

Universidade Federal do Pará  
Instituto de Tecnologia  
Programa de Pós-Graduação em Engenharia Elétrica

# **Sensoriamento Remoto Multiespectral para o Monitoramento da Cobertura Vegetal em Estruturas Geotécnicas**

Carlos André de Mattos Teixeira

TD 14/2025

UFPA / ITEC / PPGEE  
Campus Universitário do Guamá  
Belém - Pará - Brasil  
2025

**Carlos André de Mattos Teixeira**

**Sensoriamento Remoto Multiespectral para o  
Monitoramento da Cobertura Vegetal em Estruturas  
Geotécnicas**

TD 14/2025

Tese de Doutorado submetida à avaliação da Banca Examinadora aprovada pelo colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Pará e julgada adequada para a obtenção do Grau de Doutor em Engenharia Elétrica na área de Computação Aplicada.

Universidade Federal do Pará

Instituto de Tecnologia

Programa de Pós-Graduação em Engenharia Elétrica

Orientador: Prof. Dr. Carlos Renato Lisboa Francês

Belém - Pará - Brasil

2025

**Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD  
Sistema de Bibliotecas da Universidade Federal do Pará  
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)**

---

D278s De Mattos Teixeira, Carlos André.  
Sensoriamento Remoto Multiespectral para o Monitoramento  
da Cobertura Vegetal em Estruturas Geotécnicas / Carlos André De  
Mattos Teixeira. — 2025.  
129 f. : il. color.

Orientador(a): Prof. Dr. Carlos Renato Lisboa Francês  
Tese (Doutorado) - Universidade Federal do Pará, Instituto de  
Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica,  
Belém, 2025.

1. Barragens. 2. Sensoriamento Remoto. 3. Machine  
Learning. 4. Segmentação Semântica. 5. Tradução de  
Imagens. I. Título.

CDD 621.3

---



UNIVERSIDADE FEDERAL DO PARÁ  
INSTITUTO DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**“SENSORIAMENTO REMOTO MULTIESPECTRAL PARA O MONITORAMENTO  
DA COBERTURA VEGETAL EM ESTRUTURAS GEOTÉCNICAS”**

**AUTOR: CARLOS ANDRÉ DE MATTOS TEIXEIRA**

TESE DE DOUTORADO SUBMETIDA À BANCA EXAMINADORA APROVADA PELO COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, SENDO JULGADA ADEQUADA PARA A OBTENÇÃO DO GRAU DE DOUTOR EM ENGENHARIA ELÉTRICA NA ÁREA DE COMPUTAÇÃO APLICADA.

APROVADA EM: 22/09/2025

**BANCA EXAMINADORA:**

---

**Prof. Dr. Carlos Renato Lisboa Francês**  
(Orientador - PPGEE/ITEC/UFPA)

---

**Prof.<sup>a</sup> Dr.<sup>a</sup> Jasmine Priscyla Leite de Araújo**  
(Avaliadora Interna - PPGEE/ITEC/UFPA)

---

**Prof. Dr. João Crisóstomo Weyl Albuquerque Costa**  
(Avaliador Interno - PPGEE/ITEC/UFPA)

---

**Prof. Dr. Ádamo Lima de Santana**  
(Avaliador Externo - FE)

---

**Prof. Dr. André Carlos Ponce de Leon Ferreira de Carvalho**  
(Avaliador Externo - USP)

**VISTO:**

---

**Prof. Dr. Diego Lisboa Cardoso**  
(Coordenador do PPGEE/ITEC/UFPA)

---

# Agradecimentos

Gostaria de agradecer ao Professor Renato Francês pelo apoio, incentivo e pela orientação durante o desenvolvimento deste trabalho. Aos Professores Diego Lisboa Cardoso e Sanae Ishizu, agradeço pela amizade e pelas valiosas oportunidades concedidas ao longo da minha trajetória acadêmica.

Aos membros da banca examinadora, Professores Ádamo Santana, André Carvalho, Jasmine Araújo e João, agradeço por aceitarem participar da avaliação da minha tese de doutorado e pelas inúmeras contribuições feitas desde a qualificação e que foram essenciais para aprimorar minha pesquisa.

Aos meus amigos dos LabCity, sou grato pelos momentos de aprendizado e convivência ao longo destes anos. Em especial, agradeço a Evelin, Thalita, Thabatta, Vitor, Jonatã e Gabriel, que estiveram ao meu lado durante o desenvolvimento deste trabalho.

Aos meus amigos Bia, Bárbara, Gabriela, Gabriel, Matheus, Ingrid e Genú, agradeço pela amizade cultivada ao longo dos anos, pelo apoio e pelos momentos de alegria que compartilhamos. Aos amigos que tive no Japão, mesmo em um curto período de convivência, agradeço por estarem presentes não apenas nos momentos de diversão, mas também nos de dificuldade, em especial Matsuzaki, Sakka, Kamada, Kaien, Suchi e Jonathan.

À minha família, expresso minha profunda gratidão. Em especial a Paula, Zeca (in memoriam) e Brian, pelo amor e apoio incondicional em todas as minhas escolhas. Ao meu tio e padrinho Carlos André, pelo incentivo constante à vida acadêmica. E a toda a minha família, que sempre esteve ao meu lado, em especial minha avó Maria José (in memoriam), cuja presença tornaria este momento ainda mais significativo.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e Norte Energia S.A., agradeço pelo apoio financeiro aos projetos de pesquisa dos quais participei.

Por fim, agradeço a todos que, de forma direta ou indireta, contribuíram para que eu chegasse até aqui. Muito obrigado!

*"Short cuts make long delays."*

**Peregrin Took**

# Resumo

Eventos geodinâmicos como o colapso de barragens, diques e outras estruturas geotécnicas acarretam em graves impactos ao meio ambiente, infraestrutura, propriedades e vidas humanas. O Brasil ocupa o oitavo lugar no *ranking* de países com o maior número de grandes barragens, evidenciando a necessidade do monitoramento contínuo dessas estruturas. A Política Nacional de Segurança de Barragens (PNSB) foi estabelecida para atribuir aos empreendedores a responsabilidade legal de manter as condições de segurança durante a construção, operação e desativação das barragens. O processo de monitoramento baseado em sensoriamento remoto é uma alternativa eficiente para a inspeção de grandes barragens e diques, apresentando-se como alternativa aos morosos métodos tradicionais de campo. Dados de sensoriamento remoto multiespectral capturados via Veículo Aéreo Não-Tripulado (VANT) permitem a obtenção de imagens de alta resolução da estrutura, possibilitando análises posteriores relacionadas à saúde estrutural com o auxílio de técnicas de *Machine Learning* e Visão Computacional. Esta tese de doutorado apresenta uma metodologia fim-a-fim para o monitoramento da cobertura vegetal dos taludes de aterro de barragens e diques. O método compreende a coleta automatizada de dados multiespectrais, o processamento de dados para a obtenção de Mapas de Ortofoto Digital (DOMs), a segmentação semântica de *land-cover* das estruturas e a extração de métricas referentes à saúde da cobertura vegetal dos taludes. A metodologia proposta foi aplicada em um estudo de caso nas estruturas geotécnicas do Complexo da Usina Hidrelétrica Belo Monte, localizada ao norte do Rio Xingú, na região sudoeste do estado do Pará. Os resultados para segmentação de *land-cover* alcançaram F1 Score de 96,41% e IoU média de 93,31% para a segmentação da cobertura vegetal das estruturas estudadas, possibilitando a análise precisa das métricas de saúde da vegetação. A extração da cobertura vegetal dos taludes permite a análise da saúde vegetal baseada em índices de vegetação multiespectrais, evidenciando áreas com diferentes densidades de vegetação e solo exposto. Adicionalmente, visando a acessibilidade do método proposto, um modelo de IA generativa foi desenvolvido utilizando a arquitetura de cGAN Pix2Pix para a geração de índices de vegetação sintéticos a partir de imagens RGB, eliminando a necessidade de aquisição de sensores multiespectrais de custo elevado. Os modelos Pix2Pix atingiram índices de similaridade estrutural de 0,95 e 0,94 para a geração de índices NDVI e NDRE, respectivamente, resultando em imagens sintéticas de qualidade. A metodologia proposta busca adicionar redundância a processos de tomada de decisões relacionadas à segurança de barragens, contribuindo para a mitigação de riscos e a prevenção de acidentes.

**Palavras-chaves:** Barragens, Sensoriamento Remoto Multiespectral, VANT, Segmentação Semântica, Machine Learning, Vegetação.

# Abstract

Geodynamic events such as the collapse of dams, dikes, and other geotechnical structures lead to severe impacts on the environment, infrastructure, properties, and human lives. Brazil ranks eighth in the world in terms of the number of large dams, highlighting the need for continuous monitoring of these structures. The National Dam Safety Policy (PNSB) was established to assign legal responsibility to the enterprises to maintain safety conditions during the construction, operation, and decommissioning of dams. Remote sensing-based monitoring is an efficient alternative for inspecting large infrastructure such as dams and dikes, presenting itself as an alternative to the time-consuming traditional field methods. Multispectral remote sensing data captured via Unmanned Aerial Vehicle (UAV) enables the acquisition of high-resolution images of the structure, allowing for subsequent analyses related to structural health with the aid of Machine Learning and Computer Vision techniques. This doctoral thesis proposal presents an end-to-end methodology for monitoring the vegetation coverage of embankment dam slopes and dikes. The method comprises the automated collection of multispectral data, data processing to obtain Digital Orthophoto Maps (DOMs), semantic land-cover segmentation of the structures, and vegetation health analysis. The proposed methodology was applied in a case study on the geotechnical structures of the Belo Monte Hydroelectric Plant Complex, located north of the Xingu River, in the southwestern region of the state of Pará, Brazil. The land-cover segmentation results achieved an F1 Score of 96,41% and a mean IoU of 93,31% for vegetation cover segmentation of the studied structures, enabling precise analysis of vegetation health metrics. The extraction of vegetation cover from the slopes allows vegetation health assessment based on multispectral vegetation indices, highlighting areas with varying vegetation densities and exposed soil. Additionally, to improve accessibility, a generative AI model was developed using the Pix2Pix cGAN architecture to generate synthetic vegetation indices from RGB images, eliminating the need for costly multispectral sensors. The Pix2Pix models achieved structural similarity indices of 0,95 and 0,94 for the generation of NDVI and NDRE indices, respectively, resulting in high-quality synthetic images. The proposed methodology aims to add redundancy to decision-making processes related to dam safety, contributing to risk mitigation and accident prevention.

**Keywords:** Embankment Dam, Multispectral Remote Sensing, UAV, Semantic Segmentation, Machine Learning, Vegetation.

---

## Lista de Figuras

Figura 1 – Os 10 países com o maior número de barragens. O Brasil ocupa o oitavo lugar no <i>ranking</i> , com um total de 1280 estruturas. . . . .	13
Figura 2 – O caminho percorrido pela lama após o rompimento da Barragem 1 da Mina do Córrego do Feijão, em Brumadinho/MG. . . . .	14
Figura 3 – <i>Pipeline</i> completo de monitoramento desenvolvido em parceria com a Norte Energia S.A. no âmbito do projeto ANEEL #23073.014329/2020-51. A metodologia proposta neste trabalho compõe o módulo de sensoriamento remoto do sistema. . . . .	16
Figura 4 – Tipos comuns de anomalia em barragens de aterro. . . . .	22
Figura 5 – Visão transversal dos efeitos da proteção vegetal na estabilidade estrutural de taludes de aterro. As forças de arrasto gravitacional ao longo do plano de cisalhamento, representadas pelas setas, induzem tensão na superfície do talude. A zona vegetada no topo do talude (I) apresenta maior estabilidade. As zonas (II-VII) tem maior potencial de falha. As zonas (II-IV) são zonas de tensão de tração. Zonas cujo enraizamento atravessa o plano de cisalhamento potencial apresentam maior estabilização contra a tensão de tração. . . . .	26
Figura 6 – Fatores que definem a Distância de Amostra do Solo (GSD), medida de resolução espacial utilizada em sensoriamento remoto para definir a distância entre os centros de dois <i>pixels</i> adjacentes. . . . .	28
Figura 7 – Comportamento da incidência de irradiação solar sobre a vegetação. . . . .	31
Figura 8 – A distribuição não homogênea dos objetos de interesse na imagem da direita é inadequada para a análise espectral da área. . . . .	31
Figura 9 – Curvas típicas que descrevem a resposta espectral da vegetação. . . . .	33
Figura 10 – A saída de um modelo de segmentação semântica, denominada máscara de segmentação, indica a classe atribuída a cada pixel da imagem de entrada. . . . .	37

Figura 11 – Estrutura hierárquica de uma Árvore de Decisão. . . . .	39
Figura 12 – No algoritmo de Random Forests, múltiplas classificações dos dados de entrada são realizadas pelo <i>ensemble</i> de árvores de decisão. A classificação final é dada pela moda dos votos realizados por modelos individuais. . . . .	40
Figura 13 – Operação de convolução de um filtro de dimensões $3 \times 3$ sobre um mapa de características, resultando no mapa de características da camada seguinte. . . . .	41
Figura 14 – Arquitetura de Rede Neural Totalmente Convolutiva (FCN32) proposta por Long et al. (2015). . . . .	43
Figura 15 – Arquitetura da Rede Neural U-NET proposta por Ronneberger et al., 2015 (RONNEBERGER et al., 2015). . . . .	44
Figura 16 – Arquitetura Redes Adversariais Generativas (GAN) e Rede GAN Condicional Pix2Pix. . . . .	46
Figura 17 – Exemplos de anomalias encontradas durante visitas técnicas. . . . .	58
Figura 18 – Caminhos de leitura indicados pelos projetos <i>as built</i> das estruturas BVSA e Dique 6C, selecionadas para o estudo de caso na Usina Hidrelétrica de Belo Monte. . . . .	59
Figura 19 – Visão geral da metodologia de análise de cobertura vegetal. O detalhamento das etapas [1] Coleta de Dados e [2] Pré-Processamento é realizado nas Seções 4.3 e 4.4, as etapas [3] Segmentação Semântica da Estrutura e [4] Análise da Cobertura Vegetal são detalhadas nos capítulos subsequentes. . . . .	61
Figura 20 – Equipamentos utilizados para coleta dos dados do estudo de caso realizado nas dependências da UHE Belo Monte. . . . .	62
Figura 21 – A configuração correta da sobreposição entre imagens durante missões automatizadas de coleta de dados afeta a qualidade do Mapa de Ortofoto Digital. . . . .	65
Figura 22 – A captura do painel de calibração de refletância conhecida antes da execução de missões de coleta de dados é essencial para realizar a calibração radiométrica das imagens. . . . .	66
Figura 23 – As imagens brutas capturadas pelo sensor multiespectral RedEdge-P representam valores de radiância em cada banda do espectro eletromagnético capturada. . . . .	67
Figura 24 – Fluxograma de processamento de Mapas de Ortofoto Digital utilizado no <i>OpenDroneMap</i> . . . . .	68
Figura 25 – Formato do <i>tensor</i> resultante do processamento dos Mapas de Ortofoto Digital. . . . .	69

Figura 26 – Mapas de Ortofoto Digital (DOMs) resultantes das coletas de dados realizadas nas estruturas BVSA e Dique 6C nos dias 16 e 17 de maio de 2023. . . . .	70
Figura 27 – Metodologia de Segmentação Semântica com modelos de <i>Random Forests</i> composta por três macro-etapas: (1) Preparação dos dados, (2) Engenharia de <i>Features</i> e (3) Treinamento dos Modelos. . . . .	74
Figura 28 – Exemplos de imagens do conjunto de dados, <i>features</i> extraídas e máscaras de segmentação anotadas manualmente. . . . .	77
Figura 29 – Avaliação de desempenho com base no F1 Score, no Erro OOB e no tempo de treinamento para cada modelo explorado na busca em grade. . . . .	79
Figura 30 – Treinamento de modelos para as Top X <i>features</i> ranqueadas por importância calculada com base na Diminuição Média da Impureza (MDI). . . . .	81
Figura 31 – Matriz de Confusão do modelo de segmentação RF. Os valores percentuais presentes na diagonal principal da matriz representam as classificações realizadas corretamente para cada classe nos dados do conjunto de teste. . . . .	82
Figura 32 – Comparação entre as máscaras de segmentação anotadas, previstas pelo modelo e corrigidas após pós-processamento. . . . .	84
Figura 33 – Metodologia de Segmentação Semântica com modelos U-NET. . . . .	86
Figura 34 – Métricas de Perda, F1 Score e IoU ao longo do processo de treinamento do modelo U-NET. . . . .	87
Figura 35 – Exemplos de inferências com o modelo AU-NET acompanhados dos mapas de ativação de classes (Grad-CAM). . . . .	88
Figura 36 – Matriz de Confusão do modelo de segmentação AU-NET. Os valores percentuais presentes na diagonal principal da matriz representam as classificações realizadas corretamente para cada classe nos dados do conjunto de teste. . . . .	89
Figura 37 – Metodologia de geração de Índices de Vegetação (IVs) sintéticos com o modelo cGAN Pix2Pix. . . . .	92
Figura 38 – Métricas de treinamento do modelo CGAN. . . . .	94
Figura 39 – Métricas de desempenho PSNR, SSIM e MSE computadas para as 225 imagens do conjunto de teste individualmente. . . . .	95
Figura 40 – Correlação entre as métricas SSIM, PSNR e MSE computadas entre as imagens RGB originais e os IVs originais e gerados pelo modelo Pix2Pix. . . . .	96
Figura 41 – Comparação entre as imagens de entrada RGB, os índices NDVI originais e os índices NDVI gerados pelo modelo Pix2Pix. . . . .	97
Figura 42 – Comparação entre as imagens de entrada RGB, os índices NDRE originais e os índices NDRE gerados pelo modelo Pix2Pix. . . . .	98

Figura 43 – Extração dos pixels referentes a cobertura vegetal do talude com base nos resultados da segmentação semântica. . . . .	99
Figura 44 – Comparação do IV NDRE em três amostras da cobertura vegetal do talude. . . . .	101
Figura 45 – Contagem de pixels em cada categoria de saúde de vegetação nas amostras retiradas do DOM da BVSA. . . . .	101

---

## Lista de Tabelas

Tabela 1 – Tipos comuns de anomalia em taludes de jusante de barragens de aterro. <b>Fonte: Adaptado de (ANA, 2016).</b> . . . . .	23
Tabela 2 – Características de resolução espacial (GSD), campo de visão, usabilidade e custos para aquisição de dados das quatro principais plataformas utilizadas em sensoriamento remoto. (*) O custo para aquisição de imagens de satélites é considerado muito alto, especialmente em casos de imagens estéreo de alta resolução, entretanto, é possível contar com a disponibilidade gratuita de dados de satélite em certas plataformas atuais. <b>Fonte: Adaptado de Candiago et al., 2015 (CANDIAGO et al., 2015).</b> . . . . .	29
Tabela 3 – Principais índices de vegetação utilizados em sensoriamento remoto. Nas equações apresentadas, $\rho$ indica o intensidade de refletância para as bandas vermelha ( <i>Red - R</i> ), verde ( <i>Green - G</i> ), azul ( <i>Blue - B</i> ), vermelho de borda ( <i>Red Edge - RE</i> ) e infravermelho próximo ( <i>Near Infrared - NIR</i> ). <b>Fonte: Autor.</b> . . . . .	35
Tabela 4 – Áreas temáticas e contribuições identificadas para os trabalhos correlatos: Veículo Aéreo Não-Tripulado (VANT), Multiespectral (MS), Índice de Vegetação (IV), Machine Learning Tradicional (TML), Deep Learning (DL), Vegetação (VEG), Barragens (BRG). <b>Fonte: Autor.</b> . . . . .	54
Tabela 5 – Bandas espectrais capturadas pelo sensor multiespectral Micasense RedEdge-P. <b>Fonte: Autor.</b> . . . . .	63
Tabela 6 – Parâmetros de configuração para a execução de missões automáticas de coletas de dados utilizando o sensor RedEdge-P. <b>Fonte: Autor.</b> . . . . .	64
Tabela 7 – Descrição de cada classe de interesse no conjunto de dados. <b>Fonte: Autor.</b> . . . . .	71
Tabela 8 – Número balanceado de amostras (pixels) atribuídas aos conjuntos de treinamento, validação e teste. <b>Fonte: Autor.</b> . . . . .	75

Tabela 9 – Melhores resultados obtidos nas tarefas de segmentação binária e multiclasse para cada subconjunto de <i>Features</i> . <b>Fonte: Autor.</b> . . . . .	80
Tabela 10 – Análise de desempenho do modelo final de RF, incluindo métricas gerais e específicas por classe. <b>Fonte: Autor.</b> . . . . .	82
Tabela 11 – Análise de desempenho do modelo final de RF, incluindo métricas gerais e específicas por classe. <b>Fonte: Autor.</b> . . . . .	85
Tabela 12 – Dimensões dos mapas referentes a BVSA e ao Dique 6C e número de imagens resultantes do processo de fatiamento em regiões de dimensões $256 \times 256 \times 5$ . <b>Fonte: Autor.</b> . . . . .	87
Tabela 13 – Análise de desempenho do modelo AU-NET, incluindo métricas gerais e específicas por classe. <b>Fonte: Autor.</b> . . . . .	89
Tabela 14 – Métricas de desempenho gerais do modelo Pix2Pix computadas para o conjunto de teste. <b>Fonte: Autor.</b> . . . . .	94
Tabela 15 – Publicações de artigos científicos pretendidas e realizadas ao longo da realização deste trabalho. <b>Fonte: Autor.</b> . . . . .	107
Tabela 16 – Registros de Programas de Computador (RPCs) registrados no Instituto Nacional da Propriedade Industrial (INPI) oriundos do projeto de Projeto de pesquisa e desenvolvimento ANEEL #23073.014329/2020-51 em parceria com a Norte Energia S.A.. <b>Fonte: Autor.</b> . . . . .	108
Tabela 17 – Dicionário de termos relacionados a infraestruturas de contenção no âmbito de engenharia e segurança de barragens <b>Fonte: Adaptado de ANA, 2016 (ANA, 2016).</b> . . . . .	121
Tabela 18 – Dicionário de termos relacionados aos elementos constitutivos das estruturas no âmbito de engenharia e segurança de barragens <b>Fonte: Adaptado de ANA, 2016 (ANA, 2016).</b> . . . . .	121
Tabela 19 – Dicionário de termos relacionados a eventos e anomalias que ocorrem no âmbito de engenharia e segurança de barragens <b>Fonte: Adaptado de ANA, 2016 (ANA, 2016).</b> . . . . .	122
Tabela 20 – Dicionário de termos relacionados a princípios e diretrizes no âmbito de engenharia e segurança de barragens <b>Fonte: Adaptado de ANA, 2016 (ANA, 2016).</b> . . . . .	123
Tabela 21 – Dicionário de termos relacionados a governança e regulação no âmbito de engenharia e segurança de barragens <b>Fonte: Adaptado de ANA, 2016 (ANA, 2016).</b> . . . . .	125
Tabela 22 – Parâmetros de configuração do software <i>OpenDroneMap</i> para a geração de mapas de qualidade no contexto do estudo de caso apresentado. <b>Fonte: Autor.</b> . . . . .	126

---

## Lista de Siglas

<b>ANA</b>	Agência Nacional de Águas e Saneamento Básico
<b>ANEEL</b>	Agência Nacional de Energia Elétrica
<b>ANM</b>	Agência Nacional de Mineração
<b>BVSA</b>	Barragem Vertente do Santo Antônio
<b>cGAN</b>	<i>Conditional Generative Adversarial Network</i> (Rede Generativa Adversarial Condicional)
<b>DEM</b>	<i>Digital Elevation Map</i> (Mapa Digital de Elevação)
<b>DL</b>	<i>Deep Learning</i> (Aprendizado Profundo)
<b>DOM</b>	<i>Digital Orthophoto Map</i> (Mapa de Ortofoto Digital)
<b>DPA</b>	Dano Potencial Associado
<b>FCN</b>	<i>Fully Convolutional Networks</i> (Redes Totalmente Convolucionais)
<b>FN</b>	Falsos Negativos
<b>FP</b>	Falsos Positivos
<b>GAN</b>	Redes Adversariais Generativas
<b>GCP</b>	Ponto de Controle em Solo
<b>GNDVI</b>	<i>Green Normalized Difference Vegetation Index</i> (Índice de Vegetação por Diferença Normalizada no Verde)
<b>GPS</b>	<i>Global Positioning System</i> (Sistema Global de Posicionamento)
<b>GSD</b>	<i>Ground Sample Distance</i> (Distância de Amostra do Solo)

<b>IA</b>	Inteligência Artificial
<b>ICOLD</b>	<i>International Commission on Large Dams</i> (Comissão Internacional de Grandes Barragens)
<b>IoU</b>	<i>Intersection over Union</i> (Interseção sobre a União)
<b>ISE</b>	Inspeção de Segurança Especial
<b>ISR</b>	Inspeção de Segurança Regular
<b>IV</b>	Índice de Vegetação
<b>ML</b>	Machine Learning (Aprendizado de Máquina)
<b>MSE</b>	Erro Quadrático Médio
<b>NDRE</b>	<i>Normalized Difference Red Edge</i> (Diferença Normalizada no Vermelho de Borda)
<b>NDVI</b>	<i>Normalized Difference Vegetation Index</i> (Índice de Vegetação por Diferença Normalizada)
<b>NDWI</b>	<i>Normalized Difference Water Index</i> (Índice de Água por Diferença Normalizada)
<b>NIR</b>	<i>Near Infrared</i> (Infravermelho Próximo)
<b>ODM</b>	<i>OpenDroneMap</i>
<b>PNSB</b>	Política Nacional de Segurança de Barragens
<b>PSNR</b>	<i>Peak Signal to Noise Ratio</i> (Relação Sinal-Ruído de Pico)
<b>RE</b>	<i>Red Edge</i> (Vermelho de Borda)
<b>RF</b>	<i>Random Forests</i>
<b>RNA</b>	Rede Neural Artificial
<b>RNC</b>	Rede Neural Convolutacional
<b>SAVI</b>	<i>Soil Adjusted Vegetation Index</i> (Índice de Vegetação Ajustado ao Solo)
<b>SNISB</b>	Sistema Nacional de Informações sobre Segurança de Barragens
<b>SSIM</b>	<i>Structural Similarity Index</i> (Índice de Similaridade Estrutural)
<b>SVM</b>	<i>Support Vector Machines</i> (Máquina de Vetores de Suporte)

<b>VN</b>	Verdadeiros Negativos
<b>VP</b>	Verdadeiros Positivos
<b>UHE</b>	Usina Hidrelétrica
<b>VANT</b>	Veículo Aéreo Não Tripulado
<b>VC</b>	Visão Computacional

---

# Sumário

<b>1</b>	<b>INTRODUÇÃO . . . . .</b>	<b>12</b>
1.1	Contextualização . . . . .	12
1.2	Pergunta de Pesquisa e Hipóteses . . . . .	17
1.3	Objetivos . . . . .	18
1.4	Organização da Tese de Doutorado . . . . .	19
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA . . . . .</b>	<b>20</b>
2.1	Monitoramento de Estruturas Geotécnicas . . . . .	20
2.2	Sensoriamento Remoto Multiespectral . . . . .	28
2.3	Machine Learning em Visão Computacional . . . . .	37
2.3.1	Segmentação Semântica . . . . .	37
2.3.2	Random Forests . . . . .	38
2.3.3	Redes Neurais Convolucionais . . . . .	40
2.3.4	Redes Adversariais Generativas Condicionais . . . . .	45
<b>3</b>	<b>TRABALHOS CORRELATOS . . . . .</b>	<b>48</b>
3.1	Sensoriamento Remoto para Classificação de Land-Cover . . . . .	48
3.2	Análise do Perfil Espectral de Diferentes Materiais . . . . .	51
3.3	Modelos Generativos para Sintetização de Dados Multiespectrais . . . . .	52
3.4	Sumarização dos Trabalhos Correlatos . . . . .	53
<b>4</b>	<b>METODOLOGIA PARA MONITORAMENTO DA COBERTURA VEGETAL EM TALUDES DE ATERRO . . . . .</b>	<b>57</b>
4.1	Estudo de Caso . . . . .	57
4.2	Metodologia Proposta . . . . .	60
4.3	Coleta de Dados . . . . .	62
4.4	Pré-Processamento de Dados . . . . .	66
4.5	Anotação de Dados . . . . .	71
<b>5</b>	<b>SEGMENTAÇÃO SEMÂNTICA DE LAND-COVER EM TALUDES DE ATERRO . . . . .</b>	<b>73</b>
5.1	Segmentação Semântica com Random Forests . . . . .	74

5.2	Segmentação Semântica com Deep Learning . . . . .	85
6	ANÁLISE DA COBERTURA VEGETAL EM TALUDES DE ATERRO . . . . .	91
6.1	Geração de Índices de Vegetação Sintéticos a partir de Imagens RGB . . . . .	91
6.2	Extração de Métricas de Saúde da Vegetação . . . . .	99
7	CONSIDERAÇÕES FINAIS . . . . .	103
7.1	Produção Científica e Tecnológica . . . . .	107
	REFERÊNCIAS BIBLIOGRÁFICAS . . . . .	109

**APÊNDICES** **119**

APÊNDICE A	– DICIONÁRIO DE TERMOS RELACIONADOS A ENGENHARIA E SEGURANÇA DE BAR- RAGENS . . . . .	120
APÊNDICE B	– PARÂMETROS DE CONFIGURAÇÃO DO OPEN- DRONEMAP . . . . .	126

---

# Introdução

## 1.1 Contextualização

Estruturas geotécnicas são obras de engenharia concebidas para interagir com o solo ou maciços rochosos, explorando suas propriedades mecânicas e hidráulicas para garantir estabilidade, suporte e contenção (DUNCAN et al., 2014). A construção de estruturas geotécnicas complexas de grande porte, como taludes, diques e barragens pode ser motivada por diversos fatores, como o atendimento da necessidade de controle de cheias, irrigação de terras agricultáveis, acumulação de água para abastecimento humano ou industrial, navegação, piscicultura, contenção de detritos e avalanches, proteção contra maremotos, paisagismo, geração de energia elétrica, dentre muitos outros exemplos (MELLO et al., 2021). Entretanto, a construção e operação de tais estruturas envolvem riscos significativos para o meio ambiente e para a população local, especialmente quando não são adotadas medidas de segurança e rotinas de monitoramento adequadas (ANA, 2016).

O grande número de grandes barragens existentes mundialmente destaca a necessidade de que as mesmas sejam monitoradas e fiscalizadas de forma contínua e precisa, a fim de garantir sua segurança e integridade. A Figura 1 lista os dez países com o maior número de barragens construídas (ICOLD, 2024), liderados respectivamente pela China, Estados Unidos, Índia e Japão. Neste cenário internacional, a *International Commission on Large Dams* (Comissão Internacional de Grandes Barragens) (ICOLD) promove a cooperação na promoção do intercâmbio de conhecimento e experiência no campo de engenharia de barragens (MELLO et al., 2021).

De acordo com o levantamento realizado pela ICOLD (ICOLD, 2024), o Brasil ocupa o oitavo lugar no *ranking* de países com o maior número de grandes barragens construídas, com 1280 estruturas. O histórico da construção das barragens brasileiras foi guiado por objetivos e realidades distintos, refletindo as nuances regionais. As construções de barragens de energia elétrica na região sudeste, por exemplo, foram motivadas principalmente pelo




Figura 1 – Os 10 países com o maior número de barragens. O Brasil ocupa o oitavo lugar no *ranking*, com um total de 1280 estruturas.

**Fonte: Autor. Dados adaptados de ICOLD, 2024 (ICOLD, 2024).**

surto desenvolvimentista do século XIX, enquanto que as barragens de reservatórios da região nordeste visavam solucionar os problemas oriundos das secas periódicas (MELLO et al., 2021).

As diferentes motivações e naturezas dos projetos desses empreendimentos dificultaram a correta fiscalização e regulação da construção e operação dessas estruturas. Este contexto levou à ocorrência de inúmeros incidentes e acidentes ocorridos em barragens brasileiras e também à escassez de registros e informações sobre os mesmos (MELLO et al., 2021). Este cenário era propício para a subnotificação de acidentes em barragens que, em grande parte, não eram reportados pela mídia e não alcançavam o conhecimento do público geral.

No Brasil, a Política Nacional de Segurança de Barragens (PNSB) foi estabelecida a partir da promulgação da Lei Nº 12.334/2010, culminando na criação do Sistema Nacional de Informações sobre Segurança de Barragens (SNISB). Com a criação desta lei, a responsabilidade legal de manter as condições de segurança durante a construção, operação e desativação das barragens foi atribuída aos empreendedores responsáveis. Diferentes órgãos reguladores também foram assinalados para barragens de diferentes categorias, como a Agência Nacional de Energia Elétrica (ANEEL) para barragens de geração de energia elétrica, a Agência Nacional de Mineração (ANM) para barragens de mineração e a Agência Nacional de Águas e Saneamento Básico (ANA) para barragens de usos múltiplos (ANA, 2016).



Figura 2 – O caminho percorrido pela lama após o rompimento da Barragem 1 da Mina do Córrego do Feijão, em Brumadinho/MG.

Fonte: Adaptado de (G1, 2019).

Apesar das medidas de fiscalização e regulação, o Brasil ainda enfrenta desafios significativos no contexto de segurança de barragens. Dentre os grandes desastres envolvendo estruturas geotécnicas no país, é possível citar o rompimento da barragem de São Francisco em Miraf/MG, da barragem do Fundão no município de Mariana/MG, e da Barragem 1 da Mina do Córrego do Feijão, localizada na cidade de Brumadinho/MG (FOGAÇA et al., 2023). Este último ocorreu em 25 de janeiro de 2019 e foi considerado um dos maiores acidentes ambientais já registrados no mundo, responsável pelo despejo de cerca de 13 milhões de metros cúbicos de rejeitos de mineração, 250 fatalidades e pela destruição da fauna e flora de parte do bioma da Mata Atlântica (VIEZORKOSKY et al., 2020). A Figura 2 ilustra o caminho percorrido pela lama após o rompimento da Barragem 1 da Mina do Córrego do Feijão.

Eventos geodinâmicos como o colapso de estruturas geotécnicas são capazes de causar danos graves ao meio ambiente, infraestrutura, propriedades e vidas humanas (LÖBMANN et al., 2020; SOLORZANO et al., 2022). É comum que incidentes e acidentes em estruturas geotécnicas como barragens, diques e taludes sejam resultado da ação simultânea de diversas causas e agentes (MELLO et al., 2021). Neste cenário é destacada a importância do monitoramento estrutural para garantir a integridade, segurança e eficiência das estruturas geotécnicas durante e após a sua vida útil. O monitoramento estrutural pode ser realizado a partir de estratégias multi-abordagem, que tradicionalmente envolvem a realização de inspeções *in loco*, instrumentação de campo, ensaios de laboratório, simulações e modelos numéricos ou analíticos (ARAÚJO, 2024).

Recentemente, a utilização de tecnologias de Sensoriamento Remoto, Machine Learning (Aprendizado de Máquina) (ML) e Visão Computacional (VC) tem se destacado como alternativas viáveis e econômicas para adicionar redundância a rotinas de monitoramento de barragens. Em sua análise sobre o futuro do ML na geotecnia, Phoon e Zhang (2023) enfatizam a importância de abordagens que foquem na centralidade dos dados e adequação dos modelos de ML e *Deep Learning* (Aprendizado Profundo) (DL) ao contexto geotécnico. Entretanto, diversos autores reconhecem que, apesar do rápido avanço das tecnologias de Inteligência Artificial (IA), a área da engenharia civil permanece cética em relação à adoção dessas tecnologias (ZHANG et al., 2021; PHOON; ZHANG, 2023). O advento relativamente tardio de tecnologias baseadas em imagem no contexto de monitoramento de barragens também é destacado na revisão de literatura realizada por Deng et al. (DENG et al., 2025). Por este motivo, o uso de tecnologias de ML para monitoramento de estruturas geotécnicas permanece relativamente baixo.

Diversos estudos comprovam a eficácia da aliança entre sensoriamento remoto e ML para tarefas como classificação, segmentação semântica de *land-cover* e detecção de anomalias em contextos diversos (LIMÃO et al., 2023; LINHUI et al., 2021; RIEHLE et al., 2020; DAVIDSON et al., 2022). Na literatura é possível encontrar exemplos de aplicações que buscam a extração de padrões em dados de sensoriamento remoto multiespectral capturados por sensores embarcados em satélites ou em Veículo Aéreo Não Tripulado (VANT). Entretanto, é notável a inexistência de conjuntos de dados e a lacuna de estudos que explorem o uso de sensoriamento remoto multiespectral aliado a técnicas de ML para o monitoramento de estruturas geotécnicas, especialmente em barragens de aterro (DENG et al., 2025).

De acordo com o levantamento realizado por Mello et al. (2021), os três principais modos de acidentes em barragens reportados por diversos autores são percolação (38% a 40% dos casos), instabilidades (5% a 15% dos casos) e erosão (31% a 51% dos casos). Erosões são desgastes localizados sofridos pelo talude como resultado da ação das águas do reservatório, da água da chuva, do vento, da presença de tocas de animais e de outros agentes externos (ANA, 2016). Uma das formas de aumentar a resistência do talude à erosão é a proteção vegetal, que atua como uma barreira natural contra a ação dos agentes erosivos (GREENWOOD et al., 2004; LÖBMANN et al., 2020).

A erosão do talude de jusante, i.e. superfície inclinada oposta ao reservatório, é um dos principais modos de falha em barragens de aterro e pode ser identificada a partir da inspeção visual. Esta forma de inspeção baseada na observação detalhada da estrutura possibilita a percepção de variados sintomas que acarretam a erosão do talude, como a desvegetação, deslizamentos de solo, trincas, entre outros (MELLO et al., 2021). Neste contexto, técnicas de VC, ML e DL podem ser empregadas para automatizar a identificação de incidentes relacionados à cobertura vegetal em taludes de barragens de

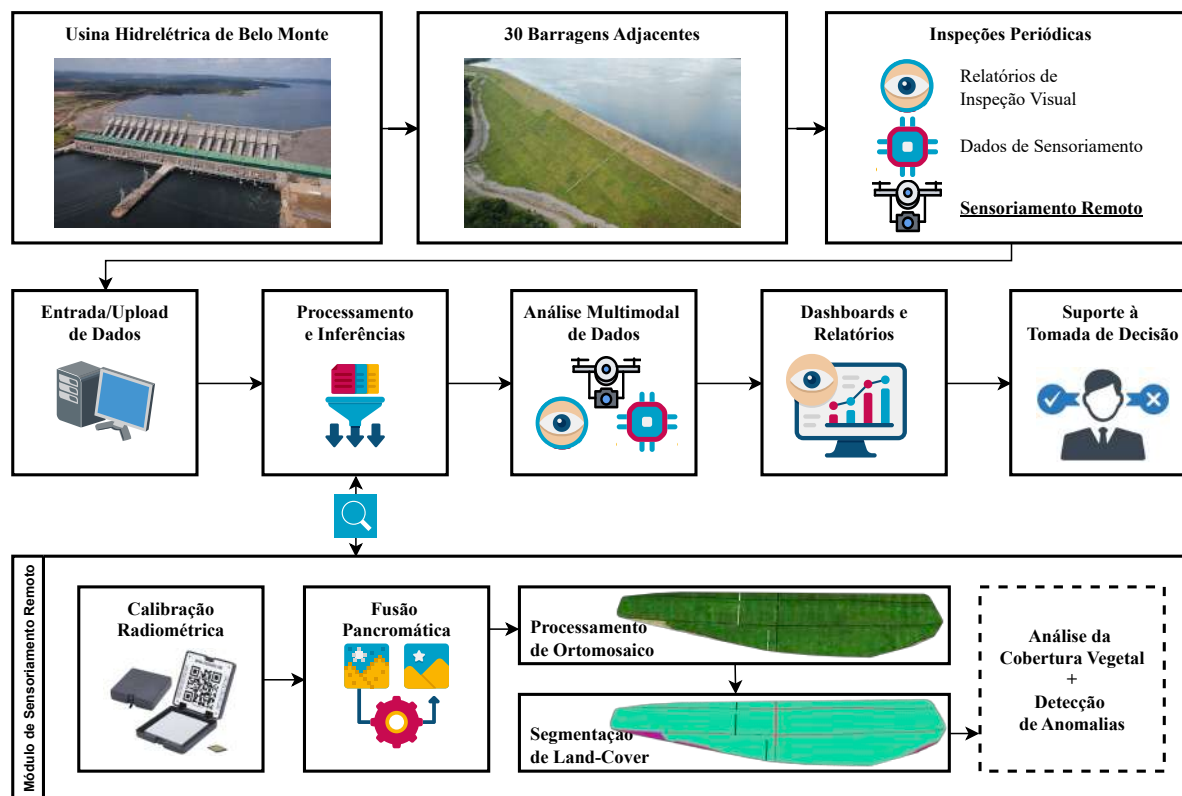


Figura 3 – *Pipeline* completo de monitoramento desenvolvido em parceria com a Norte Energia S.A. no âmbito do projeto ANEEL #23073.014329/2020-51. A metodologia proposta neste trabalho compõe o módulo de sensoriamento remoto do sistema.

