

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
INSTITUTO DE GEOGRAFIA, GEOCIÊNCIAS E SAÚDE COLETIVA

ERIKA EDUARDA SOARES RODRIGUES

Análise Temporal da Dinâmica Hídrica na UHE Santo Antônio por meio de Imagens
Multiespectrais

Monte Carmelo

2026

ERIKA EDUARDA SOARES RODRIGUES

Análise Temporal da Dinâmica Hídrica na UHE Santo Antônio por meio de Imagens
Multiespectrais

Trabalho de Conclusão de Curso apresentado à
Instituto de Geografia, Geociência e Saúde
Coletiva da Universidade Federal de
Uberlândia como requisito parcial para
obtenção do título de bacharel em Engenharia
Agrimensura e Cartográfica

Área de concentração: Sensoriamento Remoto

Orientador: Prof. Dr. George Deroco Martins

Monte Carmelo

2026

ERIKA EDUARDA SOARE RODRIGUES

Análise Temporal da Dinâmica Hídrica na UHE Santo Antônio por meio de Imagens
Multiespectrais

Trabalho de Conclusão de Curso apresentado à
Instituto de Geografia, Geociências e Saúde
Coletiva da Universidade Federal de
Uberlândia como requisito parcial para
obtenção do título de bacharel em Engenharia
Agrimensura e Cartográfica.

Área de concentração: Sensoriamento Remoto

Monte Carmelo, 24 de março 2026

Banca Examinadora:

Prof. Dr. George Deroco Martins (Orientador)

Universidade Federal de Uberlândia – Campus Monte Carmelo

Prof.^a Dr.^a. Luziane Ribeiro Indjai

Universidade Federal de Uberlândia – Campus Monte Carmelo

Eng. Lucas Henrique Vicentini Viana de Carvalho

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

R696 2026	Rodrigues, Érika Eduarda Soares, 2000- Análise Temporal da Dinâmica Hídrica na UHE Santo Antônio por meio de Imagens Multiespectrais [recurso eletrônico] / Érika Eduarda Soares Rodrigues. - 2026. Orientador: George Deroco Martins. Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Uberlândia, Graduação em Engenharia de Agrimensura e Cartográfica. Modo de acesso: Internet. Inclui bibliografia. Inclui ilustrações. 1. Agrimensura. I. Martins, George Deroco, 1987-, (Orient.). II. Universidade Federal de Uberlândia. Graduação em Engenharia de Agrimensura e Cartográfica. III. Título. CDU: 528
--------------	---

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:

Gizele Cristine Nunes do Couto - CRB6/2091

Nelson Marcos Ferreira - CRB6/3074

*“Aos meus pais, Eder e Andreia, que sempre
estiveram ao meu lado em cada passo.”*

AGRADECIMENTOS

Primeiramente, agradeço a Deus pelo dom da vida e pela oportunidade de vivenciar esta experiência tão significativa em minha trajetória. Sou grata por me permitir chegar até aqui e por me conceder força, sabedoria e perseverança para superar cada desafio encontrado ao longo deste caminho.

Aos meus pais, Eder e Andreia, expresso minha mais profunda gratidão pela criação, pelos valores e pela educação que sempre me proporcionaram. Agradeço pelo amor, pelo incentivo constante e por sempre acreditarem na importância de continuar os estudos, sendo a base fundamental para que eu pudesse alcançar este objetivo.

Ao meu amor, Moisés, agradeço por todos os momentos de apoio, compreensão e consolo ao longo desta jornada. Sua presença, paciência e incentivo foram essenciais nos momentos mais difíceis. Aos meus sogros, Ana Cristina e Eliesse, agradeço o carinho, incentivo e apoio demonstrados em cada etapa deste processo.

Ao meu orientador, George Deroco Martins, deixo meu sincero agradecimento pelo incentivo, pela dedicação e pelos valiosos conhecimentos compartilhados durante a realização deste trabalho. Sua orientação foi fundamental para o desenvolvimento desta pesquisa.

Aos professores que fizeram parte desta caminhada, agradeço pela paciência, pela bondade e por todos os ensinamentos transmitidos. Minha experiência com cada um de vocês foi esplêndida, e levarei comigo, para sempre, os conhecimentos adquiridos e as memórias dessa importante etapa da minha vida acadêmica.

RESUMO

A região hidrográfica amazônica, caracterizada por ser a rede hidrográfica terrestre mais extensa do mundo, abrange quase 50% do território brasileiro, com grande potencial para geração de energia hidrelétrica pelo seu grande volume de água e alterações no relevo da região. A principal base do sistema de geração de energia elétrica do país é constituída por usinas hidrelétricas (UHE), que correspondem cerca de 60% da produção de energia brasileira. A presença de UHE no território brasileiro, entretanto, resulta em mudanças nos recursos hídricos da área, acompanhadas de impactos ambientais relevantes. Diante da sensibilidade ambiental desta área, o presente estudo analisa a dinâmica hídrica da Usina Hidrelétrica (UHE) Santo Antônio e de afluentes estratégicos, como o Rio Madeira e Rio Madre de Dios, entre 2015 e 2025. O objetivo central foi identificar e mapear as variações no corpo hídrico, com foco na detecção de áreas de seca e alagamento através de séries temporais. Para tanto, utilizou-se o processamento de imagens dos satélites Landsat 8 e 9 (sensores OLI/TIRS) e a aplicação do Índice de Vegetação por Diferença Normalizada (NDVI). A classificação supervisionada foi realizada pelo método de Distância Mínima (MinDist), permitindo a quantificação das alterações espaciais. Os resultados revelaram que a classe "Seca" apresentou a maior variabilidade, sendo significativamente impactada pelas estiagens históricas registradas recentemente na bacia do Rio Madeira. Em contraste, a classe "Alagada" demonstrou estabilidade no decorrer do período. Conclui-se que o uso de geotecnologias de baixo custo é indispensável para o monitoramento de precisão em regiões remotas, fornecendo subsídios para a gestão de recursos hídricos frente aos desafios impostos pelas mudanças climáticas na Amazônia.

Palavras-chave: Sensoriamento Remoto, Landsat 8/9, Rio Madeira, NDVI, Usina Hidrelétrica.

ABSTRACT

The Amazon hydrographic region, characterized as the most extensive terrestrial hydrographic network in the world, covers almost 50% of Brazilian territory, with great potential for hydroelectric power generation due to its large volume of water and variations in the region's topography. The main basis of the country's electricity generation system consists of hydroelectric power plants (HPPs), which account for approximately 60% of Brazilian energy production. However, the presence of HPPs in Brazilian territory results in changes to the area's water resources, accompanied by significant environmental impacts. Given the environmental sensitivity of this area, this study analyzes the water dynamics of the Santo Antônio Hydroelectric Power Plant (HPP) and strategic tributaries, such as the Madeira River and the Madre de Dios River, between 2015 and 2025. The central objective was to identify and map variations in the water body, focusing on the detection of drought and flooding areas through time series data. To this end, image processing from Landsat 8 and 9 satellites (OLI/TIRS sensors) and the Normalized Difference Vegetation Index (NDVI) were used. Supervised classification was performed using the Minimum Distance (MinDist) method, allowing the quantification of spatial changes. The results revealed that the "Dry" class showed the greatest variability, being significantly impacted by the historical droughts recently recorded in the Madeira River basin. In contrast, the "Flooded" class demonstrated stability throughout the period. It is concluded that the use of low-cost geotechnologies is indispensable for precision monitoring in remote regions, providing support for water resource management in the face of the challenges posed by climate change in the Amazon.

Keywords: Remote Sensing, Landsat 8/9, Madeira River, NDVI, Hydroelectric Power Plant.

LISTA DE ILUSTRAÇÕES

Figura 1 - Comparação da resolução espacial do Landsat 5 e Landsat 8.	17
Figura 2 - Exemplos de resolução radiométrica.	18
Figura 3 - Características do Landsat 8	22
Figura 4 - Exemplo de matriz de confusão.	25
Figura 5 - Imagem da UHE Santo Antônio.	27
Figura 6 - Mapa de localização.....	28
Figura 7 - Fluxograma do projeto.....	29
Figura 8 - Análise Espacial da classe Seca e Alagada na UHE Santo Antônio (2015-2020). .	35
Figura 9 - Análise Espacial da classe Seca e Alagada na UHE Santo Antônio (2020-2025). .	37
Figura 10 - Gráfico de comparação das Classes Alagada e Seca.	40
Figura 11 – Mapa Comparativo da Classe Seca na UHE Santo Antônio (2015-2025).....	41
Figura 12 - Mapa com correlação da classe Seca (2015-2020) no Rio Madeira.....	42
Figura 13 - Trecho Madre De Dios com a classe Seca (2015-2025).....	43
Figura 14 - Trecho Madre De Dios com a classe Seca e Alagada (2015-2025).....	43

LISTA DE TABELAS

Tabela 1 - Índice Kappa e respectivo desempenho.	26
Tabela 2 - Características das imagens obtidas.	30
Tabela 3 - Bandas espectrais utilizadas..	30
Tabela 4 - Intervalos de Referência para a Diferença de NDVI.....	32
Tabela 5 - Matriz de Confusão (%) com Erros de Omissão (EO) e Comissão (EC) para o período 2015-2020.....	34
Tabela 6 - Matriz de Confusão (%) com Erros de Omissão (EO) e Comissão (EC) para o período 2020-2025.....	36
Tabela 7 - Comparativo da Acurácia Global e Índice Kappa entre os períodos analisados.	38
Tabela 8 - Evolução das áreas de mudança hídrica (2015-2025).	38
Tabela 9 - Evolução das áreas de mudança hídrica (2015-2025).	39

