

FACULDADE DE CIÊNCIAS
Departamento de Matemática e Informática

Trabalho de Licenciatura em
Ciências de Informação Geográfica

**Análise de Potencial de Erosão: Aplicação
da Equação Universal de Perda de Solo
Revisada (RUSLE) e de Redes Neurais
Convolucionais (CNN)**

**Estudo de Caso: Distrito de Moatize e
Sussundenga**

Autora: Hafulásia Isabel Narciso Cumbe

Maputo, Agosto de 2025

FACULDADE DE CIÊNCIAS
Departamento de Matemática e Informática

Trabalho de Licenciatura em
Ciências de Informação Geográfica

**Análise de Potencial de Erosão: Aplicação da
Equação Universal de Perda de Solo Revisada
(RUSLE) e de Redes Neurais Convolucionais
(CNN)**

**Estudo de Caso: Distrito de Moatize e
Sussundenga**

Autora: Hafulásia Isabel Narciso Cumbe

Supervisor: Dr. Silvino Cumbane, UEM

Maputo, Agosto de 2025

Dedicatória

À minha avó em memória,

Avelina Josefa Guitivane e aos meus Pais

Que sempre foram a minha fonte de inspiração e o meu porto seguro.

Declaração de Honra

Declaro por minha honra que o presente Trabalho de Licenciatura é resultado da minha investigação e que o processo foi concebido para ser submetido apenas para a obtenção do grau de Licenciado em Ciências de Informação Geográfica, na faculdade de Ciências da Universidade Eduardo Mondlane.

Maputo, Agosto de 2025

Hafulásia Isabel Narciso Cumbe

Agradecimentos

Inicialmente quero agradecer a Deus, que em Sua infinita sabedoria e misericórdia, tem me sustentado e renovado as minhas forças em toda a minha jornada académica. Se não fosse o Seu amor e misericórdia, este projecto não teria sido possível. A Ele toda honra e glória, em nome de Jesus.

Agradeço ao Corpo Docente da Universidade Eduardo Mondlane (UEM) afecto à Faculdade de Ciências - Departamento de Matemática e Informática, pela oportunidade de aprender e crescer neste ambiente.

Ao meu supervisor, Silvino Cumbane, pela transmissão do seu douto saber neste projecto, pela paciência e dedicação. Seu conhecimento e sabedoria foram fundamentais para a conclusão deste trabalho.

Sou eternamente grata aos meus pais, Narciso Cumbe e Emelda Rungo, pelo amor, apoio incondicional e pela força que sempre me deram, especialmente nos momentos desafiadores da minha trajetória. Sem vocês, nada disso seria possível.

A minha avó, Avelina Josefa Guitivane, a quem devo imensa gratidão, pela sua sabedoria, apoio constante e por sempre me encorajar a seguir os meus sonhos, independentemente das dificuldades. A sua força e persistência são uma grande inspiração para mim.

Aos meus irmãos, Carlos da Emelda, Emelda Salvador e Narciso Cumbe Júnior, que são a razão pela qual luto e busco sempre alcançar grandes objectivos. O vosso amor e apoio são incalculáveis.

Aos meus tios, especialmente ao meu querido tio Jacob Rungo, que sempre esteve disponível para me ajudar em questões académicas e pessoais. A sua generosidade e preocupação sempre foram uma fonte de apoio fundamental.

Aos meus amigos próximos, Florinda Alfredo, Gertrudes Arrone, Joline Mugabe, Jussara Borge e José Chaúque, pelo apoio incondicional, palavras de força e amizade. A vossa presença foi imprescindível ao longo desta caminhada. Também sou grata aos meus colegas de jornada, Jennifer Bié, Rosita Covela, António Macarringue, Lino Chitlhango e Ivan Bule, pela troca enriquecedora de ideias, experiências e pela parceria em vários momentos do nosso percurso académico.

A todos os meus amigos, colegas e familiares que, directa ou indirectamente, fizeram parte deste caminho, deixando a sua marca em minha vida e na minha formação.

A todos, o meu Khamambo!

Resumo

Este estudo analisa a aplicabilidade de dois modelos, Equação Universal de Perda de Solo (RUSLE) e as Redes Neurais Convolucionais (CNN), para a previsão da susceptibilidade à erosão do solo em duas regiões distintas de Moçambique, Moatize e Sussundenga. O principal objectivo é compreender a aplicabilidade de cada abordagem para o mapeamento da susceptibilidade à erosão do solo em áreas com características distintas, destacando o potencial da integração dos métodos empíricos e técnicas de inteligência artificial (IA).

A metodologia adoptada envolveu o processamento de quatro factores (R, K, LS, C) do modelo RUSLE, permitindo a estimativa da perda de solo. Paralelamente, para o modelo baseado em CNN, foram seleccionadas variáveis geoambientais de forma criteriosa, assegurando a minimização da multicolinearidade através do Factor de Inflação da Variância (VIF), mantendo apenas aquelas com $VIF \leq 5$. E foram extraídos, dessas imagens, variados conjuntos de pontos para avaliar a evolução do modelo CNN, 870, 4000, 6000 e 8000 pontos. Os dados foram normalizados e utilizados para treinar o modelo CNN.

Os resultados mostraram que o modelo RUSLE oferece uma estimativa directa de perda de solo e mantém-se como ferramenta prática para análises exploratórias e de baixo custo computacional. Por sua vez, a CNN demonstrou elevado potencial para captar padrões espaciais complexos, alcançando valores de AUC de 0,989 em Moatize e 0,984 em Sussundenga, especialmente quando treinada com um conjunto de 8000 pontos. Essa abordagem mostra-se vantajosa em contextos que requerem maior nível de precisão e flexibilidade nos resultados.

As conclusões deste estudo reforçam que ambos modelos apresentam aplicabilidade para o mapeamento da erosão em diferentes contextos. A utilização conjunta dessas abordagens contribui para o enriquecimento de base metodológica em estudos de erosão, oferecendo subsídios e estratégias de conservação do solo e mitigação de impactos ambientais.

Palavras-chave: Susceptibilidade à erosão, Inteligência Artificial, Redes Neurais Convolucionais, RUSLE.

Abreviaturas

AUC	Área sob a curva
AW	Tropical Chuvoso de Savana
BSw	Seco de Estepe com Inverno Seco
CCD	Convenção das Nações Unidas de Combate a Desertificação
CHIRPS	<i>Climate Hazards Group InfraRed Precipitation with Station data</i>
CNN	Rede Neural Convolucional
CSV	<i>Comma Separated Values</i>
DEM	Modelo Digital de Elevação
DL	<i>Deep Learning</i>
DNN	<i>Deep Neural Network</i>
FCNN	<i>Fully Connected Neural Network</i>
FN	Falsos Negativos
FP	Falsos Positivos
GEE	<i>Google Earth Engine</i>
IA	Inteligência Artificial
JS	Java Script
ML	<i>Machine Learning</i>
ReLU	<i>Rectified Linear Unit</i>
RNA	Rede neural artificial
ROC	<i>Receiver Operating Characteristic</i>
RUSLE	<i>Revised Universal Soil Loss Equation</i> (Equação Universal de Perda de Solo Revisada)
RWEQ	<i>Revised Wind Erosion Equation</i>
SIG	Sistema de Informação Geográfica
USGS	<i>United States Geological Survey</i>
USLE	Equação Universal de Perda de Solo
VIF	Factor de inflação da variância
VN	Verdadeiros Negativos
VP	Verdadeiros Positivos
WEPP	<i>Water Erosion Prediction Project</i>
WGS 84	<i>World Geodetic System 1984</i>

Índice

Dedicatória.....	i
Declaração de Honra.....	ii
Agradecimentos.....	iii
Resumo.....	iv
Abreviaturas.....	v
Lista de Figuras.....	x
Lista de Tabelas.....	xii
Introdução.....	1
1.1. Contextualização	1
1.2. Definição do problema.....	2
1.4. Relevância do estudo	3
1.5. Objectivos	4
1.5.1. Objectivo geral	4
1.5.2. Objectivos específicos	4
.....	6
Área de Estudo.....	6
2.1. Distrito de Moatize e Sussundenga	6
2.1.1. Localização geográfica.....	6
2.1.2. Clima, relevo e solos.....	7
2.1.3. Recursos minerais e flora	8
Revisão de Literatura	9
3.1. Erosão do solo.....	9
3.2. Tipos de erosão do solo	11
3.2.1. Erosão hídrica	11
3.2.2. Erosão costeira	13

3.2.3. Erosão eólica.....	14
3.3. Sistema de Informação Geográfica.....	14
3.4. Modelos de Estimativa de Erosão do Solo	15
3.5. Método de Equação Universal de Perda de Solo Revisada (RUSLE)	16
3.5.1. Factor da erosividade da chuva (R)	17
3.5.2. Factor de erodibilidade do solo (K)	17
3.5.3. Factor de comprimento e inclinação da rampa (LS)	18
3.5.4. Factor de manejo e cobertura do solo (C).....	18
3.5.5. Factor de práticas de conservação (P)	19
3.6. Inteligência Artificial.....	19
3.7. Aprendizado Profundo (Deep Learning).....	20
3.7.4. Redes Neurais Convolucionais	21
Material e Métodos	24
4.1. Descrição do material.....	24
4.1.1. Ferramentas utilizadas na análise de perda de solo.....	24
4.1.2. Fonte de Dados Adquiridos para o Modelo RUSLE	25
4.1.3. Fonte de Dados Adquiridos para o Processamento CNN.....	26
4.2. Métodos.....	29
4.2.1. Procedimentos do modelo RUSLE	29
4.2.1.1. Equação de Perda de Solo	29
4.2.1.2. Factor R.....	30
4.2.1.3. Factor K.....	31
4.2.1.4. Factor LS	32
4.2.1.5. Factor C	32
4.2.1.6. Factor de Práticas de Conservação (P).....	33
4.2.1. Procedimentos do modelo CNN	33
4.2.1.1. Análise de Multicolinearidade.....	35
4.2.1.2. Aplicação da Rede Neural Convolucional.....	35

4.3. Validação dos Modelos RUSLE e CNN	37
4.3.1 Acurácia	37
4.3.2 Precisão	37
4.3.3 Recall (Retorno)	38
4.3.4 F1 – Score	38
4.3.5 AUC – ROC Curve (Curva ROC-AUC)	39
Resultados e Discussão	40
5.1. Resultados	40
5.1.1. Mapeamento pelo Método RUSLE de Perda de Solo	40
5.1.1.1. Factor R	40
5.1.1.2. Factor K	42
5.1.1.3 Factor LS	43
5.1.1.4. Factor C	44
5.1.2. Criação do Modelo CNN para análise de perda de solo	46
5.1.2.1. Análise de Multicolinearidade dos Factores Geoambientais	46
5.1.2.2. Avaliação do Desempenho do Modelo CNN com Quantidades de Amostras Diferentes	47
5.1.2.3. Avaliação do Desempenho dos Modelos RUSLE e CNN	49
5.1.2.4. Curva ROC-AUC	50
5.1.3. Mapas de susceptibilidade à erosão baseado nos modelos RUSLE e CNN	52
Conclusões e Recomendações	56
6.1 Conclusão	56
6.2 Recomendações	57
Referências Bibliográficas	58
Anexos	64
Anexo 1: Mapa de base para o treinamento e validação dos modelos (Variável independente)	64
Anexo 2: Representação gráfica do VIF das covariáveis geoambientais dos distritos de Moatize e Sussundenga	65

Anexo 3: Representação da tabela CSV com valores de cada variável geoambiental	67
--	----

Lista de Figuras

Figura 1. Mapa de Localização do distrito de Moatize e Sussundenga.....	7
Figura 2. Etapas da Erosão (Desagregação, Transporte e Deposição).	11
Figura 3. Tipos de Erosão Hídrica: A-Erosão Laminar; B-Erosão em Sulcos; C-Erosão em Ravinas. .	12
Figura 4. Erosão fluvial.....	13
Figura 5. Erosão Costeira.....	13
Figura 6. Erosão por ação do vento.	14
Figura 7. Estrutura da Inteligência Artificial.	20
Figura 8. Estrutura de Redes Neurais Artificiais (RNA).	21
Figura 9. Estrutura da Rede Neural Convolucional.	22
Figura 10. Arquitetura da Rede Neural Convolucional 1D.	23
Figura 11. Fluxograma metodológico	29
Figura 12. Arquitetura do modelo de Rede Neural Convolucional (CNN) aplicado à classificação binária de áreas com e sem erosão.	36
Figura 13. Factor de Erosividade da Chuva.	41
Figura 14. Factor de Erodibilidade do Solo.....	43
Figura 15. Factor de Comprimento da Rampa e Inclinação da Encosta.	44
Figura 16. Factor de Maneio e Cobertura do Solo.	45
Figura 17. Gráfico de Factor de Inflação da Variância (VIF) do Distrito de Sussundenga.	46
Figura 18. Gráfico de Factor de Inflação da Variância (VIF) do distrito de Moatize.	47
Figura 19. Evolução das métricas de desempenho, em relação a quantidade de pontos amostrais, no distrito de Moatize.	48
Figura 20. Evolução das métricas de desempenho, em relação a quantidade de pontos amostrais, no distrito de Sussundenga.....	49
Figura 21. Comparação do desempenho dos modelos RUSLE e Redes Neurais Convolucionais (CNN) na predição da perda de solo em Moatize e Sussundenga, com base nas métricas de Acurácia, Precisão, Recall e F1-Score.....	50
Figura 22. Curva ROC aplicada em modelos CNN e RUSLE no distrito de Moatize.....	51
Figura 23. Curva ROC aplicada em modelos CNN e RUSLE no distrito de Sussundenga.	51
Figura 24. Mapas de Susceptibilidade á erosão do solo, baseado ao modelo RUSLE e CNN, no Distrito de Moatize.	53
Figura 25. Mapas de Susceptibilidade á erosão do solo, baseado ao modelo RUSLE e CNN, no Distrito de Sussundenga.	54

Figura 27. Distribuição de pontos com valores extraídos das covariáveis (8000 pontos).....	64
Figura 26. Simulação de dados históricos de erosão do solo (Variável independente).....	64
Figura 28. Gráfico de Colinearidade dos factores considerados para o estudo com base ao VIF, distrito de Moatize.....	65
Figura 29. Gráfico de Colinearidade dos factores considerados para o estudo com base ao VIF, distrito de Sussundenga.	66
Figura 30. Tabela CSV de valores correspondentes a cada variável geoambiental seleccionada com base a multicolinearidade e a variável independente, distrito de Sussundenga.....	67
Figura 31. Tabela CSV de valores correspondentes a cada variável geoambiental seleccionada com base a multicolinearidade e a variável independente, distrito de Moatize.	68

Lista de Tabelas

Tabela 1. Descrição de ferramentas utilizadas.....	24
Tabela 2. Dados para o processamento dos factores em RUSLE.	25
Tabela 3. Descrição das covariáveis usadas para correr o algoritmo em CNN.	26
Tabela 4. Classes do Índice de Erosividade da chuva.....	30
Tabela 5. Classes de Índice de Erodibilidade (Factor K).	31
Tabela 6. Área e Percentagem de ocorrência de Erosividade no distrito de Moatize e Distrito de Sussundenga.....	41
Tabela 7. Área e Percentagem de ocorrência de Erodibilidade do solo no distrito de Moatize e Distrito de Sussundenga.	42
Tabela 8. Área e Percentagem de ocorrência do factor LS no distrito de Moatize e Distrito de Sussundenga.....	44
Tabela 9. Métricas de validação do distrito de Moatize.....	48
Tabela 10. Métricas de validação do distrito de Sussundenga.....	48
Tabela 11. Área e Percentagem de ocorrência de perda de solo para cada modelo, no distrito de Moatize.	52
Tabela 12. Área e Percentagem de ocorrência de perda de solo para cada modelo, no distrito de Sussundenga.....	53

Introdução

1.1. Contextualização

O solo é o recurso natural fundamental para a manutenção da vida na terra, portanto o uso e manejo em função de suas implicações económicas, sociais e ambientais, tem sido alvo de atenção e preocupação (Maciel, 2000).

Nos últimos anos, a taxa de erosão do solo tem aumentado devido às mudanças climáticas globais, mudanças na cobertura e no uso da terra, representando assim, uma ameaça ao ambiente e problemas sociais e económicos (Cau Liu *et al.*, 2023). A sua conservação mantém um bom funcionamento do ecossistema, tendo em vista que num solo pobre em nutrientes e fauna microbológica não há possibilidades do desenvolvimento de plantas (tanto para alimento quanto para compor a natureza), desencadeando uma série de impactos negativos no meio ambiente (Magalhães, 2019).

