient Boosting sem aplicação do filtro Perona Malik.

Variável	Treinamento		Validação		Predição		Divisão		
	Mín	Máx	Mín	Máx	Mín	Máx	Treina mento	Validação	Predi ção
CURV	-0,36	0,18	-0,17	0,10	-0,53	0,28	1,00	0,50	1,49+
TWI	0,86	19,99	1,32	19,61	-0,29	21,88	1,00	0,96	1,16+
DTW	0,00	73,48	0,00	71,97	0,00	105,03	1,00	0,98	1,43+

Tabela 8 – Diagnóstico dos parâmetros utilizados na aplicação do algoritmo Gradient Boosting com aplicação do filtro Perona Malik.

Variável	Treinamento		Validação		Predição		Divisão		
	Mín	Máx	Mín	Máx	Mín	Máx	Treina mento	Validação	Predi ção
CURV	-0,36	0,18	-0,26	0,15	-0,53	0,28	1,00	0,76	1,49+
DTW	0,86	19,99	1,00	18,92	-0,29	21,88	1,00	0,94	1,16+
TWI	0,00	73,48	0,00	69,49	0,00	105,03	1,00	0,95	1,43+

No que diz respeito ao mapeamento das áreas úmidas, as tabelas 9, 10 e 11, apresentam as estatísticas referentes a cada teste. Em todas elas pode-se notar uma queda na qualidade do mapeamento quando se comparam

os dados de treinamento com os dados de validação, o que é esperado, pois na validação do modelo é utilizada toda a área teste no parâmetro de entrada.

A Tabela 9, mostra as estatísticas do mapeamento das Áreas Úmidas utilizando o algoritmo *Forest Based* no MDT original na área de treinamento. O *F1-score* possui valores altos, representando que os 10% das amostras da área de treinamento para a validação, tiveram um alto grau de acerto. Observa-se uma queda na qualidade do mapeamento quando se comparam os dados de treinamento com os dados de validação (Tabela 10), o que é esperado, pois na validação do modelo é utilizada toda a área teste no parâmetro de entrada.

A Tabela 10, mostra as estatísticas do processamento da Área Úmida utilizando o algoritmo *Forest Based* no MDT original na área total, com uma precisão global (*F1 Score*) de 0,54 nos dados de validação, referente às áreas úmidas e de 0,69 para as áreas não úmidas. Esse resultado é justificado porque as áreas não úmidas possuem uma dimensão muito maior do que as áreas úmidas, portanto, o *F1 Score* é proporcionalmente maior.

Tanto a precisão global quanto a acurácia do modelo nos dados de validação (área total) aumentaram para 0,72, área não úmida e 0,58, área úmida (Tabela 11), apesar da sensibilidade em ambos continuarem abaixo de 0,70, indica que em algumas porções as áreas úmidas estão sendo classificadas como não úmidas (lembrando que quanto mais baixo o valor da sensibilidade, mais falso negativo existe no processamento dos dados). Em relação à sensibilidade é interessante observar que para os dados de treinamento, para as áreas classificadas como úmidas o valor deu igual a 1 em ambos os testes, demonstrando que as amostras na verdade estavam bem ajustadas. Esses resultados demonstram um incremento no mapeamento ao se aplicar o filtro Perona Malik no MDT utilizado como dado de entrada.

Tabela 9 – Estatísticas do processamento da Área Úmida utilizando o algoritmo *Forest Based* no MDT original (treinamento)

Classe	F1-Score	MCC	Sensitividade	Acurácia
0	0,96	0,90	0,92	0,95
1	0,94	0,90	1,00	0,95

Tabela 10 – Estatísticas do processamento da Área Úmida utilizando o algoritmo *Forest Based* no MDT original (validação).

Classe	F1-Score	MCC	Sensitividade	Acurácia
--------	----------	-----	---------------	----------

0	0,69	0,24	0,66	0,63
1	0,54	0,24	0,59	0,63

Tabela 11 – Estatísticas do processamento da Área Úmida utilizando o algoritmo *Forest Based* no MDT com filtro Perona Malik (validação).

Classe	F1-Score	MCC	Sensitividade	Acurácia
0	0,72	0,30	0,69	0,66
1	0,58	0,30	0,62	0,66

Os resultados para o algoritmo *Gradient Boosting* (Tabelas 12 e 13) seguem a mesma linha, apresentando melhora no mapeamento das áreas úmidas com a aplicação do filtro Perona Malik no MDT original. Assim, observa-se que a precisão global (*F1 Score*) para o conjunto dos dados de validação para as áreas úmidas – 1 aumenta de 0,69 com o modelo original e para 0,73 com o filtro Perona Malik, aumentando também a acurácia, de 0,76 para 0,78.

Quanto aos valores de sensibilidade, em ambos os testes (com e sem filtro) os valores ficaram muito parecidos, todos próximos a 0,80, o que é um bom resultado considerando que quanto mais próximo do valor 1, menos falso negativo existe na amostra final. Assim, novamente esses resultados demonstram um incremento no mapeamento ao se aplicar o filtro Perona Malik no MDT utilizado como dado de entrada.

Tabela 12 - Estatísticas do processamento da Área Úmida utilizando o algoritmo *Gradient Boosting* no MDT sem filtro Perona Malik (validação).

Classe	F1-Score	MCC	Sensitividade	Acurácia
0	0,80	0,49	0,79	0,76
1	0,69	0,49	0,71	0,76

Tabela 13 – Estatísticas do processamento da Área Úmida utilizando o algoritmo *Gradient Boosting* no MDT com filtro Perona Malik (validação).

Classe	F1-Score	MCC	Sensitividade	Acurácia
0	0,82	0,55	0,78	0,78
1	0,73	0,55	0,79	0,78

Os testes utilizando tanto o algoritmo FB quanto o GB indicam melhoras nos resultados em todas as estatísticas analisadas à medida que se aplica o filtro Perona Malik – PM no dado de entrada (MDT) – (Tabela 14). Além disso, há melhora expressiva na utilização do GB quando se comparam

os dois algoritmos (Figura 20) em que o mapeamento apresenta as classes mais homogêneas, mais compactadas. Assim, para o presente contexto de paisagem, o algoritmo GB apresentou os melhores resultados no mapeamento das áreas úmidas, como melhora de todas as estatísticas com a utilização do algoritmo.

Tabela 14 – Síntese comparativa das estatísticas geradas com utilização do FB e GB para o mapeamento das Áreas Úmidas no MDT com aplicação do filtro Perona Malik.

Classe	Forest PM				Boosted PM			
	F1	MCC	Sensitividade	Acurácia	F1	MCC	Sensitividade	Acurácia
0	0,72	0,3	0,69	0,66	0,82	0,55	0,78	0,78
1	0,58	0,3	0,62	0,66	0,73	0,55	0,79	0,78




Figura 20 – Detalhe da comparação entre os algoritmos FB e GB, sem a aplicação do filtro Perona Malik e com a aplicação do filtro no MDT.

4.2. Mapeamento dos processos erosivos

A análise dos parâmetros morfométricos no estudo dos processos erosivos lineares demonstra que a urbanização apresenta papel fundamental

na canalização das águas pluviais (e águas servidas), contribuindo sobremaneira no desenvolvimento dos processos erosivos lineares.

Em análise multitemporal tomando como exemplo um processo erosivo linear localizado na área teste (Figura 21), pode-se observar a rápida evolução a partir do crescimento urbano na região, especialmente entre os anos de 2015 e 2016 (Figura 22).




Figura 21 – Localização do exemplo na área teste.



Figura 22 – Evolução temporal de um processo erosivo linear entre os anos de 1975 e 2016.

Na imagem de 1975 pode-se observar a área ainda coberta com vegetação nativa, com presença apenas de caminhos de largura reduzida. Em 1997 já é possível verificar o surgimento de vias e ocupação com

características urbanas, com adensamento de edificações, mas pela imagem ainda não é possível identificar o surgimento de um processo erosivo linear. No ano de 2015, já com a ocupação bastante adensada, nota-se a presença de uma cicatriz de erosão bastante visível, a qual se aprofunda em grande medida em apenas 1 ano, como pode ser observado na imagem do ano de 2016.

A análise morfométrica da área, especialmente da variável P (que indica a potência erosiva - intensidade do fluxo - ou a capacidade de incisão do escoamento), demonstra que os maiores valores coincidem com as áreas nas quais a água é canalizada na superfície por meio de caminhos impermeabilizados, especialmente em função da construção de vias de acesso (Figura 23). Na imagem de 2018 observa-se a evolução do processo erosivo linear em várias direções, principalmente na sua porção oeste, em caminho preferencial bastante definido pelo Fator P, que coincide com a via interna da ocupação.




Figura 23 – Análise do Fator P na área exemplificada.

Os algoritmos Forest-based e Gradient Boost possuem metodologias distintas para a construção de modelos e a maneira como definem a importância dos parâmetros. O Forest-based por utilizar uma média das reduções de impureza, como a impureza de Gini, hierarquiza a importância dos parâmetros a partir da frequência que são utilizados para fazer divisões. Entretanto, o Gradient Boost define a importância do parâmetro a partir do modelo que apresentou um melhor desempenho. Os parâmetros que são utilizados para promover ajustes são considerados os mais importantes.

Seguindo com o Teste 2 do fluxograma da Figura 18, em relação aos parâmetros mais importantes para o mapeamento dos processos erosivos lineares utilizando o MDT com resolução de 3 metros, pode-se observar que, para o algoritmo FB o TRI foi o mais determinante, apesar da importância estar bem próxima do Fator P. Já para o GB, a variável mais importante variou de acordo com o uso ou não do MDT filtrado, como pode ser observado na Tabela 15. Para o FB, o Índice de Robustez do Terreno - Terrain Ruggedness Index (TRI), que calcula a mudança na altura de uma encosta a partir da diferença de elevação entre células adjacentes, teve maior peso.

Assim como ocorreu na análise das amostras utilizadas no treinamento nos testes relativos ao mapeamento das áreas úmidas, todos os valores mínimo e máximo na etapa de treinamento estavam dentro do intervalo da predição, com exceção dos valores relacionados ao Forest Based sem aplicação do Filtro PM no MDT (Tabela 16, 17, 18 e 19). Neste último caso, apesar dos intervalos do treinamento não estarem contidos no de predição, os valores de validação foram próximos de 1 (excluindo o referente à curvatura tangencial, que ficou próximo à 0,5), indicando que o modelo foi treinado com uma amostra apropriada para esses parâmetros também.

Tabela 15 - Importância de cada variável nos modelos.

Variável	FB		GB	
	MDT original	MDT PM	MDT original	MDT PM
TRI	18	17	15	17
P	17	16	17	11
Fluxo acumulado	15	15	7	7
Curvatura tangente	13	13	11	13
LS	13	13	11	16
CTIN	12	13	18	19
TPI	12	13	21	17

Já quando utilizado o GB, a ausência de filtro no MDT demonstrou que o Índice de Posição Topográfica - *Topographic Position Index* (TPI) – teve importância considerável, o que pode ser justificado pelo excesso de dados e não uniformização do terreno a partir da filtragem, uma vez que esse índice compara a elevação de cada pixel com a média da vizinhança, tornando possível a identificação de áreas com possibilidade de acúmulo de água.

Desse modo, as estruturas que se mantiveram pela ausência do filtro podem ter influenciado na importância da variável para o modelo.

Quando utilizado o filtro com o GB, a variável mais importante passou a ser o Índice Topográfico Composto Normalizado (CTIN), que fornece informações sobre a susceptibilidade hidrológica e a capacidade de retenção de água de determinada área, levando em consideração a inclinação, declividade e orientação do terreno, mas desconsiderando os cumes, uma vez que a água não se acumula nesses pontos. Esse resultado se mostra interessante à medida que, pela bibliografia explorada, o desenvolvimento de processos erosivos lineares deve considerar todas essas variáveis inseridas no cálculo do índice.

Tabela 16 – Diagnóstico dos parâmetros utilizados na aplicação do algoritmo *Forest Based* sem considerar o filtro Perona Malik.

Variável	Treinamento		Validação		Predição		Divisão		
	Mín	Máx	Mín	Máx	Mín	Máx	Treina mento	Validação	Predi ção
CTIN	-15,07	12,83	-14,60	11,59	-40,92	14,88	1,00	0,94	2,00+
LS	-17,42	2,78	-17,42	2,71	-18,48	3,47	1,00	1,00	1,09+
Fluxo acumulado	0,00	9,05	0,00	8,79	0,00	10,77	1,00	0,97	1,19+
P	0,00	12,04	0,00	11,35	0,00	13,80	1,00	0,94	1,15+
TANG	-0,72	0,37	-0,40	0,17	-1,08	0,56	1,00	0,52	1,50+
TPI	-18,46	11,72	-18,67	10,23	-28,85	20,66	0,99	0,95	1,64+
TRI	0,00	10,91	0,00	11,46	0,00	40,51	40,51	1,05	3,71+

Tabela 17 - Diagnóstico dos parâmetros utilizados na utilização do algoritmo *Forest Based* com aplicação do filtro Perona Malik.

Variável	Treinamento		Validação		Predição		Divisão		
	Mín	Máx	Mín	Máx	Mín	Máx	Treina mento	Validação	Predi ção
CTIN	-14,83	12,60	-13,69	10,11	-17,52	45,70	1,00	0,87	2,30+
LS	-17,42	2,88	-17,42	2,53	-18,47	3,78	1,00	0,98	1,10+
Fluxo acumulado	0,00	9,29	0,00	9,25	0,00	11,51	1,00	1,00	1,24+
P	0,00	12,13	0,00	11,99	0,00	14,04	1,00	0,99	1,16+
TANG	-0,50	0,26	-0,28	0,16	-0,66	0,49	1,00	0,57	1,49+
TPI	0,00	9,26	0,00	9,37	0,00	40,14	0,99	1,01	4,33+
TRI	-18,53	11,60	-18,44	10,09	-27,82	20,43	1,00	0,95	1,60+

Tabela 18 - Diagnóstico dos parâmetros utilizados na utilização do algoritmo *Gradient Boosting* sem aplicação do filtro Perona Malik.

Variável	Treinamento	Validação	Predição	Divisão
----------	-------------	-----------	----------	---------

	Mín	Máx	Mín	Máx	Mín	Máx	Treina mento	Validação	Predi ção
CTIN	-15,07	12,83	-14,17	11,10	-40,92	14,88	1,00	0,91	2,00+
LS	-17,42	2,78	-17,42	2,59	-18,48	3,47	1,00	0,99	1,09+
Fluxo acumulado	0,00	9,05	0,00	8,78	0,00	10,77	1,00	0,97	1,19+
P	0,00	12,04	0,00	11,24	0,00	13,80	1,00	0,93	1,15+
TANG	-0,72	0,37	-0,61	0,24	-1,08	0,56	1,00	0,78	1,50+
TPI	-18,67	11,40	-18,46	11,72	-28,85	20,66	0,99	0,99	1,65+
TRI	0,00	11,46	0,00	10,91	0,00	40,51	1,00	0,95	3,53+

Tabela 19 - Diagnóstico dos parâmetros utilizados na utilização do algoritmo *Gradient Boosting* com aplicação do filtro Perona Malik.

Variável	Treinamento		Validação		Predição		Divisão		
	Mín	Máx	Mín	Máx	Mín	Máx	Treina mento	Validação	Predi ção
CTIN	-14,83	12,60	-14,67	10,45	-17,52	45,70	1,00	0,92	2,30+
LS	-17,42	2,88	-17,42	2,35	-18,47	3,78	1,00	0,97	1,10+
Fluxo acumulado	0,00	9,29	0,00	8,94	0,00	11,51	1,00	0,96	1,24+
P	0,00	12,13	0,00	11,75	0,00	14,04	1,00	0,97	1,16+
TANG	-0,50	0,26	-0,39	0,12	-0,66	0,49	1,00	0,66	1,49+
TPI	0,00	9,37	0,00	8,30	0,00	40,14	1,00	0,89	4,28+
TRI	-18,47	11,34	-18,53	11,60	-27,82	20,43	0,99	1,01	1,62+

Em relação aos resultados estatísticos do processamento, assim como ocorreu com o mapeamento das áreas úmidas, o mapeamento das áreas suscetíveis a processos erosivos lineares com a utilização dos algoritmos FB e GB demonstrou que os resultados melhoram tanto com a utilização do filtro PM no dado de entrada, quanto quando comparados os dois algoritmos, sendo os melhores resultados encontrados com a aplicação do GB, chegando a uma acurácia de 0,95 (Figura 24 e Tabela 20, 21, 22, 23, 24, 25, 26 e 27).

Vale salientar que em todos os testes, os resultados dos dados de treinamento sempre são melhores que o resultado na validação dos dados, uma vez que este último considera toda a área teste. Além disso, os resultados do *F1 Score* para as áreas de código 0 (áreas não compostas por processos erosivos lineares) são sempre melhores que das áreas com processos erosivos lineares, fato que se deve pela simplicidade e facilidade de detecção das áreas que não apresentam processos erosivos lineares.

Tabela 20 - Estatísticas do processamento das áreas suscetíveis a processos erosivos lineares utilizando o algoritmo *Forest Based* no MDT sem filtro Perona Malik (treinamento).

Classe	F1-Score	MCC	Sensitividade	Acurácia
0	0,96	0,83	0,93	0,94
1	0,86	0,83	0,99	0,94

Tabela 21 - Estatísticas do processamento das áreas suscetíveis a processos erosivos lineares utilizando o algoritmo *Forest Based* no MDT sem filtro Perona Malik (validação).

Classe	F1-Score	MCC	Sensitividade	Acurácia
0	0,91	0,59	0,87	0,86
1	0,67	0,59	0,80	0,86

Tabela 22 - Estatísticas do processamento das áreas suscetíveis a processos erosivos lineares utilizando o algoritmo *Forest Based* no MDT com o filtro Perona Malik (treinamento).

Classe	F1-Score	MCC	Sensitividade	Acurácia
0	0,96	0,84	0,93	0,94
1	0,87	0,84	0,99	0,94

Tabela 23 - Estatísticas do processamento das áreas suscetíveis a processos erosivos lineares utilizando o algoritmo *Forest Based* no MDT com o filtro Perona Malik (validação).

Classe	F1-Score	MCC	Sensitividade	Acurácia
0	0,91	0,61	0,87	0,86
1	0,68	0,61	0,80	0,86

Tabela 24 - Estatísticas do processamento das áreas suscetíveis a processos erosivos lineares utilizando o algoritmo *Gradiente Boosting* no MDT sem filtro Perona Malik (treinamento).

Classe	F1-Score	MCC	Sensitividade	Acurácia
0	1,00	0,99	1,00	1,00
1	0,99	0,99	0,98	1,00

Tabela 25 - Estatísticas do processamento das áreas suscetíveis a processos erosivos lineares utilizando o algoritmo *Gradiente Boosting* no MDT sem filtro Perona Malik (validação).

Classe	F1-Score	MCC	Sensitividade	Acurácia
0	0,97	0,82	0,89	0,95
1	0,85	0,82	0,81	0,95

Tabela 26 - Estatísticas do processamento das áreas suscetíveis a processos erosivos lineares utilizando o algoritmo *Gradiente Boosting* no MDT com filtro Perona Malik (treinamento).

Classe	F1-Score	MCC	Sensitividade	Acurácia
0	1,00	0,99	1,00	1,00
1	0,99	0,99	0,99	1,00

Tabela 27 - Estatísticas do processamento das áreas suscetíveis a processos erosivos lineares utilizando o algoritmo *Gradiente Boosting* no MDT com filtro Perona Malik (validação).

Classe	F1-Score	MCC	Sensitividade	Acurácia
0	0,97	0,83	0,98	0,95
1	0,86	0,83	0,84	0,95




Figura 24 – Detalhe da comparação entre os algoritmos FB (A e C) e GB (B e D), com e sem a aplicação do filtro Perona Malik no MDT para predição de áreas suscetíveis ao desenvolvimento de processos erosivos lineares (áreas escuras).

4.3. Mapeamento dos processos erosivos lineares inserindo parâmetros das áreas úmidas

O mapeamento das áreas úmidas é importante devido à incidência de processos erosivos lineares envolvendo esses ecossistemas, especialmente em suas áreas limítrofes, uma vez que os processos erosivos podem se iniciar nos limiares das variáveis utilizadas no mapeamento das áreas úmidas, como as mais altas declividades e as áreas com solos menos úmidos. Portanto, a utilização dos parâmetros de áreas úmidas consiste na possibilidade de surgimento de processos erosivos lineares nesse tipo de ecossistema. A Figura 25 ilustra essa situação, de um processo erosivo linear que se inicia no limite de uma área úmida (em área não úmida) e se estende até dentro da área úmida.




Figura 25 – Exemplo de processo erosivo linear que tem início fora de uma área úmida e se desenvolve para seu interior.

Considerando o Teste 3 do fluxograma da Figura 17, o teste da acurácia no mapeamento dos processos erosivos lineares a partir da inserção dos parâmetros de detecção das áreas úmidas (curvatura em planta, TWI e DTW) indicou que, independentemente do algoritmo (FB ou GB), a utilização dessas variáveis acrescidas às demais aumenta a capacidade de mapeamento das áreas suscetíveis. Os valores de F1 aumentam, assim como a sensibilidade, demonstrando que o conjunto de dados apresentam menos falsos positivos com a utilização dos parâmetros, levando a uma acurácia maior no mapeamento geral, como comprovado nos dados de validação apresentados na Tabela 28.


Tabela 28 – Estatísticas dos dados de validação para o teste utilizando os parâmetros de áreas úmidas.

FOREST-BASED - MDT ORIGINAL				
Classe	F1-Score	MCC	Sensitividade	Acurácia
0	0,97	0,83	0,98	0,95
1	0,86	0,83	0,84	0,95
FOREST-BASED – PM				
Classe	F1-Score	MCC	Sensitividade	Acurácia
0	0,92	0,66	0,89	0,88
1	0,72	0,66	0,84	0,88
GRADIENT BOOSTING - MDT ORIGINAL				
Classe	F1-Score	MCC	Sensitividade	Acurácia
0	0,98	0,89	0,99	0,97
1	0,91	0,89	0,89	0,97
GRADIENT BOOSTING – PM				
Classe	F1-Score	MCC	Sensitividade	Acurácia
0	0,99	0,92	0,99	0,98
1	0,93	0,92	0,90	0,98

Quando comparados os resultados com e sem a inserção dos parâmetros de áreas úmidas, as estatísticas demonstram incremento na acurácia do mapeamento. Considerando apenas o algoritmo GB, com aplicação do filtro PM, que apresentou melhor performance nos testes anteriores, a acurácia do mapeamento chega a 98% (Figura 26, Tabela 29).

