



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
TRABALHO DE CONCLUSÃO DE CURSO

JOÃO ALEXANDRE SILVA DO NASCIMENTO

**AVALIAÇÃO ESPAÇO-TEMPORAL DA COBERTURA DO SOLO EM ÁREA DE
MINERAÇÃO NO SERTÃO DE PERNAMBUCO A PARTIR DE IMAGENS
PLANETSCOPE, CLASSIFICAÇÃO KNN E ÍNDICES ESPECTRAIS**

RECIFE

2024

UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIAS E GEOCIÊNCIAS
ENGENHARIA CARTOGRÁFICA E DE AGRIMENSURA

JOÃO ALEXANDRE SILVA DO NASCIMENTO

**AVALIAÇÃO ESPAÇO-TEMPORAL DA COBERTURA DO SOLO EM ÁREA DE
MINERAÇÃO NO SERTÃO DE PERNAMBUCO A PARTIR DE IMAGENS
PLANETSCOPE, CLASSIFICAÇÃO KNN E ÍNDICES ESPECTRAIS**

TCC apresentado ao Curso de Engenharia Cartográfica e de Agrimensura da Universidade Federal de Pernambuco, Centro Recife, como requisito para a obtenção do título de Bacharel em Engenharia Cartográfica e de Agrimensura.

Orientador(a): Admilson da Penha Pacheco

RECIFE

2024

Ficha de identificação da obra elaborada pelo autor,
através do programa de geração automática do SIB/UFPE

Nascimento, João Alexandre Silva do.

Avaliação espaço-temporal da cobertura do solo em área de mineração no Sertão de Pernambuco a partir de imagens PlanetScope, classificação KNN e índices espectrais / João Alexandre Silva do Nascimento. - Recife, 2024.

46 p. : il., tab.

Orientador(a): Admilson da Penha Pacheco

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Engenharia Cartográfica e de Agrimensura - Bacharelado, 2024.

Inclui referências.

1. Mineração. 2. Semiárido. 3. PlanetScope. 4. K-Nearest Neighbors. I. Pacheco, Admilson da Penha. (Orientação). II. Título.

550 CDD (22.ed.)

JOÃO ALEXANDRE SILVA DO NASCIMENTO

**AVALIAÇÃO ESPAÇO-TEMPORAL DA COBERTURA DO SOLO EM ÁREA DE
MINERAÇÃO NO SERTÃO DE PERNAMBUCO A PARTIR DE IMAGENS
PLANETSCOPE, CLASSIFICAÇÃO KNN E ÍNDICES ESPECTRAIS**

TCC apresentado ao Curso de Engenharia Cartográfica e de Agrimensura da Universidade Federal de Pernambuco, Centro Acadêmico de Recife, como requisito para a obtenção do título de Bacharel em Engenharia Cartográfica e de Agrimensura.

Aprovado em: 04/04/2024

BANCA EXAMINADORA

Profº. Dr. Admilson da Penha Pacheco (Orientador)
Universidade Federal de Pernambuco - UFPE

Profº. Dr. Carlos Fabricio Assunção da Silva (Examinador Interno)
Universidade Federal de Pernambuco - UFPE

Profº. M.Sc Ubiratan Joaquim da Silva Júnio (Examinador Externo)
Universidade Federal de Pernambuco - UFPE

RESUMO

A mineração no Nordeste do Brasil, apesar de seu papel vital na economia, enfrenta o desafio crítico de equilibrar o crescimento econômico com a preservação ambiental. A atividade mineradora, embora geradora de empregos e contribuinte para o PIB, tem sido associada a desmatamento acelerado, degradação da biodiversidade e recursos naturais, e impactos negativos na saúde das comunidades. A necessidade de práticas sustentáveis e responsáveis é urgente, exigindo o uso de tecnologias avançadas para monitoramento e mitigação dos impactos ambientais da mineração. O objetivo deste estudo é uma análise espaço-temporal do uso e cobertura do solo em áreas de mineração de 988,92 km² no sertão de Pernambuco, Brasil, a partir de imagens de alta resolução fornecidas pela constelação de satélites PlanetScope. A metodologia consistiu em monitorar e avaliar os impactos ambientais decorrentes das atividades de mineração, por meio de uma classificação de imagens, utilizando o algoritmo K-Nearest Neighbors (KNN) e os índices espectrais de Vegetação por Diferença Normalizada (NDVI) e Índice de Água por Diferença Normalizada (NDWI), numa cobertura temporal entre os anos de 2018 e 2023. Com resultado, foi identificada uma diminuição notável na vegetação de 3,28% e nas áreas de água de 22,78%, enquanto a área de Construção/solo exposto apresentou um aumento de 5,12%, indicando uma transformação intensa da paisagem, possivelmente influenciada pela expansão da mineração e atividades de desenvolvimento. A aplicação do algoritmo KNN resultou em uma acurácia de classificação superior a 99% e um índice Kappa de 0,98, evidenciando a eficácia da abordagem metodológica adotada. Contudo, foram identificados desafios na classificação precisa entre construções/solo exposto previamente mostrado na análise das amostras pela distância de Jeffries-Matusita alcançando um valor inferior a 0,34, já a água/vegetação destaca a necessidade de uma coleta de dados mais abrangente para o treinamento semelhança entre essas assinaturas em certas condições. Os resultados enfatizam a importância de monitorar continuamente as alterações na cobertura do solo para mitigar os impactos ambientais da mineração e promover um desenvolvimento sustentável.