LISTA DE ABREVIATURAS E SIGLAS

AVHRR	Advanced Very High Resolution Radiometer
CPRM	Companhia de Pesquisa de Recursos Minerais
ENVI	Environment for Visualizing Images
EVI	Índice de Vegetação Melhorado
IBGE	Instituto Brasileiro Geografia e Estatística
MahaDist	Distância Mahalanobis
MaxVer	Máxima Verossimilhança
MinDist	Mínima Distância
MODIS	Moderate Resolution Imaging Spectroradiometer
MSS	Multispectral Scanner System
NDVI	Normalized Difference Snow Index
NDWI	Normalized Difference Water Index
NIR	Near Infrared
NOAA	National Oceanic and Atmospheric Administration
OLI	Operational Land Imager
PVI	Índice de Vegetação Perpendicular
QGIS	Quantum Geographic Information System
RBV	Return Beam Vidicom
RED	Radiação Eletromagnética
ROI	Region of Interest
RN	Redes Neurais
SAVI	Índice de Vegetação Ajustado do solo
SEB	Sistema Elétrico Brasileiro
SR	Sensoriamento Remoto
TIRS	Thermal Infrared Sensor
UFU	Universidade Federal de Uberlândia
UHE	Usina Hidrelétrica de Energia
USGS	United States Geological Survey
UTE	Usina Termoeletricas de Energia

WGS 84

World Geodetic System 1984

SUMÁRIO

1	INTRODUÇÃO.....	13
2	OBJETIVOS	15
2.1	Objetivo Geral.....	15
2.2	Justificativa	15
3	REVISÃO BIBLIOGRÁFICA	16
3.1	<i>Sensoriamento Remoto</i>	16
3.2	<i>Índice de Vegetação por Diferença Normalizada</i>	18
3.3	<i>Índice de Água por Diferença Normalizada</i>	19
3.4	<i>Series temporais</i>	20
3.5	<i>Satélites</i>	21
3.5.1	<i>Landsat 8/9</i>	21
3.6	<i>Técnicas de classificação</i>	23
3.6.1	<i>Classificação Supervisionada</i>	23
4	MATERIAS E METODOS.....	27
4.1	<i>Área de Estudo</i>	27
4.2	<i>Material</i>	28
4.3	<i>Métodos</i>	29
4.3.1	<i>Pré-processamento</i>	30
4.3.3	<i>Processamento</i>	31
4.3.4	<i>Pós Processamento</i>	33
4.3.5	<i>Geração de Produtos</i>	33
5	RESULTADOS	34
5.1	<i>Período 2015-2020</i>	34
5.2	<i>Período 2020-2025</i>	36
5.3	<i>Análise Comparativa</i>	37
5.4	<i>Dinâmica das Áreas Alagada e Seca</i>	38
6	CONCLUSÃO.....	44
	REFERÊNCIAS.....	45

1 INTRODUÇÃO

O Brasil, que ocupa mais da metade da América Latina, é um dos países com maior biodiversidade de fauna e flora do planeta, distribuída em seis biomas. Entre eles, destaca-se o bioma Amazonas, o mais expansivo do território nacional, abrangendo cerca de 49% da área do país. Este bioma apresenta uma das maiores riquezas biológicas do mundo, desempenhando papel essencial na regulação climática, na manutenção dos ciclos hidrológicos contendo cerca de 20% da disponibilidade mundial da água e, na preservação de espécies endêmicas (IBGE, 2024). O bioma Amazônica é concentrado por ser um grande potencial na geração de energia hidrelétrica brasileira, pois possui um alto volume de água que atravessa toda região e às quedas topográficas significativas nos afluentes do rio Amazonas (Fearnside, 2015).

A matriz de geração do Sistema Elétrico Brasileiro (SEB) é gerada essencialmente por Usinas Hidroelétricas de Energia (UHE) e Usinas Termoeletricas de Energia (UTE), que juntas representa mais de 90% total de empreendimentos em operação (Montalvão; Faria; Abbud, 2012). Diante disso, considerando que grande parte dessas usinas está inserida em áreas ambientalmente sensíveis, como a Amazônia, torna-se fundamental compreender os impactos das UHE sobre a dinâmica hídrica e a detecção de mudanças na superfície.

Ao longo das décadas a utilização de dados multitemporais em sensoriamento remoto tornou-se uma ferramenta indispensável e eficaz para monitoramento ambiental, mapeamento no uso e cobertura do solo, planejamento urbano e territorial. Os conjuntos de séries temporais têm possibilitado o monitoramento espaço-temporal das alterações na configuração da paisagem hídrica em escalas antes inviáveis (Freitas et Al., 2011 *apud* Antunes, 2012).

As séries temporais permitem mapear diferentes classes padrões de variação hídrica, contribuindo para a identificação e análise dos impactos associados às mudanças no uso do solo. Consequentemente, a modernização do geoprocessamento, incluindo o sensoriamento remoto e o uso de dados quantitativos georreferenciados, possibilita a identificação de padrões espaciais das diferentes coberturas do solo, tornando-se uma ferramenta essencial para o planejamento ambiental da região (Antunes, 2012). Por meio de espectros temporais de índices de vegetação e de água, pode-se verificar e identificar as mudanças na cobertura vegetal e nos corpos d'água, especialmente aquelas evidenciadas em determinadas estações do ano.

Como ferramenta de monitoramento da vegetação, o Índice de Vegetação por Diferença Normalizada (NDVI) destaca-se por sua ampla eficiência em aplicações ambientais, agrícolas e ecológicas. Esse índice permite a construção de perfis sazonais e temporais da vegetação, facilitando comparações entre diferentes períodos (Guedes e Silva, 2018). Além disso, outro

índice essencial para o monitoramento de áreas influenciadas por UHE é o Índice de Água por Diferença Normalizada (NDWI), que realça feições hídricas e reduz a interferência de outros alvos na imagem (Brenner e Guasselli, 2015).

Tendo em vista a necessidade de transformar essas informações espectrais em classes temáticas que representem de forma objetiva os diferentes padrões da paisagem, emprega-se a classificação supervisionada. A classificação supervisionada é onde utiliza-se conjuntos de amostras de treinamento para cada classe que deseja diferenciar na imagem. Essas amostras são áreas de referência delimitadas na imagem, representando, de modo preciso ou aproximado, os padrões característicos de cada classe temática (Quartarolli e Bastistella, 2006).

No contexto desta pesquisa, busca-se identificar e analisar as mudanças no recurso hídrico ocorridas no percurso do Rio Madeira até a chegada da UHE Santo Antônio por meio do índice NDVI, no qual permite realçar variações na vegetação e nos corpos d'água ao longo do período estudado. Para demonstrar essas transformações, foi aplicado técnicas de classificação supervisionada, utilizando o método Máxima Distância (MinDist), o qual possibilita a distinção precisa das classes temáticas e a comparação das alterações registradas entre os anos avaliados.

2 OBJETIVOS

2.1 *Objetivo Geral*

O objetivo deste trabalho é analisar as alterações temporais do corpo hídrico associado à UHE Santo Antônio, com ênfase na identificação de retrações e expansões do nível d'água. A metodologia consistiu na aplicação do algoritmo de Distância Mínima (MinDist) em imagens dos satélites Landsat 8 e 9 para o período entre 2015 a 2025. O estudo priorizou a distinção entre áreas de estabilidade hídrica e zonas impactadas por secas severas, permitindo uma compreensão detalhada das mudanças ocorridas na bacia do Rio Madeira e no Rio Madre de Dios.

2.2 *Justificativa*

A relevância deste estudo fundamenta-se na necessidade de monitorar as transformações espaciais em uma das regiões hidrologicamente mais complexas da Amazônia. Sendo a UHE Santo Antônio um empreendimento estratégico para a matriz energética brasileira, compreender a resposta do seu reservatório e de afluentes como o Rio Madre de Dios ao longo de uma década torna-se fundamental para a gestão dos recursos hídricos e para o planejamento ambiental regional.

A pesquisa justifica-se, predominantemente, pela ocorrência de eventos climáticos extremos e secas históricas que atingiram a bacia do Rio Madeira em anos recentes. Nesse contexto, a aplicação do índice NDVI permite distinguir variações operacionais da usina de retrações hídricas severas causadas por fatores climáticos, evidenciando as áreas onde a redução do espelho d'água foi mais acentuada.

Do ponto de vista técnico, o trabalho demonstra a eficiência de ferramentas de sensoriamento remoto gratuito, como as imagens dos satélites Landsat 8 e 9, integradas a algoritmos de classificação supervisionada. O emprego de metodologias de baixo custo para o monitoramento de precisão oferece um modelo replicável para a fiscalização de grandes reservatórios em áreas remotas, fornecendo subsídios técnicos para o poder público e órgãos ambientais no acompanhamento de mudanças ambientais críticas.

3 REVISÃO BIBLIOGRÁFICA

3.1 *Sensoriamento Remoto*

Segundo Meneses e Almeida (2012), o Sensoriamento Remoto (SR), em sua definição clássica, é uma técnica utilizada para obter imagens de objetos presentes na superfície terrestre a longa distância.


Ainda conforme os autores, o SR também pode ser compreendido como a ciência voltada à obtenção de imagens da superfície da Terra por meio da detecção e da medição quantitativa das respostas resultantes das interações entre a radiação eletromagnética (REM) e os diferentes materiais. Sendo assim, a radiação eletromagnética (REM) propaga-se pelo espaço vazio, como ocorre com a luz solar, na forma de ondas e energia, transportando as informações dos objetos na superfície terrestre até o sensor, possibilitando o processo de aquisição e posterior análise das imagens (Menezes; Almeida, 2012).

A capacidade de detectar e identificar objetos em imagens de sensoriamento remoto não é definida unicamente pela resolução espacial, mas sim pela sinergia entre quatro dimensões de resolução: espacial, espectral, radiométrica e temporal, que coletivamente determinam a eficácia do sensor em discriminar os alvos na superfície (Menezes; Almeida, 2012).

Conforme Zanotta, Zortea e Ferreira (2019), a resolução espacial de uma imagem descreve sua habilidade de distinguir as características geométricas dos alvos, como seu tamanho e forma. Essa característica é um parâmetro fundamental para o sensoriamento remoto, pois, como destacam Menezes e Almeida (2012), é ela que determina o tamanho do menor objeto detectável na cena.

Como demonstrado por Coelho e Correa (2013) na Figura 1, a comparação entre a resolução espacial do Landsat 5 (120 metros) e a do Landsat 8 (30 metros) evidencia a vantagem deste último para aplicações de geotecnologia em ambientes urbanos, devido à sua maior nitidez e detalhamento.