Assim sendo, a conservação do solo é de extrema importância para o desenvolvimento sustentável, a segurança alimentar e a proteção ambiental. Tornando assim, pertinente a criação de ferramentas que auxiliem na identificação das áreas cujos solos sejam susceptíveis a erosão, sobretudo em regiões onde não existem planos de conservação (Cumbane, 2012). Mapas de susceptibilidade a erosão do solo são ferramentas importantes para visualizar a distribuição espacial de erosão, auxiliando na gestão de áreas propensas a perda de solo (Huang *et al.*, 2020).

Nos últimos anos, diversos modelos matemáticos têm sido desenvolvidos para aprimorar o entendimento dos processos de erosão do solo, sendo amplamente utilizados para prever a perda de solo e a produção de sedimentos em áreas de menor escala (Petan *et al.*, 2010). Wischmeier e Smith (1978) desenvolveram a Equação Universal de Perda de Solo (USLE), que é um modelo estatístico empírico, porém, para aprimorar a análise e aumentar a precisão do modelo, Renard (1997) criou a versão revisada, conhecida como RUSLE, que mantém a estrutura básica do USLE (Liu *et al.*, 2023). Além disso, existem outros modelos empíricos, como o *Water Erosion Prediction Project* (WEPP) e a *Revised Wind Erosion Equation* (RWEQ).

E com o avanço da tecnologia de *Big Data* e da computação de alto desempenho, as técnicas de Inteligência Artificial (IA), especialmente o *Deep Learning* (DL), tem alcançado resultados significativos

em áreas como detecção de alvos, reconhecimento de imagens e tradução automática, o que tem atraído mais especialistas em Detecção Remota e Ciências Ambientais (Liu *et al.*, 2023). A integração de técnicas de IA ao Sistema de Informação Geográfica (SIG) potencializa a eficiência das análises geoespaciais ao automatizar o processamento de grandes volumes de dados, reconhecer padrões e realizar modelação preditiva, permitindo prever desastres futuros e seus impactos com base em dados históricos (Emami & Marzban, 2023). O algoritmo Rede Neural Convolutacional (CNN), um dos mais representativos em aprendizado profundo, tem sido amplamente aplicado nos últimos anos para a classificação de imagens de Detecção Remota, mostrando alta eficácia na análise de dados não estruturados, mesmo quando o conjunto de dados é relativamente pequeno (Liu *et al.*, 2023).

1.2. Definição do problema

Em Moçambique, a erosão do solo constitui um problema ambiental recorrente, intensificado pela exploração inadequada dos recursos naturais e pela ausência de ferramentas técnicas e tecnológicas que permitam identificar, com rigor, as zonas mais vulneráveis à erosão, dificultando, assim, a aplicação de boas medidas preventivas (Máquina et al., 2022).

Neste contexto, a insuficiência de mecanismos precisos para a análise do potencial de erosão representa um desafio significativo à gestão ambiental eficiente e à tomada de decisões inteligentes. Torna-se, por conseguinte, necessário adoptar abordagens metodológicas que garantam resultados fiáveis no mapeamento da susceptibilidade à erosão do solo. O modelo empírico tradicional, a Equação Universal de Perda de Solo Revista (RUSLE), tem sido amplamente utilizado nesta análise. Contudo, os avanços recentes em Inteligência Artificial, nomeadamente a aplicação de Redes Neurais Convolucionais (CNN), têm revelado elevado potencial para a análise geoespacial, especialmente na previsão da erosão do solo (Chen et al., 2018).

Deste modo, surge a necessidade de realizar um estudo sobre a aplicabilidade da abordagem tradicional RUSLE e dos métodos de *Deep Learning* (DL), com destaque para a CNN, com o intuito de compreender como cada modelo pode ser utilizado na previsão da erosão em áreas com características distintas como os distritos de Moatize e Sussundenga.

1.3. Justificativa

A erosão do solo é um fenómeno natural que apresenta problemas ambientais significativos causando mudanças no ecossistema, redução na fertilidade do solo, e degradação de infraestruturas sociais e económicas (Karavitis *et al.*, 2014).

Nos últimos anos, esta problemática tem impulsionado a participação de órgãos governamentais nacionais e internacionais, a fim de arranjar soluções para mitigar a erosão do solo nas comunidades afectadas e desenvolver ferramentas adequadas para planeamento e tomada de decisão (Chen *et al.*, 2018). Em Moçambique, a erosão do solo é um dos problemas de gestão ambiental, por essa razão tem parte na implementação da Convenção das Nações Unidas de Combate à Desertificação (CCD), na melhoria da gestão dos ecossistemas mais frágeis (Cumbane, 2012).

Várias técnicas têm sido propostas e desenvolvidas para estudar a susceptibilidade à erosão, incluindo modelos tradicionais e algoritmos de IA que têm ganho bastante destaque em pesquisas sobre a análise do solo. De acordo com Islam (2022), o RUSLE é um dos métodos mais utilizados para a análise da perda de solo, baseando-se em cinco factores principais e podendo ser aplicado em diferentes condições ambientais (Luz, 2024). Além disso, técnicas de IA, com destaque a CNN, segundo Chen *et al.*, (2018), representam abordagem recente na análise do potencial de erosão do solo, com a capacidade de lidar com grandes conjuntos de dados.

Esta pesquisa tem como propósito analisar a aplicabilidade do algoritmo Rede Neural Convolutacional (CNN) e do modelo tradicional, Equação Universal Revisada de Perda de Solo (RUSLE), no mapeamento da susceptibilidade à erosão do solo nos distritos de Moatize e Sussundenga. Permitindo evidenciar como cada abordagem pode contribuir para a compreensão e previsão da perda de solo, destacando suas potencialidades e limitações. Ao fazê-lo, pretende-se contribuir significativamente para a mitigação da erosão do solo no país e proporcionar uma base científica para a formulação de estratégias sustentáveis de conservação do solo.

1.4. Relevância do estudo

A degradação do solo é, muitas vezes, impulsionada pela necessidade de subsistência das comunidades rurais e periurbanas, que consequentemente geram danos ambientais significativos e afectam negativamente o desenvolvimento socioeconómico do País, sobretudo no que se refere a segurança alimentar (Cucco, 2000), comprometendo a produtividade agrícola, o abastecimento hídrico, também contribui para a intensificação da poluição atmosférica, com a emissão de gases responsáveis pelo efeito

estufa, na redução da matéria orgânica e da biomassa do solo, afectando a sustentabilidade dos ecossistemas (Marenga, 2023).

Diante desses factores, torna-se relevante o estudo de modelos eficazes que garantam ferramentas adequadas que auxiliem na criação de estratégias eficazes de gestão e mitigação da erosão do solo, visando preservar os recursos naturais e garantir o bem-estar ambiental e da população, particularmente em regiões que carecem de planos de conservação (Cumbane, 2022).

Modelos empíricos, como o RUSLE, têm sido amplamente utilizados na estimativa da erosão, contudo apresentam limitações na captura de padrões espaciais complexos, principalmente em regiões com condições diferentes dos parâmetros considerados (Islam, 2022; Rezaie *et al.*, 2023). Em contrapartida, técnicas de inteligência artificial têm sido recentemente aplicadas na modelação da susceptibilidade à erosão do solo (Rezaie *et al.*, 2023), destacando-se a Rede Neural Convolucional (CNN), um dos mais representativos em *Deep Learning (DL)*, capaz de processar grandes volumes de dados geoespaciais e identificar padrões complexos e relações ambientais no espaço e no tempo que contribuem para a erosão (Shen *et al.*, 2023).

Ao analisar a aplicabilidade dos modelos, RUSLE e CNN, em duas áreas distintas, distritos de Moatize e Sussundenga, este estudo pretende contribuir no enriquecimento de metodologias inovadoras, cujos resultados poderão servir de base para futuras pesquisas. Bem como oferecer subsídios para a definição de políticas e estratégias inteligentes voltadas a conservação do solo e a gestão dos recursos naturais, especialmente em regiões vulneráveis à erosão.

1.5. Objectivos

1.5.1. Objectivo geral

Avaliar o desempenho do modelo empírico tradicional RUSLE e do algoritmo CNN no mapeamento da susceptibilidade à erosão do solo em zonas com características geoespaciais distintas, Moatize e Sussundenga.

1.5.2. Objectivos específicos

- Processar dados usando o modelo RUSLE para o mapeamento da erosão do solo, considerando factores envolvidos na equação;

- Gerar mapa de perda de solo com base no modelo RUSLE;
- Selecionar variáveis geoambientais que influenciam a erosão do solo e que não se correlacionam entre si, para o treinamento e validação do modelo CNN;
- Treinar o modelo CNN para a previsão da susceptibilidade à erosão do solo;
- Analisar o potencial dos modelos RUSLE e CNN com base em cinco métricas de validação (Acurácia, Precisão, Recall, F1-score e ROC-AUC);

Área de Estudo

Este capítulo tem como objectivo apresentar, por meio de mapas e descrição textual as áreas de estudo, distritos de Moatize e Sussundenga

2.1. Distrito de Moatize e Sussundenga

2.1.1. Localização geográfica

O distrito de Moatize situa-se a noroeste da cidade capital provincial de Tete, entre 15°37' e 16°38' de latitude sul e 33°22' e 34°28' de longitude este (Duarte, 2023). Possui uma área de 8.462km² e faz fronteira a norte com os distritos de Chiúta e Tsangano, a este com a República do Malawi, a sul com os distritos de Tambara, Guro, Changara e o Município de Tete, sendo delimitado pelos rios Zambeze e Mutarara (Ministério da Administração Estatal, 2012).

O distrito de Sussundenga, por sua vez, localiza-se na região central, na província de Manica, sendo limitado a norte, pelos distritos de Gondola e Manica, a oeste pela República do Zimbabwe, a sul pelo Distrito de Mossurize e a este pelo distrito de Búzi, ambos pertencentes à província de Sofala (Ministério da Administração Estatal, 2012). Astronomicamente, situa-se entre os paralelos 19°12' e 20°15' latitude sul e os meridianos 32°48' e 33°52' longitude este, e com uma área de 7.100 km² (Castigo, 2000).




Figura 1. Mapa de Localização do distrito de Moatize e Sussundenga.

2.1.2. Clima, relevo e solos

Em Moatize o clima varia entre "Seco de Estepe com Inverno Seco-BSw" no sul e "Tropical Chuvoso de Savana-AW" no norte, com uma precipitação média anual de cerca de 644 mm e evapotranspiração potencial média anual de aproximadamente 1.626 mm. As chuvas são mais intensas entre dezembro e fevereiro, com variações significativas de ano para ano (Ministério da Administração Estatal, 2012).

Os solos predominantes no distrito são castanho-acinzentados e castanho-avermelhados, derivados de rochas calcárias, bem como solos resultantes de rochas basálticas que variam de avermelhados a pretos, com boa capacidade de retenção de nutrientes e de água (Ministério da Administração Estatal, 2012).

O distrito de Sussundenga apresenta um clima tropical chuvoso de savana (Aw), caracterizado por estação seca e outra chuvosa. A precipitação média anual, medida na estação mais próxima, em Messambuzi, é de aproximadamente 1.171 mm, enquanto a evapotranspiração potencial média anual é de 1,271 mm. A maior queda pluviométrica ocorre no período compreendido de novembro a março, com variações na quantidade e distribuição (Ministério da Administração Estatal, 2012).

Quanto aos solos, destacam-se os argilosos, que apresentam boa capacidade de retenção de água e nutrientes, tornando os mais férteis; arenosos vermelhos, menos férteis; os de textura média; e os litólicos que geralmente são rasos (Ministério da Administração Estatal, 2012).

Relativamente a Geomorfologia, ambos os distritos fazem parte do Complexo Gnaisso-Granítico do Moçambique *Belt*, com formações de *inselbergs* compostas por rochas intrusivas do pós-Karoo (Ministério da Administração Estatal, 2012).

2.1.3. Recursos minerais e flora

Moatize é amplamente conhecido pelos seus recursos minerais, incluindo carvão (hulha), ferro, titânio, vanádios, depósitos de quartzo-carbonato e minerais polimetálicos, além de rochas utilizadas na construção civil (Ministério da Administração Estatal, 2012).

A flora local é rica em madeira (umbila, chanfuta, pau-preto, etc.), utilizados como fonte de energia através de lenha e carvão, e para fins de construção (Ministério da Administração Estatal, 2012).

O distrito de Sussundenga, considerado o "celeiro" da província de Manica, abriga o Monte Binga, o ponto mais alto de Moçambique, com 2.436 metros de altitude. O qual faz parte do maciço de Chimanimani, uma cordilheira montanhosa que se estende ao longo da fronteira com o Zimbábwe, a oeste do distrito (Ministério da Administração Estatal, 2012).

Revisão de Literatura

O objectivo deste capítulo é apresentar uma visão geral sobre os processos de erosão do solo, incluindo suas causas naturais e humanas e os seus tipos. Exploram-se também técnicas como a Equação Universal de Perda de Solo (RUSLE). O capítulo finaliza com a análise do uso de inteligência artificial, destacando o potencial das Redes Neurais Convolucionais (CNN) para prever a erosão de maneira mais precisa.

3.1. Erosão do solo

A erosão do solo é definida como o processo de separação, remoção, transporte e deposição de partículas de solo, causado por agentes naturais como o sol, a chuva e o vento, podendo ser acelerada pela actividade humana (Ministério para a Coordenação da Ação Ambiental, 2007).

Este fenómeno subdivide-se em dois tipos principais: erosão natural e erosão acelerada.

- A **erosão natural**, também conhecida como geológica, ocorre de forma lenta e gradual, sem interferência humana, sendo responsável por moldar o relevo terrestre e contribuir para a formação de rios, montanhas, planícies, planaltos e vales (Luz, 2024).
- A **erosão acelerada** é causada pelas ações humanas, como a exploração da terra para agricultura, criação de animais e construção de infraestruturas. Estas actividades comprometem a cobertura vegetal, quebrando o equilíbrio entre solo, vida e clima, e intensificando o processo erosivo (Cabral, 1951).

A erosão do solo resulta na degradação, perda de nutrientes e matéria orgânica, afetando a fertilidade e a sustentabilidade dos ecossistemas. Este processo pode ser exacerbado por uma combinação de factores, incluindo condições climáticas (precipitação, vento, temperatura), características físicas do solo (textura e declive do terreno), o tipo de cobertura vegetal, práticas de manejo do solo e intervenções humanas inadequadas (Cherlinka, 2022).

a) Factores Naturais

Os agentes naturais, como chuva, vento são os principais elementos determinantes no processo de erosão. A **chuva**, especialmente em alta intensidade, causa desagregação e transporte do solo, aumentando o escoamento superficial e acelerando o transporte de sedimentos. O **vento**, dependendo de sua velocidade, atua como um agente erosivo poderoso, removendo partículas e promovendo a desagregação de rochas por abrasão. Já a **temperatura** actua sobre a erosão geológica ao facilitar a desagregação do solo por ciclos de aquecimento e resfriamento (Cabral, 1951).

O **relevo**, com seus gradientes e comprimentos de inclinação, também desempenha um papel importante. Áreas com maior inclinação são particularmente vulneráveis ao transporte por salpico, causando maior degradação (Capoane, 2013).

b) Textura do Solo e Vegetação

A **textura do solo** afecta sua capacidade de armazenamento, permeabilidade e infiltração de água. Solos com alto teor de argila e matéria orgânica apresentam maior coesão, reduzindo a suscetibilidade à erosão. Por outro lado, solos arenosos ou com baixa agregação são facilmente transportados pelos agentes erosivos (Cherlinka, 2022).

A **vegetação** é um factor crucial para a proteção do solo em sistemas naturais, ajudando a captar as águas das chuvas e distribuí-la pelo perfil do solo. Além disso, a cobertura vegetal enriquece o solo com matéria orgânica, aumentando sua fertilidade e capacidade de infiltração. Por outro lado, quando a vegetação é removida, o solo torna-se vulnerável à degradação, especialmente em regiões com intensa actividade agrícola (Kumar, 2021).

c) Maneio do Solo e Ações Humanas

O manejo inadequado do solo, como práticas agrícolas ineficientes, pode desequilibrar a cobertura vegetal, expondo o solo ao impacto das gotas de chuva e aumentando a erosão, o que também afecta negativamente a fertilidade do solo. As intervenções humanas são o principal factor acelerador da erosão, resultando em efeitos prejudiciais significativos (Cabral, 1951).

3.2. Tipos de erosão do solo

A erosão do solo é amplamente categorizada em diferentes tipos dependendo do agente responsável pelo desencadeamento da actividade erosiva. Portanto, a erosão é intensificada por dois principais tipos de agente: água e vento (Luz, 2024).

3.2.1. Erosão hídrica

A erosão hídrica ocorre quando as partículas são removidas pelo escoamento da água, podendo ser classificadas em erosão pluvial (splash, laminar, em sulcos e ravinas) e fluvial.

