



UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E
DE COMPUTAÇÃO



Detecção de Processos Erosivos com Aprendizado de Máquina e a Aplicação da Equação Universal de Perda de Solo (USLE)

Wesley José dos Santos Marinho

Orientador: Prof. Dr. Pablo Javier Alsina

Dissertação de Mestrado apresentada ao
Programa de Pós-Graduação em Engenharia
Elétrica e de Computação da UFRN (área de
concentração: Engenharia de Computação)
como parte dos requisitos para obtenção do
título de Mestre em Ciências.

Natal, RN, Agosto de 2025

Universidade Federal do Rio Grande do Norte - UFRN
Sistema de Bibliotecas - SISBI
Catalogação de Publicação na Fonte. UFRN - Biblioteca Central Zila Mamede

Marinho, Wesley José Dos Santos.

Detecção de processos erosivos com aprendizado de máquina e a aplicação da Equação Universal de Perda de Solo (USLE) / Wesley José Dos Santos Marinho. - 2025.

107 f.: il.

Dissertação (mestrado) - Universidade Federal do Rio Grande do Norte, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica e de Computação, Natal, 2025.

Orientação: Prof. Dr. Pablo Javier Alsina.

1. Erosão do solo - Dissertação. 2. Aprendizado de máquina - Dissertação. 3. Equação Universal de Perda de Solo (USLE) - Dissertação. I. Alsina, Pablo Javier. II. Título.

RN/UF/BCZM

CDU 621

Elaborado por Jackeline dos Santos Pinheiro da Silva Maia
Cavalcanti - CRB-15/317

*Dedico esta tese de mestrado ao meu
cachorrinho Luigi que, em fevereiro
de 2025, se tornou uma linda
lembrança em meu coração. Você
nunca será esquecido meu amor.*

Agradecimentos

Ao meu orientador e a minha colega, professores Dr. Pablo Javier Alsina e Dr. Maria de Fátima Alves Matos, sou grato pela orientação.

À meu cachorrinho, Luigi, pela alegria e amor que trouxe a minha vida.

Aos demais colegas do SENAI ISI-ER pelas críticas e sugestões.

À meu marido, José Mahon, pelo apoio durante esta jornada.

À CAPES, pelo apoio financeiro.

Resumo

A tese de mestrado em questão explora a detecção de processos erosivos por meio de aprendizado de máquina e a aplicação da Equação Universal de Perda de Solo (USLE). O estudo tem como problema central a identificação e prevenção da erosão do solo, um problema ambiental significativo. Entre os principais objetivos estão a implementação de técnicas para detectar precocemente processos erosivos próximos a linhas de transmissão de energia, utilizando a USLE como um fator de validação adicional. A motivação do estudo é a mitigação de danos às redes de distribuição de energia provocados por processos erosivos e a busca por métodos eficazes de monitoramento e prevenção da erosão.

A metodologia adotada envolve o uso de algoritmos de aprendizado de máquina, especificamente Redes Neurais Convolucionais (CNN), para analisar imagens de satélite e identificar áreas sujeitas a processos erosivos. Além disso, a USLE é aplicada como ferramenta de cálculo da perda de solo, auxiliando na avaliação da probabilidade de ocorrência de erosão em determinados locais. As principais contribuições do estudo incluem a integração de tecnologias de aprendizado de máquina na detecção de processos erosivos e a validação dessas técnicas com a USLE, mostrando-se uma ferramenta eficaz nesse contexto.

Os resultados obtidos indicam a viabilidade e a precisão do uso de aprendizado de máquina na detecção de processos erosivos, bem como a importância da USLE como método auxiliar. As conclusões do estudo destacam a relevância da aplicação prática dessas técnicas para a preservação de linhas de transmissão de energia e um monitoramento mais eficiente de seus entornos. Futuras direções de pesquisa incluem a expansão do estudo para outras regiões e aprimoramentos na metodologia de detecção.

Palavras-chave: Erosão do solo, Aprendizado de máquina, Equação Universal de Perda de Solo (USLE), Rede Neural Convolucional (CNN), Unet, D-LinkNet, LinkNet

Abstract

The research in question investigates the detection of erosion processes through machine learning and the application of the Universal Soil Loss Equation (USLE). The primary issue addressed by the study is the identification and prevention of soil erosion, a significant environmental problem. Key objectives include implementing techniques to early detect erosion processes near power transmission lines, using the USLE as an additional validation factor. The motivation behind the study is to mitigate damage to power distribution networks caused by erosion and to seek effective methods for monitoring and preventing erosion.

The methodology involves using machine learning algorithms, specifically Convolutional Neural Networks (CNNs), to analyze satellite images and identify areas prone to erosion. Additionally, the USLE is applied as a tool for calculating soil loss, aiding in the assessment of the likelihood of erosion in specific locations. The main contributions of the study include integrating machine learning technologies in the detection of erosion processes and validating these techniques with the USLE, demonstrating its effectiveness in this context.

The results indicate the feasibility and accuracy of using machine learning for detecting erosion processes, as well as the importance of the USLE as an evaluation method. The study's conclusions highlight the relevance of the practical application of these techniques for the preservation of power transmission lines and more efficient monitoring of their surroundings. Future research directions include expanding the study to other regions and improving the detection methodology.

Keywords: Soil Erosion, Machine Learning, Universal Soil Loss Equation (USLE), Convolutional Neural Network (CNN), Unet, D-LinkNet, LinkNet

Sumário

Sumário	i
Lista de Figuras	iii
Lista de Tabelas	vii
Lista de Símbolos e Abreviaturas	ix
1 Introdução	1
1.1 Objetivos	2
1.2 Revisão bibliográfica	3
1.3 Publicações Relacionadas	7
1.4 Estrutura do texto	7
2 Aspectos Fundamentais de Processos Erosivos	9
2.1 Erosão do Solo	9
2.1.1 Origem dos Processos Erosivos	10
2.1.2 Tipos de erosão	11
3 Algoritmos de Aprendizado de Máquina	13
3.1 Rede Neural Convolucional	13
3.1.1 Camada de Entrada	14
3.1.2 Camada Convolucional	14
3.1.3 Camada de <i>Pooling</i>	14
3.1.4 Camada de Normalização	14
3.1.5 Camada de <i>Fully Conected</i>	14
3.1.6 Camada de Saída	15
3.1.7 Função de Ativação	15
3.1.8 Função de Perda	16
3.1.9 Validação	17
3.2 Unet	19
3.2.1 Caminho de Contração (Encoder)	19
3.2.2 Caminho de Expansão (Decoder)	19
3.3 LinkNet	20
3.3.1 D-LinkNet	21
3.4 Adequação ao Problema de Detecção de Processos Erosivos	23

4	Metodologia	25
4.1	Análise de Suscetibilidade de Erosão	25
4.1.1	Dados do Modelo USLE	25
4.2	Segmentação de Processos Erosivos em Imagens de Satélite	33
4.2.1	Dados do Modelo de Aprendizado de Máquina	33
4.2.2	Construção da Base de Dados	33
4.2.3	Aumento de Dados	35
4.2.4	Aprendizado por Transferência	36
4.2.5	K-fold e Validação Cruzada	37
4.2.6	Early Stopping	38
4.3	Treinamento do modelo de aprendizado de máquina	38
5	Resultados	43
5.1	USLE	43
5.1.1	Fatores de Suscetibilidade à Erosão	43
5.1.2	Mapa de Suscetibilidade à Erosão	46
5.2	Algoritmos de Aprendizado de Máquina	47
5.2.1	Curvas de Aprendizado	47
5.2.2	Métricas de Validação e Eficiência Computacional	51
5.2.3	Comparação Visual dos Resultados de Segmentação e Aplicação	
	no Mundo Real	53
5.2.4	Resultados K-fold	67
5.2.5	Matriz de Confusão	68
6	Conclusão	81
	Referências bibliográficas	82

Lista de Figuras

1.1	Diagrama de Transmissão e Distribuição de Energia.	1
1.2	Diagrama de Construção de Uma Linha de Transmissão de Energia e Problemas Relacionados.	2
1.3	Gráfico de publicações por ano com o tema "Soil Erosion".	4
1.4	Gráfico de publicações por país com o tema "Soil Erosion".	4
1.5	Gráfico de publicações por ano com o tema "USLE".	5
1.6	Gráfico de publicações por país com o tema "USLE".	6
1.7	Gráfico de publicações por ano com os temas "Soil Erosion" e CNN.	6
1.8	Gráfico de publicações por ano com os temas "Machine Learning".	7
2.1	Ilustração de um processo erosivo do solo, direção do fluxo da matéria em uma encosta.	10
3.1	Arquitetura clássica de uma rede neural convolucional.	13
3.2	Arquitetura U-net.	19
3.3	Arquitetura LinkNet.	20
3.4	Arquitetura D-LinkNet.	22
4.1	Fluxograma da equação de USLE. Fonte: Elaborado pelo autor (2023).	26
4.2	Mapa de distribuição das estações pluviométricas do estado de Minas Gerais. Fonte: Elaborado pelo autor (2023).	27
4.3	Mapa de Tipos de Solo do Estado de Minas Gerais Fonte: Elaborado pelo autor (2023).	28
4.4	Mapa de Elevação do Terreno do Estado de Minas Gerais Fonte: Elaborado pelo autor (2023).	30
4.5	Mapa de Uso do Solo do Estado de Minas Gerais Fonte: Elaborado pelo autor (2023).	31
4.6	Representação das cenas utilizadas para alimentar os modelos de aprendizado de máquina.	34
4.7	Exemplo de Como Foram Identificados os Processos Erosivos.	35
4.8	Exemplo de Segmentação de um Processo Erosivo.	35
4.9	Diagrama do Funcionamento da Metodologia K-Fold.	37
4.10	Diagrama das Etapas de Processamento de Dados e Treinamento de Modelos de Aprendizado de Máquina.	39
5.1	Mapa de suscetibilidade à erosão do fator R. Fonte: Elaborado pelo autor (2024).	43

5.2	Mapa de suscetibilidade à erosão do fator K. Fonte: Elaborado pelo autor (2024).	44
5.3	Mapa de suscetibilidade à erosão dos fatores L e S. Fonte: Elaborado pelo autor (2024).	45
5.4	Mapa de suscetibilidade à erosão dos fatores C e P. Fonte: Elaborado pelo autor (2024).	46
5.5	Mapa de suscetibilidade à erosão. Fonte: Elaborado pelo autor (2024).	47
5.6	Curva de acurácia e perda do modelo U-net em treinamento e em validação.	48
5.7	Curva de acurácia e perda do modelo LinkNet34 em treinamento e em validação.	48
5.8	Curva de acurácia e perda do modelo LinkNet50 em treinamento e em validação.	48
5.9	Curva de acurácia e perda do modelo LinkNet101 em treinamento e em validação.	49
5.10	Curva de acurácia e perda do modelo LinkNet152 em treinamento e em validação.	49
5.11	Curva de acurácia e perda do modelo LinkNetB7 em treinamento e em validação.	49
5.12	Curva de acurácia e perda do modelo DLinkNet34 em treinamento e em validação.	50
5.13	Curva de acurácia e perda do modelo DLinkNet50 em treinamento e em validação.	50
5.14	Curva de acurácia e perda do modelo DLinkNet101 em treinamento e em validação.	50
5.15	Curva de acurácia e perda do modelo DLinkNet152 em treinamento e em validação.	51
5.16	Curva de acurácia e perda do modelo DLinkNetB7 em treinamento e em validação.	51
5.17	Exemplo de imagem em época de chuva usada para validação das redes neurais.	54
5.18	Exemplo de imagem em época de seca usada para validação das redes neurais.	55
5.19	Segmentação de áreas afetadas por processos erosivos durante os períodos seco (primeira linha) e chuvoso (segunda linha) - Modelo U-Net.	56
5.20	Segmentação de áreas afetadas por processos erosivos durante os períodos seco (primeira linha) e chuvoso (segunda linha) - Modelo LinkNet34.	57
5.21	Segmentação de áreas afetadas por processos erosivos durante os períodos seco (primeira linha) e chuvoso (segunda linha) - Modelo LinkNet50.	58
5.22	Segmentação de áreas afetadas por processos erosivos durante os períodos seco (primeira linha) e chuvoso (segunda linha) - Modelo LinkNet101.	59
5.23	Segmentação de áreas afetadas por processos erosivos durante os períodos seco (primeira linha) e chuvoso (segunda linha) - Modelo LinkNet152.	60
5.24	Segmentação de áreas afetadas por processos erosivos durante os períodos seco (primeira linha) e chuvoso (segunda linha) - Modelo LinkNetB7.	61

5.25	Segmentação de áreas afetadas por processos erosivos durante os períodos seco (primeira linha) e chuvoso (segunda linha) - Modelo D-LinkNet34.	62
5.26	Segmentação de áreas afetadas por processos erosivos durante os períodos seco (primeira linha) e chuvoso (segunda linha) - Modelo D-LinkNet50.	63
5.27	Segmentação de áreas afetadas por processos erosivos durante os períodos seco (primeira linha) e chuvoso (segunda linha) - Modelo D-LinkNet101.	64
5.28	Segmentação de áreas afetadas por processos erosivos durante os períodos seco (primeira linha) e chuvoso (segunda linha) - Modelo D-LinkNet152.	65
5.29	Segmentação de áreas afetadas por processos erosivos durante os períodos seco (primeira linha) e chuvoso (segunda linha) - Modelo D-LinkNetB7.	66
5.30	Matriz de Confusão do Modelo Unet.	69
5.31	Matriz de Confusão do Modelo LinkNet34.	70
5.32	Matriz de Confusão do Modelo LinkNet50.	71
5.33	Matriz de Confusão do Modelo LinkNet101.	72
5.34	Matriz de Confusão do Modelo LinkNet152.	73
5.35	Matriz de Confusão do Modelo LinkNetB7.	74
5.36	Matriz de Confusão do Modelo D-LinkNet34.	75
5.37	Matriz de Confusão do Modelo D-LinkNet50.	76
5.38	Matriz de Confusão do Modelo D-LinkNet101.	77
5.39	Matriz de Confusão do Modelo D-LinkNet152.	78
5.40	Matriz de Confusão do Modelo D-LinkNetB7.	79

Lista de Tabelas

4.1	Tabela de valores para o fator K	29
4.2	Tabela de valores para os fatores C e P	32
5.1	Tabela de Classificação de Erodibilidade dos Fatores L e S	44
5.2	Tabela de Classificação de Erosão	46
5.3	Tabela de Métricas de Validação	52
5.4	Tabela de Tempo de Treinamento	52
5.5	Média das Métricas de Validação	67
5.6	Desvio Padrão das Métricas de Validação	68
5.7	Resultados de Acurácia Convencional e Acurácia Balanceada	69

Lista de Símbolos e Abreviaturas

ANEEL:	Agência Nacional de Energia Elétrica
C:	Uso e manejo do solo (parte do USLE)
CNN:	Convolutional Neural Networks
F1-score:	F1-Score, medida de avaliação de desempenho de classificação
FN:	Falso Negativo
FP:	Falso Positivo
IoU:	Interseção sobre União
K:	Erodibilidade do solo (parte do USLE)
L:	Fator topográfico (parte do USLE)
LT:	Linhas de Transmissão de Energia Elétrica
MDE:	Modelos Digitais de Elevação
P:	Práticas conservacionistas (parte do USLE)
R:	Erosividade da chuva (parte do USLE)
ReLU:	Rectified Linear Unit
S:	Fator topográfico (parte do USLE)
Scopus:	SciVerse Scopus
USLE:	Universal Soil Loss Equation
VN:	Verdadeiro Negativo
VP:	Verdadeiro Positivo

Capítulo 1

Introdução

A construção de linhas de transmissão de energia elétrica (LT) é fundamental para o desenvolvimento do Brasil, viabilizando a utilização de energia elétrica em todo o território nacional. Esse processo é ilustrado no diagrama de transmissão e distribuição de energia apresentado na figura 1.1. A implantação dessas infraestruturas traz impactos socioeconômicos positivos, como a geração de empregos e o estímulo a setores profissionais relacionados à engenharia, construção civil e cadeia de suprimentos de matérias-primas (Menezes 2015).