Fonte: Autor.

aterro, tornando o processo de monitoramento mais eficiente e preciso.

Este estudo explora o potencial de tecnologias de sensoriamento remoto multiespectral, ML e DL para o monitoramento da cobertura vegetal em estruturas geotécnicas. A metodologia proposta foi desenvolvida em parceria com a Norte Energia S.A., responsável pelo Complexo da Usina Hidrelétrica (UHE) Belo Monte, e integrada a um sistema multimodal de monitoramento de barragens desenvolvido ao longo do projeto ANEEL #23073.014329/2020-51, apresentado na Figura 3.

No contexto do empreendimento, o monitoramento das mais de 30 barragens e diques que circundam o reservatório já é realizado por meio de relatórios de inspeção visual e dados de sensoriamento. Esta pesquisa propõe a incorporação de uma metodologia automatizada de inspeção baseada em Sensoriamento Remoto Multiespectral, capaz de ampliar a precisão e a eficiência do processo. As tecnologias desenvolvidas permitem análises objetivas, replicáveis e sob demanda, integrando dados de diferentes naturezas para aprimorar a detecção de anomalias e subsidiar decisões técnicas de forma mais assertiva. Dessa maneira, as soluções apresentadas contribuem para o fortalecimento da

segurança operacional das estruturas, além de promover a proteção das comunidades adjacentes e do meio ambiente.

## 1.2 Pergunta de Pesquisa e Hipóteses

A seguinte pergunta de pesquisa foi formulada com base na problemática apresentada e utilizada como motivação para a realização deste trabalho:

**Como o sensoriamento remoto multiespectral, aliado a modelos de aprendizado de máquina, pode monitorar de forma precisa e acessível a saúde da cobertura vegetal em estruturas geotécnicas?**

A pergunta de pesquisa supracitada foi utilizada como base para a formulação das seguintes hipóteses a serem investigadas nesta pesquisa:

**Hipótese 1:** A utilização de VANTs para a coleta automatizada de dados multiespectrais de alta resolução melhora a precisão e a eficiência do monitoramento de cobertura vegetal em estruturas geotécnicas.

**Hipótese 2:** A integração de técnicas de segmentação semântica e análise de índices de vegetação multiespectrais permite uma análise mais detalhada e precisa da cobertura vegetal de estruturas geotécnicas, facilitando a identificação precoce de falhas e áreas críticas.

**Hipótese 3:** Modelos generativos de DL para tradução de imagens são uma alternativa viável e econômica para calcular Índices de Vegetação (IVs) multiespectrais a partir de dados RGB.

## 1.3 Objetivos

O principal objetivo deste trabalho é o desenvolvimento de um *framework* para o monitoramento da cobertura vegetal presente em estruturas geotécnicas, mais especificamente em taludes de barragem de terra. A formalização da metodologia em formato de *framework* busca sistematizar o procedimento desenvolvido, objetivando a reprodutibilidade e a precisão das análises realizadas. Com base no objetivo geral, os seguintes objetivos específicos são apresentados:

- Realizar um levantamento do estado-da-arte sobre a aplicação de sensoriamento remoto multiespectral e ML no monitoramento de estruturas geotécnicas;
- Propor uma metodologia completa para o monitoramento de taludes de aterro, baseada na saúde da cobertura vegetal, utilizando tecnologias de sensoriamento remoto multiespectral;
- Definir um procedimento detalhado para a coleta de dados multiespectrais e o processamento de ortomosaicos aplicados ao monitoramento de taludes;
- Desenvolver modelos de segmentação de land-cover para a distinção de elementos presentes em taludes de aterro;
- Desenvolver uma metodologia acessível para a sintetização de índices de vegetação a partir de imagens RGB tradicionais utilizando métodos generativos;
- Demonstrar a validade da solução proposta a partir de um estudo de caso realizado nas dependências da Usina Hidrelétrica de Belo Monte.

## 1.4 Organização da Tese de Doutorado

Este trabalho está estruturado da seguinte forma:

- Capítulo 2: Define os conceitos e fundamentos teóricos necessários para a compreensão do trabalho, incluindo conceitos relacionados ao monitoramento de estruturas geotécnicas, sensoriamento remoto multiespectral, ML e VC;
- Capítulo 3: Apresenta o estado-da-arte sobre sensoriamento remoto multiespectral e ML aplicados ao monitoramento de estruturas geotécnicas;
- Capítulo 4: Descreve a metodologia proposta para o monitoramento da cobertura vegetal em taludes de barragens de aterro, apresenta os detalhes do estudo de caso e dos processos de coleta e pré-processamento de dados;
- Capítulo 5: Apresenta a metodologia proposta e os experimentos realizados para a segmentação semântica de land-cover de taludes de aterro;
- Capítulo 6: Apresenta a metodologia proposta e os experimentos realizados para a geração e análise de índices de vegetação em taludes de aterro;
- Capítulo 7: Apresenta as considerações finais do trabalho, destacando as contribuições realizadas, dificuldades encontradas e sugestões para trabalhos futuros visando a continuação da pesquisa.

---

## Fundamentação Teórica

Este capítulo apresenta o referencial teórico dos conceitos e técnicas que serão extensivamente utilizados ao longo desta tese de doutorado. A Seção 2.1 aborda conceitos fundamentais relacionados ao monitoramento de estruturas geotécnicas, com foco em barragens de aterro. A Seção 2.2 discorre sobre os conceitos relacionados ao sensoriamento remoto multiespectral baseado em imagens capturadas por VANTs. Por fim, a Seção 2.3 apresenta os conceitos relacionados às técnicas de ML e VC utilizadas ao longo do presente trabalho. Os conceitos apresentados nesta seção são fundamentais para a compreensão do trabalho proposto e para a análise dos resultados obtidos.

### 2.1 Monitoramento de Estruturas Geotécnicas

A definição de estrutura geotécnica compreende construções ou elementos de construções cuja concepção e dimensionamento são controlados pelo comportamento mecânico e hidráulico de maciços terrosos ou rochosos do local onde estão implantadas (TERZAGHI et al., 1996). Estruturas geotécnicas complexas como fundações, barragens e taludes naturais ou artificiais são compostas por diversos elementos que, em conjunto, suportam cargas e garantem a estabilidade estrutural. As técnicas desenvolvidas neste trabalho são aplicáveis a três tipos específicos de estruturas geotécnicas: taludes, diques e barragens de aterro.

Para auxiliar na leitura deste trabalho, um dicionário de termos relacionados à engenharia e segurança de barragens é apresentado no Apêndice A. O dicionário é estruturado da seguinte forma: termos referentes a infraestruturas de contenção (Tabela 17), elementos constitutivos (Tabela 18), eventos e anomalias (Tabela 19), princípios e diretrizes (Tabela 20), governança e regulação (Tabela 21).

Taludes são superfícies inclinadas, de origem natural ou artificial, compostas por maciços terrosos, rochosos ou mistos. Os taludes podem ser classificados como estruturas

geotécnicas completas quando projetados e construídos com base em técnicas e finalidades específicas para garantir sua estabilidade (ARAÚJO, 2024). A estabilidade de taludes é influenciada por diversos fatores geomorfológicos, como a elevação topográfica e a angulação da estrutura, que não deve ultrapassar 45 graus (LIMÃO et al., 2023). Taludes artificiais são frequentemente contruídos em áreas de instabilidade para prevenir a ocorrência de deslizamentos, elevar o nível do terreno ou criar diques (FERNANDES, 2006). Diques são obras de engenharia hidráulica que realizam o represamento de águas para manter determinadas porções de terra secas (ANA, 2022). Em grande parte dos casos, diques são construídos como estruturas auxiliares para barragens de maior magnitude.

De acordo com o Ato Nacional de Segurança de Barragens, ocorrido em 2006 nos Estados Unidos, uma barragem é definida como "*qualquer barreira artificial que tenha a capacidade de reter água, resíduos ou qualquer material de origem líquida, para fins de armazenamento ou controle*" (FEMA, 2013). No Brasil, a definição da ANA configura como barragem "*qualquer estrutura construída dentro ou fora de um curso permanente ou temporário de água, em talvegue ou em cava exaurida com dique, para fins de contenção ou acumulação de substâncias líquidas ou de misturas de líquidos e sólidos, compreendendo o barramento e as estruturas associadas*" (ANA, 2022). São consideradas barragens de aterro as barragens construídas a partir de terra ou uma combinação de terra e enrocamento.

A construção de barragens pode ser motivada pela necessidade de controle de cheias, irrigação de terras agricultáveis, acumulação de água para abastecimento humano ou industrial, geração de energia elétrica, dentre outros motivos (MELLO et al., 2021). Entretanto, a construção e operação dessas estruturas complexas envolvem riscos potenciais significativos para a população, economia e meio ambiente (ANA, 2016). A incidência de anomalias nessas estruturas pode comprometer a estabilidade estrutural e gerar riscos de rompimento.

Vale ressaltar as diferenças entre os conceitos de incidente e acidente utilizados neste trabalho. Incidentes são caracterizados por ocorrências isoladas que afetam o comportamento da barragem ou de estruturas anexas. Acidentes representam o comprometimento da integridade estrutural da barragem com liberação incontrolável do conteúdo do reservatório, ocasionado pelo colapso parcial ou total da barragem ou estrutura anexa. Portanto, a ocorrência de um ou mais incidentes pode preceder a ocorrência de acidentes.

O comportamento inadequado induzido por incidentes em barragens implica no investimento considerável de recursos financeiros voltados a reforços, reparos, ampliação e modernização de monitoramento e instrumentação (MELLO et al., 2021). Comportamentos inadequados são caracterizados por eventos que impedem a operação da barragem conforme o planejado, induzem apreensão por parte das comunidades vizinhas e do público em geral, e podem acarretar no descumprimento dos critérios estabelecidos pelos órgãos reguladores

e fiscalizadores. A detecção precoce da ocorrência de incidentes é fundamental para a prevenção de acidentes e para a manutenção da segurança das estruturas geotécnicas.




Figura 4 – Tipos comuns de anomalia em barragens de aterro.

Fonte: ANA, 2016 (ANA, 2016).

Uma anomalia existente em um talude, barragem ou dique, é caracterizada como qualquer deficiência, irregularidade, anormalidade ou deformação que possa afetar o funcionamento da estrutura e ameaçar a segurança das áreas adjacentes (ANA, 2016).

Anomalias podem ser classificadas de acordo com a sua magnitude e pelo nível de perigo imposto pela mesma. A Figura 4 ilustra os principais tipos de anomalias encontradas em barragens de aterro.

Dentre os principais tipos de anomalias que ocorrem em barragens de aterro (Tabela 1), é possível citar as fissuras longitudinais e transversais, afundamentos, deslocamentos, surgências, erosões superficiais, presença de árvores, arbustos e tocas de animais, por exemplo. Cada tipo de anomalia impõe riscos de diferentes magnitudes, porém a combinação de diferentes incidentes ao longo da estrutura pode desencadear eventos em cadeia, culminando em potenciais acidentes e falhas estruturais.

Tabela 1 – Tipos comuns de anomalia em taludes de jusante de barragens de aterro.

Fonte: Adaptado de (ANA, 2016).




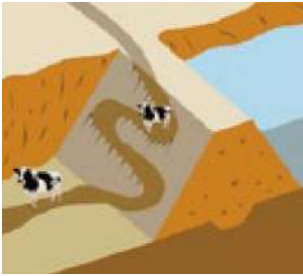
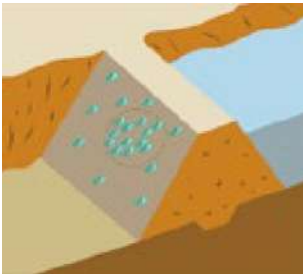
Anomalia	Causas Potenciais	Detalhamento
<p>Afundamentos</p> 	<p>Falta de compactação adequada, tocas de animais ou <i>piping</i> através do maciço ou fundação.</p>	<p>Indicação de possível erosão do maciço.</p>
<p>Árvores/Arbustos</p> 	<p>Vegetação natural da área.</p>	<p>Raízes profundas podem criar caminhos para passagem de água. Arbustos podem dificultar a inspeção visual e abrigar espécies de roedores.</p>
<p>Erosão</p> 	<p>Águas de chuva ou de galgamento carregam material da superfície do talude, produzindo valas de erosão.</p>	<p>Pode representar perigo em caso de não contenção. Erosões podem deteriorar o talude de jusante e causar a ruptura do maciço.</p>

Tabela 1 (continuação)

Anomalia	Causas Potenciais	Detalhamento
<p>Escorregamentos</p> 	<p>Falta ou perda da resistência do material do maciço da barragem. A perda de resistência pode ser atribuída à infiltração de água no maciço ou falta de suporte da fundação.</p>	<p>Deslizamento do maciço atingindo a crista ou o talude de montante, reduzindo a folga. Pode resultar no colapso do maciço ou transbordamento. Perigo Extremo.</p>
<p>Fissuras Longitudinais</p> 	<p>Ressecamento ou retração do material da superfície. Deformação a jusante devido ao recalque do maciço.</p>	<p>Podem ser avisos de futuros deslizamentos. Recalques ou deslizamentos mostrando a perda de resistência da barragem podem provocar ruptura.</p>
<p>Fissuras Transversais</p> 	<p>Recalque diferenciado do maciço da barragem provoca fissuras (rachaduras) transversais.</p>	<p>Fissuras pronunciadas devido a recalques ou retração podem provocar infiltrações de água do reservatório através da barragem. Perigo.</p>
<p>Tocas de Animais</p> 	<p>Grande quantidade de animais ou insetos. Buracos, túneis e cavernas construídos por animais como formigas, cupins ou tatus. A presença de espécies específicas de plantas e árvores nos arredores do reservatório podem atrair diferentes espécies de animais e insetos.</p>	<p>Criam passagens de água para dentro do maciço, saturando áreas adjacentes, potencialmente provocando rupturas localizadas. Podem reduzir o caminho de percolação de água e provocar <i>piping</i>. Especialmente perigosas quando atingem a linha freática.</p>

Tabela 1 (continuação)

Anomalia	Causas Potenciais	Detalhamento
Tráfego de Animais 	Tráfego constante ou ocasional da fauna local.	Danifica a proteção vegetal do talude de jusante. Permite acúmulo de água em pontos específicos. Cria áreas suscetíveis a fissuras por ressecamento. Especialmente danoso quando o talude está molhado.
Vegetação Alterada 	O material do maciço permite fluxo de água.	Pode indicar a existência de áreas saturadas.

Fissuras transversais são especialmente perigosas pois podem criar caminhos de percolação preferenciais para a água, resultando em uma potencial diminuição da resistência material do aterro (ANA, 2016). A ocorrência de deslizamentos nos taludes de jusante é fortemente relacionada com a estabilidade da estrutura, podendo provocar aumento da declividade do talude e perda de resistência do maciço. Outros elementos que em conjunto podem impactar na estabilidade do talude são as tocas de animais, árvores e arbustos.

Também é comum a ocorrência de erosões em taludes de jusante, que são caracterizadas por desgastes localizados resultantes da ação das águas do reservatório, da água da chuva, do vento, da presença de tocas de animais e de outros agentes externos. Os principais fatores que controlam processos morfodinâmicos e levam à erosão são a angulação do talude, as condições climáticas e atividades humanas (LÖBMANN et al., 2020). A presença de surgências é um indicativo de que há uma infiltração da água do reservatório no maciço, podendo causar erosão interna e comprometer a estabilidade da estrutura.

Técnicas de engenharia podem ser aplicadas para reforço da estabilidade estrutural e prevenção de acidentes em barragens de aterro. Soluções como pregagem do solo, reforço com geossintéticos, drenagem melhorada e estabilização do solo são efetivos porém demandam investimentos significativos (GREENWOOD et al., 2004; LÖBMANN et al., 2020). A utilização de proteção vegetal nas superfícies de terra inclinadas é uma prática




Figura 5 – Visão transversal dos efeitos da proteção vegetal na estabilidade estrutural de taludes de aterro. As forças de arrasto gravitacional ao longo do plano de cisalhamento, representadas pelas setas, induzem tensão na superfície do talude. A zona vegetada no topo do talude (I) apresenta maior estabilidade. As zonas (II-VII) tem maior potencial de falha. As zonas (II-IV) são zonas de tensão de tração. Zonas cujo enraizamento atravessa o plano de cisalhamento potencial apresentam maior estabilização contra a tensão de tração.

Fonte: Adaptado de Lobmann et al., 2020 (LÖBMANN et al., 2020).

comum e econômica para aumentar sua resistência a erosão.

A presença de cobertura vegetal no talude de jusante cumpre um papel chave na manutenção do solo e na estabilização dos taludes, provendo melhorias nas condições hidrológicas da estrutura e protegendo-a contra erosões causadas por galgamentos, chuvas e ventos (PEPPER, 2010). A proteção por vegetação é capaz de proteger não apenas a superfície do talude, mas também as profundezas do solo, a partir de efeitos hidrológicos e mecânicos (CAZZUFFI; CRIPPA, 2005).

Gramíneas com diâmetros de raízes reduzidos aumentam a estabilidade do talude. De forma análoga, a presença de tipos indesejados de vegetação pode acarretar em incidentes que impactam negativamente na estabilidade da estrutura. Sobrecargas podem ser causadas pelo peso de árvores e aumento da capacidade de infiltração pode ser causado pela penetração de raízes profundas no solo, por exemplo (CAZZUFFI; CRIPPA, 2005).

A Figura 5 (LÖBMANN et al., 2020) ilustra uma visão transversal de um talude de terra coberto por vegetação cujas raízes penetram o solo em diferentes níveis de profundidade. Na superfície do talude, área com alta densidade de vegetação, as raízes são mais numerosas e proporcionam alta resistência a cisalhamentos, estabilizando a encosta ao atravessarem planos de cisalhamento potencial. Na área intermediária, que conta com menor densidade de enraizamentos, a resistência ao cisalhamento é menor, porém a área ainda é beneficiada pela redistribuição do estresse e aumento da coesão do solo providos pela vegetação da superfície. A estabilidade das partes mais profundas e sem enraizamentos depende da compressão do solo e do efeito de arco nas laterais. Desta forma, a presença da cobertura vegetal adequada é de grande importância para a estabilização do talude, principalmente nas zonas intermediárias da superfície do talude.

No estudo conduzido por Pepper (2010), áreas com cobertura vegetal saudável e não-saudável foram testadas para avaliar a capacidade de erosão do solo e a importância da proteção vegetal para garantir a estabilidade do talude. Os autores encontraram maiores taxas de erosão em áreas de desvegetação e em áreas de grama alta, onde ocorre o sombreamento do solo exposto, dificultando a percepção visual. Também é necessário considerar a força da compactação do solo de cada área e definir a frequência correta de capinagem para manutenção adequada da vegetação.

Grande parte das anomalias que ocorrem em superfícies de taludes, diques e barragens de aterro citadas nesta seção são identificáveis por meio da inspeção visual, um dos principais métodos adotados para o monitoramento dessas estruturas geotécnicas. A inspeção visual periódica permite a descrição metódica e detalhada da fotografia da estrutura (DAS, 2011). Organizações responsáveis investem recursos financeiros consideráveis na realização de inspeções visuais periódicas para monitorar adequadamente a saúde estrutural de seus empreendimentos e para atingir, ao menos, a frequência mínima de inspeções *in loco* exigida pela legislação. O monitoramento contínuo baseado em estratégias multi-modais deve ser utilizado como base para a aquisição de informações essenciais para o desempenho da estrutura, facilitando o processo de tomada de decisão e permitindo a resposta rápida em caso de eventos extremos.

A detecção de danos por meio de rotinas de inspeção visual é especialmente relevante em estruturas de solo e rocha, que apresentam indicadores de falha que não podem ser diagnosticados diretamente pela instrumentação de campo ou por ensaios de laboratório (ARAÚJO, 2024). Entretanto, a metodologia e os resultados do processo de inspeção visual são fortemente dependentes da experiência profissional dos inspetores responsáveis e, portanto, sujeitos a subjetividades (PAN; CHEN, 2015). Este contexto destaca a necessidade do uso de sistema de apoio a tomada de decisão. Ferramentas promissoras tem sido construídas com base no conceito de Sensoriamento Remoto, discutido na seção seguinte.

## 2.2 Sensoriamento Remoto Multiespectral

Sensoriamento Remoto envolve a coleta remota de dados sobre a superfície terrestre, em geral por via de sensores embarcados em satélites ou em VANT e apresentados no formato de imagens RGB, multi ou hiperespectrais (HASAN et al., 2024). Na literatura relacionada, essas tecnologias tem sido utilizadas como ferramentas primárias de análise de dados em diversos campos como agricultura de precisão, monitoramento ambiental, gerenciamento de riscos e planejamento urbano. O sensoriamento remoto é especialmente importante para o monitoramento de estruturas geotécnicas, como taludes, diques e barragens, para a investigação de incidentes e acidentes (TEIXEIRA et al., 2021).




Figura 6 – Fatores que definem a Distância de Amostra do Solo (GSD), medida de resolução espacial utilizada em sensoriamento remoto para definir a distância entre os centros de dois *pixels* adjacentes.

Fonte: Adaptado de Dhari, 2024 (DHARI, 2024).

Tradicionalmente, as principais plataformas para coleta de dados para Sensoriamento Remoto eram satélites e aeronaves pilotadas em altitudes elevadas. Esses dados eram e ainda são utilizados para facilitar o entendimento das dinâmicas referentes aos estados físicos e processos que ocorrem na superfície (ASKAM et al., 2022). Entretanto, os dados coletados por esses instrumentos muitas vezes não apresentavam resoluções espaciais, i.e. *Ground Sample Distance* (Distância de Amostra do Solo) (GSD), e tem-

porais adequadas (NEBIKER et al., 2008). O GSD, representado pela Equação 2.1, é uma medida que representa a distância entre os centros de dois *pixels* adjacentes em uma imagem (LILLESAND et al., 2015). A figura 6 representa os fatores que definem o GSD em uma imagem de sensoriamento remoto.

$$\text{GSD} = \frac{S \times A}{I \times F} \quad (2.1)$$

Onde:

- $S$  representa a largura do sensor;
- $A$  representa a altitude da aeronave ou satélite;
- $I$  representa a largura da imagem;
- $F$  representa a distância focal do sensor.

É importante definir a resolução espacial adequada para cada tipo de aplicação. A Tabela 2 lista as características dos dados capturados pelos sensores embarcados nos quatro principais tipos de dispositivos remotos.

Tabela 2 – Características de resolução espacial (GSD), campo de visão, usabilidade e custos para aquisição de dados das quatro principais plataformas utilizadas em sensoriamento remoto.

(\*) O custo para aquisição de imagens de satélites é considerado muito alto, especialmente em casos de imagens estéreo de alta resolução, entretanto, é possível contar com a disponibilidade gratuita de dados de satélite em certas plataformas atuais.

Fonte: Adaptado de Candiago et al., 2015 (CANDIAGO et al., 2015).

Plataforma	GSD	Campo de Visão	Usabilidade	Custo
Satélite	1 a 25 <i>m</i>	10 a 50 <i>km</i>	-	Muito alto*
Aeronave	0.1 a 2 <i>m</i>	0.5 a 5 <i>km</i>	Piloto Necessário	Alto
Helicóptero	5 a 50 <i>cm</i>	0.2 a 2 <i>km</i>	Piloto Necessário	Médio
VANT	0.5 a 10 <i>cm</i>	50 a 500 <i>m</i>	Simples	Baixo


O sensoriamento remoto realizado a partir de imagens capturadas via satélite apresenta desafios relacionados não apenas ao alto GSD, mas também aos ruídos causados por efeitos atmosféricos (DAVIDSON et al., 2022). Estes fatores estão relacionados a distância entre os sensores embarcados no satélite e o solo. Estudos também apontam as discrepâncias entre IVs calculados para dados multiespectrais capturados via satélite e dados capturados a distâncias menores do solo, que minimizam os efeitos da atmosfera.

Recentemente, a popularização de VANTs tornou acessível a coleta de dados de sensoriamento remoto de alta resolução. Essas aeronaves, por serem pilotadas remotamente, são capazes de voar a baixas altitudes, reduzindo significativamente a ocorrência de ruídos causados por efeitos atmosféricos. Também em decorrência das altitudes relativamente baixas, dados de maior GSD podem ser adquiridos, alcançando valores na faixa de 0.5cm a 10cm de resolução espacial. O aumento da resolução espacial permite análises mais detalhadas de características que não seriam visíveis em dados aéreos ou de satélite de resolução mais baixa. Valores de GSD de aproximadamente 5cm são considerados suficientes para aplicações de agricultura de precisão, por exemplo (CANDIAGO et al., 2015).

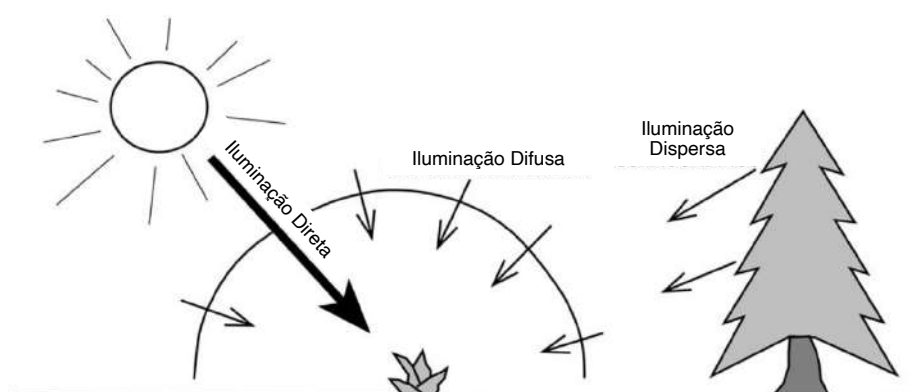
Todas as plataformas de sensoriamento remoto são amplamente utilizadas para a coleta de dados multi ou hiperespectrais, possibilitando a análise da resposta espectral de diferentes superfícies. A coleta e análise de dados dessa natureza cumpre o papel fundamental de identificar comportamentos de refletância de objetos e materiais particulares em diferentes épocas do ano (MCCOY, 2005). Com esses dados, busca-se a modelagem da interação da luz solar com os materiais biofísicos presentes na área, permitindo a avaliação das condições dos mesmos. O conceito de refletância, ilustrado pela Figura 7, compreende a capacidade de uma superfície de refletir a luz solar de acordo com suas características (SIMS; GAMON, 2002).

A incidência da radiação solar atinge a superfície terrestre a uma angulação que varia de acordo com o ângulo zenital e é refletida, absorvida ou transmitida pelos objetos presentes na área (MCCOY, 2005). Em um dia ensolarado e nas condições ideais, a radiação solar direta é a fonte de radiação dominante, representando cerca de 90% da energia incidente. A iluminação em cenários reais é mais complexa, pois os efeitos da atmosfera também influenciam as medições. O profissional responsável pela coleta de dados deve se atentar às condições da coleta para garantir que a radiação solar direta seja dominante durante todo o processo.

A medição da resposta espectral de uma determinada área de estudo resulta em uma curva espectral mista de todos os componentes existentes na superfície capturada, ressaltando a importância da diferenciação dos diferentes tipos de materiais e objetos presentes na imagem. Segmentação de *land cover* é um dos problemas clássicos de Sensoriamento Remoto que busca analisar características estruturais espaciais como cores e texturas da superfície terrestre em uma perspectiva *top-down* (WU et al., 2019). Essa diferenciação pode ser uma tarefa trivial ou complexa de acordo com os tipos de materiais presentes na superfície.



(a) A irradiação solar incide sobre a superfície a um ângulo que depende do ângulo zenital. Parte da radiação é refletida pela vegetação a um ângulo igual ao da irradiação.



(b) Em condições ideais de coleta de dados para sensoriamento remoto a luz solar é a fonte de irradiação dominante. Entretanto, os efeitos da iluminação difusa pela atmosfera e pela iluminação dispersa por outros objetos no local interferem na captação dos dados.

Figura 7 – Comportamento da incidência de irradiação solar sobre a vegetação.

Fonte: Adaptado de McCoy, 2005 (MCCOY, 2005).

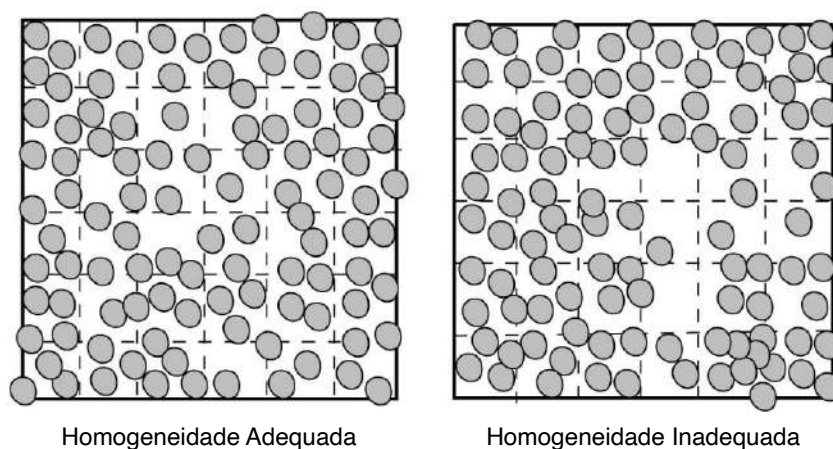


Figura 8 – A distribuição não homogênea dos objetos de interesse na imagem da direita é inadequada para a análise espectral da área.

Fonte: Adaptado de McCoy, 2005 (MCCOY, 2005).

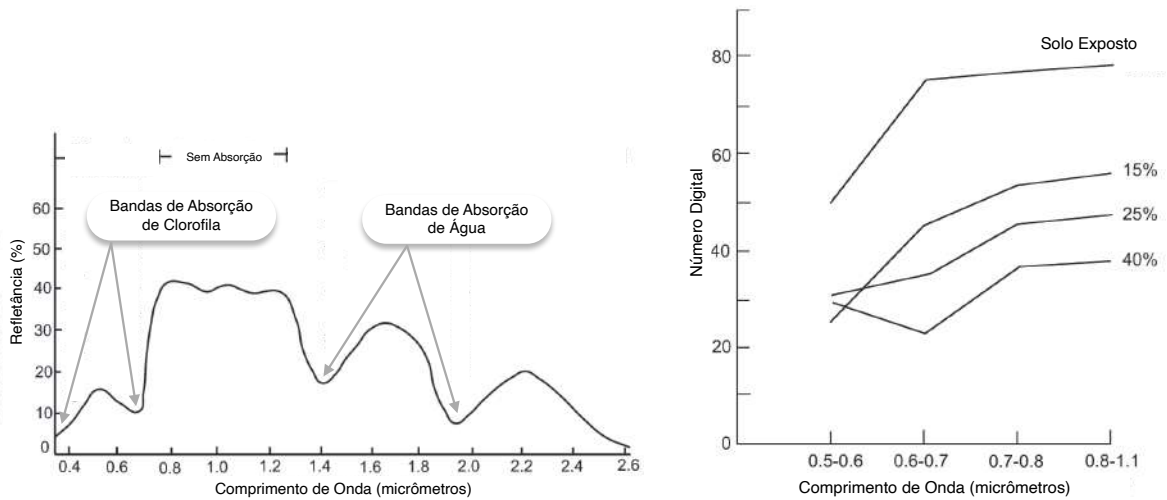
Ao selecionar uma área de coleta de dados, é necessário considerar a homogeneidade do terreno capturado. A amostra capturada deve conter apenas as características pertinentes às análises desejadas e com variações distribuídas uniformemente sobre a área de coleta. Desta forma, é possível distinguir e agrupar diferentes classes de elementos da superfície, caracterizadas pelas suas respectivas respostas espectrais (MCCOY, 2005). A Figura 8 ilustra a distribuição dos objetos de interesse ao longo da área de captura.

Também é importante entender que as respostas espectrais das superfícies exibem vieses baseados na orientação dos objetos de interesse, como a orientação do gramado. Portanto, é necessário manter a consistência das condições de aquisição de dados como horário de coleta e ângulação de câmera (MCCOY, 2005). Apesar das precauções, é inevitável a influência de fatores externos que impactam na qualidade dos dados coletados. Neste contexto, é comum assumir os seguintes fatores de simplificação:


- O campo de visão do sensor é conhecido;
- Os valores de refletância do painel de calibração radiométrica são conhecidos;
- Apenas as superfícies alvo são capturadas pelo sensor;
- A irradiância solar é constante durante a execução da coleta de dados;
- A irradiância solar durante a coleta é compatível com a capturada na imagem do painel de calibração;
- O sensor tem resposta linear a mudanças de radiação.

Um dos principais alvos de análises de resposta espectral é a vegetação. Aspectos biofísicos da vegetação como pigmentação, estrutura das células e conteúdo de água afetam a interação da cobertura vegetal com a incidência de irradiação solar (MCCOY, 2005). O estudo da refletância da vegetação é capaz de detectar variações dessas características, podendo indicar condições como desenvolvimento da vegetação, senescência, fertilidade, contaminação do solo, poluição do ar e ataque de pragas (SIMS; GAMON, 2002).

A pigmentação vegetal tem forte relação com a função fisiológica da vegetação, interagindo com os comprimentos de onda de 400 a 700  $\mu m$  do espectro eletromagnético visível e representando os níveis de antocianina, carotenóides e clorofila (SIMS; GAMON, 2002). Abundância de clorofila é caracterizada por alta reflexão da banda verde e absorção das bandas azul e vermelho, justificando a coloração esverdeada das plantas (CANDIAGO et al., 2015). De forma análoga, processos de desidratação e senescência minimizam a produção de clorofila, invertendo o comportamento de reflexão e absorção apresentados anteriormente e provocando um aspecto amarelo, marrom ou vermelho na vegetação (MCCOY, 2005).



- (a) Enquanto a absorção de clorofila é observada nas bandas do espectro de luz visível, a absorção de água ocorre em bandas do espectro não visível do infravermelho próximo.
- (b) Efeitos observáveis na refletância da superfície em diferentes níveis de exposição do solo devido a desvegetação.



- (c) O ressecamento da vegetação acarreta na redução de sua umidade, causando um aumento de intensidade da refletância e atenuação das bandas de absorção de água. As bandas de absorção do espectro visível tendem a desaparecer com o ressecamento.
- (d) A intensidade da refletância aumenta de acordo com a quantidade de camada de folhas existentes na superfície. Este efeito ocorre devido à absorção da irradiação solar, acarretando na transmissão de energia para as camadas mais internas da vegetação.

Figura 9 – Curvas típicas que descrevem a resposta espectral da vegetação.

Fonte: Adaptado de McCoy, 2005 (MCCOY, 2005).

O estudo da refletância da vegetação em comprimentos de onda visíveis cumpre um papel importante em tarefas de sensoriamento remoto, como a estimativa da área foliar. Entretanto, o comportamento espectral de certas espécies é indistinguível nas

bandas do espectro eletromagnético visível (MCCOY, 2005). Além disso, o conteúdo de água na vegetação só impacta a resposta espectral da mesma em estágios avançados de desidratação, quando as consequências começam a impactar em sua coloração. Esse cenário ressalta a importância de análises em comprimentos de onda não visíveis, como as bandas das regiões do vermelho de borda e infravermelho próximo.

A natureza da resposta espectral da vegetação muda drasticamente ao ultrapassar os comprimentos de onda do espectro da luz visível, permitindo a captação de nuances que facilitam a distinção dos efeitos da hidratação do solo e outros fatores. A interação observada na banda do infravermelho próximo não é determinada pela pigmentação, mas pela estrutura celular das plantas, pois ocorre a transmissão de energia para camadas mais internas da vegetação, atingindo o solo oculto (MCCOY, 2005). Esta propriedade facilita a distinção entre espécies e a estimativa da densidade da cobertura e biomassa (ROUSE; HAAS, 1974). A refletância elevada também facilita a distinção entre vegetação e outros tipos de superfícies, como solo e água.

Métodos tradicionais utilizados para análise de pigmentação vegetal e outras características são invasivos, pois acarretam na destruição das folhas utilizadas para medição, impedindo a análise temporal. Neste contexto, métodos de medição baseados na refletância espectral da vegetação e a modelagem matemática no formato de IVs surgem como uma forma eficiente, replicável não destrutiva e para o estudo da pigmentação vegetal, pois não dependem da coleta de material (GAMON; QIU, 1999). Outro motivo para a popularização dos IVs é a sua capacidade de simplificação da interpretação de dados multiespectrais (DAVIDSON et al., 2022).

Os IVs são modelos matemáticos utilizados no campo de sensoriamento remoto que avaliam e caracterizam a cobertura de uma determinada área conforme a sua refletância. Os índices são calculados a partir de combinações algébricas entre dados capturados em diferentes bandas do espectro eletromagnético, ressaltando propriedades referentes à saúde da vegetação, por exemplo (Gutierrez-Rodriguez et al., 2005). Uma listagem exaustiva dos IVs presentes na literatura pode ser encontrada na publicação de (ZENG et al., 2022). A Tabela 3 lista os principais IVs utilizados em estudos de sensoriamento remoto.

A análise da cobertura vegetal utilizando IVs para a extração de informações úteis pode ser conduzida com base em métricas estatísticas. Por exemplo, o cálculo da média do NDVI reflete um comportamento padrão de produtividade e biomassa da área calculada, enquanto o desvio padrão do mesmo pode indicar variabilidades espaciais na produtividade do campo (CANDIAGO et al., 2015).

Tabela 3 – Principais índices de vegetação utilizados em sensoriamento remoto. Nas equações apresentadas,  $\rho$  indica o intensidade de refletância para as bandas vermelha (*Red - R*), verde (*Green - G*), azul (*Blue - B*), vermelho de borda (*Red Edge - RE*) e infravermelho próximo (*Near Infrared - NIR*).

Fonte: Autor.