Tabela 29 – Comparação entre as estatísticas do mapeamento com e sem a inserção dos parâmetros de áreas úmidas, considerando o algoritmo GB com aplicação do filtro PM.

Sem parâmetros de áreas úmidas			
F1	MCC	Sensitividade	Acurácia
0,97	0,83	0,98	0,95
0,86	0,83	0,84	0,95
Com parâmetros de áreas úmidas			
F1	MCC	Sensitividade	Acurácia
0,99	0,92	0,99	0,98
0,93	0,92	0,99	0,98



Gradient Boosted
MDT/Perona Malik - Sem área úmida



Gradient Boosted
MDT/Perona Malik - Com área úmida

Figura 26 – Detalhe da comparação entre o mapeamento com e sem a inserção dos parâmetros de áreas úmidas, considerando apenas o algoritmo GB, com aplicação do filtro PM.

É possível verificar na Tabela 30, que o algoritmo GB classificou como classe 1 (áreas com potencial erosivo) um percentual menor de pixels que o algoritmo FB e mesmo assim, de acordo com o F1 score, obteve melhor resultado, ou seja, definiu uma área menor de áreas susceptíveis e teve um maior grau de acerto.

Tabela 30 – Percentual de pixels classificados como classe 1 (processos erosivos lineares) e resultado estatístico *do F1 Score*.

Algoritmo	F1 score		Percentual de pixels classificados como classe 1 (áreas com potencial erosivo) da área total
	0	1	
Gradient Boosting_MDT_3m	0.97	0.85	25.21%
Forest Based_MDT_3m	0.91	0.67	33.86%
Gradient Boosting_MDT_com_AU_3m	0.98	0.91	24.82%
Forest Based_MDT_com_AU_3m	0.92	0.71	29.42%
Gradient Boosting_MDT_3m_PM	0.97	0.86	26.65%
Forest Based_MDT_3m_PM	0.91	0.68	35.80%
Gradient Boosting_MDT_com_AU_3m_PM	0.99	0.93	25.97%
Forest Based_MDT_com_AU_3m_PM	0.92	0.72	31.47%

AU (área úmida) – PM (Perona Malik)

4.4. Mapeamento de áreas susceptíveis ao desenvolvimento de processos erosivos na área teste com resolução de 0,5 metros

De posse dos melhores resultados dos testes metodológicos, foram definidos os parâmetros mais adequados para o mapeamento das áreas susceptíveis ao desenvolvimento de processos erosivos, são eles:

- Aplicação do filtro Perona Malik no MDT original;
- Utilização do algoritmo *Gradient Boosting*;
- Inserção das variáveis de mapeamento das áreas úmidas junto às variáveis de mapeamento mais utilizadas na bibliografia consultada para mapeamento de áreas susceptíveis ao desenvolvimento de processos erosivos.

Assim, procedeu-se ao último teste metodológico, ainda na área teste, relacionado à melhora na resolução espacial do dado de entrada, aplicando esses parâmetros a um MDT com resolução de 0,5 metro, que demonstraram melhora na capacidade de identificação das áreas susceptíveis à medida que a resolução espacial do MDT foi aumentada de 3m para 0,5m, (Jiang *et al.*, 2020; López-Tapia *et al.*, 2021).

As estatísticas mostram que os valores de todos os parâmetros melhoram com uma resolução espacial maior, desde o F1, a sensibilidade, até

a acurácia, todos eles chegando a próximo de 1, indicando o alto desempenho do modelo (Tabela 31).

Tabela 31 – Estatísticas dos dados de validação no mapeamento das áreas suscetíveis a processos erosivos lineares com utilização do MDT com resolução de 0,5m, aplicando o filtro PM e o algoritmo GB

Classe	F1-Score	MCC	Sensitividade	Acurácia
0	1,00	0,98	1,00	0,99
1	0,98	0,98	0,98	0,99

Quando comparados os mapeamentos na resolução de 3m e de 0,5m, os dados indicam sensível melhora do F1-Score de 93 para 99%, além de visível melhora na definição espacial das áreas suscetíveis, corroborando a indicação de uso de MDT com melhor resolução espacial (Figura 27).




Figura 27 - Comparação entre os dados processados com base no MDT com resolução de 3 metros (A) e 0,5 metros (B).

Desta forma, considerando os valores de *F1 Score* e acurácia de todo o fluxograma de processamento, pode-se observar o aumento na precisão do mapeamento dos processos erosivos lineares à medida que vão integrando-se o filtro Perona Malik ao MDT, algoritmos diferentes (FB e GB), parâmetros de

mapeamento de área úmida, além do aumento na resolução espacial do dado de entrada, como mostram as Figura 28 e Figura 29.





Figura 28 – Fluxograma de crescimento da acurácia nas etapas de processamento no mapeamento das áreas suscetíveis à processos erosivos lineares.



Onde,

Eixo x (nível de processamento):

1 = Processos erosivos lineares - Forest-Based - MDT 3 metros original

2 = Processos erosivos lineares - Forest-Based - MDT 3 metros PM

3 = Processos erosivos lineares - Gradient Boosting - MDT 3 metros original

4 = Processos erosivos lineares - Gradient Boosting - MDT 3 metros PM

5 = Processos erosivos lineares com parâmetros de áreas úmidas - Gradient Boosting – MDT 3 metros PM

6 = Processos erosivos lineares com parâmetros de áreas úmidas - Gradient Boosting – MDT 0,5 metro PM

Figura 29 – Gráfico dos valores de F1 e Acurácia dos diversos níveis de processamento.

4.5. Mapeamento de áreas susceptíveis ao desenvolvimento de processos erosivos em toda a área urbana no Distrito Federal

Seguindo os procedimentos que forneceram os melhores resultados, foi elaborado o mapa final de “Áreas Suscetíveis ao Desenvolvimento de Processos Erosivos Lineares em toda a área urbana do Distrito Federal”, utilizando os seguintes parâmetros:

- MDT com resolução de 1m filtrado com o Perona Malik (devido a limitação de 2 bilhões de pixels do ArcGis Pro 3.2, só foi possível elaborar o mapa final com 1 metro de resolução espacial);
- Algoritmo *Gradient Boosting*;
- Inserção dos parâmetros para o mapeamento das áreas úmidas junto aos demais parâmetros (Figura 30).
- Parâmetros utilizados para elaboração do mapeamento dos processos erosivos lineares: MDT com resolução de 1 metro com filtro Perona Malik; utilizando sete variáveis (curvatura tangente, fluxo acumulado, TPI, CTIN, TRI, LS e P) (Figura31).

A Figura 32 mostra o resultado do mapeamento de toda a área urbana do Distrito Federal, onde a classe 1 representa as áreas susceptíveis a ocorrência de processos erosivos lineares.




Figura 30 - Variáveis de mapeamento das áreas úmidas a partir de MDT com resolução de 1 metro e filtro Perona Malik: (A) Curvatura em planta; (B) TWI; (C) DTW; (D) Abrangência da área.




Figura 31 - Parâmetros gerados a partir de MDT com resolução de 1 metro e filtro Perona Malik (A) Curvatura tangente; (B) TRI; (C) Fluxo acumulado; (D) LS; (E) TPI; (F) P; (G) CTIN; (H) Abrangência da área.




Figura 32 – Mapa de previsão de áreas susceptíveis a processos erosivos lineares da área urbana do Distrito Federal.

Esse resultado binário (área suscetível – 1, não área suscetível – 0) se mostra de enorme aplicabilidade para os gestores públicos, uma vez que consegue indicar com alto grau de acerto todas as áreas com possibilidade de desenvolvimento de processos erosivos lineares.

5. DISCUSSÃO

A obtenção de dados precisos a respeito da suscetibilidade à erosão linear continua sendo um desafio para gestores e planejadores de uso da terra. Para enfrentar esta situação, os pesquisadores têm se debruçado na proposição de modelos que possam identificar locais susceptíveis a ocorrência de processos erosivos em diversas regiões do planeta. Neste artigo, foram avaliados dois algoritmos, o *Forest Based* e o *Gradient Boosting*, que se baseiam em modelos de previsão utilizando a combinação de parâmetros morfométricos gerados a partir de MDTs com 3, 1 e 0,5 metros de resolução espacial.

Pode-se observar que, além da utilização do filtro Perona Malik no dado de entrada trazer melhores resultados, o algoritmo *Gradiente Boosting* se destacou na previsão dessas áreas, corroborando com trabalhos que utilizaram Aprendizagem de Máquina, como Chen *et al.* (2021), que testou algoritmos para o mapeamento de processos erosivos em Meimand, no Irã, incluindo o *Boosted Tree* (BT), *Boosted Generalized Linear Models* (BGLM), *Boosted Regression Tree* (BRT), *Extreme Gradient Boosting* (XGB) e *Deep Boost* (DB), sendo o último um algoritmo de aprendizagem profunda - *Deep Learning*. O autor encontrou que o método DB apresentou um desempenho um pouco maior (AUC = 0,95) do que as abordagens BT (AUC = 0,93), BGLM (AUC = 0,91), BRT (AUC = 0,94) e XGB (AUC = 0,92), sendo possível inferir que o algoritmo XGB, o mesmo utilizado na presente pesquisa, obteve apenas 0,3% a menos de acurácia que o algoritmo de aprendizagem profunda.

Assim, o trabalho no DF demonstrou alto desempenho na previsão de áreas susceptíveis a deflagração de processos erosivos lineares e o algoritmo *Gradiente Boosting* executou essas previsões com rapidez e eficiência mesmo com uma quantidade limitada de amostras, uma vez que as amostras de processos erosivos lineares mapeados são cicatrizes de processos que já

aconteceram. Esse resultado demonstra que, mesmo com amostragem reduzida, a porcentagem de acerto foi altíssima.

No que diz respeito à resolução espacial do dado de entrada, a bibliografia consultada demonstra que a maioria dos MDTs utilizados nas pesquisas são de média resolução, como do sensor ALOS, com 12,5m (ARABAMERI *et al.*, 2020b; ARABAMERI *et al.*, 2020^a, ARABAMERI *et al.*, 2020c; ARABAMERI *et al.*, 2021;; NHU *et al.*, 2020; BAND *et al.*, 2020; YANG *et al.*, 2021; SAHA *et al.*, 2021; AMARE *et al.*, 2021) ou do Shuttle Radar Topography Mission - SRTM e LANDSAT, com 30m (ARABAMERI *et al.*, 2019; ARABAMERI; PRADHAN; REZAEI, 2019; REZA *et al.*, 2020; GHORBANZADEH *et al.*, 2020; RAIKWAR, 2021; CHOWDHURI *et al.*, 2021; AHMADPOUR *et al.*, 2021; BUSCH *et al.*, 2021; HEMBRAM *et al.*, 2021). Assim, foi demonstrado que a resolução espacial influencia na melhora dos resultados e, quanto mais alta a resolução espacial, melhor o desempenho dos modelos aplicados. Além disso, à medida que se diminui o pixel, melhor é a capacidade de acerto do método, bem como menor a área identificada como susceptível. Por este motivo a utilização de dados com 3m, 1,5m e 0,5m comprova a melhoria dos resultados à medida que a resolução aumenta.

Os índices TWI, DTW e Curvatura em planta utilizados para o mapeamento das áreas úmidas e aplicados no processo de mapeamento de áreas susceptíveis a processos erosivos foi decisivo. Em todos os resultados obtidos na área teste houve o aumento do desempenho tanto do algoritmo *Forest Based* quanto do algoritmo *Gradient Boosting*, demonstrando que os processos erosivos estão intimamente relacionados com a presença de áreas úmidas no contexto da paisagem do trabalho. O melhor resultado obtido foi executado pelo algoritmo *Gradient Boosting*, chegando a uma acurácia de 0,98%, demonstrando melhora significativa com a utilização dos parâmetros, garantindo assim maior precisão nas previsões.

A capacidade de predição de um modelo está intimamente relacionada ao tamanho da área que ele irá considerar como susceptível a ocorrência de um fenômeno, no caso aqui a deflagração de processos erosivos. A maioria dos mapas de susceptibilidade são elaborados dividindo-se em classes de alta, média, baixa susceptibilidade (AMARE *et al.*, 2021; POLOVINA *et al.*, 2021;

RAHMATI *et al.*, 2022). Os diversos testes elaborados na pesquisa levaram o mapa final a um alto grau de acerto, isso permitiu que o mapa final fosse apresentado de forma binária, ou seja, a área é ou não susceptível. Essa forma de predição auxilia muito mais o planejamento de uso e ocupação do solo, possibilitando evitar ou mitigar os avanços dos processos erosivos de maneira localizada, sendo uma informação promissora para a realização de um ordenamento territorial.

6. CONCLUSÃO

Este estudo utilizou parâmetros morfométricos derivados de MDTs na escala de detalhe para o mapeamento de áreas susceptíveis a processos erosivos lineares no DF por meio da comparação entre dois algoritmos de aprendizagem de máquina: o *Forest Based* e o *Gradiente Boosting*.

A aplicação do filtro Perna Malik no MDT demonstrou que sua técnica de suavização não linear de imagens reduz o ruído e preserva detalhes importantes do MDT, aumentando a porcentagem de acertos e a acurácia dos modelos aplicados.

Tanto os algoritmos Forest Based quanto o Gradient Boosting, utilizando como parâmetros de entrada os índices DTW, TWI e curvatura em planta, obtiveram resultados satisfatórios quanto à delimitação de áreas úmidas, demonstrando que ambos são capazes de construir mapas de previsão de área desse tipo de ecossistema.

Parâmetros morfométricos derivados do relevo, quando utilizados levando em consideração o seu grau de importância para a confecção de mapas voltados à previsão de processos erosivos, são fontes importantes para representar a dinâmica geomorfológica, demonstrando a eficácia desse tipo de dado associado a estudos ambientais. Os parâmetros de áreas úmidas, quando adicionados ao processamento, aumentaram a precisão e a acurácia dos modelos, sendo fundamentais para um melhor desempenho na previsão de processos erosivos lineares.

A aprendizagem de máquina demonstrou bom desempenho quanto a sua utilização para a previsão de processos erosivos. Isso porque, mesmo diante da limitação referente ao número de amostras de cicatrizes de processos erosivos lineares mapeadas, a previsão das áreas susceptíveis teve alta acurácia e precisão.

Apesar do algoritmo GB ter classificado uma quantidade menor de pixels como áreas com potencial erosivo em comparação ao algoritmo FB, de acordo com o F1 score, o GB obteve um resultado superior. Ou seja, delimitou uma área menor de áreas suscetíveis a processos erosivos lineares e alcançou um maior grau de acerto. Assim, o algoritmo *Gradient Boosting* teve melhor desempenho no mapeamento de processos erosivos lineares, uma vez que apresentou melhores resultados em relação à precisão, acurácia e ao F1 score em todos os testes, além de apresentar maior rapidez de processamento.

Os testes relacionados à resolução espacial do MDT demonstraram que esse parâmetro influencia na acurácia e precisão do mapeamento. Entretanto, o volume de dados em consequência de sua resolução afeta a rapidez do processo e demanda hardwares com maior poder de processamento. Além disso, o trabalho demonstrou a importância da utilização de MDTs hidrologicamente consistentes.

Outro ponto importante do trabalho é que a elaboração de um mapa binário (1 – áreas susceptíveis e 0 – áreas não susceptíveis) com informações de áreas susceptíveis a processos erosivos lineares promove um mapeamento mais assertivo e localizado do que os mapeamentos que rotulam para toda a área categorias de alto, média e baixa susceptibilidade. Isso facilita a atuação dos gestores na formulação de políticas públicas e o planejamento de ações.

Assim, os mapas de susceptibilidade produzidos neste estudo podem ser utilizados para o planejamento do uso e cobertura da terra e gestão do risco de processos erosivos lineares, contribuindo significativamente com os gestores no intuito de minimizar e mitigar o problema de processos erosivos lineares, prevenindo processos futuros e tomando medidas preventivas de posse de dados confiáveis.-

7. REFERÊNCIAS BIBLIOGRÁFICAS

- ADAM, Elhadi M. I.; MUTANGA, O.; RUGEGE, D. Multispectral and hyperspectral remote sensing for identification and mapping of wetland vegetation: a review. **Wetlands Ecology and Management**, [s. l.], v. 18, n. 3, p. 281-296, jun. 2010. DOI: <https://doi.org/s11273-009-9196-z>.
- ADEDIJI, A.; JEJE, L. K.; IBITOYE, M. O. Urban development and informal drainage patterns: gully dynamics in Southwestern Nigeria. **Applied Geography**, [s. l.], v. 40, p. 90-102, jun. 2013. DOI: <https://doi.org/10.1016/j.apgeog.2013.01.012>.
- ADIMASSU, Z.; LANGAN, S.; JOHNSTON, R.; MEKURIA, W.; AMEDE, T.. Impacts of soil and water conservation practices on crop yield, run-off, soil loss and nutrient loss in Ethiopia: review and synthesis. **Environ. Manage.**, [s. l.], v. 59, n. 1, p. 87-101, jan. 2017. DOI: <https://doi.org/10.1007/s00267-016-0776-1>.
- AHMADPOUR, H.; BAZRAFSHAN, O.; RAFIEI-SARDOOI, E.; ZAMANI, H.; PANAGOPOULOS, T.. Gully erosion susceptibility assessment in the Kondoran watershed using machine learning algorithms and the Boruta Feature Selection. **Sustainability**, [s. l.], v. 13, n. 18, 2021. DOI: <https://doi.org/10.3390/su131810110>.
- ALBUQUERQUE, A. O.; CARVALHO JÚNIOR, O. A.; GUIMARÃES, R.F.; GOMES, R. A. T.; HERMUCHE, P. M. Assessment of gully development using geomorphic change detection between pre- and post-urbanization scenarios. **Environmental Earth Sciences**, [s. l.], v. 79, n. 10, p. 1-14, 2020. DOI: <https://doi.org/10.1007/s12665-020-08958-9>.
- ALGANCI, U.; BESOL, B.; SERTEL, E.. Accuracy assessment of different digital surface models. **ISPRS Int. J. Geo-Inf.**, [s. l.], v. 7, n. 3, p. 1-16, 2018. DOI: <https://doi.org/10.3390/ijgi7030114>.
- ALI, Z. A.; ABDULJABBAR, Z. H.; TAHIR, Há. A.; SALLOW, A. B.; ALMUFTI, S. M. Exploring the power of eXtreme Gradient Boosting Algorithm with Machine Learning: a review. **Academic Journal of Nawroz University (AJNU)**, [s. l.], v. 12, n. 2, p. 320-334, 2023. e-ISSN 2520-789X. DOI: <https://doi.org/10.25007/ajnu.v12n2a1612>.
- ALLAN, M. **Remote sensing of Waikato wetlands**: a literature review. Hamilton: Waikato Regional Council, 2016. ISSN 2230-4355. (Waikato Regional Council Technical Report).
- ALLOGHANI, M. A.; OBE, D. A.-J.; MUSTAFINA, J. A systematic review on supervised and unsupervised machine learning algorithms for data science. In: BERRY, Michael W.; MOHAMED, Azlinah; YAP, Bee Wah (Eds.). **Supervised and unsupervised learning for data science**. [S. l.]: Springer, 2020. p. 3-21.
- AMARE, S.; KEESSTRA, S.; VAN DER PLOEG, M.; LANGENDOEN, E.; STEENHUIS, T.; TILAHUN, S. Causes and controlling factors of Valley bottom gullies. **Land**, [s. l.], v. 8, n. 9, p. 1-21, 2019. DOI: <https://doi.org/10.3390/land8090141>.
- AMARE, S.; LANGENDOEN, KEESSTRA, S.; VAN DER PLOEG, M.; GELAGAY, H.; LEMMA, H.; VAN DER ZEE, S. E. A. T. M. Susceptibility to gully erosion: applying Random Forest (RF) and Frequency Ratio (FR) approaches to a small catchment in Ethiopia. **Water**, [s. l.], v. 13, n. 2, p. 1-21, 2021. DOI: <https://doi.org/10.3390/w13020216>.