Figura 1.1: Diagrama de Transmissão e Distribuição de Energia.

No entanto, o processo de implantação das linhas de transmissão envolve desafios significativos, especialmente no que diz respeito aos impactos ambientais. Um dos problemas mais críticos é o surgimento ou aceleração de processos erosivos nas áreas próximas

às LT, que podem levar à degradação acelerada do solo e, conseqüentemente, comprometer a estabilidade e a segurança das infraestruturas energéticas. Esse fenômeno é ilustrado na figura 1.2, que destaca os problemas relacionados à construção de linhas de transmissão.




Figura 1.2: Diagrama de Construção de Uma Linha de Transmissão de Energia e Problemas Relacionados.

Dados da Agência Nacional de Energia Elétrica (ANEEL) (SFE/ANEEL 2024) revelam que, desde 2018, ocorreram aproximadamente 20 mil interrupções no fornecimento de energia causadas por processos erosivos em redes de transmissão e distribuição. Esses danos, quando não mitigados, podem se transformar em passivos ambientais irreversíveis, impactando negativamente os ecossistemas e a infraestrutura energética (Tobouti & dos Santos 2014).

Nesse contexto, os processos erosivos próximos às linhas de transmissão de energia emergem como um estudo de caso relevante para a aplicação de novas tecnologias e metodologias de monitoramento e prevenção. Métodos tradicionais de avaliação de erosão, como levantamentos de campo, são frequentemente custosos e de difícil escalabilidade. No entanto, avanços recentes em sensoriamento remoto e aprendizado de máquina, particularmente na segmentação de imagens, oferecem oportunidades promissoras para a automação da detecção e monitoramento de processos erosivos de forma mais precisa e eficiente, reduzindo custos e aumentando a eficácia das ações preventivas e corretivas.

1.1 Objetivos

No contexto descrito, o propósito desta dissertação de mestrado é reduzir os impactos atrelados a processos erosivos. Nesta dissertação, foram explorados o uso de três arquiteturas de redes neurais convolucionais (CNN), U-Net (Ronneberger et al. 2015), DLinkNet (Zhou et al. 2018) e LinkNet (Chaurasia & Culurciello 2017), para segmentar imagens de

modo a identificar de áreas afetadas por erosão. Como objetivo complementar, almejamos comparar o desempenho desses modelos na identificação de regiões erosivas, buscando a abordagem mais adequada para o monitoramento ambiental em larga escala. Aliado aos modelos de aprendizado de máquina, foi empregada uma abordagem baseada em sensoriamento remoto com o objetivo de estimar a probabilidade de uma determinada área desenvolver um processo erosivo.

A principal contribuição deste trabalho reside no desenvolvimento de uma abordagem híbrida, que combina a utilização de modelos de aprendizado de máquina (CNN) com fatores ambientais derivados de sensoriamento remoto. Tal abordagem busca minimizar o impacto de processos erosivos, especialmente em regiões que abrigam linhas de transmissão de energia.

Para atingir esse objetivo foram utilizados dados de precipitação, elevação do terreno, composição do solo, uso e ocupação do solo para o modelo de sensoriamento remoto e imagens de satélite para o modelo de aprendizado de máquina, abrangendo parte do estado de Minas Gerais.

1.2 Revisão bibliográfica

A pesquisa acadêmica sobre processos erosivos ao longo do século XX testemunhou um notável aumento, como indicado pela análise dos dados da base de dados Scopus. Esse interesse alcançou um ponto significativo em 1979, a partir do qual houve uma tendência constante de crescimento na produção de artigos relacionados ao tema. Esse crescimento atingiu seu ápice em 2023, com a notável publicação de 2.665 artigos, totalizando 38.918 desde o início da contagem em 1901 conforme mostrado na figura 1.3.

A liderança da China em termos de número de publicações sobre processos erosivos, com 10.279 artigos, seguida de perto pelos Estados Unidos, com 7.236, reflete a importância global atribuída a esse tema fundamental. Essa tendência ressalta a relevância dos estudos sobre erosão, especialmente em contextos de conservação ambiental e gestão de recursos naturais, onde a compreensão desses processos desempenha um papel crucial na sustentabilidade e preservação do meio ambiente conforme mostrado na figura 1.4.

Considerando o aumento do interesse nos processos erosivos ao longo dos anos, é lógico inferir que também existe um desejo crescente de combater esse fenômeno, que pode ser extremamente prejudicial à sociedade como um todo. Nesse sentido, observa-se uma curva ascendente no interesse acadêmico em pesquisar formas de prevenir a ocorrência de processos erosivos em determinadas áreas, na forma da USLE (Universal Soil Loss Equation).

Essa afirmação é apoiada pela análise da Figura 1.5, proveniente da base de dados da (Scopus 2024), na qual é evidenciado um aumento do interesse desde o ano de 2006. Destaca-se que, nesse período, os Estados Unidos da América lideraram em termos de interesse em pesquisar e publicar sobre o assunto, com 312 artigos publicados 1.6.

Dentre as pesquisas realizadas com enfoque em CNN, encontramos um registro total de 122.400 publicações desde o ano de 1995 (Scopus 2024). No entanto, ao direcionarmos nossa atenção para a interseção entre os temas CNN e Erosão do Solo, encontramos




Figura 1.3: Gráfico de publicações por ano com o tema "Soil Erosion".




Figura 1.4: Gráfico de publicações por país com o tema "Soil Erosion".

apenas 25 artigos publicados. Além disso, ao incluirmos a USLE, não há nenhum estudo que utilize as três temáticas.

Considerando o aumento do interesse nos processos erosivos, observa-se também uma curva ascendente na adoção de modelos empíricos, como a USLE (Universal Soil Loss Equation), para quantificação de perdas de solo.




Figura 1.5: Gráfico de publicações por ano com o tema “USLE”.

Embora a análise bibliométrica ofereça uma visão ampla da evolução dos estudos, é essencial compreender também as características técnicas dos métodos utilizados.

Segundo (Poesen 2018), métodos tradicionais, como parcelas de monitoramento e análises laboratoriais, são precisos, porém apresentam limitações de escala e custos elevados. Modelos empíricos, como a USLE e seus derivados (Wischmeier & Smith 1978) e (Renard 1997), são amplamente empregados, mas possuem limitações em relação à representação precisa dos processos físicos, especialmente em terrenos complexos.

Por outro lado, os modelos baseados em aprendizado profundo, como as CNNs, têm se mostrado promissores para detecção e segmentação de feições erosivas em imagens de satélite (Zhang et al. 2016) e (Ma et al. 2019). No entanto, ainda há desafios relacionados à necessidade de grandes volumes de dados rotulados, além da sensibilidade à qualidade das imagens.

Uma lacuna evidente na literatura é a ausência de estudos que integrem modelos físicos tradicionais (como a USLE) com métodos baseados em aprendizado profundo, o que poderia unir a robustez dos modelos empíricos com a capacidade preditiva das CNNs.




Figura 1.6: Gráfico de publicações por país com o tema “USLE”.




Figura 1.7: Gráfico de publicações por ano com os temas “Soil Erosion” e CNN.




Figura 1.8: Gráfico de publicações por ano com os temas “Machine Learning”.

1.3 Publicações Relacionadas

Atualmente, parte dos resultados obtidos neste trabalho foi consolidada e apresentada no artigo intitulado:

“Monitoramento da Erosão em Linhas de Transmissão no Brasil: Comparação de Redes Neurais para Segmentação Automatizada”, publicado nos anais do *Simpósio Brasileiro de Sensoriamento Remoto (SBSR) 2024* (Marinho et al. 2025).

Neste artigo, foi realizada uma análise comparativa do desempenho das arquiteturas de redes neurais convolucionais D-LinkNet e LinkNet na tarefa de segmentação de áreas afetadas por processos erosivos, especificamente no contexto de linhas de transmissão de energia no Brasil. A pesquisa discute a eficácia dessas redes na identificação de regiões sujeitas à degradação do solo, demonstrando o potencial do uso de aprendizado de máquina para o monitoramento ambiental em larga escala.

Os resultados obtidos nesta publicação servem como base parcial para a presente dissertação, fortalecendo a proposta metodológica e os achados científicos apresentados neste documento.

1.4 Estrutura do texto

Nesta dissertação, foram delineados dois capítulos introdutórios que estabelecem a base teórica a ser seguida no estudo. O Capítulo 2 concentra-se no fenômeno de erosão, abordando aspectos técnicos e técnicas utilizadas para estudar esse fenômeno. No Capí-

tulo 3 por sua vez, a atenção volta-se para as técnicas de aprendizado de máquina empregadas ao longo deste estudo. Estes capítulos são seguidos pelo Capítulo 4 que descreve em detalhes a metodologia adotada. Aqui, são apresentados os pormenores referentes à construção do conjunto de dados utilizado na pesquisa, o tratamento aplicado aos dados, os hiperparâmetros dos algoritmos utilizados e os procedimentos implementados para a análise dos resultados. Em seguida, é apresentado o Capítulo 5 contendo a exposição dos resultados obtidos ao longo da investigação. O Capítulo 6 se dedica às conclusões derivadas do estudo realizado, além de abordar potenciais desdobramentos e direções futuras que podem ser exploradas a partir desta pesquisa.

Capítulo 2

Aspectos Fundamentais de Processos Erosivos

2.1 Erosão do Solo

O entendimento adequado da formação e desenvolvimento de processos erosivos é alcançado por meio de análises das causas do problema e de estudos geológico-geotécnicos do fenômeno, esse conhecimento é então utilizado para determinar medidas de prevenção ou correção mais eficazes e econômicas. A erosão é influenciada por fatores externos, como a intensidade da chuva, as características de infiltração e escoamento da água, e a inclinação e extensão do terreno afetado, bem como por fatores internos, como a resistência do solo à erosão (Carvalho et al. 2006).

No campo geotécnico, há um interesse considerável no estudo das erosões causadas pela água, sendo categorizadas como ravinas (sem fluxo de água) e voçorocas (com fluxo de água) pela maioria dos especialistas (Mesquita 2019).

A formação e desenvolvimento de ravinas, voçorocas e erosões tipo anfiteatro, diversos fenômenos como erosão superficial, erosão subterrânea, colapso, deslizamento e instabilidade do terreno atuam de forma individual ou combinada, ocorrem também alterações nos solos devido aos fluxos tanto saturados quanto não saturados em direção aos taludes (Carvalho et al. 2006). Esse contexto torna desafiador compreender os mecanismos que regem o processo de erosão ao longo do tempo.

A figura [2.1](#), descreve o processo de escoamento superficial em resposta à precipitação em áreas sem vegetação (Horton 1945). Segundo esse modelo, o escoamento superficial ocorre quando a taxa de precipitação excede a capacidade de infiltração do solo, resultando em água fluindo sobre a superfície do terreno. Horton postulou que o escoamento superficial segue um padrão uniforme e previsível, onde a taxa de escoamento é proporcional à intensidade da chuva. Esse modelo simplificado foi fundamental para o entendimento inicial do comportamento do escoamento em áreas sem cobertura vegetal e influenciou o desenvolvimento de conceitos posteriores na hidrologia.




Figura 2.1: Ilustração de um processo erosivo do solo, direção do fluxo da matéria em uma encosta.

2.1.1 Origem dos Processos Erosivos

O termo erosão tem sua origem no latim (*erodere*) e significa "desgastar". Na área das Ciências da Terra, ele é usado para descrever os processos de desgaste da superfície terrestre (seja solo ou rocha) causados pela ação da água, do vento, do gelo e por organismos vivos (como plantas e animais), além das atividades humanas. Esses processos desempenham um papel na formação do relevo, trabalhando em conjunto com os processos de formação do solo (Viero 2004). Normalmente, sob condições naturais, esses dois processos se equilibram, com a quantidade de solo erodido sendo aproximadamente igual à quantidade produzida (Carvalho et al. 2006).

Quando esse equilíbrio é perturbado devido à intervenção humana e o solo não tem a chance de se recuperar naturalmente, ocorre a erosão acelerada ou erosão antrópica. Um exemplo moderno disso é a erosão causada pelas mudanças climáticas induzidas pelas atividades humanas, que não estão diretamente ligadas à ocupação ou uso do solo. No entanto, é importante ressaltar que a dinâmica dos processos erosivos está intrinsecamente ligada a fatores causais como clima e uso do solo, onde a influência de um sobre o outro reflete a complexidade desses fenômenos (Carvalho et al. 2006).