Índice	Formulação	Aplicação	Referência
NDVI	$\frac{\rho_{NIR} - \rho_R}{\rho_{NIR} + \rho_R}$	Indica o nível de biomassa na vegetação. Índice mais amplamente utilizado na literatura como indicador geral de saúde vegetal.	(ROUSE; HAAS, 1974)
GNDVI	$\frac{\rho_{NIR} - \rho_G}{\rho_{NIR} + \rho_G}$	Variação do NDVI com normalização pela banda verde. Relacionado a atividade fotossintética da vegetação, biomassa e área foliar. Maior sensibilidade à clorofila comparado ao NDVI.	(GITELSON et al., 1996)
SAVI	$\frac{\rho_{NIR} - \rho_R}{\rho_{NIR} + \rho_R + L} + (1 + L)$	Desenvolvido com o intuito de eliminar o efeito do solo em áreas de baixa cobertura vegetal ou com solo exposto. O parâmetro $L$ pode ser ajustado para valores entre -1.0 e 1.0 de acordo com a densidade de vegetação.	(HUETE, 1988)
NDRE	$\frac{\rho_{NIR} - \rho_{RE}}{\rho_{NIR} + \rho_{RE}}$	Índice normalizado pela banda vermelho de borda, baseado na posição do comprimento de onda da transição entre a baixa refletância na região vermelha do espectro e a alta refletância no infravermelho próximo. Apresenta resultados consistentes entre diferentes estruturas vegetais e são menos sensíveis a efeitos oriundos de superfícies não vegetadas.	(SIMS; GAMON, 2002)

IVs distintos apresentam respostas e níveis de resistência diferentes a efeitos causados pelo solo e pela atmosfera. O *Normalized Difference Vegetation Index* (Índice de Vegetação por Diferença Normalizada) (NDVI) apresenta maior sensibilidade aos efeitos do solo quando comparados ao *Soil Adjusted Vegetation Index* (Índice de Vegetação Ajustado ao Solo) (SAVI), especialmente em casos de vegetação esparsa. A coloração do solo também impacta o resultado dos IVs (ZENG et al., 2022). Solo mais claro e de maior refletância pode aumentar o denominador do índice, gerando valores menores de NDVI, por exemplo. Em contrapartida, solo mais escuro ou úmido tende a aumentar os valores do índice.

Apesar de ser o índice mais utilizado na literatura de sensoriamento remoto como indicativo de saúde vegetal, estudos apontam desvantagens do NDVI ao lidar com imagens de alta densidade de vegetação (GU et al., 2013) e os grandes desvios causadas por variações de brilho no solo (TODD; HOFFER, 1998). Estes problemas de saturação do NDVI foram mitigados com a introdução do *Normalized Difference Red Edge* (Diferença Normalizada no Vermelho de Borda) (NDRE) (DAVIDSON et al., 2022). Índices baseados em bandas do vermelho de borda não são baseados na refletância do solo propriamente dita, mas na posição do comprimento de onda da transição entre a baixa refletância na região vermelha do espectro e a alta refletância no infravermelho próximo. Índices que utilizam o vermelho de borda apresentam resultados consistentes entre diferentes estruturas vegetais e são menos sensíveis a efeitos oriundos de elementos não vegetais presentes na imagem (SIMS; GAMON, 2002).

Embora os Índices de Vegetação (IV) e suas análises estatísticas sejam úteis para avaliar a saúde da vegetação, técnicas de ML e DL também são empregadas para extrair padrões de imagens de sensoriamento remoto. A próxima seção abordará a aplicação de ML e DL nesse contexto.

## 2.3 Machine Learning em Visão Computacional

Técnicas de visão computacional buscam emular a percepção visual humana, que compreende o ato de observar padrões através de informações visuais e interpretá-los para que haja o entendimento do ambiente no qual o sistema está inserido (ELGENDY, 2020). A Visão Computacional é uma área interdisciplinar que envolve conhecimentos de áreas como processamento de imagens, aprendizado de máquina e sensoriamento remoto. Modelos de ML tradicional e também de DL tem sido amplamente utilizados na literatura para a análise de imagens de sensoriamento remoto (ZHANG et al., 2021; LV et al., 2023; LUO et al., 2024; HASAN et al., 2024). As subseções a seguir apresentam a fundamentação teórica necessária sobre a tarefa de segmentação semântica, sobre os algoritmos utilizados neste trabalho e sobre as métricas de avaliação de desempenho utilizadas.

### 2.3.1 Segmentação Semântica

No campo de visão computacional existem diferentes desafios a serem tratados pelas técnicas e modelos. Cada tarefa utiliza técnicas distintas e conta com diferentes formas de representar os dados de entrada e saída. A segmentação semântica é uma tarefa de visão computacional que objetiva a classificação a nível de pixel (Figura 10), dividindo a imagem em múltiplas regiões de interesse de acordo com as características de cada categoria pré-definida (GUO et al., 2020; LV et al., 2023; HASAN et al., 2024). A identificação da classe pertencente a cada pixel é de grande importância para o entendimento do contexto da imagem. Tarefas de segmentação semântica podem ser resolvidas com o uso de métodos baseados em índices, limiares, clusterização e algoritmos de ML (LV et al., 2023; LUO et al., 2024).

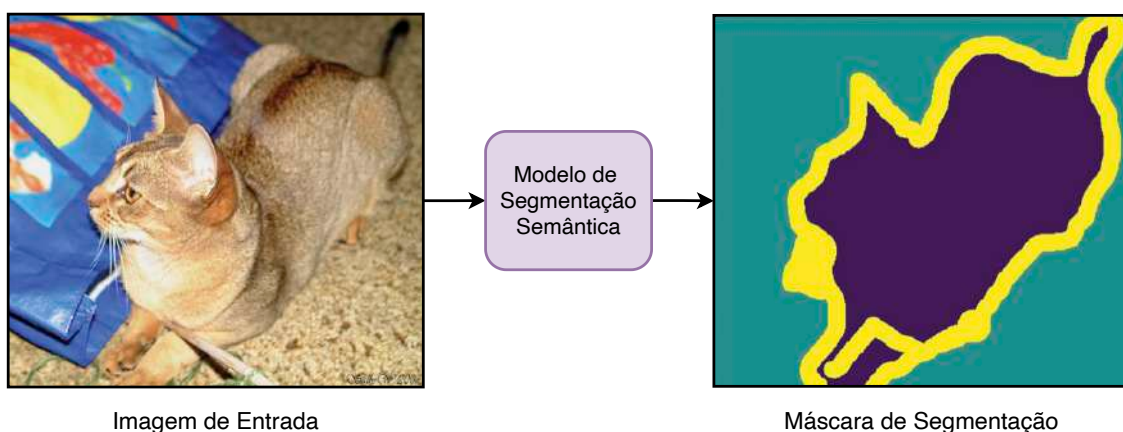


Figura 10 – A saída de um modelo de segmentação semântica, denominada máscara de segmentação, indica a classe atribuída a cada pixel da imagem de entrada.

Fonte: Autor. Adaptado de Chollet, 2021 (CHOLLET, 2021).

Métodos baseados em índices utilizam combinações algébricas entre dados do espaço de cores RGB e de brilho para calcular uma pré-segmentação, que facilita a definição de limiares. Tais métodos apresentam maiores vantagens quando dados multi ou hiperespectrais estão disponíveis, possibilitando a geração de índices mais diversos e informativos. Entretanto, a segmentação baseada em índices é sensível à variações de iluminação e sombreamento, requerendo ajustes dos limiares para atingir resultados satisfatórios (RIEHLE et al., 2020).

Métodos baseados em limiares julgam os níveis de similaridade entre os pixels com base no histograma de cores. Ao encontrar os limiares que separam adequadamente as classes de interesse é possível realizar a segmentação semântica da imagem. O método de Otsu (OTSU et al., 1975) é capaz de calcular automaticamente valores de limiares com base na minimização da dispersão intraclasse e na maximização da dispersão interclasse. Os limiares encontrados são utilizados para binarizar os valores dos índices. Entretanto, este método de segmentação apresenta limitações em cenários de baixa separabilidade entre as classes, como em imagens com iluminação não uniforme ou ruídos significativos.

Métodos baseados em clusterização utilizam algoritmos de agrupamento para segmentar a imagem de acordo com a similaridade entre os pixels de cada área. Algoritmos como o *K-Means* são capazes de agrupar os pixels em regiões de acordo com a distância euclidiana entre eles. A clusterização é uma técnica eficiente para segmentação de imagens com poucas classes, mas apresenta dificuldades em imagens com muitas classes e com variações de iluminação.

Para superar a baixa capacidade de generalização dos métodos tradicionais, algoritmos de ML tradicional foram introduzidos como alternativa no campo da segmentação semântica (HASAN et al., 2024). Algoritmos como o *Random Forests* (RF) apresentam bons resultados para segmentação ao serem aliados com técnicas de pré-processamento e extração de *features* adequadas para descrever os padrões das imagens (YANG et al., 2015; LINHUI et al., 2021). No campo de VC e processamento de imagens, o conceito de *feature* inclui características como linhas, formas, texturas e cores, por exemplo (ELGENDY, 2020).

Métodos de Deep Learning para segmentação semântica eliminam a necessidade de extração manual de *features* e apresentam maior robustez em sua capacidade de generalização. A introdução da aprendizagem automática de padrões oferecida por modelos de Redes Neurais Artificiais (RNAs) e Redes Neurais Convolucionais (RNCs) gerou consideráveis ganhos de performance em tarefas de segmentação, permitindo a análise de cenários complexos (LV et al., 2023; HASAN et al., 2024).

### 2.3.2 Random Forests

Originalmente proposto por Berman em 2001 (Leo Berman, 2001), o RF é um algoritmo tradicional e consolidado de aprendizado de máquina supervisionado não-paramétrico baseado na combinação de múltiplos modelos de árvores de decisão. No modelo de árvore de decisão exemplificado na Figura 11, cada nó interno representa uma decisão baseada no valor de uma *feature* do conjunto de dados. O conjunto de *features* de entrada é inserido no modelo e percorre a árvore, que realiza decisões hierárquicamente até alcançar um nó folha, que representa a classe de saída do modelo.




Figura 11 – Estrutura hierárquica de uma Árvore de Decisão.

Fonte: Autor.

Sendo um modelo baseado em *ensemble*, a saída resultante do RF é definida pela moda das saídas dos modelos individuais (LINHUI et al., 2021; WU et al., 2019). O funcionamento do conjunto de árvores de decisão do RF é ilustrado na Figura 12. A abordagem de *ensemble* acarreta em melhorias na capacidade de generalização do modelo ao utilizar diferentes subconjuntos de dados de treinamento para a aprendizagem de cada árvore de decisão.

O número de árvores de decisão individuais que compõem o RF pode ser configurado para controlar a complexidade do modelo final. Diferente de outros algoritmos de ML, o RF é capaz de mensurar e ordenar a contribuição de cada variável do conjunto de dados no processo de classificação dos dados de entrada (GUO et al., 2020), aumentando a interpretabilidade do modelo e dos resultados.

A eficiência computacional do RF permite o uso de conjuntos de dados de tamanho considerável, tornando este algoritmo popular para aplicações de segmentação semântica em sensoriamento remoto (WU et al., 2019; RIEHLE et al., 2020; LINHUI et al., 2021). É possível tratar o problema de segmentação semântica como uma tarefa de classificação

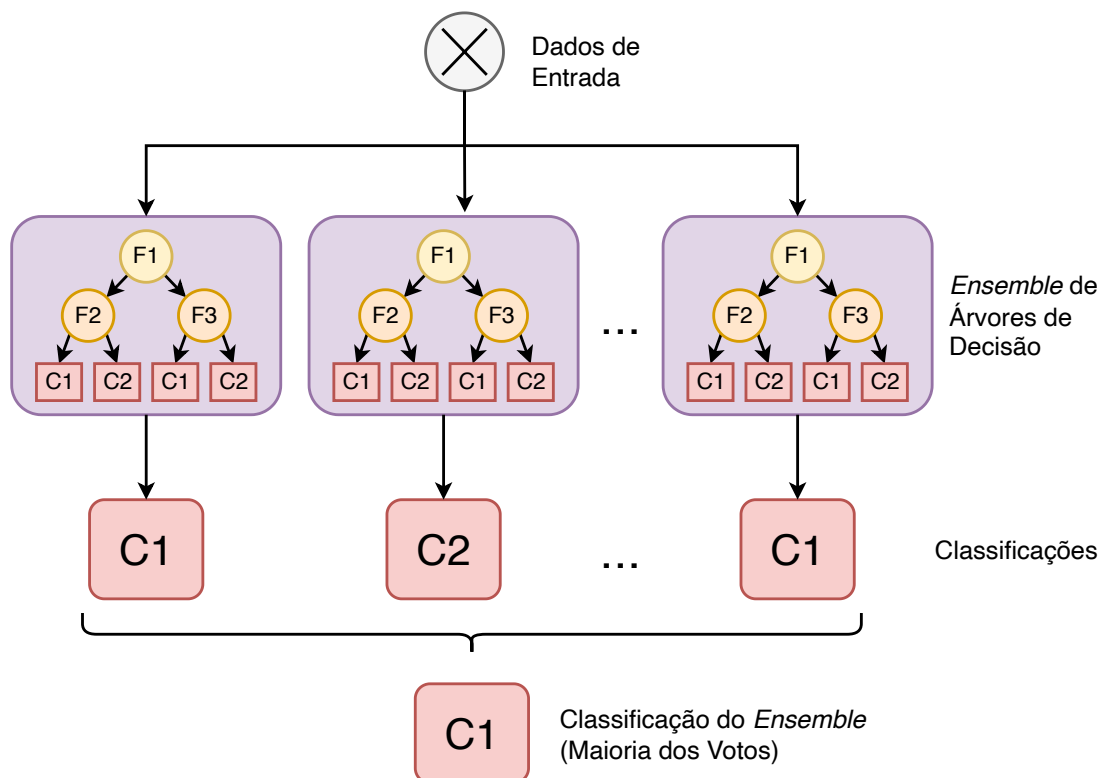


Figura 12 – No algoritmo de Random Forests, múltiplas classificações dos dados de entrada são realizadas pelo *ensemble* de árvores de decisão. A classificação final é dada pela moda dos votos realizados por modelos individuais.

Fonte: Autor.

de pixels individuais, onde as *features* computadas para cada pixel são inseridas como entrada para o modelo.

### 2.3.3 Redes Neurais Convolucionais

Redes Neurais Convolucionais (RNCs) são modelos de DL desenvolvidos com inspiração no funcionamento do córtex visual de felinos (HUBEL et al., 1959) com o objetivo de extrair padrões em dados estruturados que apresentam dependências espaciais locais (AGGARWAL, 2018). O principal exemplo de dados utilizados para treinar RNCs são imagens, embora os modelos também sejam utilizados para extração de padrões em dados de áudio, texto e séries temporais, por exemplo. A principal vantagem das RNCs está em sua capacidade de extração automática de padrões invariantes a posição e escala (ZHANG et al., 2021).

A arquitetura de uma (RNC) é composta, em sua maioria, por operações de convolução, agrupamento (*pooling*) e funções de ativação. Em cada camada, os dados são representados no formato de tensores tridimensionais com altura, largura e profundidade

(canais de cores), denominados mapas de características. Os parâmetros treináveis das RNCs são organizados em conjuntos de estruturas tridimensionais denominadas filtros, ou *kernels* convolucionais (CHOLLET, 2021). Os filtros convolucionais são utilizados para amplificar os padrões pertinentes ao domínio da aplicação, filtrando as informações irrelevantes durante a operação de convolução (ELGENDY, 2020). Os filtros localizados nas primeiras camadas da rede realizam o aprendizado de padrões primários, que aumentam de complexidade em camadas mais profundas da RNC (AGGARWAL, 2018).

Na operação de convolução, ilustrada pela Figura 13, ocorre o deslizamento de cada filtro convolucional (indexado por  $p$ ) ao longo de cada posição possível  $(i, j)$  da imagem de entrada na primeira camada, ou dos mapas de características nas camadas seguintes, calculando o produto escalar entre ambos (CHOLLET, 2021; AGGARWAL, 2018). O resultado da operação de convolução é um mapa de características que representa a ativação de padrões específicos detectados na imagem de entrada.

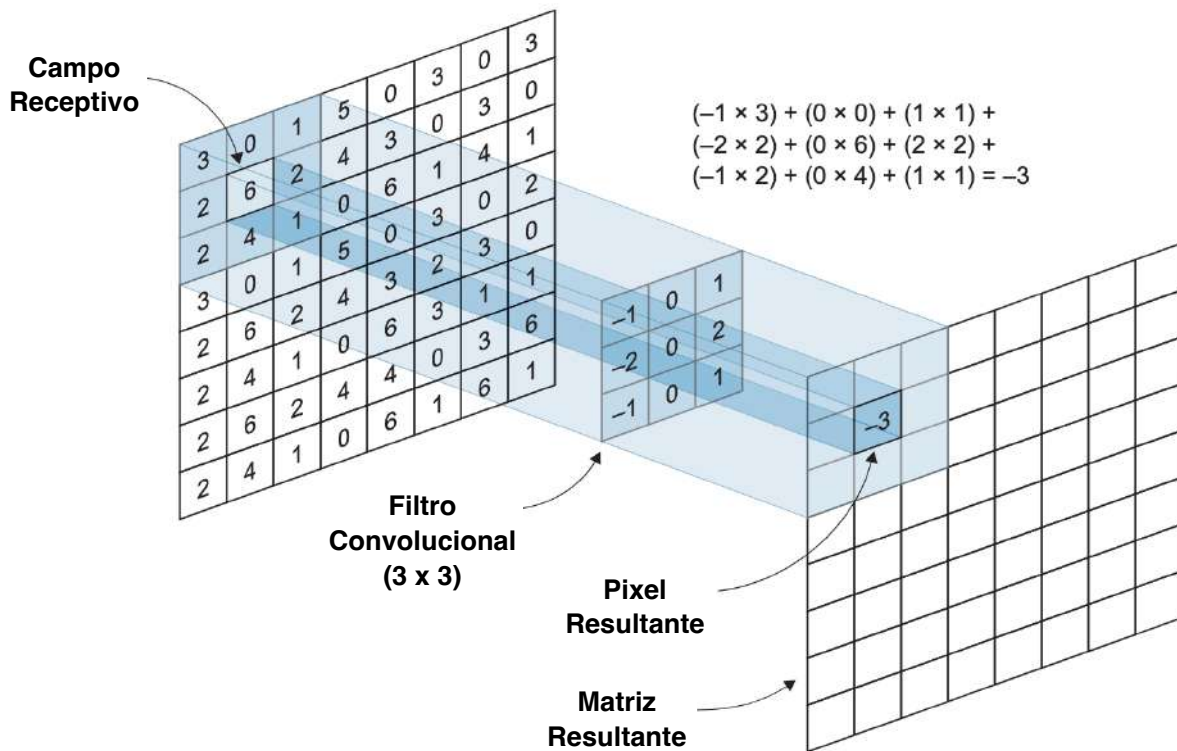


Figura 13 – Operação de convolução de um filtro de dimensões  $3 \times 3$  sobre um mapa de características, resultando no mapa de características da camada seguinte.

Fonte: Adaptado de Elgandy, 2020 (ELGENDY, 2020).

A operação matemática que descreve a convolução do filtro convolucional  $p$  na camada  $q$ , cujos parâmetros são representados pelo tensor tridimensional  $W^{(p,q)} = [w_{ijk}^{(p,q)}]$ , é apresentada na Equação 2.2 (AGGARWAL, 2018). Os índices  $i, j, k$  representam as posições ao longo da altura, largura e profundidade do filtro. Os mapas de características

da camada  $q$  são representados pelo tensor tridimensional  $H^{(q)} = [h_{ijk}^{(q)}]$ . Na ocasião especial em que  $q = 1$ , a notação  $H^{[1]}$  representa a camada de entrada.

$$h_{ijp}^{(q+1)} = \sum_{r=1}^{F_q} \sum_{s=1}^{F_q} \sum_{k=1}^{d_q} w_{rsk}^{(p,q)} h_{i+r-1, j+s-1, k}^{(q)} \quad (2.2)$$

$$\forall i \in \{1, \dots, L_q - F_q + 1\},$$

$$\forall j \in \{1, \dots, B_q - F_q + 1\},$$

$$\forall p \in \{1, \dots, d_{q+1}\}$$

Onde:

- $W^{(p,q)} = [w_{ijk}^{(p,q)}]$ : Tensor tridimensional dos parâmetros do filtro  $p$  na camada  $q$ .
- $H^{(q)} = [h_{ijk}^{(q)}]$ : Tensor tridimensional dos mapas de características na camada  $q$ .
- $h_{ijp}^{(q+1)}$ : Elemento no mapa de características  $p$  na camada  $(q + 1)$ , na posição  $(i, j)$ .
- $F_q$ : Dimensão do filtro na camada  $q$ .
- $d_q$ : Número de mapas de características (ou profundidade) na camada  $q$ .
- $L_q$ : Altura do mapa de características na camada  $q$ .
- $B_q$ : Largura do mapa de características na camada  $q$ .

Camadas de agrupamento, ou *pooling*, são geralmente inseridas em RNCs entre sequências de camadas convolucionais para realizar a sub-amostragem dos mapas de características, o que resulta no aumento dos campos receptivos e na redução da dimensionalidade dos dados (AGGARWAL, 2018). O redimensionamento é realizado ao aplicar uma função de sumarização estatística como o Agrupamento Máximo ou o Agrupamento Médio, que reduz o número de parâmetros que passam para a camada seguinte (ELGENDY, 2020). A operação de agrupamento mais utilizada em arquiteturas de RNC é a do Agrupamento Máximo, representada pela Equação 2.3.

$$MaxPooling(X)_{i,j,c} = \max_{m,n} (X_{i+m, j+n, c}) \quad (2.3)$$

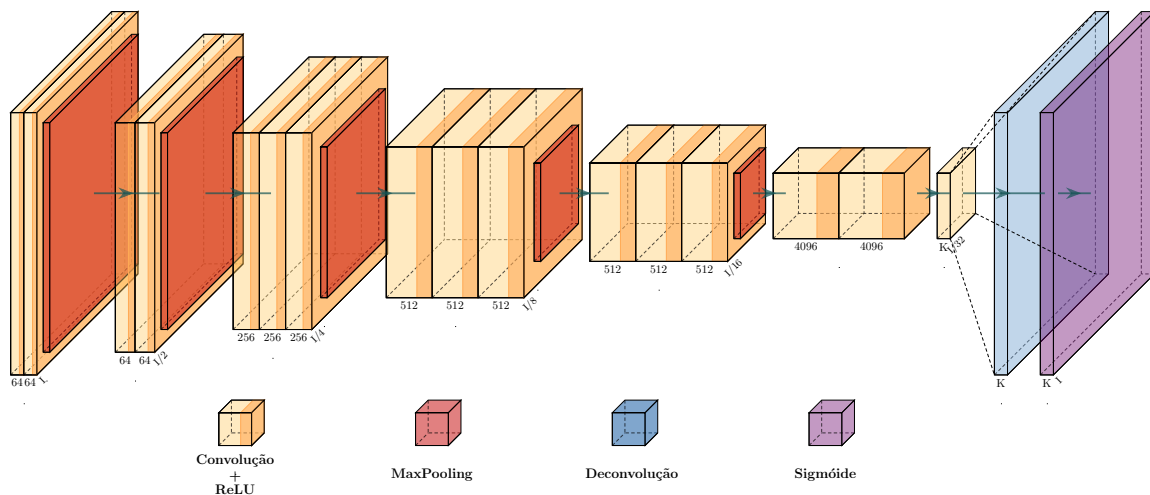
Onde:

- $MaxPooling(X)_{i,j,c}$  representa o valor da saída da operação de Agrupamento Máximo na posição  $(i, j)$ ;

- $c$  representa a dimensão dos canais de cores;
- $X_{i+m,j+n,c}$  representa os valores de entrada no canal  $c$  que estão dentro da janela de agrupamento que mapeia para a saída  $MaxPooling(X)_{i,j,c}$ ;
- $max_{m,n}$  representa a função que retorna o valor máximo dentro da janela de agrupamento de dimensões  $(m, n)$ ;

Originalmente, as RNCs eram empregadas para solucionar problemas de classificação realizada a nível de imagens, em que a saída do modelo representa uma única classe assinalada para os dados de entrada (GUO et al., 2020). Arquiteturas clássicas de RNC como a AlexNet (KRIZHEVSKY et al., 2012), VGG16 (SIMONYAN; ZISSERMAN, 2015) e GoogLeNet (SZEGEDY et al., 2015) apresentam camadas densas responsáveis pela classificação baseada nos mapas de características gerados pelas camadas convolucionais. Esses modelos recebem entradas de dimensões fixas e descartam as informações espaciais da saída. Posteriormente, novos modelos foram desenvolvidos para outros tipos de tarefas com saídas estruturadas, como detecção de objetos com caixas delimitadoras, previsão de *keypoints* e segmentação semântica com máscaras de segmentação.

Figura 14 – Arquitetura de Rede Neural Totalmente Convolutiva (FCN32) proposta por Long et al. (2015).



Fonte: Autor

A introdução de modelos de *Fully Convolutional Networks* (Redes Totalmente Convolucionais) (FCN) por (LONG et al., 2015) apresentou os primeiros resultados do uso de RNCs para segmentação semântica. Arquiteturas baseadas em FCN são baseadas em módulos de codificação e decodificação, permitindo que a rede aceite entradas de dimensões arbitrárias e gere como saída imagens de mesmas dimensões (LUO et al., 2024). A arquitetura da FCN, ilustrada na Figura 14, substitui as camadas densas de classificação

por camadas de deconvolução para super-amostragem dos mapas de características, resultando em máscaras de segmentação na saída (RONNEBERGER et al., 2015; GUO et al., 2020).

Arquiteturas de RNC baseadas na estratégia de codificação-decodificação da FCN que compõem o estado-da-arte de segmentação semântica incluem a U-NET (RONNEBERGER et al., 2015) e a DeepLab (CHEN et al., 2016; CHEN et al., 2017a; CHEN et al., 2017b; CHEN et al., 2018). A publicação de (LUO et al., 2024) também destaca a capacidade das Redes Adversariais Generativas (GAN) para realizar tarefas de segmentação semântica. A presença da rede discriminadora nessas arquiteturas facilita o aprendizado da relação entre os pixels, frequentemente ignoradas em arquiteturas de RNC (ZHANG et al., 2021).

A arquitetura de FCN U-NET foi inicialmente proposta por Ronneberger et al., 2015 (RONNEBERGER et al., 2015), superando o estado da arte para segmentação semântica de imagens biomédicas e posteriormente tornando-se o modelo mais utilizado na literatura para tarefas de segmentação semântica (LV et al., 2023). Este modelo foi apresentado como um aprimoramento da arquitetura FCN (LONG et al., 2015), introduzindo conexões de salto entre diferentes estágios de sub e sobreamostragem. A arquitetura U-NET, representada na Figura 15, é composta por três seções distintas:

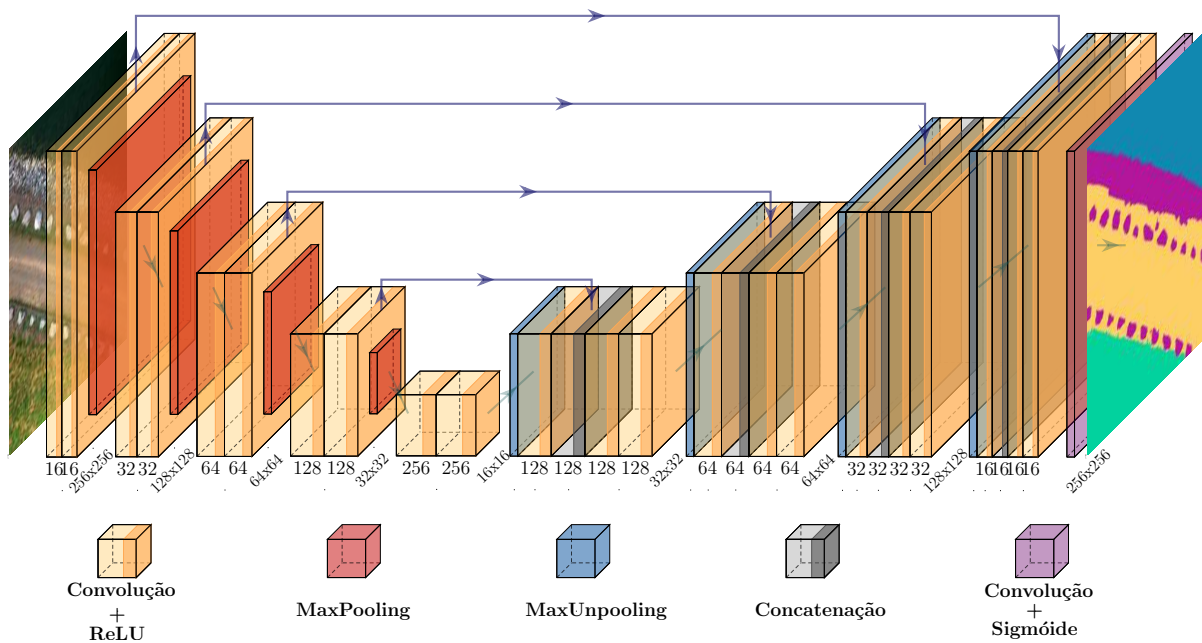


Figura 15 – Arquitetura da Rede Neural U-NET proposta por Ronneberger et al., 2015 (RONNEBERGER et al., 2015).

Fonte: Autor

- [1] **Caminho de Contração**, que segue o formato tradicional de CNNs incluindo

operações de convolução, sub-amostragem *MaxPooling* e funções de ativação ReLU, abstraindo as características da imagem de entrada em diferentes níveis;

- [2] **Caminho de Expansão**, simétrico ao caminho de contração, realiza a operação de deconvolução (LONG et al., 2015) para realizar a super-amostragem e reconstruir os mapas de características;
- [3] **Camada Convolutiva Final**, que gera saída de dimensões similares a de entrada, contendo as classificações a nível de pixel.

Adicionalmente, os mapas de características oriundos de cada etapa do caminho de contração são concatenados diretamente com os mapas de características equivalentes do caminho de expansão. Essas conexões de salto permitem a propagação de características espaciais de localização. As informações provenientes das conexões de salto aumentam a qualidade e a precisão da saída.

A U-NET apresenta como vantagem sua capacidade de extração de características a nível global e local, provendo alta performance em tarefas de segmentação semântica (LUO et al., 2024). Diversos trabalhos utilizam a arquitetura U-NET para a tarefa de segmentação semântica de imagens de sensoriamento remoto (BRAGAGNOLO et al., 2021; OSCO et al., 2021). Na literatura, a U-NET também apresenta vantagens em cenários de escassez de conjuntos de dados, superando modelos como SegNet, TLinkNet e DeepLabV3 (BRAGAGNOLO et al., 2021).

### 2.3.4 Redes Adversariais Generativas Condicionais

As Redes Adversariais Generativas, do inglês *Generative Adversarial Networks* (GAN), representam uma classe de algoritmos de IA capazes de gerar novos dados com distribuições semelhantes às de um conjunto de dados de treinamento (GOODFELLOW et al., 2020). Esses modelos representaram uma revolução nas técnicas de geração de dados sintéticos com DL. Uma rede GAN é caracterizada pelo uso de dois modelos distintos em seu processo de treinamento: o Gerador ( $G$ ) e o Discriminador ( $D$ ) (ZHANG et al., 2021). A Figura 16a apresenta um diagrama do funcionamento de uma rede GAN.

O modelo Discriminador  $D$  é responsável por analisar a distribuição e características dos dados de entrada a fim de classificá-los como reais ou falsos. O modelo Gerador  $G$  é responsável por mapear vetores aleatórios e imagens de saída  $G : z \rightarrow y$ , ou seja, transformar dados de entrada  $z$  em saídas  $y$  que sigam distribuições semelhantes aos dados de treinamento reais (ISOLA et al., 2018), dificultando a tarefa de diferenciação do discriminador. A concorrência entre os dois modelos resulta em uma arquitetura capaz de transformar sinais de entrada ruidosos em imagens sintéticas convincentes a ponto de serem aprovadas pelo discriminador (LV et al., 2023).

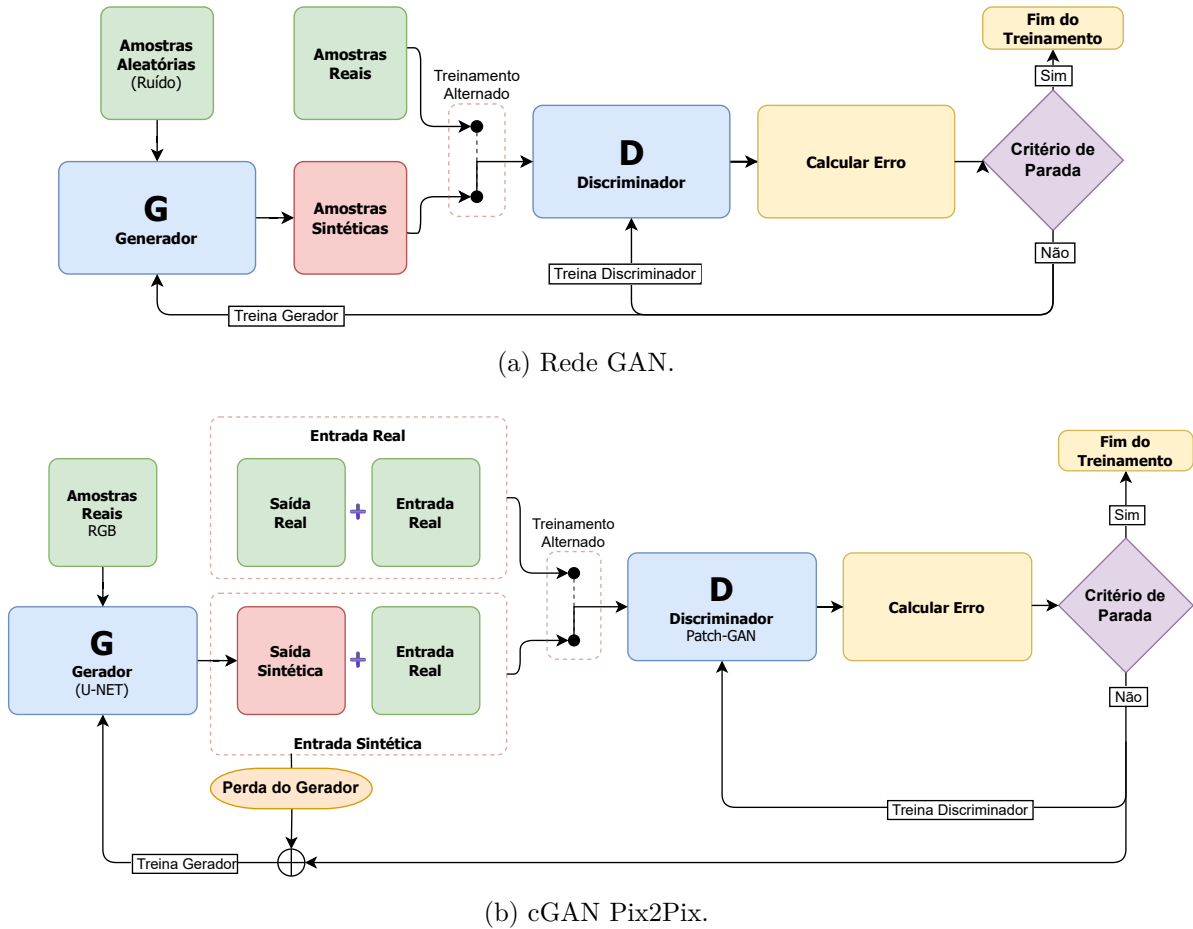


Figura 16 – Arquitetura Redes Adversariais Generativas (GAN) e Rede GAN Condicional Pix2Pix.

Fonte: Adaptado de (ZHANG et al., 2021).

Modelos GAN tradicionais são treinados para mapear vetores aleatórios  $z$  a saídas  $y$  sem considerar informações adicionais ( $G : z \rightarrow y$ ). Os autores de Isola et al. (ISOLA et al., 2018) exploram a possibilidade de condicionar o modelo gerador a informações adicionais e propõem o modelo de *Conditional Generative Adversarial Network* (Rede Generativa Adversarial Condicional) (cGAN) Pix2Pix para a tarefa de tradução de imagens. Tradução de imagens consiste na transformação da imagem de entrada em uma outra possível representação da mesma, prevendo os pixels de saída com base nos pixels de entrada (ISOLA et al., 2018). O modelo cGAN é treinado para mapear pares de imagens de entrada  $x$  e vetores  $z$  às saídas  $y$ , ou seja,  $G : x, z \rightarrow y$ .

A Figura 16b ilustra o funcionamento do modelo Pix2Pix para tradução de imagens. Neste modelo, a rede discriminadora é treinada em pares de imagens, alternando o pareamento das entradas reais e os dois tipos de saída, reais e sintéticas. Desta forma, o aprendizado da representação das imagens de entrada no domínio de saída é condicionado aos dados de entrada. O modelo de rede geradora utilizado na arquitetura Pix2Pix é a

rede U-NET (RONNEBERGER et al., 2015), enquanto o modelo da rede discriminadora foi proposto pelos autores e denominada como PatchGAN. A rede PatchGAN penaliza as diferenças estruturais entre as imagens em segmentos da imagem, ou seja, a rede discriminadora é treinada para classificar se cada segmento de  $70 \times 70$  pixels da imagem de saída é real ou falso (ISOLA et al., 2018).

Este capítulo apresentou uma síntese do referencial teórico necessário para o entendimento desta tese de doutorado. O capítulo seguinte apresenta o levantamento do estado-da-arte relacionado ao uso de sensoriamento remoto multiespectral para monitoramento de estruturas geotécnicas.

---

## Trabalhos Correlatos

Esta pesquisa aborda a utilização de dados de sensoriamento remoto multiespectral capturados via VANT para a classificação de *land-cover* e análise da cobertura vegetal presente em taludes de jusante de barragens de terra. O levantamento de trabalhos correlatos evidenciou a lacuna na literatura de trabalhos que envolvam o uso de técnicas de ML no contexto de segurança de barragens, apesar da diversidade de trabalhos existentes para outros setores. Este capítulo apresenta uma revisão bibliográfica de trabalhos correlatos que abordam temas relacionados às seguintes palavras-chave: VANT, Multiespectral (MS), IV, ML Tradicional, DL, Vegetação (VEG), Segmentação (SEG) e Barragens (BRG). As referências selecionadas foram divididas em três eixos distintos, apresentados a seguir.

### 3.1 Sensoriamento Remoto para Classificação de Land-Cover

A literatura relacionada a sensoriamento remoto para classificação de *land-cover* e análises de vegetação utiliza dados capturados via satélite (AMMIRATI et al., 2022; BALANIUK et al., 2020; BRAGAGNOLO et al., 2021; CONCEIÇÃO et al., 2021; GUO et al., 2020; LINHUI et al., 2021; NOGUEIRA et al., 2020; Paredes-Gómez et al., 2020; WU et al., 2019; ASKAM et al., 2022) ou capturados via VANT (ASKAM et al., 2022; CANDIAGO et al., 2015; CHENG et al., 2024; DAVIDSON et al., 2022; LIMÃO et al., 2023; YIN et al., 2023; BEHERA et al., 2023; Gonzalez-Moodie et al., 2021; LUO et al., 2022; OSCO et al., 2021). A recente popularização dos VANTs tornou acessível a coleta de dados de sensoriamento remoto de alta resolução e baixo GSD, reduzindo significativamente a ocorrência de ruídos causados por efeitos atmosféricos e de iluminação por voarem a baixas altitudes (ASKAM et al., 2022). Apesar de mais acessíveis para coletar imagens tradicionais RGB, aplicações que necessitam de sensores multiespectrais ainda são limitadas devido ao alto custo dos equipamentos necessários (DAVIDSON et al.,

2022).