Figura 1- Comparação da resolução espacial do Landsat 5 e Landsat 8.



Fonte: Coelho e Correa (2013).


A resolução espectral refere-se à capacidade de um sensor discriminar diferentes comprimentos de onda do espectro eletromagnético. Segundo Gomes e Cubas (20xx), trata-se da menor largura de banda espectral que o sensor consegue registrar, sendo essa alta resolução espectral a característica que define os sensores multiespectrais e, principalmente, os hiperespectrais.

Correlacionada a esta, Novo (2008) define a resolução espectral como a sensibilidade do sensor em distinguir diferentes níveis de intensidade de energia refletida ou emitida por um alvo. Em complemento a isso, Zanotta, Zortea e Ferreira (2019) alinham-se a este raciocínio, pois para os autores esta resolução espacial está ligada diretamente à capacidade do sensor de caracterizar ou registrar a assinatura espectral dos alvos: quanto mais bandas existirem, mais detalhes terá a resposta espectral de cada pixel.

A resolução radiométrica de uma imagem, também conhecida como quantização, refere-se à capacidade do sensor de distinguir diferentes níveis de intensidade de energia, geralmente representados como tons de cinza. Dessa forma, quanto maior a capacidade do sistema sensor em detectar diferenças sutis na radiação incidente, maior será a sua resolução radiométrica (Menezes; Almeida, 2012). Conforme Novo (2008), essa resolução corresponde à sensibilidade para discriminar variações na “energia refletida, emitida e retroespalhada que deixa a superfície do alvo”, gerando diferentes intensidades de sinal que devem ser captadas pelo sistema. Com base nessa intensidade de radiação, a resposta elétrica dos detectores é convertida eletronicamente em números digitais discretos (Menezes; Almeida, 2012). Por exemplo, conforme demonstra a Figura 2, de uma imagem orbital para a mesma localidade, onde um

sensor de 1 bit de resolução radiométrica distingue apenas 2 níveis de cinza, um sensor de 2 bits consegue distinguir 4 níveis de cinza, até chegar no sensor de 11 bits que analisa 2048 níveis de cinza diferentes.

Figura 2 - Exemplos de resolução radiométrica.



Fonte: Oliveira (2017).

Segundo Menezes e Almeida (2012), a resolução temporal refere-se ao intervalo de tempo em que um sensor revisita um determinado local na superfície terrestre. Essa característica é fundamental para o acompanhamento e a detecção de mudanças no planeta, especialmente para fenômenos mais dinâmicos, como desmatamento, desastres naturais e monitoramento ambiental.

3.2 Índice de Vegetação por Diferença Normalizada

Segundo Jensen (2009), os índices de vegetação são medidas radiométricas adimensionais que indicam a abundância e a atividade da vegetação verde, integrando parâmetros como área foliar, teor de clorofila e biomassa verde. O autor destaca que um índice ideal deve maximizar sua sensibilidade, preferencialmente de forma linear, aos parâmetros biofísicos das plantas, ao mesmo tempo que minimiza os efeitos de fatores externos, como ângulos solar e de visada, e interferências atmosféricas, viabilizando assim comparações espaciais e temporais confiáveis.

Vários índices de vegetação foram desenvolvidos para destacar o comportamento espectral da vegetação, como o EVI (Índice de Vegetação Melhorado), o PVI (Índice de

Vegetação Perpendicular), o SAVI (Índice de Vegetação Ajustado ao Solo) e o NDVI (Índice de Vegetação por Diferença Normalizada). Dentre estes, o NDVI destaca-se como o mais amplamente utilizado (Jensen, 2009).

Segundo Ponzoni, Shimabukuro e Kuplich (2012), a normalização da razão simples para uma escala entre -1 e +1 deu origem ao Índice de Vegetação por Diferença Normalizada (NDVI). Os autores ressaltam que este índice é uma ferramenta essencial para a construção de perfis sazonais e temporais da atividade da vegetação. Jensen (2009) complementa essa afirmação, destacando que a grande utilidade do NDVI reside na sua capacidade de reduzir certos tipos de ruído multiplicativo presentes em imagens multibanda. O NDVI é calculado a partir da seguinte equação, como proposto por Rouse et al. (1973):

$$NDVI: (\rho_{IVP} - \rho_V) / (\rho_{IVP} + \rho_V)$$

Onde:

ρ_{IVP} : *Reflectância do infravermelho proximo.*

ρ_V : *Reflectância no vermelho.*

De acordo com Baptista e Munhoz (2009) este método é a determinação do vigor da vegetação “por meio da diferença normalizada entre o pico de reflectância no infravermelho próximo e a feição de absorção de luz na região do vermelho utilizado na fotossíntese”.

3.3 Índice de Água por Diferença Normalizada

O Índice de Água por Diferença Normalizada (NDWI) é utilizado para realçar corpos d'água em imagens orbitais (Cunha et al., 2020). Para isso, emprega-se bandas espectrais que reduzem a contribuição da reflectância do solo e da vegetação, destacando preferencialmente as massas de água (EOS DATA, 2023).

Originalmente proposto para delimitar ambientes de água em superfície, o NDWI apresenta como principais vantagens: (1) maximizar a reflectância da água na faixa do verde; (2) minimizar sua baixa reflectância no infravermelho próximo; e (3) aumentar o contraste entre a água e a vegetação, utilizando a banda do infravermelho próximo (McFeeters, 1996 *apud* Brenner; Guasselli, 2015). Este índice pode ser empregado com a seguinte equação:

$$NDWI = (\rho_G - \rho_{IVP}) / (\rho_G + \rho_{IVP})$$

Onde (Cunha et al., 2020):

ρ_{IVP} = Reflectância do infravermelho próximo

ρ_G = Reflectância do verde

O comprimento de onda da faixa do verde maximiza a reflectância característica da superfície da água, enquanto o infravermelho próximo realça a alta reflectância da vegetação e do solo, minimizando simultaneamente a baixa reflectância dos corpos d'água (EOS DATA, 2023).

Visualmente, a interpretação do NDWI assemelha-se à do NDVI: valores entre -1 e 0 geralmente indicam ausência de água ou vegetação significativa, enquanto valores positivos correspondem a superfícies com presença de água e, em certos casos, de vegetação (Júnior et al., 2018).

3.4 Series temporais

No sensoriamento remoto, as séries temporais têm possibilitado o monitoramento espaço-temporal das transformações no uso e cobertura do solo em escalas temporais antes inviáveis. Anteriormente limitadas a sensores de baixa resolução espacial, como o *Advanced Very High Resolution Radiometer (AVHRR)*, a bordo dos satélites da série *National Oceanic and Atmospheric Administration (NOAA)*, as análises temporais passaram por uma revolução com o lançamento do sensor *Moderate Resolution Imaging Spectroradiometer (MODIS)*, a bordo dos satélites Terra (EOS-AM1) e Aqua (EOS-PM1) da *National Aeronautics and Space Administration (NASA)* (Freitas et al., 2011).

Na literatura do sensoriamento remoto, o termo "análise de séries temporais" abrange desde a visualização e classificação multi-temporal de imagens até a aplicação de técnicas de análise de dinâmica não linear (Freitas et al., 2011) tanto para imagens *MODIS* quanto *AVHRR*, e principalmente para índices de vegetação, como NDVI e EVI (Bruce e Mathur, 2005 apud Antunes, 2012).

As séries temporais possibilitam não apenas a identificação de mudanças, mas também a modelagem de tendências e a detecção de anomalias na paisagem ao longo do tempo (Antunes, 2012). O emprego contínuo de dados de satélites como *MODIS* e Landsat expandiu significativamente a capacidade de monitoramento em alta resolução temporal e espacial.

Essa evolução tecnológica tem sido essencial para aplicações em agricultura, gestão de recursos hídricos, vigilância de desastres naturais e estudos sobre mudanças climáticas. Nesse

contexto, Júnior et al. (2008), utilizando imagens Landsat ETM+7 em uma abordagem de série temporal, demonstraram a eficiência de índices de vegetação, como o NDVI, para monitorar e diferenciar coberturas vegetais ao longo do tempo.

De modo semelhante, o estudo de Teramoto et al. (2018) ilustra a aplicação de séries temporais de imagens Landsat 8 e análises sazonais do NDVI para avaliar respostas da vegetação às variações pluviométricas e do nível do Aquífero Rio Claro. Os resultados demonstraram que a mata nativa e áreas reflorestadas em regiões topograficamente mais elevadas apresentaram as respostas mais significativas do NDVI em relação à disponibilidade hídrica do solo, refletindo uma recarga mais expressiva do aquífero. Essa abordagem evidencia o potencial das séries temporais para monitorar relações entre vegetação e dinâmica hídrica, método passível de adaptação a estudos de detecção de mudanças em áreas como o entorno de UHEs.

3.5 Satélites

Segundo Florenzano (2011), satélites são objetos que giram em torno de um corpo celeste. Eles podem ser naturais, como a Lua que orbita a Terra, ou artificiais, criados pelo homem e colocados em órbita da Terra ou de outros corpos celestes. A órbita corresponde ao caminho percorrido pelo satélite em seu deslocamento.

De acordo com Florenzano (2011), os satélites de sensoriamento remoto de recursos terrestres descrevem uma órbita em relação ao Sol, garantindo condições constantes de iluminação ao sobrevoar uma mesma localidade na superfície terrestre. Isso permite que passem pelo mesmo ponto, no mesmo horário local, em diferentes datas. Entre as diversas missões existentes, destacam-se as séries americanas Landsat e os franceses SPOT.

3.5.1 Landsat 8/9

O programa de satélite de observação terrestre Landsat é pioneiro no sensoriamento remoto orbital. Sua série teve início na segunda metade da década de 1960, a partir de um projeto desenvolvido pela agência espacial norte-americana NASA (EMBRAPA, 2020).

O primeiro satélite, denominado Landsat 1, foi lançado em 1972. Concebido para aplicações em pesquisas de recursos naturais, ele operava com dois instrumentos a bordo: as

câmeras *Return Beam Vidicon* (RBV) e o *Multispectral Scanner System* (MSS) (EMBRAPA, 2020). E atualmente, o programa já conta com Landsat 8/9.