- I. **Erosão pluvial** – é causada pela água das chuvas, ou seja, quando o solo está exposto e desprotegido, as enxurradas resultantes da chuva carregam a camada superficial do solo (Ministério para a Coordenação da Acção Ambiental, 2007). A acção erosiva das águas pluviais é mecânica e envolve a desagregação, o transporte e a deposição das partículas do solo (Cabral, 1951).




Figura 2. Etapas da Erosão (Desagregação, Transporte e Deposição).

Fonte: Adaptado de Dampier (2013)

A desagregação ocorre quando o impacto das gotas de chuva ou da corrente de água desprende partículas do solo, aumentando com o volume da chuva; O transporte acontece simultaneamente, onde o escoamento carrega as partículas, mantendo a força até um ponto de perda de energia; por fim, a deposição, ou sedimentação, ocorre quando as partículas do solo, junto com a água, perdem energia ou encontram obstáculos, sendo depositadas, geralmente, em áreas mais baixas (Luz, 2024).

A erosão pluvial subdividi-se em:

- ❖ **Splash:** É o efeito gerado pelas gotas de chuva sobre o solo exposto, causando a separação das partículas do solo e das rochas, que se acumulam entre os agregados do solo, formando uma crosta superficial que dificulta a infiltração da água (Kumar, 2021).
- ❖ **Erosão laminar:** Caracteriza-se por ocorrer em superfícies lisas, à medida que a água que não foi filtrada devido à formação da crosta escoa das áreas mais altas para as mais baixas, ela desprende e carrega consigo as partículas superficiais do solo, desgastando-o e podendo formar sulcos que eventualmente originam ravinas (Pena, 2024).
- ❖ **Erosão em sulcos:** Ocorre quando o escoamento da água sobre o solo intensifica o seu desgaste, formando pequenos cortes visíveis que são o princípio das erosões mais severas em áreas inclinadas, com canais que se aprofundam com o tempo e podem interferir na preparação do solo (Silva, 1995).
- ❖ **Erosão em ravinas:** São causadas por grandes quantidades de água transportada em pouco tempo, abrindo cavidades maiores ao longo da declividade do terreno (Pena, 2024).




Figura 3. Tipos de Erosão Hídrica: A-Erosão Laminar; B-Erosão em Sulcos; C-Erosão em Ravinas.

Fonte: Adaptado de Guitarrara, n.d

- II. Erosão fluvial:** É o desgaste provocado pela corrente das águas dos rios, este processo retira fragmentos das margens desprotegidas pela falta de vegetação ciliar e deposita em outros locais (Pena, 2024).



Figura 4. Erosão fluvial.

Fonte: Adaptado de Pena, n.d.

3.2.2. Erosão costeira

A erosão costeira ocorre devido ao desgaste das rochas ou do solo litorâneo provocado pelas ondas do mar. torna-se problemático quando áreas sazonalmente atingidas pelas ondas são urbanizadas, afectando habitações e estradas (Pena, 2024).



Figura 5. Erosão Costeira

Fonte: Adaptado de Gama (2023)

3.2.3. Erosão eólica

A erosão eólica é causada pela acção do vento, que desagrega e transporta os materiais do solo quando em contacto com a superfície terrestre. Esse tipo de erosão é mais comum em regiões planas com pouca vegetação natural e onde os ventos são fortes. Pode ocorrer em regiões áridas, semiáridas ou em áreas onde o período chuvoso é concentrado em época do ano com curta duração. As condições edafoclimáticas que favorecem a erosão eólica incluem solo pouco coeso, seco, de textura fina, superfície uniforme e topografia plana. As condições climáticas favoráveis à erosão eólica incluem ventos intensos, clima árido e fraca pluviosidade ($P < 300 \text{ mm}$) e temperatura elevada (Cabral, 1951; Silva, 1995).




Figura 6. Erosão por acção do vento.

Fonte: Infopédia, 2025.

3.3. Sistema de Informação Geográfica

O Sistema de Informação Geográfica (SIG) é uma tecnologia que representação digital do espaço geográfico real e da sua infraestrutura em mapas digitais integrados a uma base de dados. Esta integração possibilita identificar padrões, realizar análises detalhadas, prever fenómenos e gerir eficientemente o espaço e os fenómenos nele verificados (Aquino *et al.*, 2021).

De acordo com Caeiro (2013), o SIG é constituído por um conjunto integrado de *hardware*, *software* e um ambiente institucional, que em conjunto viabilizam a captura, armazenamento, verificação, integração, sobreposição, manipulação, análise e visualização de dados georreferenciados. Desta forma, o SIG actua

como uma ferramenta essencial para a resolução de problemas geográficos, permitindo uma abordagem mais sistemática e estruturada.

Além disso, Wilson (2019) sublinha que o SIG permite analisar informações e estabelecer relações espaciais entre diferentes conjuntos de informações geográficas. Esta capacidade transforma os elementos recolhidos em informações valiosas que apoiam a tomada de decisão e contribuem para uma gestão territorial mais eficiente e sustentável.

Conforme descrito por Marcellini (2002), citado por Cumbane (2022), os *softwares* SIG apresentam quatro funcionalidades principais:

1. **Entrada de dados:** Converte as informações para um formato compatível com o SIG, sendo uma fase crítica que exige atenção à qualidade e aos métodos de integração, dado que pode comprometer a evolução do trabalho.
2. **Gestão dos dados:** Inclui o armazenamento e a recuperação eficiente das informações, sendo que a estrutura e os métodos utilizados impactam directamente o desempenho das operações e a velocidade de recuperação.
3. **Análise e modelação:** Engloba estatísticas espaciais, transformação e manipulação dos dados, determinando as informações que podem ser geradas pelos SIG.
4. **Saída de dados:** Proporciona a criação de mapas, tabelas ou relatórios, adaptados às necessidades dos utilizadores, com variações na qualidade, precisão e facilidade de uso.

3.4. Modelos de Estimativa de Erosão do Solo

Ao longo dos anos, o interesse em melhorar a estabilidade ambiental e mitigar a degradação do ecossistema tem crescido. Consequentemente, a busca por ferramentas preditivas para avaliação de processos ambientais, como a erosão dos solos, tornou-se essencial para a gestão eficiente dos recursos naturais, assim sendo, a modelação constitui-se como principal ferramenta disponível (Chang, 2019).

A modelação da erosão é o processo de descrição matemática da desagregação, transporte e deposição das partículas na superfície do solo (Cecílio et al., 2009). As características das chuvas e as propriedades dos solos durante essas ocorrências influenciam na estimativa da taxa de perda de solo, logo, em termos matemáticos, a erosão é função da erosividade da precipitação e da erodibilidade do solo (Ferreira, 2013).

Dada a complexidade do processo erosivo, diversos modelos matemáticos têm sido elaborados, podendo ser classificados como conceituais, empíricos e modelos de base física (Minella, 2024).

- **Modelos conceituais** - Os modelos são construídos com base em fórmulas que simplificam o sistema, incorporando componentes interligados para gerar e transportar sedimentos. Cada componente requer uma caracterização de seu comportamento dinâmico ao longo do tempo. Esses modelos permitem a inclusão de dados que consideram a variação temporal e espacial de forma generalizada. Os parâmetros do modelo são ajustados usando dados observados para melhorar a precisão das previsões (Minella, 2024).
- **Modelos empíricos** – Estes modelos baseiam-se na identificação das relações estatísticas mais significativas entre as variáveis mais importantes (Ferreira, 2013). Ele é amplamente usado devido a capacidade de operar com uma quantidade de variáveis reduzidas, especialmente onde há limitações de dados. Comparado a outros modelos, ele pode fornecer estimativas precisas em larga escala, tornando-o útil para identificar áreas críticas de erosão (Chang, 2019).
- **Modelos de base física** - Estes modelos exigem dados detalhados, como infiltração e evapotranspiração, e seus resultados são resolvidos a partir de equações que descrevem processos hidrológicos e erosivos. A necessidade de parâmetros específicos limita seu uso, especialmente em áreas extensas e heterogêneas com escassez de dados (Minella, 2024).

3.5. Método de Equação Universal de Perda de Solo Revisada (RUSLE)

A Equação de Perda de Solo Revisada (RUSLE) é uma versão aprimorada da Equação de Perda de Solo (USLE), originalmente desenvolvido para estimar as perdas médias de solo a longo prazo em áreas sujeitas ao escoamento superficial (Mahala, 2018). Proposto por Renard et al., (1997) com melhorias em relação à versão original, visando maior precisão em diferentes condições ambientais. De acordo com Ghosal et al. (2020), o RUSLE tornou-se amplamente aceito e universalmente implementado para a estimativa da perda de solo.

O modelo baseia-se no produto de cinco factores principais, a erosividade da chuva (R), a erodibilidade do solo (K), o comprimento e inclinação da rampa (LS), o manejo e cobertura do solo (C) e as práticas de conservação (P). Onde variam no espaço e no tempo, representando numericamente a influência de cada um no processo de erosão (Wischmeier & Smith, 1978). Esses parâmetros são combinados para calcular a perda média anual de solo (A), oferecendo uma abordagem robusta e adaptável para estudos de erosão em diferentes condições ambientais (Islam, 2022).

E é expressa pela seguinte fórmula:

$$A = R \times K \times LS \times C \times P$$

Equação 1. Factor de Perda de Solo

3.5.1. Factor da erosividade da chuva (R)

A perda de solo está directamente relacionada à precipitação, com o cujo impacto promove a desagregação do solo, sendo o transporte intensificado pelo escoamento superficial de partículas, especialmente em áreas desprotegidas por vegetação ou práticas insustentáveis do solo (Cumbane, 2012).

O factor (R), é um índice numérico essencial para quantificar a energia cinética produzida pelo impacto das gotas de chuva no solo e o potencial do escoamento superficial associado à precipitação (Reginatto *et al.*, 2011). Ele é crucial para avaliar as perdas de solo, pois está fortemente correlacionado com a desagregação e o transporte de partículas até sua deposição (Luz, 2024). Além disso, é um dos parâmetros mais importantes na estimativa de erosão pelo RUSLE, apresentando alta correlação com a remoção de partículas do solo em diferentes regiões e períodos de precipitação ao redor do mundo (Jahun *et al.*, 2015).

3.5.2. Factor de erodibilidade do solo (K)

O fator de erodibilidade do solo (K) é uma métrica essencial para avaliar a susceptibilidade do solo à erosão, considerando a interação entre o impacto das gotas de chuva e o escoamento superficial (Shen, 2023). A magnitude deste factor depende de diversas propriedades do solo, como textura, estrutura, porosidade, material geológico e o teor de matéria orgânica (Ghosal *et al.*, 2020).

Solos ricos em matéria orgânica apresentam maior resistência à erosão devido à formação de agregados que favorecem a infiltração e reduzem o escoamento. Por outro lado, solos com elevado teor de silte são mais vulneráveis, pois possuem partículas facilmente destacáveis e transportáveis (Ghosal *et al.*, 2020). Solos compactados e instáveis tendem a apresentar maior susceptibilidade à erosão, enquanto solos bem estruturados e com alta capacidade de infiltração têm valores de K mais baixos, reduzindo o risco de erosão (Mahala, 2018). Adicionalmente, características como a mineralogia e a permeabilidade do solo influenciam significativamente os valores de K. Estas propriedades podem ser melhoradas por meio de práticas de gestão da vegetação, que aumentam a matéria orgânica e estabilizam a estrutura do solo, diminuindo a sua susceptibilidade à erosão (Foster *et al.*, 2001).

3.5.3. Factor de comprimento e inclinação da rampa (LS)

A topografia tem um impacto significativo na erosão do solo e no escoamento da água. A combinação do comprimento da encosta (L) e da sua inclinação (S) são variáveis determinantes para a taxa de erosão. Em encostas mais longas e íngremes, a água ganha maior velocidade e energia, o que aumenta a sua capacidade de transportar partículas de solo, resultando em maior erosão (Jahun, 2015). Terrenos localizados em encostas apresentam maior vulnerabilidade, pois a maior velocidade de escoamento causa uma erosão mais acentuada, levando ao desgaste rápido do solo (Ghosal *et al.*, 2020).

O comprimento da encosta (L) é definido como a distância desde a fonte de escoamento até o ponto de deposição dos sedimentos. A interação entre o declive e o comprimento da vertente influencia directamente a magnitude da erosão, sendo fundamental considerar esses dois factores em conjunto na avaliação dos impactos erosivos (Cumbane, 2012). Esses fatores tornam o controlo da erosão ainda mais desafiador em áreas montanhosas ou com grande variação de relevo, exigindo práticas adequadas de manejo do solo para mitigar os impactos do escoamento superficial e da perda de solo (Wardani *et al.*, 2024).

3.5.4. Factor de manejo e cobertura do solo (C)

A vegetação desempenha um papel fundamental na erosão do solo, sendo que a taxa de erosão diminui consideravelmente com o aumento da cobertura vegetal (Shen, 2023). O factor de cobertura e manejo ou factor de cobertura e uso do solo (C) está intrinsecamente ligado à erosividade dos agentes erosivos e à erodibilidade do solo. As copas das plantas ajudam a mitigar a erosividade do impacto das gotas de chuva, enquanto a cobertura do solo reduz tanto a erosividade da chuva quanto do escoamento superficial. As raízes e resíduos vegetais contribuem para a estabilidade da estrutura superficial, enquanto práticas que perturbam o solo aumentam essa erodibilidade (Foster *et al.*, 2001).

Em áreas de cobertura florestal densa, a erosão é significativamente controlada, ao passo que a agricultura intensa contribui para a erosão prolongada, agravando a degradação do solo. Assim sendo, a gestão adequada da cobertura vegetal é essencial para mitigar os impactos erosivos e proteger a qualidade do solo (Mahala, 2018).

3.5.5. Factor de práticas de conservação (P)

O fator de práticas conservacionistas é um parâmetro fundamental para avaliar a eficácia das medidas de conservação do solo e da água, bem como o grau de degradação desses recursos. Relacionado ao tipo de uso do solo, o factor P é calculado principalmente através do método de atribuição (Shen, 2013). Este factor adimensional reflete a razão da perda de solo sob práticas específicas de manejo, como o contorno e o preparo do solo. Práticas inadequadas, como arar em linha reta sem considerar contornos ou terraços, resultam em valores de P mais elevados (Jahun, 2015). Em contrapartida, a incorporação de técnicas de conservação tende a reduzir significativamente o valor de P, demonstrando a importância de técnicas adequadas de manejo na mitigação da erosão do solo.

3.6. Inteligência Artificial

Conforme citado por Gomes (2010) o primeiro trabalho reconhecido no âmbito de Inteligência Artificial (IA) foi realizado em 1943, pelos autores Warren McCulloche Walter Pitts, contudo foi o matemático Alan Turing, o primeiro a articular uma visão completa de IA em seu artigo de 1950 “*Computing Machinery and Intelligence*”, propondo a realização de um teste para avaliar a capacidade de uma máquina em se comportar de maneira semelhante a um ser humano, o teste seria considerado bem-sucedido se um interrogador humano, após propor algumas perguntas, não conseguisse distinguir se as respostas vinham de uma pessoa ou de uma máquina.

Segundo Sichman (2021), a esta área é um ramo da ciência ou engenharia da computação que visa desenvolver sistemas computacionais capazes de solucionar problemas, utilizando uma variedade de técnicas e modelos, em função da natureza dos desafios a resolver.

De acordo com Vechio (2020), a IA é uma área inerente à computação que, por meio de algoritmos sofisticados, atribui capacidades inteligentes a sistemas de diferentes naturezas, conferindo-lhes a habilidade de realizar funções de maneira imperativa além de responder a comandos e definir o que fazer mediante cada situação.

Não há consenso sobre o conceito de IA, porém vários autores da área dividem-no em quatro principais seções: i) inteligência artificial como uma aproximação ao acto de pensar como um humano; ii) máquinas que pensam racionalmente, a fim de tomar decisões e agir; iii) agir como humano, desempenhando de forma eficiente tarefas que hoje são realizadas por pessoas; e iv) pensamento e ação racional, ou seja, projetar agentes que tomem decisões por conta própria (Vechio, 2020).

3.7. Aprendizado Profundo (Deep Learning)

O *Deep Learning* (DL) é um subconjunto do Machine Learning (ML) e da Inteligência Artificial (IA), como ilustra a figura 7, que utiliza redes neurais com múltiplas camadas para imitar o funcionamento do cérebro humano, permitindo que sistemas computacionais aprendam de forma autônoma, reconhecendo padrões em imagens, texto, som e outros tipos de dados (Gillis, *et al.*, 2023).



Figura 7. Estrutura da Inteligência Artificial.

Fonte: Chagas (2019).

A rede neural artificial (RNA), inspirada pela rede neural biológica é uma função de aproximação na qual a rede tenta aprender os parâmetros (pesos) em camadas ocultas que, quando multiplicadas pela entrada, fornecem uma saída prevista próxima da saída desejada (Viana, 2018).