- ARABAMERI, A.; BLASCHKE, T.; PRADHAN, B.; POURGHASEMI, H. R.; TIEFENBACHER, J. P.; BUI, D. T. Evaluation of recent advanced soft computing techniques for gully erosion susceptibility mapping: a comparative study. **Sensors**, [s. l.], v. 20, n. 20, p. 1-22, 2020b. DOI: <https://doi.org/10.3390/s20020335>.
- ARABAMERI, A.; CERDA, A.; RODRIGO-COMINO, J.; PRADHAN, B.; SOHRABI, M.; BLASCHKE, T.; BUI, D. T. Proposing a novel predictive technique for gully erosion susceptibility mapping in arid and semi-arid regions (Iran). **Remote Sens.**, [s. l.], v. 11, n. 21, p. 1-24, 2019. DOI: <https://doi.org/10.3390/rs11212577>.
- ARABAMERI, A.; CHEN, W.; LOCHE, M.; ZHAO, X.; LI, Y.; LOMBARDO, L.; CERDA, A.; PRADHAN, B.; BUI, D. T. Comparison of machine learning models for gully erosion susceptibility mapping. **Geoscience Frontiers**, [s. l.], v. 11, n. 5, p. 1609-1620, set. 2020a. DOI: <https://doi.org/10.1016/j.gsf.2019.11.009>.
- ARABAMERI, A.; CHEN, W.; LOMBARDO, L.; BLASCHKE, T.; BUI, D. T. Hybrid computational intelligence models for improvement gully erosion assessment. **Remote Sens.**, [s. l.], v. 12, n. 1, 2020c. DOI: <https://doi.org/10.3390/rs120101>.
- ARABAMERI, A.; PAL, S. C.; COSTACHE, R.; SAHA, A.; REZAIE, F.; DANESH, Amir S.; PRADHAN, B.; LEE, S.; HOANG, N.-D. Prediction of gully erosion susceptibility mapping using novel ensemble machine learning algorithms. **Geomatics, Natural Hazards and Risk**, [s. l.], v. 12, n. 1, p. 469-498, 2021. DOI: <https://doi.org/10.1080/19475705.2021.1880977>.
- ARABAMERI, A.; PRADHAN, B.; BUI, D. T. Spatial modelling of gully erosion in the Ardib River Watershed using three statistical-based techniques. **CATENA**, [s. l.], v. 190, jul. 2020. DOI: <https://doi.org/10.1016/j.catena.2020.104545>.
- ARABAMERI, A.; PRADHAN, B.; REZAIE, F. Gully erosion zonation mapping using integrated geographically weighted regression with certainty factor and random forest models in GIS. **Journal of Environmental Management**, [s. l.], v. 232, p. 928-942, fev. 2019. DOI: <https://doi.org/10.1016/j.jenvman.2018.11.110>.
- ARCHIBOLD, O. W.; LÉVESQUE, L. M. J.; DE BOER, D. H.; AITKEN, A. E.; DELANOY, L. Gully retreat in a semi-urban catchment in Saskatoon, Saskatchewan. **Applied Geography**, [s. l.], v. 23, n. 4, p. 261-279, out. 2003. DOI: <https://doi.org/10.1016/j.apgeog.2003.08.005>.
- ASHIQ, W.; VASAVA, H.; GHIMIRE, U.; DUNFIELD, K.; DAGGUPATI, P.; BISWAS, Assim. Seasonal agricultural wetlands act as potential source of N₂O and CH₄ emissions. **CATENA**, [s. l.], v. 213, jun. 2022. DOI: <https://doi.org/10.1016/j.catena.2022.106184>.
- AZEDOU, A.; LAHSSINI, S.; KHATTABI, A.; MELIHO, M.; RIFAI, N. A methodological comparison of three models for gully erosion susceptibility mapping in the rural municipality of El Faid (Morocco). **Sustainability**, [s. l.], v. 13, n. 2, p. 1-30, 2021. DOI: <https://doi.org/10.3390/su13020682>.
- BALOQUE, G. F.; CAPOANE, Vi. Susceptibilidade a erosão do solo na bacia hidrográfica do córrego Bandeira, Campo Grande – MS. **Revista Cerrados**, Montes Claros, MG, v. 19, n. 2, p. 183-217, jul./dez. 2021. ISSN 2448-2692. DOI: <https://doi.org/10.46551/rc24482692202124>.
- BAND, S. S.; JANIZADEH, S.; SAHA, S.; MUKHERJEE, K.; BOZCHALOEI, S. K.; CERDÀ, A.; SHOKRI, M.; MOSAVI, A. Evaluating the efficiency of different

- regression, decision tree, and Bayesian Machine Learning Algorithms in spatial piping erosion susceptibility using ALOS/PALSAR Data. **Land**, [s. l.], v. 9, n. 10, p. 1-23, 2020a. DOI: <https://doi.org/10.3390/land910034>.
- BENTÉJAC, C.; CSÖRGŐ, A. Martínez-Muñoz, G. A comparative analysis of XGBoost. **Artif. Intell. Rev**, v. 54, p. 1937-1967, 2019.
- BERTHIER, E.; ANDRIEU, H.; CREUTIN, J. D. The role of soil in the generation of urban runoff: development and evaluation of a 2D model. **Journal of Hydrology**, [s. l.], v. 299, n. 3-4, p. 252-266, dez. 2004. DOI: <https://doi.org/10.1016/j.jhydrol.2004.08.008>.
- BEVEN, K. J.; KIRKBY, M. J. A physically based, variable contributing area model of basin hydrology. **Hydrological Sciences Bulletin**, [s. l.], v. 24, n. 1, p. 43-69, mar. 1979. ISSN 0303-6936. DOI: <https://doi.org/10.1080/02626667909491834>.
- BEVEN, Keith J.; MOORE, Ian D. (Eds.). **Terrain analysis and distributed modelling in hydrology**. Chichester: Wiley & Sons, 1993. 249 p. ISBN 0471938866.
- BHAT, S. U.; ISLAM, Sheikh T.; KHANDAY, S. A.; SABHA, I.. Understanding morphometric response to erosion and flash floods in Jhelum River Basin: index-based geospatial management approach. **International Journal of Environmental Science and Technology**, [s. l.], v. 19, p. 10157-10175, 2022. DOI: <https://doi.org/10.1007/s13762-021-03701-8>.
- BIAN, L.; MELESSE, A. M.; LEON, A. S.; VERMA, V.; YIN, Z.. A deterministic topographic wetland index based on LiDAR-Derived DEM for delineating open-water wetlands. **Water**, [s. l.], v. 13, p. 1-18, 2021. DOI: <https://doi.org/10.3390/w13182487>.
- BIAS, E. S.; PIVELLO, L.; GUEDES, S. C.; ROCHA, K. C. Análise da eficiência da vegetação no controle do escoamento superficial: uma aplicação na bacia hidrográfica do rio São Bartolomeu, DF. **Geociências**, São Paulo, v. 31, n. 3, p. 411-429, 2012.
- BIGARELLA, J. J.; BECKER, R. D.; SANTOS, G. F. Controle de erosão urbana e periurbana. In: BIGARELLA, João José; BECKER, Rosemari Dora; SANTOS, Gilberto Friedenreich dos. **Estrutura e origem das paisagens tropicais e subtropicais**. 2. ed. ed. Florianópolis: Editora da UFSC, 2007. p. 961-963. v. 3.
- BILLI, P.; DRAMIS, F. Geomorphological investigation on gully erosion in the Rift Valley and the northern highlands of Ethiopia. **CATENA**, [s. l.], v. 50, n. 2-4, p. 353-368, jan. 2003. DOI: [https://doi.org/10.1016/S0341-8162\(02\)00131-5](https://doi.org/10.1016/S0341-8162(02)00131-5).
- BORGES, M. G.; COSTA, L. R. F. Tipologia de áreas úmidas na bacia hidrográfica do rio Pandeiros em Minas Gerais – Brasil. **Caderno de Geografia**, [s. l.], v. 32, n. 69, p. 508-522, 2022. ISSN 2318-2962. DOI: <https://doi.org/10.5752/P.2318-2962.2022v32n69p508>.
- BORRELLI, P.; ALEWELL, C.; ALVAREZ, P.; ANACHE, J. A. A.; BAARTMAN, J.; BALLABIO, C.; BEZAK, N.; BIDDOCU, M.; CERDÀ, A.; CHALISE, D.; CHEN, S.; CHEN, W.; DE GIROLAMO, A. M.; GESSESSE, G. D.; DEUMLICH, D.; DIODATO, N.; EFTHIMIOU, N.; ERPUL, G.; FIENER, P.; FREPPAZ, M.; GENTILE, F.; GERICKE, A.; HAREGEWEYN, N.; HU, B.; JEANNEAU, A.; KAFFAS, K.; KIANI-HARCHEGANI, M.; VILLUENDAS, I. L.; LI, C.; LOMBARDO, L.; LÓPEZ-VICENTE, M.; LUCAS-BORJA, M. E.; MÄRKER, M.; MATTHEWS, F.; MIAO, C.; MIKOŠ, M.; MODUGNO, S.; MÖLLER, M.; NAIPAL, V.; NEARING, M.; OWUSU, S.; PANAGOS, P.; PANDAY, D.; PATAULT, E.; PATRICHE, C. V.; POGGIO, L.; PORTES, R.; QUIJANO, L.; RAHDARI, M. R.;

- RENIMA, M.; RICCI, G. Fr.; RODRIGO-COMINO, J.; SAIA, S.; SAMANI, A. N.; SCHILLACI, C.; SYRRIS, V.; KIM, Hyuck S.; SPINOLA, D. N.; OLIVEIRA, P. T.; TENG, H.; THAPA, R.; VANTAS, K.; VIEIRA, D.; YANG, J. E.; YIN, S.; ZEMA, D. A.; ZHAO, G.. Soil erosion modelling: a global review and statistical analysis. **Science of the Total Environment**, [s. l.], v. 780, p. 1-18, 2021. DOI: <https://doi.org/10.1016/j.scitotenv.2021.146494>.
- BORRELLI, P.; ROBINSON, D. A.; PANAGOS, P.; BALLABIO, C.. Land use and climate change impacts on global soil erosion by water (2015-2070). **PNAS**, [s. l.], v. 117, n. 36, p. 21994-22001, ago 2020. DOI: <https://doi.org/10.1073/pnas.2001403117>.
- BOSINO, A.; SZATTEN, D. A.; OMRAN, A.; CREMA, S.; CROZI, M.; BECKER, Rike; BETTONI, M.; SCHILLACI, C.; MAERKER, M. Assessment of suspended sediment dynamics in a small ungauged badland catchment in the Northern Apennines (Italy) using an in-situ laser diffraction method. **CATENA**, [s. l.], v. 209, fev. 2022. DOI: <https://doi.org/10.1016/j.catena.2021.105796>.
- BOUCHNAK, H.; FELFOUL, M. S.; BOUSSEMA, M. R.; SNANE, M. H. Slope and rainfall effects on the volume of sediment yield by gully erosion in the Souar lithologic formation (Tunisia). **CATENA**, [s. l.], v. 78, n. 2, p. 170-177, ago. 2009. DOI: <https://doi.org/10.1016/j.catena.2009.04.003>.
- BOVIS, M. J.; JAKOB, M. The role of debris supply conditions in predicting debris flow activity. **Earth Surface Processes and Landforms**, [s. l.], v. 24, n. 11, p. 1039-1054, out. 1999. DOI: [https://doi.org/10.1002/\(SICI\)1096-9837\(199910\)24:11<1039::AID-ESP29>3.0.CO;2-U](https://doi.org/10.1002/(SICI)1096-9837(199910)24:11<1039::AID-ESP29>3.0.CO;2-U).
- BREIMAN, Leo. **Random forests**. University of California, Statistics Department, Berkeley, jan. 2001.
- BROŽOVÁ, N.; BAGGIO, T.; D'AGOSTINO, V.; BÜHLER, Y.; BEBI, P.. Multiscale analysis of surface roughness for the improvement of natural hazard modelling. **Natural Hazards and Earth System Sciences**, [s. l.], v. 21, n. 11, p. 3539-3562, 2021. DOI: <https://doi.org/10.5194/nhess-21-3539-2021>.
- BUARQUE, D. C. **Extração automática de parâmetros físicos de bacias hidrográficas a partir do MNT para utilização de modelos hidrológicos**. [S. d.]. Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul, Porto Alegre, [S. d.].
- BURKARD, M. B.; KOSTASCHUK, R. A. Patterns and controls of gully growth along the shoreline of lake huron. **Earth Surface Processes and Landforms**, [s. l.], v. 22, n. 10, p. 901-911, out. 1997. DOI: [https://doi.org/10.1002/\(SICI\)1096-9837\(199710\)22:10<901::AID-ESP743>3.0.CO;2-O](https://doi.org/10.1002/(SICI)1096-9837(199710)22:10<901::AID-ESP743>3.0.CO;2-O).
- BUSCH, R.; HARDT, J.; NIR, N.; SCHÜTT, B. Modeling gully erosion susceptibility to evaluate human impact on a local landscape system in Tigray, Ethiopia. **Remote Sens.**, [s. l.], v. 13, p. 1-19, 2021. DOI: <https://doi.org/10.3390/rs13102009>.
- CARDOSO, M. R D.; MARCUZZO, F. F. N.; BARROS, J. R.. Classificação climática de Köppen-Geiger para o Estado de Goiás e o Distrito Federal. **ACTA Geográfica**, Boa Vista, v. 8, n. 16, p. 40-55, jan./mar. 2014. ISSN 1980-5772. eISSN 2177-4307. DOI: <https://doi.org/10.5654/actageo2014.0004.0016>.
- CARVALHO JÚNIOR, O. A.; GUIMARÃES, R. F.; FREITAS, L. F.; GOMES, D. Urbanization impacts upon catchment hydrology and gully development using mutli-temporal digital elevation data analysis. **Earth Surface Processes and**

- Landforms**, [s. l.], v. 35, n. 5, p. 611-617, abr. 2010. DOI: <https://doi.org/10.1002/esp.1917>.
- CASTILLO, C.; GÓMEZ, J. A. A century of gully erosion research: urgency, complexity and study approaches. **Earth-Science Reviews**, [s. l.], v. 160, p. 300-319, set. 2016. DOI: <https://doi.org/10.1016/j.earscirev.2016.07.009>.
- CHADWICK, J. Integrated LiDAR and IKONOS multispectral imagery for mapping mangrove distribution and physical properties. **International Journal of Remote Sensing**, [s. l.], v. 32, n. 21, p. 6765-6781, 2011. DOI: <https://doi.org/10.1080/01431161.2010.512944>.
- CHATZIANTONIOU, A.; PETROPOULOS, G. P.; PSOMIADIS, E. Co-Orbital Sentinel 1 and 2 for LULC mapping with emphasis on wetlands in a mediterranean setting based on machine learning. **Remote Sens.**, [s. l.], v. 9, n. 12, 2017.
- CHEN, C. Y.; YU, F. C. Morphometric analysis of debris flows and their source areas using GIS. **Geomorphology**, [s. l.], v. 129, n. 3-4, p. 387-397, jun. 2011.
- CHEN, W.; LEI, X.; CHAKRABORTTY, R.; PAL, S. C.; SAHANA, M.; JANIZADEH, S. Evaluation of different boosting ensemble machine learning models and novel deep learning and boosting framework for head-cut gully erosion susceptibility. **Journal of Environmental Management**, [s. l.], v. 284, n. August 2020, p. 112015, 2021.
- CHIROL, C.; CHIROL, C.; HAIGH, I. D.; PONTEE, N.; THOMPSON, C. L.; GALLOP, S. L. Morphological evolution of creek networks in 10 restored coastal wetlands in the UK. **Scientific Data**, [s. l.], v. 9, n. 1, p. 1-16, 2022.
- CHOWDHURI, I.; CHOWDHURI, I.; PAL, S. C.; Saha, A.; CHAKRABORTTY, R.; Roy, P. Evaluation of different DEMs for gully erosion susceptibility mapping using in-situ field measurement and validation. **Ecological Informatics**, [s. l.], v. 65, p. 101425, nov. 2021.
- CHUST, G.; GALPARSORO, I.; BORJA, A.; FRANCO, J.; URIARTE, A. Coastal and estuarine habitat mapping, using LIDAR height and intensity and multi-spectral imagery. **Estuarine, Coastal and Shelf Science**, [s. l.], v. 78, n. 4, p. 633-643, jul. 2008.
- CODEPLAN. Atlas do Distrito Federal 2020: Capítulo 2. 2020. Disponível em: <<https://www.codeplan.df.gov.br/wp-content/uploads/2018/05/Atlas-do-Distrito-Federal-2020-Capítulo-2.pdf>>. Acesso em: 13 ago. 2024.
- CONFORTI, M.; MERCURI, M.; BORRELLI, L. Morphological changes detection of a large earthflow using archived images, lidar-derived dtm, and uav-based remote sensing. **Remote Sensing**, [s. l.], v. 13, n. 1, p. 1-25, 2021.
- CUNHA, M. A.; DA COSTA, S. M. F. Mapeamento da palmeira de açaí (*Euterpe oleracea* Mart.) na floresta Amazônica utilizando imagem de satélite de alta resolução espacial. **Revista Espinhaço**, v. 9, n. 2, p. 40-49, 2020.
- CUNHA, S. B.; GUERRA, A. J. T. (Orgs.). **A questão ambiental**: diferentes abordagens. 10. ed. Rio de Janeiro: Bertrand Brasil, 2003. 250 p. ISBN 9788528609929.
- CUNHA, Sandra Batista da; GUERRA, Antônio José Teixeira. Degradação ambiental. In: GUERRA, Antônio José Teixeira; CUNHA, Sandra Baptista da. (Org.). **Geomorfologia e meio ambiente**. 9. ed. Rio de Janeiro: Bertrand Brasil, 2010. 396 p. p. 337-371. ISBN 9788528605730.
- DE REU, J.; BOURGEOIS, J.; BATS, M.; ZWERTVAEGHER, A.; GELORINI, V.; DE SMEDT, P.; CHU, W.; ANTROP, M.; DE MAEYER, P.; FINKE, P.; VAN MEIRVENNE, M.; VERNIERS, J.; CROMBÉ, P. Application of the topographic

- position index to heterogeneous landscapes. **Geomorphology**, [s. l.], v. 186, p. 39-49, mar. 2013. DOI: <https://doi.org/10.1016/j.geomorph.2012.12.015>.
- DE SCALLY, F.; SLAYMAKER, O.; OWENS, I. Morphometric controls and basin response in the Cascade Mountains. **Geografiska Annaler, Series A: Physical Geography**, [s. l.], v. 83, n. 3, p. 117-130, 2001.
- DENG, L.; ZHU, H.; YANG, Z.; LI, Y. Hessian matrix-based fourth-order anisotropic diffusion filter for image denoising. **Optics and Laser Technology**, [s. l.], v. 110, n. September 2018, p. 184-190, 2019.
- DENG, W.; DENG, W.; HUANG, Z.; ZHANG, J.; XU, J.. A Data Mining Based System for Transaction Fraud Detection. **2021 IEEE International Conference on Consumer Electronics and Computer Engineering, ICCECE 2021**, p. 542-545, 2021.
- DIETRICH, W. E.; WILSON, C. J.; MONTGOMERY, D. R.; MCKEAN, J. Analysis of erosion thresholds, channel networks, and landscape morphology using a digital terrain model. **Journal of Geology**, [s. l.], v. 101, n. 2, p. 259-278, 1993.
- DIGIACOMO, A. E.; DIETRICH, W. E.; WILSON, C. J.; MONTGOMERY, D. R., MCKEAN, J. Modeling salt marsh vegetation height using unoccupied aircraft systems and structure from motion. **Remote Sens.**, [s. l.], v. 12, n. 14, p. 3-6, 2020.
- DISTRITO FEDERAL. Instituto de Pesquisa e Estatística do Distrito Federal. **Atlas do Distrito Federal: caracterização ambiental**. Brasília, DF: IPEDF, 2021.
- DISTRITO FEDERAL. Sistema de Informações sobre Sustentabilidade e Impacto Ambiental - SISDIA. Disponível em: <https://sisdia.df.gov.br/home/repositorio-de-dados/>. Acesso em: 14 ago. 2024.
- DREGNE, H. E. Soil erosion: cause and effect. **Land Use Policy**, [s. l.], v. 4, n. 4, p. 412-418, out. 1987. DOI: [https://doi.org/10.1016/0264-8377\(87\)90063-9](https://doi.org/10.1016/0264-8377(87)90063-9).
- DREISEITL, S.; OHNO-MACHADO, L. Logistic regression and artificial neural network classification models: a methodology review. **Journal of Biomedical Informatics**, [s. l.] v. 35, n. 5-6, p. 352-359, out. 2002. DOI: [https://doi.org/10.1016/S1532-0464\(03\)00034-0](https://doi.org/10.1016/S1532-0464(03)00034-0).
- DRONOVA, I. Object-based image analysis in wetland research: a review. **Remote Sens.**, [s. l.], v. 7, p. 6380-6413, 2015. ISSN 2072-4292. DOI: <https://doi.org/10.3390/rs70506380>.
- DUBE, H. B. A global analysis of the morphology of linear erosion features. **Catena**, v. 190, n. February 2019, p. 104542, 2020.
- DUKU, E.; MATTAH, P. A. D.; ANGNUURENG, D. B. Assessment of land use/land cover change and morphometric parameters in the keta lagoon complex ramsar site, ghana. **Water**, [s. l.], v. 13, n. 18, 2021.
- DUR, H. CÁRCELES RODRÍGUEZ, B.; DURÁN-ZUAZO, V. H.; RODRÍGUEZ, M. S.; GARCÍA-TEJERO, I. F.; Ruiz, B. G.; Távira, S. C. Conservation Agriculture as a Sustainable System for Soil Health: A Review. p. 1-37, 2022.
- EDITORA POISON (Ed.). **Engenharia no século XXI**. Belo Horizonte: Poisson, 2019. v. 10. ISBN 9788570421647.
- EMBRAPA. Sistema Brasileiro de Classificação de Solos (SiBCS). 5. ed. rev. ampl. Brasília, DF: Embrapa, 2018. Disponível em: <https://www.agroapi.cnptia.embrapa.br/portal/assets/docs/SiBCS-2018-ISBN-9788570358004.pdf>. Acesso em: 14 ago. 2024.
- EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA – EMBRAPA. Centro Nacional de Pesquisa de Solos. **Sistema Brasileiro de Classificação**

- de Solos**. Brasília, DF: EMBRAPA Serviço de Produção de Informação; Rio de Janeiro: EMBRAPA Solos, 1999. 412 p.
- EMTEHANI, S.; JETTEN, V.; VAN WESTEN, C.; & SHRESTHA, D. P. Quantifying sediment deposition volume in vegetated areas with UAV data. **Remote Sens.**, [s. l.], v. 13, n. 12, 2021.
- ESRI. *Forest-based classification and regression*. 2023. Disponível em: <<https://pro.arcgis.com/en/pro-app/latest/tool-reference/spatial-statistics/forestbasedclassificationregression.htm>>. Acesso em: 13 ago. 2024.
- FILIN, Sagi. Recovery of systematic biases in laser altimetry data using natural surfaces. **Photogrammetric Engineering & Remote Sensing**, v. 69, n. 11, p. 1235-1242, 2003.
- FILIZOLA, H. F.; ALMEIDA FILHO, G. S.; CANIL, K.; DE SOUZA, M. D. Controle dos processos erosivos em áreas de afloramento do Aquífero Guarani no Brasil. **Embrapa Meio Ambiente-Capítulo em livro científico (ALICE)**, 2008.
- FONSECA, Cláudia Adriana Bueno da; AL-ANSARI, Nadhir; SILVA, Richarde Marques da; SANTOS, Celso Augusto Guimarães; ZEROUALI, Bilel; OLIVEIRA, Daniel Bezerra de; ELBELTAGI, Ahmed. Investigating relationships between Runoff–Erosion processes and land use and land cover using remote sensing multiple gridded datasets. **ISPRS Int. J. Geo-Inf.**, [s. l.], v. 11, p. 1-27, 2022. DOI: <https://doi.org/10.3390/ijgi11050272>.
- FRIEDMAN, J. H. Greedy function approximation: a gradient boosting machine. **Annals of Statistics**, [s. l.], v. 29, n. 5, p. 1189-1232, 2001.
- FRIEDMAN, J. H. Stochastic gradient boosting. **Computational Statistics and Data Analysis**, [s. l.], v. 38, n. 4, p. 367-378, 2002.
- FROHN, R. C. ; AUTREY, B. C.; LANE, C. R.; & REIF, M. Segmentation and object-oriented classification of wetlands in a karst Florida landscape using multi-season Landsat-7 ETM+ imagery. **International Journal of Remote Sensing**, [s. l.], v. 32, n. 5, p. 1471-1489, 2011.
- FURMAN, A. Modeling Coupled Surface–Subsurface Flow Processes: A Review. **Vadose Zone Journal**, [s. l.], v. 7, n. 2, p. 741-756, 2008.
- GALLANT, A. L. The challenges of remote monitoring of wetlands. **Remote Sensing**, v. 7, n. 8, p. 10938-10950, 2015.
- GANAI, M. A., Hu, M., Malik, A. K., Tanveer, M., & Suganthan, P. N. Ensemble deep learning: A review. **Engineering Applications of Artificial Intelligence**, v. 115, p. 105151, 2022.
- Geoportal: Plataforma de informações geográficas. 2023. Disponível em: <<https://www.geoportal.com>>. Acesso em: 13 ago. 2023.
- GHOLAMI, V.; SAHOUR, H.; HADIAN AMRI, M. A. Soil erosion modeling using erosion pins and artificial neural networks. **CATENA**, [s. l.], v. 196, p. 104902, jan. 2021.
- GHORBANZADEH, O.; SHAHABI, H.; MIRCHOOI, F.; VALIZADEH KAMRAN, K.; LIM, S.; ARYAL, J.; BLASCHKE, T. 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**, [s. l.], v. 11, n. 1, p. 1653-1678, 2020.
- GHUNOWA, K.; MACVICAR, B. J.; ASHMORE, P. Stream power index for networks (SPIN) toolbox for decision support in urbanizing watersheds. **Environmental Modelling & Software**, [s. l.], v. 144, p. 105185, out. 2021.