Palavras-chave: Mineração; Semiárido; PlanetScope; K-Nearest Neighbors.

ABSTRACT

Mining in Northeast Brazil, despite its vital role in the economy, faces the critical challenge of balancing economic growth with environmental preservation. Although mining activity generates jobs and contributes to GDP, it has been associated with accelerated deforestation, biodiversity degradation, and negative impacts on natural resources and community health. The need for sustainable and responsible practices is urgent, requiring the use of advanced technologies for monitoring and mitigating the environmental impacts of mining. The aim of this study is a space-time analysis of land use and land cover in mining areas spanning 988.92 km² in the hinterland of Pernambuco, Brazil, using high-resolution imagery provided by the PlanetScope satellite constellation. The methodology consisted of monitoring and evaluating the environmental impacts of mining activities through image classification using the K-Nearest Neighbors (KNN) algorithm and spectral indices such as Normalized Difference Vegetation Index (NDVI) and Normalized Difference Water Index (NDWI), over a temporal coverage between 2018 and 2023. As a result, a notable decrease in vegetation of 3.28% and water areas of 22.78% was identified, while Construction/Exposed Soil area showed an increase of 5.12%, indicating intensive landscape transformation possibly influenced by mining expansion and development activities. The application of the KNN algorithm resulted in a classification accuracy exceeding 99% and a Kappa index of 0.98, demonstrating the effectiveness of the adopted methodological approach. However, challenges were identified in accurately classifying between Construction/Exposed Soil previously shown in the analysis of samples by Jeffries-Matusita distance reaching a value below 0.34, while water/vegetation highlights the need for more comprehensive data collection for training due to similarity between these signatures under certain conditions. The results emphasize the importance of continuously monitoring changes in land cover to mitigate the environmental impacts of mining and promote sustainable development.

Keywords: Mining; Semiarid; PlanetScope; K-Nearest Neighbors.

SUMÁRIO

| | |
|--|-----------|
| 1 INTRODUÇÃO | 8 |
| 2 OBJETIVO | 10 |
| 2.1 Objetivo Geral | 10 |
| 2.2 Objetivo específico | 10 |
| 3 FUNDAMENTAÇÃO TEÓRICA | 11 |
| 3.1 Desmatamento na Caatinga | 11 |
| 3.2 Sensoriamento remoto em áreas de desmatamento | 13 |
| <i>3.2.1 Satélites PlanetScope</i> | <i>14</i> |
| 3.3 Classificadores de Aprendizagem de Máquina | 16 |
| 4 MATERIAIS E MÉTODOS | 17 |
| 4.1 Área de estudo | 17 |
| 4.2 Material | 19 |
| <i>4.2.1 Imagens Orbitais: PlanetScope (PS2/ PSB.SD)</i> | <i>19</i> |
| <i>4.2.2 Dados Hidrológicos</i> | <i>20</i> |
| 4.3 Métodos | 21 |
| <i>4.3.1 Fluxograma da Metodologia</i> | <i>21</i> |
| <i>4.3.2 Índices Espectrais</i> | <i>22</i> |
| <i>4.3.3 Distância de Jeffries-Matusita</i> | <i>23</i> |
| <i>4.3.4 Classificação K-Nearest Neighbors (KNN)</i> | <i>24</i> |
| <i>4.3.5 Amostras e treinamento</i> | <i>25</i> |
| <i>4.3.6 Análise de Erro de Comissão e Omissão</i> | <i>26</i> |
| <i>4.3.7 Análise Quantitativa</i> | <i>26</i> |
| 5 RESULTADOS E DISCUSSÃO | 27 |
| 5.1 Análise da distância de Jeffries-Matusita | 27 |
| 5.2 Treinamento do K-Nearest Neighbors (KNN) | 29 |

| | |
|---|-----------|
| 5.3 Análise de Erro de Comissão e Omissão..... | 31 |
| 5.4 Análise por fotointerpretação | 33 |
| 5.3 Análise quantitativa..... | 37 |
| 6 CONCLUSÃO | 39 |
| REFERÊNCIAS..... | 41 |

1 INTRODUÇÃO

A indústria da mineração tem sido fundamental para o desenvolvimento econômico e social em diversas regiões do Brasil, gerando empregos e contribuindo significativamente para o Produto Interno Bruto (PIB) nacional (IBRAM, 2020). No Nordeste brasileiro, a mineração é uma prática tradicional, com muitos estabelecimentos operando há mais de duas décadas (Souza et al., 2014). Essa região, marcada pela diversidade geológica, hospeda grandes minas, incluindo as de ouro, urânio, potássio, talco e cobre, que se destacam entre as 200 maiores do país (MINÉRIOS & MINERALES, 2013).