Neste estudo, foram utilizados dados dos satélites Landsat 8 e Landsat 9, equipados com os sensores *Operational Land Imager* (OLI) e *Thermal Infrared Sensor* (TIRS). Esses dados já são fornecidos com correções atmosféricas prévias, o que agiliza o processamento e aumenta a confiabilidade das análises.

A constelação Landsat 8/9 é composta por 11 bandas espectrais, cujas características são detalhadas na Figura 3. O sistema oferece uma resolução temporal de aproximadamente 16 dias (combinando os dois satélites, o intervalo de revisita é reduzido para 8 dias), resolução espacial de 30 metros para as bandas do visível e infravermelho próximo, 15 metros para a banda pancromática e 100 metros para as bandas termais. Além disso, possui uma resolução radiométrica de 16 bits, o que favorece a detecção de nuances sutis na superfície terrestre (Franco, 2017).

Figura 3 - Características do Landsat 8

Sensor	Bandas Espectrais	Resolução Espectral	Resolução Espacial	Resolução Temporal	Área Imageada	Resolução Radiométrica
OLI (Operational Land Imager)	(B1) AZUL COSTEIRO	0.43 - 0.45 μm	30 m	16 dias	170 x 183 km	16 bits
	(B2) AZUL	0.45 - 0.51 μm				
	(B3) VERDE	0.53 - 0.59 μm				
	(B4) VERMELHO	0.64 - 0.67 μm				
	(B5) INFRAVERMELHO PRÓXIMO	0.85 - 0.88 μm				
	(B6) INFRAVERMELHO MÉDIO	1.57 - 1.65 μm				
	(B7) INFRAVERMELHO MÉDIO	2.11 - 2.29 μm				
	(B8) PANCROMÁTICA	0.50 - 0.68 μm	15 m			
	(B9) CIRRUS	1.36-1.38 μm	30 m			
TIRS (Thermal Infrared Sensor)	(B10) INFRAVERMELHO TERMAL	10.6-11.19 μm	100 m			
	(B11) INFRAVERMELHO TERMAL	11.5-12.51 μm	100 m			

Fonte: Engesat (2025).

3.6 Técnicas de classificação

De acordo com Novo (2008), o ato de extrair informações de imagens digitais por meio de computadores é denominado “análise quantitativa”, por envolver a avaliação de propriedades numéricas. O processo de atribuir significado a um pixel com base nessas propriedades é chamado de “classificação”. Dessa forma, as técnicas de classificação buscam associar cada pixel a uma categoria, considerando suas características espectrais e espaciais.

Meneses e Almeida (2012) complementam essa perspectiva ao analisar que as técnicas de classificação digital de imagens asseguram a automatização do processo de extração de informações, eliminando a subjetividade inerente à interpretação humana. A classificação de imagens multiespectrais consiste em um método que agrupa os pixels da imagem em um número finito de classes representativas da realidade, com base em seus valores digitais.

Como resultado desse processo, obtém-se um mapa temático composto por pixels classificados, representados por meio de símbolos, gráficos e cores. Portanto, segundo os autores, a classificação automática de imagens constitui, em essência, um reconhecimento de pixels (Meneses; Almeida, 2012).

A forma mais comum, tanto entre usuários quanto em softwares, é a divisão dos classificadores em supervisionados e não supervisionados.

3.6.1 Classificação Supervisionada

Diferentemente da classificação não supervisionada, a classificação supervisionada exige um conhecimento prévio das classes de interesse, visando categorizar os pixels da imagem em classes predefinidas pelo analista. Esse processo inicia-se com a seleção, pelo analista, de pequenas áreas amostrais que sejam espectralmente representativas dos alvos reconhecidos. Se o treinamento atingir uma boa precisão, as classes resultantes representarão de forma fiel as feições originais (Meneses; Almeida, 2012).

Para assegurar uma classificação de qualidade, em muitos casos é também necessário que a imagem esteja previamente corrigida quanto a efeitos atmosféricos e à presença de ruídos (Meneses; Almeida, 2012).

A precisão estatística das classes, derivada das amostras de treinamento, varia conforme o método de classificação escolhido. Entre os métodos de classificação supervisionada existentes, é factível citar: Distância Mínima (MinDist), Distância Mahalanobis (MahaDist), Máxima Verossimilhança (MaxVer) e Redes Neurais (RN) (Meneses; Almeida, 2012).

Novo (2008) redige que para um bom resultado existe alguns procedimentos relevantes a serem seguidos, independentemente do método de classificação supervisionada aplicado. Os procedimentos constituem-se:

- a. “a escolha do melhor conjunto de bandas espectrais (...);”;
- b. “a localização precisa de áreas de treinamento”;
- c. “a avaliação da exatidão da classificação”.

O primeiro procedimento consiste em selecionar o algoritmo e o melhor conjunto de bandas espectrais, considerando a divergência entre as assinaturas das classes que se pretende discriminar. Esse processo é útil para reduzir o número de canais necessários à discriminação de um conjunto de alvos, garantindo a precisão da classificação sem comprometê-la (Novo, 2008).

O segundo procedimento consiste na seleção de amostras, etapa fundamental para o treinamento do algoritmo. É necessário criar descrições representativas das classes, as quais serão então atribuídas a todos os pixels que correspondam a cada classe espectral. Alguns cuidados devem ser observados, tais como: verificar se as amostras de uma determinada classe são representativas de todos os pixels pertencentes a essa classe; e assegurar que essas amostras estejam alinhadas com os pressupostos teóricos da regra de decisão adotada (Novo, 2008).

A etapa final consiste na avaliação da exatidão da classificação, cujo objetivo é verificar se o resultado obtido corresponde adequadamente à realidade mapeada (Novo, 2008). O método mais comum para quantificar essa exatidão é a utilização de uma matriz de confusão, que compara o mapa temático gerado a partir da imagem com um mapa de referência confiável. Nessa matriz, analisa-se classe por classe, confrontando os dados de referência (considerados verdade terrestre) com os dados classificados. Teoricamente, o número de linhas e colunas da matriz deve corresponder ao número de classes espectrais definidas no estudo (Meneses; Almeida, 2012).

Com base nela, é possível calcular os erros de omissão (quando pixels de uma classe são excluídos dela) e os erros de comissão (quando pixels de outras classes são incluídos indevidamente em uma classe) para cada categoria analisada (Meneses; Almeida, 2012). Na Figura 4 é apresentado uma matriz de confusão, obtida a partir de classificação não supervisionada pelo algoritmo MaxVer, no que possui nove classes de treinamento, sendo elas: VN = Vegetação Nativa, SE = Seringueira, AG = Água, EU = Eucalipto, SO = Solo Exposto, FR = Fruticultura, CA= Cana de-açúcar, PA = Pastagem, RC = Restos Culturais.

Figura 4 - Exemplo de matriz de confusão.

Classe	VN	SE	AG	EU	SO	FR	CA	PA	RC
VN	68,14	4,76	0	0	0	0	0	4,08	0
SE	0	95,24	0	0	0	0	0	0	0
AG	0	0	100	0	0	0	0	0	0
EU	6,98	0	0	100	0	0	18,18	0	0
SO	8,60	0	0	0	75	0	9,09	16,33	0
FR	4,65	0	0	0	0	75	0	0	0
CA	0	0	0	0	0	0	54,55	10,2	0
PA	2,33	0	0	0	0	0	18,18	46,94	0
RC	9,30	0	0	0	25	25	0	22,45	100
Total (%)	100	100	100	100	100	100	100	100	100

Fonte: Romero *et al.* (2018).

A partir dos dados contidos na matriz de confusão, derivam-se métricas estatísticas que quantificam a acurácia do mapeamento. Entre as mais utilizadas estão a exatidão global e o índice Kappa, as quais sintetizam a qualidade geral da classificação (Figueiredo; Vieira, 2007).

Vale et al. (2018) apontam que a exatidão global constitui uma métrica de verificação obtida pela razão entre a soma dos acertos, representados pelos elementos da diagonal principal da matriz de confusão, e o número total de pixels amostrados na imagem classificada. Esse índice pode ser calculado conforme a equação a seguir:

$$EG = \frac{A}{N} * 100$$

Onde:

EG = Exatidão Global

A = Número de pontos amostrais com acerto

N = Número de pontos amostrais

O índice Kappa, por sua vez, é analisado por Figueiredo e Vieira (2007) como uma técnica multivariada discreta aplicada na avaliação da precisão temática. Vale et al. (2018) complementam ao especificar que esse índice representa uma medida de concordância que quantifica o distanciamento entre as observações realizadas e as esperadas, indicando a validade das análises. Ele é calculado com base na matriz de confusão e serve como uma medida de concordância entre o mapa classificado e o mapa de referência, sendo utilizado na estimativa da precisão global. O índice Kappa pode ser obtido por meio da seguinte equação:

$$K = \frac{[n * \sum_{i=1}^r x_{ij} - \sum_{i=1}^r (x_i * x_j)]}{[n^2 - \sum_{i=1}^r (x_i * x_j)]}$$

Onde (Vale et al., 2018):

K = Índice de extidão Kappa

r = Número de linhas na matriz

x_{ij} = Número de observações na linha (i) e colunas (j)

n = Número total de observações

Segundo Meneses e Almeida (2012), o índice Kappa constitui um dos métodos estatísticos empregados para validar a precisão de classificações temáticas. Sua escala de interpretação situa-se entre 0 e 1, em que o valor mínimo corresponde à total discordância e o máximo à concordância perfeita entre o mapa gerado e a referência, respectivamente. A Tabela 1 expõe os níveis de desempenho da classificação correspondentes aos valores obtidos pelo índice Kappa:

Tabela 1 - Índice Kappa e respectivo desempenho.

Índice Kappa	Desempenho
< 0	Péssimo
$0 < k < 0,2$	Ruim
$0,2 < k < 0,4$	Razoável
$0,4 < k < 0,6$	Bom
$0,6 < k < 0,8$	Muito Bom
$0,8 < k < 1$	Excelente

Fonte: Figueiredo; Vieira (2007).