O DL utiliza camadas de neurónios matemáticos para processar dados, a primeira camada de rede é chamada de camada de entrada, as camadas intermediárias são conhecidas como camadas ocultas, e a última é a camada de saída. Cada camada da rede consiste num algoritmo simples e uniforme que inclui uma função de ativação (Chagas, 2019). Cada neurônio recebe informações dos neurônios da camada de entrada, e a saída de um neurônio torna-se a entrada para outros neurônios na próxima camada da rede. Esse processo continua até que a camada final produza a saída da rede. As camadas da rede neural

transformam os dados de entrada por meio de uma série de transformações não lineares, permitindo que a rede aprenda representações complexas dos dados de entrada (Saxena, 2024). Esta iteração entre os neurónios continua até que a saída atinja um nível aceitável de precisão (Gillis, *et al.*, 2023).




Figura 8. Estrutura de Redes Neurais Artificiais (RNA).

Fonte: Chagas (2019).

3.7.4. Redes Neurais Convolucionais

Segundo Ghosh (2009), a Rede Neural Convolucional (CNN), também conhecida como ConvNet, é uma forma avançada da Rede Neural Artificial (RNA) notável por sua arquitetura *feed-forward* profunda, que gradualmente aprende e extrai características dos dados de entrada, como imagens, em diferentes níveis de abstração. O autor ainda destaca que a CNN é especialmente eficaz na aprendizagem de características altamente abstratas de objectos, principalmente em dados espaciais.

Esta arquitetura é composta por várias camadas fundamentais: a camada de entrada, camada convolucional, camada de *pooling*, camada totalmente conectada e camada de saída.

- I. **Camada convolucional:** esta camada é essencial na arquitetura e é responsável por extrair *features* ou características do objecto de entrada, usando filtros (kernels) (Rodrigues, 2018). Segundo Rocha, *et al.*, (2021) os filtros compostos por pesos inicialmente aleatórios e ajustados durante o treinamento via retro propagação, são aplicados em diferentes locais da imagem para capturar padrões frequentes em qualquer parte da matriz.

Porém, a medida que os filtros vão aprendendo estruturas mais complexas, ou seja, quanto mais filtros convolucionais, mais custo de memória e processamento terá (Rodrigues, 2018).

- II. **Camada de *pooling*:** Após a convolução, esta camada reduz o tamanho do mapa de características, comprimindo dados e diminuindo o número de parâmetros aprendidos, isso é crucial para evitar o sobreajuste (*overfitting*), melhorando a eficiência do modelo (Gio, 2023).
- III. ***Fully connected*** (camada totalmente conectada): são camadas densas em que cada neurônio está conectado directamente a todos os neurónios da camada anterior, permitindo uma representação completa das características aprendidas durante as fases anteriores da rede (Rocha, *et al.*, 2021).

A capacidade da CNN de extrair eficientemente recursos de imagens de entrada é ampliada pela combinação da camada de *pooling* e da camada convolucional (Shen, *et al.*, 2023). Essas camadas trabalham em conjunto para processar a informação de forma hierárquica e abstrair características relevantes, tornando a CNN uma poderosa ferramenta para tarefas de visão computacional e reconhecimento de padrões em imagens (Gio, 2023).




Figura 9. Estrutura da Rede Neural Convolucional.

Fonte: Adaptado em Rocha, *et al.*, (2021).

Embora a CNN tenha sido desenvolvida inicialmente para lidar com dados de entrada no formato 2D, também apresenta boa capacidade de adaptação, podendo lidar com tipos variados de dados, incluindo 1D, que se mostrou bem-sucedido em diversos campos (Hoa *et al.*, 2024).




Figura 10. Arquitetura da Rede Neural Convolucional 1D.

Fonte: Adaptado em (Hoa *et al.*, 2024).

Material e Métodos

O presente capítulo descreve os materiais usados, bem como as metodologias seguidas para alcançar os resultados obtidos com os modelos RUSLE e CNN.

4.1. Descrição do material

4.1.1. Ferramentas utilizadas na análise de perda de solo

A tabela 1 apresenta as ferramentas computacionais empregues no processamento, análise e visualização dos dados utilizados neste estudo, para os dois modelos de previsão de perda de solo: o modelo RUSLE e a CNN.

Tabela 1. Descrição de ferramentas utilizadas.

Ferramentas	Descrição	Linguagem de programação utilizada	Bibliotecas	Objectivo
<i>Google Earth Engine</i> (GEE)	Plataforma baseada na nuvem para análises geospaciais em larga escala.	Java Script (Js)	Não aplicável	Processamento de imagens de Satélite, obtenção e extracção de variáveis geoambientais em pontos amostrais e reprojecção de dados.
Qgis 3.28	<i>Software open source</i> , de um Sistema de informação geográfica (SIG), que permite edição, visualização e análise de dados georreferenciados.	Não aplicável	Não aplicável	Interpolação espacial dos dados e concepção de mapas temáticos
Google Colab	Ambiente de desenvolvimento hospedado na nuvem do <i>Jupyter Notebook</i> , que	Python	NumPy, Pandas, Geopandas, Scikit-learn, TensorFlow/Keras, Matplotlib	Construção, treinamento e validação do modelo CNN.

	permite a execução do código Python com suporte a GPU.			Análise estatística dos dados e criação de gráficos.
Draw.io	Ferramenta online para criação de diagramas e fluxogramas.	Não aplicável	Não aplicável	Desenho do fluxograma metodológico.
Excel 2013	Aplicativo para criação e análise de planilhas e gráficos.	Não aplicável	Não aplicável	Criação de gráficos para análises estatísticas.
Word 2013	Editor de texto para compilação de documentos.	Não aplicável	Não aplicável	Compilação e organização do documento.

4.1.2. Fonte de Dados Adquiridos para o Modelo RUSLE

Os dados raster necessários para a determinação do factor de perda de solo (A) nas duas regiões analisadas foram adquiridos a partir de várias fontes, incluindo informações sobre precipitação, textura do solo, topografia e cobertura vegetal, como descrito na tabela 2.

Todos os dados dispõem de uma resolução espacial de 30 metros e foram reprojectados para o sistema de coordenadas WGS 84 UTM 36S (32736).

Tabela 2. Dados para o processamento dos factores em RUSLE.

Dados	Tipos de Dados	Fonte de Dados	Descrição	Utilidade
Precipitação	Dados de precipitação (mm)	CHIRPS	Dados quase globais de precipitação combinando imagens de satélite e medições <i>in situ</i> , com resolução de 0,05° e cobertura de 1981 até o presente.	Determinar o factor de erosividade da chuva (R)
Solos	Textura do Solo (areia, argila, carbono, lodo)	<i>OpenLandMap</i> , <i>ISDAsoil</i>	Dados globais e de alta resolução (30m) sobre as propriedades do solo, cobrindo profundidade de 0-20 cm e 20-50 cm.	Determinar o factor de erodibilidade do solo (K)

Topografia	Acumulação de fluxo, inclinação de encostas	<i>HydroSHEDS</i>	Conjuntos de dados hidrográficos baseados em elevações do STRM (NASA, 2000), fornecendo redes fluviais, direções de drenagem e informações de relevo.	Determinar o factor topográfico ou factor de comprimento e inclinação da rampa (LS)
Cobertura Vegetal	Índices de vegetação, uso e manejo do solo	Landsat 8 OLI	Imagens de Satélite com resolução de 15m (pancromático), 30m (visível, NIR, SWIR) e 100m (termal).	Determinar o Factor de Cobertura do Solo (C)

4.1.3. Fonte de Dados Adquiridos para o Processamento CNN

Na análise da perda de solo com recurso à rede neural convolucional (CNN), foram seleccionados 42 factores geoambientais conforme sugerido por Luz (2024), dos quais 29 foram extraídos a partir do MDE, obtido pelo USGS (STRMGL1_003) e 13 provenientes de imagens do satélite Landsat 8, sensor OLI, com base em 6 bandas do espectro electromagnético, a partir das quais foram derivadas 7 covariáveis adicionais, todas com resolução espacial de 30 metros e foram reprojectados no sistema de coordenadas WGS 84 UTM 36S (32736).

Tabela 3. Descrição das covariáveis usadas para correr o algoritmo em CNN.

Covariáveis			
Derivadas do MDE			
Nr	Nome	Sigla	Função
1	<i>Analytical Hillshading</i>	AH	Cálculo analítico de sombreamento para uma grade de elevação, em que a luz proveniente da posição da fonte de luz atingiria a superfície.
2	<i>Aspect</i>	AS	Cria um mapa de inclinação que mostra tanto o aspecto quanto a inclinação do terreno.
3	<i>Channel Network Base Level</i>	CNBL	Distância vertical até um nível base da rede de canais.
4	<i>Closed Depressions</i>	CD	Trata-se de uma área fechada que não tem saída de drenagem superficial e da qual a água escapa apenas por evaporação ou drenagem subterrânea.
5	<i>Convergence Index</i>	CI	Calcula o índice de convergência/divergência em relação ao escoamento superficial.

6	<i>Cross Sectional Curvature</i>	CSC	Curvatura relativa ao plano vertical das diferenças de nível.
7	<i>Flow Accumulation</i>	FA	Áreas onde o fluxo se concentra e permite identificar os caminhos ou fluxo da água.
8	<i>General Curvature</i>	GC	Curvatura geral
9	<i>Gradient</i>	GD	Corresponde ao gradiente hidráulico.
10	<i>Local Curvature</i>	LCU	Curvatura local.
11	<i>Longitudinal Curvature</i>	LGC	Taxa de mudança de inclinação, representa o desvio do gradiente ao longo do fluxo (é negativo se o gradiente aumentar).
12	<i>LS Factor</i>	LSF	Representa o cálculo do fator de comprimento de declive.
13	<i>Mass Balance Index</i>	MBI	Índice de balanço de massa.
14	<i>Multiresolution Index of Ridge Top Flatness</i>	MRRTF	Índice de Multiresolução de topo de vale (MRRTF).
15	<i>Multiresolution Index of Valley Bottom Flatness</i>	MRVBF	Índice de Multiresolução do Fundo do Vale (MRVBF).
16	<i>Plan Curvature</i>	PC	Refere-se à curvatura plana do local. Serve para previsão de risco de movimento de massa.
17	<i>Profile Curvature</i>	PFC	Formas das feições das paisagens. Descreve o segundo mecanismo de acumulação
18	<i>Relative Slope Position</i>	RSP	Representa a posição do declive da célula e sua posição relativa entre o vale e o cume.
19	<i>Slope Inclinação</i>	SP	Inclinação que a superfície do terreno possui em relação ao plano horizontal.
20	<i>Tangential Curvature</i>	TC	Descreve o primeiro mecanismo de acumulação.
21	<i>Terrain Ruggedness Index</i>	TRI	Calcula a diferença dos valores de elevação a partir de uma célula central e as oito células vizinhas.
22	<i>Texture</i>	TX	Textura da superfície do terreno.
23	<i>Topographic Position Index</i>	TPI	Índice topográfico baseado na geomorfologia.
24	<i>Topographic Wetness Index</i>	TWI	Relação entre a declividade local e a área de contribuição específica de montante, é uma medida relativa da disponibilidade em longo prazo de humidade do solo de um determinado local na paisagem.
25	<i>Total Insolation</i>	TI	Cálculo de potencial de entrada de radiação solar (insolação).
26	<i>Upslope Curvature</i>	USC	É a curvatura local média ponderada de distância na área de contribuição de uma célula com base na direção de fluxo múltiplo.
27	<i>Valley Depth</i>	VD	A profundidade do vale refere-se à distância vertical a um nível de base da rede do canal.
28	<i>Vector Ruggedness Measure</i>	VMR	Rugosidade de superfície.
29	<i>Vertical Distance to Channel Network</i>	VDCN	Distância vertical para o nível de base da rede do canal
Derivadas de Imagem de satélite			
30	<i>Banda-Blue</i>	B2	Essa banda é sensível à luz azul e é útil para distinguir características como corpos d'água e áreas urbanas. Também é valiosa na detecção de sedimentos em corpos d'água.

31	<i>Banda-green</i>	B3	A banda verde é eficaz na discriminação de diferentes tipos de vegetação e na identificação de mudanças na cobertura vegetal.
32	<i>Banda-red</i>	B4	Esta banda é crítica para a detecção de saúde das plantas. É particularmente útil na distinção entre vegetação saudável e estressada, bem como na identificação de diferentes tipos de vegetação.
33	<i>Banda-NIR</i>	B5	A banda do infravermelho próximo é crucial para avaliar a saúde das plantas, pois é altamente sensível à estrutura das plantas e ao teor de clorofila. Ajuda na diferenciação de tipos de vegetação e na detecção de áreas afetadas por estresse vegetativo.
34	<i>Banda-SWIR1</i>	B6	Esta banda é valiosa na caracterização de cobertura do solo, identificação de tipos de solo e detecção de minerais expostos. Também é útil na discriminação de áreas afetadas por queimadas.
35	<i>Banda-SWIR2</i>	B7	Essa banda é sensível à humidade do solo e é frequentemente usada na detecção de mudanças na umidade do solo e na identificação de diferentes tipos de superfícies terrestres.
36	<i>Clay Minerals Raton</i>	CMR	Esta razão de banda destaca rochas hidrotermicamente alteradas contendo argila e alunite. Este índice atenua as mudanças de iluminação devido ao terreno, uma vez que é uma razão.
37	<i>Enhanced Vegetation Index</i>	EVI	É um índice otimizado projetado para aprimorar o sinal de vegetação com sensibilidade aprimorada em regiões de alta biomassa e monitoramento de vegetação.
38	<i>Ferrous Minerals Ratio</i>	FMR	Esta relação de banda destaca minerais de rolamento de ferro. Ele usa a relação entre a banda SWIR e a banda NIR.
39	<i>Iron Oxide Ratio</i>	IOR	A razão de óxido de ferro é um razão dos comprimentos de onda vermelho e azul. Isso faz com que áreas com forte alteração de ferro sejam brilhantes. A natureza da razão permite que este índice atenua as diferenças de iluminação causadas pela sombra do terreno.
40	<i>Normalized Difference Vegetation Index</i>	NDVI	Analisa a resposta espectral das plantas nas bandas do vermelho e do infravermelho próximo, com valores possíveis variando de -1 a 1.
41	<i>Simple Ratio</i>	SR	É um índice baseado na razão entre a banda infravermelho próximo (NIR) e a banda do vermelho (RED), produzindo um parâmetro que é altamente sensível à presença de vegetação.
42	<i>Soil Adjusted Vegetation Index</i>	SAVI	É um índice de vegetação que tenta minimizar as influências do brilho do solo recorrendo a um coeficiente de correção do brilho do solo.

Fonte: Adaptado de Farias (2023).

4.2. Métodos

O processo do trabalho até o resultado consistiu numa revisão extensiva da literatura, destacando que a aplicação de algoritmos de Inteligência Artificial (IA) para análise de erosão constitui uma abordagem recente, mas em rápida expansão. Neste sentido, esta secção visa expressar a metodologia usada para se obter os resultados em CNN e RUSLE, nos distritos de Moatize e Sussundenga. O fluxograma apresentado na figura 11, descreve todo o processo seguido até o resultado final.




Figura 11. Fluxograma metodológico

4.2.1. Procedimentos do modelo RUSLE

4.2.1.1. Equação de Perda de Solo

A determinação da erosão do solo com base no modelo RUSLE, no ambiente do Google Earth Engine (GEE), exigiu a recolha e o tratamento de dados provenientes de várias fontes. Estes dados foram reprojectados para o sistema de coordenadas WGS 84 UTM 36S (EPSG:32736), com resolução espacial

de 30 metros. Em seguida, aplicou-se a Equação 1, na qual todos os factores são multiplicados, à exceção do factor P.

4.2.1.2. Factor R

O cálculo do factor de erosividade da chuva (R) exige registros pluviométricos de alta precisão e é obtido pela média anual da soma dos índices de erosividade EI30 para todos os eventos de chuva ocorridos ao longo do ano. No cálculo do índice EI30, são considerados apenas os eventos cuja precipitação ultrapasse 2,5 mm, desde que não haja intervalos sem chuva superiores a 6 horas. Excepções são feitas quando pelo menos 6,5 mm de chuva ocorrem em um período de 15 minutos (Cumbane, 2012; Wischmeier & Smith, 1978).

Uma vez que há escassez de informação meteorológica de alta precisão para as áreas em estudo, usou-se dados raster de precipitação diária do CHIRPS (*Climate Hazards Group InfraRed Precipitation with Station data*) para o período de 2010 a 2020. Onde os dados foram reprojectados para a mesma resolução espacial e sistema de coordenadas da análise, de modo a garantir compatibilidade com outras camadas geoespaciais. E fez-se o cálculo da precipitação anual para cada ano estimado para o estudo.