Muitos dos processos erosivos são resultado direto e previsível da intervenção humana no meio ambiente. Por exemplo, no meio rural, práticas como o manejo inadequado do solo, como a falta de cuidado com as curvas de nível ou o desmatamento das matas ciliares, contribuem para a erosão. Já no meio urbano, práticas como o excesso de impermeabilização da superfície, que aumenta o fluxo de água superficial, e o mau gerenciamento das águas pluviais também desempenham um papel significativo (Carvalho et al. 2006). Além disso, obras de engenharia, como barragens, linhas de transmissão e

estradas, podem causar problemas de erosão se não forem devidamente planejadas e mantidas, especialmente no que diz respeito ao controle das águas pluviais e ao cuidado das áreas de onde os materiais foram retirados.

2.1.2 Tipos de erosão

Existem duas categorias principais de erosão: a natural, também chamada geológica, e a erosão antrópica, que é acelerada devido à intervenção humana. Às vezes, o termo *erosão acelerada* é usado como sinônimo de erosão causada por atividades humanas, especialmente em relação ao fenômeno de ravinas e voçorocas. No entanto, essa visão negligencia o fato de que ravinas e voçorocas são características erosivas que existem em depósitos sedimentares antigos, presentes no Brasil e em outras regiões do mundo, datando de antes da chegada dos primeiros humanos à América do Sul (Viero 2004). No Brasil, geralmente, processos erosivos são desencadeados pela chuva e podem ser classificadas em erosão superficial; erosão interna e erosão linear (sulco, ravina, voçoroca), dependendo de seu estágio de evolução (Carvalho et al. 2006).

Erosão Superficial

A erosão superficial é o resultado do escoamento da água sobre o solo, que pode carregar consigo partículas devido ao impacto das gotas de chuva no solo. A inclinação do terreno desempenha um papel fundamental, influenciando a formação de filetes, sulcos e ravinas. Este fenômeno é comum em regiões tropicais e afeta tanto áreas rurais quanto urbanas, causando danos como perda de nutrientes, instabilidade das plantações e assoreamento de corpos d'água (Carvalho et al. 2006). Além dos fatores naturais, como cobertura do solo e declividade, a intervenção humana desempenha um papel significativo na intensificação da erosão, especialmente quando a preparação do solo não é adequada. A erodibilidade do solo varia de acordo com o grau de intemperismo, sendo maior em solos mais intemperizados (Viero 2004).

Erosão Interna

A erosão subterrânea, também conhecida como piping, é um processo em que a percolação de água remove partículas do solo, formando cavidades tubulares que avançam para o subsolo. Esse fenômeno pode resultar na formação de canais que se estendem a partir da encosta, enfraquecendo o solo e criando regiões de percolação preferencial, muitas vezes levando a afundamentos superficiais, conhecidos como subsidência (Avila Pimenta Filho 2013).

Erosão Linear

A erosão superficial pode evoluir em uma sequência que inclui erosão laminar, sulcos, ravinas e voçorocas, sendo esta última o estágio mais avançado e destrutivo. A classificação desses estágios pode variar, considerando critérios geométricos, geomecânicos e de fluxo. Sulcos são pequenos canais gerados pela concentração do escoamento superficial,

que podem evoluir para ravinas e, eventualmente, para voçorocas. Estas são caracterizadas por serem o estágio mais complexo da erosão, envolvendo diversos processos erosivos e sendo mais difícil de controlar e recuperar. Elas podem surgir tanto em ambientes urbanos quanto rurais, sendo influenciadas por fatores como desmatamento, alterações hidrológicas e geologia estrutural (Viero 2004).

Capítulo 3

Algoritmos de Aprendizado de Máquina

3.1 Rede Neural Convolucional

As redes neurais clássicas, especialmente as Convolutional Neural Networks (CNNs), são uma classe poderosa de modelos de aprendizado profundo amplamente empregados em tarefas de visão computacional e processamento de imagens (Li et al. 2021). Inspiradas na estrutura do cérebro humano, as CNNs são concebidas para extrair automaticamente características significativas das imagens de entrada, eliminando a necessidade de extração manual de recursos.

Essas redes são compostas por várias camadas, incluindo camadas de convolução, *pooling*, normalização, *fully connected* e de saída, ver figura 3.1, cada uma desempenhando um papel específico no processo de aprendizado e classificação. A capacidade das CNNs de aprender padrões complexos e hierárquicos nas imagens, combinada com características como conexões locais, compartilhamento de pesos e redução de dimensionalidade, as tornam extremamente eficazes em uma variedade de aplicações, desde reconhecimento de objetos e classificação de imagens até segmentação semântica e detecção de objetos (Li et al. 2021).




Figura 3.1: Arquitetura clássica de uma rede neural convolucional.

3.1.1 Camada de Entrada

A camada de entrada é a primeira camada de uma CNN e é responsável por receber os dados brutos de entrada, que geralmente são imagens no contexto de visão computacional. As imagens de entrada são representadas como tensores multidimensionais, onde cada dimensão corresponde a uma característica da imagem, como largura, altura e canais de cor. A camada de entrada não realiza nenhuma cálculo, apenas transmite os dados de entrada para a próxima camada da rede (Li et al. 2021).

3.1.2 Camada Convolutacional

A camada de convolução é a etapa que é incumbida de identificar atributos (features) nas imagens originais (Li et al. 2021). Durante essa etapa, são empregados filtros convolucionais na imagem inicial para detectar detalhes específicos, como contornos, texturas e formas. Cada filtro se move pela imagem, executando operações de multiplicação e soma para gerar um mapa de características. A utilização de diversos filtros convolucionais produz uma variedade de mapas, cada um capturando distintos elementos da imagem.

3.1.3 Camada de *Pooling*

A camada de *pooling* em uma CNN tem o papel de diminuir a dimensionalidade dos mapas de características gerados pelas camadas de convolução (Li et al. 2021). Diversas técnicas de *pooling* são empregadas, com o *max pooling* e o *average pooling* sendo os mais comuns. O *pooling* é executado em regiões locais dos mapas de características, onde cada região é simplificada para um único valor representativo. Esse processo ajuda a manter as características mais relevantes da imagem enquanto reduz o volume de dados a ser processado nas camadas subsequentes.

3.1.4 Camada de Normalização

A camada de normalização em uma CNN é responsável por regularizar e normalizar as ativações das camadas anteriores, a fim de acelerar o treinamento e melhorar a capacidade de generalização do modelo. Existem diferentes técnicas de normalização, como *Batch Normalization* e *Layer Normalization*, que podem ser aplicadas em diferentes pontos da arquitetura da rede (Li et al. 2021).

3.1.5 Camada de *Fully Connected*

A camada *fully connected*, também conhecida como camada densa, é responsável por realizar a classificação final com base nas características extraídas pelas camadas de convolução (Li et al. 2021). Nessa camada, todos os neurônios estão conectados a todos os neurônios da camada anterior, formando uma rede neural tradicional, ver figura 3.1. A camada *fully connected* combina as características aprendidas nas camadas anteriores para gerar uma saída que representa a classe ou categoria à qual a imagem pertence.

3.1.6 Camada de Saída

A última camada da CNN é a camada de saída, responsável por fornecer a saída final do modelo, geralmente uma distribuição de probabilidade entre as classes de saída. A função de ativação na camada de saída pode variar dependendo do problema, como softmax para classificação multiclasse ou sigmoid para classificação binária. Durante o treinamento, o resultado da camada de saída é comparada com os rótulos verdadeiros dos dados para calcular a perda e ajustar os pesos da rede usando um algoritmo de otimização (Li et al. 2021).

3.1.7 Função de Ativação

As funções de ativação desempenham um papel crucial nas redes neurais, incluindo as *Convolutional Neural Networks* (CNNs), ao introduzir não linearidades nas saídas das camadas, permitindo que a rede aprenda e represente relações complexas nos dados. Diferentes funções de ativação são utilizadas em diferentes partes da rede, como ReLU (*Rectified Linear Unit*), *Sigmoid*, *Tanh* e *Leaky ReLU*, cada uma com suas próprias características e benefícios (Li et al. 2021).

ReLU (*Rectified Linear Unit*) e *Leaky ReLU*

A função ReLU, uma das funções de ativação mais amplamente utilizadas devido à sua simplicidade e eficácia (Clevert et al. 2015), é fundamental para o aprendizado da rede. Ela mapeia todos os valores negativos para zero e mantém os valores positivos inalterados, introduzindo não linearidades essenciais, ver equação 3.1.

Leaky ReLU é uma variação do ReLU que permite um pequeno gradiente para valores negativos, ajudando a mitigar o problema de neurônios "mortos" que não ativam.

$$ReLU = \begin{cases} x & \text{quando } x > 0 \\ 0 & \text{quando } x \leq 0 \end{cases} \quad (3.1)$$

Sigmoid e Tanh

A equação 3.2, apresenta uma função de ativação sigmoide típica. Essa função serve como não-linearidade aplicada ponto a ponto a todas as unidades ocultas de uma DNN (*Deep Neural Network*). A ativação de uma única unidade oculta $h(i)$ é calculada por:

$$\phi = \frac{1}{1 + e^{-x}} \quad (3.2)$$

Na qual: A função sigmoide, representada por ϕ , é definida pela equação 3.2, onde x representa a entrada. Essa função mapeia qualquer valor real para o intervalo entre 0 e 1, sendo amplamente utilizada em redes neurais para modelar a ativação de neurônios. Onde a operação e^{-x} suaviza a curva de ativação, permitindo que valores menores de x resultem em saídas próximas de zero e valores maiores de x resultem em saídas próximas de 1.

A função de ativação Tangente Hiperbólica ($\tanh$) é semelhante à função Sigmóide, mas possui a característica de ser simétrica em relação à origem (Araújo 2019). Por esse motivo, seus valores variam no intervalo de -1 a 1. A função Tanh pode ser descrita matematicamente pelas equações 3.3 ou 3.4.

$$\tanh(x) = 2 \cdot \phi(2x) - 1 \quad (3.3)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.4)$$

Na qual: $\tanh(x)$ representa a função tangente hiperbólica, e representa a base do logaritmo natural, x é a variável de entrada da função e $\phi(2x)$ representa uma função sigmoide.

3.1.8 Função de Perda

Também chamada de função de custo, a função de perda, desempenha um papel crucial na avaliação do desempenho do modelo em uma tarefa específica (Li et al. 2021). Em problemas de classificação, essa função mede a discrepância entre as previsões do modelo e os rótulos reais dos dados de treinamento (Araújo 2019). Algumas das funções de perda comumente usadas são *Cross-Entropy* e *Binary Cross Entropy*.

Entropia Cruzada

Entropia cruzada, ou *Cross-entropy*, é uma medida da diferença entre duas distribuições de probabilidade, geralmente referindo-se à divergência entre a distribuição de probabilidade verdadeira e uma distribuição de probabilidade estimada ou prior (Shore & Johnson 1981). A definição matemática da *cross-entropy* entre duas densidades de probabilidade $q(x)$ e $p(x)$ é dada pela fórmula 3.5

É comumente utilizada em teoria da informação, estatística e aprendizado de máquina para avaliar o quão bem uma distribuição de probabilidade estimada se ajusta à distribuição verdadeira. Quanto menor a *cross-entropy*, mais próximas estão as duas distribuições.

$$H[q, p] = - \int q(x) \log \left(\frac{p(x)}{q(x)} \right) dx \quad (3.5)$$

Na qual: $q(x)$ representa a densidade de probabilidade posterior, $p(x)$ representa a estimativa prévia da densidade de probabilidade, $H[q, p]$ refere-se à *cross-entropy* entre as densidades $q(x)$ e $p(x)$, dx indica a integração em relação a x , $\log$ representa o logaritmo natural.

Entropia Cruzada Binária

A Entropia Cruzada Binária, ou *Binary Cross Entropy*, é uma função de perda comumente usada em problemas de classificação binária em machine learning. Durante o treinamento de uma rede neural, a função de perda é essencial para ajustar os pesos

da rede neural e criar um modelo de aprendizado de máquina melhor ajustado (Ho & Wookey 2019).

Especificamente, durante a propagação direta, a rede neural é executada nos dados do conjunto de treinamento e gera saídas que, no caso da classificação, indicam a probabilidade ou confiança em possíveis rótulos. Essas probabilidades são comparadas aos rótulos alvo, e a função de perda calcula uma penalidade para qualquer desvio entre o rótulo alvo e as saídas da rede neural.

$$J_{bce} = -\frac{1}{M} \sum_{m=1}^M [y_m \cdot \log(h\theta(x_m)) + (1 - y_m) \cdot \log(1 - h\theta(x_m))] \quad (3.6)$$

Na qual: M é o número de exemplos de treinamento, y_m representa o rótulo alvo para o exemplo de treinamento m , x_m simboliza a entrada para o exemplo de treinamento m e $h\theta$ é parametrizada pelos pesos da rede neural θ .

3.1.9 Validação

A natureza do problema impacta diretamente como o modelo de aprendizado de máquina criado para o solucionar será avaliado. Tendo isso em mente, a detecção de processos erosivos pode ser considerada como um problema binário, onde os pixels que contém o processo erosivo são considerados como verdade ou 1 e os demais pixels são considerados como falsos ou 0. Por tanto todos os resultados providos pelo modelo podem ser classificados em: verdadeiro positivo, verdadeiro negativo, falso positivo e falso negativo.

Verdadeiro positivo (VP) denota o número de pixels alvo que são classificados corretamente, verdadeiro negativo (VN) denota o número de pixels não alvo que são classificados corretamente, falso positivo (FP) é o número de pixels não alvo que são classificados como alvos falso negativo (FN) é o número de pixels alvo que são classificados como não alvos. Os testes se fundamentam em diversos critérios de avaliação: acurácia 3.7, recall 3.8, F1 score 3.9 e a métrica de Interseção sobre União (IoU) 3.10.