- GONÇALVES, M. B.; DA COSTA, L. R. F. TIPOLOGIA DE ÁREAS ÚMIDAS NA BACIA HIDROGRÁFICA DO RIO PANDEIROS EM MINAS GERAIS – BRASIL. **Caderno de Geografia**, v. 32, n. 69, p. 508-522, 2022.
- GREGORY, K. J. Changing Drainage Basins Author (s): K. J. Gregory
Published by : geographicalj Stable URL : <http://www.jstor.org/stable/1796598>
REFERENCES Linked references are available on JSTOR for this article: You may need to log in to JSTOR to access the linke. **The Royal Geographical Society**, [s. l.], v. 142, n. 2, p. 237-247, 1976.
- GUAN, H.; JI, Z.; ZHONG, L.; LI, J.; REN, Q. Partially supervised hierarchical classification for urban features from lidar data with aerial imagery. **International Journal of Remote Sensing**, [s. l.], v. 34, n. 1, p. 190-210, 2013.
- GUELMAN, L. Gradient boosting trees for auto insurance loss cost modeling and prediction. **Expert Systems with Applications**, [s. l.], v. 39, n. 3, p. 3659-3667, 2012.
- GUERRA, A. J. T.; JORGE, M. D. C. O.; RANGEL, L. D. A.; BEZERRA, J. F. R.; LOUREIRO, H. A. S.; & GARRITANO, F. D. N. Soil Erosion, Different Approaches And Techniques Applied to Gullies and Trail Erosion. **William Morris Davis-Revista de Geomorfologia**, [s. l.], v. 1, n. 1, p. 75-117, 2020.
- GUERRA, A. J. T. Encostas urbanas. Em: **Geomorfologia urbana**. Rio de Janeiro: Bertrand Brasil, 2011.
- GUERRA, A. J. T. O papel da matéria orgânica e dos agregados na erodibilidade dos solos. **Anuário do Instituto de Geociências**, [s. l.], v. 13, p. 43-52, 1990.
- GUERRA, A. J. T.; BEZERRA, J. F. R.; JORGE, M. DO C. O. Recovery of gullies and degraded areas in Brazil and worldwide - case study of the Sacavém gully - São Luís – MA. **Revista Brasileira de Geomorfologia**, [s. l.], v. 24, 2023.
- GUERRA, A. J. T.; JORGE, M. DO C. O. Geomorfologia Do Cotidiano – a Degradação Dos Solos. **Revista Geonorte**, [s. l.], v. 4, p. 116-135, 2012.
- GUIMARAES, R. F.; MONTGOMERY, D. R.; GREENBERG, H. M.; FERNANDES, N. F.; GOMES, R. A. T.; de Carvalho Júnior, O. A. Parameterization of soil properties for a model of topographic controls on shallow landsliding: Application to Rio de Janeiro. **Engineering Geology**, [s. l.], v. 69, n. 1-2, p. 99–108, 2003.
- GUO, M.; LI, J.; SHENG, C.; XU, J.; WU, L. A review of wetland remote sensing. **Sensors**, [s. l.], v. 17, n. 4, p. 1-36, 2017.
- GURNELL, A.; LEE, M.; SOUCH, C. Urban Rivers: Hydrology, Geomorphology, Ecology and Opportunities for Change. **Geography Compass**, [s. l.], v. 1, n. 5, p. 1118-1137, set. 2007.
- GUTH, P. L. VAN NIEKERK, A.; GROHMANN, C. H.; MULLER, J. P.; HAWKER, L.; FLORINSKY, I. V.; GESCH, D.; REUTER, H. I.; HERRERA-CRUZ, V.; RIAZANOFF, S.; LÓPEZ-VÁZQUEZ, C.; CARABAJAL, C. C.; ALBINET, C.; STROBL, P. Strobl, P. Digital elevation models: terminology and definitions. **Remote Sensing**, [s. l.], v. 13, n. 18, p. 1-19, 2021.
- HAMMER, D. A. (Ed.). **Constructed wetlands for wastewater treatment: municipal, industrial and agricultural**. Boca Raton: CRC Press, 2020. 856 p. ISBN 9781003069850.
- HELLWEGER, F. L.; MAIDMENT, D. R. **HEC-PREPRO**: um pré-processador GIS para programas de modelagem hidrológica de parâmetros concentrados. [S. l.]: [s. n.], 1997.

- HEMBRAM, T. K.; SAHA, S.; PRADHAN, B.; ABDUL MAULUD, K. N.; ALAMRI, A. M. Robustness analysis of machine learning classifiers in predicting spatial gully erosion susceptibility with altered training samples. **Geomatics, Natural Hazards and Risk**, [s. l.], v. 12, n. 1, p. 794-828, 2021.
- HENDERSON, F. M.; LEWIS, A. J. Radar detection of wetland ecosystems: a review. **International journal of remote sensing**, v. 29, n. 20, p. 5809-5835, 2008.
- HENRIQUE H. G.; BINGNER, R. L.; WELLS, R. R.; RIGBY, J. R.; DABNEY, S. M. Effect of Topographic Characteristics on Compound Topographic Index for Identification of Gully Channel Initiation Locations. **Transactions of the ASABE**, [s. l.], v. 56, n. 2, p. 523-537, 2013.
- HINDERSAH, R.; HANDYMAN, Z.; INDRIANI, F. N.; SURYATMANA, P.; NURLAENY, N. Azotobacter population, soil nitrogen and groundnut growth in mercury-contaminated tailing inoculated with Azotobacter. **J. Degrade. Min. Land Manage**, [s. l.], v. 5, n. 53, p. 2502-2458, 2018.
- HITOURI, S. VARASANO, A.; MOHAJANE, M.; IJLIL, S.; ESSAHLAOUI, N.; ALI, S. A.; ESSAHLAOUI, A.; PHAM, Q. B.; WALEED, M.; PALATEERDHAM, S. K.; TEODORO, A. C. Hybrid Machine Learning Approach for Gully Erosion Mapping Susceptibility at a Watershed Scale. **ISPRS International Journal of Geo-Information**, [s. l.], v. 11, n. 7, 2022.
- HOLANDA LEITE, M. J. DE. Características gerais dos principais solos da região semiárida. **RECIMA21 - Revista Científica Multidisciplinar - ISSN 2675-6218**, v. 3, n. 10, p. e3101964, 12 out. 2022.
- HRABALÍKOVÁ, M.; JANEČEK, M. Comparison of different approaches to Is factor calculations based on a measured soil loss under simulated rainfall. **Soil and Water Research**, [s. l.], v. 12, n. 2, p. 69-77, 2017.
- HU, S.; NIU, Z.; CHEN, Y.; LI, L.; & ZHANG, H. Global wetlands: Potential distribution, wetland loss, and status. **Science of the Total Environment**, [s. l.], v. 586, p. 319-327, maio 2017.
- IKEDA-CASTRILLON, S. K.; OLIVEIRA-JUNIOR, E. S.; ROSSETTO, O. C.; SAITO, C. H.; WANTZEN, K. M. The Pantanal: A Seasonal Neotropical Wetland Under Threat. Em: **The Palgrave Handbook of Global Sustainability**. [S. l.] Springer International Publishing, 2022. p. 1-27.
- IMWANGANA, Fils Makanzu; DEWITTE, Olivier; NTOMBI, Médard; MOEYERSONS, Jan. Topographic and road control of mega-gullies in Kinshasa (DR Congo). **Geomorphology**, [s. l.], v. 217, p. 131-139, jul. 2014. DOI: <http://dx.doi.org/10.1016/j.geomorph.2014.04.021>.
- INFASCELLI, R.; FAUGNO, S.; PINDOZZI, S.; BOCCIA, L.; MEROT, P.. Testing Different Topographic Indexes to Predict Wetlands Distribution. **Procedia Environmental Sciences**, [s. l.], v. 19, p. 733-746, 2013.
- Instituto Brasileiro de Geografia e Estatística - IBGE. Censo Demográfico 2020. Disponível em: <https://www.ibge.gov.br/estatisticas/sociais/trabalho/9663-censo-demografico-2000.html?edicao=9861> . Acesso em: 14 ago. 2024.
- JARRAH, M.; MAYEL, S.; TATARKO, J.; FUNK, R.; KUKA, K. A review of wind erosion models: Data requirements, processes, and validity. **CATENA**, [s. l.], v. 187, n. March 2019, p. 104388, 2020.
- JEONG, A.; DORN, R. I. Soil erosion from urbanization processes in the Sonoran Desert, Arizona, USA. **Land Degradation and Development**, [s. l.], v. 30, n. 2, p. 226-238, 2019.

- JIANG, L.; HU, Y.; XIA, X.; LIANG, Q.; SOLTOGGIO, A.; KABIR, S. R.. A multi-scale mapping approach based on a deep learning CNN model for reconstructing high-resolution urban DEMs. **Water**, [s. l.], v. 12, n. 5, 2020.
- JIANG, T.; GRADUS, J. L.; ROSELLINI, A. J. Supervised Machine Learning: A Brief Primer. **Behavior Therapy**, [s. l.], v. 51, n. 5, p. 675–687, 2020b.
- JIANG, Tammy; GRADUS, Jaimie L.; ROSELLINI, Anthony J. Supervised machine learning: a brief primer. **Behavior therapy**, v. 51, n. 5, p. 675-687, 2020.
- JUNGERIUS, P. D.; MATUNDURA, J.; VAN DE ANCKER, J. A. M. Road construction and gully erosion in West Pokot, Kenya. **Earth Surface Processes and Landforms**, [s. l.], v. 27, n. 11, p. 1237–1247, out. 2002.
- KERTZMAN, F. F. ; OLIVEIRA, A. M. D. S.; SALOMÃO, F. X. D. T.; GOUVEIA, M. I. F. Mapa de erosão do estado de São Paulo. **Revista do Instituto Geológico**, v. 16, n. special, 1995.
- KLUSOWSKI, J. M. Complete Analysis of a Random Forest Model. **arXiv**, [s. l.], v. 13, p. 1063–1095, 2018.
- KOCAMAN, S.; TAVUS, B.; NEFESLIOGLU, H. A.; KARAKAS, G.; GOKCEOGLU, C.. Evaluation of Floods and Landslides Triggered by a Meteorological Catastrophe (Ordu, Turkey, August 2018) Using Optical and Radar Data. **Geofluids**, [s. l.], v. 2020, 2020.
- KOPEĆ, D.; MICHALSKA-HEJDUK, D.; KROGULEC, E. The relationship between vegetation and groundwater levels as an indicator of spontaneous wetland restoration. **Ecological Engineering**, [s. l.], v. 57, p. 242–251, 2013.
- KROGH, Anders. What are artificial neural networks?. **Nature Biotechnology**, [s. l.], v. 26, n. 2, p. 195-197, 2008.
- KUFFOUR, B. N. O. ; ENGDAHL, N. B. ; WOODWARD, C.S., CONDON, L.E., KOLLET, S.; MAXWELL, R.M. Simulating coupled surface-subsurface flows with ParFlow v3.5.0: Capabilities, applications, and ongoing development of an open-source, massively parallel, integrated hydrologic model. **Geoscientific Model Development**, [s. l.], v. 13, n. 3, p. 1373-1397, 2020.
- LAL, R. Soil degradation by erosion. **Land Degradation and Development**, v. 12, n. 6, p. 519–539, 2001.
- LAL, R. Soil Erosion Impact on Agronomic Productivity and Environment Quality. **Critical Reviews in Plant Sciences**, [s. l.], v. 17, n. 4, p. 319-464, 1998.
- LANA, J. C. Gully erosion prediction method from geoenvironmental data and supervised machine learning techniques. **MethodsX**, [s. l.], v. 10, n. December 2022, p. 102059, 2023.
- LANG, M.; MCCARTY, G.; OESTERLING, R.; YEO, I.Y. Topographic metrics for improved mapping of forested wetlands. **Wetlands**, [s. l.], v. 33, n. 1, p. 141-155, fev. 2013.
- LEU, W. H.; CHEN, H. W.; CHEN, C. Y. Using an unmanned aerial system to monitor and assess irrigation water channels susceptible to sediment deposition. **Environmental Monitoring and Assessment**, [s. l.], v. 193, n. 8, 2021.
- LI, H.; ZHANG, Y.; ZHOU, X. Predicting surface runoff from catchment to large region. **Advances in Meteorology**, [s. l.], v. 2015, 2015.
- LIAW, A.; WIENER, M. Classification and Regression by randomForest. **R News**, [s. l.], v. 2, n. 3, p. 18-22, 2002.
- LIMA, I. F.; FERNANDES, N. F. Detritos na região serrana do rio de janeiro morphometric analysis of watershed affected by debris flows in mountain region of rio de janeiro. **Revista Brasileira de Geomorfologia** v. 2, 2020.

- LINDSAY, J. B.; CREED, I. F. Removal of artifact depressions from digital elevation models: Towards a minimum impact approach. **Hydrological Processes**, [s. l.], v. 19, n. 16, p. 3113-3126, out. 2005.
- LIVINGSTON, K. Wetlands . William J. Mitsch and James G. Gosselink. Van Nostrand Reinhold, New York, 1986. xvi, 539 pp., illus. \$44.50. **Science**, [s. l.], v. 233, n. 4769, p. 1209-1209, set. 1986.
- LÓPEZ-TAPIA, S.; RUIZ, P.; SMITH, M.; MATTHEWS, J.; ZERCHER, B.; SYDORENKO, L., Varia N.; JIN, Y.; WANG, M.; DUNN, J. B.; KATSAGGELOS, A.K. (Machine learning with high-resolution aerial imagery and data fusion to improve and automate the detection of wetlands. **International Journal of Applied Earth Observation and Geoinformation**, [s. l.], v. 105, 25 dez. 2021.
- MA, Y.; LI, Z.; TIAN, L.; YANG, Y.; LI, W.; HE, Z.; NIE, X.; LIU, Y. Erosion of Granite Red Soil Slope and Processes of Subsurface Flow Generation, Prediction, and Simulation. **International Journal of Environmental Research and Public Health**, [s. l.], v. 20, n. 3, 2023.
- MACEDO, S. A.; MOREAU, M. S.; SPANGHERO, P. E. S. F. Caracterização morfológica e uso e ocupação da terra da microbacia hidrográfica do Rio Água Branca de Itabuna-BA. **Revista Geonorte**, [s. l.], v. 10, n. 34, p. 82-99, 2019. ISSN 2237-1419. DOI: <https://doi.org/10.21170/geonorte.2019.V.10.N.34.82.99>.
- MAHESH, B. Machine Learning Algorithms – A review. **International Journal of Science and Research (IJSR)**, [s. l.], v. 9, n. 1, p. 381-386, jan. 2020. ISSN 2319-7064. DOI: <https://doi.org/10.21275/ART20203995>.
- MARÇAL, M. S.; GUERRA, A. J. T. Indicadores ambientais relevantes para a análise da suscetibilidade à erosão dos solos em Açailândia (MA). **Revista Brasileira de Geomorfologia**, [s. l.], ano 4, n. 2, p. 1-16, 2003. DOI: <https://doi.org/10.20502/rbg.v4i2.20>.
- MARIA, I. Cl.; PECHE FILHO, Afonso. Terraceamento complementa proteção da superfície. **Visão Agrícola**, [s. l.], n. 9, p. 140-143, jul./dez. 2009.
- MARIMON JUNIOR, B. Hur; HARIDASAN, M. Comparação da vegetação arbórea e características edáficas de um cerradão e um cerrado sensu stricto em áreas adjacentes sobre solo distrófico no leste de Mato Grosso, Brasil. **Acta Bot. Bras.**, [s. l.], v. 19, n. 4, p. 913-926, 2005. DOI: <https://doi.org/10.1590/S0102-33062005000400026>.
- MARTZ, L. W.; GARBRECHT, J. **Automated recognition of valley lines and drainage networks from grid digital elevation models: a review and a new method-Comment**. v.167, n. 1 – 4, p. 393-396, 1995.
- MENESES, B. M.; REIS, R.; VALE, M. J.; & SARAIVA, R. Land use and land cover changes in Zêzere watershed (Portugal) - Water quality implications. **Science of the Total Environment**, [s. l.], v. 527–528, p. 439–447, 5 set. 2015.
- MENG, X.; CURRIT, N.; ZHAO, K. Ground filtering algorithms for airborne LiDAR data: A review of critical issues. **Remote Sens.**, [s. l.], v. 2, n. 3, p. 833-860, 2010.
- MENG, X.; WANG, L.; SILVÁN-CÁRDENAS, J. L.; CURRIT, N. A multi-directional ground filtering algorithm for airborne LIDAR. **ISPRS Journal of Photogrammetry and Remote Sensing**, [s. l.], v. 64, n. 1, p. 117–124, 2009.
- MERRITT, W. S.; LETCHER, R. A.; JAKEMAN, A. J. A review of erosion and sediment transport models. **Environmental Modelling and Software**, [s. l.], v. 18, n. 8-9, p. 761-799, 2003.

- MESA-MINGORANCE, J. L.; ARIZA-LÓPEZ, F. J. Accuracy assessment of digital elevation models (DEMs): A critical review of practices of the past three decades. **Remote Sens.**, [s. l.], v. 12, n. 16, p. 1-27, 2020.
- MHASKE, S. N.; PATHAK, K.; DASH, S. S.; & NAYAK, D. B. ASSESSMENT and management of soil erosion in the hilltop mining dominated catchment using GIS integrated RUSLE model. **Journal of Environmental Management**, [s. l.], v. 294, set. 2021.
- MITÁŠOVÁ, H.; HOFIERKA, J. Interpolation by regularized spline with tension: II. Application to terrain modeling and surface geometry analysis. **Mathematical Geology**, [s. l.], v. 25, n. 6, p. 657-669, 1993.
- MOHAMMED, S.; AL-EBRAHEEM, A.; HOLB, I. J.; ALSAFADI, K.; DIKKEH, M., PHAM, Q. B.; LINH, N. T. T.; SZABO, S. Soil management effects on soil water erosion and runoff in Central Syria-A comparative evaluation of general linear model and random forest regression. **Water**, [s. l.], v. 12, n. 9, 2020.
- MOISA, M. B.; DEJENE, I. N.; HIRKO, Ob.; GEMEDA, D. O. Impact of deforestation on soil erosion in the highland areas of western Ethiopia using geospatial techniques: a case study of the Upper Anger watershed. **Asia-Pacific Journal of Regional Science**, [s. l.], abr. 2022. DOI: <https://doi.org/10.1007/s41685-022-00238-7>.
- MÖLLER, D. P. F. Machine Learning and Deep Learning. **Advances in Information Security**, [s. l.], v. 103, p. 347-384, 2023.
- MOMM-SCHULT, S. I.; PIPER, J.; DENALDI, R.; FREITAS, S. R.; FONSECA, M. D. L. P.; OLIVEIRA, V. E. D. Integration of urban and environmental policies in the metropolitan area of São Paulo and in Greater London: the value of establishing and protecting green open spaces. **International Journal of Urban Sustainable Development**, v. 5, n. 1, p. 89-104, 2013.
- MONTGOMERY, D. R. Road surface drainage, channel initiation, and slope instability. **Water Resources Research**, [s. l.], v. 30, n. 6, p. 1925-1932, jun. 1994.
- MONTGOMERY, DAVID R.; DIETRICH, WILLIAM E. A physically based model for the topographic control on shallow landsliding. **Water Resources Research**, [s. l.], v. 30, p. 1153-1171, 1994.
- MOORE, I. D.; BURCH, G. J. Physical basis of the length-slope factor in the universal soil loss equation. **Soil Science Society of America Journal**, v. 50, n. 5, p. 1294-1298, 1986.
- MOORE, I. D.; BURCH, G. J.; MACKENZIE, D. H. Topographic Effects on the Distribution of Surface Soil Water and the Location of Ephemeral Gullies. **Transactions of the American Society of Agricultural Engineers**, [s. l.], v. 31, n. 4, p. 1098-1107, 1988.
- MOORE, I. D.; GESSLER, P. E.; NIELSEN, G. A. E.; PETERSON, G. A. Soil Attribute Prediction Using Terrain Analysis. **Soil Science Society of America Journal**, [s. l.], v. 57, n. 2, p. 443-452, mar. 1993.
- MOORE, I. D.; GRAYSON, R. B.; LADSON, A. R. Digital terrain modelling: A review of hydrological, geomorphological, and biological applications. **Hydrological Processes**, [s. l.], v. 5, n. 1, p. 3-30, jan. 1991.
- MOORE, I.D.; BURCH, G.J. Modelling Erosion and Deposition: Topographic Effects. **Transactions of the ASAE**, v. 29, n. 6, p. 1624-1630, 1986.
- MOORE, I.D.; BURCH, G. J.; MACKENZIE, D. H. Topographic Effects on the Distribution of Surface Soil Water and the Location of Ephemeral Gullies. **Transactions of the ASAE**, v. 31, n. 4, p. 1098-1107, 1988.