Contudo, essa atividade também se associa a uma série de impactos ambientais e sociais, evidentes na Região Nordeste, onde a prática mineradora é tradicional e destacada no cenário nacional (Souza et al., 2011; MINÉRIOS & MINERALES, 2013).

A aceleração do desmatamento em áreas de mineração, particularmente em regiões ricas em biodiversidade e recursos minerais, apresenta um desafio significativo para a conservação ambiental e o desenvolvimento sustentável (Rezende, 2016). No Nordeste do Brasil, as atividades de mineração têm sido identificadas como um motor crítico da degradação ambiental, afetando a qualidade do solo, os recursos hídricos, a biodiversidade e a saúde humana (Bezerra, Lira e Silva, 2020; Silva, 2018). A Agência Nacional de Mineração (ANM) destaca a contribuição da região para a produção mineral do país, onde Pernambuco é um pequeno centro de exploração de ouro (ANM, 2023; MINERAÇÃO & SUSTENTABILIDADE, 2021).

Apesar dos benefícios econômicos, os impactos socioambientais adversos associados à mineração necessitam de um entendimento matizado e uma monitoração rigorosa dessas atividades (Leite, 2020; Souza et al., 2014). Os desafios são exacerbados por operações de mineração ilegais e informais, que não só violam as regulamentações ambientais, mas também representam ameaças significativas aos ecossistemas e comunidades locais (Manzoli et al., 2021; Siqueira-Gay e Sánchez, 2021).

A necessidade de práticas de mineração responsáveis, que minimizem os impactos negativos no meio ambiente e nas comunidades locais, é evidenciada pelo

quadro legislativo brasileiro, que inclui a Política Nacional do Meio Ambiente (PNMA, Lei nº 6.938/81), o Código de Mineração (Decreto-Lei nº 227/1967) e o Decreto Federal nº 97.632/1989, que regulamenta o Plano de Recuperação de Áreas Degradadas (PRAD) para a exploração mineral.

A integração de técnicas avançadas de sensoriamento remoto e algoritmos de aprendizado de máquina, como o k-Nearest Neighbor (kNN), junto aos índices espectrais Índice de Vegetação por Diferença Normalizada (NDVI) e Índice de Água por Diferença Normalizada (NDWI), emergem como ferramentas essenciais no monitoramento da cobertura do solo em áreas de mineração, possibilitando a análise espaço-temporal com precisão e eficácia (Alba et al., 2022). Este enfoque metodológico permite identificar e quantificar as mudanças na vegetação e na umidade do solo, fornecendo dados importantes para avaliar os impactos ambientais decorrentes das atividades de mineração. O crescente desmatamento, associado à mineração, emerge como uma ameaça significativa à conservação ambiental e à sustentabilidade das regiões afetadas. O estudo de Pacheco et al. (2021) demonstraram a aplicabilidade dessa técnica no mapeamento de áreas afetadas por incêndios florestais em Portugal, empregando eficientemente o KNN para classificar imagens de satélite Landsat-8, Sentinel-2 e Terra. O estudo de Phan e Kappas (2018) demonstra que, embora o kNN possa ser ligeiramente mais sensível ao tamanho da amostra de treinamento em comparação com outros algoritmos como SVM, ele ainda apresenta uma precisão geral alta, especialmente quando o tamanho da amostra é suficiente.

O NDVI surge como uma metodologia no âmbito do sensoriamento remoto para avaliar e monitorar a vegetação, proporcionando entendimentos essenciais sobre a saúde e a densidade vegetal (Huang et al., 2021). O NDWI é um índice espectral para a análise espacial da cobertura do solo, especialmente em estudos de áreas de mineração, onde a gestão dos recursos hídricos é fundamental (Mashala et al., 2023).

As técnicas avançadas de sensoriamento remoto têm sido fundamentais no estudo de mudanças climáticas e no funcionamento dos ecossistemas amazônicos, integrando informações sobre diversos processos físicos e biológicos (Valeriano et al., 2012). Essencial também para o monitoramento ambiental, o sensoriamento remoto fornece dados confiáveis para a gestão e conservação da biodiversidade em diferentes biomas, como evidenciado pelo SAD Caatinga e o PRODES na Amazônia

(INPE, 2024). No contexto da legislação brasileira, que enfatiza a importância do planejamento cuidadoso e da adoção de tecnologias sustentáveis, este trabalho contribui para o corpo de literatura que busca soluções sustentáveis, ressaltando a importância de práticas mineradoras responsáveis (Saito et al., 2011).