Um dos objetivos da presente pesquisa é de analisar imagens de sensoriamento remoto espectral para realizar a segmentação semântica de imagens aéreas de barragens de terra, o que configura um problema de *land-cover* (WU et al., 2019). A classificação de *land-cover* é um problema clássico abordado na literatura para diversas finalidades (HASAN et al., 2024), como monitoramento ambiental (LINHUI et al., 2021; BRAGAGNOLO et al., 2021; GUO et al., 2020; LUO et al., 2022; CONCEIÇÃO et al., 2021; AMMIRATI et al., 2022), agricultura (OSCO et al., 2021) e planejamento urbano (WU et al., 2019). A extração correta dos padrões que caracterizam diferentes classes de *land-cover* é essencial, pois possibilita a extração de pixels de interesse, utilizados para análises direcionadas.

Diferentes técnicas são utilizadas nos trabalhos correlatos para segmentação semântica e classificação de *land-cover*, incluindo abordagens tradicionais (MCCOOL et al., 2018; RIEHLE et al., 2020), técnicas de ML tradicionais aliadas a metodologias de seleção de *features* (CONCEIÇÃO et al., 2021; LINHUI et al., 2021; WU et al., 2019; LUO et al., 2022), ou aprendizado profundo (GUO et al., 2020; NOGUEIRA et al., 2020; BEHERA et al., 2023; OSCO et al., 2021; BRAGAGNOLO et al., 2021; Gonzalez-Moodie et al., 2021). Abordagens tradicionais, que podem ser baseadas em índices, limiares e clusterização, tendem a ter maior sensibilidade a interferências geradas por condições de iluminação e sombreamento (RIEHLE et al., 2020) e, portanto, menor acurácia e maior necessidade de ajustes manuais. Por outro lado, abordagens baseadas em ML tendem a ser mais robustas e menos sensíveis a interferências, sendo capazes de aprender padrões complexos e não-lineares presentes nos dados (HASAN et al., 2024).

Algoritmos tradicionais de ML apresentam bons resultados para segmentação semântica e classificação de *land-cover* em imagens de sensoriamento remoto ao serem aliados com técnicas de pré-processamento, extração e seleção de *features* adequadas (YANG et al., 2015; LINHUI et al., 2021). Essas abordagens apresentam como vantagens o menor custo computacional e a maior interpretabilidade dos critérios de decisão adotados pelos modelos.

O artigo de Linhui et al., 2021 (LINHUI et al., 2021) compara modelos de RF para classificação de tipos de floresta na província de Heilongjiang, China, em dados de sensoriamento remoto via satélite GF-2. A classificação é realizada a nível de pixel e conta com *features* extraídas manualmente que representam características de brilho, textura, entropia, elevação e índices de vegetação. O modelo final alcançou 83.16% de acurácia após um processo de seleção de *features* via ranqueamento baseado na contribuição de cada característica. A precisão e a sensibilidade do modelo alcançaram, respectivamente, faixas de 75.58% a 89.04% e 78.31% a 90.12% para os seis tipos de floresta analisados. Os testes foram replicados utilizando modelos de *Support Vector Machines* (Máquina de

Vetores de Suporte) (SVM), porém os resultados obtidos foram inferiores aos computados para RF.

O estudo de Wu et al., 2019 (WU et al., 2019) também utiliza o algoritmo RF para a classificação de *land-cover* em imagens do satélite GF-2, porém para cenários urbanos. *Features* foram extraídas com base nas bandas espectrais capturadas, NDVI, LiDAR e características da imagem como média, variância, homogeneidade, contraste e entropia. O processo de ranqueamento também foi aplicado neste trabalho, apontando a maior significância da banda infravermelho próximo, características derivadas dos dados de LiDAR e NDVI. Ambos os trabalhos (LINHUI et al., 2021; WU et al., 2019) utilizaram o agrupamento de diferentes conjuntos de características para diferentes cenários de classificação e evidenciar os tipos de *features* mais relevantes. Resultados satisfatórios para o uso do algoritmo RF também são alcançados por Conceição et al., 2021 (CONCEIÇÃO et al., 2021), Paredes-Gomez et al., 2020 (Paredes-Gómez et al., 2020) e Luo et al., 2022 (LUO et al., 2022).

A seleção de *features*, geralmente necessária ao utilizar algoritmos tradicionais de ML, é realizada manualmente, podendo ser demorada e dependente dos conhecimentos específicos de profissionais, pertinentes ao domínio do problema (ELGENDY, 2020). A necessidade de extração manual de *features* é eliminada com a introdução de modelos de DL, que são capazes de aprender os padrões diretamente dos dados, extraindo *features* automaticamente para a geração de mapas de características (ELGENDY, 2020). Diversos trabalhos correlatos utilizam modelos de DL para tarefas sensoriamento remoto (GUO et al., 2020; NOGUEIRA et al., 2020; BEHERA et al., 2023; OSCO et al., 2021; BRAGAGNOLO et al., 2021; Gonzalez-Moodie et al., 2021).

O monitoramento florestal também é abordado por Bragagnolo et al., 2021 (BRAGAGNOLO et al., 2021), que identifica áreas florestais em imagens de satélite capturadas na região da floresta amazônica. Diferentes modelos de FCN, incluindo FCN32 (LONG et al., 2015), U-NET (RONNEBERGER et al., 2015), DeepLabV3 (CHEN et al., 2018) e SegNet (BADRINARAYANAN et al., 2017) foram treinados para a segmentação semântica binária das florestas baseadas em um conjunto de dados reduzido de 60 imagens RGB, emulando a frequente escassez de dados e ausência de informações do espectro eletromagnético não visível. Neste cenário de dados escassos e RGB, o modelo U-NET apresentou resultados superiores para segmentação. As máscaras resultantes são posteriormente utilizadas para mapear regiões de desflorestamento com base na matriz de diferenças entre máscaras de segmentação computadas em dados de diferentes datas. Nogueira et al., 2020 (NOGUEIRA et al., 2020) também compara o desempenho dos modelos de FCN do estado-da-arte para o mapeamento de erosões ao longo de ferrovias em imagens de satélite. Apesar de todos os modelos testados apresentarem resultados satisfatórios nesta aplicação, o modelo denominado *Dynamic Dilated Convolutional Network* apresentou

melhor desempenho.

Abordagens similares para classificação de *land-cover* e segmentação semântica utilizando modelos de FCN podem ser identificadas na literatura relacionada. Soluções para mapeamento de cobertura de neve são propostas por Guo et al., 2020 (GUO et al., 2020), que utiliza o modelo DeepLabV3 com transferência de aprendizado da rede neural pré-treinada Xception65 para segmentação binária de imagens de satélite, alcançando IoU médio de 91.5%. A técnica de transferência de aprendizado permite que os pesos treinados em modelos robustos sejam ajustados, i.e. ajuste fino (*fine tuning*), para especializá-los em outro domínio de conhecimento (GUO et al., 2020; ELGENDY, 2020; CHOLLET, 2021). Em contraste aos modelos robustos, Behera et al., 2023 (BEHERA et al., 2023) apresenta uma arquitetura simplificada de FCN, testada em dois conjuntos de dados voltados para classificação de *land-cover* de rodovias, veículos e vegetação, alcançando IoU média de 82% e 72%. No quesito de custo computacional, o modelo proposto conta com uma redução de 8.4 milhões de parâmetros em relação ao menor modelo da literatura, tornando-o ideal para ser embarcado em sistemas de baixa capacidade.

Técnicas de classificação de *land-cover* são aplicadas em conjunto com outras metodologias para a análise das classes segmentadas, principalmente de classes referentes a vegetação. Ammirati et al., 2022 apresenta uma metodologia para mapear a área afetada pelo colapso da barragem de rejeitos B1, ocorrido em Brumadinho, Brasil. As assinaturas espectrais de elementos como água, vegetação, barragens de rejeitos e áreas de mineração foram analisadas com o auxílio da técnica de *spectral unmixing*, muito utilizada em imagens de satélite, que apresenta a fusão de diferentes materiais em um único pixel. Os mapas de land cover de antes e depois do evento permitiram a análise das consequências da tragédia envolvendo a barragem.

## 3.2 Análise do Perfil Espectral de Diferentes Materiais

A análise do perfil espectral de diferentes materiais também é realizada na literatura correlata (CANDIAGO et al., 2015; ASKAM et al., 2022; Paredes-Gómez et al., 2020). Candiago et al., 2015 (CANDIAGO et al., 2015) investiga o uso de fotogrametria multiespectral com VANTs para análises de vinícolas baseadas em índices de vegetação. Os autores destacam a importância da correta segmentação das áreas de interesse para mitigar interferências causadas por pixels de áreas externas. O trabalho de Askam et al., 2022 (ASKAM et al., 2022) utiliza dados multiespectrais temporais capturados via satélites e VANTs para avaliar o impacto causado pela instalação de mini-barragens em Montana, EUA. A análise é baseada no índice de vegetação aprimorado, desenvolvido para áreas de vegetação com alto valor de biomassa (ASKAM et al., 2022). Por fim, o trabalho de Paredes-Gomez, 2020 (Paredes-Gómez et al., 2020) propõe um método

para diferenciação de áreas com vegetação irrigada e não-irrigada baseada na assinatura espectral e na classificação via RF.

Métodos que utilizam padrões extraídos nas bandas não-visíveis do espectro eletromagnético contam com um maior número de padrões descritivos em imagens de vegetação. Entretanto, trabalhos relacionados foram desenvolvidos apenas com dados RGB tradicionais, atingindo métricas de desempenho satisfatórias para classificação de espécies de vegetação e estimativa da cobertura vegetal (MCCOOL et al., 2018), segmentação de vegetação (BEHERA et al., 2023) e mapeamento de atividades de desmatamento (BRAGAGNOLO et al., 2021).

A análise da literatura revela a variedade de publicações que utilizam técnicas de sensoriamento remoto para tarefas de classificação de *land-cover* e análise da assinatura espectral da vegetação. Porém, trabalhos que aplicam essas técnicas para a análises relacionadas ao monitoramento de barragens de terra é escassa. A presente pesquisa tem como hipótese que a utilização de VANTs para a coleta automatizada de dados multiespectrais de alta resolução, aliada a técnicas de ML para classificação de *land-cover* e análise da cobertura vegetal, contribui na precisão e eficiência do monitoramento de cobertura vegetal dessas estruturas geotécnicas.

A escassez de trabalhos publicados na área pode ser explicada pelo ceticismo da área de engenharia civil em relação a aplicação de técnicas de IA e VC em seus processos, característica identificada por Zhang et al., 2021 (ZHANG et al., 2021) e Phoon et al., 2023 (PHOON; ZHANG, 2023). Grande parte da literatura relacionada ao monitoramento da saúde estrutural objetiva a identificação de falhas em conjuntos de dados provenientes de medições realizadas por instrumentos de campo (ARAUJO, 2024) e, portanto, não se configura como trabalho correlato a presente pesquisa. Apenas quatro trabalhos (BALANIUK et al., 2020; AMMIRATI et al., 2022; LUO et al., 2022; LIMÃO et al., 2023) relacionados ao conceito de barragem e compatíveis com a metodologia proposta foram identificados durante o levantamento bibliográfico.

Balaniuk et al., 2020 (BALANIUK et al., 2020) desenvolveu uma metodologia baseada em imagens de satélite que executa a varredura de vastas áreas para mapeamento de barragens de rejeitos de mineração, classificando-as de acordo com o nível dos riscos impostos por suas operações. Uma arquitetura de FCN foi utilizada para realizar as classificações com base em dados multiespectrais, alcançando acurácia de 97.44%. O trabalho visa como contribuição o mapeamento áreas de risco e a identificação de operações ilegais. Luo et al., 2022 (LUO et al., 2022) também aplica técnicas de sensoriamento remoto multiespectral em barragens de mineração, porém utiliza imagens capturadas via VANT para avaliar a vegetação presente nos arredores das estruturas. O algoritmo RF é utilizado para segmentar os pixels referentes a solo exposto, vegetação, areia e água,

alcançado acurácia geral de 97.60% e índice Kappa de 96.60%.

O trabalho de Limão et al., 2023 (LIMÃO et al., 2023) propõe uma arquitetura de RNC composta de três blocos convolucionais para a classificação binária de danos em taludes de aterro. O modelo foi treinado em dataset autoral composto por 300 imagens, atingindo acurácia 86.3% no conjunto de validação. Este trabalho se configura como um passo inicial para a aplicação de técnicas de VC no contexto de monitoramento de barragens de terra, permitindo o desenvolvimento de novos trabalhos com base em suas limitações. Tais limitações incluem a necessidade de propor datasets mais robustos e diversificados e o uso de modelos de VC que resolvem tarefas mais complexas, como detecção de objetos e segmentação semântica, por exemplo.

### 3.3 Modelos Generativos para Sintetização de Dados Multiespectrais

Uma parte reduzida da literatura relacionada aborda o problema da acessibilidade de dados multiespectrais, propondo soluções para a sintetização de bandas além do espectro visível ou índices de vegetação a partir de imagens RGB tradicionais. Modelos de cGAN, especialmente a arquitetura Pix2Pix (ISOLA et al., 2018) e suas variantes, são as mais comumente utilizadas para a geração de imagens sintéticas neste domínio. A aplicação primária de técnicas de tradução de imagens é focada em agricultura e monitoramento florestal, sendo que a sintetização da banda *Near Infrared* (Infravermelho Próximo) (NIR) e do índice NDVI sendo as mais comuns.

Diversos trabalhos utilizam a arquitetura Pix2Pix para a geração da banda NIR a partir de entradas RGB (YUAN et al., 2020; ILLARIONOVA et al., 2021; ASLAHISHAHRI et al., 2021). Outro alvo comum dos modelos é a geração do índice NDVI a partir de imagens RGB (DAVIDSON et al., 2022; ADAMIAK et al., 2023; MOSCOVINI et al., 2024). Esses trabalhos demonstram a viabilidade de utilizar modelos de cGAN para a sintetização de bandas espectrais e índices de vegetação em domínios específicos, com aplicações em cenários agrícolas, florestais e urbanos. Entretanto, é notável a lacuna na literatura de trabalhos que busquem a sintetização da banda *Red Edge* (Vermelho de Borda) (RE), que também é muito utilizada no contexto de sensoriamento remoto multiespectral, e do principal índice derivado da mesma, o NDRE, que é abordado em apenas um trabalho no contexto agrícola (DAVIDSON et al., 2022). Também não foram encontrados trabalhos que apliquem estas técnicas no contexto de monitoramento estrutural.

### 3.4 Sumarização dos Trabalhos Correlatos

A revisão da literatura apresentada neste capítulo resultou na identificação de 21 trabalhos correlatos, cujos temas e contribuições são sumarizados na Tabela 4. Os artigos identificados durante a revisão não se configuram como resposta para a pergunta de pesquisa apresentada, evidenciando as lacunas na literatura que serão preenchidas com o desenvolvimento desta pesquisa. A aplicação de técnicas de ML para a classificação de *land-cover* e análise da cobertura vegetal em taludes de jusante de barragens de terra é uma abordagem inovadora no âmbito de monitoramento e segurança de barragens, com potencial de contribuição na prevenção de acidentes e na mitigação de impactos ambientais.

Tabela 4 – Áreas temáticas e contribuições identificadas para os trabalhos correlatos: Veículo Aéreo Não-Tripulado (VANT), Multiespectral (MS), Índice de Vegetação (IV), Machine Learning Tradicional (TML), Deep Learning (DL), Vegetação (VEG), Barragens (BRG).

Fonte: Autor.

Referência	Ano	VANT	MS	IV	TML	DL	VEG	SEG	BRG	Contribuições
(CANDIAGO et al., 2015)	2015	✓	✓	✓			✓			Análises estatísticas baseadas em IVs para imagens multiespectrais de plantações de tomates coletadas por VANT.
(MCCOOL et al., 2018)	2018						✓	✓		Utilização da Gaussiana Multivariada para classificação da vegetação em gramíneas e herbáceas a partir de câmeras RGB tradicionais.
(WU et al., 2019)	2019		✓	✓	✓			✓		Algoritmo RF e seleção de features para segmentação de land cover em cenários urbanos a partir de dados multiespectrais capturados via satélite.
(BALANIUK et al., 2020)	2020		✓			✓		✓	✓	DL para mapeamento via satélite e classificação de riscos de projetos de mineração em áreas vastas.
(GUO et al., 2020)	2020		✓	✓		✓		✓		DL para segmentação binária de land-cover em áreas de neve baseado em imagens de sensoriamento remoto multiespectral via satélite.
(NOGUEIRA et al., 2020)	2020		✓			✓		✓		Comparação entre modelos de DL para segmentação binária de erosões ao longo de ferrovias a partir de imagens capturadas via satélite.
(Paredes-Gómez et al., 2020)	2020		✓	✓	✓		✓	✓		Avaliação da qualidade da irrigação de coberturas vegetais utilizando o algoritmo RF em imagens capturadas via satélite.
(RIEHLE et al., 2020)	2020		✓	✓				✓		Métodos tradicionais para segmentação de cobertura vegetal baseada em IVs RGB e limiarização em diferentes espaços de cores.
(BRAGAGNOLO et al., 2021)	2021				✓	✓	✓	✓		DL para segmentação binária de áreas florestais e identificação de desmatamentos em imagens de satélite e conjunto de dados reduzido.
(CONCEIÇÃO et al., 2021)	2021		✓		✓			✓		Algoritmo RF e seleção de features para segmentação de áreas com derramamento de petróleo no oceano utilizando imagens de satélite.

Tabela 4 (continuação)

Referência	Ano	VANT	MS	IV	TML	DL	VEG	SEG	BRG	Contribuições
(Gonzalez-Moodie et al., 2021)	2021	✓	✓		✓	✓	✓	✓		TML e DL para análise e estimativa da cobertura vegetal em áreas de dunas baseada em sensoriamento remoto multiespectral via VANT.
(LINHUI et al., 2021)	2021		✓	✓	✓			✓		Algoritmos RF e SVM e seleção de features para segmentação de land cover de diferentes tipos de florestas a partir de imagens de satélite.
(OSCO et al., 2021)	2021	✓	✓			✓	✓	✓		Comparação entre modelos de DL para segmentação semântica binária em pomares de citrinos a partir de imagens capturadas por VANTs.
(ASKAM et al., 2022)	2022	✓	✓	✓			✓			Uso de imagens de satélite e VANT para avaliar o impacto da instalação de pequenas barragens nos IVs locais em Montana, EUA.
(DAVIDSON et al., 2022)	2022	✓	✓	✓		✓	✓			Uso de modelos generativos Pix2Pix para geração de IVs sintéticos baseados em dados RGB visando a viabilidade econômica.
(AMMIRATI et al., 2022)	2022		✓				✓	✓	✓	Mapeamento via satélite das áreas afetadas pelo colapso da barragem de rejeitos B1 em Brumadinho, MG, Brasil.
(LUO et al., 2022)	2022	✓		✓	✓		✓	✓	✓	Análise da cobertura vegetal em barragens de rejeitos baseada em imagens de VANTs, segmentação via RF e utilizando IVs RGB.
(LIMÃO et al., 2023)	2023	✓				✓			✓	Arquitetura de CNN para classificação binária com conjunto de dados reduzido de imagens RGB contendo danos em taludes de terra.
(YIN et al., 2023)	2023	✓	✓	✓	✓		✓			Utilização de doze IVs multiespectrais como features para o treinamento de modelos de TML para avaliação do conteúdo de clorofila da vegetação.
(BEHERA et al., 2023)	2023	✓				✓	✓	✓		Arquitetura simplificada de FCN para segmentação semântica de land-cover embarcada em dispositivos de baixa capacidade computacional.
(CHENG et al., 2024)	2024	✓	✓	✓	✓	✓	✓			Ensembles de algoritmos de TML e DL para estimativa do LAI em imagens de plantações de milho sob diferentes condições de irrigação e fertilização.

Tabela 4 (continuação)

Referência	Ano	VANT	MS	IV	TML	DL	VEG	SEG	BRG	Contribuições
Este Trabalho		✓	✓	✓	✓	✓	✓	✓	✓	Framework para monitoramento da cobertura vegetal de barragens de aterro baseado em sensoriamento remoto multiespectral via VANT, TML e DL.

---

# Metodologia para Monitoramento da Cobertura Vegetal em Taludes de Aterro

A metodologia de monitoramento da cobertura vegetal de taludes de aterro apresentada nesta tese de doutorado foi desenvolvida em parceria com a empresa Norte Energia S.A. no formato de Projeto de Pesquisa e Desenvolvimento ANEEL #23073.014329/2020-51. Ao longo do projeto, a metodologia foi aplicada em um estudo de caso nas dependências da UHE Belo Monte. Este capítulo detalha o estudo de caso e suas motivações, além de apresentar uma visão geral sobre a metodologia proposta neste trabalho.

## 4.1 Estudo de Caso

O complexo da UHE Belo Monte está localizado ao norte do Rio Xingú, na região sudoeste do estado do Pará, Brasil. O reservatório ocupa uma área total de 478 quilômetros quadrados e conta com uma capacidade de 11.233,1MW para geração de energia, configurando-se como a maior UHE localizada 100% em território brasileiro (NESA, 2020). O arranjo das estruturas do complexo compreende quatro sítios, constituídos de seis barragens de terra e terra-enrocamento, 30 diques, um canal de derivação, duas casas de força e um vertedouro com 18 comportas (Comitê Brasileiro de Barragens, 2017).

Em decisão conjunta com a Norte Energia S.A., duas estruturas do complexo foram selecionadas estrategicamente como objetos de estudo para os experimentos conduzidos neste estudo de caso. A Figura 18 apresenta uma visão aérea das barragens selecionadas. As missões automatizadas de coletas e as análises de dados multiespectrais foram concentradas nas seguintes estruturas:

- **Barragem Vertente do Santo Antônio:** É uma das principais estruturas do Complexo Belo Monte. De acordo com projeto *as built*, na Barragem Vertente do Santo Antônio (BVSA) é predominante a presença de materiais migmatíticos na

fundação e no aterro. Esse tipo de solo é caracterizado por textura argilosa e baixa permeabilidade. A estrutura possui taludes em solo compactado com cobertura vegetal e taludes em enrocamento.

- **Dique 6C:** Localiza-se na região denominada de Graben, com predominância de solo arenítico na fundação. Este solo tem como característica a permeabilidade relativamente alta e coesão baixa, implicando em fácil carreamento de materiais (erosão) e o aparecimento de surgências a jusante. A estrutura possui taludes em solo compactado com cobertura vegetal.

Em conformidade com a Lei 12.334, a Norte Energia S.A. emprega uma série de medidas preventivas e rotinas relacionadas à Segurança de Barragens. Os principais elementos que compõem o plano de segurança incluem a instrumentação de campo com 1976 instrumentos de 12 tipos diferentes instalados nas estruturas. Além da instrumentação de campo, cada estrutura é alvo de inspeções regulares que avaliam metodicamente uma série de itens que descrevem as condições de cada estrutura (NESA, 2020). Dentre os itens avaliados durante as inspeções visuais regulares, ocorrências anômalas como a presença de tocas de animais, erosão, surgências e necessidade de manutenção na cobertura vegetal são causas potenciais de instabilidades estruturais e, portanto, devem ser monitoradas de forma sistemática para detecção precoce. Exemplos de anomalias, como os descritos anteriormente na Tabela 1, encontradas durante as visitas técnicas nas dependências da UHE Belo Monte são ilustradas na Figura 17.

Conforme os documentos de projeto das estruturas em estudo, foi realizada a reconstrução das rotas de inspeção utilizando a ferramenta *Google Earth*. Foi constatado que, para percorrer as canaletas, escadarias e demais estruturas de drenagem, bem como para averiguar as condições dos taludes, os caminhos de inspeção somam 3,005km e



Figura 17 – Exemplos de anomalias encontradas durante visitas técnicas.

Fonte: Autor



Figura 18 – Caminhos de leitura indicados pelos projetos *as built* das estruturas BVSA e Dique 6C, selecionadas para o estudo de caso na Usina Hidrelétrica de Belo Monte.

Fonte: *Google Earth*.

3,210km para a BVSA e para o Dique 6C, respectivamente. As rotas de inspeção como descritas nos projetos são ilustradas na Figura 18. A grande extensão total percorrida pelos inspetores durante as inspeções regulares em todas as estruturas do complexo evidencia a necessidade do desenvolvimento de métodos automatizados para inspeção e monitoramento das barragens e diques.

Segundo a experiência profissional dos engenheiros da Norte Energia S.A., as anomalias listadas na Tabela 1 podem ser identificadas por meio da inspeção visual e são detectáveis precocemente a partir da análise de seus efeitos sobre a cobertura vegetal. Neste contexto, a implantação de métodos de sensoriamento remoto multiespectral aliados com técnicas de IA permite a avaliação sistemática e automatizada da cobertura vegetal, possibilitando a detecção precoce de anomalias e a identificação de áreas críticas nas estruturas. A replicabilidade da metodologia proposta com relação à coleta de dados e extração de métricas descritivas da vegetação é crucial para que a evolução da saúde vegetal seja monitorada ao longo do tempo e que alterações sutis sejam identificadas.

Como produto do projeto de P&D, a metodologia desenvolvida nesta pesquisa foi

implementada em formato de aplicação *web*. O módulo de análise da cobertura vegetal da aplicação permite que os engenheiros da Norte Energia S.A. cadastrem as imagens capturadas durante as missões de coleta automática, que são processadas automaticamente e os resultados provenientes das análises são visualizados em formato de *dashboard*. Além do módulo de inspeção visual, a aplicação conta com um módulo de análise de dados de instrumentação baseado em algoritmos de IA para detecção de anomalias. Em conjunto, o sistema computacional desenvolvido permite a integração dos dados de diferentes fontes e a análise conjunta dos resultados, facilitando a tomada de decisão dos engenheiros responsáveis pela segurança das barragens e diques do complexo Belo Monte.

## 4.2 Metodologia Proposta

Este trabalho apresenta uma metodologia replicável de monitoramento estrutural e análise da cobertura vegetal de estruturas geotécnicas. A metodologia é composta por quatro macro-etapas: [1] Coleta de Dados, [2] Pré-Processamento de Dados, [3] Segmentação Semântica da Estrutura, [4] Análise da Cobertura Vegetal.

- **Etapa 1: Coleta de Dados** consiste da formalização da estratégia de coleta automática de dados multiespectrais. A rotina de aquisição de dados deve ser replicável para garantir a reprodutibilidade das inspeções regulares;
- **Etapa 2: Pré-Processamento de Dados** realiza o tratamento dos dados brutos capturados pelo sensor multiespectral. Inclui a calibração radiométrica das imagens e o processamento de *Digital Orthophoto Maps* (Mapas de Ortofoto Digital) (DOMs);
- **Etapa 3: Segmentação Semântica da Estrutura** realiza a classificação a nível de pixel dos diferentes tipos de land-cover que compõem as estruturas. A diferenciação entre as classes permite a extração da classe de interesse para análises posteriores;
- **Etapa 4: Análise da Cobertura Vegetal** consiste na execução de análises da cobertura vegetal baseadas em Índices de Vegetação. As métricas de saúde vegetal extraídas serão armazenadas e, futuramente, utilizadas para avaliação da evolução da cobertura vegetal e detecção de anomalias ao longo do tempo. Adicionalmente, um método para geração de IVs sintéticos é proposto para eliminar a necessidade de aquisição de sensores multiespectrais.

A metodologia de análise da cobertura vegetal de diques e barragens de aterro proposta na presente pesquisa é ilustrada na Figura 19. O detalhamento das etapas [1] e [2] é realizado nas subseções seguintes, enquanto as etapas [3] e [4] são detalhadas nos capítulos posteriores.

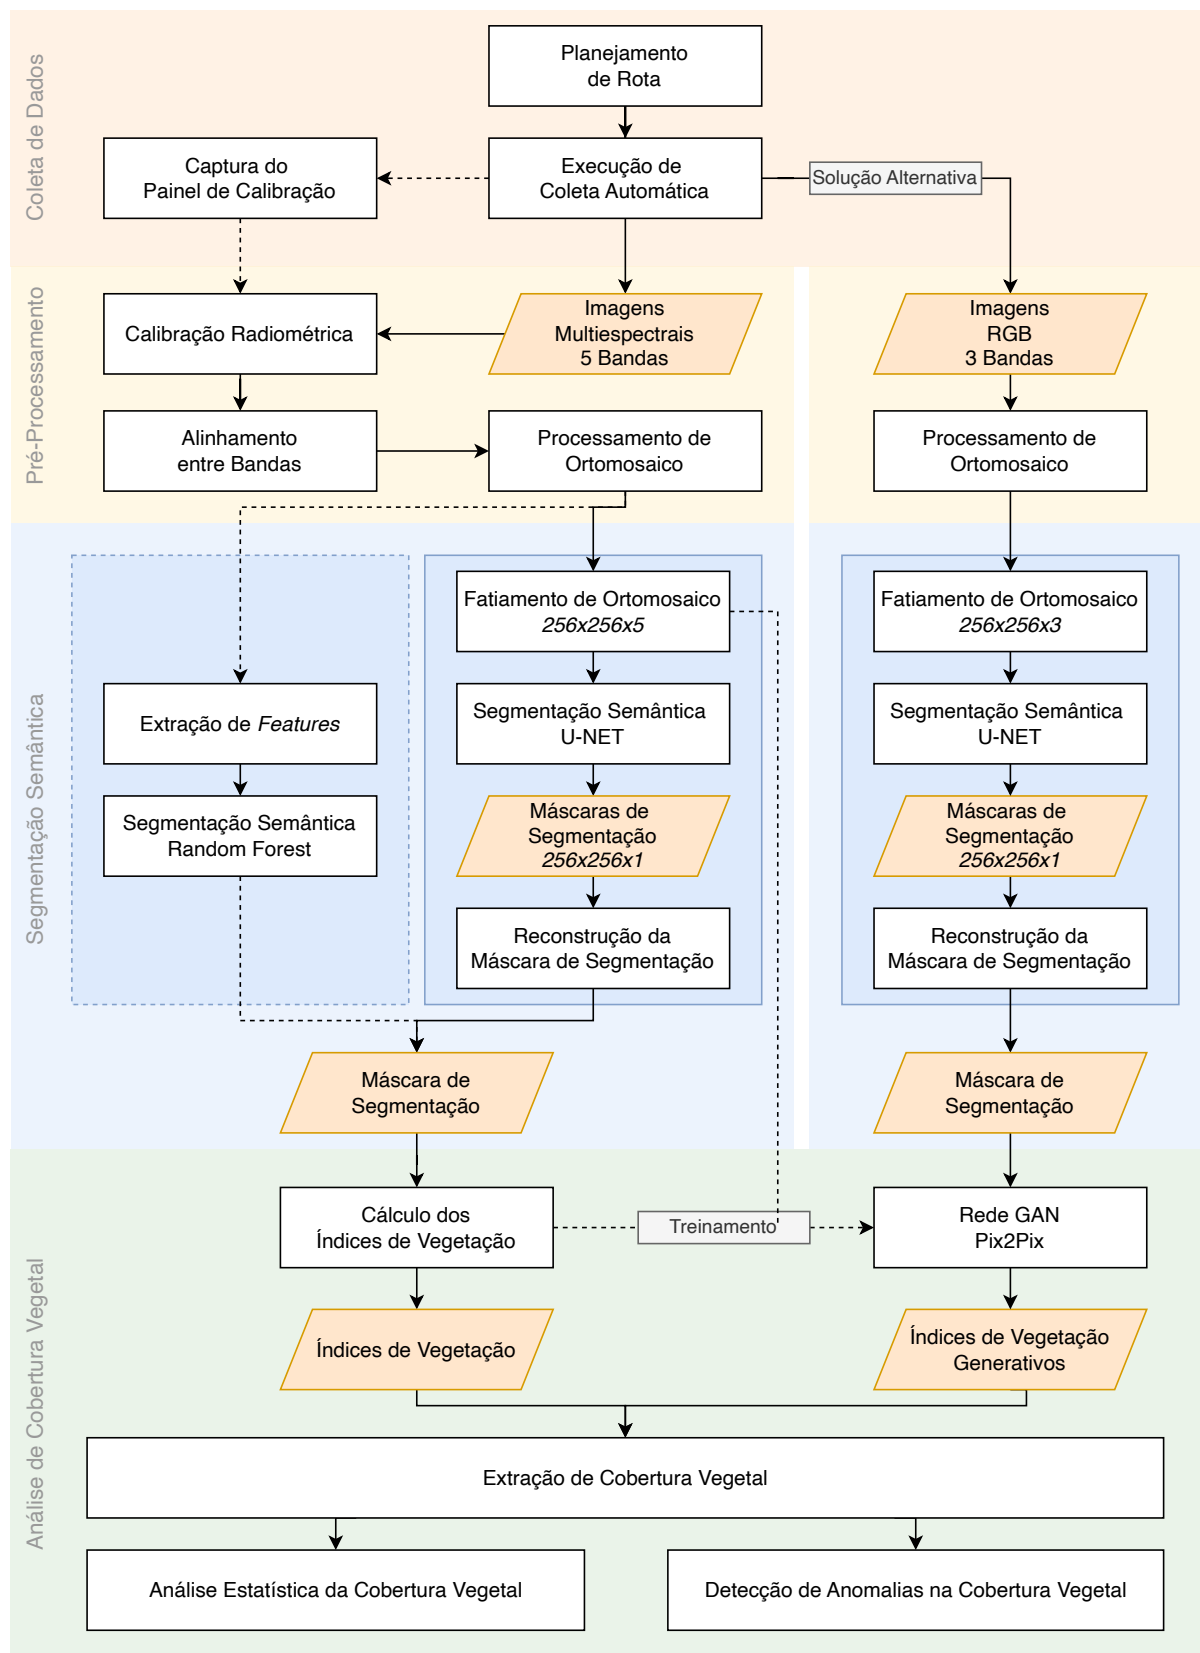


Figura 19 – Visão geral da metodologia de análise de cobertura vegetal. O detalhamento das etapas [1] Coleta de Dados e [2] Pré-Processamento é realizado nas Seções 4.3 e 4.4, as etapas [3] Segmentação Semântica da Estrutura e [4] Análise da Cobertura Vegetal são detalhadas nos capítulos subsequentes.

Fonte: Autor

### 4.3 Coleta de Dados

A tecnologia embarcada em VANTs modernos, principalmente nos de escala industrial, permite a execução de missões de coleta de dados automatizadas e replicáveis. A metodologia desenvolvida neste trabalho prevê o uso de rotas de inspeção pré-definidas para que as missões de coletas de dados sejam reproduzíveis. A reprodutibilidade das missões de coleta garante que os dados coletados sejam comparáveis ao longo do tempo, permitindo a análise da evolução da cobertura vegetal. Neste contexto, os equipamentos listados a seguir foram adquiridos para o desenvolvimento do projeto.

O DJI Matrice 210 V2 (DJI, 2020), ilustrado na Figura 20a, é um VANT de nível empresarial projetado para aplicações comerciais e tarefas industriais, como mapeamento e inspeção de infraestruturas. A aeronave é equipada com um sistema de baterias duplas, proporcionando um tempo máximo de voo de 38 minutos. O sistema de *gimbal* duplo suporta uma ampla gama de cargas especializadas, incluindo câmeras RGB, sensores multi e hiperespectrais, e sensores LiDAR, por exemplo. O módulo nativo de planejamento de missões permite o planejamento e a execução de voos automatizados de coleta de dados.

Acoplado ao DJI M210 V2 foi utilizado o sensor multiespectral Micasense RedEdge-P (MICASENSE, 2021), ilustrado na Figura 20b. A integração desse sensor terceirizado é facilitada pelo kit de integração DJI *SkyPort*. O RedEdge-P é equipado com seis sensores ópticos capazes de capturar dados de seis bandas distintas do espectro eletromagnético: Vermelha, Verde, Azul, Vermelho de Borda, Infravermelho Próximo (NIR) e Pancromática. Cada sensor captura dados de uma banda única com uma resolução de  $1456 \times 1088$  pixels, correspondendo a 1,58 megapixels por banda com um tamanho de pixel de  $3,45\mu m$ . A Tabela 5 resume as características das bandas multiespectrais. Os dados da banda pancromática foram utilizados na etapa de calibração para aprimorar a nitidez das imagens.



(a) DJI Matrice 210 V2.



(b) Micasense RedEdge-P.

Figura 20 – Equipamentos utilizados para coleta dos dados do estudo de caso realizado nas dependências da UHE Belo Monte.

Fonte: DJI, 2020 (DJI, 2020) e Micasense, 2021 (MICASENSE, 2021)

Tabela 5 – Bandas espectrais capturadas pelo sensor multiespectral Micasense RedEdge-P.

**Fonte: Autor.**

Banda	Comprimento de Onda Central	Largura de Banda
Azul (B)	475nm	32nm
Verde (G)	560nm	27nm
Vermelho (R)	668nm	16nm
Vermelho de Borda (RE)	717nm	12nm
Infravermelho Próximo (NIR)	842nm	57nm

De acordo com a fabricante do sensor (Micasense, 2024), o sucesso de uma missão de coleta de dados automatizada é diretamente dependente da estrita obediência a uma série de boas práticas que devem ser observadas pelo profissional responsável pela coleta. As boas práticas abrangem detalhes desde a configuração do drone, até a observação das condições climáticas e horário de inspeção. Ao seguir as especificações citadas pela fabricante, o inspetor garante que os dados coletados tenham a qualidade necessária para que a calibração dos dados, o pré-processamento sejam realizados adequadamente e para que o DOM seja gerado com o mínimo possível de imperfeições e maior qualidade.

O primeiro passo para a execução da coleta de dados automatizada é o planejamento de missão. No fluxo de trabalho definido para este projeto, a área que será capturada deverá ser definida previamente com o auxílio da ferramenta *Google Earth* e exportada em formato “.kml”. Vale ressaltar que, idealmente, o polígono selecionado deve ser ao menos 10% maior do que a área de inspeção desejada para garantir o processamento do DOM. O arquivo contendo uma área de inspeção gerada para cada estrutura separadamente deve ser armazenado em um dispositivo de armazenamento (*pen-drive* ou cartão de memória) e transferido para o sistema de arquivos do controlador do VANT.

Ao iniciar o *software* do VANT no modo de Missões Automáticas e inserir o arquivo contendo a área de inspeção, o controlador irá gerar automaticamente uma rota de inspeção que cobre a área definida. Também é necessário inserir as configurações específicas do sensor multiespectral, as configurações ideais identificadas para o sensor RedEdge-P são listadas na Tabela 6. Após a correta configuração das missões automáticas, as missões de coleta são armazenadas para reexecuções futuras. No momento da coleta, a missão é transferida ao sistema embarcado na aeronave e o VANT executa o processo de coleta de dados de forma autônoma.

Tabela 6 – Parâmetros de configuração para a execução de missões automáticas de coletas de dados utilizando o sensor RedEdge-P.