- MURPHY, P. N. C.; OGILVIE, J.; CONNOR, K.; ARP, P. A. Mapping wetlands: a comparison of two different approaches for New Brunswick, Canada. **Wetlands**, [s. l.], v. 27, n. 4, p. 846-854, 2007.
- NASTESKI, V. An overview of the supervised machine learning methods. **Horizons.B**, [s. l.], v. 4, p. 51-62, dez. 2017.
- NATEKIN, A.; KNOLL, A. Gradient boosting machines, a tutorial. **Frontiers in Neurorobotics**, [s. l.], v. 7, n. dez. 2013.
- NEARING, M. A.; LANE, L. J.; ALBERTS, E. E.; LAFLEN, J. M. Prediction Technology for Soil Erosion by Water: Status and Research Needs. **Soil Science Society of America Journal**, [s. l.], v. 54, n. 6, p. 1702–1711, 1990.
- NEVES, G.; SENA-SOUZA, J. P.; VASCONCELOS, V.; MARTINS, É. D. S.; COUTO, A. F. Dinâmica Da Cobertura Da Terra Do Distrito Federal Dentro De Suas Unidades Geomorfológicas. **Sociedade & Natureza**, [s. l.], v. 29, n. 3, p. 383–396, 2017.
- NHU, V. H.; JANIZADEH, S.; AVAND, M.; CHEN, W.; FARZIN, M.; OMIDVAR, E.; SHIRZADI, A.; SHAHABI, H.; CLAGUE, J. J.; JAAFARI, A.; MANSOORYPOOR, F.; PHAM, B. T.; AHMAD, B. B.; LEE, S. GIS-Based gully erosion susceptibility mapping: A comparison of computational ensemble data mining models. **Applied Sciences (Switzerland)**, [s. l.], v. 10, n. 6, 2020.
- NOBLE, William S. What is a support vector machine?. **Nature Biotechnology**, [s. l.], v. 24, n. 12, p. 1565-1567, 2006.
- NYSSSEN, J.; POESEN, J.; MOEYERSONS, J.; LUYTEN, E.; VEYRET-PICOT, M.; DECKERS, J.; HAILE, M.; GOVERS, G. Impact of road building on gully erosion risk: A case study from the Northern Ethiopian Highlands. **Earth Surface Processes and Landforms**, [s. l.], v. 27, n. 12, p. 1267-1283, nov. 2002.
- O'CALLAGHAN, J. F.; MARK, D. M. The extraction of drainage networks from digital elevation data. **Computer Vision, Graphics, & Image Processing**, [s. l.], v. 28, n. 3, p. 323-344, 1984.
- O'LOUGHLIN, E. M. Prediction of Surface Saturation Zones in Natural Catchments by Topographic Analysis. **Water Resources Research**, [s. l.], v. 22, n. 5, p. 794–804, maio 1986.
- O'NEIL, G. L.; SABY, L.; BAND, L. E.; GOODALL, J. L. Effects of LiDAR DEM Smoothing and Conditioning Techniques on a Topography-Based Wetland Identification Model. **Water Resources Research**, [s. l.], v. 55, n. 5, p. 4343-4363, 2019.
- ODEMERHO, F. O.; SADA, P. O. The role of urban surface characteristics on the extent of gully erosion in Auchi, Bendel State, Nigeria. **Applied Geography**, v. 4, n. 4, p. 333-344, 1984. DOI: [https://doi.org/10.1016/0143-6228\(84\)90029-8](https://doi.org/10.1016/0143-6228(84)90029-8)
- OZESMI, Stacy L.; BAUER, Marvin E. Satellite remote sensing of wetlands. **Wetlands Ecology and Management**, [s. l.], v. 10, n. 5, p. 381-402, out. 2002. DOI: <https://doi.org/10.1023/A:1020908432489>.
- PAL, S. C.; ARABAMERI, A.; BLASCHKE, T.; CHOWDHURI, I.; SAHA, A., CHAKRABORTTY, R.; SAHA, A.; CHAKRABORTY, R.; LE, S.; BAND, S. S. Ensemble of machine-learning methods for predicting gully erosion susceptibility. **Remote Sensing**, [s. l.], v. 12, n. 22, p. 1–25, 2020.
- PALIAGA, G.; FACCINI, F.; LUINO, F.; TURCONI, L.; BOBROWSKY, P. Geomorphic processes and risk related to a large landslide dam in a highly urbanized Mediterranean catchment (Genova, Italy). **Geomorphology**, [s. l.], v. 327, p. 48-61, 2019.

- PARMAR, A.; KATARIYA, R.; PATEL, V. A review on random forest: an ensemble classifier. **Lecture Notes on Data Engineering and Communications Technologies**, [s. l.], v. 26, p. 758–763, 2019.
- PASSALACQUA, P.; BELMONT, P.; STALEY, D. M.; SIMLEY, J. D.; ARROWSMITH, J. R.; BODE, C. A.; CROSBY, C.; LONG, S. B.; GLENN, N. F.; KELLY, S. A.; LAGUE, D.; SANGIREDDY, H.; SCHAFFRATH, K.; TARBOTON, D.; WASKLEWICZ, T.; WEATON, J. M. Analyzing high resolution topography for advancing the understanding of mass and energy transfer through landscapes: A review. **Earth-Science Reviews**, v. 148, p. 174-193, 2015.
- PASSALACQUA, P.; TAROLLI, P.; FOUFOULA-GEORGIOU, E. Testing space-scale methodologies for automatic geomorphic feature extraction from lidar in a complex mountainous landscape. **Water Resources Research**, [s. l.], v. 46, n. 11, p. 1-17, 2010.
- PASSO, Denilson Pereira. Desenvolvimento de aplicação para análise geográfica de imagens, baseada em objeto, com a finalidade de identificar automaticamente focos erosivos lineares. 2017. 185 f. Tese (Doutorado em Geociências)—Universidade de Brasília, Brasília, 2017.
- PINTO, Maria Novaes. Unidades geomorfológicas do Distrito Federal. **Boletim de Geografia Teoretica**, [s. l.], v. 16-17, n. 31-34, p. 352-355, 1986-1987.
- PIZZUTO, J. E.; MECKELNBURG, T. S. Evaluation of a linear bank erosion equation. **Water Resources Research**, [s. l.], v. 25, n. 5, p. 1005-1013, 1989.
- POLIDORI, L.; HAGE, M. EL. Digital elevation model quality assessment methods: A critical review. **Remote Sens.**, [s. l.], v. 12, n. 21, p. 1-36, 2020.
- POLOVINA, S.; RADIĆ, B.; RISTIĆ, R.; KOVAČEVIĆ, J.; MILČANOVIĆ, V.; ŽIVANOVIĆ, N. Soil erosion assessment and prediction in urban landscapes: A new G2 model approach. **Applied Sciences**, [s. l.], v. 11, n. 9, 2021.
- PREITI, G.; ANTONIO, C.; PORTO, P.; ROMEO, M.; MONTI, M.; & BACCHI, M. Long-term effects of different arable cropping systems on surface erosion processes and C-factor in hilly Mediterranean environment. **Soil and Tillage Research**, [s. l.], v. 223, set. 2022.
- PROBST, P.; WRIGHT, M. N.; BOULESTEIX, A. L. Hyperparameters and tuning strategies for random forest. **Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery**, [s. l.], v. 9, n. 3, p. 1-15, 2019.
- RAHMATI, O.; KALANTARI, Z.; FERREIRA, C. S.; CHEN, W.; SOLEIMANPOUR, S. M.; KAPOVIĆ-SOLOMUN, M.; SEIFOLLAHI-AGHMIUNI, A.; GHAJARNIA, N.; KAZEMABADY, N. K. Contribution of physical and anthropogenic factors to gully erosion initiation. **CATENA**, [s. l.], v. 210, n. November 2021, 2022.
- RAHMATI, O.; TAHMASEBPOUR, N.; HAGHIZADEH, A.; POURGHASEMI, H. R.; FEIZIZADEH, B. Evaluating the influence of geo-environmental factors on gully erosion in a semi-arid region of Iran: An integrated framework. **Science of the Total Environment**, [s. l.], v. 579, p. 913-927, 2017.
- RAIKWAR, V. A comparison of different Artificial Intelligence and Machine Learning methods for Gully Erosion Susceptibility Mapping in the Upper Narmada Basin. p. 1–21, 2021.
- RAN, Q.; WANG, F.; LI, P.; YE, S.; TANG, H.; GAO, J.. Effect of rainfall moving direction on surface flow and soil erosion processes on slopes with sealing. **Journal of Hydrology**, [s. l.], v. 567, p. 478-488, 2018.

- RANA, S. Use of plan curvature variations for the identification of ridges and channels on DEM. **Progress in Spatial Data Handling - 12th International Symposium on Spatial Data Handling, SDH 2006**, p. 789-804, 2006.
- RAPINEL, S.; HUBERT-MOYA, L.; CLÉMENTB', B. Combined use of lidar data and multispectral earth observation imagery for wetland habitat mapping. **International Journal of Applied Earth Observation and Geoinformation**, [s. l.], v. 37, p. 56-64, 2015.
- REATTO, A.; MARTINS, É. D. S.; FARIAS, M. F. R.; SILVA, A. V. D.; & CARVALHO JÚNIOR, O. A. D. Mapa Pedológico Digital - SIG Atualizado do Distrito Federal Escala 1:100.000 e uma Síntese do Texto Explicativo. **Documentos/Embrapa Cerrados**, p. 1–29, 2004.
- RECLA, M.; SCHMITT, M. The SAR2Height framework for urban height map reconstruction from single SAR intensity images. **ISPRS Journal of Photogrammetry and Remote Sensing**, [s. l.], v. 211, p. 104-120, maio 2024.
- REDDY, K. R.; DELAUNE, R. D.; INGLETT, P. W. **Biogeochemistry of Wetlands**. Boca Raton: CRC Press, 2022.
- REHM, R.; ZEYER, T.; SCHMIDT, A.; FIENER, P. Soil erosion as transport pathway of microplastic from agriculture soils to aquatic ecosystems. **Science of the Total Environment**, [s. l.], v. 795, 2021.
- REZA, H.; SADHASIVAM, N.; KARIMINEJAD, N.; COLLINS, A. L. Geoscience frontiers gully erosion spatial modelling: role of machine learning algorithms in selection of the best controlling factors and modelling process. **Geoscience Frontiers**, [s. l.], v. 11, n. 6, p. 2207-2219, 2020.
- RICKENMANN, D.; ZIMMERMANN, M. The 1987 debris flows in Switzerland: documentation and analysis. **Geomorphology**, [s. l.], v. 8, n. 2-3, p. 175-189, nov. 1993.
- RILEY SHAWN, J.; DEGLORIA STEPHEN, D.; ELLIOT ROBERT, A. Terrain Ruggedness Index That Quantifies Topographic Heterogeneity. *intermountain Journal of Science*, v. 5, n. 1-4, p. 23-27, 1999.
- ROGELIS, M. C.; WERNER, M. Regional debris flow susceptibility analysis in mountainous peri-urban areas through morphometric and land cover indicators. **Natural Hazards and Earth System Sciences**, [s. l.], v. 14, n. 11, p. 3043-3064, nov. 2014.
- RUHOFF, A. L.; CASTRO, N. M. R.; RISSO, A. Numerical Modelling of the Topographic Wetness Index: An Analysis at Different Scales. **International Journal of Geosciences**, [s. l.], v. 02, n. 04, p. 476-483, 2011.
- SAHA, S.; SARKAR, R.; THAPA, G.; ROY, J. Modeling gully erosion susceptibility in Phuentsholing, Bhutan using deep learning and basic machine learning algorithms. **Environmental Earth Sciences**, [s. l.], v. 80, n. 8, p. 1-21, 2021.
- SAQUIB, S. GUPTA, A. J. Akanksha. Emerging water crisis: Impact of urbanization on water resources and constructed wetlands as a nature-based solution (NbS). In: **Current Directions in Water Scarcity Research**. Elsevier, p. 447-468, 2022.
- SCHMIDT, J.; EVANS, I. S.; BRINKMANN, J. Comparison of polynomial models for land surface curvature calculation. **International Journal of Geographical Information Science**, [s. l.], v. 17, n. 8, p. 797-814, dez. 2003.
- SESTRAS, P. ; BILAŞCO, Ş.; ROŞCA, S.; DUDIC, B.; HYSA, A.; SPALEVIĆ, V. Geodetic and UAV monitoring in the sustainable management of shallow

- landslides and erosion of a susceptible urban environment. **Remote Sens.**, [s. l.], v. 13, n. 3, p. 1-29, 1 fev. 2021.
- SHAHID, M. J. Role of microorganisms in the remediation of wastewater in floating treatment wetlands: a review. **Sustainability**, v. 12, n. 14, p. 5559, 2020.
- SHAN, J.; SAMPATH, A. Urban DEM generation from raw lidar data: A labeling algorithm and its performance. **Photogrammetric Engineering and Remote Sens.**, [s. l.], v. 71, n. 2, p. 217-226, 2005.
- SHARMA, M.; GARG, R. D.; BADENKO, V.; FEDOTOV, A.; MIN, L.; YAO, A. Potential of airborne LiDAR data for terrain parameters extraction. **Quaternary International**, [s. l.], v. 575-576, p. 317-327, fev. 2021.
- SHARMA, P.; FACCINI, F.; LUINO, F.; TURCONI, L.; BOBROWSKY, P. The Role of Cover Crops towards Sustainable Soil Health and Agriculture—A Review Paper. **American Journal of Plant Sciences**, [s. l.], v. 9, n. 9, p. 1935-1951, 2018.
- SILVA, J. R. I.; SOUZA, E. S.; SOUZA, R.; SANTOS, E. S.; ANTONINO, A. C. D. Efeito de diferentes usos do solo na erosão hídrica em região semiárida. **Engenharia na Agricultura**, Viçosa, MG, v. 27, n. 3, p. 272-283, 2019. ISSN 2175-6813. DOI: <https://doi.org/10.13083/reveng.v27i3.867>.
- SOLEIMANPOUR, S. M.; POURGHASEMI, H. R.; ZARE, M. A comparative assessment of gully erosion spatial predictive modeling using statistical and machine learning models. **CATENA**, [s. l.], v. 207, n. September 2020, 2021.
- SUR, U.; SINGH, P.; MEENA, S. R.; SINGH, T. N. Article Predicting Landslides Susceptible Zones in the Lesser Himalayas by Ensemble of Per Pixel and Object-Based Models. **Remote Sens.**, [s. l.], v. 14, n. 8, 2022.
- TALUKDAR, S. Land-use land-cover classification by machine learning classifiers for satellite observations—A review. **Remote sensing**, v. 12, n. 7, p. 1135, 2020.
- TANIGUCHI, K. T. BIGGS, T. W., LANGENDOEN, E. J., CASTILLO, C., GUDINO-ELIZONDO, N., YUAN, Y., & LIDEN, D. Stream channel erosion in a rapidly urbanizing region of the US–Mexico border: documenting the importance of channel hardpoints with Structure-from-Motion photogrammetry. **Earth Surface Processes and Landforms**, [s. l.], v. 43, n. 7, p. 1465-1477, jun. 2018.
- THORNE, C. R., ZEVENBERGEN, L. W., GRISSINGER, E. H., & MURPHEY, J. B. **Ephemeral gullies as sources of sediment**. Proceedings of the Fourth Federal Interagency Sedimentation Conference March 24-27. **Anais...Las Vegas, Nevada**: 1986.
- TORKAMANI-AZAR, F.; TAIT, K. E. Image recovery using the anisotropic diffusion equation. **IEEE Transactions on Image Processing**, [s. l.], v. 5, n. 11, p. 1573-1578, 1996.
- TREMARIN, P. I.; MOREIRA-FILHO, H.; LUDWIG, T. A. V. Pinnulariaceae (Bacillariophyceae) do rio Guaraguaçu, bacia hidrográfica litorânea paranaense, Brasil. **Acta Botanica Brasilica**, [s. l.], v. 24, n. 2, p. 335-353, 2010.
- TREPEKLI, K.; BALSTROM, T.; FRIBORG, T.; FOG, B.; ALLOTEY, A. N.; KOFIE, R. Y.; MOLLER-JENSEN, L. UAV-borne, LiDAR-based elevation modelling: a method for improving local-scale urban flood risk assessment. **Natural Hazards**, [s. l.], v. 113, n. 1, p. 423-451, 2022.
- TURCOTTE, R.; FORTIN, J. P.; ROUSSEAU, A. N.; MASSICOTTE, S.; VILLENEUVE, J. P. Determination of the drainage structure of a watershed

- using a digital elevation model and a digital river and lake network. **Journal of hydrology**, v. 240, n. 3-4, p. 225-242, 2001.
- VELTHOEN, J.; DOMBRY, C.; CAI, J. J.; ENGELKE, S. Gradient boosting for extreme quantile regression. p. 1–48, 2021.
- VILELA JUNIOR, G. B.; LIMA, B. N.; PEREIRA, A. A.; RODRIGUES, M. F.; OLIVEIRA, J. R. L.; SILIO, L. F.; CARVALHO, A. S.; FERREIRA, H. R.; PASSOS, R. Métricas utilizadas para avaliar a eficiência de classificadores em algoritmos inteligentes. **Centro de Pesquisas Avançadas em Qualidade de Vida**, [s. l.], v. 14, n. 2, 2022.
- WANG, N.; SHANG, Y.; CHEN, Y.; YANG, M.; ZHANG, Q.; LIU, Y.; GUI, Z. A Hybrid Model for Image Denoising Combining Modified Isotropic Diffusion Model and Modified Perona-Malik Model. **IEEE Access**, v. 6, n. c, p. 33568–33582, 2018.
- WEINACKER, H.; KOCH, B.; HEYDER, U. Development of filtering, segmentation and modelling modules for lidar and multispectral data as a fundament of an automatic forest inventory system. **International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XXXVI, n. June 2016, p. 50–55, 2004.
- WEISS, A. Topographic position and landforms analysis. **Poster presentation, ESRI User Conference, San Diego, CA**, [s. l.], v. 64, p. 227-245, 2001.
- WHITLOW, R. Gullying within wetlands in Zimbabwe: an examination of conservation history and spatial patterns. **South African Geographical Journal**, [s. l.], v. 74, n. 2, p. 54-62, 1992. DOI: <https://doi.org/10.1080/03736245.1992.10586397>.
- WILLIAMS, J. R. The erosion-productivity impact calculator (EPIC) model: a case history. **Philosophical Transactions of the Royal Society of London. Series B: Biological Sciences**, [s. l.], v. 329, n. 1255, p. 421-428, 1990.
- WILSON, J. P. Digital terrain modelling. **Geomorphology**, n. 137, p. 107–121, 2012
- WILSON, J. P.; GALLANT, J. C. EROS: A grid-based program for estimating spatially-distributed erosion indices. **Computers & Geosciences**, [s. l.], v. 22, n. 7, p. 707–712, ago. 1996.
- WU, S.; CHEN, L. Modeling Soil Erosion With Evolving Rills on Hillslopes. **Water Resources Research**, [s. l.], v. 56, n. 10, 2020.
- WU, S.; CHEN, L.; WANG, N.; ASSOULINE, S. Modeling rainfall-infiltration-runoff processes on sloping surfaces subject to rapidly changing soil properties during seal formation. **Journal of Hydrology**, [s. l.], v. 619, 1 abr. 2023.
- XIE, Z.; FENGGE, S.; XU, L.; QINGCUN, Z.; ZHENCHUN, H.; & YUFU, G. Applications of a surface runoff model with Horton and Dunne runoff for VIC. **Advances in Atmospheric Sciences**, [s. l.], v. 20, n. 2, p. 165-172, 2003.
- YANG, A.; WANG, C.; PANG, G.; LONG, Y.; WANG, L.; CRUSE, R. M.; YANG, Q. Gully erosion susceptibility mapping in highly complex terrain using machine learning models. **ISPRS International Journal of Geo-Information**, [s. l.], v. 10, n. 10, 2021.
- YANG, J.; YIN, Z. Y.; LAOUAFA, F.; HICHER, P. Y. Modeling coupled erosion and filtration of fine particles in granular media. **Acta Geotechnica**, [s. l.], v. 14, n. 6, p. 1615-1627, dez. 2019.
- YIRDAW, E.; TIGABU, M.; MONGE, A. Rehabilitation of degraded dryland ecosystems – review. **Silva Fennica**, [s. l.], v. 51, n. 1, p. 1-32, 2017.

YUNFEI, B.; GUOPING, L.; CAO, C.; XIAOWEN, L. Classification of Lidar Point Cloud and Generation of DTM from LiDAR Height and Intensity Data in Forested Area. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, Beijing, v. XXXVII, p. 313-318, 2008.

ZEVENBERGEN, L. W.; THORNE, C. R. Quantitative analysis of land surface topography. **Earth Surface Processes and Landforms**, [s. l.], v. 12, n. 1, p. 47-56, jan./fev. 1987. DOI: <https://doi.org/10.1002/esp.3290120107>.

ZHANG, J.; GUO, W.; ZHOU, B.; OKIN, G. S. Drone-based remote sensing for research on wind erosion in drylands: possible applications. **Remote Sens.**, [s. l.], v. 13, n. 2, 2021. DOI: <https://doi.org/10.3390/rs13020283>.

ZHANG, L.; HUANG, Y.; RONG, L.; DUAN, R.; LI, Y.; GUAN, J. Effect of soil erosion depth on crop yield based on topsoil removal method: a meta-analysis. **Agronomy for Sustainable Development**, [s. l.], v. 41, n. 63, set. 2021.

ZHU, P.; GONG, P. Suitability mapping of global wetland areas and validation with remotely sensed data. **Science China Earth Sciences**, [s. l.], v. 57, p. 2283-2292, 2014.