4 MATERIAS E METODOS

4.1 *Área de Estudo*

A área de estudo corresponde à Usina Hidrelétrica (UHE) Santo Antônio, como demonstrado na Figura 5, localizada no estado de Rondônia, no rio Madeira, a aproximadamente 7 km de Porto Velho, entre os paralelos: Latitude 08° 47' 42" S e Longitude 63° 50' 45" W.

Figura 5 - Imagem da UHE Santo Antônio.




Fonte: ESTADÃO (2021).

O estado de Rondônia possui uma área estimada de 237.765,293 km², está localizado na Região Norte, é composto por 52 municípios, faz divisa com os estados do Mato Grosso, Amazonas e Acre, além da Bolívia, e conta com uma população residente de 1.581.196 habitantes (IBGE, 2022).

Diante dessas características geográficas e demográficas, sobressai-se o Rio Madeira como uma das maiores e mais importantes sub-bacias da Amazônia, sendo primordial no eixo hidrográfico que estrutura o espaço rondoniense. Nasce nos Andes bolivianos, a partir da confluência do rio Beni e Mamoré, e percorre mais de três mil quilômetros até desaguar no rio Amazonas. Por atravessar tanto áreas de planalto quanto de planície, o Madeira é classificado

como um rio misto, apresentando variabilidade geomorfológica e hidrossedimentalógica ao longo do seu curso (CEMADEN, 2018; Oliveira et al., 2024). A área de influência direta da usina inclui o reservatório, o trecho do rio a montante e a jusante da barragem, bem como as comunidades ribeirinhas e urbanas de Porto Velho/RO. Na Figura 6, é exposto o mapa de localização da área de estudo.

Figura 6 - Mapa de localização



Fonte: a autora (2025).

4.2 Material

Para a execução deste estudo, utilizaram-se imagens dos satélites Landsat 8 e Landsat 9, dos sensores OLI (Operational Land Imager) e TIRS (Thermal Infrared Sensor), referentes aos anos de 2015, 2020 e 2025. O objetivo foi realizar a detecção de mudanças por meio de classificação supervisionada, com a avaliação da acurácia baseada no Índice Global de Exatidão e no Índice Kappa.


Para o processamento das imagens, foram utilizados os softwares ENVI e QGIS. O ENVI é um *software* especializado no processamento e análise de imagens de sensoriamento remoto, capaz de trabalhar com dados matriciais e vetoriais. Ele oferece ferramentas para

visualizar, explorar, analisar e apresentar dados geoespaciais, integrando funcionalidades de sensoriamento remoto e Sistemas de Informação Geográfica, SIG (ENVI, 200?). Já o QGIS é um *software* de código aberto e de interface amigável, mantido como projeto oficial da *Open Source Geospatial Foundation* (OSGeo). Ele suporta diversos formatos de dados, incluindo matriciais, vetoriais e bancos de dados, além de oferecer amplas funcionalidades para análise espacial (Santos, 2018).

4.3 Métodos

A metodologia deste estudo foi estruturada em cinco etapas: (1) pré-processamento, (2) processamento, (3) pós-processamento, e (4) geração de produtos. O fluxograma completo do processo é apresentado na Figura 7.

Figura 7 - Fluxograma do projeto.



Fonte: a autora (2025).

4.3.1 Pré-processamento

A primeira etapa do estudo consistiu no pré-processamento das imagens de satélite, visando assegurar a qualidade, a consistência e a integridade dos dados para as análises subsequentes. Inicialmente, foram selecionadas imagens dos sensores Landsat 8 e 9, obtidas via plataforma *United States Geological Survey* (USGS), referentes aos anos de 2015, 2020 e 2025, como demonstra a Tabela 2. As cenas utilizadas já apresentavam correção atmosférica e foram selecionadas com base no critério de baixa cobertura de nuvens, minimizando interferências sazonais ou atmosféricas.

Tabela 2 - Características das imagens obtidas.

SATELITE	SENSOR	DATA	FONTE
Landsat 8	OLI/TIRS	2015	USGS
Landsat 8	OLI/TIRS	2020	USGS
Landsat 8/9	OLI /TIRS	2025	USGS

Fonte: a autora (2025).

Devido à extensão da área de estudo, que abrange dois fusos distintos, a primeira etapa de tratamento ocorreu no software *QGIS*. Os arquivos originais foram convertidos para o formato GeoTIFF e submetidos a uma reprojeção cartográfica. Para eliminar as distorções causadas pela transição de fusos e viabilizar os cálculos de área e distância, todas as cenas foram padronizadas para o sistema de referência WGS 84, garantindo a compatibilidade geométrica entre as oito cenas utilizadas para cada ano.

Posteriormente, no ambiente *ENVI Classic*, procedeu-se ao empilhamento de bandas (*layer stacking*), utilizando as bandas espectrais na Tabela 3.

Tabela 3 - Bandas espectrais utilizadas.

Banda	Nome comum	Resolução Espectral
B2	Azul	0,48 μm
B3	Verde	0,56 μm
B4	Vermelho	0,65 μm
B5	Infravermelho próximo (NIR)	0,86 μm
B6	Infravermelho Ondas Curtas (SWIR 1)	1,61 μm

Fonte: Adaptado de *Engesat* (Engesat, 2025).

Justifica-se a escolha desse conjunto pela necessidade de realizar a detecção de mudanças na área de estudo. As bandas do espectro visível (RGB – *Red, Green e Blue*) são fundamentais para a visualização e interpretação dos mapas em cor real. E, a inclusão das bandas de Infravermelho Próximo e Infravermelho de Ondas Curtas é essencial para o cálculo de índices vegetativos e hídricos, uma vez que estas faixas oferecem informações espectrais que o olho humano não é capaz de enxergar, permitindo identificar variações no vigor da vegetação e na superfície da água que não seriam perceptíveis apenas no visível. Após essa etapa, as oito cenas individuais de cada período foram unidas para a composição de mosaicos anuais.

Por fim, realizou-se o registro de imagens, etapa primordial para viabilizar a análise multitemporal e assegurar a coincidência espacial entre os pixels das diferentes datas. Tomando o mosaico de 2015 como imagem de referência (*master*), os mosaicos de 2020 e 2025 foram ajustados geometricamente. Para tanto, foram coletados Pontos de Controle Terrestre (GCPs - *Ground Control Points*) em feições estáveis na paisagem, como cruzamentos de vias e infraestruturas consolidadas. Esse procedimento garantiu o alinhamento preciso entre os planos de informação, mitigando erros de deslocamento que poderiam induzir a falsas interpretações de mudança no uso e cobertura da terra.

4.3.3 Processamento

Com as imagens devidamente preparadas, procedeu-se ao cálculo de índices espectrais, ferramentas que realçam características específicas da superfície terrestre por meio de operações matemáticas entre bandas. Para esta análise, utilizou-se o NDVI, fundamentado na razão entre as bandas do infravermelho próximo (NIR) e do vermelho (RED), conforme a Equação 1 abaixo.

$$NDVI: (\rho_{IVP} - \rho_V) / (\rho_{IVP} + \rho_V)$$

Onde:

ρ_{IVP} : *Reflectância do infravermelho proximo.*

ρ_V : *Reflectância no vermelho.*

Embora o NDVI seja classicamente vinculado à densidade de vegetação, sua variação temporal neste estudo foi empregada para identificar dinâmicas hídricas na área da UHE Santo Antônio. A etapa central consistiu na Álgebra de Mapas, realizada pela ferramenta ‘*Band Math*’ do software *ENVI Classic*, onde foi efetuada a subtração dos índices entre os períodos:

Posteriormente, aplicou-se a Classificação Supervisionada pelo método da Distância Mínima (MinDist) sobre os resultados das subtrações. Para o treinamento do algoritmo, foram criadas Regiões de Interesse (ROI's) contemplando quatro classes distintas. A interpretação visual dos produtos gerados seguiu a escala descrita na Tabela 4 abaixo:

Tabela 4 - Intervalos de Referência para a Diferença de NDVI.

CLASSES	SIGLA	COR	VALOR
Alagada	ALA	Branco	0,10 >
Seca	SEC	Preto	< -0,2
Não Mudança	NM	Cinza escuro	-0,05 a 0,03
Não Mudança na Água	NMA	Cinza	0,01 a 0,10

Fonte: a autora (2026).

A análise da dinâmica hídrica na UHE Santo Antônio foi fundamentada nos intervalos de referência da diferença de NDVI ($NDVI_{inicial} - NDVI_{final}$), obtidos pela subtração entre o estado inicial e o estado final da cobertura da terra, vistos anteriormente. Nesta lógica, os valores positivos altos foram categorizados como área Alagada, representando a transição de áreas de vegetação densa ou solo exposto para lâmina d'água, onde a redução do vigor fotossintético gera um saldo positivo na equação. Por outro lado, os valores negativos altos indicam áreas de Seca, evidenciando locais onde o espelho d'água retraiu para dar lugar ao solo exposto ou ao crescimento de vegetação pioneira. Os valores que orbitam a neutralidade (próximos a zero) foram definidos como áreas de Não Mudança, indicando a estabilidade das

classes terrestres ou a permanência do corpo hídrico consolidado, onde a resposta espectral permaneceu constante entre os anos analisados.

4.3.4 Pós Processamento

Esta etapa consistiu na validação dos resultados por meio do cálculo dos índices Kappa, Exatidão Global e da Matriz de Confusão. Para isso, foram coletadas amostras de validação utilizando a ferramenta ‘ROI tool’ no software *ENVI Classic*, as quais foram posteriormente processadas pela função ‘*Confusion Matrix*’. Esse recurso permitiu a obtenção dos parâmetros estatísticos necessários para avaliar o desempenho da classificação, gerando, além dos índices globais, as tabelas com os erros de omissão e comissão para cada classe mapeada.

4.3.5 Geração de Produtos

Após a realização da classificação supervisionada por Distância Mínima, os dados foram exportados para o software *QGIS* para a elaboração dos mapas finais. No ambiente GIS, foi estruturado o layout de cada mapa, incluindo elementos como legenda, escala gráfica e orientação do Norte. A escolha da paleta de cores buscou destacar as mudanças na UHE Santo Antônio, diferenciando as áreas de alagamento e seca. Além da parte visual, foram geradas tabelas estatísticas e gráficos de barras para permitir uma análise mais detalhada das mudanças ocorridas na UHE Santo Antônio e no seu percurso. Essa combinação de mapas e dados numéricos foi fundamental para comparar com precisão as áreas de alagamento e seca.