**Fonte: Autor.**

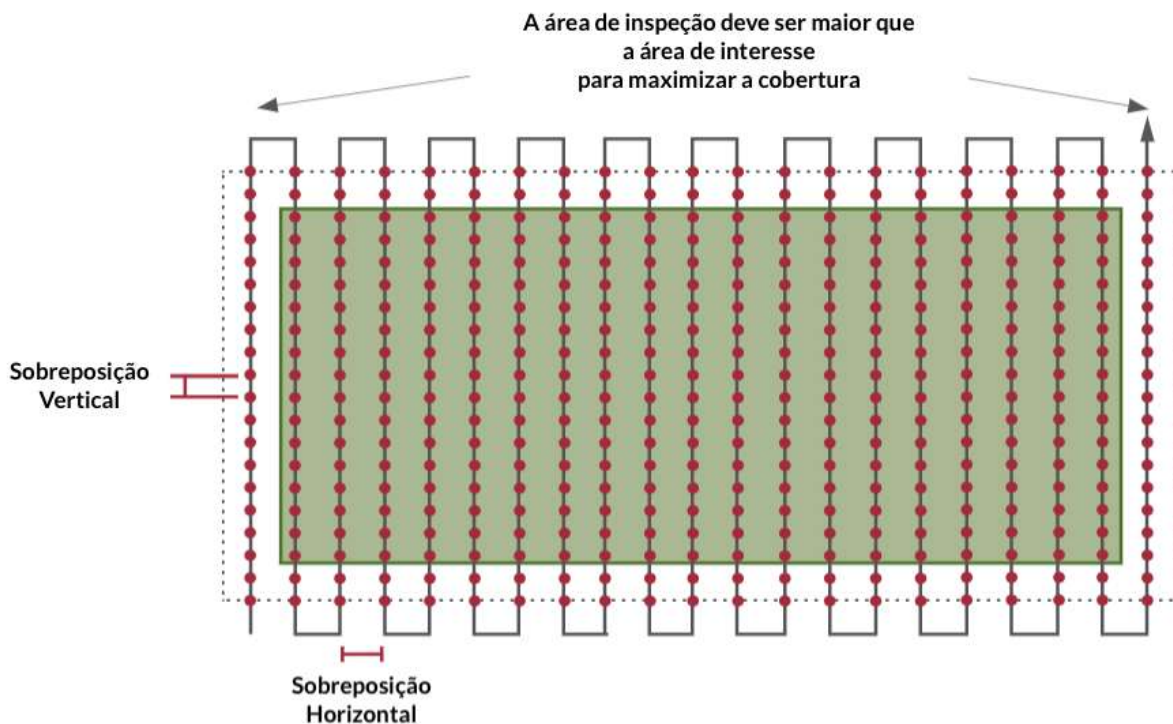
Parâmetro	Valor
Nome	Micasense RedEdge-P
Largura da Imagem	1456px
Altura da Imagem	1088px
Largura do Sensor	5.02mm
Altura do Sensor	3.75mm
Abertura Focal	5.5mm
Intervalo Mínimo	2.5s
Sobreposição	75%

Parâmetros como largura e altura da imagem e do sensor, abertura focal e intervalo mínimo de captura são referentes a especificação do sensor utilizado e foram retirados do manual do usuário fornecido pela fabricante Micasense (MICASENSE, 2021). O índice de sobreposição é referente ao grau de sobreposição vertical e horizontal entre imagens capturadas consecutivamente pelo sensor. A sobreposição adequada das imagens é essencial para o correto processamento dos DOMs. De acordo com o manual de boas práticas publicado por Micasense, 2024 (Micasense, 2024), os graus de sobreposição horizontal e vertical devem ser configurados para 75%. A Figura 21 representa as características ideais de sobreposição e de abrangência de área de inspeção.

Outro fator que afeta diretamente a qualidade da coleta de dados multiespectrais e o posterior processamento de DOM é o horário de coleta (MICASENSE, 2021). Imagens capturadas com o objetivo de medir a resposta espectral de objetos a irradiação solar devem ser capturadas em horários específicos. A recomendação oficial da fabricante do sensor é de que as coletas sejam realizadas por volta das 10:00 ou por volta das 14:00, há cerca de duas horas do meio-dia. Desta forma, é possível prevenir possíveis sombreamentos, que podem afetar diretamente a qualidade dos dados capturados, comprometendo a análise dos IVs.

Os valores de refletância capturados pelo sensor multiespectral estão sujeitos a variações baseadas nas condições climáticas e de iluminação. Para mitigar este problema, o uso do painel de calibração incluso no kit do sensor multiespectral RedEdge-P é essencial, pois o mesmo contém uma superfície cujos valores de refletância são previamente conhecidos, permitindo a calibração (MCCOY, 2005). Ao capturar uma imagem do painel de calibração imediatamente antes da execução da missão automática, é possível gerar resultados calibrados para compensar as alterações nos valores de refletância. O painel deve ser posicionado diretamente no chão, longe de quaisquer objetos que possam interferir

Figura 21 – A configuração correta da sobreposição entre imagens durante missões automatizadas de coleta de dados afeta a qualidade do Mapa de Ortofoto Digital.



Fonte: Micasense, 2024 (Micasense, 2024)

na captura da imagem ou quaisquer tipos de sombras. O operador do VANT deve segurar a aeronave a cerca de um metro de altura acima do painel sem gerar sombras. A captura da imagem pode ser realizada fisicamente através do botão de captura presente no sensor, ou através do botão de captura do controle remoto. A Figura 22a indica a posição que o operador deve assumir ao capturar a imagem de calibração, e a Figura 22b demonstra as características da imagem resultante, na qual o painel deve ocupar ao menos 1/3 da largura total da imagem.

Outros tipos de características também podem impactar a qualidade da coleta de dados multiespectrais. A iluminação solar deve permanecer o mais constante possível ao longo de toda a missão de coleta de imagens. Dias ensolarados e sem nuvens permitem realizar missões de coleta de maior qualidade. É recomendado evitar a realização de missões em dias nublados ou com nuvens em movimento para evitar a presença de anomalias nos DOM. As características do terreno a ser capturado também influenciam na qualidade do DOM. Terrenos que apresentam uma grande variabilidade de *features*, como texturas diferentes, facilitam a execução dos algoritmos de processamento de DOMs.

As especificações descritas nesta seção contribuem para que dados de qualidade sejam capturados pelo sensor multiespectral durante a execução de missões automáticas




Figura 22 – A captura do painel de calibração de refletância conhecida antes da execução de missões de coleta de dados é essencial para realizar a calibração radiométrica das imagens.

Fonte: Micasense, 2024 (Micasense, 2024)

de coleta, possibilitando os processos subsequentes. A seção seguinte apresenta as etapas de pré-processamento definidas para a metodologia proposta.

## 4.4 Pré-Processamento de Dados

Esta seção discorre sobre as etapas de pré-processamento necessárias para gerar o DOM a partir dos dados brutos capturados pelo sensor multiespectral. Um Mapa de Ortofoto Digital (DOM) é uma imagem obtida por projeção paralela vertical de uma superfície, possuindo a precisão geométrica de um mapa e as características visuais de uma imagem (LIU et al., 2018), sendo um dos principais produtos de processos de fotogrametria, assim como os mapas de elevação, nuvens de pontos e reconstruções 3D de ambientes (PARK et al., 2022). O fluxo de pré-processamento adotado nesta pesquisa consiste em duas etapas: [1] calibração radiométrica e [2] processamento de DOM.

A Figura 23 apresenta uma captura única realizada pelo sensor RedEdge-P nas dependências da UHE Belo Monte. Cada captura gera seis arquivos distintos, cada um representando os valores brutos de radiância em uma banda específica do espectro eletromagnético. O tamanho de arquivo médio para uma captura de imagem pelo sensor RedEdge-P é de 26Mb, os arquivos são armazenados em formato *".tiff"*. O processo de calibração radiométrica é necessário para realizar conversão de dados brutos de radiância capturado por sensores multiespectrais em dados de refletância. Os valores calibrados de refletância levam em consideração fatores como as condições climáticas e a incidência de luz solar no horário da coleta de dados (MCCOY, 2005).

O código-fonte para a calibração radiométrica das imagens foi desenvolvido com base na biblioteca de código aberto disponibilizada pela fabricante Micasense (MICA-




Figura 23 – As imagens brutas capturadas pelo sensor multiespectral RedEdge-P representam valores de radiância em cada banda do espectro eletromagnético capturada.

Fonte: Autor.

SENSE... ) e implementada na linguagem de programação Python. A biblioteca oferece funcionalidades de leitura e manipulação das imagens capturadas pelo sensor multiespectral, incluindo a leitura automática do painel de calibração, conversão dos valores de radiância, correção de distorções e efeitos de vinheta, alinhamento entre bandas e manipulação de metadados. As imagens resultantes são submetidas ao processo de geração do DOM.

Apesar da existência de ferramentas comerciais para a tarefa, o processamento do DOM é realizado neste trabalho com o auxílio do software *OpenDroneMap* (ODM) (OpenDroneMap, 2020). O ODM é uma solução de software para fotogrametria gratuita e de código aberto focado, mas não limitado a, processamento de imagens aéreas. As imagens processadas por esta ferramenta podem gerar produtos como nuvens de pontos georreferenciadas, modelos 3D, modelos digitais de elevação e DOMs. O ODM disponibiliza diversas formas de interface para interação com o software, incluindo uma interface de linha de comando, biblioteca Python e interface gráfica em formato de aplicação web. Os nós de processamento do ODM são executados em contêineres *Docker*.

O fluxograma de funcionamento geral empregado no ODM elaborado por Toffanin, 2023 (TOFFANIN, 2023) é apresentado na Figura 24. O processo de geração de DOMs é composto de tarefas complexas realizadas de maneira incremental, ou seja, cada etapa depende do resultado da etapa anterior. Uma breve descrição do método é elaborada a

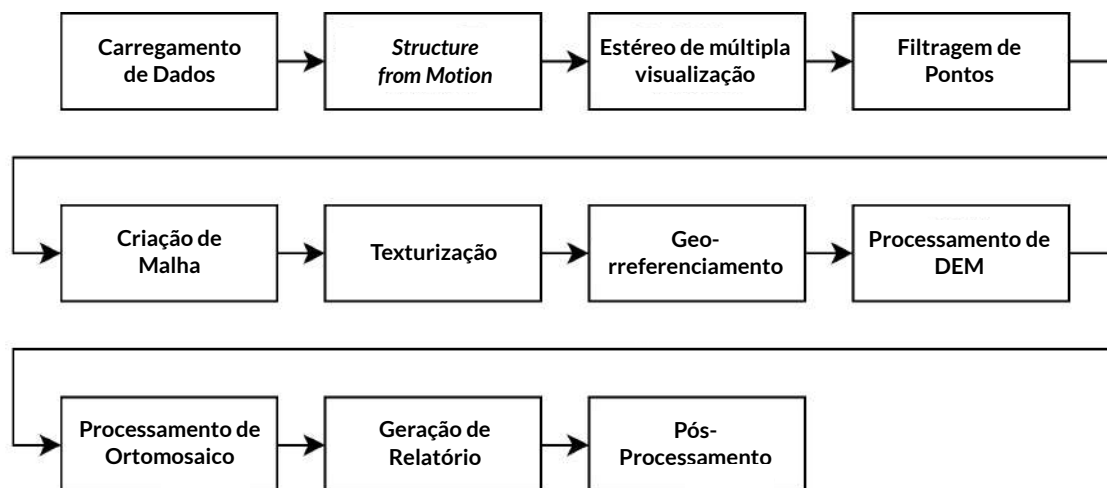


Figura 24 – Fluxograma de processamento de Mapas de Ortofoto Digital utilizado no *OpenDroneMap*.

Fonte: Adaptado de Toffanin, 2023 (TOFFANIN, 2023).

seguir.

O primeiro passo do processamento consiste no carregamento do conjunto de dados. Nesta etapa são extraídas informações contidas nos metadados EXIF contidos na imagem. Nos casos em que dados de *Global Positioning System* (Sistema Global de Posicionamento) (GPS) estão disponíveis, ou que haja disponibilidade de Ponto de Controle em Solo (GCP), um centro geográfico é determinado para permitir a conversão para coordenadas geográficas. No caso de uso deste projeto, nesta etapa é realizado o upload dos dados em que já foi aplicada a calibração radiométrica previamente.

Em seguida é aplicada uma técnica de fotogrametria conhecida como *Structure from Motion*, utilizada para estimar a estrutura de objetos 3D a partir de sequências de imagens sobrepostas. Este processo é ideal para calcular o posicionamento das câmeras ao longo da missão de coleta de dados, além de não depender de informações de GPS (TOFFANIN, 2023). A partir deste resultado, a próxima etapa, chamada de Estéreo de Visualização Múltipla, é focada na reconstrução de modelos 3D a partir de múltiplos pares de imagens sobrepostas. Para criar um mapa detalhado de pontos 3D, é necessário que as configurações ideais de coleta de dados sejam aplicadas, garantindo uma sobreposição de imagens adequada. A presença de erros e *outliers* que podem ser produzidos nessas etapas é tratada na etapa de filtragem de pontos.

A nuvem de pontos já tratada e filtrada é submetida aos processos de criação de malha e texturização. Na criação de malha ocorre a conexão entre os pontos existentes para a geração de malhas poligonais, utilizadas tradicionalmente em modelagem 3D. A malha de polígonos não possui nenhum tipo de colorização nesta etapa. O processo de




Figura 25 – Formato do *tensor* resultante do processamento dos Mapas de Ortofoto Digital.

Fonte: Autor.

texturização é capaz de colorir o modelo 3D a partir das cores presentes nas imagens originais.

Até a etapa de texturização, todos os processamentos foram realizados considerando um sistema de coordenadas local, que não representa uma localização real no planeta Terra. A transformação deste sistema local para um sistema de coordenadas real é feita na etapa de georreferenciamento. Nesta etapa o ODM utiliza as informações de GPS contidas nos metadados EXIF das imagens, ou dados de GCP, para converter os sistemas de coordenadas. O resultado desta etapa é uma nuvem de pontos georreferenciadas com limiares de corte acoplados.

A partir daqui é possível processar alguns dos produtos principais que o ODM é capaz de gerar. Primeiramente é feito o processamento do *Digital Elevation Map* (Mapa Digital de Elevação) (DEM), que representa a elevação presente em cada ponto da imagem em um sistema de coordenadas XY e mapa de cores. Após a geração do DEM ocorre o processamento do DOM. O DOM é gerado ao capturar uma imagem da malha 3D texturizada vista de cima. A imagem é salva em formato GeoTIFF juntamente com todos os metadados necessários. No caso das imagens multiespectrais utilizadas neste projeto, o formato utilizado é representado na Figura 25, consistindo nas cinco bandas multiespectrais e linha de corte.

Após a geração do DOM, as informações do pipeline completo e métricas de desempenho são compiladas automaticamente em formato de relatório PDF. A partir das estatísticas do relatório é possível inferir a qualidade da coleta de dados e do pipeline de processamento, identificando possíveis falhas e dando as informações necessárias para que os processos de coleta e processamento sejam melhorados. Os parâmetros de configuração do ODM para a geração de mapas de qualidade são apresentados no Apêndice B. A partir desta etapa é possível executar a etapa opcional de pós-processamento, onde são gerados produtos como modelos 3D completos das imagens capturadas.

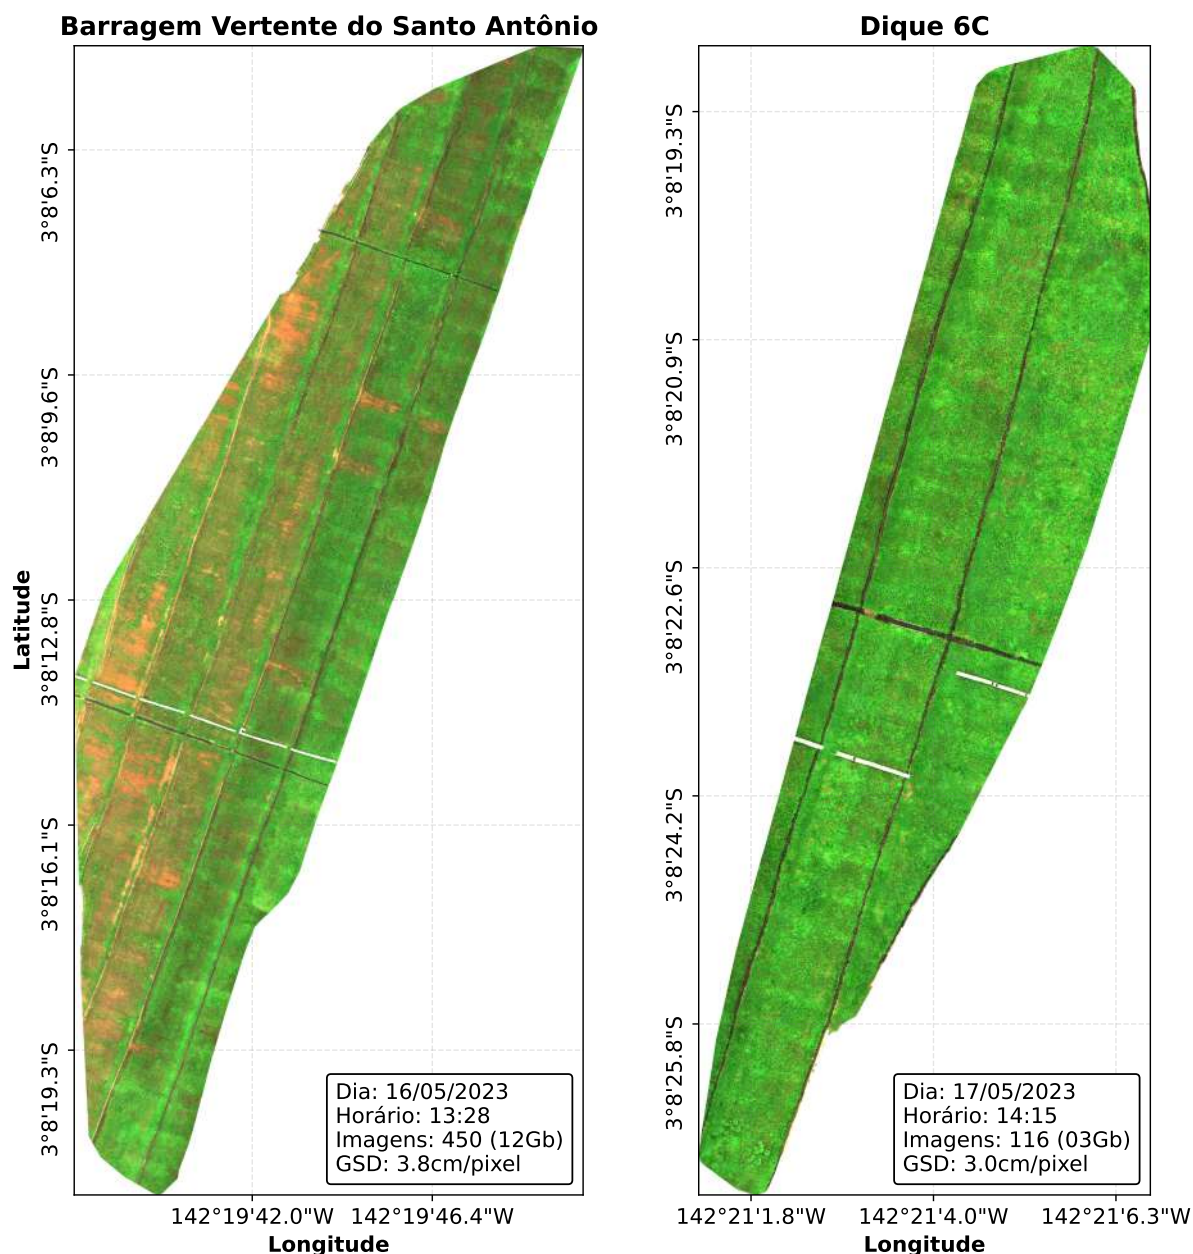


Figura 26 – Mapas de Ortofoto Digital (DOMs) resultantes das coletas de dados realizadas nas estruturas BVSA e Dique 6C nos dias 16 e 17 de maio de 2023.

Fonte: Autor.

Os arquivos `boundary.json` e `cameras.json` contêm configurações necessárias para a geração do DOM. O arquivo `boundary.json` representa uma linha de corte manual personalizada para cada estrutura em que serão realizadas missões coleta de dados. Recomenda-se que a linha de corte seja criada manualmente usando a ferramenta disponível em <https://geojson.io>, onde é possível desenhar um polígono ao redor da área desejada e exportar o polígono georreferenciado em formato JSON. O polígono deve conter a área desejada que o DOM deve representar. O arquivo `cameras.json` contém informações sobre as câmeras utilizadas na captura de imagens.

A execução das missões automáticas de coleta de dados *in loco* ocorreu durante a Visita Técnica III, realizada pela equipe do projeto nas dependências da UHE Belo Monte nos dias 16 e 17 de maio de 2023. Os DOMs resultantes das coletas de dados na BVSA e no Dique 6C são ilustrados pela Figura 26. Nesta coleta de dados, duas abordagens distintas foram executadas para teste. No DOM da BVSA, uma rota de coleta única foi executada em toda a extensão da estrutura. Esta abordagem acaba demandando mais tempo de bateria, entretanto, o DJI Matrice 210 v2 foi capaz de executar a rota de coleta completa com apenas uma carga de bateria. A segunda abordagem dividiu a coleta de dados do Dique 6C em três seções distintas do talude: superior, intermediária e inferior. A segunda abordagem mostrou-se falha, pois não foi possível realizar a junção dos três arquivos de DOM resultantes. Após estes experimentos, concluiu-se que as missões de coletas devem ser realizadas de maneira ininterrupta, apesar dos maiores custos computacionais necessários para o processamento do DOM.

## 4.5 Anotação de Dados

A anotação de dados para segmentação semântica é um procedimento complexo e moroso, contribuindo para a escassez de conjuntos de dados de alta qualidade disponíveis para a solução de problemas nichados (LV et al., 2023). Devido à ausência de conjuntos de dados contendo imagens aéreas pré-annotadas para a segmentação semântica de land-cover de taludes de aterro, os arquivos de DOM foram anotados manualmente com o auxílio do *software* CVAT (SEKACHEV et al., 2020). Durante a anotação manual das imagens, cada pixel foi rotulado de acordo com as classes de interesse definidas em conjunto com a equipe de segurança de barragens da Norte Energia S.A.. As quatro classes a seguir foram definidas para a segmentação semântica dos DOMs:

Tabela 7 – Descrição de cada classe de interesse no conjunto de dados.

**Fonte: Autor.**

Classe	Descrição
Cobertura Vegetal	Talude a jusante da barragem de aterro. Neste trabalho, essa classe representa a superfície do talude coberta por vegetação.
Canaletas de Drenagem	Estruturas de drenagem encontradas em cada berma do talude de jusante.
Escadarias	Escadarias de aço que vão da base até a crista da estrutura.
Plano de Fundo	Plano de fundo dos DOM.

Como experimento adicional, o conjunto de dados multiclasse foi adaptado para o treinamento de modelos de segmentação binária. Neste novo conjunto, todas as amostras pertencentes às classes diferentes de Cobertura Vegetal foram agrupadas em uma classe

única de Plano de Fundo. Em seguida, os mapas e suas respectivas máscaras de segmentação foram fatiados em segmentos de formato 256x256 pixels.

De posse dos DOMs processados e anotados, a próxima etapa da metodologia desenvolvida neste trabalho é a segmentação semântica dos DOMs, que possibilitará que a cobertura vegetal dos taludes seja extraída e analisada em etapas subsequentes. As abordagens de segmentação semântica das estruturas são detalhadas no capítulo seguinte.

---

## Segmentação Semântica de Land-Cover em Taludes de Aterro

Este capítulo apresenta os resultados obtidos durante os experimentos referentes à etapa [3] Segmentação Semântica de Land-Cover. Os experimentos foram realizados nos DOMs processados a partir dos dados capturados *in loco* nas estruturas BVSA e Dique 6C do complexo da UHE Belo Monte.

Nos campos de VC e Sensoriamento Remoto, o objetivo de problemas de segmentação semântica é de atribuir significado semântico, ou classe, individualmente a cada pixel da imagem de entrada. Esse processo divide a imagem em áreas visualmente significativas ou interessantes, permitindo a compreensão visual e análises subsequentes da imagem com base na máscara de segmentação resultante (MO et al., 2022). No contexto desta pesquisa, a segmentação semântica de land-cover é utilizada para identificar os pixels referentes aos diferentes elementos das estruturas estudadas, com foco inicial na extração da cobertura vegetal. A extração dos pixels referentes a classes de interesse possibilita a realização de análises quantitativas e qualitativas da cobertura vegetal, com a minimização da interferência de outros tipos de land-cover presentes na imagem.

Duas abordagens foram avaliadas para a segmentação semântica de land-cover dos taludes das barragens e diques da UHE Belo Monte, a primeira baseada no algoritmo RF, a segunda baseada em RNCs. As duas abordagens variam nos quesitos de complexidade, desempenho, custo computacional e interpretabilidade dos modelos, apresentando vantagens e desvantagens no contexto da aplicação em segurança de barragens. As subseções seguintes apresentam os resultados obtidos nos dois experimentos de segmentação de land-cover das imagens multiespectrais capturadas no complexo Belo Monte.

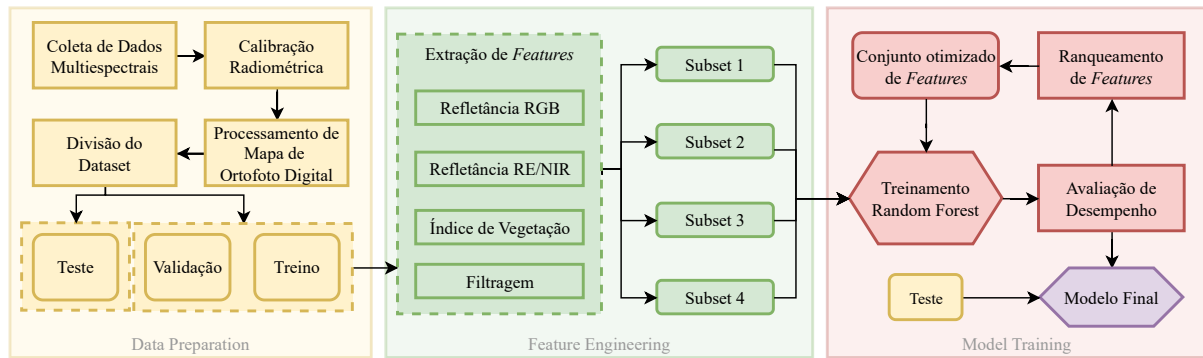


Figura 27 – Metodologia de Segmentação Semântica com modelos de *Random Forests* composta por três macro-etapas: (1) Preparação dos dados, (2) Engenharia de *Features* e (3) Treinamento dos Modelos.

Fonte: Autor.

## 5.1 Segmentação Semântica com Random Forests

A aplicação de modelos tradicionais de ML em tarefas de segmentação semântica, nas quais a classificação é geralmente realizada ao nível de pixel, melhorou significativamente o desempenho dos modelos em relação a abordagens tradicionais como limiarização e clusterização (KOTARIDIS; LAZARIDOU, 2021). Conjuntos de técnicas consolidadas de ML como K-Nearest Neighbors, SVM, RF e XGBoost costumam apresentar bons resultados em problemas de segmentação semântica para classificação de land-cover. O algoritmo RF, amplamente utilizado na literatura correlata em diferentes cenários de classificação de land-cover (CONCEIÇÃO et al., 2021; LINHUI et al., 2021; WU et al., 2019; LUO et al., 2022) foi selecionado para os primeiros experimentos deste trabalho, que foram realizados em um cenário de escassez de dados de treinamento, o que impossibilitava a adoção de técnicas de DL.

O RF é um algoritmo supervisionado de ML baseado em um *ensemble* de modelos individuais de árvores de decisão (QUINLAN, 1986). Os modelos desta coleção de classificadores são estruturados em árvore  $h(x, \Theta_k), k = 1, \dots$ , nos quais os  $\theta_k$  são vetores aleatórios independentes e identicamente distribuídos (Leo Berman, 2001). Neste *ensemble*, dada uma entrada  $X$ , cada árvore de decisão dá um voto para definir a classe mais popular, contribuindo para a definição da saída  $y$ . As vantagens do algoritmo de RF incluem o fato de ser não paramétrico, não exigir suposições sobre a distribuição dos dados de treinamento, capacidade de treinamento eficiente em conjuntos de dados grandes e possibilidade de ranqueamento de *features* baseado em contribuição (WU et al., 2019).

A Figura 27 apresenta a estratégia empregada nos experimentos de segmentação semântica dos elementos das barragens e diques utilizando modelos de RF. A metodologia é composta por três macro-etapas. A Etapa (1) consiste no método de pré-processamento

de dados apresentado no capítulo anterior, que culmina na produção dos DOMs. A Etapa (2) envolve a engenharia das *Features* utilizadas para o treinamento dos modelos, que ocorre na Etapa (3). O resultado deste processo é um modelo de segmentação semântica treinado em um conjunto otimizado de *features* e avaliado com base em métricas de desempenho aplicadas ao conjunto de teste.

Para a criação de um conjunto de dados para segmentação semântica baseada em pixel, os dados foram transformados em tabela, na qual cada linha representa um pixel da imagem de entrada e cada coluna representa as *features* de entrada do modelo. Inicialmente, o conjunto de dados compreendeu sete características: pixels em escala de cinza, valores de refletância para cada banda capturada pelo sensor RedEdge-P e os rótulos de pixel definidos nesta seção.

Como mencionado anteriormente, cada DOM foi fatiado em segmentos de  $256 \times 256$  pixels, dos quais 70% foram alocados para o conjunto de treinamento, 15% para o conjunto de validação e 15% para o conjunto de teste. Devido ao desequilíbrio entre classes no conjunto de dados de treinamento, causado pela dominância das classes “Cobertura Vegetal” e “Plano de Fundo”, as classes majoritárias foram subamostradas e a classe minoritária “Escadarias” foi sobreamostrada para igualar o número de amostras pertencentes à classe “Canaletas de Drenagem”. As distribuições originais foram mantidas para os conjuntos de validação e teste. O número total de amostras em cada conjunto após o processo de balanceamento é sumarizado na Tabela 8.

O processo de sobreamostragem foi realizado utilizando a técnica ADASYN (Adaptive Synthetic Sampling), que gera exemplos sintéticos da classe minoritária de forma adaptativa, priorizando regiões do espaço de atributos onde o modelo apresenta maior dificuldade de aprendizado. Essa abordagem permite reduzir o viés causado pelo desbalanceamento de classes e melhora a representatividade das amostras minoritárias no conjunto de treinamento (HE et al., 2008). Como experimento adicional, o conjunto de dados multiclasse também foi adaptado para realizar a tarefa de segmentação binária da classe “Cobertura Vegetal”.

Tabela 8 – Número balanceado de amostras (pixels) atribuídas aos conjuntos de treinamento, validação e teste.

**Fonte: Autor.**

Classe	Treinamento	Validação	Teste
Cobertura Vegetal	707,843	1,404,283	1,835,333
Canaletas de Drenagem	703,870	128,464	139,307
Escadarias	707,843	33,676	40,205
Plano de Fundo	707,843	334,121	475,523

A engenharia de *features* é uma etapa crucial no pipeline de aprendizado de máquina, onde conjuntos adicionais de *features* são computados para melhorar a separabilidade entre as classes e, conseqüentemente, aprimorar o desempenho do modelo. Para enriquecer o conjunto de dados, um total de cinco grupos de *features* distintos foram selecionados:

- **Refletância RGB (RGB):** Dados de refletância para as bandas Vermelho, Verde e Azul;
- **Refletância RE/NIR (MS):** Dados de refletância para as bandas Vermelho de Borda e Infravermelho Próximo;
- **Índices de Vegetação (IV):** NDVI, *Green Normalized Difference Vegetation Index* (Índice de Vegetação por Diferença Normalizada no Verde) (GNDVI), NDRE, e *Normalized Difference Water Index* (Índice de Água por Diferença Normalizada) (NDWI);
- **Operações de Filtragem (FLT):** Operações de filtragem de bordas e de suavização;

Cada *feature* calculada é responsável por mapear diferentes características das imagens de entrada. Para avaliar o impacto de cada grupo de características no desempenho do modelo de segmentação, diferentes combinações entre os grupos de *features*, referenciados neste trabalho como subconjuntos, foram testadas individualmente de acordo com a metodologia proposta por Wu (WU et al., 2019). O subconjunto com melhor desempenho é submetido ao processo de ranqueamento de *features* baseado na métricas de contribuição baseada em impureza (SCORNET, 2021). O modelo final é então selecionado, sendo composto pelo conjunto de características mais relevantes.

A engenharia de *features* descritivas das classes em estudo é uma etapa essencial do processo de construção de modelos de ML (LINHUI et al., 2021), contribuindo para aumentar a separabilidade entre as classes. Neste experimento, os subconjuntos de *features* de treinamento são compostos a partir de combinações entre os quatro grupos de *features* mencionados anteriormente. Exemplos de imagens do conjunto de dados, *features* extraídas de cada grupo e máscaras de segmentação anotadas manualmente são ilustrados na Figura 28.

As *features* iniciais são baseadas nas medições de refletância calibradas capturadas pelo sensor multiespectral. As diferentes bandas capturadas pelo sensor são divididas em dois grupos: o primeiro grupo contendo os valores de refletância RGB, ou seja, dados da banda visível, e o segundo grupo contendo valores de refletância multiespectral, ou seja, dados das bandas não visíveis RE (Red Edge) e NIR (Infravermelho Próximo). Essa




Figura 28 – Exemplos de imagens do conjunto de dados, *features* extraídas e máscaras de segmentação anotadas manualmente.

**Fonte: Autor.**

distinção é feita para avaliar o impacto dos dados de sensoriamento remoto multiespectral no desempenho do modelo RF.

O terceiro grupo de *features* consiste em uma seleção de IVs multiespectrais, que se baseiam na absorção e no espalhamento da radiação eletromagnética pela vegetação (TSOUROS et al., 2019). Os IVs são amplamente usados no campo do sensoriamento remoto e podem combinar informações RGB com outras bandas espectrais, como NIR e RE. Características como biomassa, status de nitrogênio, índice de água e saúde da vegetação podem ser obtidas pelo cálculo de diferentes IVs. Neste experimento, os seguintes IVs foram selecionados como *features* de treinamento: NDVI, GNDVI, NDRE e NDWI.

O quarto grupo de *features* foi extraído por meio de operações de filtragem para destacar diferentes características das imagens de entrada. Seis filtros distintos foram

usados para a detecção de bordas: Canny, Laplaciano, Roberts, Sobel, Scharr e Prewitt. Neste grupo também são incluídas operações de desfoque gaussiano e mediano com tamanhos de *kernel* variados.

Uma estratégia de treinamento baseada em subconjuntos (WU et al., 2019) foi utilizada para selecionar o conjunto de *features* ideal para treinamento do modelo final. As bandas de fora do espectro visível capturadas pelo sensor RedEdge-P foram propositalmente omitidas de alguns destes subconjuntos para que a contribuição das bandas Vermelho de Borda e Infravermelho Próximo pudessem ser analisadas. Os quatro subconjuntos selecionados para os experimentos são descritos a seguir <sup>1</sup>:

- **Subconjunto 1: RGB (4 *features*)** - Inclui apenas dados de refletância das bandas R, G e B. Este cenário emula o uso de sensores de câmeras tradicionais;
- **Subconjunto 2: RGB + MS + IV (11 *features*)** - Inclui dados de refletância das cinco bandas capturadas pelo sensor multiespectral (R, G, B, RE e NIR) e os IVs resultantes;
- **Subconjunto 3: RGB + FLT (21 *features*)** - Inclui a refletância das bandas R, G e B e as *features* geradas manualmente por operações de filtragem e detecção de texturas;
- **Subconjunto 4: RGB + MS + VI + FLT (27 *features*)** - Inclui todas as *features* geradas.

Nesta primeira etapa de treinamento, uma abordagem de busca em grade foi utilizada para treinar modelos de RF para segmentação binária e multiclasse, com números variados de classificadores, a fim de determinar a configuração ideal. Cada subconjunto foi treinado e avaliado para *ensembles* de 2, 4, 8, 16, 32, 64, 128 e 256 árvores de decisão (parâmetro *nTrees*). A avaliação de desempenho dos modelos desta etapa foi realizada com base nas métricas acurácia, F1-Score, erro *out-of-bag* e tempo de treinamento. Um total de 64 modelos únicos foram treinados neste estágio, e suas respectivas métricas de desempenho são apresentadas na Figura 29. Todos os experimentos deste trabalho foram realizados em um computador com um processador Apple Silicon M1 Pro de 8 núcleos com 3,22 GHz e 16 Gb de memória RAM, executando o sistema operacional MacOS Sequoia 15.1. Os melhores resultados encontrados para cada subconjunto de *features* são sumarizados na Tabela 9.

Em contraste com o Subconjunto 1, que foi treinado somente com dados de refletância nas bandas RGB, a inserção dos valores de refletância nas bandas RE e NIR capturadas pelo sensor multiespectral e dos IVs, no Subconjunto 2, levou a uma

<sup>1</sup> Todos os subconjuntos já incluem por padrão a imagem representada em escala de cinza.

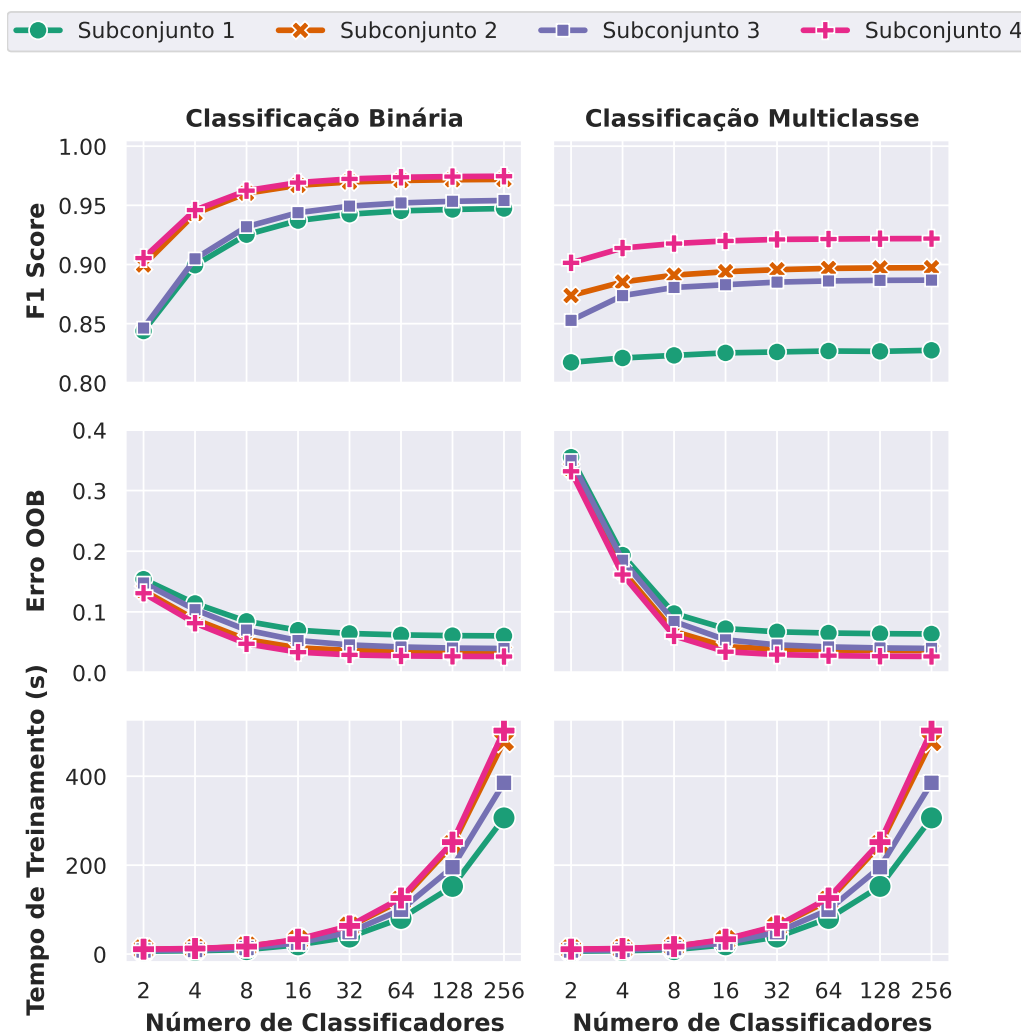


Figura 29 – Avaliação de desempenho com base no F1 Score, no Erro OOB e no tempo de treinamento para cada modelo explorado na busca em grade.