Este estudo se propõe a preencher uma lacuna na literatura científica ao monitorar e analisar o desmatamento em áreas de mineração aurífera no sertão de Pernambuco, uma região até então pouco explorada neste contexto. A motivação para esta pesquisa surgiu com o anúncio de investimentos da mineradora Trilha Gold Capital (TGC) no projeto Serrita-Cedro, que teve início em 1995 busca avaliar o potencial de mineralizações auríferas entre as cidades de Serrita e Cedro. Utilizando imagens de alta resolução espacial dos CubeSats da constelação PlanetScope, este trabalho adota aplicar técnicas de sensoriamento remoto e algoritmos de aprendizado de máquina para uma análise espaço-temporal detalhada do desmatamento, focando em um cenário comparativo 'antes e depois', ressaltando a importância de práticas mineradoras responsáveis e o papel do sensoriamento remoto como ferramenta para a sustentabilidade ambiental.

2 OBJETIVO

2.1 Objetivo Geral

O objetivo deste trabalho é avaliar as mudanças de uso e cobertura do solo em área de mineração no sertão de Pernambuco, utilizando imagens de alta resolução espacial derivadas do satélite PlanetScope, numa cobertura temporal de 2018 a 2023.

2.2 Objetivo específico

- Identificar mudanças de uso e cobertura do solo em áreas de mineração no sertão pernambucano por meio de uma análise espaço temporal de uma série de imagens de alta resolução espacial do satélite PlanetScope, entre 2018 e 2023.

- Implementar o classificador KNN para a classificação de imagens, com o objetivo de identificar e quantificar alterações espaciais das classes: vegetação, água, solo exposto e construções.
- Integrar dados espectrais normalizados como o NDVI e NDWI, com ferramentas para análise espaço temporal de uso e cobertura do solo, identificando padrões espectrais dos alvos.
- Realizar uma análise estatística de acurácia global, índice kappa, omissão e comissão do modelo KNN que se baseia em técnicas de validação cruzada, proporcionando uma quantificação rigorosa da qualidade da classificação obtida e avaliando a generalização do modelo para novos dados.

3 FUNDAMENTAÇÃO TEÓRICA

3.1 Desmatamento na Caatinga

A Caatinga, um bioma exclusivamente brasileiro, é caracterizada por sua vegetação xerófila adaptada ao clima semiárido. Este ecossistema é marcado por temperaturas médias elevadas, entre 25° e 30°C, e baixa precipitação, variando entre 400 e 1200 mm anuais. Apesar das condições adversas, a Caatinga abriga uma biodiversidade rica e peculiar, com uma flora e fauna que desenvolveram estratégias únicas para sobreviver em um ambiente de recursos limitados. A região semiárida, onde se localiza a Caatinga, é frequentemente associada a desafios como secas severas (Tabarelli et al., 2018). No entanto, a Caatinga tem enfrentado desafios significativos devido a processos de degradação ambiental, que incluem o desmatamento e a desertificação. A recuperação dessas áreas degradadas é essencial para preservar a biodiversidade e garantir a continuidade dos serviços ecossistêmicos. Estudos sobre métodos e técnicas de recuperação são fundamentais para reverter os danos causados e promover a resiliência do bioma frente às pressões antrópicas (Gomes e Silva, 2023).

De acordo com o relatório MapBiomas (2022), o bioma Caatinga registrou um desmatamento de 140.637 hectares, representando 6,8% do desmatamento total no

Brasil. Esse número reflete um crescimento de 22,2% em comparação com o ano anterior, evidenciando uma pressão crescente sobre esse ecossistema único. A introdução do Sistema de Alerta de Desmatamento da Caatinga (SAD Caatinga), criado especificamente para monitorar esse bioma, permitiu um avanço significativo na precisão e adaptação à detecção de desmatamentos na Caatinga. Esse sistema considerou as características únicas do bioma, como a vegetação xerófila e a marcante sazonalidade. O resultado foi um aumento substancial no número de alertas de desmatamento validados, demonstrando a eficácia dessa ferramenta para o monitoramento temporal e espacial do desmatamento e indicando uma pressão crescente sobre a Caatinga, potencialmente influenciada por atividades de mineração e garimpo.

O relatório MapBiomas (2022), destaca a importância ecológica e socioeconômica da Caatinga, um bioma exclusivamente brasileiro, que enfrenta desafios de conservação. O aumento do desmatamento, inclusive em áreas de mineração e garimpo, ameaça a biodiversidade desse bioma e os serviços ecossistêmicos essenciais para as comunidades locais. Além disso, ressalta a necessidade de ações concretas para combater o desmatamento ilegal na Caatinga. Apesar de grande parte do desmatamento não possuir autorização legal, políticas públicas e esforços de fiscalização robustos são vitais para proteger o bioma de atividades predatórias, incluindo a mineração e garimpo irregulares.