5 RESULTADOS

A validação estatística dos produtos gerados foi realizada por meio da análise de matrizes de confusão, aplicadas individualmente para as transições 2015-2020 e 2020-2025. A matriz de confusão atua como um validador cruzado entre as classes preditas pelo algoritmo *Minimum Distance* e os pontos de controle de referência. A seguir, apresentam-se os resultados obtidos, detalhando o desempenho do classificador na distinção das dinâmicas hídricas e de cobertura da terra, evidenciando o nível de precisão alcançado em cada intervalo quinquenal do estudo.

5.1 Período 2015-2020

Na Tabela 5, é mostrado a matriz confusão 2015-2020 gerada pela classificação supervisionada Mínima Distância.

Tabela 5 - Matriz de Confusão (%) com Erros de Omissão (EO) e Comissão (EC) para o período 2015-2020.

CLASSES	SEC	ALA	NM	NMA	TOTAL	EC	EC
SEC	95,10	0	0	0	15,70	0,00	4,90
ALA	0	99,19	0	0	19,74	0,00	0,81
NM	0	0,81	43,90	12,89	13,59	45,24	56,60
NMA	4,90	0	56,60	87,11	50,97	20,63	12,89
TOTAL	100	100	100	100	100		

Fonte: a autora (2026).

A matriz de confusão do período de 2015 a 2020 mostra que a classificação apresentou bom desempenho para algumas classes e maior dificuldade para outras.

As classes SEC e ALA tiveram os melhores resultados. A classe SEC apresentou 95,10% de acerto, enquanto a classe ALA alcançou 99,19%, sendo a classe com melhor desempenho. Além disso, essas duas classes apresentaram erros de comissão baixos ou inexistentes, indicando que foram classificadas corretamente na maior parte.

A classe NMA também apresentou bom resultado, com 87,11% de acerto. No entanto, foi observado certa confusão principalmente com a classe NM.


A classe NM foi a que apresentou maior dificuldade de classificação, com apenas 43,90% de acerto. Essa classe apresentou valores elevados de erro de omissão (45,24%) e erro

de comissão (56,60%), indicando que parte das áreas que deveriam ser classificadas como NM foram confundidas com outras classes, principalmente com NMA.

De forma geral, os resultados indicam que o modelo conseguiu classificar bem as classes mais distintas (SEC e ALA), mas apresentou maior dificuldade nas classes que possuem características mais semelhantes entre si. A confusão observada entre as classes NM e NMA pode estar relacionada à semelhança das características dessas áreas no período analisado. Em muitos casos, essas classes podem apresentar padrões visuais e espectrais parecidos nas imagens utilizadas, o que dificulta a diferenciação pelo classificador. Além disso, fatores como variações sazonais, qualidade da imagem e heterogeneidade da cobertura do solo também podem ter contribuído para o aumento dos erros.

O mapa referente na Figura 8, da área da UHE Santo Antônio, apresenta apenas as classes seca (SEC) e alagada (ALA), pois o objetivo da análise é a detecção de mudanças entre essas duas condições. As demais classes foram desconsideradas nessa etapa para permitir a visualização mais clara das áreas que permaneceram em condição de seca e daquelas que passaram por eventos de alagamento.

Figura 8 - Análise Espacial da classe Seca e Alagada na UHE Santo Antônio (2015-2020).



Fonte: a autora (2026).

5.2 Período 2020-2025

A seguir, é apresentado na Tabela 6 a matriz de confusão para o período 2020 a 2025.

Tabela 6 - Matriz de Confusão (%) com Erros de Omissão (EO) e Comissão (EC) para o período 2020-2025.

CLASSES	SEC	ALA	NM	NMA	TOTAL	EC	EC
SEC	91,82	0	0	0	21,77	0,00	8,18
ALA	0	100	0	0	26,29	0,00	0
NM	8,18	0	91,45	0	25,00	7,76	8,55
NMA	0	0	8,55	100	26,94	8,00	0
TOTAL	100	100	100	100	100		

Fonte: a autora (2026).

A classe ALA apresentou 100% de acerto, não registrando erros de omissão e de comissão, demonstrando excelente desempenho na identificação dessa classe. A classe NMA também apresentou 100% de acerto, com ausência de erro de omissão, embora tenha apresentado pequeno erro de comissão (8,00%).


A classe NM apresentou 91,45% de acerto, com erro de omissão de 7,76% e erro de comissão de 8,55%. Observa-se que a principal confusão ocorreu entre as classes NM e NMA, embora em menor proporção quando comparado ao período anterior.

A classe SEC apresentou 91,82% de acerto, com erro de comissão de 8,18%. Apesar de ter apresentado leve redução no percentual de acerto em relação ao período 2015-2020, o desempenho ainda pode ser considerado bom.

De modo geral, os resultados mostram que a classificação no período 2020-2025 apresentou maior precisão, com redução significativa das confusões entre as classes, principalmente entre NM e NMA. Isso indica uma melhoria na capacidade do modelo em diferenciar classes com características semelhantes, qualidade da imagem ou heterogeneidade da cobertura do solo.

O mapa referente na Figura 9 do período de 2020–2025, da área da UHE Santo Antônio, apresenta as classes seca (SEC) e alagamento (ALA), com foco nas áreas que apresentaram maior ocorrência de mudanças entre essas duas condições, permitindo identificar de forma mais clara os locais onde houve alteração mais significativa ao longo do período analisado.

Figura 9 - Análise Espacial da classe Seca e Alagada na UHE Santo Antônio (2020-2025).



Fonte: a autora (2026).

5.3 Análise Comparativa

A análise comparativa entre os dois intervalos quinquenais revela uma evolução significativa na estabilidade e na precisão da classificação. Enquanto o período de 2015-2020 apresentou uma Acurácia Global de 83,33% e um Índice Kappa de 0,7530, o intervalo de 2020-2025 atingiu índices superiores, com 95,90% de acurácia e Kappa de 0,9454, como demonstra na Tabela 7. Essa melhoria estatística pode ser atribuída à consolidação das margens do reservatório e a uma definição espectral mais nítida das classes de 'Não Mudança' no segundo período, reduzindo a confusão entre áreas terrestres e hídricas. É importante destacar que as classes de maior interesse para o estudo, 'Alagada' e 'Seca', mantiveram níveis de acerto próximos ou iguais a 100% em ambos os períodos, com erros de comissão e omissão residuais. Tais resultados confirmam que a álgebra de mapas baseada no NDVI diferencial, associada ao classificador *Minimum Distance*, constitui uma metodologia consistente e confiável para o monitoramento das dinâmicas espaciais na UHE Santo Antônio ao longo da última década.

Observa-se também que, ambos os períodos superaram o limite de 0,70 para o Índice Kappa, valor frequentemente adotado na literatura como patamar de qualidade para mapeamentos temáticos. A transição para o nível 'Excelente' no período 2020-2025 reforça a precisão do algoritmo classificador na identificação das áreas de influência da UHE Santo Antônio.

Tabela 7 - Comparativo da Acurácia Global e Índice Kappa entre os períodos analisados.

Período de análise	Exatidão Global (%)	Índice Kappa	Classificação
2015-2020	83,33	0,7530	Muito Boa
2020-2025	95,90	0,9454	Excelente

Fonte: a autora (2026).

5.4 Dinâmica das Áreas Alagada e Seca

A classificação Supervisionada pelo método de Mínima Distância permitiu analisar a dinâmica espaço-temporal das mudanças na cobertura superficial da área de estudo. Os resultados mostram alterações no balanço entre áreas inundadas e áreas secas ao comparar os períodos de 2015-2020 e 2020-2025. A Tabela 8 apresenta a evolução das áreas de mudanças hídrica no percurso ao longo do período analisado.

Observa-se que a classe Alagada apresentou redução de 16.024,71 km² (2015-2020) para 14.709,16 km² (2020-2025). Por outro lado, a classe Seca apresentou aumento, passando de 9.265,35 km² para 13.274,65 km², indicando maior presença de áreas secas no segundo período.

Em relação às classes NM e NMA, nota-se uma variação expressiva entre os períodos. Esse comportamento pode estar relacionado a certa confusão do algoritmo no momento da classificação, como visto anteriormente, já que as classes possuem características semelhantes, o que pode ter dificultado a separação exata entre áreas estáveis de água.

Tabela 8 - Evolução das áreas de mudança hídrica (2015-2025).

Classe	Área 2015-2020 (km²)	Área 2020-2025 (km²)
Alagada	16.024,71	14.709,16
Seca	9.265,35	13.274,65
Não Mudança	126.857,79	675.685,14

Não Mudança na Água	609.830,58	59.661,20
----------------------------	------------	-----------

Fonte: a autora (2026).

Como o objetivo principal deste estudo é a detecção de mudanças, foram priorizadas as classes Alagada e Seca, por representarem diretamente as alterações na dinâmica hídrica da área analisada. Dessa forma, a Tabela 9 apresenta a variação líquida e percentual entre os períodos de 2015-2020 e 2020-2025. Observa-se que a classe Alagada apresentou redução de 1.315,55 km², correspondendo a uma diminuição de 8,21%. Em contrapartida, a classe Seca apresentou aumento de 4.009,30 Km², equivalente a um crescimento de 43,27%. Esses resultados evidenciam uma tendência de expansão das áreas secas e redução das áreas alagadas ao longo do período analisado.


Tabela 9 - Evolução das áreas de mudança hídrica (2015-2025).

Classe	Variação Líquida (Δkm^2)	Variação (%)
Alagada	-1.315,55	-8,21
Seca	+4.009,30	+43,27

Fonte: a autora (2026).

A Figura 10 apresenta a visualização gráfica da comparação entre as classes Alagada e Seca. O gráfico permite observar de forma mais clara a evolução espaço-temporal das áreas analisadas no projeto, evidenciando a redução das áreas alagadas e o aumento das áreas secas ao longo do tempo. Essa representação facilita a compreensão das mudanças ocorridas, complementando as informações apresentadas nas tabelas anteriores e reforçando a tendência de alteração na dinâmica hídrica da área de estudo.