Nome do Artigo	Autores	Ano	Revista	Parâmetros																						
				elevation Altitude	slope	slope degree	aspect	plan curvature	Hand	Plan	precipitation	Normalized difference vegetation index	profile curvature	Convergenc e Index - CI	EC	Relative Slope Position - RSP	Topographic wetness index	CA + Mg	Content of silt	Texture	Resolução do MDT	Parâmetros + Impotantes	Método	Melhor Método		
A comparative assessment of gully erosion spatial predictive modelling using statistical and machine learning models	Seyed Masoud Soleimanpour a,*, Hamid Reza Pourghasemi b, Maryam Zare c	2021	Catena	1	1		1	1					1							1:25000	NÃO TEM	quick, unbiased, efficient statistical tree (QUEST)	QUEST			
A Comparative Assessment of Random Forest and k-Nearest Neighbor Classifiers for Gully Erosion Susceptibility Mapping	Mohammadtaghi Avand 1, Saeid Janizadeh 1, Seyed Amir Naghibi 1, Hamid Reza Pourghasemi 2*, Saeid Khosrobeigi Bozchaloei 3 and Thomas Blaschke	2019	Water	1	1		1	1					1							ALOS PALSAR Global Radar 125 m	altitude rainfall distance to roads distance from the river	RF KNN	RF			
A comparison of different Artificial Intelligence and Machine Learning methods for Gully Erosion Susceptibility Mapping in the Upper Narmada Basin	Vinay Ralkwar Pramod Pagare Aminu Abdulwahab Priyank Pravin Patel Vikram Agone	in review		1	1		1													SRTM 30 m						
A Methodological Comparison of Three Models for Gully Erosion Susceptibility Mapping in the Rural Municipality of El Faid (Morocco)	Ali Azedou 1, , Said Lahssini 1, Abdellatif Khattabi 1, Modeste Meliho 2 and Nabil Rifai 3	2021	Sustainability	1	1		1	1														Frequency Ratio (FR) Random Forest (RF) Logistic Regression (LR)	Logistic Regression (LR)			
A wrapper feature selection approach for efficient modelling of gully erosion susceptibility mapping	Hamed Rouhani, Aboalhasan Fathabadi, Jantiene Baartman	2021	Artide	1	1		1	1					1								Elevation/ distance to fault/slope/ index of connectivity	Logistic Regression (LR)/SVN/ KNN	KNN			
Assessing gully erosion susceptibility using topographic derived attributes, multi-criteria decision-making, and machine learning classifiers	Ahmed J. Al-Bawi, Alaa M. Al-Abadi, Biswajeet Pradhan & Abdullah M. Alami	2021	Geomatics, Natural Hazards and Risk	1	1								1							DEM resolução média	TWI/ SPI/ LS	Feature Selection /Ahp and TOPSIS/SVM / Naive Bayes/NN/L	AHP-TOPSIS			
Automatic gully detection: neural networks and computer vision	Arthur M. Gafurov, Oleg P. Yermolayev	2020	Remote Sensing																	Digital Globe		GECCN				
Comparison of differences in resolution and sources of controlling factors for gully erosion susceptibility mapping	Younes Garosi, Mohsen Shekhabadi, , Hamid Reza Pourghasemi, Ali Asghar Besalatpour, Christian Cosentino, Kristof Van Oost, Umid Kahmati, Zahra Kalantari b,c, Carla Sofia Ferreira b,d,e, Wei Chen f, Seyed Masoud Soleimanpour g, , Marijana Kapović c, Solomon h, Samaneh Seifollahi Ardebilzadeh b, Navid	2018	Science Direct	1	1		1	1					1									GLMs/BRT/MARS/ANN				
Contribution of physical and anthropogenic factors to gully erosion initiation		2021	Science Direct	1	1		1	1					1								distance from roads and streams/land use/TWI/drainage intensity/aspect	maximum entropy (ME)/ random forest (RF)/ boosted regression	Random Forest			
Deep learning and boosting framework for piping erosion susceptibility modeling: spatial evaluation of agricultural areas in the semi-arid region	Yunzhi Chen, Wei Chen, Saeid Janizadeh, Gouri Sankar Bhunia, Amit Bera, Quoc Bao Pham, Nguyen Thi Thuy Linh, Abdul-Lateef Balogun & Xiaojing Wang	2021	Geocarto International	1	1		1	1					1								Topographic/ hidrological/geographical/soil	Boosted regression tree (BRT)/Boosted linear model (BLM)/Boosted	Deep Boosting/ BRT			
Ensemble of Machine-Learning Methods for Predicting Gully Erosion Susceptibility	Subodh Chandra Pal 1, Alireza Arabameri 2, Thomas Blaschke 3, Indrajit Chowdhuri 1, Ashish Saha 1, Rabin Chakraborty 1, Soro Lee 4,5 and Shahab S. Band 6,*	2020	Remote Sensing	1	1		1	1					1								Slope/ LULC/ Drainage Density/ Profile Curvature,/ Geomorphology/ Ferrous Minerals/ Soil Texture	Random Forest/ Boosted Regression Tree/ K4 Fold	K4 Fold/ BRT			

Nome do Artigo	Autores	Ano	Revista	Parâmetros																				
				elevation Altitude	slope	slope degree	aspect	plan curvature	Hand	PLAN	precipitation	Normalized difference vegetation index	profile curvature	Convergenc e Index - CI	EC	Relative Slope Position - RSP	Topographic wetness index	CA + Mg	Content of silt	Texture	Resolução do MDT	Parâmetros + Impotantes	Método	Melhor Método
Gully erosion susceptibility mapping (GESM) using machine learning methods optimized by the multi-collinearity analysis and K-fold cross validation	Omid Ghorbanzadeh, Hejar Shahabi, Fahimeh Mircholi, Khalil Valizadeh Kamran, Samsung Lim, Jagannath Aryal, Ben Jarihani & Thomas Blaschke	2020	GEOMATICS, NATURAL HAZARDS AND RISK	1	1		1				1		1								SRTm - 30m		Artificial Neural Network/ Random Forest	
Gully headcut susceptibility modeling using functional trees, naïve Bayes tree, and random forest models	Mohsen Hosseinalizadeha, Narges Kariminejada, Wei Chenb, Hamid Reza Pourghasemic,d,* Mohammad Alinejada, Ali	2019	Science Direct	1	1	1	1	1					1	1	1			1			UAV 1 m		FT/ NBTree/RF	Random Forest
Hybrid Computational Intelligence Models for Improvement Gully Erosion Assessment	Alireza Arabameri 1,*, Wei Chen 2,3,4, Luigi Lombardo 5, Thomas Blaschke 6 and Dieu Tien Bui 7,*	2020	Remote Sensing	1	1		1	1									1				ALOS - 12,5 m		NBTree/FLD A/LMT	NBTree
Hydrological Modelling and Evaluation of Detention Ponds to Improve Urban Drainage System and Water Quality	Fernanda Pereira Souza, Maria Elisa Leite Costa * and Sergio Koide	2019	Water	1																			Storm Water Management Model - SWMM	
Modeling gully erosion susceptibility in Phuentsholing, Bhutan using deep learning and basic machine learning algorithms	Sunil Saha1 · Raju Sarkar2 · Gautam Thapa3 · Jagabandhu Roy1	2021	Earth Sciences	1	1		1	1						1		1					Palsar- 12,5 m	LULC/ Clay/ Altitude	CNN/ ANN/SVM/RF	CNN
Modeling Gully Erosion Susceptibility to Evaluate Human Impact on a Local Landscape System in Tigray, Ethiopia	Robert Busch *, Jacob Hardt, Nadav Nir and Brigitta Schütt	2021	Remote Sensing	1	1	1		1				1		1							ALOS GLOBAL - DSM 30m		Random Forest	Random Forest
Modelling of piping collapses and gully headcut landforms: 4 Evaluating topographic variables from different types of DEM	Alireza Arabameri,*, Fatemeh Rezaie,b,c, Subodh Chandra Pal,d, Artemi Cerdas, Asish GSahad, Rabin Chakrabortty, Saro Lee,h	2021	Journal Pre-proofs	1	1		1	1					1	1							ALOS PALSAR - 12,5 m e 30 m/ AW3D30 e ASTER		ML methods of conditional inference forests	
Novel Ensemble Approach of Deep Learning Neural Network (DLNN) Model and Particle Swarm Optimization (PSO) Algorithm for Prediction of Gully Erosion Susceptibility	Shahab S. Band 1,2,*, Saeid Janizadeh 3, Subodh Chandra Pal 4, Asish Saha 4, Rabin Chakrabortty 4, Manouchehr Shokri 5 and Amirhosein Mosavi 6,7	2020	Sensors	1	1		1	1					1								DEM- 12,5 m		SVM/ ANN/ DLNN/PSO	PSO-DLNN
Novel Machine Learning Approaches for Modelling the Gully Erosion Susceptibility	Alireza Arabameri 1, Omid Asadi Nalivan 2, Subodh Chandra Pal 3, Rabin Chakrabortty 3, Asish Saha 3, Saro Lee 4,5,*, Biswajeet Pradhan 6,7,8,9 and Dieu	2020	Remote Sensing	1	1		1		1	1						1					DALOS DEM - 12,5 m		ANN/ MaxEnt/SVM /GLM	ANN/SVM
Prediction of gully erosion susceptibility mapping using novel ensemble machine learning algorithms	Alireza Arabameri, Subodh Chandra Pal, Romulus Costache, Asish Saha, Fatemeh Rezaie, Amir Seyed Danesh, Biswajeet Pradhan, Saro Lee & Nhat Duc Hoang	2021	Geomatics, Natural Hazards and Risk	1	1					1			1	1							ALOS PALSAR - / GSI/ Landsat O8/O mapa topográfico com escala de 1:50.000 foi coletado de fontes		RF/ SVM/LR/ Modelos de referencia e GE-XGBoost	GE-XGBoost

Nome do Artigo	Autores	Ano	Revista	Parâmetros																			
				elevation Altitude	slope	slope degree	aspect	plan curvature	Hand	Plan	precipitation	Normalized difference vegetation index	profile curvature	Convergenc e Index - CI	EC	Relative Slope Position - RSP	Topographic wetness index	CA + Mg	Content of silt	Texture	Resolução do MDT	Parâmetros + Impotantes	Método
Proposing a Novel Predictive Technique for Gully Erosion Susceptibility Mapping in Arid and Semi-arid Regions (Iran)	Alireza Arabameri 1, Artemi Cerda 2, Jesús Rodrigo-Comino 2,3, Biswajeet Pradhan 4,5, Masoud Sohrabi 6, Thomas Blaschke 7 and Dieu Tien Bui 8,*	2019	Remote Sensing	1	1		1	1												ALOS - 30 m	Soil/Lithology/ elevation	index of entropy (IoE)/ Vise Kriterijumska Optimizacija I Kompromisno Resenje	IoE
Robustness analysis of machine learning classifiers in predicting spatial gully erosion susceptibility with altered training samples	Tusar Kanti Hembram, Sunil Saha, Biswajeet Pradhan, Khairul Nizam Abdul Maulud & Abdullah M. Alami	2021	Geomatics, Natural Hazards and Risk	1			1													ASTER GDM - 30m / Landsat 8- 30m/ Weather station precipitation data 30 m/Weather station recorded temperature data/ Topographical maps 1:50 000/Geomorphic features 1:50 000/ Reference		RF/ RT/ Naive Bayes - NB	Random Forest
Spatial modeling of gully head erosion on the Loess Plateau using a certainty factor and random forest model	Chengcheng Jiang a, Wen Fan a,b,*, Ningyu Yue,b, Enlong Liu c	2021	Science Direct	1	1		1	1					1	1						DEM - 10 m - Original/ Usado para conversão de 5 m de resolução após interpolação por meio do método TIN		certainty factor (CF)/random forest (RF)	Random Forest
Spatial Pattern Analysis and Prediction of Gully Erosion Using Novel Hybrid Model of Entropy-Weight of Evidence	Alireza Arabameri 1,* , Artemi Cerda 2 and John P. Tiefenbacher 3	2019	Water	1	1		1	1					1	1						ALOS - 12,5m	drainage density/ slope/ rainfall	IOE/WOE	Modelo híbrido de combinação entre IoE e WoE
Susceptibility to Gully Erosion: Applying Random Forest (RF) and Frequency Ratio (FR) Approaches to a Small Catchment in Ethiopia	Selamawit Amare 1,2,*, Eddy Langendoen 3, Saskia Keesstra 4,5, Martine van der Ploeg 6, Habtamu Gelagay 7, Hanibal Lemma 2 and Sjoerd E. A. T. M. van der Zee 1	2021	Water	1	1		1	1					1	1				1		ALOS - 12,6m/Soil data - 1:50 000	drainage density/elevati on/ land use/ groundwater	frequency ratio (FR)/random forest (RF)	Random Forest
Predicting gully densities at sub-continental scale: a case study for the Horn of Africa	Matthias Vanmaercke1,*, Yixian Chen1,2, Nigussie Hangeeweyn3, Sofie De Geeter1,4, Benjamin Campforts5, Wouter Heyndrickx6, Atsushi Tsunekawa7, Jean Poissen	2020	Earth Surface Processes and Landforms																			Random Forest	
Evaluation of Recent Advanced Soft Computing Techniques for Gully Erosion Susceptibility Mapping: A Comparative Study	Alireza Arabameri 1, Thomas Blaschke 2, Biswajeet Pradhan 3,4, Hamid Reza Pourghasemi 5,* , John P. Tiefenbacher 6 and Dieu Tien Bui	2020	Sensors	1	1			1						1						12.5		Frequency Ratio (FR) and Statistical Index (SI)/Random Forest (RF)/Maximum	Random Forest
Credal decision tree based novel ensemble models for spatial assessment of gully erosion and sustainable management	AlirezaArabameri1*, Nitheshnirmal Sadhasivam2,3, HamzaTurabieh4, Majdi Mafarja5, Fatemeh Rezaie6,7, Subodh Chandra Pal8 & M. Santosh9,1	2021	Scientific reports	1		1												1		12.5		Bagging/Daggin g/Random Forest/ NBTree	
Comparison of machine learning models for gully erosion susceptibility mapping	Alireza Arabameri a, Wei Chen b,c,d, Marco Loche e, Xia Zhao b, Yang Li b, Luigi Lombardo f, Artemi Cerda g, Biswajeet Pradhan h,i,* , Dieu Tien Bui j	2019	Science Direct	1	1		1	1					1	1						12.5		NBTree/ADTree/LMT	

Nome do artigo	Autores	Ano	Revista	drainage density,	distance from rivers	topographic	wetness index (TWI)	distance from road	road density	Stream-road junctions and sites of existing gullies	rainfall	land use	Land cover	distance to pathways	Distance to residential areas	NDVI	Lithology	Geomorphology	Soil classes	composite topographic index (CTI)	stream power index (SPI)	Resolução do MDT	Parâmetros + Importantes	Método	Melhor Método
A comparative assessment of gully erosion spatial predictive modeling using statistical and machine learning models	Sayed Masoud Soleimanpour a,*, Hamid Reza Pourghasemi b, Maryam Zare c	2021	Catena	1	1	1	1	1			1	1										1:25000	NÃO TEM	quick, unbiased, efficient statistical tree (QUEST) model frequency ratio (FR) and evidential belief	QUEST
A Comparative Assessment of Random Forest and k-Nearest Neighbor Classifiers for Gully Erosion Susceptibility Mapping	Mohammadtaghi Avand 1, Saeid Janizadeh 1, Seyed Amir Naghibi 1, Hamid Reza Pourghasemi 2,*, Saeid Khosrobeigi Bozchaloei 3 and Thomas Blaschke	2019	Water	1	1			1			1	1				1	1					ALOS PALSAR Global Radar 12,5 m	altitude rainfall distance to roads distance from the river	RF KNN	RF
A comparison of different Artificial Intelligence and Machine Learning methods for Gully Erosion Susceptibility Mapping in the Upper Narmada Basin	Vinay Raikwar Pramod Pagare Aminu Abdulwahab Priyank Pravin Patel Vikram Agone	in review		1					1	1	1	1				1		1	1	1		SRTM 30 m			
A Methodological Comparison of Three Models for Gully Erosion Susceptibility Mapping in the Rural Municipality of El Faïd (Morocco)	Ali Aze dou 1, , Said Lahssini 1, Abdellatif Khattabi 1, Modeste Meli ho 2 and Nabil Rifai 3	2021	Sustainability				1									1	1			1	1			Frequency Ratio (FR) Random Forest (RF) Logistic Regression (LR)	Logistic Regression (LR)
A wrapper feature selection approach for efficient modelling of gully erosion susceptibility mapping	Hamed Rouhani, Aboalhasan Fathabadi, Jantien Baartman	2021	Artide				1	1				1				1	1				1		Elevation/ distance to fault/slope/ index of connectivity	Logistic Regression (LR)/ SVM/ KNN	KNN
Assessing gully erosion susceptibility using topographic derived attributes, multi-criteria decision-making, and machine learning classifiers	Ahmed J. Al-Bawi, Alaa M. Al-Abadi, Biswajeet Pradhan & Abdullah M. Alami	2021	Geomatics, Natural Hazards and Risk				1														1	DEM resolução média	TWI/ SPI/ LS	Feature Selection /AHP and TOPSIS/SVM/ Naive bayes (NB)/ Performance evaluation metrics/ Software used and the	AHP-TOPSIS
Automatic gully detection: neural networks and computer vision	Arthur M. Gafurov, Oleg P. Yermolayev	2020	Remote Sensing																			Digital Globe		GECNN	
Comparison of differences in resolution and sources of controlling factors for gully erosion susceptibility mapping	Younes Garosi, Mohsen Sheklabadi, , Hamid Reza Pourghasemi, Ali Asghar Besalatpour, Christian Coscoventid, Kristof Van Oost Omid Rahmati a, Zahra Kalantari b, c, Carla Sofia Ferreira b, d, e, Wei Chen f, Seyed Masoud Soleimanpour g, , Marjana Kapović c-Solomon h, Samaneh Seifollahi-Aghmiuni b, , David Ghalamian b, Nader	2018	Science Direct				1					1				1								GLMs/BRT/MARS/ANN	
Contribution of physical and anthropogenic factors to gully erosion initiation	Kristof Van Oost Omid Rahmati a, Zahra Kalantari b, c, Carla Sofia Ferreira b, d, e, Wei Chen f, Seyed Masoud Soleimanpour g, , Marjana Kapović c-Solomon h, Samaneh Seifollahi-Aghmiuni b, , David Ghalamian b, Nader	2021	Science Direct	1			1	1				1					1						distance from roads and streams/land use/TWI/drainage intensity/aspect	maximum entropy (ME)/ random forest (RF)/ boosted regression trees (BRT)	Random Forest
Deep learning and boosting framework for piping erosion susceptibility modeling: spatial evaluation of agricultural areas in the semi-arid region	Yunzhi Chen, Wei Chen, Saeid Janizadeh, Gouri Sankar Bhunia, Amit Bera, Quoc Bao Pham, Nguyen Thi Thuy Linh, Abdul-Lateef Balogun & Xiaojing Wang	2021	Geocarto International	1	1			1				1											Topographic/ hidrological/geographical/soil	Boosted regression tree (BRT)/Boosted linear model (BLM)/Boosted generalized linear model (BGLM)	Deep Boosting/ BRT
Ensemble of Machine-Learning Methods for Predicting Gully Erosion Susceptibility	Subodh Chandra Pal 1, Alireza Arabameri 2, Thomas Blaschke 3, Indrajit Chowdhuri 1, Asish Saha 1, Rabin Chakraborty 1, Saro Lee 4,5 and Shahab. S. Band 6,*	2020	Remote Sensing	1			1									1	1	1			1		Slope/ LULC/ Drainage Density/ Profile Curvature,/ Geomorphology/ Ferrous Minerals/ Soil Texture	Random Forest/ Boosted Regression Tree/ K4Fold	K4Fold/ BRT

Nome do artigo	Autores	Ano	Revista	drainage density,	distance from rivers	topographic	wetness index (TWI)	distance from road	road density	Stream-road junctions and sites of existing gullies	rainfall	land use	Land cover	distance to pathways	Distance to residential areas	NDVI	Lithology	Geomorphology	Soil classes	composite topographic index (CTI)	stream power index (SPI)	Resolução do MDT	Parâmetros + Impotantes	Método	Melhor Método	
Ephemeral Gully Recognition and Accuracy 1 Evaluation using Deep Learning in the Hilly and 2 Gully Region of the Loess Plateau in China	Boyang Liuab, Biao Zhangab, Hao Fengb, Shufang Wuab*, Jiangtao Yangc, Yufeng S Zouabd, Kadamot H.M. Siddiquee	2021	Journal Pre-proof																			QuickBird, WorldView, Pleiades e SuperView 0,5 cm de resolução/ Vant./ UAV/ DII PHANTOM 4 RTK		SegNet/R2U-Net/U-Net		
Evaluating the Efficiency of Different Regression, Decision Tree, and Bayesian Machine Learning Algorithms in Spatial Piping Erosion Susceptibility Using ALOS/PALSAR Data	Shahab S. Band 1,2*, Saeid Janizadeh 3, Sunil Saha 4, Kaustuv Mukherjee 5, Saeid Khosrobeigi oz chaloiei 6, Artemi Cerdà 7, Manouchehr Shokri 8 and Amirhosein Mosavi 9,10	2020	Land	1	1		1				1	1					1					1	DEM - 12,5 M de resolução	PH/ Altitude/ Bulk Density/ CEC/ SOIL/ Distance From the River	Random Forest/ SVM/ Bayesian GLM	
Evaluation of different boosting ensemble machine learning models and novel deep learning and boosting framework for head-cut gully erosion susceptibility	Wei Chen a,b, Xinxiang Lei a, Rabin Chakraborty c, Subodh Chandra Pal c*, Mehebub Sahana d, Saeid Janizadeh e	2021	Science Direct	1	1		1	1				1					1					1	DEM de Alos Palsar- 12,7m de resolução	topographic/ geomorphological	Boosted Tree (BT)/Boosted Generalized Linear Models (BGLM)/Boosted Regression Tree (BRT)	Deep Boost
Evaluation of different DEMs for gully erosion susceptibility mapping using in-situ field measurement and validation	Indrajit Chowdhuri, Subodh Chandra Pal*, Asish Saha, Rabin Chakraborty, Paramita Roy	2021	Science Direct	1			1				1					1	1					1	SRTM- 30m/ ASTER- 30 m/ Cartosat1- 30 m/ AW3D- 30 m/ ALOS- 12,5 m/		ANN/ DLNN/ CNN	DLNN
Evaluation of Recent Advanced Soft Computing Techniques for Gully Erosion Susceptibility Mapping: A Comparative Study	Alireza Arabameri 1, Thomas Blaschke 2, Biswajeet Pradhan 3,4, Hamid Reza Pourghasemi 5*, John. Tiefenbacher 6 and Dieu Tien Bui 7,*	2020	Sensors	1	1		1	1			1					1	1						DEM de Alos- 12,5m de resolução		Frequency Ratio (FR) and Statistical Index (SI)/Random Forest (RF)/Maximum Entropy (ME)/ Generalized Linear Model (GLM)/ Functional Data	Random Forest
GIS-Based Gully Erosion Susceptibility Mapping: A Comparison of Computational Ensemble Data Mining Models	Janizadeh 3, Mohammadtaghi Avand 3, Wei Chen 4, Mohsen Farzin 5, Ebrahim Omidvar 6, Ataollah Shirzadi 7, Himan Shahabi 8,9, John J. Clague 10, Hamed Ahmadpour 1,*	2020	Applied Sciences	1	1			1			1	1				1	1						DEM de Alos Palsar- 12,5m de resolução	Rainfall/elevation/ river density	Bagging (Bag)/Random Subspace/Reduced-Error Pruning Tree (REPTree)	RS-REPTree
Gully erosion as a mechanism for wetland formation: An examination of two contrasting landscapes	Simon Pulley William N. Ellery Juliette V. Lagesse Philippa K. Schlegel Shaun J. McNamara	2018	Research article																							
Gully erosion spatial modelling: Role of machine learning algorithms in selection of the best controlling factors and modelling process	Hamid Reza Pourghasemi a*, Nitheeshnirmal Sadhasivam b, Narges Kariminejad c, Adrian L. Collins d	2020	Science Direct	1	1		1	1			1						1						ASTER- GDEM 30 m	Lasso/ SGLM/ GLM/ ENET/ PLS/ Ridge Regr/ SVM/ CART/ Bagged CART/ RF	Random Forest	
Gully Erosion Susceptibility Assessment in the Kondoran Watershed Using Machine Learning Algorithms and the Boruta Feature Selection	Hamed Ahmadpour 1, Omidbani Bazarfshan 1, Elham Rafiei-Sardooi 2, Hossein Zamani 3 and Thomas Panagopoulos 4,*	2021	Sustainability	1	1		1					1					1						DEM 30 m		Gully susceptibility mapping/ Random Forest/ SVM/ Multiple Discriminate Analysis (MDA)	Random Forest
Gully Erosion Susceptibility Mapping in Highly Complex Terrain Using Machine Learning Models	Annan Yang 1,2, Chunmei Wang 1,2, Guowei Pang 1,2, Yongqing Long 1,2*, Lei Wang 1,2, Richard M. Cruse 3 and Qinke Yang 1,2	2021	International Journal of Geo-Information	1			1	1				1										1	12,5 m		RF/ GBDT/ XGBoost	XGBoost