Para obter o factor R, aplicou-se a equação 2, que relaciona a precipitação anual com a erosividade da chuva, desenvolvida por Singh (1981) citado por Ghosal & Bhattacharya (2019),

$$R = 79 + 0.363 * AAP$$

Equação 2. Fórmula do factor R

Onde:

R é o fator de erosividade da chuva;

AAP é a precipitação média anual em mm;

Após o cálculo anual do factor R, fez-se a média ao longo dos 10 anos, e classificou-se de acordo com a intensidade, seguindo a abordagem ilustrada na tabela 4.

Tabela 4. Classes do Índice de Erosividade da chuva.

Valores de R	Grau de erosividade
< 5000	Fraca
5000 – 7500	Moderada
7500 - 10000	Forte
< 10000	Muito Forte

Fonte: Chueh, (2004)

4.2.1.3. Factor K

Considerando os dados de frações do solo, o factor de erodibilidade (K) foi calculado com base em dados espaciais sobre a composição do solo, que inclui a fração de areia, silte, argila e carbono orgânico. O processo envolveu a combinação de imagens raster adquiridas do OpenLand e IsadaSoil para a obtenção do valor final do factor K.

Para o cálculo do factor K foi usada a equação 4, adoptada por Sharpley & Williams (1990) citado por Ghosal & Bhattacharya (2019),

$$SN_1 = 1 - \frac{SAN}{100}$$

Equação 3. Fórmula de percentagem de área.

$$K = \left\{ 0,2 + 0,3 \exp \left[0,0256 SAN \left(1 - \frac{SIL}{100} \right) \right] \right\} \times \left(\frac{SIL}{CLAY + SIL} \right)^{0.3} \\ \times \left[1,0 - \frac{0,25C}{C + \exp(3,72 - 2,95C)} \right] \times \left[1,0 - \frac{0,7SN_1}{SN_1 + \exp(-5,51 + 2,95SN_1)} \right]$$

Equação 4. Fórmula do Factor K.

Onde:

SAN e a percentagem de área;

SIL percentagem de lodo;

CLAY percentagem de Argila;

C é o teor de carbono da camada superficial do solo em percentagem;

O Resultado final representa a distribuição espacial da erodibilidade do solo ao longo dos distritos de Moatize e Sussundega. Onde fez-se a classificação de grau de erodibilidade, como ilustra a tabela 5.

Tabela 5. Classes de Índice de Erodibilidade (Factor K).

Erodibilidade (Mg.h/MJ.mm)	Classe de erodibilidade
< 0,1	Muito baixa
0,1 – 0,25	Baixa
0,25 – 0,35	Média

0,35 – 0,50	Alta
> 0,50	Muito alta

Fonte: Ranzani, (1980).

4.2.1.4. Factor LS

O fator LS representa a influência da topografia na erosão, comprimento da rampa (L) e da inclinação da encosta (S). para a determinação desse factor, utilizou-se um Modelo Digital de Elevação (DEM) e o fluxo acumulado¹ das áreas de estudo, derivados do *HydroSHEDS*.

O factor comprimento da rampa e da inclinação da encosta foi calculado usando a equação 5 desenvolvida por Moore e Wilson (1992), com base em técnicas de acoplamento em etapas avaliadas por McCool *et al.*, (1989) e Liu *et al.*, (1994) citado por Islam (2022),

$$LS = (0,4 + 1) \times \left(Flowacc \times \frac{CellSize}{22,13} \right)^{0,4} \times \left(\frac{\sin \theta}{0,0896} \right)^{1,3}$$

Equação 5. Fórmulodo Factor LS

Onde:

Flowacc é a acumulação de fluxo (comprimento horizontal da inclinação);

CellSize é o tamanho da célula raster;

θ é a inclinação do DEM em graus;

A inclinação (θ) influencia directamente o factor LS e foi calculada a partir do DEM. A acumulação de fluxo e a inclinação foram combinados numa única camada raster.

4.2.1.5. Factor C

O factor C representa o efeito das condições de cobertura do solo no risco de erosão. Este factor é calculado com base ao *Normalized Difference Vegetation Index* (NDVI). Esse Índice ajuda a inferir a quantidade de cobertura vegetal presente em cada pixel, pois áreas com maior vegetação tendem a ter valores de NDVI mais altos, refletindo menos susceptibilidade a erosão (Ghossal & Bhattacharya 2019).

¹ Fluxo acumulado representa a quantidade de água que escoar em direção a cada célula do raster.

Para o cálculo do factor C foi usada a colecção de imagens do Landsat 8, do ano 2020, com base no NDVI, que foi determinado usando a equação 6 formulada por McFarlane *et al.*, (1991), citado por Ghosal & Bhattacharya (2019),

$$NDVI = \frac{(NIR - Red)}{(NIR + Red)}$$

Equação 6. Fórmula do NDVI.

Onde:

Red e **NIR** são as bandas do espectro eletromagnético correspondentes ao vermelho e ao infravermelho próximo.

Este índice varia entre -1 e 1, onde valores mais altos indicam maior cobertura vegetal. A equação 7, usada para o cálculo do factor C foi formulada por Almagro *et al.*, (2019) citado por Islam (2022),

$$C = 0,1 \times \left(\frac{(-NDVI + 1)}{2} \right)$$

Equação 7. Fórmula do Factor C.

4.2.1.6. Factor de Práticas de Conservação (P)

O factor de medidas de conservação indica a percentagem de perda de solo devido ao plantio em encostas com base em medidas de conservação de solo e água, com valores variando de 0 a 1, onde valores menores indicam boas práticas adoptadas (Zeng *et al.*, 2017). No entanto, a obtenção de informações relacionadas às medidas de conservação, exige levantamento detalhado no terreno (Lee *et al.*, 2017).

Devido a indisponibilidade de informação referente ao factor P, nas áreas de estudo, optou-se por excluir este factor da equação de RUSLE. Reconhecendo que a exclusão deste factor pode levar a superestimação de perda de solo, particularmente em áreas onde práticas de conservação são implementadas (Panagos *et al.*, 2015).

4.2.1. Procedimentos do modelo CNN

A estrutura do modelo CNN para a previsão de perda de solo requer um conjunto de dados de entrada, dividido em subconjunto de treino e validação. Estes dados consistem em factores geoambientais,

conforme apresentados e descritos na Tabela 3, os quais foram processados e seleccionados após a análise de multicolinearidade, garantindo que apenas variáveis com $VIF \leq 5$ fossem utilizadas .

Das variáveis seleccionadas, foram extraídos quatro conjunto de pontos, com os valores correspondentes a cada imagem dos factores geoambientais, referentes aos distritos de Sussundenga e Moatize, que não se correlacionam e armazenados num ficheiro CSV (*Comma Separated Values*), com a extensão espacial (x, y), nomeadamente: 870, 4000, 6000 e 8000 pontos. O primeiro conjunto, com 870 pontos, foi baseado na metodologia proposta por Luz (2024). E os restantes conjuntos foram seleccionados de forma aleatória, com intervalos de aproximadamente 2000 pontos entre si, a fim de avaliar como a quantidade de dados pode influenciar no desempenho do modelo de IA. Optou-se por interromper a análise no conjunto de 8000 pontos, uma vez que, à medida que o número de amostras aumentava, os valores das métricas dos modelos tornaram-se estáveis, não se registando divergências significativas nos resultados, indicando que, a partir de 8000 pontos, o modelo já atingia um nível de desempenho satisfatório.

Uma vez que a CNN é frequentemente usada para análise de imagens, foi necessário adaptá-la para trabalhar com dados tabulares, uma vez que o processamento de grandes volumes de imagens no Google Colab seria dispendioso, devido à capacidade limitada do computador utilizado. Assim, os dados foram convertidos para uma representação unidimensional, reduzindo significativamente o tempo de processamento.

Foram integrados dados históricos de erosão, armazenados num ficheiro CSV com coordenadas espaciais (x, y), para melhorar a previsão da susceptibilidade à erosão do solo. Conforme salientado por Saeed *et al.*, (2023), a inclusão de registos históricos constitui uma variável independente essencial em análises espaciais. Contudo, devido à ausência de dados históricos reais nas áreas de estudo, Moatize e Sussundenga, foi necessário gerar mapas estimados de perda de solo com base no modelo RUSLE, a fim de simular dados históricos de perda de solo.

Para esse efeito, utilizaram-se dados de imagens de satélite do ano de 2010 e dados de precipitação do período de 2000 a 2010. Foram calculados os factores do modelo RUSLE (R, K, LS e C), permitindo gerar mapas de erosão estimada para os distritos de Moatize e Sussundenga. A partir desses mapas, foram extraídos pontos representativos de perda de solo, utilizados como substitutos dos dados históricos ausentes, sendo integrados nos modelo CNN como variável independente com extensão espacial definida. Essa abordagem garantiu que o modelo fosse treinado de forma supervisionado, ainda que com dados simulados.

4.2.1.1. Análise de Multicolinearidade

Para mitigar problemas de sobreajuste devido à correlação entre variáveis, foi realizada uma análise de multicolinearidade às variáveis, utilizando o factor de inflação da variância (VIF). O VIF mede o grau de multicolinearidade e afecta a variância dos coeficientes (Kelly, 2024). A sua interpretação é a seguinte:

- VIF = 1: Ausência de correlação;
- $1 < \text{VIF} \leq 5$: Correlação moderada;
- $\text{VIF} > 5$: Correlação elevada;
- $\text{VIF} > 10$: Multicolinearidade severa que precisa ser corrigida.

O VIF é calculado pela expressão:

$$\text{VIF}_i = \frac{1}{1 - R_i^2}$$

Equação 8. Fórmula para o cálculo de multicolinearidade.

R_i^2 : representa o coeficiente de determinação da regressão da i-ésima variável independente em relação às restantes.

4.2.1.2. Aplicação da Rede Neural Convolucional

Após a selecção das covariáveis de acordo com o grau de multicolinearidade, os dados foram normalizados utilizando o *StandardScaler*, de forma que a distribuição tenha média zero e desvio padrão unitário. A variável alvo (variável independente) foi traduzida para um problema de classificação binária e foi categorizada da seguinte forma: 0 para áreas sem erosão (valores de perda de solo ≤ 70); 1 para áreas com erosão (valores > 70).

Os dados foram organizados de forma aleatória e separados em dois subconjuntos, com 80% para treino e 20% para validação, usando um *random_state* fixo, a fim de possibilitar a repetição dos experimentos com os mesmos resultados.

A arquitetura da CNN foi composta por:

- Uma camada convolucional unidimensional (Conv1D) com 64 filtros e função de activação ReLU (*Rectified Linear Unit*), responsável pela extracção de padrões locais nas sequências de dados;
- Uma camada de achatamento (*Flatten*), que transformou as saídas em um tensor unidimensional;

- Uma camada densa com 64 neurónios e activação ReLU;
- Uma camada *dropout* com taxa de 0.3 para o controle de *overfitting*;
- Uma camada de saída com activação *sigmoid*, responsável por estimar a probabilidade de ocorrência de erosão.

O modelo foi treinado usando:

- Otimizador Adam (taxa de aprendizagem = 0,001);
- Função de perda *binary_crossentropy*, adequada para classificação binária;
- Interrupção antecipada (*early stopping*) monitorando a perda no conjunto de validação e interrompendo o treinamento quando não houvesse melhoria por 10 épocas consecutivas, prevenindo *overfitting*.
- O treinamento foi realizado por um máximo de 200 épocas, com desempenho sendo acompanhado pelo conjunto de validação.




Figura 12. Arquitectura do modelo de Rede Neural Convolutacional (CNN) aplicado à classificação binária de áreas com e sem erosão.

4.3. Validação dos Modelos RUSLE e CNN

Os modelos foram avaliados com recurso a métricas como acurácia, precisão, recall, F1-score e curva ROC-AUC.

4.3.1 Acurácia

De acordo com Rodrigues *et al.*, (2022), diversas métricas são utilizadas para avaliar a eficiência de classificadores em algoritmos inteligentes, uma delas é a acurácia, que é considerada devido à sua facilidade e eficácia.

A acurácia pode ser compreendida descrita como a razão das classificações correctas feitas em relação ao número total de classificações realizadas. Assim sendo, mostra com que frequência o classificador prevê com sucesso o futuro (Correia *et al.*, 2021, citado por Barbosa, 2022).

Essa métrica é calculada pela razão do número de previsões correctas em relação ao número total de previsões realizadas. A acurácia é calculada com base nas ocorrências de verdadeiros positivos (VP), verdadeiros negativos (VN), falsos positivos (FP) e falsos negativos (FN). Quanto menores forem os valores de FP e FN, maior será a acurácia do modelo.

A fórmula que expressa essa relação é:

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN}$$

Equação 9. Cálculo da acurácia.

4.3.2 Precisão

A precisão mede o percentual de dados classificados como positivos que são realmente correctos, sendo calculada pela razão entre os verdadeiros positivos (VP) e o total de positivos classificados (VP + FP). Assim, quanto maior o número de falsos positivos (FP), menor será a precisão (Granato, 2022).

Essa métrica é mais útil quando os falsos positivos (FP) são mais prejudiciais do que os falsos negativos (FN), pois mede a capacidade do modelo de os evitar. A fórmula é:

$$Precisão = \frac{VP}{VP + FP}$$

Equação 10. Cálculo de precisão

4.3.3 Recall (Retorno)

De acordo com Granato (2022), O retorno, que também é chamado de sensibilidade, avalia a capacidade de o modelo identificar corretamente todos os casos que deveriam ser classificados como positivos. Ele é calculado pela razão entre os VP e a soma dos verdadeiros positivos e falsos negativos ($VP + FN$). É expressa pela seguinte fórmula:

$$Recall = \frac{VP}{VP + FN}$$

Equação 11. Cálculo da recall.

Essa métrica é pertinente em contextos onde os FN são mais críticos do que FP, pois determina a proporção de casos positivos reais que foram capturados corretamente pelo modelo. Um alto recall indica uma menor taxa de falsos negativos e uma maior capacidade do classificador em detectar casos positivos.

4.3.4 F1 – Score

Segundo Júnior (2023), O F1-score, é definida como a média harmônica entre precisão e recall, que avalia a proporção das duas dimensões. É particularmente significativo quando considera tanto os falsos positivos (FP) quanto os falsos negativos (FN) do modelo.

O F1-Score é calculada pela seguinte expressão:

$$F1 - score = 2 \times \frac{Precisão \times Recall}{Precisão + Recall}$$

Equação 12. Cálculo da f1-score.

Essa métrica é útil quando um modelo precisa encontrar um equilíbrio entre a precisão e o recall, sobretudo em casos onde os FN superam os FP. Um alto F1-Score revela que o modelo possui altos valores de precisão recall, indicando forte capacidade de prever corretamente a classe de interesse e identificar casos positivos.

4.3.5 AUC – ROC Curve (Curva ROC-AUC)

A curva ROC é usada para determinar a capacidade que um modelo de classificação tem em discriminar duas classes, positivo e negativo (0 e 1). Ela traça a relação entre a Taxa de Verdadeiros Positivos (eixo y) e a Taxa de Falsos Positivos (eixo x) em vários limiares de classificação. Modelos com bom desempenho tendem a acumular altos valores de verdadeiros positivos no eixo y enquanto mantêm baixos valores no eixo x.

A área sob a curva (AUC) leva em consideração a separabilidade entre as classes, ilustrando o desempenho do modelo. Quanto maior o AUC, melhor a previsão, onde o modelo acerta as classes 0 e 1, sendo 0,5 o ponto de corte entre as classes (Rodrigues *et al.*, 2022).

Resultados e Discussão

O objetivo deste capítulo é apresentar e discutir os resultados obtidos a partir da aplicação da metodologia RUSLE e da Rede Neural Convolucional (CNN) nos distritos de Moatize e Sussundenga. A análise dos resultados é realizada com base em mapas temáticos, tabelas e gráficos, permitindo uma interpretação visual e quantitativa da susceptibilidade à erosão nas áreas de estudo.

5.1. Resultados

5.1.1. Mapeamento pelo Método RUSLE de Perda de Solo

5.1.1.1. Factor R

A análise da distribuição do factor da erosividade da chuva ao longo dos 10 anos revelou resultados significativos entre os distritos de Moatize e Sussundenga. Os mapas apresentados na figura 13 ilustram a distribuição espacial do factor R que representa o potencial erosivo da chuva, nos distritos em estudo.

No distrito de Moatize, os valores do factor R variam entre 4000 e 11000 MJ.mm/ha.h.ano, enquanto no distrito de Sussundenga variam entre 2500 e 7000 MJ.mm/ha.h.ano.

Segundo a classificação dos graus de erosividade apresentada na tabela 6, observa-se que Moatize apresenta predominância de áreas classificadas como de erosividade forte (67,68%) e moderada (24,54%), sobretudo na região norte. A classe de erosividade muito forte representa apenas 7,78% da área e a fraca não foi identificada.