Fonte: Autor.

contribuição de até 2,46% e 6,98% no F1 Score para as tarefas de segmentação binária e multiclasse, respectivamente. Modelos baseados na refletância espectral de todas as bandas capturadas pelo sensor RedEdge-P alcançaram F1 Score de até 97,19% e 89,73% sem engenharia de *features* adicional.

O terceiro subconjunto é composto por dados de refletância RGB e os grupos de *features* extraídas manualmente, incluindo operações de filtragem e extração de texturas. Dados de refletância do espectro eletromagnético não-vísivel foram omitidos propositalmente neste experimento para avaliar a viabilidade de cenários em que sensores multiespectrais não estão disponíveis. Comparado ao subconjunto 1, o F1 Score do modelo de segmentação binária aumentou de 94,73% para 95,41%, enquanto o do modelo multiclasse aumentou de 82,75% para 88,68%. Este experimento destaca a importância da engenharia de *features* para alcançar modelos mais precisos.

O quarto subconjunto combina todas as *features* selecionadas, incluindo dados de refletância nas bandas R, G, B, RE e NIR, IVs, operações de filtragem e extração de texturas. Este modelo alcançou os melhores resultados, com 97,02% de acurácia e 97,46% F1 Score para segmentação binária. Para a segmentação multiclasse, a acurácia foi de 96,58% e F1 Score de 92,19%. O modelo treinado com o conjunto completo de *features* obteve o melhor resultado para ambas as tarefas de segmentação.

Tabela 9 – Melhores resultados obtidos nas tarefas de segmentação binária e multiclasse para cada subconjunto de *Features*.

Fonte: Autor.

Tarefa	Sub-conjunto	Features	<i>nTrees</i>	Acurácia	F1 Score	Erro OOB	Tempo de Execução
Binária	1	4	256	93.98%	94.73%	$6.04 * 10^{-2}$	306s
Binária	2	10	256	96.73%	97.19%	$3.40 * 10^{-2}$	479s
Binária	3	63	256	94.98%	95.41%	$3.96 * 10^{-2}$	385s
Binária	4	69	256	97.02%	97.46%	$2.64 * 10^{-2}$	502s
Multiclasse	1	4	256	93.05%	82.75%	$6.35 * 10^{-2}$	330s
Multiclasse	2	10	256	95.89%	89.73%	$3.62 * 10^{-2}$	543s
Multiclasse	3	63	256	95.06%	88.68%	$3.97 * 10^{-2}$	410s
Multiclasse	4	69	256	96.58%	92.19%	$2.65 * 10^{-2}$	581s

Embora o desempenho de modelos treinados apenas com dados de refletância RGB tenda a ser inferior, a grande quantidade de características que podem ser geradas por operações nessas bandas costuma ser suficiente para alcançar níveis satisfatórios de performance em tarefas de classificação de pixels, como segmentação de land-cover. Operações como suavização de imagens por meio de filtros de desfoque, detecção de bordas e extratores de textura são capazes de produzir características de alta qualidade que destacam diferentes aspectos das imagens de entrada. No entanto, várias características espectrais não são capturadas por sensores RGB tradicionais, abrindo espaço para melhorias com a adição de dados de refletância em bandas não visíveis.

O treinamento de um modelo de RF em um conjunto de dados com excesso de *features*, ou colunas, pode causar sobreajuste (LINHUI et al., 2021). Para mitigar este problema e para melhorar o desempenho do modelo, foi aplicada uma metodologia de ranqueamento de *features* para selecionar e manter apenas as características com contribuição significativa para a precisão geral do modelo. A importância de cada coluna do conjunto de dados foi calculada com base na métrica de diminuição média da impureza (MDI) (SCORNET, 2021).

Um total de 38 modelos foram treinados utilizando conjuntos que incluíam as *features* com MDI superior a 0,01, conforme calculado com base no modelo treinado

no subconjunto 4 e com  $nTrees = 256$ . Uma tendência de aumento nas métricas de desempenho foi observada com a adição sequencial de características seguindo a ordem das taxas de contribuição. Um total de 15 modelos foram treinados para segmentação binária (Top 2 ao Top 16). Para a tarefa de segmentação multiclasse, 23 modelos foram treinados (Top 2 ao Top 24). Uma tendência de subida nas métricas de de desempenho foi observada com a inclusão das *features* com  $MDI > 0.01$ , evidenciando a contribuição das características de maior MDI. Os modelos de melhor performance atingiram F1 Scores de 97,42% e 92,15%, respectivamente para as tarefas de segmentação binária e multiclasse. A Figura 30 apresenta os resultados do processo de ranqueamento.




Figura 30 – Treinamento de modelos para as Top X *features* ranqueadas por importância calculada com base na Diminuição Média da Impureza (MDI).

Fonte: Autor.

O ranqueamento de *features* revelou que os IVs (NDWI, GNDVI, NDVI, NDRE) e as bandas capturadas pelo sensor multiespectral tiveram os maiores impactos positivos na performance dos modelos RF. A banda Azul apresentou maior impacto positivo na performance de modelos de segmentação multiclasse. Adicionalmente, apesar do menor grau de MDI, as características derivadas de filtros Gaussianos, Médios e Gabor foram consistentemente selecionadas, destacando sua contribuição na distinção entre diferentes tipos de land-cover. Os resultados do processo de ranqueamento demonstram que um




Figura 31 – Matriz de Confusão do modelo de segmentação RF. Os valores percentuais presentes na diagonal principal da matriz representam as classificações realizadas corretamente para cada classe nos dados do conjunto de teste.

Fonte: Autor.

conjunto compacto contendo *features* selecionadas é suficiente para alcançar desempenhos satisfatórios, reduzindo o custo computacional dos modelos.

O modelo final para a tarefa de segmentação binária foi treinado com as 17 *features* que mais contribuíram para a performance com base no MDI. O modelo multiclasse foi treinado com as 24 *features* mais significativas. Estes modelos foram avaliados com base em métricas derivadas da matriz de confusão apresentada na Figura 31. Com base nas métricas apresentadas a seguir é possível avaliar a qualidade do modelo treinado e a capacidade de diferenciação entre as classes.

Métricas como precisão, sensibilidade e F1 *Score* foram calculadas para cada classe com base na matriz de confusão e estão resumidas na Tabela 10. Além disso, as métricas gerais dos modelos finais também são apresentadas.

Tabela 10 – Análise de desempenho do modelo final de RF, incluindo métricas gerais e específicas por classe.

Fonte: Autor.

Métricas por Classe				
Classe	Precisão	Revocação	F1-Score	IoU
<b>Segmentação Binária</b>				
Vegetação	0,994	0,953	0,973	0,948
Não-Vegetação	0,882	0,984	0,930	0,870
<b>Segmentação Multiclasse</b>				
Vegetação	0,985	0,989	0,987	0,975
Drenos	0,850	0,814	0,832	0,712
Escadarias	0,990	0,968	0,979	0,958
Plano de Fundo	0,999	0,999	0,999	0,999

Métricas Gerais do Modelo RF	Binária	Multiclasse
Acurácia	0,968	0,942
Precisão	0,994	0,955
Revocação	0,9531	0,942
F1-Score	0,973	0,949
IoU	0,909	0,911
Tempo de Treinamento	500s	2.061s

Os resultados obtidos para a tarefa de segmentação binária atingiram 98,4% de F1 Score e 94,8% de IoU para a classe cobertura vegetal. No entanto, para a classe negativa, que representa os demais tipos de land-cover, houve uma queda em ambas as métricas para 93,0% F1 Score e 87,0% IoU. Essa queda indica um aumento na taxa de falsos positivos, ou seja, pixels que deveriam ter sido classificados como cobertura vegetal foram atribuídos à classe negativa. Em geral, o classificador binário alcançou 97,3% de F1 Score e 90,9% de IoU.

O modelo de segmentação multiclasse alcançou 97,9% F1 Score e 95,8% IoU para todas as classes consideradas neste estudo, exceto pela classe "Canaletas de Drenagem", que obteve 82,9% F1 Score e 71,2% IoU. O desempenho inferior obtido por esta classe pode ser atribuído à qualidade do processo de rotulagem das imagens, especificamente nas áreas sombreadas e de transição entre a cobertura vegetal e os drenos. A matriz de confusão indica que a cobertura vegetal foi classificada corretamente 98,9% das vezes, enquanto as canaletas de drenagem foram confundidas com a vegetação em 18,8% dos casos, que estão concentrados nas bordas das canaletas. O excesso de vegetação presente nas bordas dos drenos é apontada como uma das possíveis causas que dificulta a distinção entre as classes.

Apesar da performance satisfatória do modelo em obtida nesta análise quantitativa, a avaliação qualitativa das máscaras de segmentação foi prejudicada pela presença de artefatos e ruídos. O efeito *salt-and-pepper* é um fenômeno comum em abordagens de segmentação semântica baseadas em pixel e que afeta negativamente a qualidade das máscaras de segmentação (Paredes-Gómez et al., 2020). Para mitigar este problema, uma etapa de pós-processamento foi aplicada às máscaras de segmentação resultantes para remover ruídos isolados e suavizar as máscaras, melhorando a continuidade das classificações (LINHUI et al., 2021).

Para reduzir as classificações errôneas causadas pelo efeito *salt-and-pepper*, o filtro de maioria foi aplicado na etapa de pós-processamento. Especificamente, uma janela deslizante de tamanho  $k \times k$  (com  $k=3$ ) foi aplicada a cada imagem de saída. Cada pixel




Figura 32 – Comparação entre as máscaras de segmentação anotadas, previstas pelo modelo e corrigidas após pós-processamento.

Fonte: Autor.

foi reatribuído à classe mais frequente em sua vizinhança local. A Figura 32 apresenta uma comparação entre imagens RGB, máscaras de segmentação anotadas, previsões do modelo e previsões refinadas.

A comparação entre as máscaras de segmentação anotadas, previstas e refinadas é feita utilizando a métrica Interseção sobre União (IoU), como mostrado na Figura 32. O pós-processamento das previsões resultou em melhorias na IoU de todas as imagens do conjunto de teste, juntamente com um aprimoramento significativo na qualidade visual

das previsões pela remoção de ruídos. Para detalhar os efeitos do pós-processamento, a Tabela 11 reporta a IoU das previsões brutas e das saídas refinadas. Em resumo, o pós-processamento melhorou a IoU das máscaras de segmentação em até 3,68%.

Tabela 11 – Análise de desempenho do modelo final de RF, incluindo métricas gerais e específicas por classe.

Fonte: Autor.

Segmentação Binária	IoU Original	IoU Refinada
Vegetação	0,948	0,962 (+1,48%)
Não-Vegetação	0,870	0,902 (+3,68%)

Segmentação Multiclasse	IoU Original	IoU Refinada
Vegetação	0,975	0,977 (+0,21%)
Drenos	0,712	0,738 (+3,65%)
Escadarias	0,958	0,963 (+0,52%)
Plano de Fundo	0,999	0,999 (+0,00%)

Métricas Gerais dos Modelos	IoU Original	IoU Refinada
Segmentação Binária	0,909	0,932 (+2,53%)
Segmentação Multiclasse	0,911	0,919 (+0,88%)

Apesar do desempenho melhorado obtido após a aplicação da etapa de pós-processamento das máscaras de segmentação, os modelos de RF para segmentação baseada em pixel ainda apresentam limitações quanto ao aprendizado das características espaciais e contextuais presentes na vizinhança dos pixels. Uma solução mais robusta para este problema inclui a utilização de modelos de DL com RNCs como a FCN (LONG et al., 2015), U-NET (RONNEBERGER et al., 2015) ou DeepLab (CHEN et al., 2017a), que são capazes de abstrair características complexas e espaciais durante o processo de treinamento. Entretanto, modelos de DL tipicamente requerem conjuntos de dados maiores e mais robustos, o que pode ser um fator limitante em tarefas nichadas. A subseção seguinte apresenta os resultados obtidos com a abordagem baseada em RNCs para segmentação semântica de land-cover das estruturas.

## 5.2 Segmentação Semântica com Deep Learning

O advento de técnicas de DL desenvolvidas para segmentação semântica de imagens trouxe avanços significativos na capacidade de aprendizado e generalização dos modelos, além de eliminar a necessidade da extração manual de *features* (LV et al., 2023; HASAN et al., 2024). Modelos baseados em redes neurais totalmente convolucionais (LONG et al.,

2015), compostas por módulos de codificação e decodificação, apresentaram os primeiros resultados dos usos de RNCs para segmentação semântica. A Figura 33 apresenta a metodologia empregada para o treinamento de modelos de DL para segmentação de land-cover em barragens e diques de aterro.

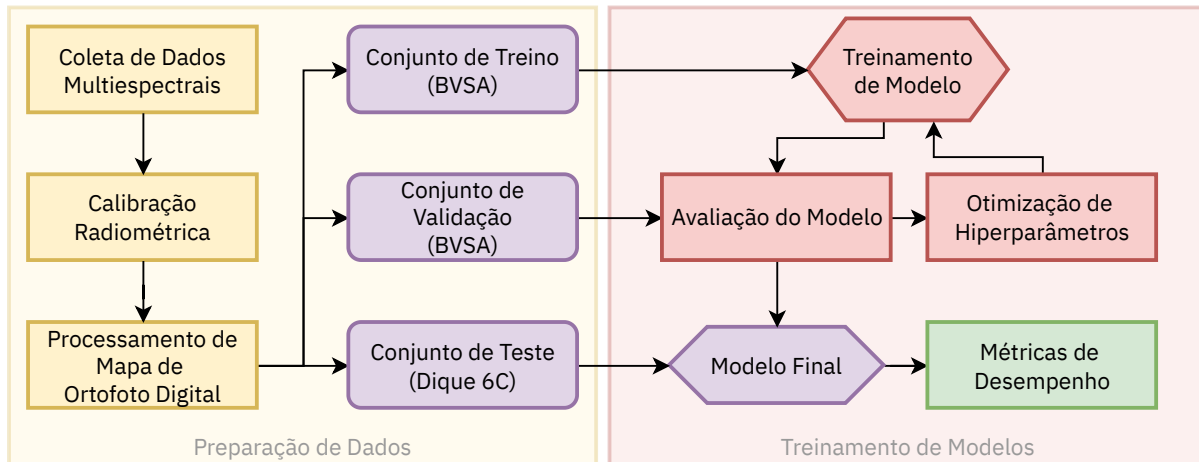


Figura 33 – Metodologia de Segmentação Semântica com modelos U-NET.

**Fonte: Autor**

A metodologia é composta por três macro-etapas. A Etapa (1) consiste no pré-processamento similar ao realizado anteriormente, no qual os dados são coletados durante missões automáticas utilizando o sensor RedEdge-P e posteriormente calibrados para processamento de DOMs. A Etapa (2) envolve o *loop* de treinamento e otimização de hiperparâmetros dos modelos de DL, que são treinados em segmentos do DOM de entrada. Após a geração das máscaras de segmentação, a Etapa (3) é responsável por reconstruir os resultados no tamanho original do DOM e realizar a avaliação de desempenho dos modelos treinados.

A técnica de fatiamento foi utilizada para dividir os DOMs em fatias de dimensões corretas para a inserção na camada de entrada dos modelos ( $256 \times 256 \times 5$ ). Durante o processo, a localização de cada fatia na imagem original é armazenada para que as máscaras de segmentação resultantes possam ser utilizadas para reconstruir o ortomosaico original. A Tabela 12 apresenta o número de imagens resultantes do processo de fatiamento. Um total de 1015 imagens foram geradas seguindo esta metodologia, sendo 67% imagens da BVSA utilizadas para treinamento, e os 33% restantes direcionados para o conjunto de teste com imagens do Dique 6C. Para avaliar a capacidade de generalização de modelos de DL, os dados capturados na Barragem Vertente do Santo Antônio foram utilizados apenas para treinamento e validação, enquanto os dados capturados no Dique 6C foram atribuídos ao conjunto de teste. A importância da testagem de modelos de ML e DL em imagens de localidades diferentes para avaliar o desempenho do modelo é destacada pelos autores de Osco et al., 2021 (OSCO et al., 2021).

Tabela 12 – Dimensões dos mapas referentes a BVSA e ao Dique 6C e número de imagens resultantes do processo de fatiamento em regiões de dimensões  $256 \times 256 \times 5$ .

Fonte: Autor.

Estrutura	Resolução do DOM	Número de Fatias
BVSA	$7661 \times 14799 \times 5$	677
Dique 6C	$4126 \times 10498 \times 5$	338

Neste trabalho, as arquiteturas de dois modelos derivados da FCN foram adaptadas para a utilização de dados multiespectrais de cinco canais. A primeira arquitetura consiste no modelo U-NET (RONNEBERGER et al., 2015), que apresenta vantagens como a capacidade de extração de características aos níveis global e local, além de apresentar bom desempenho em cenários com quantidades limitadas de dados (BRAGAGNOLO et al., 2021). A segunda arquitetura, a AU-NET é uma modificação da rede U-NET original proposta por Oktay et al. (OKTAY et al., 2018), que introduz o mecanismo de atenção à arquitetura para suprimir regiões irrelevantes à tarefa de classificação e destacar regiões de interesse.

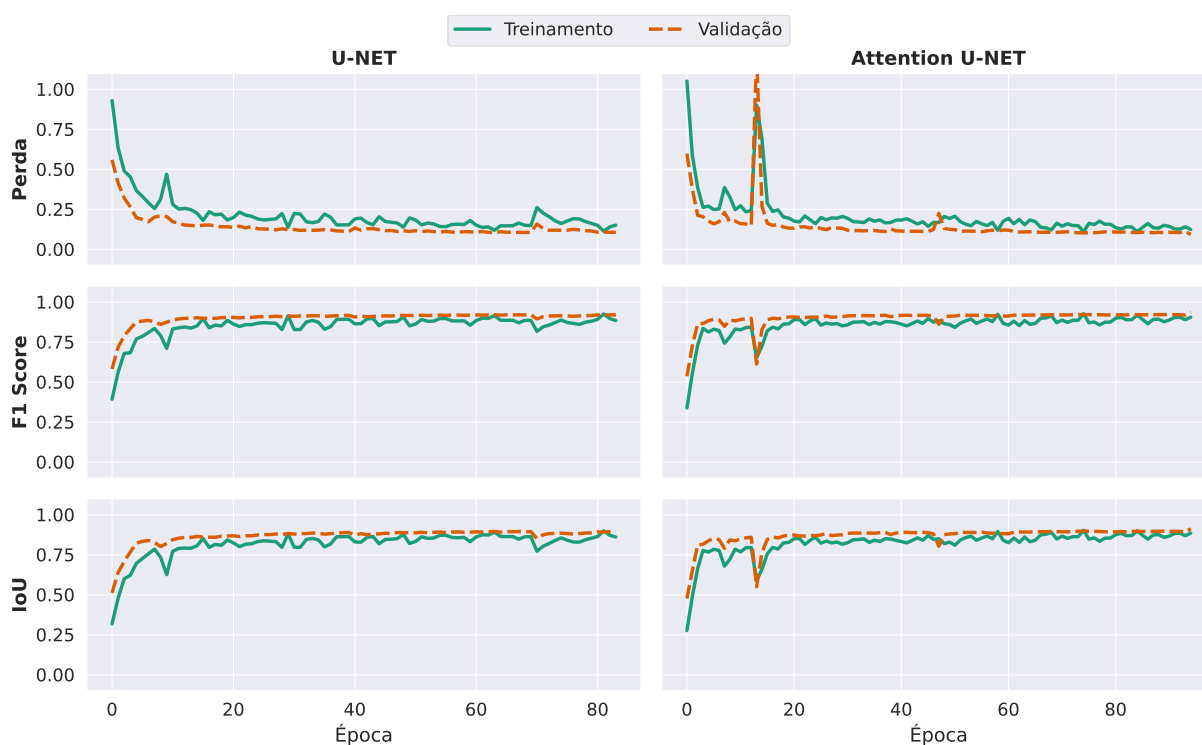


Figura 34 – Métricas de Perda, F1 Score e IoU ao longo do processo de treinamento do modelo U-NET.

Fonte: Autor

O treinamento dos modelos foi realizado em um computador com processador Apple Silicon M1 Pro de 8 núcleos com 3,22 GHz e 16 Gb de RAM, executando o sistema

operacional MacOS Sonoma 14.0. O otimizador selecionado para esta tarefa foi o otimizador ADAM (ZHANG, 2018), amplamente utilizado na literatura de aprendizado profundo, em conjunto com a combinação das funções de perda Entropia Cruzada Categórica, que mede a dissimilaridade entre a distribuição de probabilidade prevista e a distribuição real, e perda IoU, frequentemente utilizada em tarefas de segmentação. Os modelos foram treinados com tamanho de lote de 16, número máximo de 150 épocas, e com paciência de 10, permitindo que o treinamento seja interrompido caso não haja melhora na performance após 20 épocas. A taxa de aprendizado utilizada foi de 0,01 com parâmetro de decaimento até 0,001. Os gráficos da Figura 34 apresentam as métricas de perda, F1 Score e IoU obtidas ao longo do processo de treinamento dos dois modelos.

Os dois modelos testados convergiram nas primeiras dez épocas de treinamento, apresentando queda significativa na métrica de perda e ganhos nas métricas de F1 Score e IoU. O treinamento seguiu com ganhos progressivos de desempenho até atingir o critério de parada após 83 épocas para o modelo U-NET e 94 épocas para o modelo AU-NET. É notável que o modelo AU-NET, que utiliza mecanismos de atenção em sua arquitetura, convergiu mais rapidamente nas primeiras 5 épocas. Os modelos que obtiveram melhor desempenho para cada rede neural foram selecionados para a etapa de teste. A rede U-NET atingiu F1 Score de 91,86% e IoU de 89,21% para o conjunto de dados de validação, enquanto a rede AU-NET alcançou F1 Score de 93,70% e IoU de 91,27%, revelando a efetividade do mecanismo de atenção para segmentação semântica.

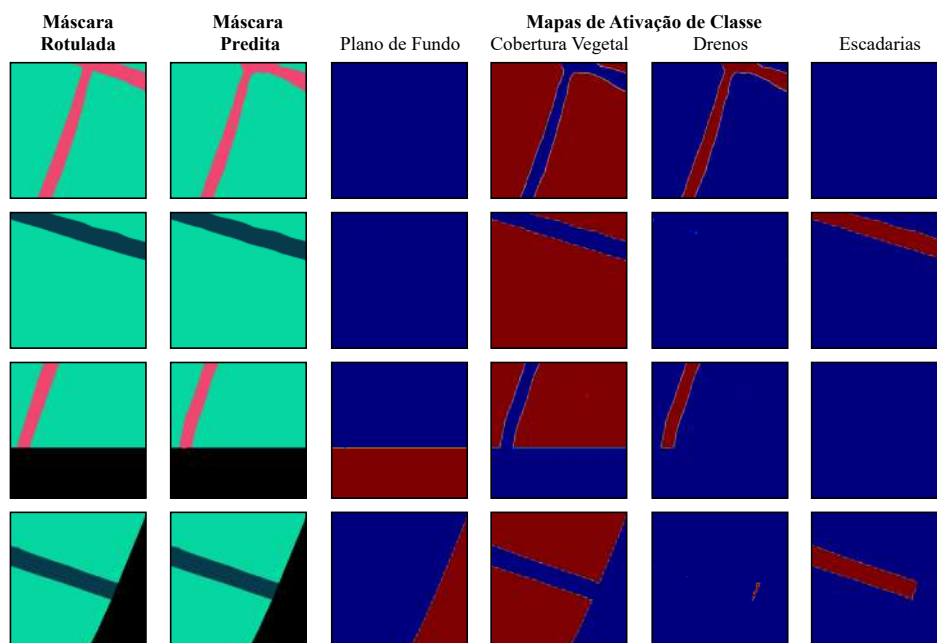


Figura 35 – Exemplos de inferências com o modelo AU-NET acompanhados dos mapas de ativação de classes (Grad-CAM).

Fonte: Autor

Classe Predita	(1) -	99.935%	0.065%	0.000%	0.000%
	(2) -	0.025%	98.866%	0.066%	1.043%
	(3) -	0.003%	0.888%	99.044%	0.065%
	(4) -	0.101%	7.292%	0.969%	91.637%
		(1) Plano de Fundo	(2) Vegetação	(3) Escadarias	(4) Drenos
<b>Classe Real</b>					

Figura 36 – Matriz de Confusão do modelo de segmentação AU-NET. Os valores percentuais presentes na diagonal principal da matriz representam as classificações realizadas corretamente para cada classe nos dados do conjunto de teste.

Fonte: Autor.

Exemplos de inferências realizadas pelo modelo AU-NET em imagens do conjunto de teste são apresentados na Figura 35. As inferências são acompanhadas dos mapas de ativação de classes, calculados com base no método de visualização Grad-CAM (SELVA-RAJU et al., 2017), que destaca as regiões de maior relevância para a classificação de cada pixel. Os mapas de ativação são úteis para entender como o modelo toma decisões e quais regiões da imagem influenciam mais na classificação de cada pixel. A visualização dos mapas de ativação revela que o modelo AU-NET é capaz de identificar corretamente as classes de interesse, destacando as áreas relevantes para a segmentação e também os erros cometidos pelo modelo.

Tabela 13 – Análise de desempenho do modelo AU-NET, incluindo métricas gerais e específicas por classe.

Fonte: Autor.

Métricas por Classe			
Classe	Precisão	Revocação	F1-Score
Cobertura Vegetal	0,993	0,989	0,991
Escadarias	0,939	0,990	0,964
Canaletas de Drenagem	0,889	0,916	0,903
Plano de Fundo	0,998	0,999	0,999

Métricas Gerais do Modelo AU-NET	
Acurácia Balanceada	0,9737
F1 Score	0,9641
IoU	0,9331

As máscaras de segmentação foram computadas para o conjunto de teste e utilizadas

na reconstrução do DOM em seu formato original. Com base na comparação com a máscara de segmentação anotada manualmente, a matriz de confusão da Figura 36 foi construída e utilizada para calcular as métricas de desempenho apresentadas na Tabela 13. Quando comparado ao desempenho dos modelos RF, a transição para modelos de RNC acarretou em melhorias significativas no número de classificações corretas das classes subrepresentadas, com um aumento de 2,24% para a classe de escadarias e, mais significativamente, um aumento de 10,4% para a classe canaletas de drenagem. Como ocorrido nos modelos RF, grande parte das classificações incorretas realizadas pelo modelo AU-NET consistem na confusão entre os pixels de transição entre as canaletas de drenagem e a cobertura vegetal, o que é esperado devido à precisão das anotações e áreas de sombreamento.

Em suma, os modelos de DL baseados em RNCs demonstraram ser mais robustos e eficazes na segmentação semântica de land-cover em comparação com os modelos de ML tradicional com RF. A capacidade de aprender características espaciais e contextuais das imagens, aliada à redução do esforço de engenharia de *features*, resultou em melhorias significativas na precisão da segmentação da classe canaletas de drenagem, que apresentou maior desafio para ambos os modelos. De posse dos modelos de segmentação treinados é possível avançar para a etapa seguinte, que consiste na extração da classe de interesse para análises posteriores baseadas em IV.

---

# Análise da Cobertura Vegetal em Taludes de Aterro

Este capítulo apresenta os resultados obtidos durante os experimentos referentes à etapa [4]. Análise da Cobertura Vegetal de Taludes de Aterro. Os experimentos foram realizados nos DOMs processados a partir dos dados capturados *in loco* nas estruturas BVSA e Dique 6C do complexo da UHE Belo Monte.

## 6.1 Geração de Índices de Vegetação Sintéticos a partir de Imagens RGB

O uso de dados multiespectrais no campo de sensoriamento remoto desempenha um papel fundamental na distinção, caracterização e análise de diferentes alvos na superfície terrestre, capturando informações que seriam indistinguíveis ao olho humano e imperceptíveis em imagens tradicionais RGB. Conforme demonstrado pelos resultados dos modelos de segmentação semântica apresentados no Capítulo 5, a inclusão das bandas do espectro não-visível, como o infravermelho próximo (NIR) e o vermelho de borda (RE) resultou em uma melhoria expressiva de até 8% no F1 Score dos modelos baseados em RF, destacando o enriquecimento que este tipo de informação proporciona ao conjunto de dados e seu impacto na performance dos modelos.

Apesar dessas vantagens, o custo associado à aquisição de sensores multiespectrais ainda é uma barreira significativa, frequentemente inviabilizando a utilização em larga escala desse tipo de equipamento, especialmente em contextos de recursos limitados ou estudos extensivos. Além disso, etapas adicionais de calibração radiométrica e alinhamento de bandas aumentam a complexidade e o tempo necessário para a utilização correta de dados multiespectrais, exigindo ferramentas especializadas e conhecimento técnico avançado.

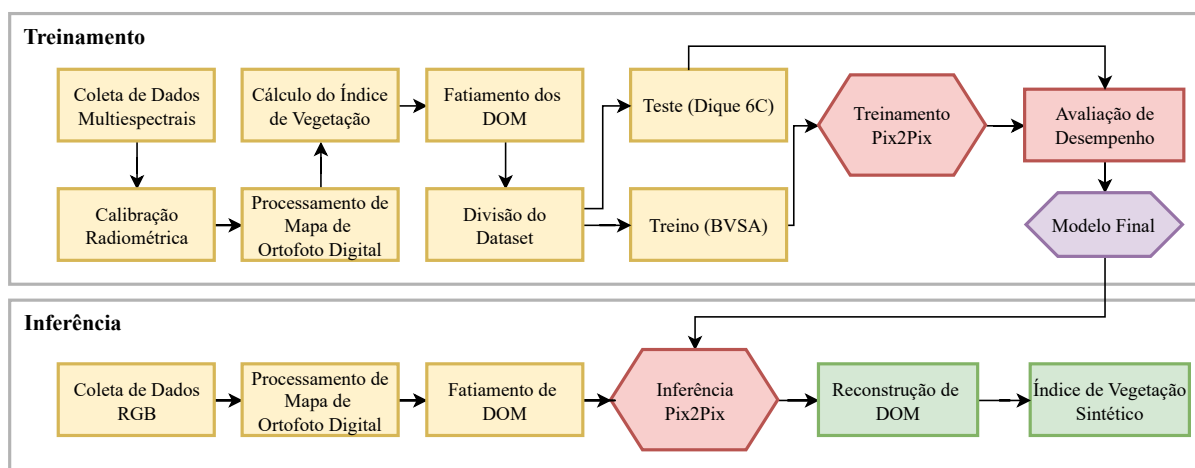


Figura 37 – Metodologia de geração de IVs sintéticos com o modelo cGAN Pix2Pix.

Fonte: Autor.

Para contornar essa limitação, esta seção propõe a adoção de técnicas de IA generativa, especificamente o modelo de cGAN Pix2Pix, para a geração de IVs sintéticos diretamente a partir de imagens RGB. O Pix2pix é um modelo de GAN condicional capaz de aprender a mapear uma imagem de entrada, gerando uma imagem de saída correspondente em domínios diferentes (ISOLA et al., 2018). A arquitetura do modelo é composta pela rede geradora U-NET, que preserva detalhes espaciais da imagem de entrada por meio de conexões entre camadas de codificação e decodificação, e pela rede discriminadora PatchGAN, responsável por avaliar o realismo das imagens geradas pelo gerador.

A Figura 37 detalha a metodologia empregada nesta etapa para a geração de IVs sintéticos com o modelo Pix2Pix. A metodologia proposta requer inicialmente uma fase de treinamento, utilizando pares correspondentes de imagens RGB e seus respectivos IVs calculados a partir dos dados multiespectrais originais. O método de coleta estabelecido nos capítulos anteriores foi utilizado para a produção dos DOMs utilizados para o treinamento dos modelos cGAN. Durante o treinamento, um dos IV calculáveis a partir dos dados multiespectrais disponíveis deve ser elencado como saída do modelo, enquanto a imagem RGB correspondente é utilizada como entrada. Os índices selecionados para os experimentos deste trabalho foram o NDVI e NDRE, amplamente utilizados na literatura de sensoriamento remoto multiespectral para análise da vegetação. De posse do modelo treinado para gerar IVs sintéticos a partir de imagens de entrada RGB, o método de inferência passa a ser simplificado, utilizando DOMs RGB como entrada para gerar IVs sintéticos.

O objetivo de uma rede cGAN é expresso pela equação 6.1, em que a função objetivo de  $G$  é minimizada contra o adversário  $D$ , que tenta maximizá-la. Durante o

treinamento do modelo Pix2Pix, o treinamento do discriminador  $D$  é alternado com o treinamento do gerador  $G$  a cada passo do gradiente descendente. Os autores propõem o uso do Gradiente Descendente Estocástico (SGD) com o otimizador Adam, com taxa de aprendizado de 0.0002 e parâmetros de *momentum*  $\beta_1 = 0.5$  e  $\beta_2 = 0.999$  (ISOLA et al., 2018). Além da função adversarial, o modelo inclui um termo de perda adicional baseado na distância L1 entre a imagem gerada  $G(x, z)$  e a imagem real  $y$ , como demonstrado na Equação 6.2. A função de perda total do gerador é definida

$$\mathcal{L}_{cGAN}(G, D) = \mathbb{E}_{x,y}[\log D(x, y)] + \mathbb{E}_{x,z}[\log(1 - D(x, G(x, z)))] \quad (6.1)$$

$$\mathcal{L}_{L1} = \mathbb{E}_{x,y,z}[\|y - G(x, z)\|_1] \quad (6.2)$$

A função objetivo final do modelo Pix2Pix é definida como a soma das Equações 6.1 e 6.2. O valor de  $\mathcal{L}_{L1}$  é ponderado por um fator  $\lambda$ , normalmente fixado em  $\lambda = 100$  conforme recomendação dos autores originais para preservar estruturas globais e a fidelidade das regiões contínuas da imagem (ISOLA et al., 2018). Desta forma, a função objetivo final é expressa pela Equação 6.3.

$$G^* = \arg \min_G \max_D \mathcal{L}_{cGAN}(G, D) + \lambda \mathcal{L}_{L1} \quad (6.3)$$

O conjunto de dados foi dividido entre treinamento e teste, sendo que os dados capturados na estrutura BVSA foram utilizados apenas para treinamento, enquanto os dados capturados no Dique 6C foram atribuídos ao conjunto de teste para avaliar a capacidade de generalização do modelo em diferentes localidades. Um total de 100 épocas de treinamento foram executadas com tamanho de lote de 1, como recomendado pelos autores do modelo Pix2Pix (ISOLA et al., 2018). As métricas de perda do discriminador e gerador dos modelos treinados para cada IV ao longo do processo de treinamento são apresentadas na Figura 38.

A qualidade dos modelos treinados foi avaliada no conjunto de teste com o uso de três métricas quantitativas: Erro Quadrático Médio (MSE), *Structural Similarity Index* (Índice de Similaridade Estrutural) (SSIM) e *Peak Signal to Noise Ratio* (Relação Sinal-Ruído de Pico) (PSNR). Essas métricas são comumente utilizadas na avaliação de modelos de tradução de imagens, pois permitem avaliar a similaridade entre a imagem gerada e a imagem de referência (ADAMIAK et al., 2023). As métricas de desempenho gerais alcançadas pelo modelo Pix2Pix são sumarizadas na Tabela 14.




Figura 38 – Métricas de treinamento do modelo CGAN.

Fonte: Autor.

Tabela 14 – Métricas de desempenho gerais do modelo Pix2Pix computadas para o conjunto de teste.

Fonte: Autor.

Métrica	NDVI	NDRE
PSNR	30,11 ( $\pm 2,09$ )	31,01 ( $\pm 1,97$ )
SSIM	0,95 ( $\pm 0,03$ )	0,94 ( $\pm 0,02$ )
MSE	$1,30 \times 10^{-3}$ ( $\pm 7,11 \times 10^{-4}$ )	$1,02 \times 10^{-3}$ ( $\pm 9,29 \times 10^{-4}$ )

O modelo Pix2Pix demonstrou capacidade satisfatória na geração de IVs sintéticos NDVI e NDRE, apresentando desempenho consistente no conjunto de teste para as três métricas de avaliação. As imagens geradas atingiram valores médios de similaridade estrutural de 0,95 ( $\pm 0,03$ ) para NDVI e 0,94 ( $\pm 0,02$ ) para NDRE, indicando que a estrutura espacial das imagens de referência foi preservada com alta fidelidade nas imagens sintéticas geradas pelo modelo.

No que se refere à qualidade visual expressa pela métrica PSNR, os valores médios obtidos foram de 30,11 ( $\pm 2,09$ ) dB para NDVI e 31,01 ( $\pm 1,97$ ) dB para NDRE, sugerindo que as imagens geradas possuem uma relação sinal-ruído satisfatória e condizente com os resultados alcançados na literatura correlata (DAVIDSON et al., 2022). Além disso, a métrica MSE apresentou valores médios de erro de  $1,30 \times 10^{-3}$  e  $1,02 \times 10^{-3}$  para NDVI e NDRE, respectivamente, confirmando que os valores gerados pelos modelos se aproximam numericamente dos valores reais, com baixa variabilidade.




Figura 39 – Métricas de desempenho PSNR, SSIM e MSE computadas para as 225 imagens do conjunto de teste individualmente.

**Fonte: Autor.**

A Figura 39 complementa a análise dos resultados do modelo ao ilustrar o desempenho do modelo para cada uma das 225 imagens presentes no conjunto de teste, revelando a baixa dispersão e estabilidade dos resultados. Em conjunto, o conjunto de métricas apresentado demonstra que o modelo foi capaz de generalizar adequadamente para o conjunto de teste que contém imagens capturadas em uma localidade diferente daquela utilizada para treinamento, mantendo as características estruturais e visuais das imagens de entrada.

A análise de regressão apresentada nas Figuras 40a e 40b foi realizada para avaliar a correlação entre as métricas SSIM, PSNR e MSE computadas entre as imagens RGB originais e os IVs originais e gerados pelo modelo Pix2Pix. A alta correlação apresentada entre as métricas obtidas para os IVs originais e os sintéticos ( $R^2 > 0.95$ ) indica que os dois modelos foram capazes de gerar imagens sintéticas de qualidade e com consistência, preservando características estruturais (SSIM), a qualidade visual (PSNR) e a acurácia radiométrica (MSE) das imagens de referência.