Nome do artigo	Autores	Ano	Revista	drainage density,	distance from rivers	topographic	wetness index (TWI)	distance from road	road density	Stream-road junctions and sites of existing gullies	rainfall	land use	Land cover	distance to pathways	Distance to residential areas	NDVI	Lithology	Geomorphology	Soil classes	composite topographic index (CTI)	stream power index (SPI)	Resolução do MDT	Parâmetros + Importantes	Método	Melhor Método
Gully erosion susceptibility mapping (GESM) using machine learning methods optimized by the multi-collinearity analysis and K-fold cross validation	Omid Ghorbanzadeh, Hejar Shahabi, Fahimeh Mircholi, Khalil Valizadeh Kamran, Samsung Lim, Jagannath Aryal, Ben Jarihani & Thomas Blaschke	2020	GEOMATICS, NATURAL HAZARDS AND RISK				1	1				1				1	1				1	SRTm - 30 m		Artificial Neural Network/ Random Forest	
Gully headcut susceptibility modeling using functional trees, naïve Bayes tree, and random forest models	Mohsen Hosseinalizadeha, Narges Kariminejada, Wei Chenb, Hamid Reza Pourghasemid, Mohammad Alinejada, Ali Mohammadian	2019	Science Direct				1	1				1										UAV 1 m		FT/ NBTree/RF	Random Forest
Hybrid Computational Intelligence Models for Improvement Gully Erosion Assessment	AlirezaArabameri 1,* , Wei Chen 2,3,4 , Luigi Lombardo 5 , Thomas Blaschke 6 and Dieu Tien Bui 7,*	2020	Remote Sensing	1				1			1	1				1	1				1	ALOS - 12,5 m		NBTree/FLDA/LMT	NBTree
Hydrological Modelling and Evaluation of Detention Ponds to Improve Urban Drainage System and Water Quality	Fernanda Pereira Souza, Maria Elisa Leite Costa* and Sergio Koide	2019	Water								1													Storm Water Management Model - SWMM	
Modeling gully erosion susceptibility in Phuentsholing, Bhutan using deep learning and basic machine learning algorithms	Sunil Saha1 , Raju Sarkar2 , Gautam Thapa3 , Jagabandhu Roy1	2021	Earth Sciences	1			1				1						1					Palsar- 12,5 m	LULC/ Day/ Altitude	CNN/ANN/SVM/RF	CNN
Modeling Gully Erosion Susceptibility to Evaluate Human Impact on a Local Landscape System in Tigray, Ethiopia	Robert Busch *, Jacob Hardt , Nadav Nir and Brigitta Schütt	2021	Remote Sensing	1	1		1					1	1	1	1							ALOS GLOBAL - DSM30m		Random Forest	Random Forest
Modelling of piping collapses and gully headcut landforms: 4 Evaluating topographic variables from different types of DEM	Alireza Arabameri,*, Fatemeh Rezaiebc, Subodh Chandra Pal d, Artemi Cerdas, Ashish Sahad, Rabin Chakraborty d, Saro Lee b	2021	Journal Pre-proofs	1			1				1	1	1				1					ALOS PALSAR - 12,5 m e 30 m/ AW3D30 e ASTER		ML methods of conditional inference forests (Cforest)/Cubist model/Elasticnet	
Novel Ensemble Approach of Deep Learning Neural Network (DLNN) Model and Particle Swarm Optimization (PSO) Algorithm for Prediction of Gully Erosion Susceptibility	Shahab S. Band 1,2,* , Saeid Janizadeh 3, Subodh Chandra Pal 4, Ashish Saha 4, Rabin Chakraborty 4, Manouchehr Shokri 5 and Amirhosein Mosavi 6,7	2020	Sensors	1	1		1				1	1					1				1	DEM - 12,5 m		SVM/ ANN/ DLNN/ PSO	PSO-DLNN
Novel Machine Learning Approaches for Modelling the Gully Erosion Susceptibility	AlirezaArabameri 1, Omid Asadi Nalivan 2, Subodh Chandra Pal 3, Rabin Chakraborty 3, Ashish Saha 3, Saro Lee 4,5,* , Biswajeet Pradhan 6,7,8,9 and Dieu Tien	2020	Remote Sensing	1				1				1	1				1					DALOS DEM - 12,5 m		ANN/ MaxEnt/SVM/GLM	ANN/SVM
Prediction of gully erosion susceptibility mapping using novel ensemble machine learning algorithms	AlirezaArabameri, Subodh Chandra Pal, Romulus Costache, Ashish Saha, Fatemeh Rezaie, Amir Seyed Danesh, Biswajeet Pradhan, Saro Lee & Nhat Duc Hoang	2021	Geomatics, Natural Hazards and Risk	1			1	1			1		1			1	1	1			1	ALOS PALSAR-/ GSI/ Landsat 08/ O m a p a t o p o g r á f i c o c o m e s c a l a d e 1:50.000foi coletado de fontes		RF/ SVM/LR/ - Modelos de referencia e GE-XGBoost	GE-XGBoost

Nome do artigo	Autores	Ano	Revista	drainage density,	distance from rivers	topographic	wetness Index (TWI)	distance from road	road density	Stream-road junctions and sites of existing gullies	rainfall	land use	Land cover	distance to pathways	Distance to residential areas	NDVI	Lithology	Geomorphology	Soil classes	composite topographic Index (CTI)	stream power Index (SPI)	Resolução do MDT	Parâmetros + Impotantes	Método	Melhor Método	
Proposing a Novel Predictive Technique for Gully Erosion Susceptibility Mapping in Arid and Semi-arid Regions (Iran)	Alireza Arabameri 1, Artemi Cerdà 2, Jesús Rodrigo-Comino 2,3, Biswajeet Pradhan 4,5, Masoud Sohrabi 6, Thomas Blaschke 7 and Dieu Tien Bui 8,*	2019	Remote Sensing	1	1		1	1			1	1	1				1					1	ALOS - 30m	Soil/Lithology/elevation	index of entropy (IoE)/ Vlse Kriterijumska Optimizacija I Kompromisno Resenje (VIKOR)	IoE
Robustness analysis of machine learning classifiers in predicting spatial gully erosion susceptibility with altered training samples	Tusar Kanti Hembram, Sunil Saha, Biswajeet Pradhan, Khairul Nizam Abdul Maulud & Abdullah M. Alamri	2021	Geomatics, Natural Hazards and Risk		1		1									1		1				1	ASTER GDM - 30m / Landsat 8-30m/Weather station precipitation data 30 m/Weather station recorded temperature data/ Topographical maps		RF/ RT/ Naive Bayes - NB	Randon Forest
Spatial modeling of gully head erosion on the Loess Plateau using a certainty factor and random forest model	Chengcheng Jiang a, Wen Fan a,b,*, Ningyu Yu a,b, Enlong Liu c	2021	Science Direct				1					1				1	1						DEM - 10m - Original/ Usado para conversão de 5 m de resolução após interpolação por meio do método TIN		certainty factor (CF)/random forest (RF)	Randon Forest
Spatial Pattern Analysis and Prediction of Gully Erosion Using Novel Hybrid Model of Entropy-Weight of Evidence	Alireza Arabameri 1,*, Artemi Cerdà 2 and John P. Tiefenbacher 3	2019	Water	1			1	1			1						1					1	ALOS - 12,5m	drainage density/ slope/ rainfall	IOE/WOE	Modelo híbrido de combinação entre IoE e WoE
Susceptibility to Gully Erosion: Applying Random Forest (RF) and Frequency Ratio (FR) Approaches to a Small Catchment in Ethiopia	Selamawit Amare 1,2,*, Eddy Langendoen 3, Saskia Keesstra 4,5, Martine van der Ploeg 6, Habtmu Gelagay 7, Hanibal Lemma 2 and Sjoerd E. A. T. M. van der Zee 1	2021	Water	1									1									1	ALOS - 12,6m/Soil data - 1:50.000	drainage density/elevation/ land use/ groundwater	frequency ratio (FR)/random forest (RF)	Randon Forest
Predicting gully densities at sub-continental scales: a case study for the Horn of Africa	Matthias Vanmaercke1,*, Yixian Chen1,2, Nigussie Haregeweyn3, Sofie De Geeter1,4, Benjamin Campfort5, Wouter Heyndrickx6, Atsushi Tsunekawa7, Jean Poesen	2020	Earth Surface Processes and Landforms																						Randon Ferest	
Evaluation of Recent Advanced Soft Computing Techniques for Gully Erosion Susceptibility Mapping: A Comparative Study	Alireza Arabameri 1, Thomas Blaschke 2, Biswajeet Pradhan 3,4, Hamid Reza Pourghasemi 5,*, John P. Tiefenbacher 6 and Dieu Tien Bui	2020	Sensors	1			1	1			1					1	1						12.5		Frequency Ratio (FR) and Statistical Index (SI)/Random Forest (RF)/Maximum Entropy (ME)/Generalized Linear Model (GLM)/Functional Data Analysis	Randon Forest
Credal decision tree based novel ensemble models for spatial assessment of gully erosion and sustainable management	AlirezaArabameri1*, Nitheshnirmal Sadhasivam2,3, HamzaTurabieh4, Majdi Mafarja5, Fatemeh Rezaei6,7, Subodh Chandra Pal8 & M. Santosh9,1	2021	Scientific reports	1			1	1			1	1				1	1						12.5		Bagging/Dagging/ Randon Forest/ NBTree	
Comparison of machine learning models for gully erosion susceptibility mapping	Alireza Arabameri a, Wei Chen b,c,d, Marco Loche e, Xia Zhao b, Yang Li b, Luigi Lombardo f, Artemi Cerdà g, Biswajeet Pradhan h,i,*, Dieu Tien Bui j	2019	Science Direct	1			1	1			1						1					1	12.5		NBTree/ADTree/LMT	

																		Resolução do MDT	Parâmetros + Impotantes	Método	Melhor Método
Nome do Artigo	Autores	Ano	Revista	Valley Depth - VD	multi-resolution index of valley bottom flatness (MRVBF)	LS	terrain surface texture (TST)	Catchment area	Distance from stream	Sand	Silt	Clay	Terrace	PH	Bulk Density	ESP	Temperature				
Ephemeral Gully Recognition and Accuracy 1 Evaluation using Deep Learning in the Hilly and 2 GullyRegion of the Loess Plateau in China	Boyang Liuab , Biao Zhangab , Hao Fengb , Shufang Wuab* , Jiangtao Yangc , Yufeng 5 Zouabd , Kadambot H.M. Siddiquee	2021	Journal Pre-proof															QuickBird, WorldView, Pleiades e SuperView 0,5 m de resolução/Vant / UAV/ DJI PHANTOM 4 RTK		SegNet/R2U-Net/U-Net	
Evaluating the Efficiency of Different Regression, Decision Tree, and Bayesian Machine Learning Algorithms in Spatial Piping Erosion Susceptibility Using ALOS/PALSAR Data	Shahab S. Band 1,2,* , Saeid Janizadeh 3 , Sunil Saha 4 , Kaustuv Mukherjee 5 , Saeid Khosrobeigiozchaloel 6 , Artemi Cerdà 7 , Manouchehr Shokri 8 and Amirhosein Mosavi 9,10	2020	Land							1	1	1		1	1			DEM - 12,5 M de resolução	PH/ Altitude/ Bulk Density/ CEC/ SOIL/ Distance From the River	Randon Forest/ SVM/ Bayesian GLM	
Evaluation of different boosting ensemble machine learning models and novel deep learning and boosting framework for head-cut gully erosion susceptibility	Wei Chen a,b , Xinxiang Lei a , Rabin Chakrabortty c , Subodh Chandra Pal c,* , Mehebbub Sahana d , Saeid Janizadeh e	2021	Science Direct															DEM de Alos Palsar - 12,7m de resolução	topographic/ geomorphological	Boosted tree (BT)/Boosted Generalized Linear Models (BGLM)/Boosted Regression Tree (BRT)/Extreme	Deep Boost
Evaluation of different DEMs for gully erosion susceptibility mapping using in-situ field measurement and validation	Indrajit Chowdhuri, Subodh Chandra Pal* , Asish Saha, Rabin Chakrabortty, Paramita Roy	2021	Science Direct						1									SRTM - 30 m/ ASTER - 30 m/ Cartosat1 - 30 m/ AW3D - 30 m/ ALOS - 12,5 m/ Ancillary data		ANN/ DLNN/ CNN	DLNN
Evaluation of Recent Advanced Soft Computing Techniques for Gully Erosion Susceptibility Mapping: A Comparative Study	Alireza Arabameri 1 , Thomas Blaschke 2 , Biswajeet Pradhan 3,4,Hamid Reza Pourghasemi 5,* , John. Tiefenbacher 6 and Dieu Tien Bui 7,*	2020	Sensors															DEM de Alos- 12,5m de resolução	Frequency Ratio (FR) and Statistical Index (SI)/Random Forest (RF)/Maximum Entropy (ME/ Generalized Linear Model (GLM)/	Random Forest	
GIS-Based Gully Erosion Susceptibility Mapping: A Comparison of Computational Ensemble Data Mining Models	Viret-Harindra 1,2, Saeid Janizadeh 3 , Mohammadtaghi Avand 3 , Wei Chen 4 , Mohsen Farzin 5 , Ebrahim Omidvar 6 , Ataollah Shirzadi 7 , Himan Shahabi 8,9 , John J. Clague 10 , Atafshah Farzad 11,12,13,14,15,16,17,18,19,20,21,22,23,24,25,26,27,28,29,30,31,32,33,34,35,36,37,38,39,40,41,42,43,44,45,46,47,48,49,50,51,52,53,54,55,56,57,58,59,60,61,62,63,64,65,66,67,68,69,70,71,72,73,74,75,76,77,78,79,80,81,82,83,84,85,86,87,88,89,90,91,92,93,94,95,96,97,98,99,100	2020	Applied Sciences															DEM de Alos Palsar - 12,5m de resolução	Rainfall/elevation/riv er density	Bagging (Bag)/Random Subspace/Reduced-Error Pruning Tree (REPTree)	RS-REPTree
Gully erosion as a mechanism for wetland formation: An examination of two contrasting landscapes	Simon Pulley William N. Ellery Juliette V. Lagesse Philippa K. Schlegel Shaun J. McNamara	2018	Research article																		
Gully erosion spatial modelling: Role of machine learning algorithms in selection of the best controlling factors and modelling process	Hamid Reza Pourghasemi a,* , Nitheshnirmal Sadhasivam b , Narges Kariminejad c , Adrian L. Collins d	2020	Science Direct															ASTER - GDEM 30 m		Lasso/ SGLM/ GLM/ ENET/ PLS/Ridge Regr/SVM/CART/Bagged CART/ RF	Random Forest
Gully Erosion Susceptibility Assessment in the Kondoran Watershed Using Machine Learning Algorithms and the Boruta Feature Selection	Hamed Ahmadpour 1 , Ommolbanin Bazrafshan 1 , Elham Rafiei-Sardooi 2 , Hossein Zamani 3 and Thomas Panagopoulos 4,*	2021	Sustainability				1											DEM 30 m		Gully susceptibility mapping/ Randon Forest/ SVM/ Multiple Discriminate Analysis (MDA)	Random Forest
Gully Erosion Susceptibility Mapping in Highly Complex Terrain Using Machine Learning Models	Annan Yang 1,2, Chunmei Wang 1,2 , Guowei Pang 1,2, Yongqing Long 1,2,* , Lei Wang 1,2, Richard M. Cruse 3 and Qinke Yang 1,2	2021	International Journal of Geo - Information				1		1				1					12,5 m		RF/ GBDT/XGBoost	XGBoost

Nome do Artigo	Autores	Ano	Revista	Valley Depth - VD	multi-resolution index of valley bottom flatness (MRVBF)	LS	terrain surface texture (TST)	Catchment area	Distance from stream	Sand	Silt	Clay	Terrace	PH	Bulk Density	ESP	Temperature	Resolução do MDT	Parâmetros + Impotantes	Método	Melhor Método
Gully erosion susceptibility mapping (GESM) using machine learning methods optimized by the multi-collinearity analysis and K-fold cross validation	Omid Ghorbanzadeh, Hejar Shahabi, Fahimeh Mirchooli, Khalil Valizadeh Kamran, Samsung Lim, Jagannath Aryal, Ben Jarihani & Thomas Blaschke	2020	GEOMATICS, NATURAL HAZARDS AND RISK						1									SRTm - 30 m		Artificial Neural Network/Random Forest	
Gully headcut susceptibility modeling using functional trees, naive Bayes tree, and random forest models	Mohsen Hosseinalizadeha, Narges Kariminejada, Wei Chenb, Hamid Reza Pourghasemid, d,* Mohammad Alinejada, Ali Mohammadian	2019	Science Direct			1			1	1	1			1	1	1		UAV 1 m		FT/ NBTree/RF	Random Forest
Hybrid Computational Intelligence Models for Improvement Gully Erosion Assessment	Alireza Arabameri 1,* , Wei Chen 2,3,4, Luigi Lombardo 5, Thomas Blaschke 6 and Dieu Tien Bui 7,*	2020	Remote Sensing			1			1									ALOS - 12,5 m		NBTree/FLDA/LMT	NBTree
Hydrological Modelling and Evaluation of Detention Ponds to Improve Urban Drainage System and Water Quality	Fernanda Pereira Souza, Maria Elisa Leite Costa * and Sergio Koide	2019	Water																	Storm Water Management Model - SWMM	
Modeling gully erosion susceptibility in Phuentsholing, Bhutan using deep learning and basic machine learning algorithms	Sunil Saha1 · Raju Sarkar2 · Gautam Thapa3 · Jagabandhu Roy1	2021	Earth Sciences	1						1	1	1						Palsar- 12,5 m	LULC/ Clay/ Altitude	CNN/ ANN/SVM/RF	CNN
Modeling Gully Erosion Susceptibility to Evaluate Human Impact on a Local Landscape System in Tigray, Ethiopia	Robert Busch *, Jacob Hardt , Nadav Nir and Brigitta Schütt	2021	Remote Sensing															ALOS GLOBAL - DSM 30m		Random Forest	Random Forest
Modelling of piping collapses and gully headcut landforms: 4 Evaluating topographic variables from different types of DEM	Alireza Arabameri*, Fatemeh Rezaie, c, Subodh Chandra Pal d, Artemi Cerdas, Asish 6 Sahad, Rabin Chakrabortty d, Saro Lee b	2021	Journal Pre-proofs		1				1									ALOS PALSAR - 12,5 m e 30 m/ AW3D30 e ASTER		ML methods of conditional inference forests (Cforest)/Cubist model/Elasticnet	
Novel Ensemble Approach of Deep Learning Neural Network (DLNN) Model and Particle Swarm Optimization (PSO) Algorithm for Prediction of Gully Erosion Susceptibility	Shahab S. Band 1,2,* , Saeid Janizadeh 3, Subodh Chandra Pal 4, Asish Saha 4, Rabin Chakrabortty 4, Manouchehr Shokri 5 and Amirhosein Mosavi 6,7	2020	Sensors															DEM - 12,5 m		SVM/ ANNN/ DLNN/PSO	PSO-DLNN
Novel Machine Learning Approaches for Modelling the Gully Erosion Susceptibility	Alireza Arabameri 1, Omid Asadi Nalivan 2, Subodh Chandra Pal 3, Rabin Chakrabortty 3, Asish Saha 3, Saro Lee 4,5,* , Biswajeet Pradhan 6,7,8,9 and Dieu Tien	2020	Remote Sensing	1					1			1			1			DALOS DEM - 12,5 m		ANN/ MaxEnt/SVM/GLM	ANN/SVM
Prediction of gully erosion susceptibility mapping using novel ensemble machine learning algorithms	Alireza Arabameri, Subodh Chandra Pal, Romulus Costache, Asish Saha, Fatemeh Rezaie, Amir Seyed Danesh, Biswajeet Pradhan, Saro Lee & Nhat Duc Hoang	2021	Geomatics, Natural Hazards and Risk						1									ALOS PALSAR -/ GSI/ Landsat 08/O mapa topográfico com escala de 1:50.000 foi coletado de fontes secundárias (www.ngo-org.ir).		RF/ SVM/LR/ - Modelos de referencia e GE-XGBoost	GE-XGBoost