Figura 10 - Gráfico de comparação das Classes Alagada e Seca.




Fonte: a autora (2026).

Os resultados obtidos corroboram com os dados de monitoramento hidrológico do Serviço Geológico do Brasil (SGB) e do Cemaden, que classificou o período recente como a seca mais severa da história da região. A expansão de 43,27% na classe 'Seca', observada neste estudo, alinha-se diretamente aos registros de níveis críticos nos rios da bacia; como o Rio Madeira, que atingiu cotas inferiores a 1,10 m, e o Rio Solimões, que registrou mínima histórica de -0,94 m em Tabatinga (CNN Brasil, 2024). Essa convergência entre os dados de sensoriamento remoto e os registros *in situ* evidencia a gravidade da crise hídrica, demonstrando que a retração das superfícies alagáveis e o aumento das áreas secas mapeadas são reflexos diretos de um déficit hídrico sem precedentes nos últimos 44 anos.

Nesse contexto, a variação na extensão da classe 'Seca' observada na Figura 11 não decorre exclusivamente da operação da usina hidrelétrica, mas está intrinsecamente vinculada aos eventos climáticos extremos. Dados do SGB/CPRM já confirmavam a gravidade desse cenário em períodos anteriores, como em 2020, quando o nível do rio em Porto Velho atingiu 1,88 m, superando a seca de 2016 e consolidando-se, à época, como uma das maiores vazantes da série histórica (RONDONIAGORA, 2020). Portanto, esses episódios recorrentes de estiagem severa explicam a detecção de áreas de solo exposto e bancos de areia nas margens do reservatório, feições que foram captadas com precisão pelo Índice vegetativo (NDVI) como perdas significativas de cobertura hídrica.


Figura 11 – Mapa Comparativo da Classe Seca na UHE Santo Antônio (2015-2025).



Ao correlacionar os dados espaciais com o histórico hidrológico do Rio Madeira, percebe-se que as manchas de seca (em amarelo e laranja nos mapas), na Figura 12, coincidem com os períodos de baixa acentuada do rio. Essa relação demonstra a sensibilidade da metodologia em detectar mudanças ambientais reais, separando o que é o espelho d'água permanente das áreas que ficam expostas durante as crises hídricas recentes. Portanto, os resultados reforçam que a UHE Santo Antônio opera em um cenário de alta variabilidade climática, onde os eventos de seca extrema deixam marcas visíveis na configuração espacial da paisagem.

Ao comparar as transformações ocorridas no reservatório, observa-se que a classe Seca foi a mais impactada e apresentou a maior variabilidade espacial ao longo do período estudado. Essa diferença no comportamento das classes revela que, embora a área alagada permaneça relativamente constante em sua cota operacional, as margens e áreas de menor profundidade sofrem exposições severas de solo, tornando a detecção de 'Seca' o indicador mais dinâmico e sensível da paisagem no intervalo de 2015 a 2025.


Figura 12 - Mapa com correlação da classe Seca (2015-2020) no Rio Madeira.



Fonte: a autora (2026).


A análise espacial revelou que o Rio Madre de Dios, um dos principais tributários da bacia, também apresentou mudanças significativas em sua morfologia hídrica durante o período estudado. Conforme observado nos mapeamentos na Figuras 13 e 14, a classe Seca manifestou-se de forma expressiva ao longo do canal, evidenciando a retração do espelho d'água e a exposição de bancos de areia e sedimentos marginais. Essa dinâmica é particularmente visível no comparativo entre 2015 e 2025, onde a predominância da cor amarela indica que as áreas de seca foram mais extensas no primeiro período, mas continuaram a ocorrer de forma pontual (em laranja) no segundo intervalo. Tais resultados reforçam que a bacia como um todo sofreu os impactos das estiagens históricas recentes, mostrando que o fenômeno da redução do fluxo hídrico é um processo regional que afeta tanto o curso principal do Rio Madeira quanto seus afluentes diretos.

Figura 13 - Trecho Madre De Dios com a classe Seca (2015-2025).



Fonte: a autora (2026).

Figura 14 - Trecho Madre De Dios com a classe Seca e Alagada (2015-2025).



Fonte: a autora (2026).

6 CONCLUSÃO

A presente pesquisa analisou a dinâmica na área de influência da UHE Santo Antônio, do Rio Madre de Dios e Rio Madeira entre os anos de 2015 e 2025, evidenciando a eficácia do uso de geotecnologias para o monitoramento de áreas ambientalmente sensíveis na Amazônia. Diante da relevância da matriz hidrelétrica para o Sistema Elétrico Brasileiro (Montalvão; Faria; Abbud, 2012), compreender as alterações na superfície hídrica torna-se vital para a gestão de recursos naturais e segurança energética.

Os resultados deste estudo ganham ainda mais relevância quando confrontados com os dados do Serviço Geológico do Brasil (CPRM), que já em 2020 alertava para vazantes extremas no Rio Madeira, com níveis superando secas históricas anteriores (como a de 2016) e atingindo cotas mínimas de 1,88 metros em Porto Velho. A detecção de mudanças realizada nesta pesquisa comprova que esse prolongamento do período de vazante e o atraso nas chuvas, observados tecnicamente pela CPRM (2020), deixam marcas espectrais claras na paisagem hídrica. A identificação de áreas de seca através do NDVI e da classificação supervisionada permitiu espacializar esses eventos críticos, confirmando que a bacia enfrenta um cenário de vulnerabilidade hidroclimática crescente. Assim, o monitoramento por satélite consolida-se como uma ferramenta de resposta rápida para prever restrições na navegação e impactos na geração de energia, transformando dados brutos em informações estratégicas para a gestão de crises hídricas em Rondônia.

A aplicação da classificação supervisionada pelo método da Mínima Distância (Quartarolli e Batistella, 2006) mostrou-se adequada para a conversão de dados espectrais em classes temáticas objetivas, validando a hipótese de que sensores multiespectrais com alta resolução espectral (Gomes e Cubas, 2012) são fundamentais para o monitoramento temporal de precisão.

Conclui-se que o monitoramento espaço-temporal, embasado em series temporais (Teramoto et al., 2018), fornece subsídios essenciais para entender como a paisagem hídrica reage à operação de grandes empreendimentos e às variações do ciclo hidrológico amazônico. Este estudo reforça que o sensoriamento remoto gratuito e de baixo custo é uma ferramenta indispensável para a governança ambiental, permitindo que gestores antecipem impactos e planejem o uso sustentável dos recursos hídricos em um cenário de mudanças climáticas globais.

REFERÊNCIAS

ANTUNES, R. L. dos S. **Variação espaço-temporal de NDVI em área de aproveitamento hidrelétrico – UHE Santo Antônio, Porto Velho (RO)**. 2012. 122 f. Dissertação (Mestrado em Geografia) – Instituto de Geociências, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2012.

BAPTISTA, G. M. de M; MUNHOZ, C. B. R. Comportamento do sequestro florestal de carbono, do conteúdo de CO₂ atmosférico e do conteúdo de umidade da vegetação no Pantanal de Nhecolândia, MS, por meio de sensoriamento remoto hiperespectral. In: SIMPOSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 2009, Natal. Anais [...]. Natal: INPE, 2009. Disponível em: <http://marte.sid.inpe.br/col/dpi.inpe.br/sbsr@80/2008/11.17.01.40/doc/1071-1078.pdf>. Acesso em: 20 dez. 2025.

BRENNER, V. C; GUASSELLI, L. A. Índice de Diferença Normalizada da água (NDWI) para identificação de meandros ativos no leito do canal do rio Gravataí/RS-Brasil. In: SIMPOSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 2015, João Pessoa. **Anais** [...]. João Pessoa: INPE, 2015. Disponível em: <http://www.dsr.inpe.br/sbsr2015/files/p0727.pdf>. Acesso em: 20 dez. 2025.

CEMADEN. Bacia do rio Madeira. 2018. Disponível em: <http://www2.cemaden.gov.br/categoria/monitoramento/monitoramento-hidrologico/bacia-do-rio-madeira/>. Acesso em: 06 mar. 2026.

COELHO, A. L. N.; CORREA, W. de S. C. TEMPERATURA DE SUPERFÍCIE CELSIUS DO SENSOR TIRS/LANDSAT-8: METODOLOGIA E APLICAÇÕES. **REVISTA GEOGRÁFICA ACADÊMICA**, [S. l.], v. 7, n. 1, p. 31–45, 2013. DOI: 10.18227/1678-7226rga.v7i1.2996. Disponível em: <https://revista.ufr.br/rga/article/view/2996>. Acesso em: 5 dez. 2025.

DA CUNHA, C. F.; CARDOSO, S. B; TERAMOTO, Elias Hideo; CHANG, Hung Kiang. Modelo área-volume para a Represa Guarapiranga empregando o índice NDWI. **Holos Environment**, [S. l.], v. 20, n. 1, p. 137–151, 2020. DOI: 10.14295/holos.v20i1.12370. Disponível em: <https://www.cea-unesp.org.br/holos/article/view/12370>. Acesso em: 12 mar. 2026.

EMBRAPA. Landsat - Land Remote Sensing Satellite. 2020. Disponível em: <https://www.embrapa.br/satelites-de-monitoramento/missoes/landsat>. Acesso em: 09 dez. de 2025.

ENGESAT Imagens de Satélites. **Landsat 8**. Disponível em: https://www.engesat.com.br/imagem-de-satelite/landsat-8/?gad_source=1&gad_campaignid=21199667725&gbraid=0AAAAADAI_hLKnYrVgu71tY-Vp87X4Clgp&gclid=Cj0KCQiA8KTNBhD_ARIsAOvp6DKNb9v3RfW73-5VdrG2fpKyCCxt2Sd7yNMCg48O2iRrjo349pgFVNAAAny2EALw_wcB. Acesso em: 12 mar. 2026.