Por fim, as Figuras 41 e 42 apresentam uma comparação visual entre as imagens RGB de entrada, os índices NDVI e NDRE calculados a partir dos dados multiespectrais originais e os índices sintéticos gerados pelo modelo Pix2Pix. As Figuras também apresentam uma comparação entre os histogramas dos valores dos índices originais e sintéticos,

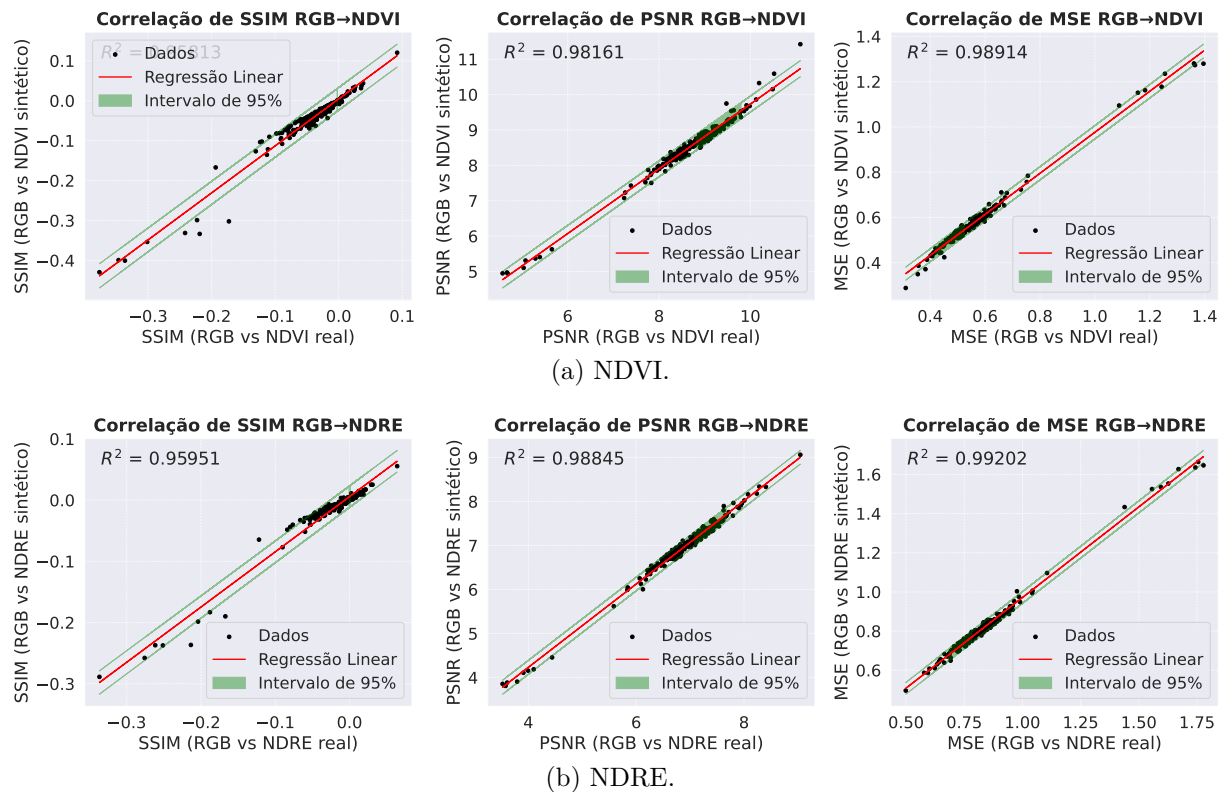


Figura 40 – Correlação entre as métricas SSIM, PSNR e MSE computadas entre as imagens RGB originais e os IVs originais e gerados pelo modelo Pix2Pix.

Fonte: Autor.

permitindo uma análise mais detalhada da distribuição dos valores obtidos pelo modelo e como eles se comparam aos valores alvo.

Em uma análise qualitativa e visual, os índices gerados pelo modelo Pix2Pix se assemelham aos índices calculados a partir dos dados multiespectrais capturados pelo sensor RedEdge-P tanto em estrutura quanto em distribuição de valores. A similaridade estrutural é evidente, com os índices sintéticos preservando as características espaciais e texturas das imagens de referência. A distribuição dos valores dos índices sintéticos também se alinha com a distribuição dos valores dos índices originais, indicando que o modelo foi capaz de capturar as variações nos valores dos índices de vegetação presentes nas imagens de entrada.

Os resultados apresentados nesta seção demonstram que o modelo Pix2Pix é capaz de gerar IVs sintéticos de qualidade a partir de imagens RGB no contexto de monitoramento de barragens de aterro, preservando as características estruturais e visuais das imagens de referência. Os índices existentes na literatura de sensoriamento remoto multiespectral, como o GNDVI e NDWI, permitem que a metodologia seja adaptada para diferentes tipos de análise, reduzindo a necessidade de aquisição de sensores multiespectrais. A próxima seção apresenta os resultados finais da extração de métricas de saúde da cobertura vegetal.

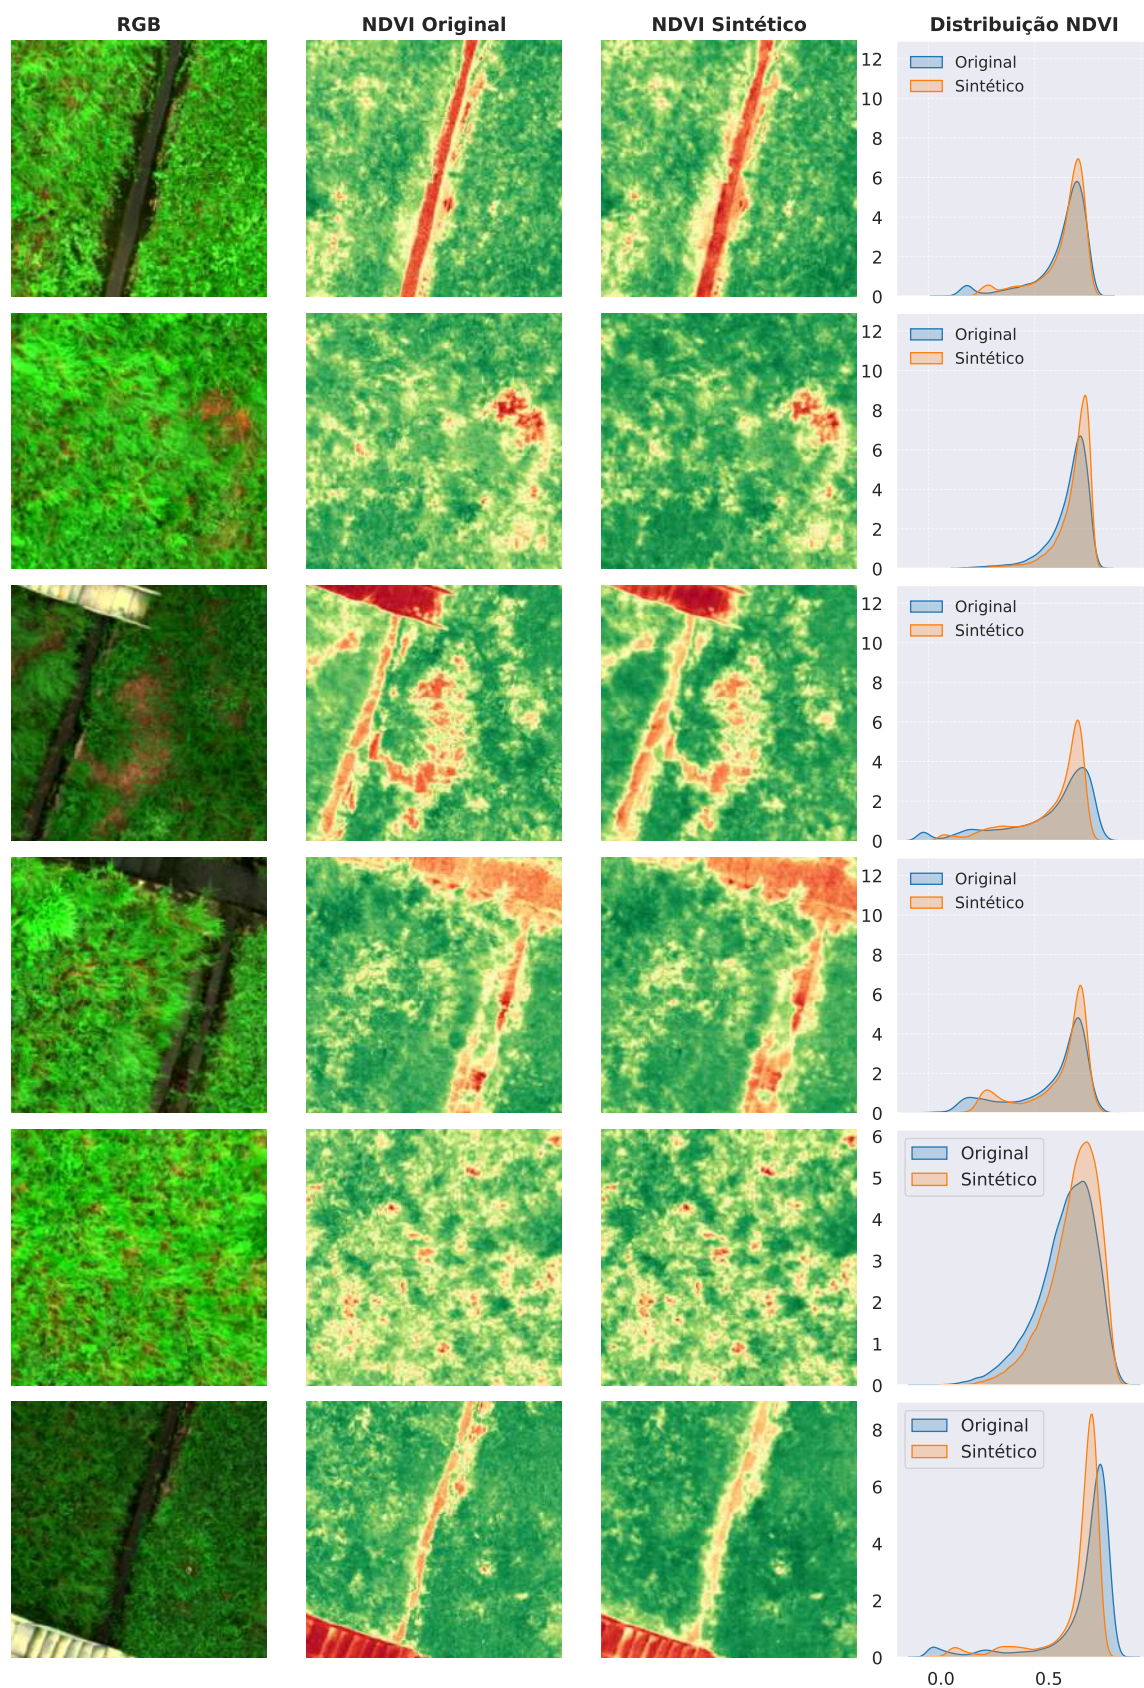


Figura 41 – Comparação entre as imagens de entrada RGB, os índices NDVI originais e os índices NDVI gerados pelo modelo Pix2Pix.

Fonte: Autor.

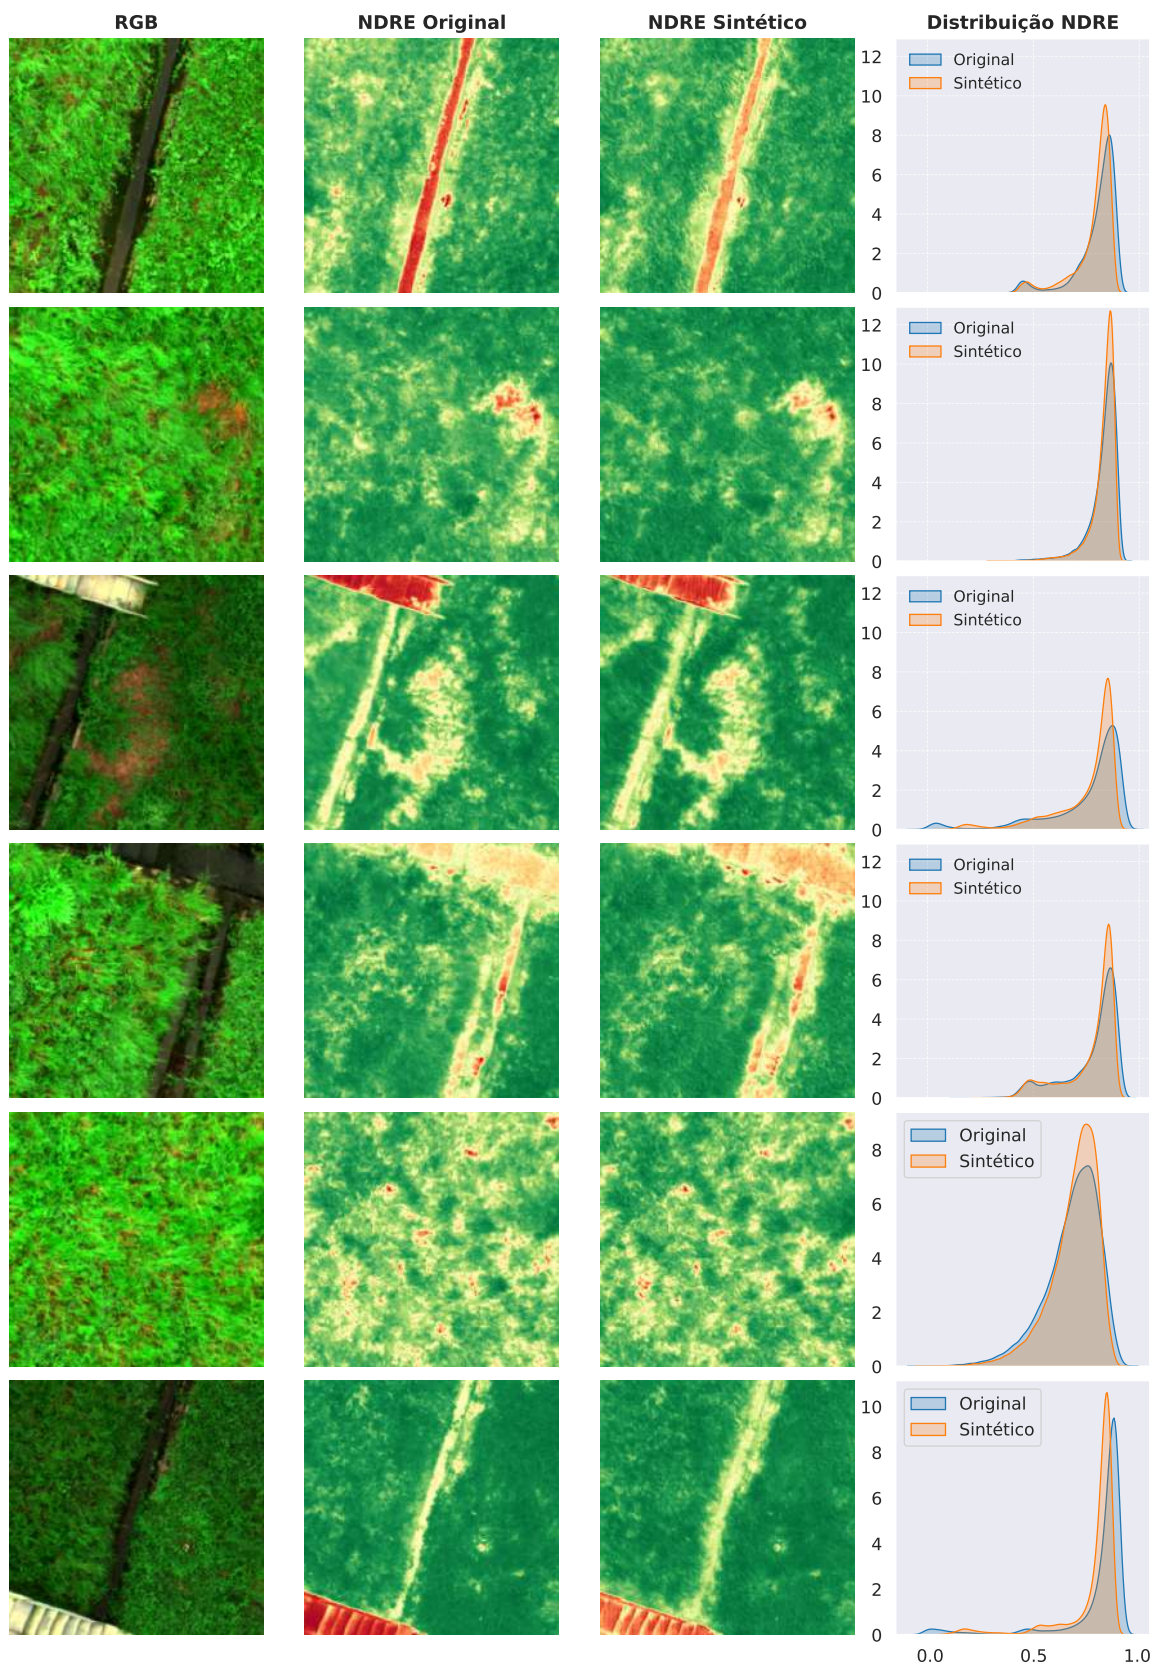


Figura 42 – Comparação entre as imagens de entrada RGB, os índices NDRE originais e os índices NDRE gerados pelo modelo Pix2Pix.

Fonte: Autor.

## 6.2 Extração de Métricas de Saúde da Vegetação

O conjunto de metodologias apresentadas neste trabalho, desde a definição dos protocolos para execução de missões automatizadas nas estruturas do Complexo da UHE Belo Monte, calibração e processamento da imagens para geração dos DOMs, incluindo as metodologias de segmentação semântica dos mapas e geração de IVs sintéticos, culminam na etapa de extração de métricas de saúde da cobertura vegetal. O objetivo desta etapa é extrair o conjunto de índices de vegetação selecionados pelo time de segurança de barragens do complexo com precisão, contribuindo para o monitoramento contínuo das estruturas e detecção precoce de anomalias.

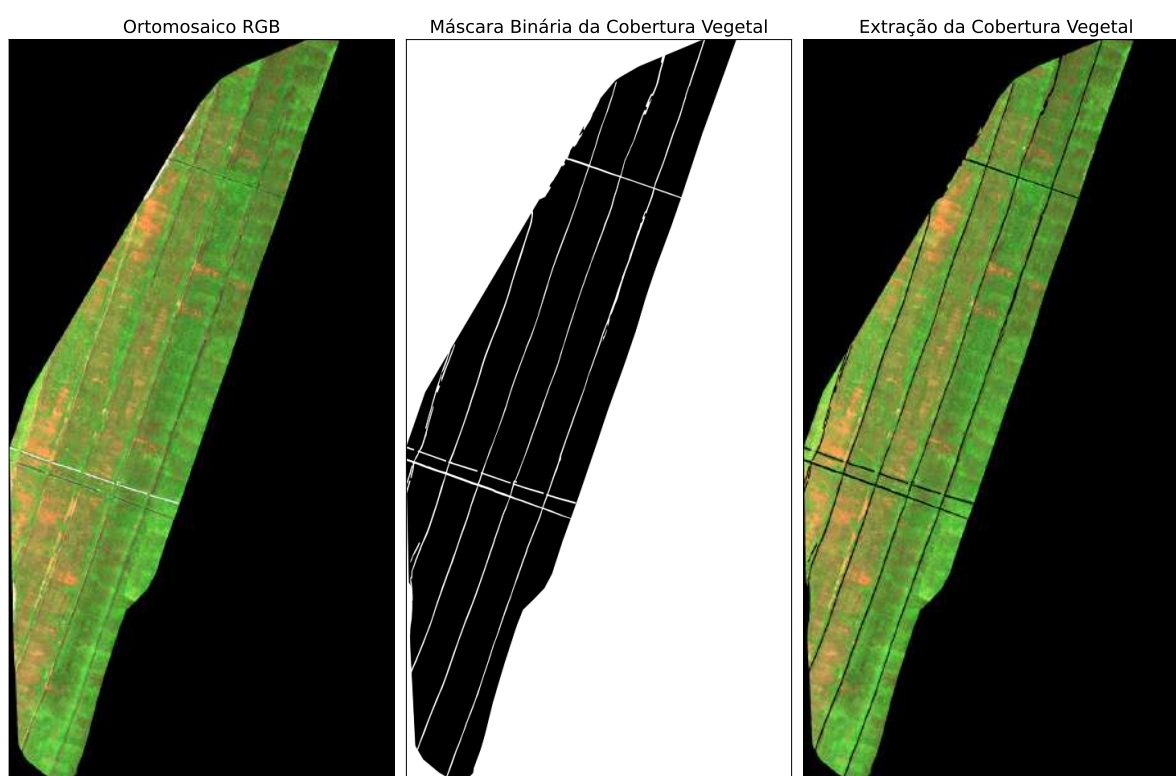


Figura 43 – Extração dos pixels referentes a cobertura vegetal do talude com base nos resultados da segmentação semântica.

**Fonte: Autor**

Os DOMs processados são submetidos aos modelos de segmentação semântica para que a extração da cobertura vegetal seja realizada de forma precisa, removendo elementos que não são necessários para a análise da cobertura vegetal para que os mesmos não interfiram na análise da vegetação. A Figura 43 apresenta o processo de extração da cobertura vegetal, no qual a máscara de segmentação binária gerada pelo modelo AU-NET identifica os pixels pertencentes à classe de cobertura vegetal. A máscara binária é aplicada ao DOM através de uma operação de multiplicação ponto-a-ponto, resultando

em uma imagem RGB que contém apenas os pixels de vegetação e o plano de fundo. As análises posteriores consideram apenas estes pixels, evitando que os demais tipos de land-cover presentes na barragem interfiram nos resultados.

A extração dos índices de vegetação é então realizada para os pixels de cobertura vegetal das barragens, nesta etapa são calculados os índices NDVI, NDRE, GNDVI e NDWI, que são armazenados no banco de dados do sistema computacional para acompanhamento da saúde da vegetação ao longo do tempo. A análise inicial empregada nesta etapa, a partir dos valores de pixel dos IVs, busca a diferenciação entre áreas de solo exposto e áreas de vegetação saudável. Para analisar as diferenças nas distribuições estatísticas de pixels em imagens de vegetações em diferentes estados de saúde, algumas amostras do ortomosaico capturado na BVSA foram selecionadas como exemplo.

A Figura 44 apresenta uma comparação entre três diferentes amostras de tamanho  $512 \times 512$  do ortomosaico. Para cada amostra são exibidos a imagem RGB, o índice NDRE, o histograma e o *boxplot* representando a distribuição de pixels na amostra. A primeira amostra apresenta, em sua maioria, pixels de vegetação saudável com valores de NDRE em torno de 0,8. A segunda amostra apresenta certa deterioração na saúde da vegetação, apresentando uma variação maior na distribuição de pixels. Já a terceira amostra exibe uma grande porcentagem de solo exposto, com uma variação ainda maior na distribuição de pixels.

Com a análise das distribuições de dados em cada um dos recortes apresentados na Figura 44 é possível inferir comportamentos distintos a partir das distribuições estatísticas de imagens de vegetação saudável, solo exposto, e situações intermediárias. Nesse contexto, com base nos conceitos dos IV e nas classificações apresentadas na literatura (CANDIAGO et al., 2015; CHENG et al., 2024), o valor do índice será utilizado para classificar a saúde da vegetação de cada pixel em categorias distintas:

- **Categoria 1 (entre 0.6 e 1.0):** Vegetação muito densa e saudável, representada pela cor verde-escuro;
- **Categoria 2 (entre 0.3 e 0.6):** Vegetação moderada a densa, representada pela cor verde-claro;
- **Categoria 3 (entre 0.0 e 0.3):** Vegetação esparsa ou estressada, representada pela cor amarela;
- **Categoria 4 (entre -1 e 0):** Ausência de vegetação na superfície e *outliers*, representada pela cor vermelha.

Os pixels pertencentes a cada uma das amostras retiradas do DOM da BVSA e apresentadas na Figura 44 foram submetidos a um processo de classificação com base nas

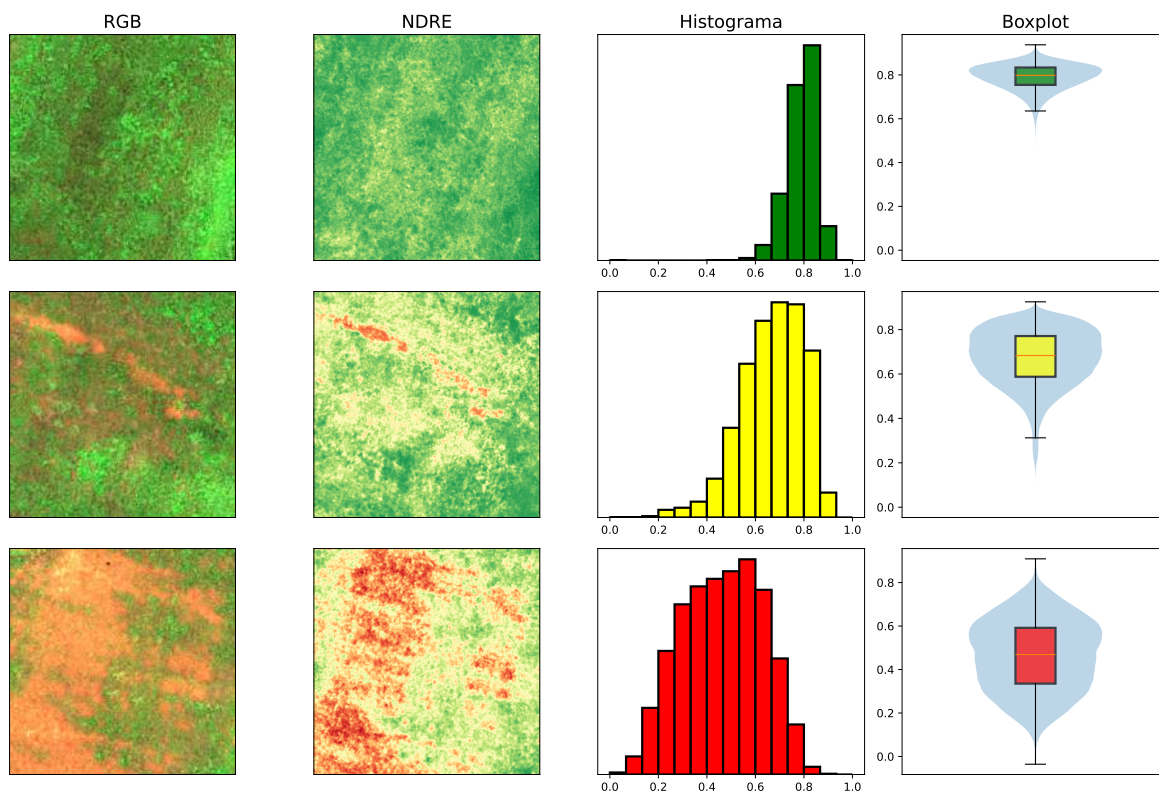


Figura 44 – Comparação do IV NDRE em três amostras da cobertura vegetal do talude.

Fonte: Autor

categorias apresentadas acima. A Figura 45 apresenta as proporções de pixels pertencentes a cada categoria para cada amostra. Com base neste resultado é possível quantificar a saúde geral da cobertura vegetal da estrutura com base em categorias. A métrica de desempenho definida para avaliação geral da saúde da vegetação é obtida a partir da soma da quantidade de pixels pertencentes às categorias de vegetação saudável (Categorias 1 e 2), em porcentagem.




Figura 45 – Contagem de pixels em cada categoria de saúde de vegetação nas amostras retiradas do DOM da BVSA.

Fonte: Autor

O conjunto de imagens, gráficos estatísticos e métricas objetivas permite que o usuário tenha uma visão geral da saúde da vegetação da estrutura em questão. Apesar do caráter subjetivo da interpretação visual das imagens, a análise quantitativa dos índices de vegetação fornece uma base sólida para a tomada de decisões. As métricas extraídas refletem o estado atual da cobertura vegetal dos taludes, porém seu real potencial só será plenamente explorado com a consolidação de uma série histórica proveniente de inspeções regulares. Esse acúmulo de dados é essencial para o desenvolvimento de metodologias automatizadas de detecção de anomalias baseadas em variações temporais. A metodologia proposta neste trabalho, aliada ao sistema computacional desenvolvido em colaboração com a Norte Energia S.A., estabelece uma base consistente para a automação do monitoramento com o uso de sensoriamento remoto multiespectral, técnicas de IA e VC, agregando redundância e confiabilidade aos processos de tomada de decisão.

---

## Considerações Finais

Esta tese de doutorado propôs e validou uma metodologia inovadora para o monitoramento da cobertura vegetal em taludes de aterro, fundamentada na integração de sensoriamento remoto multiespectral com algoritmos de IA e VC. Para demonstrar a aplicabilidade da metodologia proposta, foi conduzido um estudo de caso em parceria com a Norte Energia S.A. nas estruturas geotécnicas do Complexo da UHE Belo Monte, a maior hidrelétrica localizada 100% em território brasileiro, situada na bacia do Rio Xingu, Pará. A metodologia foi implementada como parte de um sistema *web* multimodal de monitoramento, desenvolvido para fortalecer e adicionar redundância aos processos de tomada de decisão, contribuindo diretamente para a segurança de barragens do complexo.

A metodologia proposta é estruturada em quatro macro-etapas. A Etapa [1] estabelece o protocolo para aquisição automatizada de dados multiespectrais nas estruturas monitoradas com o objetivo de garantir a consistência dos dados e, conseqüentemente, a reprodutibilidade dos experimentos. Subseqüentemente, na Etapa [2] são realizados os procedimentos de calibração radiométrica dos dados multiespectrais e o alinhamento entre bandas, possibilitando o processamento do DOM, que consolida toda a área inspecionada em um único arquivo de mapa de alta resolução. Com o DOM como base, a Etapa [3] emprega modelos de segmentação semântica para extrair e classificar os diferentes tipos de cobertura do solo (land-cover) presentes nas estruturas, com foco na cobertura vegetal dos taludes. Por fim, a Etapa [4] analisa os pixels correspondentes à cobertura vegetal dos taludes para extrair métricas relacionadas à saúde vegetal, objetivando a avaliação contínua da integridade estrutural e detecção precoce de anomalias.

O desenvolvimento da metodologia foi pautado nas necessidades e especificações apresentadas pelo time de segurança de barragens, engenheiros da Norte Energia S.A., que participaram ativamente do processo de concepção e validação do sistema de monitoramento. Duas estruturas do complexo de Belo Monte foram selecionadas para a realização dos experimentos: A BVSA e o Dique 6C. Campanhas de coleta de dados foram realizadas

com sucesso em ambas as estruturas seguindo os protocolos estabelecidos na Etapa [1] e permitindo o processamento de DOMs multiespectrais de alta resolução. Os mapas produzidos foram utilizados como base para o treinamento dos modelos desenvolvidos nas Etapas [3] e [4].

Dois métodos foram apresentados para segmentação semântica dos DOMs com o objetivo de extração da cobertura vegetal dos taludes de aterro. O primeiro método, baseado em ML, utiliza modelos de RF para classificar os diferentes tipos de land-cover presentes nas barragens. Após seleção e ranqueamento de *features*, o modelo alcançou 93,2% de IoU para segmentação binária e 91,9% para segmentação multiclasse, porém apresentou limitações na classificação das canaletas de drenagem e a presença de ruídos, comprometendo a qualidade das máscaras resultantes.

O segundo método foi testado para a segmentação semântica multiclasse para tentar contornar as dificuldades encontradas com o método de ML. Utilizando a arquitetura de FCN U-NET com mecanismo de atenção, o novo modelo baseado em DL alcançou 93,31% de IoU na classificação de land-cover, com um aumento de 7,1% no F1 Score da classe canaletas de drenagem. Em suma, o modelo baseado em DL apresentou resultados superiores ao modelo de ML, atingindo capacidade de generalização superior e máscaras resultantes com qualidade visual superior, facilitando a interpretação dos resultados. A acurácia satisfatória atingida pelos modelos de segmentação possibilitam a extração mais precisa de métricas relacionadas à cobertura vegetal dos taludes, focando em áreas de interesse.

A extração precisa da cobertura vegetal dos taludes foi então realizada a partir das máscaras geradas pelos modelos de segmentação. Métricas relevantes foram então extraídas para análise da saúde vegetal com base em IVs como NDVI, NDRE, GNDVI e NDWI. As métricas extraídas permitiram a diferenciação de áreas com diferentes densidades de vegetação, incluindo solo exposto, e a classificação da saúde vegetal de acordo com escalas encontradas na literatura. As métricas calculadas são automaticamente armazenadas no banco de dados do sistema de monitoramento, permitindo a análise temporal contínua mediante a realização das inspeções periódicas.

Levando em consideração a acessibilidade e a viabilidade de implementação da metodologia proposta, apenas ferramentas gratuitas e de código aberto foram utilizadas no desenvolvimento do sistema de monitoramento. Entretanto, entende-se que o elevado custo de aquisição de sensores multiespectrais pode ser um fator limitante para a adoção da metodologia em larga escala. Neste contexto, um modelo adicional foi proposto para possibilitar as análises propostas com o uso de imagens RGB tradicionais. Um modelo de cGAN Pix2Pix foi treinado para gerar IVs sintéticos a partir de entradas RGB, alcançando 95% de similaridade estrutural em relação aos dados reais para geração de NDVI e 94%

para geração de NDRE. Apesar do caráter experimental deste modelo, os resultados quantitativos e qualitativos apontam para a viabilidade de sua utilização em cenários onde a aquisição de imagens multiespectrais não é viável.

O desenvolvimento do projeto também foi marcado por dificuldades que impactaram o cronograma de execução e a abrangência dos resultados. Destaca-se a ausência de conjuntos de dados e de trabalhos correlatos que aplicassem técnicas de visão computacional e sensoriamento remoto multiespectral especificamente ao monitoramento de taludes de aterro, o que exigiu a construção de um pipeline metodológico próprio. Houve também atrasos significativos na aquisição de equipamentos e no início das campanhas de coleta de dados na UHE Belo Monte, comprometendo a disponibilidade de amostras para treinamento e validação. Adicionalmente, a incompatibilidade das bibliotecas oficiais de código aberto com o sensor RedEdge-P dificultou o processamento das imagens multiespectrais. Por fim, embora os modelos desenvolvidos tenham alcançado desempenho satisfatório nas barragens analisadas, sua aplicação ainda não foi avaliada em estruturas externas ao complexo, limitando a generalização dos resultados. As dificuldades encontradas e as soluções empregadas abrem portas para o desenvolvimento de trabalhos futuros.

O uso de VANTs para o monitoramento de estruturas geotécnicas apresenta desafios operacionais chave que devem ser abordados para implementações em larga escala. A autonomia da bateria continua sendo uma limitação principal, pois a maioria dos VANTs comerciais opera por menos de uma hora por ciclo. Neste estudo, uma missão completa de coleta de dados para uma única estrutura foi concluída em um único ciclo de bateria. Contudo, o monitoramento em larga escala de múltiplas estruturas exige a otimização do tamanho da frota e de baterias de reserva para manter a coleta de dados contínua. Questões de estabilidade devido ao vento e às condições climáticas variáveis podem ser mitigadas por meio de planejamento de rota em tempo real e controle de voo adaptativo, garantindo o georreferenciamento preciso e o alinhamento das imagens.

Este estudo representa um primeiro passo para o avanço do monitoramento baseado em imagens na indústria de barragens, abordando a lacuna crítica causada pela inexistência de conjuntos de dados disponíveis publicamente. Sem dados acessíveis, o desenvolvimento de soluções inovadoras de aprendizado de máquina e profundo permanece limitado. A expansão do conjunto de dados para incluir uma gama mais diversificada de estruturas e condições ambientais é uma prioridade chave para trabalhos futuros, permitindo o desenvolvimento de modelos de aprendizado profundo para segmentação de imagens e detecção de anomalias, que exigem dados mais volumosos e variados para um desempenho ótimo. A realização contínua de inspeções regulares e a atualização periódica do conjunto de dados também é essencial para o desenvolvimento de modelos temporais para detecção de anomalias.

Pesquisas futuras também explorarão a viabilidade do monitoramento em tempo real, avaliando como métodos de coleta de dados automatizados e contínuos podem ser integrados ao fluxo de trabalho proposto. Embora a análise em tempo real não seja um requisito atual para detectar anomalias graduais na vegetação, avançar para avaliações mais frequentes ou automatizadas poderia aprimorar as capacidades de alerta precoce na segurança de barragens. Adicionalmente, a avaliação da escalabilidade será um foco crítico, avaliando como esta metodologia pode ser implementada de forma eficaz em múltiplas barragens de grande porte com condições geotécnicas e ambientais distintas. O desenvolvimento futuro envolverá a otimização das estratégias de aquisição e processamento de dados para permitir uma adoção mais ampla de estruturas de monitoramento baseadas em VANTs na gestão da segurança de barragens. Além disso, a estrutura apresentada neste trabalho pode ser adaptada para uma gama mais ampla de estruturas geotécnicas, expandindo o conjunto de dados e ajustando o modelo de segmentação para diferentes contextos ambientais e geológicos.

## 7.1 Produção Científica e Tecnológica

Esta seção apresenta a produção científica e tecnológica oriunda dos resultados da presente pesquisa. Os artigos científicos produzidos como compilação de resultados são apresentados na Tabela 15. Os produtos de *software* desenvolvidos no contexto do projeto da pesquisa, desenvolvimento e inovação em parceria com a Norte Energia S.A. foram registrados pelo Instituto Nacional da Propriedade Industrial (INPI) e são listados na Tabela 16.

Tabela 15 – Publicações de artigos científicos pretendidas e realizadas ao longo da realização deste trabalho.

**Fonte: Autor.**

<b>Enhancing Geotechnical Damage Detection with Deep Learning: a Convolutional Neural Network Approach</b>	
<b>Autores</b>	ARAUJO, T. M. A. ; TEIXEIRA, C. A. M. ; FRANCES, C. R. L.
<b>Status</b>	Publicado
<b>Publicação</b>	<i>PeerJ Computer Science</i>
<b>Qualis</b>	A1
<b>DOI</b>	< <a href="https://doi.org/10.7717/peerj-cs.2052">https://doi.org/10.7717/peerj-cs.2052</a> >

<b>Aerial Image Segmentation of Embankment Dams based on Multispectral Remote Sensing: A case study in the Belo Monte Hydroelectric Complex, Pará, Brazil</b>	
<b>Autores</b>	TEIXEIRA, C. A. M.; ARAUJO, T. M. A.; CARDOSO, E. H. S.; FILHO, M. A. C.; COSTA, J. C. W. A.; FRANCES, C. R. L.
<b>Status</b>	Publicado
<b>Publicação</b>	<i>PeerJ Computer Science</i>
<b>Qualis</b>	A1
<b>DOI</b>	< <a href="https://doi.org/10.7717/peerj-cs.2917">https://doi.org/10.7717/peerj-cs.2917</a> >

Tabela 16 – Registros de Programas de Computador (RPCs) registrados no Instituto Nacional da Propriedade Industrial (INPI) oriundos do projeto de Projeto de pesquisa e desenvolvimento ANEEL #23073.014329/2020-51 em parceria com a Norte Energia S.A..

Fonte: Autor.