O estudo realizado por Albuquerque, Lombardi Neto e Srinivasan (2001) na caatinga da região de Sumé, Paraíba, Brasil, fornece evidências significativas dos efeitos danosos do desmatamento nessas áreas. A pesquisa demonstrou que o desmatamento da caatinga levou a um aumento drástico nas perdas de solo e água em parcelas desmatadas, as perdas de solo alcançaram 477 e 617 vezes a mais que do que a caatingas nativa, as parcelas desmatadas perdem aproximadamente 10 vezes mais água por ano do que parcelas com caatinga nativa. Tais achados ressaltam a importância da vegetação nativa na prevenção da erosão e na conservação dos recursos hídricos. A caatinga, ao reduzir o impacto das gotas de chuva sobre o solo e aumentar a infiltração de água, desempenha um papel crítico na manutenção do equilíbrio ecológico desses ecossistemas semiáridos.

Esses resultados corroboram estudos anteriores que também apontaram para o aumento da erosão e das perdas de água após o desmatamento (Ramos e Marinho,

1981; Sousa et al., 1993). Eles reforçam a necessidade de práticas de manejo do solo e da vegetação que considerem a sustentabilidade e a conservação da caatinga, especialmente em áreas sujeitas a atividades de mineração e garimpo, que são particularmente propensas à degradação ambiental.

A análise temporal das perdas de solo e água permite uma compreensão aprofundada dos efeitos do desmatamento ao longo do tempo, destacando a importância de longo prazo da preservação da vegetação nativa para a sustentabilidade ambiental. Conforme apresentado por Albuquerque, Lombardi Neto e Srinivasan (2001), é fundamental que políticas públicas e práticas de manejo do solo e da vegetação sejam orientadas para minimizar os impactos ambientais do desmatamento em áreas de mineração e garimpo. Promover a recuperação e a conservação da vegetação nativa surge como medidas essenciais para a prevenção da erosão e a conservação dos recursos hídricos. Essas constatações também sublinham a situação preocupante do desmatamento na Caatinga, reforçando a necessidade de ferramentas de monitoramento específicas, como o SAD Caatinga, para análises detalhadas das mudanças na cobertura do solo. Dessa forma, torna-se urgente a implementação de políticas de conservação e fiscalização para mitigar os impactos do desmatamento, especialmente em áreas vulneráveis à mineração, conforme destacado pelo MapBiomias (2022).

3.2 Sensoriamento remoto em áreas de desmatamento

A introdução do Sistema de Alerta de Desmatamento da Caatinga (SAD Caatinga) representa um avanço significativo na utilização do sensoriamento remoto para a monitoração do desmatamento neste bioma específico. Semelhante ao que ocorre com o PRODES na Amazônia, o SAD Caatinga utiliza dados de sensoriamento remoto para identificar e quantificar áreas de desmatamento em tempo quase real, permitindo uma resposta rápida às atividades de degradação ambiental (INPE, 2024). No estudo de Adami et al. (2017), é possível ver a eficácia na estimativa da acurácia do mapeamento do desmatamento no estado do Mato Grosso, enfatizando a capacidade desta tecnologia em fornecer dados confiáveis para a gestão ambiental e monitoramento do desmatamento em larga escala. Essa confiabilidade é fundamental para a aplicação do sensoriamento remoto em diferentes biomas, incluindo a

Caatinga, onde o desmatamento muitas vezes ocorre de maneira mais fragmentada e menos intensiva do que na Amazônia

Saito et al. (2011) discutem os efeitos da mudança de escala em padrões de desmatamento na Amazônia, uma análise relevante para a Caatinga, onde o sensoriamento remoto pode ajudar a identificar padrões específicos de desmatamento e degradação. A capacidade de analisar dados em diferentes escalas é crucial para entender a dinâmica do desmatamento e implementar estratégias eficazes de manejo e conservação.

Valeriano et al. (2012) ressaltam a importância do monitoramento do desmatamento como parte das estratégias para sustentabilidade populacional e ambiental, um princípio aplicável à Caatinga, onde a pressão sobre os recursos naturais é intensificada pela seca e pelas atividades humanas. A utilização do sensoriamento remoto para monitorar o desmatamento neste bioma é essencial para promover o uso sustentável dos recursos e preservar a biodiversidade.

O sucesso e a eficácia do SAD Caatinga, assim como do PRODES na Amazônia, destacam a importância do sensoriamento remoto como uma ferramenta indispensável no monitoramento ambiental. Eles demonstram como a tecnologia pode ser adaptada para atender às necessidades específicas de diferentes biomas, proporcionando uma base sólida para a tomada de decisões informadas no manejo dos recursos naturais e na conservação da biodiversidade (Adami et al., 2017; INPE, 2024; Saito et al., 2011; Valeriano et al., 2012).