Em contraste, o distrito de Sussundenga apresenta maior ocorrência de áreas classificadas como de erosividade moderada (36,26%), com ausência total das classes forte e muito forte. As áreas de erosividade moderada concentram-se principalmente na região central do distrito, e os valores de erosividade predominam no resto do distrito.

Os resultados demonstram que Moatize possui maior erosividade da chuva em relação a Sussundenga, indicando maior risco potencial de processos erosivos. Esse padrão pode estar associado a factores como a exploração de recursos naturais e minerais, bem como à adopção de práticas não sustentáveis de uso da terra. Segundo Rattner (2009), tais práticas contribuem significativamente para a degradação dos solos, especialmente quando combinadas com chuvas frequentes e intensas. Portanto, os dados reforçam a necessidade de medidas de conservação do solo mais rigorosas e adaptadas à realidade ambiental do distrito de Moatize.

Tabela 6. Área e Percentagem de ocorrência de Erosividade no distrito de Moatize e Distrito de Sussundenga.

Valores de R	Grau de Erosividade	Área de ocorrência (km ²)		Percentagem de Ocorrência (%)	
		Moatize	Sussundenga	Moatize	Sussundenga
< 5000	Fraca	0	4528,490	0	63,74
5000 – 7500	Moderada	2068,392	2576,530	24,54	36,26
7500 - 10000	Forte	5704, 184	0	67,68	0
< 10000	Muito Forte	655,577	0	7,78	0




Figura 13. Factor de Erosividade da Chuva.

5.1.1.2. Factor K

Os resultados do factor K, como apresentados nos mapas da figura 14, revelam uma variabilidade considerável nas características do solo em termos de susceptibilidade à erosão ao longo das áreas de estudo. Os valores do factor de erodibilidade variam entre 0,110 e 0,135 Mg.h/MJ.mm para o distrito de Moatize e entre 0,120 e 0,170 Mg.h/MJ.mm para o distrito de Sussundenga.

Segundo a classificação descrita na tabela 7, as classes predominantes são baixas e médias nos distritos de Moatize e Sussundenga. O distrito de Moatize apresenta maior área com classe baixa, ocupando 99,986%, enquanto Sussundenga apresenta maior porção na classe média.

Tabela 7. Área e Percentagem de ocorrência de Erodibilidade do solo no distrito de Moatize e Distrito de Sussundenga.

Erodibilidade (Mg.h/MJ.mm)	Classe erodibilidade	Área de ocorrência (km ²)		Percentagem de Ocorrência (%)	
		Moatize	Sussundenga	Moatize	Sussundenga
< 0,1	Muito baixa	0	0	0	0
0,1 – 0,25	Baixa	8387,434	7014,155	99,986	99,437
0,25 – 0,35	Média	1,176	39,724	0,014	0,563
0,35 – 0,50	Alta	0	0	0	0
> 0,50	Muito alta	0	0	0	0




Figura 14. Factor de Erodibilidade do Solo.

5.1.1.3 Factor LS

Os mapas do factor LS nos distritos de Moatize e Sussundenga ilustrados na figura 15 mostram uma variação significativa deste factor, que afecta directamente o risco de erosão do solo. Em Moatize, os valores alcançam um máximo de 971,132, enquanto em Sussundenga o limite superior é 373,666.

Para melhor representar as variações locais e facilitar a interpretação, a simbologia foi ajustada, limitando a escala máxima de 50. Os resultados, conforme ilustrados na tabela 8, mostram que os valores mais altos do factor LS estão concentrados no Norte de Moatize e no nordeste e sudoeste de Sussundenga, incluindo as linhas de drenagem para ambos os distritos.

Observa-se que Sussundenga ocupa maior extensão de áreas classificadas como de alto risco, enquanto Moatize apresenta maior predominância de valores baixos. Sugerindo que maior parte do distrito de Sussundenga é composto por encostas mais longas e íngremes, e como referência o Monte binga. Por outro lado, o distrito de Moatize apresenta uma topografia menos acidentada.

Tabela 8. Área e Percentagem de ocorrência do factor LS no distrito de Moatize e Distrito de Sussundenga.

Inclinação da encosta e comprimento da rampa	Classe do factor LS	Área de ocorrência (km ²)		Percentagem de Ocorrência (%)	
		Moatize	Sussundenga	Moatize	Sussundenga
0 - 10	Baixa	7611,9669	5212,7200	90	77
10 – 30	Média	649,5687	1149,9201	8	17
30 – 50	Alta	77,9949	216,7767	1	3
>50	Muito alta	80, 1099	175,2615	1	3




Figura 15. Factor de Comprimento da Rampa e Inclinação da Encosta.

5.1.1.4. Factor C

O mapa do fator C, como ilustra a figura 16, demonstra a cobertura vegetal no distrito de Moatize e Sussundenga, que são áreas com características ambientais e de uso do solo distintas. No distrito de

Moatize, os valores do factor C variam entre 0,0301 e 0,0566, enquanto que no distrito de Sussundenga variam entre 0,0274 e 0,0593.

Pode-se observar que áreas com valores mais baixos (próximos de 0,0301 para Moatize e 0,0274 para Sussundenga) apresentam melhor cobertura vegetal, o que contribui para uma menor susceptibilidade à erosão. Essa proteção natural pode ser decorrente da vegetação nativa ou de práticas agrícolas que mantêm uma boa cobertura vegetal do solo, reduzindo o impacto das gotas de chuva e o transporte de sedimentos.

Por outro lado, regiões com valores mais altos (0,0566 para Moatize e 0,0593 para Sussundenga), predominantes no extremo sul de Moatize e nos cursos de água do mesmo distrito, bem como valores altos, especialmente na região norte do distrito de Sussundenga e nos seus cursos de água, mostram maior vulnerabilidade à erosão. Nessas áreas, a cobertura do solo é menos eficaz na protecção contra os processos erosivos, o que pode refletir práticas inadequadas de manejo do solo.




Figura 16. Factor de Maneio e Cobertura do Solo.

5.1.2. Criação do Modelo CNN para análise de perda de solo

5.1.2.1. Análise de Multicolinearidade dos Factores Geoambientais

As variáveis seleccionadas para o treino do modelo foram filtradas com base no nível de correlação, uma vez que factores altamente correlacionados podem provocar sobreajuste, comprometendo a precisão do modelo. Para evitar este problema, foram escolhidas apenas as variáveis com correlação moderada, ou seja, aquelas cujo factor de inflação da variância (VIF) é inferior ou igual a 5 ($VIF \leq 5$).

Deste modo, dos 42 factores geoambientais analisados, apenas 21 foram considerados adequados para o treino, pois apresentaram VIF dentro do intervalo aceitável. As Figuras 17 e 18 mostram a distribuição do VIF das variáveis que não se correlacionam nos distritos de Sussundenga e Moatize.

Observa-se que Sussundenga possui mais factores com valores próximos de 5, enquanto em Moatize os valores tendem a ser inferiores, mais próximos de 4. Além disso, Moatize apresenta um maior número de factores com VIF próximos de 1, sugerindo que o modelo para este distrito foi mais preciso e menos susceptível a sobreajustes. Estes resultados indicam que os factores seleccionados em ambos os distritos influenciaram o modelo de forma significativa e precisa, minimizando o risco de overfitting durante o treino.




Figura 17. Gráfico de Factor de Inflação da Variância (VIF) do Distrito de Sussundenga.




Figura 18. Gráfico de Factor de Inflação da Variância (VIF) do distrito de Moatize.

5.1.2.2. Avaliação do Desempenho do Modelo CNN com Quantidades de Amostras Diferentes

As tabelas 9 e 10 ilustram o comportamento do modelo CNN para a análise de perda de solo nos distritos de Moatize e Sussundenga, usando métricas de desempenho, como acurácia, precisão, recall e f1-score, considerando diferentes quantidades de pontos de amostragem usados no treino.

No distrito de Moatize, com apenas 870 pontos, o modelo apresentou uma acurácia de 76,16%, precisão de 68,27%, recall de 80,56% e F1-score de 73,90%. À medida que o número de pontos aumentou, verificaram-se melhorias significativas em todas as métricas. A partir de 4000 e 6000 pontos, nota-se que o modelo começa a responder de forma positiva, mostrando eficiência. Com 8000 pontos, observou-se uma melhoria muito considerável, sugerindo que o modelo teve uma evolução consistente e se tornou mais eficaz, atingindo valores como 89,98% de acurácia, 90,98% de precisão, 93,42% de recall e 92,18% de F1-score.

De forma semelhante, no distrito de Sussundenga, os resultados também revelam uma evolução considerável de valores. Com 870 pontos a acurácia foi de 76,57%, com uma precisão de 64,60%, recall de 77,72% e F1-score de 70,60%. Ao utilizar 8000 pontos, os valores aumentaram para 89,54% (acurácia), 90,16% (precisão), 91,54% (recall) e 90,84% (F1-score).

Tabela 9. Métricas de validação do distrito de Moatize.

Nr de pontos	Métricas Moatize			
	Acurácia	Precisão	Recall	F1-Score
870	76,16%	68,27%	80,56%	73,9%
4000	86,05%	82,55%	86,40%	84,43%
6000	88,92%	88,29%	87,88%	88,08%
8000	89,98%	90,98%	93,42%	92,18%

Tabela 10. Métricas de validação do distrito de Sussundenga.

Nr de pontos	Métricas Sussundenga			
	Acurácia	Precisão	Recall	F1-Score
870	76,57%	64,60%	77,72%	70,60%
4000	85,68%	84,34%	86,99%	85,64%
6000	88,58%	89,05%	89,58%	89,31%
8000	89,54%	90,16%	91,54%	90,84%

As figuras 19 e 20 demonstram graficamente essa progressão para o distrito de Moatize e Sussundenga. É possível verificar em ambas figuras a evolução nas métricas para cada conjunto de pontos utilizados. Demonstrando que o desempenho do modelo na rede neural convolucional está directamente relacionado a quantidade de dados ou pontos disponíveis para o treino.

Constata-se também, que o uso de 4000 a 6000 pontos já proporcionam resultados satisfatórios, mas o uso de 8000 mostra-se ideal, conferindo ao modelo uma capacidade preditiva e robusta.




Figura 19. Evolução das métricas de desempenho, em relação a quantidade de pontos amostrais, no distrito de Moatize.




Figura 20. Evolução das métricas de desempenho, em relação a quantidade de pontos amostrais, no distrito de Sussundenga.

5.1.2.3. Avaliação do Desempenho dos Modelos RUSLE e CNN

Para avaliar os modelos foi considerado o modelo CNN treinado com 8000 pontos, que é o conjunto de amostras que se mostrou ideal.

A Figura 21 apresenta os resultados obtidos para ambos modelos nos distritos de Moatize e Sussundenga, considerando quatro métricas de avaliação: acurácia, precisão, recall e F1-score.

Em Moatize, a acurácia do modelo RUSLE foi de 74,92%, enquanto a CNN alcançou 89,98%, reflectindo melhoria considerável na capacidade de classificação correcta das amostras de classes. Em Sussundenga, a CNN também se destacou, alcançando uma acurácia de 89,54%, em comparação com os 74,68% do modelo RUSLE.

Quanto à precisão, o modelo CNN alcançou 90,98% em Moatize e 90,16% em Sussundenga, superando os 85,47% e 85,33% obtidos pelo RUSLE, respectivamente. Isso indica que o RUSLE é capaz de oferecer boa confiabilidade na identificação de áreas erodidas, porém a CNN apresenta maior vantagem pois tem uma taxa de falsos positivos baixos, melhorando sua confiança na identificação de áreas afectadas pela erosão.

A métrica de recall, que mede a capacidade do modelo em classificar corretamente todas as áreas erodidas, foi de 93,42% em Moatize e 91,54% em Sussundenga para o modelo CNN, e 77,30% e 76,87%

apresentados pelo RUSLE. Esses números apontam que a CNN consegue identificar com eficácia áreas de risco, reduzindo falsos negativos.

Por fim, o F1-score, que é a média entre precisão e recall, valida a robustez do modelo CNN, com valores de 92,18% em Moatize e 90,84% em Sussundenga, enquanto que o modelo RUSLE, obteve 81,18% em Moatize e 80,88% em Sussundenga.

Esses resultados sugerem que, embora o RUSLE continue sendo uma ferramenta de referência prática, a CNN apresenta maior capacidade de generalização e precisão na previsão da erosão do solo em diferentes contextos geográficos, especialmente nos distritos de Moatize e Sussundenga.




Figura 21. Comparação do desempenho dos modelos RUSLE e Redes Neurais Convolucionais (CNN) na predição da perda de solo em Moatize e Sussundenga, com base nas métricas de Acurácia, Precisão, Recall e F1-Score.

5.1.2.4. Curva ROC-AUC

A aplicabilidade dos modelos CNN e RUSLE também foi avaliada com base na métrica ROC-AUC. Esta métrica permite aferir a capacidade que os modelos têm em diferenciar áreas susceptíveis e não suscetíveis à erosão do solo. Os resultados apresentados nas Figuras 22 e 23, reforçam a diferença de abordagens entre os modelos.

O modelo CNN com 8000 amostras, no distrito de Sussundenga, apresentou o melhor desempenho, atingindo um valor de 0,984, seguido do modelo CNN com 6000 amostras, com 0,973, e 4000 amostras, com 0,962. O modelo treinado com 870 amostras teve desempenho inferior (0,852).

O modelo RUSLE registou um desempenho significativamente inferior, com um valor de AUC-ROC de 0,690, indicando desempenho limitado em termos de discriminação.

Para o distrito de Moatize, o modelo CNN com 8000 amostras obteve o melhor resultado global, com um valor de AUC-ROC de 0,989, indicando elevada precisão na classificação das áreas susceptíveis à erosão. Em seguida, o modelo com 6000 amostras obteve 0,985, o de 4000 amostras, 0,970, e o de 870 amostras, 0,893. O modelo RUSLE para esta região também demonstrou um desempenho inferior (AUC-ROC = 0,725).




Figura 22. Curva ROC aplicada em modelos CNN e RUSLE no distrito de Moatize




Figura 23. Curva ROC aplicada em modelos CNN e RUSLE no distrito de Sussundenga.

5.1.3. Mapas de susceptibilidade à erosão baseado nos modelos RUSLE e CNN

Os resultados obtidos pelos modelos RUSLE e CNN são apresentados nos mapas das figuras 24 e 25, que ilustram a distribuição espacial de erosão em diferentes classes de perda de solo. A perda média anual de solo no distrito de Moatize foi de 93,91 t/(ha.ano) e, em Sussundenga, de 204,92 t/(ha.ano), segundo o método empírico RUSLE. Para o modelo baseado em *Deep Learning*, os valores estimados foram mais elevados, 125,37 t/(ha.ano) para Moatize e 325,73 t/(ha.ano) para Sussundenga.

De acordo com a classificação da tabela 11, verifica-se que, na classe de baixa perda de solo em Moatize, o modelo RUSLE apresentou maior ocorrência, cobrindo cerca de 72% da área, enquanto o modelo CNN registou apenas 51% para esta mesma classe. Por outro lado, nas classes média, alta e severa, o modelo CNN apresentou valores de ocorrência mais elevados em relação ao modelo tradicional, com 20%, 9% e 20%, respectivamente.

No distrito de Sussundenga, observa-se um cenário semelhante, onde o modelo RUSLE teve 55% de ocorrência para classe baixa, e para as classes média, alta e severa, o modelo CNN apresentou maior cobertura espacial. Neste distrito, o modelo CNN registrou 48% de ocorrência para a classe severa, apresentando uma diferença de 23% em relação ao modelo empírico.

Tal padrão reforça a tendência do modelo CNN identificar uma maior extensão de áreas com perda de solo mais acentuada.

Tabela 11. Área e Percentagem de ocorrência de perda de solo para cada modelo, no distrito de Moatize.

Moatize					
Perda de Solo	Classes da erosão do solo	Área de Ocorrência (km^2)		Percentagem de Ocorrência (%)	
		RUSLE	CNN	RUSLE	CNN
≤ 50	Baixa	5958,04	4298,59	72	51
50 – 100	Média	941,01	1652,69	11	20
100 – 150	Alta	414,78	782,01	5	9
> 150	Severo	924,08	1674,76	11	20

Tabela 12. Área e Percentagem de ocorrência de perda de solo para cada modelo, no distrito de Sussundenga.

Sussundenga					
Perda de Solo (Factor A)	Classes da erosão do solo	Área de Ocorrência (<i>km</i> ²)		Percentagem de Ocorrência (%)	
		RUSLE	CNN	RUSLE	CNN
<=50	Baixa	3853,81	1449,78	55	21
50 – 100	Média	887,54	1461,40	13	21
100 – 150	Alta	499, 15	710,69	7	10
>150	Severo	1791,97	3410,60	25	48




Figura 24. Mapas de Susceptibilidade á erosão do solo, baseado ao modelo RUSLE e CNN, no Distrito de Moatize.