Nesse sentido, os classificadores foram submetidos a um conjunto de avaliações em contraposição à realidade objetiva, e as métricas de desempenho resultantes para cada um deles foram analisadas e registradas. A acurácia representa a proporção de elementos positivos corretamente identificados em relação a todos os elementos positivos previstos pelo classificador, enquanto a recall (também conhecida como completude) é a fração de elementos positivos corretamente identificados entre todos os elementos positivos verdadeiros. O F1 score é uma média ponderada da acurácia e do recall, levando em conta tanto os falsos positivos quanto os falsos negativos. Outra métrica relevante é a medida IoU, que representa a média da interseção das áreas previstas e verdadeiras sobre a união delas (Shrestha & Vanneschi 2018).

$$acuracia = \frac{VP}{VP + FP} \quad (3.7)$$

$$recall = \frac{VP}{VP + FN} \quad (3.8)$$

$$F1 = \frac{2 \cdot \textit{acuracia} \cdot \textit{recall}}{\textit{acuracia} + \textit{recall}} \quad (3.9)$$

$$IoU = \frac{\textit{acuracia} \cdot \textit{recall}}{\textit{acuracia} + \textit{recall} - \textit{acuracia} \cdot \textit{recall}} \quad (3.10)$$

3.2 Unet

A arquitetura de rede neural U-Net é especialmente projetada para segmentação de imagens biomédicas (Ronneberger et al. 2015). Ela consiste em uma estrutura em forma de U, conforme mostrado na Figura 3.2. Essa forma permite alcançar a localização precisa e segmentação eficiente de imagens biomédicas, sendo capaz de treinar com sucesso em conjuntos de dados limitados e superar métodos anteriores em desafios de segmentação. A arquitetura consiste em um caminho de contração (esquerda) e um caminho de expansão (direita).




Figura 3.2: Arquitetura U-net.

No exemplo da figura 3.2, com o dado entrada nas dimensões 32x32 pixels na resolução mais baixa, cada caixa verde corresponde ao mapa de recursos multicanal, número de canais é expresso acima das caixas, as dimensões x-y estão na borda inferior esquerda da caixa, as caixas brancas representam as features copiadas e as setas indicam diferentes operações.

3.2.1 Caminho de Contração (Encoder)

O caminho de contração segue a arquitetura típica de uma rede convolucional, consistindo na aplicação repetida de duas convoluções 3x3 (convoluções não preenchidas), seguidas por uma unidade linear retificada (ReLU) e a etapa 2 de uma operação de pooling máximo 2x2 para redução da resolução. Em cada etapa de redução da resolução, o número de canais de recursos é duplicado.

3.2.2 Caminho de Expansão (Decoder)

Cada etapa no caminho de expansão consiste em uma operação de aumento da resolução do mapa de recursos, seguida por uma convolução 2x2 ("convolução ascendente")

que reduz pela metade o número de canais de recursos, concatenação com o mapa de recursos recortado correspondente do caminho de contração e duas convoluções 3×3 , cada seguido por um ReLU. Como os pixels das bordas são perdidos em cada convolução, é necessário cortar e, na última camada, uma convolução 1×1 é usada para mapear cada vetor de recursos de 64 componentes para o número necessário de classes.

3.3 LinkNet

A arquitetura do modelo LinkNet, ilustrada na Figura 3.3, é baseada em uma estrutura codificador-decodificador e utiliza camadas convolucionais para processar os dados. No diagrama, "conv" representa uma camada convolucional, enquanto "full-conv" indica uma convolução completa. A notação $/2$ refere-se a uma redução na resolução por um fator de 2, obtida por meio de convoluções com passo maior, enquanto $*2$ indica um aumento na resolução, também por um fator de 2. Cada camada convolucional é seguida por normalização em lote e ativação ReLU, tornando a arquitetura eficiente e modular.




Figura 3.3: Arquitetura LinkNet.

A rede é dividida em duas partes principais: o codificador, responsável por extrair características, e o decodificador, que reconstrói a saída. O codificador inicia com um bloco que aplica uma convolução na imagem de entrada utilizando um kernel de 7×7 e passo 2, seguido de uma operação de max-pooling em uma região de 3×3 com passo 2.

Após essa etapa inicial, são utilizados blocos residuais, indicados como *encoder-block(i)* (Chaurasia & Culurciello 2017).


Uma característica fundamental do LinkNet é o uso de conexões diretas entre as saídas de cada camada do codificador e as entradas correspondentes do decodificador. Essas conexões permitem recuperar informações espaciais perdidas durante o processo de redução de resolução, o que melhora a precisão das operações de aumento de amostragem no decodificador. Além disso, ao compartilhar o conhecimento aprendido em cada camada, o decodificador opera de forma eficiente, com menos parâmetros, o que torna a arquitetura leve e eficaz (Chaurasia & Culurciello 2017).

3.3.1 D-LinkNet

D-LinkNet é uma rede neural de segmentação semântica projetada para a extração de estradas em imagens de satélite de alta resolução. A arquitetura da rede é baseada na estrutura codificador-decodificador e utiliza camadas de convolução dilatada e um codificador pré-treinado. A rede é construída com base na arquitetura LinkNet e possui camadas de convolução dilatada em sua parte central. A arquitetura LinkNet é eficiente em termos de computação e memória, enquanto a convolução dilatada é uma ferramenta poderosa que pode aumentar o campo receptivo dos pontos de características sem reduzir a resolução dos mapas de características (Zhou et al. 2018).

Na arquitetura da D-LinkNet, representada na Figura 3.4, o bloco retangular azul simboliza um mapa de características de vários canais. A Parte A corresponde ao codificador do D-LinkNet, que utiliza a ResNet34 como base. A Parte C, por sua vez, é o decodificador do D-LinkNet, configurado de maneira semelhante ao decodificador do LinkNet original.

Enquanto o LinkNet original possui apenas as Partes A e C, o D-LinkNet inclui uma Parte B adicional. Esta parte extra aplica uma técnica chamada de convolução dilatada, que consiste em aumentar o campo receptivo dos pontos de feature sem reduzir a resolução dos mapas de features. No D-LinkNet, a convolução dilatada é aplicada na parte central da rede, permitindo a agregação de features em múltiplas escalas. Essa abordagem ajuda a preservar informações espaciais detalhadas enquanto expande o campo receptivo, sendo especialmente útil para tarefas como a extração de estradas em imagens de satélite, onde a conectividade e a longa extensão das estradas são características críticas. (Zhou et al. 2018)



3.4 Adequação ao Problema de Detecção de Processos Erosivos

No contexto específico da detecção de processos erosivos em imagens de satélite, as características visuais mais relevantes são a variação de cor e textura na superfície do solo, que frequentemente se manifestam como padrões heterogêneos e contrastantes em relação às áreas não afetadas. As arquiteturas de redes neurais convolucionais discutidas (CNN clássica, U-Net, LinkNet e D-LinkNet) mostram-se particularmente adequadas para esta tarefa devido às suas capacidades intrínsecas de extração e processamento desses atributos visuais.

As CNNs tradicionais, com suas camadas de convolução e *pooling* hierárquicas, são eficazes na captura de padrões locais de textura e gradientes de cor, características fundamentais para identificar áreas de erosão. No entanto, para problemas de segmentação pixel a pixel como o proposto, as arquiteturas em forma de U (U-Net e suas variações) apresentam vantagens significativas. Sua estrutura codificador-decodificador com conexões residuais permite: (1) a preservação de informações espaciais de alta resolução durante o processo de *downsampling* (essencial para manter a precisão na delimitação de áreas erosivas) e (2) a combinação eficiente de features de baixo nível (cor, textura) com informações contextuais de alto nível.

Particularmente, a D-LinkNet se destaca pelo uso estratégico de convoluções dilatadas na Parte B de sua arquitetura (Figura 3.4), que amplia o campo receptivo sem perder resolução espacial, uma característica importante para detectar padrões erosivos que podem se estender por grandes áreas enquanto mantém detalhes finos de textura. Esta abordagem multiescala é especialmente relevante para processos erosivos, que frequentemente apresentam tanto micro-padrões de textura quanto macro-estruturas morfológicas discerníveis.

A escolha das funções de ativação ReLU/Leaky ReLU (Equação 3.1) também se justifica pela necessidade de modelar adequadamente as não-linearidades presentes nas assinaturas espectrais de solos degradados, enquanto a função de perda Binary Cross-Entropy (Equação 3.6) é particularmente adequada para este problema de classificação binária (erosão vs. não-erosão), onde o desbalanceamento entre classes é comum.

Capítulo 4

Metodologia

4.1 Análise de Suscetibilidade de Erosão

Para prevenir a erosão e minimizar suas consequências, é importante entender os processos erosivos, sejam naturais ou causados pelo homem. Estes processos são condicionados por fatores geológicos, geomorfológicos e pedológicos, que determinam a suscetibilidade do solo à erosão. A avaliação geológico-geotécnica, baseada em perfis típicos de solos tropicais, é essencial para prever e prevenir a erosão, fornecendo informações úteis para o planejamento ambiental e a preservação dos recursos naturais (Freitas 2016). Essa avaliação considera a suscetibilidade do terreno a diferentes processos físicos, como erosão, deslizamentos e assoreamento, sendo fundamental para determinar a viabilidade de empreendimentos e a conservação do meio ambiente (Carvalho et al. 2006).

Nesse contexto, podem ser empregados diversos modelos de geoprocessamento distintos. Em sua maioria, os modelos derivam de uma mesma fonte: a Equação Universal de Perda de Solo (USLE, da sigla em inglês *Universal Soil Loss Equation*). Devido a ser o modelo mais clássico e amplamente utilizado, optou-se por sua utilização.

A equação de USLE foi desenvolvida por uma parceria entre a *Agricultural Research Service* e a Universidade de Purdue por (Wischmeier & Smith 1978), nos Estados Unidos. Essa equação representa um avanço em relação a equações anteriores relacionadas à perda de solo, resultando da combinação da análise estatística de dados de perda de solo e água. A USLE é composta por seis fatores, sendo eles:

R - Erosividade da chuva: Refere-se à capacidade da chuva de transportar sedimentos.

K - Erodibilidade do solo: Indica a suscetibilidade do solo à erosão.

L e S - Fatores topográficos: Avalia o impacto do relevo na erosão.

C - Uso e manejo do solo: Descreve como o solo é utilizado e gerenciado.

P - Práticas conservacionistas: Engloba as estratégias empregadas para reduzir a erosão.

4.1.1 Dados do Modelo USLE

Para a elaboração do mapa de suscetibilidade de erosão, adotou-se uma abordagem que integra dados matriciais e vetoriais de diversas fontes. Além disso, foi realizada uma

revisão extensiva da literatura para obter valores específicos dos fatores K, C e P, essenciais para técnica de USLE, mas que não puderam ser diretamente calculados inicialmente. Uma representação da estrutura da equação pode ser vista na figura 4.1.

Essa abordagem permitiu uma análise mais abrangente da suscetibilidade à erosão, combinando dados empíricos com conhecimento teórico, resultando em uma representação dos padrões de erosão em uma determinada área.

A integração de diferentes tipos de dados e a consulta à literatura especializada possibilitaram não apenas preencher lacunas no cálculo dos fatores essenciais, mas também enriquecer o contexto científico subjacente ao desenvolvimento do modelo. Esse método proporcionou uma base sólida para a avaliação da suscetibilidade à erosão, considerando variáveis climáticas, aspectos ambientais e geológicos relevantes. Assim, o dado resultante não apenas reflete uma visão detalhada da distribuição potencial da erosão, mas também serve como uma ferramenta útil para corroborar a base de dados utilizada para treinar o modelo de aprendizado de máquina.




Figura 4.1: Fluxograma da equação de USLE. Fonte: Elaborado pelo autor (2023).

Fator de Erosividade da Chuva (R)

Para determinar os valores de erosividade da chuva, foram analisados dados coletados ao longo de 41 anos (de 1981 a 2022) (Xavier et al. 2022). Utilizando 66 pontos de coleta pluviométricos como referência (figura 4.2), o objetivo foi abranger uma vasta área do estado de Minas Gerais. Dessa maneira, foi possível calcular as médias mensais e anuais.

A erosividade média mensal para cada um dos pontos de coleta foi determinada com base nas equações 4.1 e 4.2 (Lombardi Neto & Moldenhauer 1992). Posteriormente realizando a espacialização da erosividade utilizando o algoritmo Inverso do Quadrado da

Distância, assim possibilitando a cartografia da erosividade da chuva em toda a área de estudo e gerando um mapeamento espacial dos valores do fator R.

$$El_{30} = 67,355 \cdot \left(\frac{p^2}{P} \right)^{0,85} \quad (4.1)$$

$$R = \sum_{j=1}^{12} El_{30j} \quad (4.2)$$

Na qual: p é a média total mensal de precipitação (mm), P é a média total anual de precipitação e El30 é a média mensal do índice de erosividade ($\text{MJ m ha}^{-1} \text{ h}^{-1}$)




Figura 4.2: Mapa de distribuição das estações pluviométricas do estado de Minas Gerais. Fonte: Elaborado pelo autor (2023).

Fator de Erodibilidade do Solo (K)

A erodibilidade do solo é representada pelo fator K, que expressa a relação entre a intensidade da erosão e a erosividade das chuvas específicas para um solo desprovido de cobertura contínua (Florenzano 2007), e revelando a susceptibilidade do solo à erosão e sua capacidade de resistir a esse processo (Oliveira Carvalho & de Oliveira Carvalho 2008).

O tipo e a intensidade da erosão são variáveis que dependem das características individuais dos solos. Consequentemente cada tipo de solo possui seu próprio fator K que é influenciado por uma gama de atributos como a textura do solo, o conteúdo de matéria orgânica, sua estrutura e permeabilidade (Resende 1985). Para determinar o fator K foram consolidados dados de diversas pesquisas realizadas em solos brasileiros, tabela 4.1,

que compartilham características pedológicas semelhantes àsquelas encontradas na área de estudo, figura 4.3.




Figura 4.3: Mapa de Tipos de Solo do Estado de Minas Gerais Fonte: Elaborado pelo autor (2023).