3.2.1 Satélites PlanetScope

A constelação PlanetScope, sob gestão da Planet, compreende cerca de 130 satélites, com órbitas relativamente baixa entre 475km e 525km de altitude, a órbita é síncrona ao sol e de inclinação 98° tornando uma órbita heliossíncronas, o ciclo de revisita cruzam o equador aproximadamente 9:30h e 11:30h. Esta rede tem a capacidade única de capturar, diariamente, imagens de todo o planeta, alcançando uma cobertura impressionante de até 200 milhões de quilômetros quadrados. As imagens geradas por essa constelação apresentam uma resolução de aproximadamente 3 metros por pixel, evidenciando detalhes notáveis da superfície terrestre (PlanetScope, 2024).

A PlanetScope (2024) destaca que sua constelação é equipada com três tipos de instrumentos essenciais:

- O Dove Classic (PS2), que registra canais vermelhos, verdes, azuis e infravermelho próximo, gerando cenas com dimensões de cerca de 25,0 x 11,5 km². Essas imagens foram disponibilizadas desde julho de 2014 até 29 de abril de 2022.
- O Dove-R (PS2.SD), semelhante ao PS2 em funcionalidade, mas com tecnologia de sensor aprimorada. Este instrumento captura os mesmos canais, cobrindo áreas de cena de aproximadamente 25,0 x 23,0 km², com imagens disponíveis de março de 2019 a 22 de abril de 2022.
- O SuperDove (PSB.SD), que amplia as capacidades de captura para incluir canais como vermelho, verde, azul, infravermelho próximo, borda vermelha, verde I, azul costeiro e canal amarelo. As cenas geradas por este instrumento abrangem cerca de 32,5 x 19,6 km², com disponibilidade que vai de meados de março de 2020 até o momento atual.

Os produtos de imagem do PlanetScope, disponíveis desde 2014, são oferecidos em diversos formatos para atender a uma ampla gama de necessidades analíticas e visuais:

- Ativos Analíticos Básicos (basic_analytic): imagens multiespectrais não ortorretificadas e calibradas, ajustadas para eliminar artefatos de sensor e convertidas para a radiância no topo da atmosfera.
- Ativos Analíticos (analytic): imagens multiespectrais ortorretificadas e calibradas, livres de artefatos de sensor e distorções de terreno, também convertidas para a radiância no topo da atmosfera.
- Ativos Visuais (visual): imagens RGB ortorretificadas e corrigidas de cor, otimizadas para a percepção humana, retratando a aparência real se vistas da perspectiva do satélite.
- Ativos de Refletância de Superfície (analytic_sr): imagens ortorretificadas e corrigidas radiometricamente, projetadas para oferecer consistência em variadas condições atmosféricas locais e minimizar incertezas na resposta espectral ao longo do tempo e em diferentes locais.

Para este trabalho foi utilizado o sensor PSB.SD para as imagens de 2023 e sensor PS2 para as imagens de 2018

Tabela 1 – Especificações técnicas dos Sensores do PlanetScope

| Número da Banda | Faixa Espectral (PS2) | Faixa Espectral (PSB.SD) | Tamanho do Pixel |
|-----------------|------------------------|--------------------------|------------------|
| Banda 1 | Azul: 455 - 515 nm | Azul: 465 - 515 nm | 3 m |
| Banda 2 | Verde: 500 - 590 nm | Verde: 547 - 585 nm | |
| Banda 3 | Vermelho: 590 - 670 nm | Vermelho: 650 - 680 nm | |
| Banda 4 | NIR: 780 - 860 nm | NIR: 845 - 885 nm | |

Fonte: PlanetScope – Instrumentos do PlanetScope

3.3 Classificadores de Aprendizagem de Máquina

Com o avanço da ciência da computação, técnicas de Inteligência Artificial e aprendizado de máquina ganharam notoriedade, especialmente na análise de dados de sensoriamento remoto (Fernandes, 2003; Alpaydin, 2016). O uso dessas técnicas permite simular habilidades humanas, otimizando a classificação e monitoramento do uso da terra e cobertura vegetal. O K-Nearest Neighbors (KNN), um algoritmo fundamental neste domínio, exemplifica a aplicação eficaz na detecção de mudanças no desmatamento, graças à sua simplicidade e eficiência na classificação de dados complexos (Alba et al., 2022).