ESTADÃO. Seca histórica faz 53 cidades do Sudeste, Sul e Centro-Oeste racionarem água. 2021. Disponível em: <https://www.estadao.com.br/sustentabilidade/seca-historica-faz-53->

[cidades-de-sudeste-sul-e-centro-oeste-rationarem-agua/?srsId=AfmBOopY3TWhvQ-WjfGX7aLyU_69XuTRvsmuuDZZGO-f5Tj5masrbWrV](https://www.cidades-de-sudeste-sul-e-centro-oeste-rationarem-agua/?srsId=AfmBOopY3TWhvQ-WjfGX7aLyU_69XuTRvsmuuDZZGO-f5Tj5masrbWrV). Acesso em 20 dez. 2025.

ENVI. Aspectos. [S. l.], 202-?. Disponível em: <https://www.envi.com.br/>. Acesso em: 23 dez. 2025.

FEARNSIDE, P. M. Barragens na Amazônia 2: Hidrelétricas planejadas em longo prazo na Amazônia brasileira. Instituto Nacional de Pesquisas da Amazônia (INPA). Amazonas, 2013. Disponível em: https://philip.inpa.gov.br/publ_livres/2013/Barragens%20na%20Amaz%C3%B4nia_S%C3%A9rie_Amaz%C3%B4nia%20Real.pdf. Acesso em 25 dez. 2025.

FIGUEIREDO, G. C.; VIEIRA, C. A. O. Estudo do comportamento dos índices de Exatidão Global, Kappa e Tau, comumente usados para avaliar a classificação de imagens do sensoriamento remoto. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13, 2007, Florianópolis. **Anais** [...]. Florianópolis: INPE, 2007. p. 5755-5762. Disponível em: <http://marte.sid.inpe.br/col/dpi.inpe.br/sbsr@80/2006/11.13.17.35/doc/5755-5762.pdf>. Acesso em: 25 dez. 2025.

FLORENZANO, T. G. **Iniciação em Sensoriamento Remoto**. 3. ed. São Paulo: Oficina de Textos, 2011.

FRANCO, G. S. Impactos ambientais nas áreas de influência das usinas hidrelétricas de Santo Antônio e Jirau, no estado de Rondônia. 2017. **Trabalho de Conclusão de Curso** (Graduação em Engenharia Florestal) – Universidade de Brasília, Departamento de Engenharia Florestal, Brasília, 2017.

FREITAS, R. M; ARAI, E; ADAMI, M; SOUZA, A. F. de; SHIMABUKURO, Y. E; RUDORFF, B. F. T; YUZO, F; ROSA, R. R. Visualização Instantânea de Séries Temporais EVI2-MODIS na América do Sul. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 2011, Curitiba, **Anais** [...]. Curitiba: INPE, 2011. p. 6866. Disponível em: https://www.researchgate.net/publication/236989651_Virtual_laboratory_of_remote_sensing_time_series_Visualization_of_MODIS_EVI2_data_set_over_South_America. Acesso em: 25 dez. 2025.

GOMES, L. N.; CUBAS, R. **Sensoriamento Remoto**. Curitiba: InterSaberes, 2012.

GUEDES, J. C. F; SILVA, S. M. P. da. SENSORIAMENTO REMOTO NO ESTUDO DA VEGETAÇÃO: PRINCÍPIOS FÍSICOS, SENSORES E MÉTODOS. Boa Vista, 2018. ACTA Geográfica. ISSN 1980-5572. DOI: <https://doi.org/10.18227/2177-4307.acta.v12i29.4001>. Disponível em: <https://revista.ufrb.br/actageo/article/view/4001>. Acesso em: 22. dez 2025.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos da Terra**. São Paulo: 2009.

JÚNIOR, O. A. de C; SAMPAIO, C. da S; SILVA, N. C. da; JUNIOR, A. F. C; GOMES, R. A. T; CARVALHO, A. P. F. de; SHIMABUKURO, Y. E. CLASSIFICAC AO DE PADRÕES DE SAVANA USANDO ASSINATURAS TEMPORAIS NDVI. Revista Brasileira de Geodésia, 2008. Disponível em: <https://www.scielo.br/j/rbg/a/NwhZqZV5hFdQnxNw7SrnGKD/?lang=pt>. Acesso em: 25 dez. 2025.

JÚNIOR, J. A. da S; MORAES, V. S. de; CANDEIAS, A. L. B; JÚNIOR, J. R. T. ANÁLISE DO NDVI E NDWI E UMIDADE LOCAL NO MUNÍCIPIO DE ÁGUA BRANCA – AL. In: Congresso Técnico Científico da Engenharia e da Agronomia, 2018, Maceió. Disponível em: https://www.confea.org.br/sites/default/files/antigos/contecc2018/agrimensura/1_adneneulnm_d%C3%A1ba.pdf . Acesso em: 25 dez. 2025.

IBGE EDUCA. Biomas brasileiros. Rio de Janeiro: IBGE: 2024. Disponível em: <https://educa.ibge.gov.br/jovens/conheca-o-brasil/territorio/18307-biomas-brasileiros.html>. Acesso em: 5 dez. 2025.

IBGE – Instituto Brasileiro de Geografia e Estatística. Área Territorial Oficial do Brasil. Rio de Janeiro: IBGE, 2022. Disponível em: <https://www.ibge.gov.br> . Acesso em: 06 dez. 2025.

IBGE – Instituto Brasileiro de Geografia e Estatística. Cidades – Porto Velho (RO). 2021. Disponível em: <https://cidades.ibge.gov.br> . Acesso em: 05 dez. 2025.

MENESES, P. R.; ALMEIDA, T de. **Introdução ao Processamento de Imagens de Sensoriamento Remoto**. Brasília: UnB, 2012. Disponível em: https://edisciplinas.usp.br/pluginfile.php/5550408/mod_resource/content/3/LivroSensoriamentoRemoto.pdf . Acesso em: 20 dez. 2025.

MONTALVÃO, E.; FARIA, I. D.; ABBUD, O. A. **Ambiente e Energia: Crença e Ciência no Licenciamento Ambiental**. Parte IV: A Opção de Geração Hidroelétrica no Brasil. Brasília: Senado Federal, Consultoria Legislativa, 2012. Disponível em: <https://pnla.mma.gov.br/teses-dissertacoes-e-artigos?download=7:ambiente-e-energia-crenca-e-ciencia-no-licenciamento-ambiental> . Acesso em: 22 dez. 2025.

NOVO, E. M. L. de M. **Sensoriamento Remoto: Princípios e Aplicações**. 4. ed. São Paulo: Blucher, 2010.

OLIVEIRA, B. S. **Satélites e Sensores**. INPE, 2017. São Jose dos Campos (SP). Disponível em: <http://www.dsr.inpe.br/DSR/educacao/uso-escolar-sensoriamento-remoto/material-didatico-anos-anteriores/arquivos/3-satelites-e-sensores.pdf>. Acesso em: 20 dez. 2025.

OLIVEIRA, I. de; PIFFER, C; GARCIA, D. S. S. **A Transnacionalidade do Rio Madeira**. **Revista Jurídica da Amazônia**, v. 1, n. 1, p. 135 a 157, 2024. ISSN: 2965-9426, DOI: 10.63043/rja.v1i1.63. Disponível em: <https://revista.mpro.mp.br/amazonia/article/view/63/57> . Acesso em: 25 dez. 2025.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da vegetação**. 2. ed. atual. e ampla. São Paulo: Oficina de Textos, 2012.

QUARTAROLI, C. F.; BATISTELLA, M. **Classificação digital de imagens de sensoriamento remoto**. Campinas: Embrapa Monitoramento por Satélite, 2006. 35 p. (Documentos, 50).

RIO Solimões registra menor nível da história no AM. CNN Brasil, São Paulo, 3 set. 2024. Disponível em: <https://www.cnnbrasil.com.br/nacional/rio-solimoes-registra-menor-nivel-da-historia-no-am/> . Acesso em 4 mar. 2026

ROMERO, C. W. da S.; SILVA, Y. de F. da; SILVA, I. D. C.; GARÇON, E. A. M.; LAMPARELLI, R. A. C.; ROCHA, J. V. Comparação entre resultados de classificação

supervisionada para única data e para diferentes datas do município de Santa Fé do Sul-SP. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 19, 2019, Santos. **Anais [...]**. Santos: INPE, 2019. Disponível em: <https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1108757/1/5063.pdf> . Acesso em: 20 dez. 2025.

RONDONIAGORA. Rio Madeira atinge o segundo pior nível de seca em Porto Velho. Rondônia, 2020. Disponível em: <https://www.rondoniagora.com/geral/rio-madeira-atinge-o-segundo-pior-nivel-de-seca-em-porto-velho>. Acesso em: 04 mar. 2026.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. **Monitoring vegetation systems in the Great Plains with ERTS**. Third ERTS Symposium, NASA SP-351 I, p. 309-317, 1973.

TERAMOTO, E. H.; BENJUMEA, M. T.; GONÇALVES, R. D.; KIANG, C. H. Séries temporais do índice NDVI na avaliação do comportamento sazonal do Aquífero Rio Claro. **Revista Brasileira de Cartografia**, v. 70, n. 3, p. 1042-1064, 2018

VALE, J. R. B.; COSTA, J. A. da; SANTOS, J. F. dos; SILVA, E. L. S. da; FAVACHO, A. T. Análise comparativa de métodos de classificação supervisionada aplicada ao mapeamento da cobertura do solo no município de Medicilândia, Pará. **Revista de Geografia e Interdisciplinaridade**, Grajaú, MA, v. 4, n. 13, p. 26-44, 2018. DOI: <http://dx.doi.org/10.18764/2446-6549.v4n13p26-44>. Disponível: <https://periodicoseletronicos.ufma.br/index.php/interespaco/article/view/7884/5289> . Acesso em: 20 dez. 2025.

ZANOTTA, D. C.; FERREIRA, M. P.; ZORTEA, M. **Processamento de imagens de satélite**. [S. l.]: Oficina de Textos, 2019. Disponível em: https://books.google.com.br/books?hl=ptBR&lr=&id=l6SWDwAAQBAJ&oi=fnd&pg=PT5&ots=YwLW9me7c&sig=C_1nhZOvVrrLtH_nzDpn6ZNXXsl#v=onepage&q&f=false . Acesso em: 20 dez. 2025.