Tabela 4.1: Tabela de valores para o fator K

Tipo de Solo	Fator K	Referência
Cambissolo Háplico	0,0263	(Oliveira 2019)
Gleissolo Háplico	0,0355	(Oliveira 2019)
Gleissolo Melânico	0,0355	(Oliveira 2019)
Latossolo Vermelho	0,0263	(Oliveira 2019)
Latossolo Vermelho-Amarelo	0,0237	(Oliveira 2019)
Neossolo Flúvico	0,025	(Oliveira 2019)
Nitossolo Háplico	0,0197	(Oliveira 2019)
Neossolo Litólico	0,11	(Segedi 2019)
Plintossolo Pétrico	0,057	(Segedi 2019)
Latossolo Amarelo	0,0179	(Batista 2022)
Chernossolo Argilúvico	0,0292	(Sousa Moraes & Silva 2020)
Plintossolo Argilúvico	0,0622	(Sousa Moraes & Silva 2020)
Vertissolo Ebânico	0,0138	(Sousa Moraes & Silva 2020)
Argissolo Amarelo	0,0547	(Souza et al. 2019)
Argissolo Vermelho	0,046	(Souza et al. 2019)
Argissolo Vermelho-Amarelo	0,0547	(Souza et al. 2019)
Planossolo Nátrico	0,0219	(Basin et al. 2022)
Neossolo Quartzarênico	0,045	(Barbosa et al. 2015)
Nitossolo Vermelho	0,018	(Barbosa et al. 2015)
Luvissolo Crômico	0,0459	(Francisco et al. 2023)
Planossolo Háplico	0,0543	(Francisco et al. 2023)
Cambissolo Húmico	0,0175	(Schick et al. 2014)
Corpo d'água continental	0	(Guedes et al. 2022)

Fatores Comprimento do Declive (L) e Grau do Declive (S)

Os valores associados a L e S podem ser obtidos diretamente através de medições de campo ou deduzidos a partir de dados topográficos, como curvas de nível ou Modelos Digitais de Elevação (MDE) (Renard 1997). Para a determinação destes fatores, foram adotadas as equações 4.3, 4.4 e 4.5 (Foster et al. 1977). Os cálculos foram executados de maneira a conduzir os valores associados a cada pixel no arquivo de origem, figura 4.4, por meio de todas as equações (Hawker et al. 2022).




Figura 4.4: Mapa de Elevação do Terreno do Estado de Minas Gerais Fonte: Elaborado pelo autor (2023).

$$\beta_{ij} = \frac{\text{sen}(\theta \cdot 0.01745)}{(3 \cdot \text{sen}(\theta)^{0.8} + 0.56)} \quad (4.3)$$

Na qual: θ é o ângulo de declividade em graus e β é a razão entre a erosão por sulco (causada pelo fluxo) e a erosão entre sulcos (causada principalmente pelo impacto das gotas de chuva)

$$m_{ij} = \frac{\beta}{(1 + \beta)} \quad (4.4)$$

Na qual: m é o coeficiente função da declividade para a grade de célula com coordenada (i,j)

$$L_{ij} = \frac{\left((A_{ij} + D)^{m+1} - (A_{ij})^{m+1}\right)}{X_{ij}^m \cdot (D^{m+2}) \cdot 22,13^m} \quad (4.5)$$

Na qual: L é o fator de comprimento de vertente de uma célula com coordenadas (i,j), A é a área de contribuição da célula em coordenadas (i,j) (m²), D é o tamanho da célula em metros, X é o coeficiente função do aspecto para grade de célula em coordenada (i,j) e m é o coeficiente função da declividade para a grade de célula com coordenada (i,j)

$$S_{ij} = \begin{cases} 10,8 \cdot \text{sen}\theta + 0,3, & \text{quando declividade} < 9 \\ 16,8 \cdot \text{sen}\theta - 0,5, & \text{quando declividade} \geq 9 \end{cases} \quad (4.6)$$

Na qual: θ é o ângulo de declividade.

Fator Cobertura e Manejo (C) e Prática Conservacionista (P)

O fator C avalia os impactos do uso e conservação da terra nos níveis de erosão do solo 4.5. Sua relação está intrinsecamente ligada ao uso da terra e à presença da cobertura vegetal na região estudada. Por outro lado, o fator de prática conservacionista, P, quantifica a relação entre a perda de solo em áreas que adotam medidas de conservação em comparação com aquelas que não implementam essas práticas (Wischmeier & Smith 1978). Para obter esses fatores, foram utilizados valores disponíveis na literatura, conforme indicado na tabela 4.2 e na figura 4.5.




Figura 4.5: Mapa de Uso do Solo do Estado de Minas Gerais Fonte: Elaborado pelo autor (2023).

Tabela 4.2: Tabela de valores para os fatores C e P

Uso do solo	Fator C e P	Referência
Citrus	0,135	(Vázquez Fernández et al. 1996)
Algodão	0,4737	(Vázquez Fernández et al. 1996)
Área urbanizada	0,0075	(Thompson & Fidalgo 2013)
Afloramento rochoso	0,01	(Thompson & Fidalgo 2013)
Outras formações não florestais	0,25	(Oliveira 2019)
Mosaico de usos	0,25	(Oliveira 2019)
Praia, duna e areal	0,25	(Oliveira 2019)
Mineração	0,25	(Oliveira 2019)
Formação savânica	0,0223	(Batista 2022)
Campo alagado e área pantanosa	0,0001	(Batista 2022)
Cana	0,05	(Batista 2022)
Outras áreas não vegetadas	0,801	(Batista 2022)
Soja	0,2	(Batista 2022)
Café	0,2	(Batista 2022)
Outras lavouras temporais	0,05	(Souza et al. 2019)
Outras lavouras perenes	0,05	(Souza et al. 2019)
Formação florestal	0,00004	(Guedes et al. 2022)
Silvicultura	0,0001	(Guedes et al. 2022)
Formação campestre	0,01	(Guedes et al. 2022)
Pastagem	0,18	(Guedes et al. 2022)
Rio, lago e oceano	0	(Guedes et al. 2022)

4.2 Segmentação de Processos Erosivos em Imagens de Satélite

Para desenvolver modelos preditivos capazes de identificar e quantificar processos erosivos com precisão, é necessário combinar dados geoespaciais, técnicas computacionais e metodologias de validação. A crescente disponibilidade de imagens de satélite, como as do Sentinel-2, oferece oportunidades para analisar variações morfológicas e espectrais do terreno em diferentes escalas temporais e espaciais.

Nesse cenário, técnicas como aprendizado por transferência permitem aproveitar conhecimentos adquiridos em domínios correlatos, reduzindo a dependência de grandes volumes de dados rotulados e acelerando o treinamento de modelos a contextos específicos (Zhuang et al. 2020). Paralelamente, métodos de validação cruzada e *early stopping* garantem que os resultados sejam estatisticamente significativos e menos suscetíveis a superajuste, enquanto o aumento artificial de dados amplia a diversidade do conjunto de treinamento, simulando condições variáveis de iluminação, orientação e textura do solo. Essas abordagens, integradas a arquiteturas de redes neurais profundas como as baseadas em *ResNet* e *EfficientNet*, permitem extrair padrões sutis associados à erosão.

4.2.1 Dados do Modelo de Aprendizado de Máquina

Para o treinamento dos modelos de inteligência artificial, foram utilizadas imagens do Sentinel-2, obtidas pelo Google Earth Engine (Engine 2024). O Sentinel-2 consiste em dois satélites idênticos em órbita sincronizada com o Sol a uma altitude média de 786 km, com revisita a cada cinco dias no equador. Cada satélite possui um Instrumento Multiespectral (MSI) que coleta dados em 13 bandas espectrais com resoluções espaciais de 10, 20 e 60 metros. As imagens são processadas com correções geométricas e ortorretificação, podendo ser ajustadas para refletância no fundo da atmosfera (BOA) e classificação básica de pixels, como identificação de tipos de nuvens. Esses dados são amplamente utilizados no monitoramento de terras, gestão agrícola, controle de desastres, ajuda humanitária e mapeamento de riscos (Agency 2024).

Nesta dissertação, as imagens foram obtidas pelo Copernicus Open Access Hub, garantindo acesso gratuito a dados atualizados e históricos. As cenas selecionadas passaram por pré-processamentos, como correção atmosférica e remoção de nuvens, utilizando o Sentinel-2 Toolbox (S2TBX) da Agência Espacial Europeia (ESA). Optamos por uma resolução espacial de 10 metros, que permitiu analisar detalhadamente o solo e a vegetação, além de facilitar a identificação e marcação manual dos processos erosivos visíveis nas imagens. Foram utilizadas 18 cenas do Sentinel-2, cobrindo áreas de 18 x 18 km, capturadas entre 2021 e 2023, ver imagem 4.6. Essas imagens possibilitaram observar variações espaciais e temporais, auxiliando na anotação dos processos erosivos na área de estudo.

4.2.2 Construção da Base de Dados

Para a construção da base de dados destinada ao treinamento dos modelos de aprendizado de máquina, adotou-se uma abordagem multimodal que integra interpretação visual




Figura 4.6: Representação das cenas utilizadas para alimentar os modelos de aprendizado de máquina.

4.2. SEGMENTAÇÃO DE PROCESSOS EROSIVOS EM IMAGENS DE SATÉLITE35

e modelagem geoespacial. O processo centralizou-se na análise de imagens de satélite, onde as feições erosivas foram inicialmente identificadas através do mapa de suscetibilidade à erosão e de inspeção visual apoiada pelo plugin *Polygon by clicking in map image* do *QGIS*, ver Figura 4.7).




Figura 4.7: Exemplo de Como Foram Identificados os Processos Erosivos.

O plugin utiliza técnicas de agrupamento espectral para identificar e agrupar pixels homogêneos, delimitando assim as feições de interesse. Conforme ilustrado na Figura 4.8, um polígono é gerado ao redor do agrupamento de pixels, o qual posteriormente se transforma em uma máscara que será então utilizada no treinamento dos modelos de aprendizado de máquina.




Figura 4.8: Exemplo de Segmentação de um Processo Erosivo.

4.2.3 Aumento de Dados

O Aumento de Dados (*Data Augmentation*) é fundamental para instruir a rede sobre as propriedades desejadas de invariância e robustez, especialmente em situações em que há escassez de amostras de treinamento (Ronneberger et al. 2015). Dessa forma, introduzir

deformações elásticas aleatórias nas amostras de treinamento é a chave para treinar uma rede de segmentação com um número limitado de imagens anotadas, ver pseudo código 1. Das 18 cenas utilizadas, foram extraídas 757 imagens anotadas com processos erosivos. Dessas, 6 imagens foram reservadas para validação, 226 para teste e 525 para treinamento. Em seguida, as imagens de treinamento passaram por um processo de aumento de dados, no qual foram aplicadas deformações e rotações, resultando na geração de 6.300 imagens de treinamento.

Algoritmo 1: Aumento dos dados de treinamento

Input : Dados de treinamento (*images_training*, *labels_training*), Parâmetros de rotação (*rotations*), espelhamento (*flips*), deslocamento (*shifts*), tamanho de redimensionamento (*training_resize*)

Output: Dados de treinamento aumentados (*images_augmented*, *labels_augmented*)

```

1 Inicializar images_augmented e labels_augmented com o tamanho adequado;
2 for cada imagem e rótulo em images_training, labels_training do
3   for cada rotação em rotations do
4     Aplicar rotação à imagem e ao rótulo;
5     for cada espelhamento em flips do
6       Aplicar espelhamento à imagem e ao rótulo rotacionados;
7       for cada deslocamento em shifts do
8         Aplicar deslocamento à imagem e ao rótulo espelhados;
9         Armazenar imagem e rótulo aumentados em images_augmented e labels_augmented;
10      end
11    end
12  end
13 end
14 Permutar aleatoriamente os dados em images_augmented e labels_augmented;
15 return images_augmented, labels_augmented;

```

4.2.4 Aprendizado por Transferência

Aprendizado por transferência é uma técnica de aprendizado de máquina que melhora o desempenho de um modelo em uma tarefa específica ao utilizar conhecimentos adquiridos em uma tarefa relacionada, porém distinta. Em vez de treinar um modelo do zero com grandes quantidades de dados rotulados—o que pode ser caro e demorado—o aprendizado por transferência permite que os modelos adaptem conhecimentos de um domínio de origem, onde há abundância de dados, para um domínio-alvo com dados limitados. Essa abordagem é especialmente útil em cenários onde a coleta de dados rotulados é impraticável, como em imagens médicas, bioinformática e análise de transporte (Zhuang et al. 2020).

Existem diversas estratégias para implementar o aprendizado por transferência, incluindo ponderação de instâncias, transformação de características, compartilhamento de parâmetros e combinação de modelos. Esses métodos ajudam a ajustar diferenças na distribuição dos dados, criar novas representações de características ou ajustar modelos pré-treinados para melhorar o desempenho. Embora o aprendizado por transferência ofereça vantagens significativas, desafios como transferência negativa, interpretabilidade e questões de privacidade ainda são áreas de pesquisa ativa. Com a evolução desse campo, enfrentar esses desafios será essencial para liberar todo o seu potencial em diversas indústrias (Zhou et al. 2018).

4.2. SEGMENTAÇÃO DE PROCESSOS EROSIVOS EM IMAGENS DE SATÉLITE37

Com base no conceito de aprendizado por transferência, foram utilizados pesos pré-treinados e uma base composta por cinco modelos diferentes de *Deep Residual Learning for Image Recognition*: ResNet34, ResNet50, ResNet101, ResNet152 e EfficientNet B7.

4.2.5 K-fold e Validação Cruzada

O *k-fold cross-validation* (validação cruzada k-fold) é uma técnica amplamente utilizada para avaliar o desempenho de modelos de machine *learning* de maneira mais robusta, evitando problemas como o *overfitting*, que ocorre quando um modelo se ajusta excessivamente aos dados de treinamento e perde a capacidade de generalizar para novos dados. Essa abordagem é especialmente útil quando se trabalha com conjuntos de dados limitados, pois permite aproveitar ao máximo as informações disponíveis (Gorritz et al. 2024).

A ideia central do *k-fold* é dividir o conjunto de dados em k partes iguais, chamadas de "**folds**". Em seguida, o modelo é treinado e validado k vezes, alternando a parte dos dados usada para validação em cada iteração. Em cada uma dessas iterações, $k - 1$ *folds* são utilizados para treinar o modelo, enquanto o *fold* restante é usado para validação conforme ilustrado na Figura 4.9. Esse processo é repetido até que cada *fold* tenha sido usado exatamente uma vez como conjunto de validação. Ao final, o desempenho do modelo é calculado como a média das pontuações obtidas em cada iteração (Wong 2015).




Figura 4.9: Diagrama do Funcionamento da Metodologia K-Fold.

Uma das principais vantagens do *k-fold* é que ele não desperdiça dados, já que todos os exemplos são usados tanto para treinamento quanto para validação, embora em momentos

diferentes. Isso contrasta com a abordagem tradicional de dividir os dados em conjuntos de treinamento e validação fixos, o que pode reduzir a quantidade de dados disponíveis para treinamento e tornar a avaliação do modelo dependente de uma divisão específica. Além disso, o *k-fold* é particularmente útil para ajustar hiperparâmetros, pois permite testar diferentes configurações do modelo sem que haja vazamento de informações do conjunto de teste para o treinamento (Gorriz et al. 2024).