Este classificador identifica a classe de um elemento desconhecido buscando os K elementos mais próximos no conjunto de treinamento, utilizando métricas de distância como a Euclidiana e a Manhattan para determinar a proximidade (Capacia et al., 2023). Sua eficácia foi demonstrada em variadas aplicações, classificação de plantas daninhas em contextos agrícolas quanto no mapeamento espaço-temporal de uso da terra em regiões extensas, como demonstrado nos estudos sobre a região do reservatório de Tucuruí, PA, até o mapeamento de uso da terra em regiões extensas como a Amazônia, onde a combinação de sensoriamento remoto e aprendizado de máquina forneceu percepções valiosas sobre as mudanças na cobertura do solo (Vasconcelos e Novo, 2004; Capacia et al., 2023).

A seleção do número K é crítica, pois um valor muito baixo pode levar a uma alta sensibilidade ao ruído dos dados, enquanto um valor muito alto pode suavizar as fronteiras de decisão do modelo, afetando sua precisão (Medeiros et al., 2019). A validação cruzada é uma técnica empregada para avaliar a generalização do modelo KNN e consiste em dividir o conjunto de dados em várias partes, ou "dobras". O modelo é então treinado em todas as dobras, exceto uma que é utilizada para teste. Esse processo é repetido para que cada dobra seja usada como conjunto de teste uma vez, permitindo uma avaliação robusta do desempenho do modelo. A validação cruzada não apenas ajuda a evitar o sobreajuste, mas também possibilita a seleção de um valor ótimo para K baseando-se no desempenho médio do modelo através das diferentes dobras (Piovesan, Araújo e Dias, 2009).

Esses métodos, quando combinados, tornam o KNN com validação cruzada particularmente eficaz para tarefas de classificação em uma ampla gama de aplicações, desde a análise de patologias de coluna vertebral (Medeiros et al., 2019) até a otimização de modelos agrônômicos (Piovesan, Araújo e Dias, 2009), demonstrando sua versatilidade e capacidade de adaptação a diferentes tipos de dados e contextos de análise.

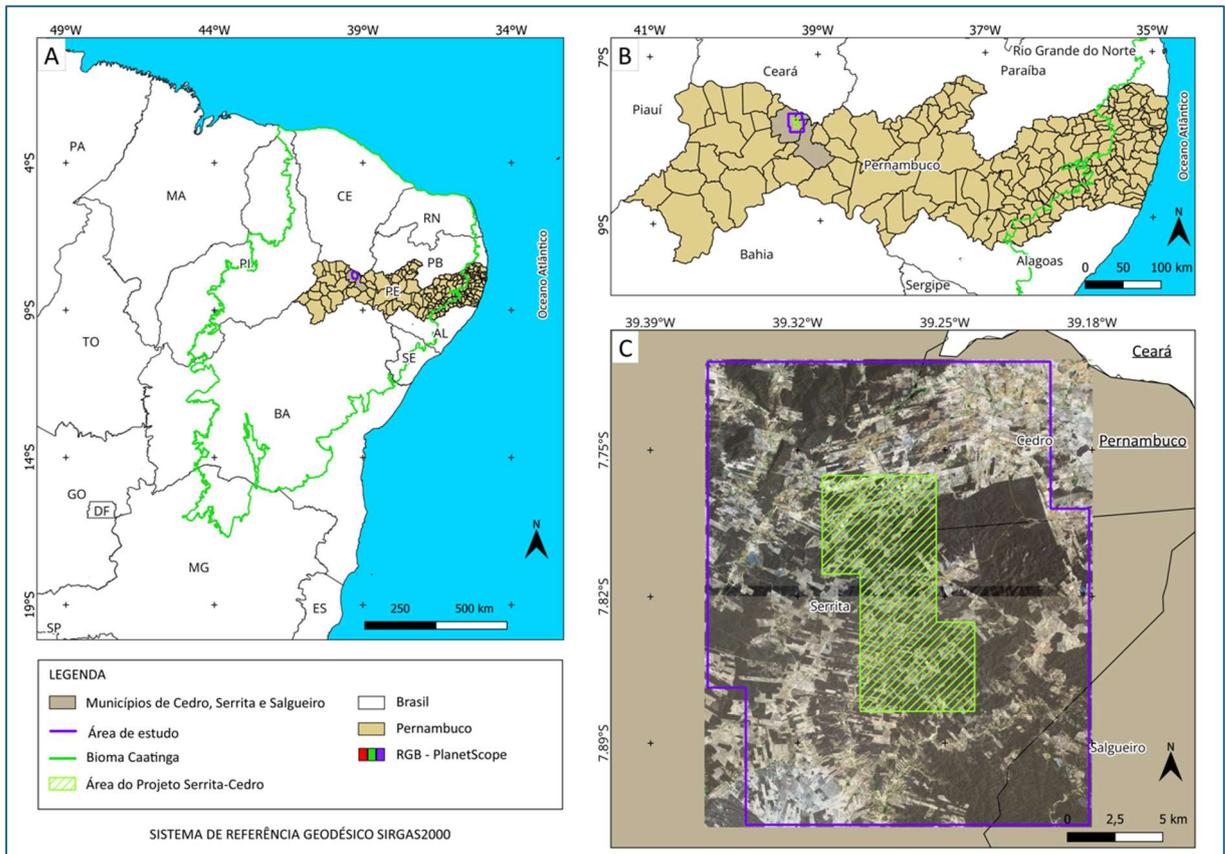
Em síntese, o uso de classificadores de aprendizagem de máquina como o KNN em conjunto com técnicas de validação cruzada, representa uma abordagem robusta para a análise espaço-temporal do desmatamento, oferecendo uma alternativa precisa e eficiente para o mapeamento e monitoramento das mudanças na cobertura do solo.