<b>Sistema de Monitoramento de Barragens (SMB)</b>	
Tipo de Programa	IA-01
Número do Registro	BR512024002208-2
Data do Registro	01/12/2022
Linguagens de Programação	Python, Javascript, HTML, CSS
Instituição do Registro	INPI - Instituto Nacional da Propriedade Industrial

<b>Módulo de Visão Computacional para Classificação e Análise da Cobertura Vegetal</b>	
Tipo de Programa	IA-01
Número do Registro	BR512024002215-5
Data do Registro	01/05/2024
Linguagens de Programação	Python
Instituição do Registro	INPI - Instituto Nacional da Propriedade Industrial

<b>Módulo de Detecção de Anomalias a partir de Dados de Instrumentos de Campo</b>	
Tipo de Programa	IA-01
Número do Registro	BR512024002214-7
Data do Registro	01/02/2024
Linguagens de Programação	Python, Javascript, HTML, CSS
Instituição do Registro	INPI - Instituto Nacional da Propriedade Industrial

<b>Módulo de Rede Neural Artificial para Previsão de Subpressões em Barragens</b>	
Tipo de Programa	IA-01
Número do Registro	BR512024002706-8
Data do Registro	03/10/2023
Linguagens de Programação	Python
Instituição do Registro	INPI - Instituto Nacional da Propriedade Industrial

---

## Referências Bibliográficas

ADAMIAK, M.; BĘDKOWSKI, K.; BIELECKI, A. Generative adversarial approach to urban areas ndvi estimation: A case study of łódź, poland. *Quaestiones Geographicae*, Uniwersytet im. Adama Mickiewicza w Poznaniu, v. 42, n. 1, p. 87–105, 2023. Citado 2 vezes nas páginas 53 e 93.

AGGARWAL, C. C. *Neural Networks and Deep Learning: A Textbook*. Cham: Springer International Publishing, 2018. ISBN 978-3-319-94462-3 978-3-319-94463-0. Disponível em: <<http://link.springer.com/10.1007/978-3-319-94463-0>>. Citado 3 vezes nas páginas 40, 41 e 42.

AMMIRATI, L. et al. Application of Multispectral Remote Sensing for Mapping Flood-Affected Zones in the Brumadinho Mining District (Minas Gerais, Brasil). *Remote Sensing*, v. 14, n. 6, p. 1501, mar. 2022. ISSN 2072-4292. Disponível em: <<https://www.mdpi.com/2072-4292/14/6/1501>>. Citado 3 vezes nas páginas 48, 52 e 55.

ANA. *Definições Importantes Sobre Segurança de Barragens*. 2022. Citado 2 vezes nas páginas 21 e 120.

ANA, A. N. d. Á. *Manual Do Empreendedor Sobre Segurança de Barragens, Volume II*. [S.l.: s.n.], 2016. ISBN 978-85-8210-038-7. Citado 11 vezes nas páginas 12, 13, 15, 21, 22, 23, 25, 121, 122, 123 e 125.

ARAUJO, T. M. A. de. *Detecção de Danos em Superfícies Geotécnicas com Redes Neurais Convolucionais de Baixa Complexidade*. Tese (Doutorado) — Universidade Federal do Pará, 2024. Citado 4 vezes nas páginas 14, 21, 27 e 52.

ASKAM, E. et al. Satellite and sUAS Multispectral Remote Sensing Analysis of Vegetation Response to Beaver Mimicry Restoration on Blacktail Creek, Southwest Montana. *Remote Sensing*, v. 14, n. 24, p. 6199, dez. 2022. ISSN 2072-4292. Disponível em: <<https://www.mdpi.com/2072-4292/14/24/6199>>. Citado 4 vezes nas páginas 28, 48, 51 e 55.

ASLAHISHAHRI, M. et al. From rgb to nir: Predicting of near infrared reflectance from visible spectrum aerial images of crops. In: *2021 IEEE/CVF International Conference on Computer Vision Workshops (ICCVW)*. Montreal,

- BC, Canada: IEEE, 2021. p. 1312–1322. ISBN 978-1-6654-0191-3. Disponível em: <<https://ieeexplore.ieee.org/document/9607701/>>. Citado na página 52.
- BADRINARAYANAN, V.; KENDALL, A.; CIPOLLA, R. SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 39, n. 12, p. 2481–2495, dez. 2017. ISSN 0162-8828, 2160-9292, 1939-3539. Disponível em: <<https://ieeexplore.ieee.org/document/7803544/>>. Citado na página 50.
- BALANIUK, R.; ISUPOVA, O.; REECE, S. Mining and Tailings Dam Detection in Satellite Imagery Using Deep Learning. *Sensors*, v. 20, n. 23, p. 6936, dez. 2020. ISSN 1424-8220. Disponível em: <<https://www.mdpi.com/1424-8220/20/23/6936>>. Citado 3 vezes nas páginas 48, 52 e 54.
- BEHERA, T. K.; BAKSHI, S.; SA, P. K. A Lightweight Deep Learning Architecture for Vegetation Segmentation using UAV-captured Aerial Images. *Sustainable Computing: Informatics and Systems*, v. 37, p. 100841, jan. 2023. ISSN 22105379. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S221053792200172X>>. Citado 5 vezes nas páginas 48, 49, 50, 51 e 55.
- BRAGAGNOLO, L.; SILVA, R. D.; GRZYBOWSKI, J. Amazon forest cover change mapping based on semantic segmentation by U-Nets. *Ecological Informatics*, v. 62, p. 101279, maio 2021. ISSN 15749541. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S1574954121000704>>. Citado 7 vezes nas páginas 45, 48, 49, 50, 51, 54 e 87.
- CANDIAGO, S. et al. Evaluating Multispectral Images and Vegetation Indices for Precision Farming Applications from UAV Images. *Remote Sensing*, v. 7, n. 4, p. 4026–4047, abr. 2015. ISSN 2072-4292. Disponível em: <<http://www.mdpi.com/2072-4292/7/4/4026>>. Citado 9 vezes nas páginas 12, 29, 30, 32, 34, 48, 51, 54 e 100.
- CAZZUFFI, D.; CRIPPA, E. Contribution of Vegetation to Slope Stability: An Overview of Experimental Studies Carried Out on Different Types of Plants. In: *Erosion of Soils and Scour of Foundations*. Austin, Texas, United States: American Society of Civil Engineers, 2005. p. 1–12. ISBN 978-0-7844-0781-3. Disponível em: <<http://ascelibrary.org/doi/abs/10.1061/40781%28160%299>>. Citado na página 26.
- CHEN, L.-C. et al. *Semantic Image Segmentation with Deep Convolutional Nets and Fully Connected CRFs*. arXiv, 2016. Disponível em: <<http://arxiv.org/abs/1412.7062>>. Citado na página 44.
- CHEN, L.-C. et al. *DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs*. arXiv, 2017. Disponível em: <<http://arxiv.org/abs/1606.00915>>. Citado 2 vezes nas páginas 44 e 85.
- CHEN, L.-C. et al. *Rethinking Atrous Convolution for Semantic Image Segmentation*. arXiv, 2017. Disponível em: <<http://arxiv.org/abs/1706.05587>>. Citado na página 44.
- CHEN, L.-C. et al. *Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation*. arXiv, 2018. Disponível em: <<http://arxiv.org/abs/1802.02611>>. Citado 2 vezes nas páginas 44 e 50.

CHENG, Q. et al. Quantifying corn LAI using machine learning and UAV multispectral imaging. *Precision Agriculture*, v. 25, n. 4, p. 1777–1799, ago. 2024. ISSN 1385-2256, 1573-1618. Disponível em: <<https://link.springer.com/10.1007/s11119-024-10134-z>>. Citado 3 vezes nas páginas 48, 55 e 100.

CHOLLET, F. *Deep Learning with Python*. Second edition. Shelter Island: Manning Publications, 2021. ISBN 978-1-61729-686-4. Citado 4 vezes nas páginas 37, 40, 41 e 50.

Comitê Brasileiro de Barragens. Revista brasileira de barragens: Edição especial Belo Monte. v. 04, 2017. Citado na página 57.

CONCEIÇÃO, M. R. A. et al. SAR Oil Spill Detection System through Random Forest Classifiers. *Remote Sensing*, v. 13, n. 11, p. 2044, maio 2021. ISSN 2072-4292. Disponível em: <<https://www.mdpi.com/2072-4292/13/11/2044>>. Citado 4 vezes nas páginas 48, 49, 54 e 74.

DAS, B. M. *Geotechnical Engineering Handbook*. [S.l.]: J. Ross publishing, 2011. Citado na página 27.

DAVIDSON, C. et al. Ndvi/Ndre Prediction from Standard Rgb Aerial Imagery Using Deep Learning. *Computers and Electronics in Agriculture*, v. 203, p. 107396, dez. 2022. ISSN 01681699. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0168169922007049>>. Citado 8 vezes nas páginas 15, 29, 34, 36, 48, 53, 55 e 94.

DENG, Z. et al. From data processing to behavior monitoring: A comprehensive overview of dam health monitoring technology. *Structures*, v. 71, p. 108094, jan. 2025. ISSN 23520124. Citado na página 15.

DHARI, R. *GSD Calculator – Ground Sample Distance*. 2024. Disponível em: <<https://www.omnicalculator.com/other/ground-sample-distance>>. Citado na página 28.

DJI. *DJI Matrice 200 Series V2 User Manual*. DJI, 2020. Disponível em: <<https://www.dji.com/br/downloads/products/matrice-200-series-v2>>. Citado na página 62.

DUNCAN, J. M.; WRIGHT, S. G.; BRANDON, T. L. *Soil strength and slope stability*. [S.l.]: John Wiley & Sons, 2014. Citado na página 12.

ELGENDY, M. *Deep Learning for Vision Systems*. Shelter Island, NY: Manning Publications Co, 2020. ISBN 978-1-61729-619-2. Citado 5 vezes nas páginas 37, 38, 41, 42 e 50.

FEMA. *Federal Guidelines for Inundation Mapping of Flood Risks Associated with Dam Incidents and Failures*. [S.l.: s.n.], 2013. Citado na página 21.

FERNANDES, M. d. M. *Mecânica Dos Solos*. [S.l.: s.n.], 2006. v. 1. Citado na página 21.

FOGAÇA, P.; RAEDER, F.; MARQUES, J. Impactos dos Acidentes Ambientais de Mariana e Brumadinho no Preço das Ações da Mineradora Vale S.A. *Revista de Administração, Ciências Contábeis e Sustentabilidade*, 2023. ISSN 01013289. Citado na página 14.

- G1. *Tragédia Em Brumadinho: o Caminho Da Lama*. 2019. Disponível em: <<https://g1.globo.com/mg/minas-gerais/noticia/2019/01/27/tragedia-em-brumadinho-o-caminho-da-lama.ghhtml>>. Citado na página 14.
- GAMON, J.; QIU, H.-L. Ecological applications of remote sensing at multiple scales. *Handbook of Functional Plant Ecology*, p. 805–846, jan. 1999. Citado na página 34.
- GITELSON, A. A.; KAUFMAN, Y. J.; MERZLYAK, M. N. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote sensing of Environment*, Elsevier, v. 58, n. 3, p. 289–298, 1996. Citado na página 35.
- Gonzalez-Moodie, B. et al. Multispectral Drone Data Analysis on Coastal Dunes. In: *2021 IEEE International Conference on Big Data (Big Data)*. Orlando, FL, USA: IEEE, 2021. p. 5903–5905. ISBN 978-1-66543-902-2. Disponível em: <<https://ieeexplore.ieee.org/document/9671340/>>. Citado 4 vezes nas páginas 48, 49, 50 e 55.
- GOODFELLOW, I. et al. Generative adversarial networks. *Communications of the ACM*, ACM New York, NY, USA, v. 63, n. 11, p. 139–144, 2020. Citado na página 45.
- GREENWOOD, J. R.; NORRIS, J. E.; WINT, J. Assessing the contribution of vegetation to slope stability. *Proceedings of the Institution of Civil Engineers - Geotechnical Engineering*, v. 157, n. 4, p. 199–207, out. 2004. ISSN 1353-2618, 1751-8563. Disponível em: <<https://www.icevirtuallibrary.com/doi/10.1680/geng.2004.157.4.199>>. Citado 2 vezes nas páginas 15 e 25.
- GU, Y. et al. NDVI saturation adjustment: A new approach for improving cropland performance estimates in the Greater Platte River Basin, USA. *Ecological Indicators*, v. 30, p. 1–6, 2013. Citado na página 36.
- GUO, X. et al. Extraction of snow cover from high-resolution remote sensing imagery using deep learning on a small dataset. *Remote Sensing Letters*, v. 11, n. 1, p. 66–75, jan. 2020. ISSN 2150-704X, 2150-7058. Disponível em: <<https://www.tandfonline.com/doi/full/10.1080/2150704X.2019.1686548>>. Citado 7 vezes nas páginas 37, 39, 43, 48, 49, 50 e 54.
- Gutierrez-Rodriguez, MARIO.; Escalante-Estrada, J. A.; Rodriguez-Gonzalez, M. T. Canopy reflectance, stomatal conductance, and yield of *Phaseolus vulgaris* L. and *Phaseolus coccineus* L. under saline field conditions. v. 7, p. 491–494, 2005. Citado na página 34.
- HASAN, K. R. et al. Deep-Learning-Based Semantic Segmentation for Remote Sensing: A Bibliometric Literature Review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 17, p. 1390–1418, 2024. ISSN 1939-1404, 2151-1535. Disponível em: <<https://ieeexplore.ieee.org/document/10301677/>>. Citado 6 vezes nas páginas 28, 37, 38, 48, 49 e 85.
- HE, H. et al. Adasyn: Adaptive synthetic sampling approach for imbalanced learning. In: IEEE. *2008 IEEE international joint conference on neural networks (IEEE world congress on computational intelligence)*. [S.l.], 2008. p. 1322–1328. Citado na página 75.

- HUBEL, D. H.; WIESEL, T. N. et al. Receptive fields of single neurones in the cat's striate cortex. *The Journal of physiology*, v. 148, n. 3, p. 574–591, 1959. Citado na página 40.
- HUETE, A. R. A soil-adjusted vegetation index (SAVI). *Remote sensing of environment*, Elsevier, v. 25, n. 3, p. 295–309, 1988. Citado na página 35.
- ICOLD. *Number of Dams by Country*. 2024. Disponível em: <[https://www.icold-cigb.org/article/GB/world\\_register/general\\_synthesis/number-of-dams-by-country](https://www.icold-cigb.org/article/GB/world_register/general_synthesis/number-of-dams-by-country)>. Citado 2 vezes nas páginas 12 e 13.
- ILLARIONOVA, S. et al. Generation of the nir spectral band for satellite images with convolutional neural networks. arXiv, n. arXiv:2106.07020, 2021. ArXiv:2106.07020 [cs]. Disponível em: <<http://arxiv.org/abs/2106.07020>>. Citado na página 52.
- ISOLA, P. et al. *Image-to-Image Translation with Conditional Adversarial Networks*. arXiv, 2018. Disponível em: <<http://arxiv.org/abs/1611.07004>>. Citado 6 vezes nas páginas 45, 46, 47, 52, 92 e 93.
- KOTARIDIS, I.; LAZARIDOU, M. Remote sensing image segmentation advances: A meta-analysis. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 173, p. 309–322, mar. 2021. ISSN 09242716. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0924271621000265>>. Citado na página 74.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, v. 25, 2012. Citado na página 43.
- Leo Berman. Random Forests. *Machine Learning*, v. 45, p. 5–32, 2001. Citado 2 vezes nas páginas 38 e 74.
- LILLESAND, T.; KIEFER, R. W.; CHIPMAN, J. *Remote Sensing and Image Interpretation*. [S.l.]: John Wiley & Sons, 2015. Citado na página 29.
- LIMÃO, C. H. E.; ARAÚJO, T. M. A. de; FRANCÊS, C. R. L. Deep learning based slope erosion detection. *IAES International Journal of Artificial Intelligence (IJ-AI)*, v. 12, n. 3, 2023. Citado 5 vezes nas páginas 15, 21, 48, 52 e 55.
- LINHUI, L.; WEIPENG, J.; HUIHUI, W. Extracting the Forest Type From Remote Sensing Images by Random Forest. *IEEE Sensors Journal*, v. 21, n. 16, p. 17447–17454, ago. 2021. ISSN 1530-437X, 1558-1748, 2379-9153. Disponível em: <<https://ieeexplore.ieee.org/document/9296741/>>. Citado 10 vezes nas páginas 15, 38, 39, 48, 49, 55, 74, 76, 80 e 83.
- LIU, Y. et al. Generating a high-precision true digital orthophoto map based on UAV images. *ISPRS International Journal of Geo-Information*, v. 7, n. 9, p. 333, 2018. Citado na página 66.
- LÖBMANN, M. T. et al. The influence of herbaceous vegetation on slope stability – A review. *Earth-Science Reviews*, v. 209, p. 103328, out. 2020. ISSN 00128252. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0012825220303743>>. Citado 4 vezes nas páginas 14, 15, 25 e 26.

- LONG, J.; SHELHAMER, E.; DARRELL, T. *Fully Convolutional Networks for Semantic Segmentation*. arXiv, 2015. Disponível em: <<http://arxiv.org/abs/1411.4038>>. Citado 5 vezes nas páginas 9, 43, 44, 50 e 85.
- LUO, W. et al. Test and Analysis of Vegetation Coverage in Open-Pit Phosphate Mining Area around Dianchi Lake Using UAV–VDVI. *Sensors*, v. 22, n. 17, p. 6388, ago. 2022. ISSN 1424-8220. Disponível em: <<https://www.mdpi.com/1424-8220/22/17/6388>>. Citado 5 vezes nas páginas 48, 49, 52, 55 e 74.
- LUO, Z. et al. Semantic segmentation of agricultural images: A survey. *Information Processing in Agriculture*, v. 11, n. 2, p. 172–186, jun. 2024. ISSN 22143173. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S2214317323000112>>. Citado 4 vezes nas páginas 37, 43, 44 e 45.
- LV, J. et al. Deep learning-based semantic segmentation of remote sensing images: A review. *Frontiers in Ecology and Evolution*, v. 11, p. 1201125, jul. 2023. ISSN 2296-701X. Disponível em: <<https://www.frontiersin.org/articles/10.3389/fevo.2023.1201125/full>>. Citado 6 vezes nas páginas 37, 38, 44, 45, 71 e 85.
- MCCOOL, C. et al. Automating analysis of vegetation with computer vision: Cover estimates and classification. *Ecology and Evolution*, v. 8, n. 12, p. 6005–6015, jun. 2018. ISSN 2045-7758, 2045-7758. Disponível em: <<https://onlinelibrary.wiley.com/doi/10.1002/ece3.4135>>. Citado 3 vezes nas páginas 49, 51 e 54.
- MCCOY, R. M. *Field Methods in Remote Sensing*. New York, NY London: The Guilford Press, 2005. ISBN 978-1-59385-079-1 978-1-59385-080-7. Citado 7 vezes nas páginas 30, 31, 32, 33, 34, 64 e 66.
- MELLO, F. M. de; SANDRONI, S. S.; GUIDICINI, G. *Lições Aprendidas com Acidentes e Incidentes em Barragens e Obras Anexas no Brasil*. Rio de Janeiro: Comitê Brasileiro de Barragens, 2021. ISBN 978-65-990860-1-4. Citado 5 vezes nas páginas 12, 13, 14, 15 e 21.
- MICASENSE. *User Guide for MicaSense Sensors*. 2021. Citado 2 vezes nas páginas 62 e 64.
- Micasense. *Best Practices: Collecting Data with MicaSense Sensors*. 2024. Disponível em: <<https://support.micasense.com/hc/en-us/articles/224893167-Best-practices-Collecting-Data-with-MicaSense-Sensors>>. Citado 4 vezes nas páginas 63, 64, 65 e 66.
- MICASENSE RedEdge and Altum Image Processing Tutorials. Micasense. Disponível em: <<https://github.com/micasense/imageprocessing>>. Citado na página 66.
- MO, Y. et al. Review the state-of-the-art technologies of semantic segmentation based on deep learning. *Neurocomputing*, v. 493, p. 626–646, jul. 2022. ISSN 09252312. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0925231222000054>>. Citado na página 73.
- MOSCOVINI, L. et al. An open-source machine-learning application for predicting pixel-to-pixel ndvi regression from rgb calibrated images. *Computers and Electronics in Agriculture*, v. 216, p. 108536, jan. 2024. ISSN 01681699. Citado na página 53.

- NEBIKER, S. et al. A light-weight multispectral sensor for micro UAV—Opportunities for very high resolution airborne remote sensing. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.*, Citeseer, v. 37, n. B1, p. 1193–1200, 2008. Citado na página 28.
- NESA. *A Peek Inside Belo Monte*. [S.l.]: Norte Energia S.A., 2020. Citado 2 vezes nas páginas 57 e 58.
- New Hampshire Department of Environmental Services. *Basic Terms of Dam Characteristics*. 2020. Disponível em: <[www.des.nh.gov](http://www.des.nh.gov)>. Citado na página 120.
- NOGUEIRA, K. et al. Facing Erosion Identification in Railway Lines Using Pixel-Wise Deep-Based Approaches. *Remote Sensing*, v. 12, n. 4, p. 739, fev. 2020. ISSN 2072-4292. Disponível em: <<https://www.mdpi.com/2072-4292/12/4/739>>. Citado 4 vezes nas páginas 48, 49, 50 e 54.
- OKTAY, O. et al. Attention u-net: Learning where to look for the pancreas. arXiv, n. arXiv:1804.03999, maio 2018. ArXiv:1804.03999 [cs]. Disponível em: <<http://arxiv.org/abs/1804.03999>>. Citado na página 87.
- OpenDroneMap. *ODM - A Command Line Toolkit to Generate Maps, Point Clouds, 3D Models and DEMs from Drone, Balloon or Kite Images*. 2020. Disponível em: <<https://github.com/OpenDroneMap/ODM>>. Citado na página 67.
- OSCO, L. P. et al. Semantic segmentation of citrus-orchard using deep neural networks and multispectral UAV-based imagery. *Precision Agriculture*, v. 22, n. 4, p. 1171–1188, ago. 2021. ISSN 1385-2256, 1573-1618. Disponível em: <<https://link.springer.com/10.1007/s11119-020-09777-5>>. Citado 6 vezes nas páginas 45, 48, 49, 50, 55 e 86.
- OTSU, N. et al. A threshold selection method from gray-level histograms. *Automatica*, v. 11, n. 285-296, p. 23–27, 1975. Citado na página 38.
- PAN, N.-H.; CHEN, K.-y. Applying fuzzy theory to develop a model for inspecting and assessing soil and water conservation facilities. *Journal of Civil Structural Health Monitoring*, Springer, v. 5, p. 441–455, 2015. Citado na página 27.
- Paredes-Gómez, V. et al. A Methodological Approach for Irrigation Detection in the Frame of Common Agricultural Policy Checks by Monitoring. *Agronomy*, v. 10, n. 6, p. 867, jun. 2020. ISSN 2073-4395. Disponível em: <<https://www.mdpi.com/2073-4395/10/6/867>>. Citado 5 vezes nas páginas 48, 49, 51, 54 e 83.
- PARK, J.; CHO, Y. K.; KIM, S. Deep learning-based UAV image segmentation and inpainting for generating vehicle-free orthomosaic. *International Journal of Applied Earth Observation and Geoinformation*, v. 115, p. 103111, 2022. Citado na página 66.
- PEPPER, A. (Ed.). *Managing Dams Challenges in a Time of Change*. London: Thomas Telford Ltd, 2010. ISBN 978-0-7277-4099-1. Disponível em: <<https://www.icevirtuallibrary.com/doi/book/10.1680/mdctc.40991>>. Citado 2 vezes nas páginas 26 e 27.
- PHOON, K.-K.; ZHANG, W. Future of machine learning in geotechnics. *Georisk: Assessment and Management of Risk for Engineered Systems and Geohazards*,

- v. 17, n. 1, p. 7–22, jan. 2023. ISSN 1749-9518, 1749-9526. Disponível em: <<https://www.tandfonline.com/doi/full/10.1080/17499518.2022.2087884>>. Citado 3 vezes nas páginas 14, 15 e 51.
- QUINLAN, J. R. Induction of decision trees. *Machine Learning*, v. 1, n. 1, p. 81–106, mar. 1986. ISSN 0885-6125, 1573-0565. Disponível em: <<http://link.springer.com/10.1007/BF00116251>>. Citado na página 74.
- RIEHLE, D.; REISER, D.; GRIEPENTROG, H. W. Robust index-based semantic plant/background segmentation for RGB- images. *Computers and Electronics in Agriculture*, v. 169, p. 105201, fev. 2020. ISSN 01681699. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0168169919314346>>. Citado 5 vezes nas páginas 15, 38, 39, 49 e 54.
- RONNEBERGER, O.; FISCHER, P.; BROX, T. *U-Net: Convolutional Networks for Biomedical Image Segmentation*. arXiv, 2015. Disponível em: <<http://arxiv.org/abs/1505.04597>>. Citado 7 vezes nas páginas 9, 43, 44, 47, 50, 85 e 87.
- ROUSE, W.; HAAS, R. H. Monitoring Vegetation Systems in the Great Plains with ERTS. *NASA Special Publication*, p. 309–317, 1974. Citado 2 vezes nas páginas 34 e 35.
- SCORNET, E. *Trees, Forests, and Impurity-Based Variable Importance*. 2021. Citado 2 vezes nas páginas 76 e 80.
- SEKACHEV, B. et al. *Opencv/Cvat: V1.1.0*. 2020. Zenodo. Disponível em: <<https://doi.org/10.5281/zenodo.4009388>>. Citado na página 71.
- SELVARAJU, R. R. et al. Grad-cam: Visual explanations from deep networks via gradient-based localization. In: *Proceedings of the IEEE international conference on computer vision*. [S.l.: s.n.], 2017. p. 618–626. Citado na página 89.
- SIMONYAN, K.; ZISSERMAN, A. *Very Deep Convolutional Networks for Large-Scale Image Recognition*. arXiv, 2015. Disponível em: <<http://arxiv.org/abs/1409.1556>>. Citado na página 43.
- SIMS, D. A.; GAMON, J. A. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. *Remote Sensing of Environment*, v. 81, n. 2-3, p. 337–354, ago. 2002. ISSN 00344257. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S003442570200010X>>. Citado 4 vezes nas páginas 30, 32, 35 e 36.
- SOLORZANO, J. et al. A systematic review of the relationship between geotechnics and disasters. *Sustainability*, MDPI, v. 14, n. 19, p. 12835, 2022. Citado na página 14.
- SZEGEDY, C. et al. Going deeper with convolutions. In: *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Boston, MA, USA: IEEE, 2015. p. 1–9. ISBN 978-1-4673-6964-0. Disponível em: <<http://ieeexplore.ieee.org/document/7298594/>>. Citado na página 43.
- TEIXEIRA, D. B. D. S. et al. Spectro-temporal analysis of the Paraopeba River water after the tailings dam burst of the Córrego do Feijão mine, in Brumadinho, Brazil. *Environmental Monitoring and Assessment*, v. 193, n. 7, p. 435, jul. 2021. ISSN 0167-6369,

- 1573-2959. Disponível em: <<https://link.springer.com/10.1007/s10661-021-09218-4>>. Citado na página 28.
- TERZAGHI, K.; PECK, R. B.; MESRI, G. *Soil Mechanics in Engineering Practice*. [S.l.]: John Wiley & Sons, 1996. Citado na página 20.
- TODD, S. W.; HOFFER, R. M. Responses of spectral indices to variations in vegetation cover and soil background. *Photogrammetric engineering and remote sensing*, ASPRS AMERICAN SOCIETY FOR PHOTOGRAMMETRY and, v. 64, p. 915–922, 1998. Citado na página 36.
- TOFFANIN, P. *OpenDroneMap: The Missing Guide*. 2. ed. [S.l.]: UAV4GEO, 2023. Citado 2 vezes nas páginas 67 e 68.
- TSOUROS, D. C.; BIBI, S.; SARIGIANNIDIS, P. G. A Review on UAV-Based Applications for Precision Agriculture. *Information*, v. 10, n. 11, p. 349, nov. 2019. ISSN 2078-2489. Disponível em: <<https://www.mdpi.com/2078-2489/10/11/349>>. Citado na página 77.
- VIEZORKOSKY, VC. et al. Análise da reação dos preços das ações da mineradora vale após o acidente ambiental em brumadinho/MG e do seu impacto no mercado de mineração americano. In: *Congresso UFSC de Iniciação Científica Em Contabilidade*. [S.l.: s.n.], 2020. v. 10. Citado na página 14.
- WU, Q. et al. Land-cover classification using GF-2 images and airborne lidar data based on Random Forest. *International Journal of Remote Sensing*, v. 40, n. 5-6, p. 2410–2426, mar. 2019. ISSN 0143-1161, 1366-5901. Disponível em: <<https://www.tandfonline.com/doi/full/10.1080/01431161.2018.1483090>>. Citado 8 vezes nas páginas 30, 39, 48, 49, 54, 74, 76 e 78.
- YANG, W. et al. Greenness identification based on HSV decision tree. *Information Processing in Agriculture*, v. 2, n. 3-4, p. 149–160, out. 2015. ISSN 22143173. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S2214317315000347>>. Citado 2 vezes nas páginas 38 e 49.
- YIN, H. et al. Multi-temporal UAV Imaging-Based Mapping of Chlorophyll Content in Potato Crop. *PFG – Journal of Photogrammetry, Remote Sensing and Geoinformation Science*, v. 91, n. 2, p. 91–106, abr. 2023. ISSN 2512-2789, 2512-2819. Disponível em: <<https://link.springer.com/10.1007/s41064-022-00218-8>>. Citado 2 vezes nas páginas 48 e 55.
- YUAN, X.; TIAN, J.; REINARTZ, P. Generating artificial near infrared spectral band from rgb image using conditional generative adversarial network. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, V-3-2020, p. 279–285, ago. 2020. ISSN 2194-9050. Citado na página 52.
- ZENG, Y. et al. Optical vegetation indices for monitoring terrestrial ecosystems globally. *Nature Reviews Earth & Environment*, v. 3, n. 7, p. 477–493, maio 2022. ISSN 2662-138X. Disponível em: <<https://www.nature.com/articles/s43017-022-00298-5>>. Citado 2 vezes nas páginas 34 e 36.

ZHANG, W. et al. Application of deep learning algorithms in geotechnical engineering: A short critical review. *Artificial Intelligence Review*, v. 54, n. 8, p. 5633–5673, dez. 2021. ISSN 0269-2821, 1573-7462. Disponível em: <<https://link.springer.com/10.1007/s10462-021-09967-1>>. Citado 7 vezes nas páginas 15, 37, 40, 44, 45, 46 e 51.

ZHANG, Z. Improved adam optimizer for deep neural networks. In: *2018 IEEE/ACM 26th International Symposium on Quality of Service (IWQoS)*. [S.l.]: Ieee, 2018. p. 1–2. Citado na página 88.

# **Apêndices**

---

## **Dicionário de Termos Relacionados a Engenharia e Segurança de Barragens**

Esta seção apresenta a definição de uma série de termos relacionados a engenharia e segurança de barragens de acordo com a definição fornecida pela ANA, 2022 (ANA, 2022) e pelo *New Hampshire Department of Environmental Services*, 2020 (New Hampshire Department of Environmental Services, 2020), com o intuito de facilitar a compreensão do leitor sobre o tema abordado neste trabalho. Os termos foram listados em ordem alfabética e estão organizados em cinco grupos distintos, podendo ser referentes a infraestruturas de contenção, elementos constitutivos, eventos e anomalias, princípios e diretrizes, ou a governança e regulação. A definição dos termos é apresentada nas Tabelas 17, 18, 19, 20 e 21 a seguir.

## Termos Referentes a Infraestruturas de Contenção

Tabela 17 – Dicionário de termos relacionados a infraestruturas de contenção no âmbito de engenharia e segurança de barragens

Fonte: Adaptado de ANA, 2016 (ANA, 2016).

Termo	Definição
<b>Barragem</b>	Estrutura construída dentro ou fora de um curso de água para fins de contenção ou acumulação de substâncias líquidas ou de misturas de líquidos e sólidos, compreendendo o barramento e as estruturas associadas
<b>Barragem de Aterro</b>	Barragens construídas a partir de terra ou uma combinação de terra e enrocamento
<b>Dique</b>	Obra de engenharia hidráulica que realizam o represamento de águas com a finalidade de manter determinadas porções de terra secas. Em grande parte dos casos, os diques são construídos como estruturas auxiliares para barragens de maior magnitude
<b>Talude</b>	Superfícies inclinadas, naturais ou artificiais, compostas por maciços terrosos, rochosos ou mistos

## Termos Referentes a Elementos Constitutivos

Tabela 18 – Dicionário de termos relacionados aos elementos constitutivos das estruturas no âmbito de engenharia e segurança de barragens

Fonte: Adaptado de ANA, 2016 (ANA, 2016).

Termo	Definição
<b>Bordas</b>	Interseções da crista com os taludes de montante e jusante
<b>Cobertura Vegetal</b>	Cobertura vegetal e camadas de brita ou pedregulho ou mesmo de enrocamento são comumente usadas para proteger o talude de jusante contra erosão
<b>Crista</b>	Superfície plana no topo da barragem. Normalmente, a crista é usada como uma estrada para tráfego de veículos ou para facilitar a operação, inspeção e manutenção da barragem
<b>Dreno de Pé</b>	Zona de material permeável usada pra drenagem interna em barragens de terra. Coleta e carreia a água de infiltração para fora da barragem
<b>Enrocamento</b>	Do inglês <i>RipRap</i> , é uma camada de rochas brutas, trituradas ou em formato de bloco posicionadas aleatoriamente na barragem para proteção

Tabela 18 (continuação)

<b>Termo</b>	<b>Definição</b>
<b>Maciço</b>	O próprio corpo da barragem erguido sobre o curso d'água feito principalmente de terra ou concreto
<b>Ombreira</b>	Laterais do vale onde a barragem se apoia
<b>Piezômetro</b>	Dispositivo usado para medir a pressão da água no interior da barragem
<b>Reservatório</b>	Acumulação não natural de água, de substâncias líquidas ou de mistura de líquidos e sólidos
<b>Talude de Jusante</b>	Superfície inclinada do maciço oposta ao reservatório. O talude de jusante também necessita alguma forma de proteção contra a erosão das águas de superfície
<b>Talude de Montante</b>	Superfície inclinada do maciço em contato com o reservatório. Assim, esta superfície deve ser protegida contra o poder erosivo das ondas

## Termos Referentes a Eventos e Anomalias

Tabela 19 – Dicionário de termos relacionados a eventos e anomalias que ocorrem no âmbito de engenharia e segurança de barragens

Fonte: Adaptado de ANA, 2016 (ANA, 2016).

<b>Termo</b>	<b>Definição</b>
<b>Acidente</b>	Comprometimento da integridade estrutural com liberação incontrolável do conteúdo do reservatório, ocasionado pelo colapso parcial ou total da barragem ou de estrutura anexa
<b>Anomalia</b>	Deficiência, irregularidade, anormalidade ou deformação que possa afetar a segurança da barragem
<b>Desastre</b>	Resultado de evento adverso, de origem natural ou induzido pela ação humana, sobre ecossistemas e populações vulneráveis, que causa significativos danos humanos, materiais ou ambientais e prejuízos econômicos e sociais
<b>Incidente</b>	Ocorrência que afeta o comportamento da barragem ou de estrutura anexa que, se não controlada, pode causar um acidente
<b>Percolação</b>	Passagem de água pela barragem através de fissuras ou material poroso. Deve ser controlada para não erodir o material do maciço

Tabela 19 (continuação)

<b>Termo</b>	<b>Definição</b>
<b><i>Piping</i></b>	Também chamado de erosão interna ou erosão tubular, é o processo de erosão do material do maciço da barragem devido à percolação descontrolada. Começa em forma de tubo e se expande até destruir a barragem. É uma das principais causas de rompimentos em todo o mundo
<b>Surgência</b>	Aparecimento de água que passa por percolação pelas estruturas das barragens e surge em local não previsto. Exige medidas de controle, pois essa água pode alterar as propriedades do material utilizado, como a coesão entre as partículas, gerando instabilidade na barragem

## Termos Referentes a Princípios e Diretrizes

Tabela 20 – Dicionário de termos relacionados a princípios e diretrizes no âmbito de engenharia e segurança de barragens

Fonte: Adaptado de ANA, 2016 (ANA, 2016).

<b>Termo</b>	<b>Definição</b>
<b>Dano Potencial Associado (DPA)</b>	Dado que pode ocorrer devido a rompimento, vazamento, infiltração no solo ou mau funcionamento de uma barragem, independentemente da sua probabilidade de ocorrência, a ser graduado de acordo com as perdas de vidas humanas e os impactos sociais, econômicos e ambientais
<b>Inspeção de Segurança Especial (ISE)</b>	Atividade sob a responsabilidade do empreendedor que visa avaliar as condições de segurança da barragem em situações específicas, devendo ser realizada por equipe multidisciplinar de especialistas nas fases de construção, operação e desativação
<b>Inspeção de Segurança Regular (ISR)</b>	Atividade sob responsabilidade do empreendedor que visa identificar e a avaliar anomalias que afetem potencialmente as condições de segurança e de operação da barragem, bem como seu estado de conservação, devendo ser realizada, regularmente, com a periodicidade estabelecida pelo órgão fiscalizador
<b>Gestão de Risco</b>	Ações de caráter normativo, bem como aplicação de medidas para prevenção, controle e mitigação de riscos
<b>Segurança de barragem</b>	Condição que vise a manter a sua integridade estrutural e operacional e a preservação da vida, da saúde, da propriedade e do meio ambiente

Tabela 20 (continuação)

<b>Termo</b>	<b>Definição</b>
<b>Sistema de Alerta</b>	Conjunto de equipamentos ou recursos tecnológicos para informar a população potencialmente afetada na ZAS sobre a ocorrência de perigo iminente

## Termos Referentes a Governança e Regulação

Tabela 21 – Dicionário de termos relacionados a governança e regulação no âmbito de engenharia e segurança de barragens

Fonte: Adaptado de ANA, 2016 (ANA, 2016).

<b>Termo</b>	<b>Definição</b>
<b>Agência Nacional de Águas e Saneamento Básico (ANA)</b>	Exerce a função de órgão fiscalizador de segurança de barragens de usos múltiplos em rios federais que não gerem energia elétrica como uso preponderante e também algumas atribuições especiais: articulação entre os fiscalizadores de segurança de barragens, elaboração do Relatório de Segurança de Barragens e implementação e gestão do Sistema Nacional de Informações sobre Segurança de Barragens
<b>Comissão Internacional de Grandes Barragens (ICOLD)</b>	Entidade não governamental internacional responsável pela promoção de intercâmbio de conhecimento e experiência no campo de engenharia de barragens
<b>Política Nacional de Segurança de Barragens (PNSB)</b>	Tem como propósito assegurar a adesão aos padrões de segurança estabelecidos para as barragens, objetivando a minimização da probabilidade de ocorrência de acidentes e seus impactos, ao mesmo tempo em que regulamenta as práticas e os critérios de segurança relacionados a essas estruturas
<b>Sistema Nacional de Informações sobre Segurança de Barragens (SNISB)</b>	Sistema que disponibiliza informações atualizadas sobre as barragens brasileiras, consolidando dados encaminhados à agências fiscalizadoras do país

---

## Parâmetros de Configuração do OpenDroneMap

Uma série exaustiva de experimentos foi realizada para avaliar a qualidade dos DOMs gerados a partir das imagens capturadas pelo sensor multiespectral RedEdge-P durante as missões automáticas de coleta de dados *in loco*. Os parâmetros de configuração listados na Tabela 22 foram ajustados para otimizar a performance do processamento e a qualidade dos mapas deste projeto.

Tabela 22 – Parâmetros de configuração do software *OpenDroneMap* para a geração de mapas de qualidade no contexto do estudo de caso apresentado.

Fonte: Autor.

Parâmetro	Valor
boundary	boundary.json
cameras	cameras.json
fast-ortophoto	True
feature-quality	ultra
feature-type	akaze
optimize-disk-space	True
ortophoto-cutline	True
ortophoto-resolution	2.4
rerun-from	opensfm
skip-3dmodel	True
texturing-skip-global-seam-leveling	True