4.2.6 Early Stopping

Early Stopping é uma técnica usada no treinamento de modelos de aprendizado de máquina, principalmente em redes neurais, para evitar *overfitting*. Esse fenômeno ocorre quando o modelo se adapta excessivamente aos dados de treinamento, capturando não só padrões relevantes, mas também ruídos, comprometendo sua generalização para novos dados.

O *early stopping* oferece diversos benefícios, sendo o principal deles a prevenção do *overfitting*. Ao interromper o treinamento antes que o modelo comece a se sobreajustar aos dados de treinamento, essa técnica ajuda a melhorar a generalização do modelo para dados não vistos. Além disso, o *early stopping* promove uma economia de tempo e recursos computacionais, pois evita que o treinamento continue desnecessariamente após atingir um ponto ótimo. Outra vantagem é a simplicidade de implementação, já que a técnica não requer alterações complexas no modelo ou no processo de treinamento. Por fim, ao evitar o *overfitting*, o *early stopping* contribui para a estabilidade e confiabilidade do modelo, resultando em desempenho mais consistente em diferentes cenários (Bai et al. 2021).

O funcionamento do *early stopping* é baseado em um processo de monitoramento e decisão. Durante o treinamento, o desempenho do modelo no conjunto de validação é monitorado, geralmente por meio de métricas como precisão ou perda (*loss*). Um critério de parada é definido, como a falta de melhoria na métrica de desempenho por um número específico de épocas consecutivas (conhecido como "paciência" ou "*patience*"). Quando esse critério é atingido, o treinamento é interrompido, e os parâmetros do modelo que apresentaram o melhor desempenho no conjunto de validação são retidos como o modelo final (Bai et al. 2021).

4.3 Treinamento do modelo de aprendizado de máquina

O processo de treinamento de uma rede neural pode ser descrito por uma sequência estruturada de etapas, que abrange desde a preparação dos dados até a avaliação do desempenho do modelo. Esse fluxo é detalhado no pseudocódigo apresentado na Figura 4.10 e seu treinamento no Algoritmo 2.

Para poder treinar e poder fazer uma comparação quantitativa entre os modelos de CNN, foram utilizados os seguintes parâmetro de configuração:

Batch Size Foi definido como 4 para otimizar o uso eficiente dos recursos computacionais e manter um fluxo de dados estável durante o treinamento.

Taxa de Aprendizado Foi ajustada para $2e-4$ para controlar a taxa de atualização dos pesos do modelo e evitar *overfitting* durante o treinamento.

Épocas Foi definido para 100 épocas de treinamento, permitiu-se que o modelo aprendesse gradualmente.

Função de Ativação escolhida foi ReLU para introduzir não-linearidade nas camadas ocultas da rede, permitindo a modelagem de relações complexas nos dados.

Função de Perda Foi utilizada a DCBOLoss como função de perda, essa função é baseada em *Binary Cross Entropy*.

K-fold A base de dados foi dividida em 5 partes, onde cada parte foi usada para teste uma vez, enquanto as outras 4 foram usadas para treino.

Early Stopping Foi utilizado um limite de 15 épocas de espera. Isso significa que, a partir do primeiro momento em que as métricas de validação deixarem de apresentar melhora, o treinamento continuará por mais 15 épocas. Caso não haja progresso nesse período, o treinamento será interrompido.




Figura 4.10: Diagrama das Etapas de Processamento de Dados e Treinamento de Modelos de Aprendizado de Máquina.

Algoritmo 2: Algoritmo de Treinamento do Modelo

Input : Modelo (model), Gerador de Treinamento (training_generator), Gerador de Validação (validation_generator), Função de Perda (loss_func), Taxa de Aprendizado (learning_rate), Número de Épocas (epochs), Validação do Modelo (model_validation), Disponibilidade de CUDA (cuda_available), Caminho para Salvar o Modelo (path_model), Paciência para Early Stopping (patience)

Output: Histórico de Métricas de Treinamento e Validação

```

1 Inicializar optimizer e scheduler com calc_scheduler(model, learning_rate);
2 Inicializar listas para armazenar histórico de métricas de treinamento e validação
3 Inicializar best_val_loss com infinito e best_iou_vall com 0;
4 Inicializar patience_counter com 0;
5 for cada época em epochs do
6     Colocar o modelo em modo de treinamento (model.train());
7     Inicializar loss_training e accuracy_training com 0;
8     Inicializar cont com 0;
9     for cada batch em training_generator do
10         if cuda_available then
11             Transferir inputs e labels para a GPU;
12         end
13         Zerar os gradientes do otimizador (optimizer.zero_grad());
14         Calcular as saídas do modelo (outputs = model(inputs));
15         Calcular a perda (loss = loss_func(outputs, labels));
16         Realizar backpropagation (loss.backward());
17         Atualizar os pesos (optimizer.step());
18         Atualizar loss_training e accuracy_training;
19         Calcular e armazenar métricas como F1-score, IoU, Recall e Matriz de Confusão;
20     end
21     Calcular accuracy_training_final e loss_training_final;
22     Armazenar métricas de treinamento nas listas correspondentes;
23     if model_validation then
24         Colocar o modelo em modo de avaliação (model.eval());
25         Inicializar loss_validation e accuracy_validation com 0;
26         Inicializar cont1 com 0;
27         for cada batch em validation_generator do
28             if cuda_available then
29                 Transferir inputs e labels para a GPU;
30             end
31             Calcular as saídas do modelo (outputs = model(inputs));
32             Calcular a perda (loss_validation += loss_func(outputs, labels));
33             Atualizar accuracy_validation;
34             Calcular e armazenar métricas como F1-score, IoU, Recall e Matriz de Confusão;
35         end
36         Calcular loss_validation_final;
37         Armazenar métricas de validação nas listas correspondentes;
38     end
39     Atualizar o scheduler (scheduler.step());
40     if condição de early stopping satisfeita then
41         Parar o treinamento;
42     end
43 end
44 return Histórico de métricas de treinamento e validação;

```

O treinamento de um modelo de aprendizado profundo passa por várias etapas organizadas, com o objetivo de ajustar os parâmetros do modelo para que ele consiga realizar a tarefa proposta. O processo começa com a configuração do modelo, incluindo o otimizador e o scheduler, além das métricas de desempenho, como perda, precisão, F1-score e IoU, que serão registradas durante o treinamento. A cada época, o modelo é colocado no modo de treinamento e os dados são processados em lotes. Para cada lote, a perda é calculada e os gradientes são propagados para ajustar os parâmetros do modelo, com a ajuda do otimizador. Durante esse processo, as métricas de treinamento são calculadas e armazenadas, o que permite acompanhar o progresso.

Ao final de cada época, o modelo é avaliado com o conjunto de validação. Nesse momento, as métricas de perda e precisão são calculadas da mesma forma que no treinamento, mas sem a atualização dos parâmetros. Outras métricas, como o F1-score e IoU, também são registradas para análise posterior. O scheduler ajusta a taxa de aprendizado conforme o treinamento avança, buscando melhorar a eficiência da aprendizagem. Além disso, pode ser ativado um mecanismo de **early stopping**, que interrompe o treinamento se não houver melhoria nas métricas de validação após um número definido de épocas. Ao final, o histórico das métricas é retornado, fornecendo uma visão clara do desempenho do modelo durante todo o processo.

Capítulo 5

Resultados

5.1 USLE

5.1.1 Fatores de Suscetibilidade à Erosão

A erosividade das chuvas em Minas Gerais, calculada por meio da interpolação dos índices anuais médios de erosividade EI30 de cada estação, conforme apresentado na figura 4.2, pode ser visualizada no mapa de erosividade (R) 5.1. Nesse mapa, os valores máximos e mínimos para a área de estudo são 9.576,63 e 4.892,16 MJ mm ha-1 h-1 ano-1, respectivamente. Esses valores estão próximos dos valores estimados para a erosividade anual média do estado de Minas Gerais, que varia de 5.000 a mais de 12.000 MJ mm ha-1 ano-1 (Pereira & others 2014).




Figura 5.1: Mapa de suscetibilidade à erosão do fator R. Fonte: Elaborado pelo autor (2024).

Conforme mostra a Tabela 4.1, os valores de erodibilidade K na área de estudo va-

riam de 0 a 0,11 (mm ha⁻¹ h⁻¹ ano⁻¹), refletindo os tipos de solo presentes na região. Com base nesses dados, foi elaborado o Mapa 5.2, que permite analisar as características de erodibilidade dos solos no estado de Minas Gerais. A análise dos pixels do mapa indica que 42,26% da área corresponde ao valor de K de 0,026, caracterizando solos como Cambissolo Háptico ou Latossolo Vermelho, os quais apresentam um nível mediano de erodibilidade.




Figura 5.2: Mapa de suscetibilidade à erosão do fator K. Fonte: Elaborado pelo autor (2024).

Para avaliar o impacto dos fatores de declividade, L e S, foi analisada a distribuição das classes de inclinação conforme a classificação apresentada na Tabela 5.1 (Guedes et al. 2022). A partir da Tabela 5.1 e da Figura 5.3, observa-se que a classe de relevo Plano predomina, abrangendo aproximadamente 95,66% da área total do estado, enquanto cerca de 2,91% da área é classificada como fortemente ondulada.

Tabela 5.1: Tabela de Classificação de Erodibilidade dos Fatores L e S

Classificação	Classe	Porcentagem
Plano	0-3	95,66%
Suave	3-8	0,05%
Ondulado	8-20	0,43%
Forte Ondulado	20-45	2,91%
Montanhoso	45-75	0,88%
Escarpado	>75	0,07%




Figura 5.3: Mapa de suscetibilidade à erosão dos fatores L e S. Fonte: Elaborado pelo autor (2024).

Na figura 5.4, pode-se observar o resultado da integração e espacialização dos valores de cobertura, manejo e práticas conservacionistas (CP), obtida de acordo com a classificação apresentada na tabela 4.2, com valores que variam entre 0 e 0,801. Ao contar os pixels no mapa, foi identificado que 30,13% possuem valor igual a 0,18, o que, segundo a tabela 5.4, indica que essa área corresponde a pastagem.




Figura 5.4: Mapa de suscetibilidade à erosão dos fatores C e P. Fonte: Elaborado pelo autor (2024).

5.1.2 Mapa de Suscetibilidade à Erosão

O estudo realizado resultou na criação de um mapa de suscetibilidade à erosão, com resoluções espaciais de 30 metros por pixel. Levando em conta todos os fatores utilizados no cálculo da fórmula de USLE, o potencial de perda de solo variou entre o mínimo de 0,000002 e o máximo de 118.110,94 toneladas por hectare por ano. Para facilitar a visualização os dados passaram por uma reclassificação (Guedes et al. 2022), de acordo com a tabela 5.2, resultando no mapa da figura 5.5.

Tabela 5.2: Tabela de Classificação de Erosão

Classificação	Classe	Área (%)
Nenhuma ou Ligeira	0-1	21,52%
Ligeira	1-10	27,38%
Moderada	10-20	21,26%
Moderada a alta	20-50	18,40%
Alta	50-200	9,20%
Muito Alta	>200	2,24%

A classificação das categorias de suscetibilidade à erosão é apresentada de forma onde é possível notar que a classificação dos valores está predominantemente situada entre 1 e 10 (abrangendo 27,38% do mapa) e indicando um risco ligeiro de desenvolver um processo erosivo. A segunda classe mais predominante é a que indica uma chance nenhuma

ou ligeira de desenvolver um processo erosivo cobrindo 21,52% do mapa, assim é possível inferir que o estado de Minas Gerais tem um nível mediano de suscetibilidade à erosão.

O mapa de suscetibilidade à erosão desempenhou um papel de grande importância na elaboração das máscaras de treinamento utilizadas pelos modelos de rede neural. Esse recurso permitiu direcionar nossos esforços para a análise de áreas com maior probabilidade de ocorrência de processos erosivos, ao mesmo tempo que possibilitou desconsiderar regiões de baixa suscetibilidade. Dessa forma, evitou-se a busca aleatória por áreas potencialmente sujeitas a erosão no estado de Minas Gerais, facilitando a identificação mais precisa de locais com processos erosivos ativos.




Figura 5.5: Mapa de suscetibilidade à erosão. Fonte: Elaborado pelo autor (2024).

5.2 Algoritmos de Aprendizado de Máquina

5.2.1 Curvas de Aprendizado

Para obter uma compreensão mais detalhada do comportamento de treinamento dos modelos de aprendizado de máquina, foram geradas curvas de perda e precisão ao longo das épocas de treinamento. Essas curvas oferecem uma visão clara de como cada modelo evoluiu durante o processo de aprendizado e permitem uma avaliação crítica de sua capacidade de convergência e generalização.

As figuras 5.6, 5.7, 5.8, 5.9, 5.10, 5.11, 5.12, 5.13, 5.14, 5.15 e 5.16 apresentam, no gráfico à direita as curvas de perda e a esquerda as curvas de acurácia dos modelos durante seu treinamento e validação. As das curvas de aprendizagem dos modelos se demonstraram um progresso estável além de não apresentar sinais de overfitting, sugerindo que todos os modelos generalizaram adequadamente para os dados de validação, mantendo um equilíbrio entre capacidade de aprendizado e adaptação a novos dados.




Figura 5.6: Curva de acurácia e perda do modelo U-net em treinamento e em validação.




Figura 5.7: Curva de acurácia e perda do modelo LinkNet34 em treinamento e em validação.




Figura 5.8: Curva de acurácia e perda do modelo LinkNet50 em treinamento e em validação.




Figura 5.9: Curva de acurácia e perda do modelo LinkNet101 em treinamento e em validação.




Figura 5.10: Curva de acurácia e perda do modelo LinkNet152 em treinamento e em validação.




Figura 5.11: Curva de acurácia e perda do modelo LinkNetB7 em treinamento e em validação.




Figura 5.12: Curva de acurácia e perda do modelo DLinkNet34 em treinamento e em validação.




Figura 5.13: Curva de acurácia e perda do modelo DLinkNet50 em treinamento e em validação.




Figura 5.14: Curva de acurácia e perda do modelo DLinkNet101 em treinamento e em validação.




Figura 5.15: Curva de acurácia e perda do modelo DLinkNet152 em treinamento e em validação.




Figura 5.16: Curva de acurácia e perda do modelo DLinkNetB7 em treinamento e em validação.