Nome do Artigo	Autores	Ano	Revista	Valley Depth - VD	multi-resolution index of valley bottom flatness (MRVBF)	LS	terrain surface texture (TST)	Catchment area	Distance from stream	Sand	Silt	Clay	Terrace	PH	Bulk Density	ESP	Temperature	Resolução do MDT	Parâmetros + Impotantes	Método	Melhor Método
Proposing a Novel Predictive Technique for Gully Erosion Susceptibility Mapping in Arid and Semi-arid Regions (Iran)	Alireza Arabameri 1, Artemi Cerda 2, Jesús Rodrigo-Comino 2,3, Biswajeet Pradhan 4,5, Masoud Sohrabi 6, Thomas Blaschke 7 and Dieu Tien Bui 8,*	2019	Remote Sensing															ALOS - 30 m	Soil/Lithology/elevation	index of entropy (IoE)/Vise Kriterijumska Optimizacija I Kompromisno Resenje (VIKOR)	IoE
Robustness analysis of machine learning classifiers in predicting spatial gully erosion susceptibility with altered training samples	Tusan Kanti Hembram, Sunil Saha, Biswajeet Pradhan, Khairul Nizam Abdul Maulud & Abdullah M. Alami	2021	Geomatics, Natural Hazards and Risk			1											1	ASTER GDM - 30m / Landsat 8-30m/Weather station precipitation data 30 m/Weather station recorded temperature data/ Topographical maps 1:50.000/Geomorphic features 1:50.000/ Reference		RF/ RT/ Naive Bayes - NB	Random Forest
Spatial modeling of gully head erosion on the Loess Plateau using a certainty factor and random forest model	Chengcheng Jiang a, Wen Fan a,b,*, Ningyu Yua,b, Enlong Liu c	2021	Science Direct			1												DEM - 10 m - Original/ Usado para conversão de 5 m de resolução após interpolação por meio do método TIN		certainty factor (CF)/random forest (RF)	Random Forest
Spatial Pattern Analysis and Prediction of Gully Erosion Using Novel Hybrid Model of Entropy-Weight of Evidence	Alireza Arabameri 1,* , Artemi Cerda 2 and John P. Tiefenbacher 3	2019	Water			1			1									ALOS - 12,5m	drainage density/ slope/ rainfall	IOE/WOE	Modelo híbrido de combinação entre IoE e WoE
Susceptibility to Gully Erosion: Applying Random Forest (RF) and Frequency Ratio (FR) Approaches to a Small Catchment in Ethiopia	Selamawit Amare 1,2,*, Eddy Langendoen 3, Saskia Keesstra 4,5, Martine van der Ploeg 6, Habtamu Gelagay 7, Hanibal Lemma 2 and Sjoerd E. A. T. M. van der Zee 1	2021	Water															ALOS - 12,6m/Soil data - 1:50.000	drainage density/elevation/ land use/ groundwater	frequency ratio (FR)/random forest (RF)	Random Forest
Predicting gully densities at sub-continental scales: a case study for the Horn of Africa	Matthias Vanmaercke1,*, Yixian Chen2, Nigussie Haregeweyn3, Sofie De Geeter1,4, Benjamin Campforts5, Wouter Heyndrickx6, Atsushi Tsunekawa7, Jean Foesen	2020	Earth Surface Processes and Landforms																	Random Forest	
Evaluation of Recent/Advanced Soft Computing Techniques for Gully Erosion Susceptibility Mapping: A Comparative Study	Alireza Arabameri 1, Thomas Blaschke 2, Biswajeet Pradhan 3,4, Hamid Reza Pourghasemi 5,* , John P. Tiefenbacher 6 and Dieu Tien Bui	2020	Sensors						1									12.5		Frequency Ratio (FR) and Statistical Index (SI)/Random Forest (RF)/Maximum Entropy (ME)/Generalized Linear Model (GLM)	Random Forest
Credal decision tree based novel ensemble models for spatial assessment of gully erosion and sustainable management	Alireza Arabameri 1*, Nitheshnimal Sadhasivam 2,3, Hamza Turabieh 4, Majdi Mafarja 5, Fatemeh Rezaei 6,7, Subodh Chandra Pal 8 & M. Santosh 9,1	2021	Scientific reports						1			1			1			12.5		Bagging/Dagging/Random Forest/NBTree	
Comparison of machine learning models for gully erosion susceptibility mapping	Alireza Arabameri a, Wei Chen b,c,d, Marco Loche e, Xia Zhao b, Yang Li b, Luigi Lombardi f, Artemi Cerda g, Biswajeet Pradhan h,i,*, Dieu Tien Bui j	2019	Science Direct			1			1									12.5		NBTree/ADTree/LMIT	

Nome do artigo	Autores	Ano	Revista																	Resolução do MDT	Parâmetros + Impotantes	Método	Melhor Método
				Rainfall	Geology	Iron Oxide	Ferrous Minerals	Lineament Density	Distance to Drainage	stream Density	FVC	Slope Gradient	Convergence Index	Bedrock	SOIL EC	Soil Depth	Mineral Soil	groundwater	Soil				
A comparative assessment of gully erosion spatial predictive modeling using statistical and machine learning models	Seyed Masoud Soleimanpour a,*, Hamid Reza Pourghasemi b, Maryam Zare c	2021	Catena																1:25000	NÃO TEM	quick, unbiased, efficient statistical tree (QUEST) model frequency ratio (FR) and	QUEST	
A Comparative Assessment of Random Forest and k-Nearest Neighbor Classifiers for Gully Erosion Susceptibility Mapping	Mohammadtaghi Avand 1, Saeid Janizadeh 1, Seyed Amir Naghibi 1, Hamid Reza Pourghasemi 2,*, Saeid Khosrobeigi Bozchaloei 3 and Thomas Blaschke	2019	Water																ALOS PALSAR Global Radar 12,5 m	altitude rainfall distance to roads distance from the river	RF KNN	RF	
A comparison of different Artificial Intelligence and Machine Learning methods for Gully Erosion Susceptibility Mapping in the Upper Narmada Basin	Vinay Raikwar Pramod Pagare Aminu Abdulwahab Priyank Pravin Patel Vikram Agone	in review																	SRTM 30 m				
A Methodological Comparison of Three Models for Gully Erosion Susceptibility Mapping in the Rural Municipality of El Faid (Morocco)	Ali Azedou 1, Said Lahssini 1, Abdellatif Khattabi 1, Modeste Meliho 2 and Nabil Rifai 3	2021	Sustainability																		Frequency Ratio (FR) Random Forest (RF) Logistic Regression (LR)	Logistic Regression (LR)	
A wrapper feature selection approach for efficient modelling of gully erosion susceptibility mapping	Hamed Rouhani, Aboalhasan Fathabadi, Jantien Baartman	2021	Artide																	Elevation/ distance to fault/slope/ index of connectivity	Logistic Regression (LR)/ SVM/ KNN	KNN	
Assessing gully erosion susceptibility using topographic derived attributes, multi-criteria decision-making, and machine learning classifiers	Ahmed J. Al-Bawi, Alaa M. Al-Abadi, Biswajeet Pradhan & Abdullah M. Alami	2021	Geomatics, Natural Hazards and Risk																DEMresolução média	TWI/ SPI/ LS	Feature Selection /Ahp and TOPSIS/SVM/ Naive bayes (NB)/ Performance evaluation matrices/	AHP-TOPSIS	
Automatic gully detection: neural networks and computer vision	Arthur M. Gafurov, Oleg P. Yermolayev	2020	Remote Sensing																Digital Globe		GECNN		
Comparison of differences in resolution and sources of controlling factors for gully erosion susceptibility mapping	Younes Garosi, Mohsen Shekhabadi, Hamid Reza Pourghasemi, Ali Asghar Besalatpour, Christian Conocentid, Kristof Van Oost, Umio Kihmami a, Zahira Kalantari b, c, Carla Sofia Ferreira b, d, e, Wei Chen f, Seyed Masoud Soleimanpour g, Marijana Kapovic c-Solomon h, Samaneh Seifollahi-Aghmiuni b, Navid Ghahani b, Nader	2018	Science Direct																		GLMs/BRT/MARS/ANN		
Contribution of physical and anthropogenic factors to gully erosion initiation	Kalantari b, c, Carla Sofia Ferreira b, d, e, Wei Chen f, Seyed Masoud Soleimanpour g, Marijana Kapovic c-Solomon h, Samaneh Seifollahi-Aghmiuni b, Navid Ghahani b, Nader	2021	Science Direct																	distance from roads and streams/land use/TWI/drainage intensity/aspect	maximum entropy (ME)/ random forest (RF)/ boosted regression trees (BRT)	Random Forest	
Deep learning and boosting framework for piping erosion susceptibility modeling: spatial evaluation of agricultural areas in the semi-arid region	Yunzhi Chen, Wei Chen, Saeid Janizadeh, Gouri Sankar Bhunia, Amit Bera, Quoc Bao Pham, Nguyen Thi Thuy Linh, Abdul-Lateef Balogun & Xiaojing Wang	2021	Geocarto International																1	Topographic/ hidrological/geographical/soil	Boosted regression tree (BRT)/Boosted linear model (BLM)/Boosted generalized linear model (BGLM)	Deep Boosting/ BRT	
Ensemble of Machine-Learning Methods for Predicting Gully Erosion Susceptibility	Subodh Chandra Pal 1, Alireza Arabameri 2, Thomas Blaschke 3, Indrajit Chowdhuri 1, Asish Saha 1, Rabin Chakraborty 1, Saro Lee 4,5 and Shahab. S. Band 6,*	2020	Remote Sensing	1	1	1	1	1	1										1	Slope/ LULC/ Drainage Density/ Profile Curvature./ Geomorphology/ Ferrous Minerals/ Soil Texture	Random Forest/ Boosted Regression Tree/K4 Fold	K4 Fold/ BRT	

Nome do artigo	Autores	Ano	Revista																	Resolução do MDT	Parâmetros + Impotantes	Método	Melhor Método
				Rainfall	Geology	Iron Oxide	Ferrous Minerals	Lineament Density	Distance to Drainage	stream Density	FVC	Slope Gradient	Convergence index	Bedrock	SOIL EC	Soil Depth	Mineral Soil	groundwater	Soil				
Ephemeral Gully Recognition and Accuracy 1 Evaluation using Deep Learning in the Hilly and 2 GullyRegion of the Loess Plateau in China	Boyang Liua,b , Biao Zhangab , Hao Fengb , Shufang Wuab* , Jiangtao Yangc , Yufeng 5 Zouabd , Kadambot H.M. Siddiquee	2021	Journal Pre-proof																	QuickBird, WorldView, Pleiades e SuperView 0,5 cm de resolução/ Vant / UAV / DJI PHANTOM 4 RTK		SegNet/R2U-Net/U-Net	
Evaluating the Efficiency of Different Regression, Decision Tree, and Bayesian Machine Learning Algorithms in Spatial Piping Erosion Susceptibility Using ALOS/PALSAR Data	Shahab S. Band 1,2,* , Saeid Janizadeh 3 , Sunil Saha 4 , Kaustuv Mukherjee 5, Saeid Khosrobeigiozchaloel 6, Artemi Cerdà 7 , Manouchehr Shokri 8 and Amirhosein Mosavi 9,10	2020	Land																	DEM - 12,5 m de resolução	PH/ Altitude/ Bulk Density/ CEC/ SOIL/ Distance From the River	Random Forest/ SVM/ Bayesian GLM	
Evaluation of different boosting ensemble machine learning models and novel deep learning and boosting framework for head-cut gully erosion susceptibility	Wei Chen a,b , Xinxiang Lei a , Rabin Chakraborty c , Subodh Chandra Pal c,* , Meheebub Sahana d , Saeid Janizadeh e	2021	Science Direct	1															1	DEM de Alos Palsar - 12,7m de resolução	topographic/ geomorphological	Boosted tree (BT)/Boosted Generalized Linear Models (BGLM)/Boosted Regression Tree	Deep Boost
Evaluation of different DEMs for gully erosion susceptibility mapping using in-situ field measurement and validation	Indrajit Chowdhuri, Subodh Chandra Pal* , Ashish Saha, Rabin Chakraborty, Paramita Roy	2021	Science Direct			1													1	ASTER - 30 m/ ASTER - 30 m/ Cartosat1 - 30 m/ AW3D - 30 m/ ALOS - 12,5 m/ Ancillary data		ANN/ DLNN/ CNN	DLNN
Evaluation of Recent Advanced Soft Computing Techniques for Gully Erosion Susceptibility Mapping: A Comparative Study	Alireza Arabameri 1, Thomas Blaschke 2, Biswajeet Pradhan 3,4, Hamid Reza Pourghasemi 5,* , John . Tiefenbacher 6 and Dieu Tien Bui 7,*	2020	Sensors																1	DEM de Alos- 12,5m de resolução		Frequency Ratio (FR) and Statistical Index (SI)/Random Forest (RF)/Maximum Entropy (ME/ Generalized Linear Model (GLM)/	Random Forest
GIS-Based Gully Erosion Susceptibility Mapping: A Comparison of Computational Ensemble Data Mining Models	Janizadeh 3 , Mohammadtaghi Avand 3 , Wei Chen 4 , Mohsen Farzin 5 , Ebrahim Omidvar 6 , Ataollah Shirzadi 7 , Himan Shahabi 8,9 , John J. Clague 10 ,	2020	Applied Sciences																	DEM de Alos Palsar - 12,5m de resolução	Rainfall/elevation/river density	Bagging (Bag)/Random Subspace/Reduced-Error Pruning Tree (REPTree)	RS-REPTree
Gully erosion as a mechanism for wetland formation: An examination of two contrasting landscapes	Simon Pulley William N. Ellery Juliette V. Lagesse Philippa K. Schlegel Shaun J. McNamara	2018	Research article																				
Gully erosion spatial modelling: Role of machine learning algorithms in selection of the best controlling factors and modelling process	Hamid Reza Pourghasemi a,* , Nitheshnirmal Sadhasivam b , Narges Kariminejad c, Adrian L. Collins d	2020	Science Direct																1	ASTER - GDEM 30 m		Lasso/ SGLM/ GLM/ ENET/ PLS/Ridge Regr/SVM/CART/Bagged CART/ RF	Random Forest
Gully Erosion Susceptibility Assessment in the Kondoran Watershed Using Machine Learning Algorithms and the Boruta Feature Selection	Hamed Ahmadvand 1 , Omolbanin Bazrafshan 1 , Elham Rafiei-Sardooi 2 , Hossein Zamani 3 and Thomas Panagopoulos 4,*	2021	Sustainability																1	DEM 30 m		Gully susceptibility mapping/ Random Forest/ SVM/ Multiple Discriminate Analysis (MDA)	Random Forest
Gully Erosion Susceptibility Mapping in Highly Complex Terrain Using Machine Learning Models	Annan Yang 1,2, Chunmei Wang 1,2 , Guowei Pang 1,2, Yongqing Long 1,2,* , Lei Wang 1,2, Richard M. Cruse 3 and Qinke Yang 1,2	2021	International Journal of Geo-Information								1	1								12,5 m		RF/ GBDT/ XGBoost	XGBoost

Nome do artigo	Autores	Ano	Revista																	Resolução do MDT	Parâmetros + Impotantes	Método	Melhor Método
				Rainfall	Geology	Iron Oxide	Ferrous Minerals	Lineament Density	Distance to Drainage	stream Density	FVC	Slope Gradient	Convergence Index	Bedrock	SOIL EC	Soil Depth	Mineral Soil	groundwater	Soil				
Gully erosion susceptibility mapping (GESM) using machine learning methods optimized by the multi-collinearity analysis and K-fold cross validation	Omid Ghorbanzadeh, Hejar Shahabi, Fahimeh Mirchooli, Khalil Valizadeh Kamran, Samsung Um, Jagannath Aryal, Ben Jarihani & Thomas Blaschke	2020	GEOMATICS, NATURAL HAZARDS AND RISK							1									1	SRTm - 30 m		Artificial Neural Network/ Random Forest	
Gully headcut susceptibility modeling using functional trees, naïve Bayes tree, and random forest models	Mohsen Hosseinalizadeh, Narges Kariminejad, Wei Chenb, Hamid Reza Pourghasemid,* Mohammad Alinejad, Ali Mohammadian	2019	Science Direct							1										UAV 1 m		FT/ NBTree/RF	Random Forest
Hybrid Computational Intelligence Models for Improvement Gully Erosion Assessment	Alireza Arabameri 1,* , Wei Chen 2,3,4 , Luigi Lombardo 5 , Thomas Blaschke 6 and Dieu Tien Bui 7,*	2020	Remote Sensing										1						1	ALOS - 12,5 m		NBTree/FLDA/LMIT	NBTree
Hydrological Modelling and Evaluation of Detention Ponds to Improve Urban Drainage System and Water Quality	Fernanda Pereira Souza, Maria Elisa Leite Costa * and Sergio Koide	2019	Water																			Storm Water Management Model - SWMM	
Modeling gully erosion susceptibility in Phuentsholing, Bhutan using deep learning and basic machine learning algorithms	Sunil Saha1 · Raju Sarkar2 · Gautam Thapa3 · Jagabandhu Roy1	2021	Earth Sciences																	Palsar- 12,5 m	LULC/ Clay/ Altitude	CNN/ ANN/SVM/RF	CNN
Modeling Gully Erosion Susceptibility to Evaluate Human Impact on a Local Landscape System in Tigray, Ethiopia	Robert Busch *, Jacob Hardt , Nadav Nir and Brigitta Schlütt	2021	Remote Sensing											1					1	ALOS GLOBAL - DSM 30m		Random Forest	Random Forest
Modelling of piping collapses and gully headcut landforms: 4 Evaluating topographic variables from different types of DEM	Alireza Arabameri,*, Fatemeh Rezaiebc, Subodh Chandra Pald , Artemi Cerdas, Ashish Saha d , Rabin Chakraborty d , Saro Lee b	2021	Journal Pre-proofs																	ALOS PALSAR - 12,5 m e 30 m/ AW3D30 e ASTER		ML methods of conditional inference forests (Cforest)/Cubist model/Elastic net	
Novel Ensemble Approach of Deep Learning Neural Network (DLNN) Model and Particle Swarm Optimization (PSO) Algorithm for Prediction of Gully Erosion Susceptibility	Shahab S. Band 1,2,* , Saeid Janizadeh 3 , Subodh Chandra Pal 4 , Ashish Saha 4 , Rabin Chakraborty 4 , Manouchehr Shokri 5 and Amirhosein Mosavi 6,7	2020	Sensors																1	DEM - 12,5 m		SVM/ ANN/ DLNN/PSO	PSO-DLNN
Novel Machine Learning Approaches for Modelling the Gully Erosion Susceptibility	Alireza Arabameri 1 , Omid Asadi Nalivan 2 , Subodh Chandra Pal 3 , Rabin Chakraborty 3 , Ashish Saha 3 , Saro Lee 4,5,* , Biswajeet Pradhan 6,7,8,9 and Dieu Tien	2020	Remote Sensing														1		1	DALOS DEM - 12,5 m		ANN/ MaxEnt/SVM/ GLM	ANN/SVM
Prediction of gully erosion susceptibility mapping using novel ensemble machine learning algorithms	Alireza Arabameri, Subodh Chandra Pal, Romulus Costache, Ashish Saha, Fatemeh Rezaie, Amir Seyed Danesh, Biswajeet Pradhan, Saro Lee & Nhat Duc Hoang	2021	Geomatics, Natural Hazards and Risk												1	1			1	ALOS PALSAR-/ GSI/ Landsat 08/ O mapa topográfico com escala de 1:50.000 foi coletado de fontes secundárias (www.ngo-org.ir).		RF/ SVM/LR/ - Modelos de referência e GE-XGBoost	GE-XGBoost

Nome do artigo	Autores	Ano	Revista																	Resolução do MDT	Parâmetros + Impotantes	Método	Melhor Método
				Rainfall	Geology	Iron Oxide	Ferrous Minerals	Lineament Densuty	Distance to Drainage	stream Density	FVC	Slope Gradient	Converge n index	Bedrock	SOIL EC	Soil Depth	Mineral Soil	groundwater	Soil				
Proposing a Novel Predictive Technique for Gully Erosion Susceptibility Mapping in And and Semi-arid Regions (Iran)	Alireza Arabameri 1, Artemi Cerda 2, Jesús Rodrigo-Comino 2,3, Biswajeet Pradhan 4,5, Masoud Sohrabi 6, Thomas Blaschke 7 and Dieu Tien Bui 8,*	2019	Remote Sensing																1	ALOS - 30 m	Soil/Lithology/elevation	index of entropy (IoE)/ Vise Kriterijumska Optimizacija I Kompromisno Resenje (VIKOR)	IoE
Robustness analysis of machine learning classifiers in predicting spatial gully erosion susceptibility with altered training samples	Tusar Kanti Hembram, Sunil Saha, Biswajeet Pradhan, Khairul Nizam Abdul Maulud & Abdullah M. Alami	2021	Geomatics, Natural Hazards and Risk																1	ASTER GDM- 30m / Landsat 8- 30m/Weather station precipitation data 30 m/Weather station recorded temperature data/ Topographical maps 1:50.000/Geomorphic features 1:50.000/ Reference		RF/ RT/ Naive Bayes - NB	Random Forest
Spatial modeling of gully head erosion on the Loess Plateau using a certainty factor and random forest model	Chengcheng Jiang a, Wen Fan a,b,* , Ningyu Yua, b, Enlong Liu c	2021	Science Direct																	DEM- 10 m - Original/ Usado para conversão de 5 m de resolução após interpolação por meio do método TIN		certainty factor (CF)/random forest (RF)	Random Forest
Spatial Pattern Analysis and Prediction of Gully Erosion Using Novel Hybrid Model of Entropy-Weight of Evidence	Alireza Arabameri 1,* , Artemi Cerda 2 and John P. Tiefenbacher 3	2019	Water																1	ALOS - 12,5m	drainage density/ slope/ rainfall	IOE/WOE	Modelo híbrido de combinação entre IoE e WoE
Susceptibility to Gully Erosion: Applying Random Forest (RF) and Frequency Ratio (FR) Approaches to a Small Catchment in Ethiopia	Selamawit Amare 1,2,* , Eddy Langendoen 3, Saskia Keesstra 4,5, Martine van der Ploeg 6, Habtamu Gelagay 7, Hanibal Lemma 2 and Sjoerd E. A. T. M. van der Zee 1	2021	Water															1	ALOS - 12,6m/Soil data - 1:50.000	drainage density/elevation/ land use/ groundwater	frequency ratio (FR)/random forest (RF)	Random Forest	
Predicting gully densities at sub-continental scales: a case study for the Horn of Africa	Matthias Vanmaerckel1,* , Yixian Chen1,2, Nigusie Haregeweyn3 , Sofia De Geeter1,4 , Benjamin Campforts5 , Wouter Heyndrickx6 , Atsushi Tsunekawa7 , Jean Poesen	2020	Earth Surface Processes and Landforms																			Random Forest	
Evaluation of Recent Advanced Soft Computing Techniques for Gully Erosion Susceptibility Mapping: A Comparative Study	Alireza Arabameri 1, Thomas Blaschke 2, Biswajeet Pradhan 3,4, Hamid Reza Pourghasemi 5,* , John P. Tiefenbacher 6 and Dieu Tien Bui	2020	Sensors																1	12.5		Frequency Ratio (FR) and Statistical Index (SI)/Random Forest (RF)/Maximum Entropy (ME)/Generalized Linear Model	Random Forest
Credal decision tree based novel ensemble models for spatial assessment of gully erosion and sustainable management	AlirezaArabameri1*, Nitheshnirmal Sadhasivam2,3, HamzaTurabieh4, Majdi Mafarja5, Fatiemeh Rezaei6,7, Subodh Chandra Pal8 & M. Santosh9,1	2021	Scientific reports																	12.5		Bagging/Dagging/Random Forest/ NBTree	
Comparison of machine learning models for gully erosion susceptibility mapping	Alireza Arabameri a, Wei Chen b,c,d , Marco Loche e, Xia Zhao b, Yang Li b, Luigi Lombardo f , Artemi Cerda g, Biswajeet Pradhan h,i,* , Dieu Tien Bui j	2019	Science Direct																1	12.5		NBTree/ADTree/LMT	