Figura 25. Mapas de Susceptibilidade á erosão do solo, baseado ao modelo RUSLE e CNN, no Distrito de Sussundenga.

5.2. Discussão

Os resultados obtidos neste estudo evidenciam o elevado potencial da aplicação e integração de técnicas de Inteligência Artificial (IA), particularmente das Redes Neurais Convolucionais (CNN), na análise da susceptibilidade à erosão do solo em diferentes contextos geográficos, nomeadamente nos distritos de Moatize e Sussundenga.

O modelo CNN demonstrou desempenho notável, mesmo ao ser alimentado exclusivamente com valores tabulares pontuais extraídos de factores geoambientais não correlacionados, ao invés de imagens, como é comumente usado. Esta abordagem apresenta uma vantagem em contextos em que o volume de dados é elevado, mas há limitações computacionais para o processamento integral das imagens.

O modelo CNN treinado com 8.000 pontos (modelo considerado nesta pesquisa) registou valores elevados de AUC, que foram 0,989 para Moatize e 0,984 para Sussundenga, Já o modelo RUSLE, obteve valores de AUC de 0,725 e 0,690, respectivamente.

Esta diferença reflecte-se pela limitação do modelo RUSLE, que considera um conjunto de factores pré-definidos fixos, enquanto que a CNN oferece maior flexibilidade permitindo integrar diferentes tipos e quantidade de variáveis, ajustando-se melhor a complexidade espacial das áreas estudadas.

Os resultados desta pesquisa fundamentam os estudos de Khosravi *et al.*, (2022), cuja pesquisa obteve valores de AUC de 0,61 para o RUSLE e 0,85 para CNN, destacando limitações do modelo empírico frente às técnicas de IA. O modelo CNN tabular, atingiu valores altos, superando inclusive os modelos híbridos como o CNN-GWO e o SVR-GWO (ambos com AUC de 0,87) considerados por esses autores. Tais resultados podem estar associados à elevada quantidade de pontos de treino extraídos de várias variáveis geoambientais.

De modo semelhante, Aliche *et al.*, (2023) demonstraram nos seus estudos, elevado potencial do modelo CNN, com AUC de 0,97, superando outros modelos por eles estudado, mas ligeiramente inferior ao modelo Stacking, que atingiu 0,98, resultado semelhante ao modelo CNN tabular para os distritos de Moatize e Sussundenga. É relevante referir que esse estudo utilizou 19 imagens como base para os modelos, enquanto na presente pesquisa os dados tabulares derivam de 22 imagens, o que pode ter contribuído para um maior volume de informação útil durante o treino.

Por outro lado, Sarif *et al.*, (2024) reforçam o potencial dos modelos de IA para a predição da erosão do solo. Neste caso, os modelos CNN e *Deep Neural Network* (DNN) apresentaram AUC de 0,98, superando o *Fully connected neural network* (FCNN) e o modelo híbrido DNN-CNN (ambos com AUC de 0,97), mesmo utilizando imagens como entrada (17 imagens). Contudo, ainda que com desempenho similar, os resultados da CNN com dados tabulares da presente pesquisa obtiveram valores elevados no distrito de Moatize (AUC de 0,989), demonstrando que, sob certas condições, o uso de dados pontuais pode ser mais eficaz do que imagens raster directamente aplicadas.

A confrontação entre os resultados apresentados neste trabalho e os de autores anteriores permite concluir que o modelo CNN adaptado para dados tabulares (1D) se mostra competitivo e, em alguns casos, superior às abordagens baseadas em imagens ou modelos híbridos. Este comportamento pode estar associado tanto ao elevado número pontos de treino (8.000) quanto à diversidade de factores geombientais consideradas, aumentando a capacidade de generalização do modelo.

Conclusões e Recomendações

O presente capítulo tem como objetivo apresentar as principais conclusões obtidas ao longo desta pesquisa, com base nos resultados alcançados. Além disso, são formuladas recomendações práticas e científicas que visam contribuir para futuras investigações ou para a aplicação dos resultados em contextos relevantes.

6.1 Conclusão

A presente pesquisa demonstrou o avanço significativo da tecnologia na previsão da erosão do solo, através da aplicação de técnicas de IA, especificamente o modelo de *Deep Learning* (DL), baseado em CNN. O estudo explorou a aplicabilidade da CNN com o método empírico RUSLE, utilizando métricas de validação como precisão, acurácia, recall, F1-score e ROC-AUC.

Verificou-se que a CNN é capaz de lidar com diferentes factores geoambientais que influenciam a erosão do solo, independentemente do seu tipo (imagem ou pontos), representando uma alternativa robusta e eficiente para a modelação da susceptibilidade à erosão do solo, destacando-se como uma opção viável em contextos de elevada disponibilidade de dados raster e limitações computacionais. O aumento da quantidade de dados de treino mostrou impacto directo na melhoria do desempenho do modelo, reforçando a importância da densidade e diversidade das amostras para a robustez do modelo.

O estudo permite concluir que ambos modelos apresentam aplicabilidade em diferentes contextos. O RUSLE expressa o seu valor como modelo empírico consolidado e prático, que permite obter resultados de forma rápida e com menor exigência computacional, sendo especialmente útil em análises prévias, e a CNN mostra maior flexibilidade e boa capacidade de generalização.

Em suma, este trabalho demonstra que a integração de abordagens empíricas e baseadas em IA podem ser ferramentas valiosas para apoiar a definição de estratégias de conservação do solo e mitigação de impactos ambientais, ajustando-se às condições e necessidades específicas de cada estudo.

6.2 Recomendações

Para a continuação deste estudo, recomenda-se a exploração de diferentes algoritmos de IA, especialmente modelos híbridos, a fim de avaliar o seu desempenho na análise da susceptibilidade à erosão nas regiões estudadas, Moatize e Sussundenga, e compará-los com o modelo CNN. Seria, de igual modo, interessante usar dados tabulares e imagens raster para comparar o comportamento do modelo face a diferentes tipos de dados de entrada na mesma área de estudo.

Além disso, considera-se relevante aprofundar a investigação sobre a influência de cada factor geoambiental no desempenho do modelo CNN, identificando quais variáveis exercem maior impacto na previsão da perda de solo.

Propõe-se também que este trabalho seja acolhido e desenvolvido por instituições como o Instituto Nacional de Gestão de Calamidades (INGC) e a Universidade Eduardo Mondlane (UEM), que possuem interesse na gestão ambiental e na mitigação de riscos relacionados à erosão do solo em Moçambique.

Espera-se que futuros estudos permitam que as informações obtidas sejam de grande utilidade e contribuam, de forma prática, para a conservação do solo e mitigação da erosão no país.

Referências Bibliográficas

- Alkahtania, M., Mallick, J., Alqadhia, S., Sarif, M. N., Mohamed Ahmed, M. F., & Abdo, H. G. (2024). Interpretation of Bayesian-optimized deep learning models for enhancing soil erosion susceptibility prediction and management: A case study of Eastern India. *Geocarto International*, 39(1), 2367611. <https://doi.org/10.1080/10106049.2024.2367611>
- Awan, A. A. (2023). O que é Deep Learning? Um tutorial para iniciantes. DataCamp. Obtido de <https://www.datacamp.com/tutorial/tutorial-deep-learning-tutorial>
- Barakat, A., Rafai, M., Mosaid, H., Islam, M. S., & Saeed, S. (2023). Mapping of water-induced soil erosion using machine learning models: A case study of Oum Er Rbia Basin (Morocco). *Earth Systems and Environment*, 7(151–170).
- Barbosa, M. B. de C. (2022). Avaliação de Desempenho de Mecanismos de Machine Learning para a Detecção de Fake News [Trabalho de Conclusão de Curso, Universidade Federal do Sul e Sudeste do Pará].
- Bouguerra, H., Tachi, S. E., Bouchehed, H., Gilja, G., Aloui, N., Hasnaoui, Y., Aliche, A., Benmamar, S., & Navarro-Pedreño, J. (2023). *Integration of high-accuracy geospatial data and machine learning approaches for soil erosion susceptibility mapping in the Mediterranean Region: A case study of the Macta Basin, Algeria*. **Sustainability**, 15(13), 10388. <https://doi.org/10.3390/su151310388>
- Cabral, A. L. (1951). O problema de erosão do solo: Contribuindo para o seu estudo na região de Cuba (Alentejo). Universidade Técnica de Lisboa, Instituto Superior de Agronomia.
- Capoane, V. (2013). Utilização do fator topográfico da RUSLE para análise da susceptibilidade a erosão do solo em uma bacia hidrográfica com pecuária intensiva do sul do Brasil. *Revista Geonorte*, 8(1), 85–101.
- Castigo, P. (2000). *Análise da produção agrícola no Distrito de Sussundenga (1992-1999)*. Universidade Eduardo Mondlane.
- Cecílio, R. A., Rodriguez, R. D. G., Baena, L. G. N., Oliveira, F. G., & Pruski, F. F. (2009). Aplicação dos modelos RUSLE e WEPP para a estimativa da erosão hídrica em microbacia hidrográfica de Viçosa (MG). *Revista Verde de Agroecologia e Desenvolvimento Sustentável*, 4(2), 39-45.

- Chagas, E. T. de O. (2019). Deep learning e suas aplicações na atualidade. *Revista Científica Multidisciplinar Núcleo do Conhecimento*, RC: 29451. <https://doi.org/10.32749/nucleodoconhecimento.com.br/administracao/deep-learning>
- Chang, P. (2019). Modelagem matemática das perdas de água, solo e nutrientes em Latossolo argiloso sob sistemas de uso e manejo. Universidade Estadual do Oeste do Paraná.
- Chau Liu, H. L. (2023). Applying Convolutional Neural Network to Predict Soil Erosion: A Case of Study of Coastal areas. *International Journal of Environmental Research and Public Health*, 2-21.
- Cherlinka, V. (2022, agosto 11). Erosão do solo: Tipos e prevenção das consequências. EOS Data Analytics. <https://eos.com/pt/blog/erosao-do-solo/>
- Chueh, A. M. (2004). Análise do uso do solo e degradação ambiental na bacia hidrográfica do rio Pequeno São José dos Pinhais/PR, por meio do diagnóstico físico-conservacionista DFC. Universidade Federal do Paraná (Dissertação de Mestrado em Geografia e Ciências da Terra).
- Correia, C. H. G., Komati, K. S., & Boldt, F. de A. (2021). Reconhecimento de gestos de mão em sequência a partir de sensores inerciais. *Journal of Health Informatics*, 12.
- Cumbane, B. L. (2012). Aplicação de Sistemas de Informação Geográfica para a determinação Potencial Natural de Erosão do solo no Distrito de Sussundenga - Moçambique. Lisboa: Instituto Superior de Agronomia da Universidade Técnica de Lisboa.
- Duarte, G. F. P. (2023). Impacto da mineração do carvão nos padrões climáticos locais e na vida da comunidade local em Moatize, Moçambique. *Intermaths*, 4(1), 78–87. <https://doi.org/10.22481/intermaths.v4i1.12541>
- FAO. (28 de Janeiro de 2022). Solos saudáveis para as pessoas e para o planeta: FAO pede reversão da degradação do solo. Roma/Berlim, Itália/Alemanha.
- Ferreira, C. (2013). O Mundo (Im) Perfeito dos modelos de erosão. *Revista da Faculdade de Letras – Geografia – Universidade do Porto*, III série, 2, 51-82.
- Geoprocessamento e Inteligencia Artificial. (25 de maio de 1023). Fonte: geo sem froteiras: <https://geosemfronteiras.org/blog/geoprocessamento-e-inteligencia-artificial/>
- Ghosal, K., & Bhattacharya, S. D. (2020). A Review of RUSLE Model. *Indian Society of Remote Sensing*. Received: 22 March 2019 / Accepted: 26 December 2019 / Published online: 11 January 2020.

- Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., & De, D. (2020). Fundamental concepts of convolutional neural network. In R. Bhatia, A. Sufian, & S. Patil (Eds.), *Advances in Neural Computation, Machine Learning, and Cognitive Research IV* (pp. 535-550). Springer. https://doi.org/10.1007/978-3-030-32644-9_36
- Gillis, A. S., Burns, E., & Brush, K. (2013). O que é o aprendizado profundo e como funciona? TechTarget. Obtido de <https://www.techtarget.com/searchenterpriseai/definition/deep-learning-deep-neural-network>
- Golkarian, A., Khosravi, K., Panahi, M., & Clague, J. J. (2022). *Spatial variability of soil water erosion: Comparing empirical and intelligent techniques*. **Journal of Environmental Management**, **321**, 115859. <https://doi.org/10.1016/j.jenvman.2022.115859>
- Gomes, D. S. (2010). Inteligência Artificial: Conceitos e Aplicações. *Revista Olhar Científico*, 1(2), 234-246.
- Jahun, B. G., Ibrahim, R., Dlamini, N. S., & Musa, S. M. (2015). Review of soil erosion assessment using RUSLE model and GIS. *Journal of Biology, Agriculture and Healthcare*, 5(9), 36. Disponível em <http://www.iiste.org/Journals/index.php/JBAH/article/view/23706>
- Jahun, B. G., Ibrahim, R., Dlamini, N. S., & Musa, S. M. (2015). Review of soil erosion assessment using RUSLE model and GIS. *Journal of Biology, Agriculture and Healthcare*, 5(9). Recuperado de <https://www.iiste.org/Journals/index.php/JBAH/article/view/XXX>
- José, D. S., & Sampaio, C. H. (s.d.). Estado da arte da mineração em Moçambique: Caso carvão de Moatize, Tete. Universidade Federal do Rio Grande do Sul, RS, Brasil.
- Jovino dos Santos, A. M., & Del Vechio, G. H. (2020). INTELIGÊNCIA ARTIFICIAL, DEFINIÇÕES E APLICAÇÕES: o uso de sistemas inteligentes em benefício da medicina. *Interface Tecnológica*, 17(1). <https://doi.org/10.31510/inf.v17i1.782>
- Kelly, R. C. (2024). *Variance Inflation Factor (VIF)*. Investopedia. Atualizado em 27 de junho de 2024. Disponível em: [<https://www.investopedia.com/terms/v/variance-inflation-factor.asp>]
- Khosravi, K., Rezaie, F., Cooper, J. R., Kalantari, Z., Abolfathi, S., & Hatamiafkoueih, J. (2023). Soil water erosion susceptibility assessment using deep learning algorithms. *Journal of Hydrology*, 618, 129229. <https://doi.org/10.1016/j.jhydrol.2023.129229>

- Kumar, S. (2020). Soil erosion and its types: Introduction, principles of soil erosion, wind erosion - type, factors affecting, water erosion - type, factors affecting, mechanism of soil erosion, effect of soil erosion.
- Laflen, J. M., & Moldenhauer, W. C. (2003). Pioneering soil erosion prediction: The USLE story. World Association of Soil & Water Conservation (WASWC), Special Publication No. 1.
- Liu, C., Li, H., Xu, J., Gao, W., Shen, X., & Miao, S. (2023). Applying Convolutional Neural Network to Predict Soil Erosion: A Case Study of Coastal Areas. *International Journal of Environmental Research and Public Health*, 20(3), 2513. <https://doi.org/10.3390/ijerph20032513>
- Liu, C., Li, H., Xu, J., Gao, W., Shen, X., & Miao, S. (2023). Applying convolutional neural network to predict soil erosion: A case study of coastal areas. *International Journal of Environmental Research and Public Health*, 20, 2513. <https://doi.org/10.3390/ijerph20032513>
- Liu, C., Wang, W., Tang, J., Wang, Q., Zheng, K., Sun, Y., Zhang, J., Gan, F., & Cao, B. (2023). A deep-learning-based mineral prospectivity modeling framework and workflow in prediction of porphyry–epithermal mineralization in the Duolong ore District, Tibet. *Ore Geology Reviews*, 156, 105419.
- Maciel, M. M. (2000). APLICAÇÃO DA EQUAÇÃO UNIVERSAL DE PERDAS DE SOLO (USLE) EM AMBIENTE DE GEOPROCESSAMENTO E SUA COMPARAÇÃO COM APTIDÃO AGRÍCOLA. CURITIBA.
- Máquina, D. A., Ramalho, A. R., da Silva, A. J. V., Malei, B. A., Dede Faustino João, C., Serrote, C. M. L., & Mussalama, A. Z. (2022). Spatial analysis of susceptibility to erosion in the Administrative Post of Bilibiza, Mozambique. *Nativa*, 10(2), 225–229. <https://doi.org/10.31413/NATIVA.V10I2.13172>
- Minella, J. P. G., Merten, G. H., Reichert, J. M., & Cassol, E. A. (2010). Processos e modelagem da erosão: da parcela à bacia hidrográfica. In R. B. Prado, A. P. D. Turetta, & A. G. Andrade (Eds.), *Manejo e conservação do solo e da água no contexto das mudanças ambientais* (1ª ed., pp. 105-122). Rio de Janeiro: EMBRAPA Solos.
- Ministério da Administração Estatal, Direcção Nacional de Administração Local. (2012). *Perfil do Distrito de Moatizze, Província de Tete* (Primeira edição, primeira impressão). Maputo, Moçambique: Ministério da Administração Estatal.