5.2.2 Métricas de Validação e Eficiência Computacional

O desempenho de todos os modelos, foi avaliado utilizando três métricas principais: precisão, F1-score e Interseção sobre União (IoU). Essas métricas fornecem uma visão abrangente de quão bem os modelos detectam erosão no conjunto de validação. A Tabela 5.3 apresenta uma comparação detalhada desses indicadores de desempenho para ambos os modelos.

Primeiramente, observa-se que todas as redes apresentaram um desempenho semelhante nas métricas de acurácia e F1-Score, com todas as redes alcançando valores próximos de 0,99, o que sugere que as redes são bastante eficazes em realizar classificações corretas, acertando quase todas as previsões.

Em relação ao IoU, os modelos que atingiram o maior score foram LinkNet101, LinkNet-B7 e D-LinkNetB7. As três redes neurais possuem um F1-score de 0,76. Em relação ao IoU, os modelos que atingiram o maior score foram LinkNet101, LinkNet-B7 e D-LinkNetB7. As três redes neurais possuem um F1-score de 0,76 o que pode indicar que, apesar de todas as redes apresentarem alta acurácia, esses três modelos sejam os mais indicados, sugerindo um equilíbrio mais eficaz entre falsos positivos e falsos negativos.

As redes D-LinkNet apresentaram, em média, resultados ligeiramente inferiores, o que pode indicar que essas variações da rede, embora mantenham alta acurácia, possuem desempenho mais baixo na detecção e classificação correta de exemplos das classes menos representadas.

O tempo de treinamento de cada modelo também foi registrado para avaliar a efici-

Tabela 5.3: Tabela de Métricas de Validação

Rede Neural	Acurácia	F1-score	IoU
Unet	0,98	0,98	0,57
LinkNet34	0,99	0,99	0,70
LinkNet50	0,99	0,99	0,75
LinkNet101	0,99	0,99	0,76
LinkNet152	0,98	0,98	0,58
LinkNetB7	0,99	0,99	0,76
D-LinkNet34	0,98	0,98	0,69
D-LinkNet50	0,99	0,99	0,74
D-LinkNet101	0,99	0,99	0,76
D-LinkNet152	0,98	0,98	0,57
D-LinkNetB7	0,99	0,99	0,76

ência computacional das redes neurais. Essa métrica é utilizada para entender o custo de processamento de cada arquitetura e a quantidade de tempo necessária para alcançar um bom desempenho. A Tabela 5.4 apresenta os tempos de treinamento de cada rede, permitindo uma comparação direta entre elas em termos de eficiência computacional.

Tabela 5.4: Tabela de Tempo de Treinamento

Rede Neural	Tempo de Treinamento
Unet	06:50:58
LinkNet34	04:10:07
LinkNet50	06:36:42
LinkNet101	05:09:56
LinkNet152	05:04:17
LinkNetB7	04:23:43
D-LinkNet34	04:02:37
D-LinkNet50	05:39:23
D-LinkNet101	07:44:42
D-LinkNet152	07:07:28
D-LinkNetB7	06:05:52

Analisando as tabelas 5.3 e 5.4, podemos observar que não existe uma relação direta entre o desempenho das redes neurais, expresso pelas métricas de validação, e o tempo de treinamento necessário para cada uma delas.

Primeiramente, é importante observar que as redes que apresentaram os melhores desempenhos em termos de métricas também registraram, em média, uma diferença de uma hora no tempo necessário para concluir seus treinamentos. Dentre elas, o modelo Link-

NetB7 foi o mais rápido, finalizando o treinamento em apenas 4 horas e 23 minutos.

Por sua vez, o desempenho da arquitetura Unet, apesar de sua ampla utilização em tarefas de segmentação, mostrou-se inferior em termos de IoU em comparação com as demais redes mais modernas. Isso reforça a ideia de que arquiteturas mais recentes, como as variações da LinkNet e D-LinkNet, mesmo que mais complexas, tendem a oferecer resultados mais robustos em contextos que exigem maior refinamento na detecção de bordas e áreas de interesse.

Por fim, cabe destacar que modelos como o LinkNet34 e D-LinkNet34, apresentaram tempos de treinamento significativamente menores que os demais, ainda mantendo resultados satisfatórios, o que os torna opções viáveis em contextos com restrições computacionais mais severas. Portanto, a escolha do modelo ideal dependerá não apenas do desempenho métrico, mas também das exigências práticas de cada aplicação, como tempo disponível para treinamento, capacidade de hardware e necessidade de precisão na segmentação.

5.2.3 Comparação Visual dos Resultados de Segmentação e Aplicação no Mundo Real

Para corroborar os dados apresentados pela tabela 5.3 foi feita uma análise qualitativa por meio da comparação direta entre as máscaras previstas pelos modelos e as máscaras de referência (ground truth), permitindo identificar acertos, erros e padrões recorrentes nas predições. Além disso, são comparadas visualmente as segmentações geradas para imagens capturadas em períodos de seca e de chuva. Foram utilizadas as imagens 5.17 e 5.18 para exemplificar o processo de segmentação, e essa análise visa observar a robustez dos modelos frente às variações climáticas e de textura no terreno, avaliando a consistência e a fidelidade da segmentação em contextos reais e desafiadores.

As imagens 5.19, 5.20, 5.21, 5.22, 5.23, 5.24, 5.25, 5.26, 5.27, 5.28 e 5.29 apresentam comparações entre máscaras de segmentação geradas pelas redes neurais e as máscaras de referência (groundtruth), aplicadas a cenas de satélite em duas épocas distintas: seca e chuvosa.

De maneira geral, observa-se que as redes neurais testadas foram capazes de identificar corretamente as principais regiões indicadas no *ground truth*, embora apresentem falhas em alguns pontos — com variações no desempenho entre os diferentes modelos. Ao analisarmos as segmentações das imagens que representam áreas afetadas por processos erosivos em períodos de vegetação mais verde, percebe-se que os modelos delimitam melhor as bordas. Por outro lado, existe uma maior dificuldade na segmentação durante épocas em que a vegetação se encontra mais seca.



Figura 5.17: Exemplo de imagem em época de chuva usada para validação das redes neurais.



Figura 5.18: Exemplo de imagem em época de seca usada para validação das redes neurais.




Figura 5.19: Segmentação de áreas afetadas por processos erosivos durante os períodos seco (primeira linha) e chuvoso (segunda linha) - Modelo U-Net.




Figura 5.20: Segmentação de áreas afetadas por processos erosivos durante os períodos seco (primeira linha) e chuvoso (segunda linha) - Modelo LinkNet34.




Figura 5.21: Segmentação de áreas afetadas por processos erosivos durante os períodos seco (primeira linha) e chuvoso (segunda linha) - Modelo LinkNet50,




Figura 5.22: Segmentação de áreas afetadas por processos erosivos durante os períodos seco (primeira linha) e chuvoso (segunda linha) - Modelo LinkNet101.




Figura 5.23: Segmentação de áreas afetadas por processos erosivos durante os períodos seco (primeira linha) e chuvoso (segunda linha) - Modelo LinkNet152.




Figura 5.24: Segmentação de áreas afetadas por processos erosivos durante os períodos seco (primeira linha) e chuvoso (segunda linha) - Modelo LinkNetB7.




Figura 5.25: Segmentação de áreas afetadas por processos erosivos durante os períodos seco (primeira linha) e chuvoso (segunda linha) - Modelo D-LinkNet34.




Figura 5.26: Segmentação de áreas afetadas por processos erosivos durante os períodos seco (primeira linha) e chuvoso (segunda linha) - Modelo D-LinkNet50,




Figura 5.27: Segmentação de áreas afetadas por processos erosivos durante os períodos seco (primeira linha) e chuvoso (segunda linha) - Modelo D-LinkNet101.




Figura 5.28: Segmentação de áreas afetadas por processos erosivos durante os períodos seco (primeira linha) e chuvoso (segunda linha) - Modelo D-LinkNet152.




Figura 5.29: Segmentação de áreas afetadas por processos erosivos durante os períodos seco (primeira linha) e chuvoso (segunda linha) - Modelo D-LinkNetB7.

5.2.4 Resultados K-fold

As Tabelas 5.5 e 5.6 apresentam, respectivamente, as médias e os desvios padrão das métricas obtidas ao longo das validações. De modo geral, os resultados indicam uma performance consistente e elevada entre os diferentes modelos avaliados.

Avaliando as médias, observa-se que os modelos da família D-LinkNet e LinkNet com backbones mais profundos, como LinkNet101 e D-LinkNetB7, obtiveram os melhores resultados em termos de acurácia (acima de 0,992), F1-score (acima de 0,991), e IoU (em torno de 0,73). Por outro lado, modelos como Unet, LinkNet152 e D-LinkNet152 apresentaram valores de IoU mais baixos (próximos de 0,52), o que pode indicar uma menor capacidade de delimitação precisa das regiões segmentadas, apesar de manterem bons valores de acurácia e recall. Isso sugere que esses modelos podem estar acertando a classificação de muitos pixels, mas com sobreposição reduzida entre as máscaras previstas e as máscaras reais.

Em relação ao desvio padrão, os valores bastante baixos em todas as métricas (em geral menores que 0,001 para acurácia, F1 e recall) indicam alta estabilidade dos modelos durante as diferentes execuções do k-fold. A pequena variação entre os folds evidencia que os modelos estão generalizando bem para diferentes subconjuntos de validação, sem apresentar oscilações significativas de desempenho.

Por fim, a métrica de IoU, por ser mais sensível à segmentação precisa, serve como critério adicional importante de comparação entre os modelos. Os melhores valores foram observados para os modelos LinkNet101, D-LinkNetB7 e D-LinkNet101, reforçando sua superioridade nas tarefas de segmentação.

Tabela 5.5: Média das Métricas de Validação

Rede Neural	Acurácia	F1-score	IoU	Recall
Unet	0,9840	0,9823	0,5193	0,9840
LinkNetB7	0,9921	0,9916	0,7348	0,9921
LinkNet50	0,9914	0,9906	0,7093	0,9914
LinkNet34	0,9898	0,9885	0,6555	0,9898
LinkNet152	0,9848	0,9829	0,5249	0,9848
LinkNet101	0,9925	0,9916	0,7374	0,9925
D-LinkNetB7	0,9922	0,9916	0,7374	0,9922
D-LinkNet50	0,9913	0,9904	0,7071	0,9913
D-LinkNet34	0,9898	0,9886	0,6591	0,9898
D-LinkNet152	0,9849	0,9826	0,5198	0,9849
D-LinkNet101	0,9923	0,9914	0,7327	0,9923

Tabela 5.6: Desvio Padrão das Métricas de Validação

Rede Neural	Acurácia	F1-score	IoU	Recall
Unet	0,0010	0,0012	0,0139	0,0010
LinkNetB7	0,0006	0,0006	0,0036	0,0006
LinkNet50	0,0007	0,0008	0,0128	0,0007
LinkNet34	0,0008	0,0012	0,0231	0,0008
LinkNet152	0,0011	0,0011	0,0134	0,0011
LinkNet101	0,0006	0,0007	0,0061	0,0006
D-LinkNetB7	0,0006	0,0007	0,0084	0,0006
D-LinkNet50	0,0008	0,0009	0,0081	0,0008
D-LinkNet34	0,0008	0,0010	0,0101	0,0008
D-LinkNet152	0,0012	0,0017	0,0183	0,0012
D-LinkNet101	0,0006	0,0007	0,0059	0,0006

5.2.5 Matriz de Confusão

Os altos valores de acurácia observados nas tabelas 5.3 e 5.5 pode ser compreendida a partir da natureza específica do problema em questão: a detecção de processos erosivos. Tal cenário gera um desequilíbrio na distribuição das classes, em que a proporção de pixels classificados como plano de fundo (verdadeiros negativos) supera significativamente a quantidade de áreas segmentadas como regiões de interesse (verdadeiros positivos). Consequentemente, ao calcular a acurácia convencional, o predomínio de classificações corretas para a classe majoritária tende a inflacionar os resultados, mascarando o desempenho real do modelo nas classes minoritárias.

Para contornar essa limitação em conjuntos de dados desbalanceados, pode ser usada a formula de acurácia balanceada, ver equação 5.1 (Velez et al. 2007), uma métrica que pondera igualmente as taxas de acerto de ambas as classes, diminuindo o viés provocado pela disparidade amostral.

$$\text{Acurácia Balanceada} = \frac{1}{2} \left(\frac{TP}{TP + FN} + \frac{TN}{TN + FP} \right) \quad (5.1)$$

A Tabela 5.7 sintetiza os resultados obtidos a partir das matrizes de confusão, ver figuras 5.30, 5.31, 5.32, 5.33, 5.34, 5.35, 5.36, 5.37, 5.38, 5.39 e 5.40, nas quais foram analisados os valores de verdadeiros positivos (TP), falsos positivos (FP), verdadeiros negativos (TN) e falsos negativos (FN). A comparação entre a acurácia convencional e a acurácia balanceada revela uma discrepância significativa: enquanto a primeira apresenta valores próximos à saturação (98%–99%), a segunda demonstra variações mais condizentes com a complexidade do problema, oscilando entre 86,79% e 94,64%. Essa diferença evidencia que a métrica balanceada oferece uma avaliação mais fidedigna do desempenho dos modelos, especialmente em contextos onde a distribuição das classes é assimétrica.

Tabela 5.7: Resultados de Acurácia Convencional e Acurácia Balanceada

Modelo	Acurácia	Acurácia Balanceada
Unet	0,98	0,8679
LinkNet34	0,99	0,9265
LinkNet50	0,99	0,9369
LinkNet101	0,99	0,9413
LinkNet152	0,98	0,8705
LinkNetB7	0,99	0,9367
D-LinkNet34	0,98	0,9208
D-LinkNet50	0,99	0,9362
D-LinkNet101	0,99	0,9464
D-LinkNet152	0,98	0,8711
D-LinkNetB7	0,99	0,9457



Figura 5.30: Matriz de Confusão do Modelo Unet.



Figura 5.31: Matriz de Confusão do Modelo LinkNet34.



Figura 5.32: Matriz de Confusão do Modelo LinkNet50.



Figura 5.33: Matriz de Confusão do Modelo LinkNet101.



Figura 5.34: Matriz de Confusão do Modelo LinkNet152.



Figura 5.35: Matriz de Confusão do Modelo LinkNetB7.