Ministério Nacional da Administração Local. (2005). *Perfil do Distrito de Sussundenga, Província de Manica*. Ministério Nacional da Administração Local.

Ministério para a Coordenação da Acção Ambiental. (2007). Plano de acção para a prevenção e controlo da erosão de solos (2008 - 2018). Aprovado na 32ª Sessão do Conselho de Ministros, 04 de Dezembro de 2007. República de Moçambique.

Pena, R. F. A. (2024). Tipos de erosão. Brasil Escola. Recuperado de <https://brasilecola.uol.com.br/geografia/tipos-erosao.htm>

Queiroz da Luz, J. P. (2024). Perdas de solos por erosão hídrica usando RUSLE e Random Forest de Tracuateua - Pará. Universidade Federal Rural da Amazônia, Campus Capanema.

Ranzani, G. (1980). Erodibilidade de alguns solos do Estado do Amazonas. *Acta Amazonica* 10 (2).

Rattner, H. (2009). Meio ambiente, saúde e desenvolvimento sustentável. *Ciência & Saúde Coletiva*, 14(6), 1965-1971. <https://doi.org/10.1590/S1413-81232009000600002>

Reginatto, G. M. P., Maciel, C. B., Corseuil, C. W., Grando, Â., Maccarini, M., Higashi, R. A. R., Feilstrecker, L. B., & Scaburri Júnior, R. (2011). Avaliação das perdas de solo utilizando o modelo RUSLE integrado a um SIG.

Renard, K. G. et al. (1997). *Predicting Soil Erosion by Water: A Guide to Conservation Planning with the Revised Universal Soil Loss Equation (RUSLE)*. USDA Agriculture Handbook No. 703.

Santos, J. C. N., Andrade, E. M., Medeiros, P., & Palácio, Q. (2014). Determinação do fator de cobertura e dos coeficientes da MUSLE em microbacias no semiárido brasileiro. *Revista Brasileira de Engenharia Agrícola e Ambiental*, 18(11), 1157–1164. <https://doi.org/10.1590/1807-1929/agriambi.v18n11p1157-1164>

Saxena, S. (2024). Introdução ao Aprendizado Profundo. Recuperado em 7 de julho de 2024, de <https://www.geeksforgeeks.org/introduction-deep-learning/>

Sena, E. G. C., & Rocha, H. P. (2021). Implementação de Rede Neural Convolucional para Predição de COVID-19 Através de Imagens de Raio X. In *Proceedings of CBIC2021* (pp.15). doi:10.21528/CBIC2021-15

Sichman, J. S. (2021). Inteligência artificial e sociedade: avanços e riscos. Universidade de São Paulo, Escola Politécnica, Departamento de Engenharia de Computação e Sistemas Digitais. <https://doi.org/10.1590/s0103-4014.2021.35101.004>

Silva, M. S. L. (1995). Estudos da erosão. Ministério da Agricultura, do Abastecimento e da Reforma Agrária - MAARA, Empresa Brasileira de Pesquisa Agropecuária - EMBRAPA, Centro de Pesquisa Agropecuária do Trópico Semi-Árido - CPATSA, Coordenadoria de Transferência de Tecnologia Agropecuária - CTTA, Petrolina, PE.

Tziolas, N., Samarinas, N., Tsivlidis, I., & Zalidis, G. (2024, 13 de setembro). Evaluating the effectiveness of improved digital soil maps, generated through a hybrid CNN-XGBoost approach, for estimating soil loss due to water erosion. In *Proceedings of the Tenth International Conference on Remote Sensing and Geoinformation of the Environment (RSCy2024)* (Artigo No. 132120T). <https://doi.org/10.1117/12.3037235>

USDA Agricultural Research Service. (2008). Revised Universal Soil Loss Equation, Version 2 (RUSLE2). Washington, D.C.

Viana, G. (2018). Diferença entre Aprendizado de Máquina (Machine Learning) & Aprendizagem Profunda (Deep Learning). Medium. Recuperado de <https://medium.com/@gviana93/diferen%C3%A7a-entre-aprendizado-de-m%C3%A1quina-machine-learning-aprendizagem-profunda-deep-learning-3035e95ba1d1>

Vilela Junior, G. de B., Lima, B., Pereira, A. de A., Rodrigues, M. F., & outros. (2022). Métricas utilizadas para avaliar a eficiência de classificadores em algoritmos inteligentes. Centro de Pesquisas Avançadas em Qualidade de Vida, 14(2).

Wischmeier, W. H., & Smith, D. D. (1978). Predicting rainfall erosion losses: a guide to conservation planning. USDA Agricultural Handbook No. 537.

Anexos

Anexo 1: Mapa de base para o treinamento e validação dos modelos (Variável independente)




Figura 27. Simulação de dados históricos de erosão do solo (Variável independente).




Figura 26. Distribuição de pontos com valores extraídos das covariáveis (8000 pontos).

Anexo 2: Representação gráfica do VIF das covariáveis geoambientais dos distritos de Moatize e Sussundenga




Figura 28. Gráfico de Colinearidade dos factores considerados para o estudo com base ao VIF, distrito de Moatize.




Figura 29. Gráfico de Colinearidade dos factores considerados para o estudo com base ao VIF, distrito de Sussundenga.

Anexo 3: Representação da tabela CSV com valores de cada variável geoambiental

	A	B	C	D	E	F	G	H	I	J	K	L	M
1	system:js			Blue band (B2)	EVI	FMR	GD	green band (B3)	MRVBF	LSF	NDVI	NIR Band (B5)	PC
2	0 0	33.34403678744329	-19.895977564937134	8077.0	2.329925	0.745564	-0.19446	9031.0	1.949522	2.949522	0.34754	17981.0	12.29758
3	1 0	33.15673805070435	-19.437567275450938	8333.5	1.476902	0.799644	-0.25390	9649.0	1.1459317	3.864823	0.331305	18931.5	4.347446
4	3 0	33.29633624585654	-19.830759875310058	8647.0	1.867189	0.886721	-0.66899	9832.0	10.976755	11.976755	0.33093	19069.0	-35.3894
5	4 0	33.74827866529705	-19.8851977815277	9021.0	1.224041	0.862418	-1.661973	10531.0	4.2540536	5.254053	0.29747	19850.0	8.639773
6	6 0	33.20551657063206	-19.448077564275145	8185.5	2.066051	0.671642	2.427473	9453.5	-7.5367846	0.49754	0.391440	20701.5	8.547724
7	7 0	33.43701241934966	-19.753414929347365	8378.0	2.260518	0.837394	-1.711548	9279.0	0.09956646	1.049783	0.302264	16949.0	-2.616591
8	8 0	33.32759761774389	-19.8641772038793	8925.0	2.1141296	0.799403	-0.46591	9704.0	1.7055802	2.705580	0.32723	18789.0	-8.01304
9	9 0	33.163205920750016	-19.438645253791883	8526.0	2.042833	0.826864	0.205634	9377.5	11.769178	12.76917	0.310679	18003.5	28.60024
10	11 0	33.14299382685732	-19.44861655344561	7742.5	3.335814	0.678721	-1.805951	8465.5	23.067642	24.06764	0.368402	17351.0	-15.34123
11	13 0	33.16455339367619	-20.09809850386403	8802.0	1.255371	0.845851	11.733371	9909.0	2.6273675	2.313683	0.313739	19735.0	-13.72216
12	14 0	33.167248339528555	-20.167656807201157	8450.0	2.1593101	0.799834	-0.46268	9336.0	-0.2917409	0.902751	0.344754	18600.0	4.837144
13	16 0	33.13302252720359	-19.736167275892278	8288.0	1.467623	1.039921	-48.7856	9519.0	-0.26711607	0.946574	0.180130	13827.0	1.554025
14	17 0	33.59870917049116	-19.722962041215716	8240.0	2.306140	0.808204	1.333652	9287.5	-6.07259	0.132487	0.312664	17221.5	7.087704
15	18 0	33.590624332934084	-19.712182257806283	7985.5	2.175175	0.735641	0.357851	9349.0	1.485251	1.742625	0.359744	18728.5	-7.45328
16	21 0	33.670394730163906	-19.713799225317693	8473.0	1.679800	0.697894	4.423621	9467.5	2.6316595	1.526331	0.349471	19832.5	11.053164
17	22 0	33.1359869676412	-20.070340561584736	8346.0	2.245321	0.828815	1.108283	9401.0	6.1198993	7.119899	0.337842	18594.0	-12.91098

N	O	P	Q	R	S	T	U	V	W	X	Y
PFC	SAVI	TC	TX	TI	TPI	TRI	TVI	USC	YDCN	YMR	valor independente
473.3421	0.5213114	-0.27544951583	1.8149106	0.998675255536501	1.752068	1.7612611	-5.142234	-0.27544	169	1.71753619105166	1.8460798526224138
1287.409	0.496943	2.617413780432	20.48037	0.9638199625327418	-7.97520	15.33944	-15.75421	0.654353	796	15.968647586362604	113.79474867855022
1236.408	0.496396	-1.09774140994	17.03807	0.9782318698618534	11.79338	8.411728	-1.49477	-1.09774	243	27.702369846378797	158.119337479036
364.5588	0.446198	-0.99921301609	4.248882	0.995798451476666	0.214876	3.466505	-0.60169	-0.99921	129	2.9061491032363835	12.731786470341003
386.8947	0.587150	-1.20243277701	8.492402	0.991528456583929	3.190082	5.131750	6.179264	-0.08016	562	6.824240675047395	83.0746758814551
319.17618	0.453391	0.57921645085	2.504473	0.999328671022234	2.603308	1.431483	-1.168532	0.289608	211	2.4374335085563956	1.5931182077340456
847.5061	0.490843	6.23369549436	2.137446	0.998885282364014	-1.099173	1.4142135	-2.146291	6.233695	172	2.0046002982737177	1.1891191129789942
-0.0	0.466011	0.33796027215	25.69631	0.975268392687698	-6.115702	17.75915	4.862988	0.337960	772	12.92650281791848	242.73879033809908
6448.274	0.552592	0.38405884222	37.53060	0.913064636253294	-7.314041	22.99301	-0.55372	0.384058	1214	32.85060966342715	17.704942423165395
-0.0	0.470601	-2.2696768337	8.671142	0.996740457498472	8.206611	6.541572	0.170453	-1.134838	289	8.720428976358123	36.749268163470425
360.7141	0.517125	-7.9740270288	8.167338	0.998883074255790	5.826444	4.328353	-6.48421	-2.65800	316	8.754725683900231	22.43738322166908
669.4758	0.270190	59.6205783680	5.857737	0.996590195472947	-2.132231	5.095996	-0.102481	11.924115	1619	15.449757166031741	67.47625681140056
166.9337	0.468987	1.03899748470	2.240690	0.999869003782187	0.578512	1.575531	5.248748	0.148428	151	2.3338715182647918	0.0
1052.937	0.539613	-2.36061610685	2.497591	0.998150480434794	0.958677	1.5118578	5.588804	-1.180308	159	1.7674189898777317	10.139422801888466
1487.200	0.524197	-17.3448909712	4.769590	0.9911423089921265	1.900821	4.331533	1.130294	-3.46897	142	3.2788264378528447	37.08698861715985
747.7471	0.506754	-0.35893550314	11.799910	0.992288950276640	8.438016	6.290088	0.902296	-0.35893	247	11.360793949372692	28.744866176005797

Figura 30. Tabela CSV de valores correspondentes a cada variável geoambiental selecionada com base a multicolinearidade e a variável independente, distrito de Sussundenga.

1	system	x	y	EVI	Blue Band (B2)	FMR	GD	green b	LGC	LSF	NDVI	NIR band (B5)	PC	F
2	0_0	33.8708	-16.0484	0.82029	8799.0	1.07082	2.29901	9843.0	9.58529	10.58529	0.14684	14331.0	22.5932	2
3	1_0	34.0428	-15.9640	0.68082	8906.0	0.93337	4.21759	10140.0	0.33799	1.33799	0.22108	16586.0	0.57130	3
4	2_0	34.2948	-16.1357	0.60043	9037.0	1.03686	-1.31307	10262.0	7.50484	8.50484	0.15980	15190.0	27.7161	4
5	3_0	33.8994	-16.1599	0.97597	9171.0	0.78792	-1.55786	10489.0	-45.8585	0.04461	0.33667	21082.0	-5.1594	5
6	4_0	33.7159	-16.2575	0.78590	9022.0	0.92704	-1.74746	10264.0	-15.9094	0.11614	0.24070	18149.0	-6.5430	6
7	5_0	33.9064	-16.4774	0.76538	9177.0	1.01982	-3.43184	10357.0	-2.14566	0.46358	0.18560	16391.0	-3.2515	7
8	6_0	34.0606	-15.8826	0.81027	9227.0	1.18279	-0.10688	10027.0	0.03511	1.01170	0.14628	14191.0	-15.3136	8
9	7_0	34.0212	-16.1898	0.68024	9055.0	0.94939	0.81915	10157.0	-0.17209	0.95697	0.20761	16580.0	-6.9098	9
10	8_0	33.9388	-15.6331	0.91767	8851.0	0.97458	-47.264	10123.0	-125.124	0.05921	0.22977	16961.0	-22.0836	10
11	9_0	34.0447	-15.9532	0.50772	9223.0	0.86045	-0.5043	10255.0	1.67445	2.67445	0.23741	18302.0	-13.4595	11
12	10_0	34.0145	-15.6325	1.40264	8480.0	0.90200	7.07732	9466.0	-181.286	0.04081	0.23583	15807.0	-11.1902	12
13	11_0	34.0724	-15.9726	0.76316	9125.0	0.82029	-1.75005	10616.0	1.08992	2.08992	0.28332	18820.0	2.96344	13
14	12_0	34.3096	-16.2567	0.64673	9415.0	0.86396	0.24688	10509.0	2.38364	3.38364	0.26325	19245.0	-5.2344	14

PFC	SAVI	TC	TX	TI	TPI	TRI	TWI	USC	VDCN	VMR	valor independente	
2586.35	0.22026	0.68722	10.82613	0.98298	14.79338	7.73014	0.43496	0.68722	408	8.58815	1024426914	57.89221973035915
302.555	0.33162	0.64281	2.37608	0.99972	-0.12396	1.45428	0.23710	0.64281	414	3.65269	2403697763	6.1864839745630436
1420.09	0.23970	-0.62448	14.78604	0.98900	18.03305	11.31105	-0.76157	-0.62448	413	13.02946	2655631017	56.45767144481001
523.260	0.50500	2.08604	3.41915	0.99930	-4.75206	2.56899	-30.8114	0.04345	233	3.45814	6520780451	20.63643627011273
695.089	0.36104	-0.26588	2.35059	0.99933	-0.75206	2.42642	-10.3006	-0.01477	119	2.50304	4080784371	19.762172834362726
333.780	0.27840	-3.25157	2.37855	0.99947	0.24793	1.58685	-1.16555	-8.12894	138	1.94640	6070333041	5.274688808620073
873.434	0.21942	0.41611	2.96766	0.99859	1.42975	2.78943	-28.0686	0.13870	343	2.27667	2363335774	28.0942694222252
744.878	0.31142	-0.72403	3.21724	0.99776	2.32231	2.60729	4.88305	-0.18100	306	3.56073	5455641268	11.070414030394193
815.363	0.34465	-0.09300	5.77492	0.99056	0.14876	5.53637	-2.81393	-6.99252	298	7.75147	1344014761	255.84498014314659
604.760	0.35611	-1.24264	3.43980	0.99891	2.04958	2.43259	-1.98266	-1.24264	404	3.31098	3634283601	6.846093281710195
2135.622	0.35375	5.07110	8.42292	0.99095	-2.32231	8.08905	26.7050	0.02683	245	11.70861	6201850294	45.701618932902534
318.759	0.42498	-0.18005	2.14343	0.99933	-2.55371	2.08622	-0.57140	-0.18005	416	2.40320	2477221558	12.976174777125738
726.729	0.39487	1.73809	1.35305	0.99825	-0.76853	1.30356	4.05040	1.73809	272	1.66576	9665594330	1.8246630925036755

Figura 31. Tabela CSV de valores correspondentes a cada variável geoambiental selecionada com base a multicolinearidade e a variável independente, distrito de Moatize.