Figura 5.36: Matriz de Confusão do Modelo D-LinkNet34.



Figura 5.37: Matriz de Confusão do Modelo D-LinkNet50.



Figura 5.38: Matriz de Confusão do Modelo D-LinkNet101.



Figura 5.39: Matriz de Confusão do Modelo D-LinkNet152.



Figura 5.40: Matriz de Confusão do Modelo D-LinkNetB7.

Capítulo 6

Conclusão

A presente dissertação de mestrado abordou a complexa problemática dos processos erosivos associados a áreas próximas a linhas de transmissão de energia, propondo uma abordagem que integra sensoriamento remoto, aprendizado de máquina e a Equação Universal de Perda de Solo (USLE). Diante da relevância ambiental e econômica do tema, especialmente em um país com extensão continental como o Brasil, este estudo buscou não apenas entender os mecanismos da erosão, mas também desenvolver uma ferramenta de monitoramento automatizado, eficiente e replicável.

A análise comparativa entre as arquiteturas de redes neurais convolucionais — UNet, LinkNet e D-LinkNet — revelou que modelos de deep learning, quando corretamente treinados e validados, são altamente eficazes na segmentação de áreas afetadas por processos erosivos, mesmo sob condições climáticas distintas. As métricas obtidas confirmaram que as redes utilizadas são capazes de identificar padrões com elevado grau de precisão, sensibilidade e especificidade, reforçando o potencial dessas técnicas como aliadas na gestão ambiental e na manutenção da infraestrutura energética nacional.

Além disso, a utilização da USLE não apenas contribuiu para a validação dos resultados dos modelos, como também permitiu o mapeamento detalhado da suscetibilidade à erosão, agregando valor à análise espacial e fornecendo uma base sólida para decisões preventivas. A convergência entre modelos matemáticos clássicos e inteligência artificial demonstrou ser uma estratégia promissora para o enfrentamento de desafios ambientais complexos.

Dentre as contribuições deste trabalho, destaca-se a elaboração de um fluxo metodológico completo, desde a aquisição e preparação de dados até a validação cruzada dos modelos, o que confere robustez e aplicabilidade prática à proposta. A metodologia aqui desenvolvida pode ser adaptada para outros contextos geográficos e ambientais, ampliando seu alcance e utilidade.

Para trabalhos futuros, recomenda-se o uso de imagens multiespectrais e hiperespectrais, a aplicação de redes mais profundas. Além disso, a criação de um sistema contínuo de monitoramento baseado em dados em tempo real poderia revolucionar o acompanhamento de áreas vulneráveis, permitindo intervenções mais rápidas e assertivas.

Referências Bibliográficas

- Agency, European Space (2024). sentinel.esa.int/documents/247904/685211/Sentinel-2_User_Handbook.
- Araújo, Aline Moura (2019), Classificação e detecção de pessoas em ambientes não controlados utilizando redes neurais convolucionais, Dissertação de mestrado, Universidade Federal da Paraíba. Trabalho de Conclusão de Curso.
- Avila Pimenta Filho, Marcos (2013), Análise da erosão interna de solos em barragens com base na distribuição de vazios, Dissertação de mestrado, Universidade Federal de Minas Gerais. Dissertação de Mestrado. Disponível no Repositório da UFMG.
- Bai, Yingbin, Erkun Yang, Bo Han, Yanhua Yang, Jiatong Li, Yinian Mao, Gang Niu & Tongliang Liu (2021), ‘Understanding and improving early stopping for learning with noisy labels’, *Advances in Neural Information Processing Systems* **34**, 24392–24403.
- Barbosa, Amanda Fernandes, Everton Falcão de Oliveira, Camila Leonardo Miotto et al. (2015), ‘Aplicação da equação universal de perda do solo (USLE) em softwares livres e gratuitos.’, *Anuário do Instituto de Geociências* **38**(1).
- Basin, Itacolomi River Hydrographic, Distribución Espacial De La Pérdida De Suelo De & Del Río Itacolomi La Cuenca Hidrográfica (2022), ‘Distribuição espacial da perda de solo na bacia hidrográfica do Rio Itacolomi, Ceará, Brasil’, *Estudos Geográficos: Revista Eletrônica de Geografia* **20**(2).
- Batista, Giovana Souza (2022), ‘Avaliação da sustentabilidade da RIDE-DF a partir de indicadores de serviços ecossistêmicos.’.
- Carvalho, José Camapum, Maurício Martines Sales, Newton Moreira de Souza & Maria Tereza da Silva Melo (2006), *Processos erosivos no Centro-Oeste brasileiro*, Finatec.
- Chaurasia, Abhishek & Eugenio Culurciello (2017), Linknet: Exploiting encoder representations for efficient semantic segmentation, *em* ‘2017 IEEE visual communications and image processing (VCIP)’, IEEE, pp. 1–4.
- Clevert, Djork-Arné, Thomas Unterthiner & Sepp Hochreiter (2015), ‘Fast and accurate deep network learning by exponential linear units (ELUS)’, *arXiv preprint arXiv:1511.07289*.

- Engine, Google Earth (2024). <https://earthengine.google.com/>.
- Florenzano, Teresa Gallotti (2007), *Iniciação em sensoriamento remoto*, Editora Oficina de Textos.
- Foster, George R, LD Meyer & CA Onstad (1977), 'A runoff erosivity factor and variable slope length exponents for soil loss estimates', *Transactions of the ASAE* **20**(4), 683–0687.
- Francisco, Paulo Roberto Megna, Djail Santos, Flávio Pereira De Oliveira et al. (2023), Estimativa e classificação da erodibilidade dos solos do estado da Paraíba, em 'Anais do CONTECC — Congresso Técnico e Científico da Engenharia e da Agronomia', CONTECC.
- Freitas, Raissa Rattes Lima de (2016), Mapeamento de risco a movimentos de massa e inundação em áreas urbanas do município de Moreno-PE, Dissertação de mestrado, Universidade Federal de Pernambuco.
- Gorriz, Juan M, Fermín Segovia, Javier Ramirez, Andrés Ortiz & John Suckling (2024), 'Is k-fold cross validation the best model selection method for machine learning?', *arXiv preprint arXiv:2401.16407*.
- Guedes, Flávio Cota, Jean Aparecido Viegas & Maisa Comar Pinhotti Aguiar (2022), 'Aplicação da equação universal de perda do solo (USLE) na bacia hidrográfica urbana do córrego Carneirinhos, na cidade de João Monlevade-MG', *Research, Society and Development* **11**(7), e40411730094–e40411730094.
- Hawker, Laurence, Peter Uhe, Luntadila Paulo et al. (2022), 'A 30 m global map of elevation with forests and buildings removed', *Environmental Research Letters* **17**(2), 024016.
- Ho, Yaoshiang & Samuel Wookey (2019), 'The real-world-weight cross-entropy loss function: Modeling the costs of mislabeling', *IEEE access* **8**, 4806–4813.
- Horton, Robert E (1945), 'Erosional development of streams and their drainage basins; hydrophysical approach to quantitative morphology', *Geological society of America bulletin* **56**(3), 275–370.
- Li, Zewen, Fan Liu, Wenjie Yang, Shouheng Peng & Jun Zhou (2021), 'A survey of convolutional neural networks: analysis, applications, and prospects', *IEEE transactions on neural networks and learning systems* **33**(12), 6999–7019.
- Lombardi Neto, Francisco & William Calvin Moldenhauer (1992), 'Erosividade da chuva: sua distribuição e relação com as perdas de solo em Campinas (SP)', *Bragantia* **51**, 189–196.
- Ma, Lei, Yu Liu, Xueliang Zhang, Yuanxin Ye, Gaofer Yin & Brian Alan Johnson (2019), 'Deep learning in remote sensing applications: A meta-analysis and review', *ISPRS journal of photogrammetry and remote sensing* **152**, 166–177.

- Marinho, Wesley José dos Santos, Raniere Lima, Fátima Matos, Luisa Souza, Marina Siqueira, Luiz Luck, Jesaias Carvalho Pereira Silva, Bruno Costa, Alisson Alves & Rafael Capuano (2025), Monitoramento da erosão em linhas de transmissão no Brasil: Comparação de redes neurais para segmentação automatizada, em 'Anais do XXI Simpósio Brasileiro de Sensoriamento Remoto (SBSR)', Galoá, Salvador, Brasil. Acesso em: 19 jun. 2025.
- Menezes, Victor Prangiel de (2015), 'Linhas de transmissão de energia elétrica—aspectos técnicos, orçamentários e construtivos', *Rio de Janeiro* **1**, 1–75.
- Mesquita, Pedro Baena de (2019), 'Cartografia geotécnica para análise de suscetibilidade e risco a movimentos de massa e erosão entorno de rodovias'.
- Oliveira Carvalho, Newton & Newton de Oliveira Carvalho (2008), *Hidrossedimentologia prática*, Editora Interciência.
- Oliveira, PLG (2019), 'Análise do potencial de erosão laminar na sub-bacia Ribeirão Ponte Alta (DF) utilizando a EUPS'.
- Pereira, Juliana Sousa et al. (2014), Avaliação das perdas de solos por erosão laminar na área de influência da UHE Amador Aguiar I, Dissertação de mestrado, Universidade Federal de Uberlândia.
- Poesen, Jean (2018), 'Soil erosion in the anthropocene: Research needs', *Earth surface processes and landforms* **43**(1), 64–84.
- Renard, Kenneth G (1997), *Predicting soil erosion by water: a guide to conservation planning with the Revised Universal Soil Loss Equation (RUSLE)*, US Department of Agriculture, Agricultural Research Service.
- Resende, Mauro (1985), 'Aplicações de conhecimentos pedológicos à conservação de solos', *Inf. Agropec* **11**(128), 3–18.
- Ronneberger, Olaf, Philipp Fischer & Thomas Brox (2015), U-net: Convolutional networks for biomedical image segmentation, em N.Navab, J.Hornegger, W. M.Wells & A. F.Frangi, eds., 'Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015', Springer International Publishing, Cham, pp. 234–241.
- Schick, Jefferson, Ildegardis Bertol, Neroli Pedro Cogo & Antonio Paz González (2014), 'Erodibilidade de um cambissolo húmico sob chuva natural', *Revista Brasileira de Ciência do Solo* **38**, 1906–1917.
- Scopus (2024).
URL: www.scopus.com
- Segedi, Gabriella Corrêa (2019), 'Estimativa de erosão pela equação universal de perda do solo (USLE) para a bacia de São Marcos'. Publicado pela UnB.

- SFE/ANEEL (2024), 'Interrupções de energia elétrica nas redes de distribuição'.
URL: <https://dadosabertos.aneel.gov.br/dataset/interruptoes-de-energia-eletricas-nas-redes-de-distribuicao>
- Shore, John & Rodney Johnson (1981), 'Properties of cross-entropy minimization', *IEEE Transactions on Information Theory* **27**(4), 472–482.
- Shrestha, Sanjeevan & Leonardo Vanneschi (2018), 'Improved fully convolutional network with conditional random fields for building extraction', *Remote Sensing* **10**(7), 1135.
- Sousa Morais, Reurysson Chagas & Antonio James Oliveira Silva (2020), 'Estimativa do potencial natural de erosão dos solos na bacia hidrográfica do Rio Longá, Piauí, Brasil', *Revista Geotemas* **10**(2), 116–137.
- Souza, Flávia Luize Pereira, Mateus de Campos Leme, Anderson Antônio da Conceição Sartori et al. (2019), 'Geotecnologias na avaliação de perdas de solo', *Irriga* **24**(3), 624–644.
- Thompson, Dayse & Elaine Cristina Cardoso Fidalgo (2013), 'Estimativa da perda de solos por meio da equação universal de perdas de solos (USLE) com uso do INVEST para a bacia hidrográfica do rio Guapi-Macacu-RJ', *Simpósio Brasileiro de Recursos Hídricos* **20**.
- Tobouti, Alexandre Kazuo & Vera Lucia Pereira dos Santos (2014), 'Impactos ambientais causados na implantação de linhas de transmissão no Brasil/environmental impacts caused the establishment of transmission lines in Brazil', *Meio Ambiente e Sustentabilidade* **4**(3), 184–199.
- Vázquez Fernández, Gonzalo A, Antônio Roberto FORMAGGIO, José Carlos Neves Epiphany et al. (1996), 'Determinação de sequências culturais em microbacia hidrográfica para caracterização do fator C da EUPS, utilizando fotografia aérea', *Simpósio Brasileiro De Sensoriamento Remoto (Sbsr)* **8**, 14–19.
- Velez, Digna R, Bill C White, Alison A Motsinger, William S Bush, Marylyn D Ritchie, Scott M Williams & Jason H Moore (2007), 'A balanced accuracy function for epistasis modeling in imbalanced datasets using multifactor dimensionality reduction', *Genetic Epidemiology: the Official Publication of the International Genetic Epidemiology Society* **31**(4), 306–315.
- Viero, Ana Claudia (2004), Análise da geologia, geomorfologia e solos no processo de erosão por voçorocas: bacia do Taboão, RS, Tese de mestrado, Universidade do Rio Grande do Sul (UFRGS).
- Wischmeier, Walter H & Dwight David Smith (1978), *Predicting rainfall erosion losses: a guide to conservation planning*, número 537, Department of Agriculture, Science and Education Administration.

- Wong, Tzu-Tsung (2015), ‘Performance evaluation of classification algorithms by k-fold and leave-one-out cross validation’, *Pattern recognition* **48**(9), 2839–2846.
- Xavier, Alexandre C, Bridget R Scanlon, Carey W King et al. (2022), ‘New improved brazilian daily weather gridded data (1961–2020)’, *International Journal of Climatology* **42**(16), 8390–8404.
- Zhang, Liangpei, Lefei Zhang & Bo Du (2016), ‘Deep learning for remote sensing data: A technical tutorial on the state of the art’, *IEEE Geoscience and remote sensing magazine* **4**(2), 22–40.
- Zhou, Lichen, Chuang Zhang & Ming Wu (2018), D-linknet: Linknet with pretrained encoder and dilated convolution for high resolution satellite imagery road extraction, *em* ‘Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR) Workshops’.
- Zhuang, Fuzhen, Zhiyuan Qi, Keyu Duan, Dongbo Xi, Yongchun Zhu, Hengshu Zhu, Hui Xiong & Qing He (2020), ‘A comprehensive survey on transfer learning’, *Proceedings of the IEEE* **109**(1), 43–76.