4 MATERIAIS E MÉTODOS

4.1 Área de estudo

A região de estudo compreende partes das cidades de Serrita, Cedro e Salgueiro, todas situadas no estado de Pernambuco, especificamente na mesorregião do Sertão Pernambucano, no semiárido nordestino. A região investigada é a região do Projeto Serrita-Cedro (Figura 1) e de investimento da mineradora Trilha Gold Capital (TGC) na região deste projeto, gerando uma oportunidade de realizar uma avaliação espaço-temporal da cobertura do solo.

Figura 1 – Localização da área de Estudo



Fonte: O Autor (2024)

O Projeto Serrita-Cedro, parte do Programa Nacional de Estudos dos Distritos Mineiros e conduzido pelo DNPM - Departamento Nacional da Produção Mineral, teve como foco a investigação de mineralizações auríferas numa área de 580 km² entre as cidades de Serrita e Cedro, em Pernambuco. O projeto abrangeu levantamentos geoquímicos, geológicos e geofísicos, com o apoio financeiro e logístico da Delegacia do MME em Pernambuco (DEPARTAMENTO NACIONAL DA PRODUÇÃO MINERAL, 1995). Para demarcar a área de estudo, utilizou-se um buffer de aproximadamente 6 km em todos os lados da região definida pelo projeto Serrita-Cedro. Esse buffer foi estabelecido com o intuito de não ultrapassar as fronteiras com o estado do Ceará, permitindo uma análise abrangente das regiões adjacentes à área do projeto (Figura 1).

Esta região identifica-se por um clima semiárido e quente, com distinção entre uma estação chuvosa de fevereiro a maio e uma estação seca, acompanhadas por uma precipitação média anual de aproximadamente 500 mm e temperaturas que

variam entre 20°C e 40°C. A região é dominada pela caatinga xerófito, evidenciando uma vegetação adaptada às condições climáticas, com presença significativa de bromeliáceas e cactáceas, além de árvores de médio porte nas proximidades de corpos d'água. A hidrografia é caracterizada por riachos intermitentes com um padrão de drenagem dendrítico, e o relevo, predominantemente colinoso, apresenta altitudes médias em torno de 480 metros, atingindo até 756 metros no batólito granodiorítico do Baixio do Fumo (DEPARTAMENTO NACIONAL DA PRODUÇÃO MINERAL, 1995).

4.2 Material

4.2.1 Imagens Orbitais: PlanetScope (PS2/ PSB.SD)

Foram utilizadas seis imagens com refletância da superfície, ortorretificadas e sem nebulosidade, também não foram aplicados métodos de normalização radiométrica (Tabela 2).

Tabela 2 – Imagens utilizadas

| Imagem ID | Data de Aquisição | Resolução Espacial | Resolução Radiométrica | Local de Aquisição | Sensor |
|-------------------------|-------------------|--------------------|------------------------|--|--------|
| 20231031_120836_24_24a1 | 31/10/23 | 3 m | 16 bits | -39,426°W / -8,017°S -39,083°W / -7,775°S | PSB.SD |
| 20231031_120836_96_24a1 | 31/10/23 | 3 m | 16 bits | -39,397°W / -7,873°S -39,055°W / -7,631°S | PSB.SD |
| 20181020_122327_0e0e | 20/10/18 | 3 m | 16 bits | -39,370°W / -7,780°S -39,130°W / -7,662°S | PS2 |
| 20181020_122328_0e0e | 20/10/18 | 3 m | 16 bits | -39,984°W / -7,842°S -39,144°W / -7,724°S | PS2 |
| 20181020_122329_0e0e | 20/10/18 | 3 m | 16 bits | -39,398°W / -7,904°S -39,157°W / -7,786°S | PS2 |
| 20181020_122330_0e0e | 20/10/18 | 3 m | 16 bits | -39,410°W / -7,968°S -39,170°W / -7,850°S | PS2 |

Fonte: PlanetScope (2024).

4.2.2 Dados Hidrológicos

Segundo o estudo conduzido por Trovão et al. (2007), a vegetação da Caatinga demonstrou sensibilidade à disponibilidade de água da chuva. Portanto, para uma análise precisa da cobertura vegetal, estamos considerando os dados hidrológicos dos anos de aquisição das imagens. Esses dados pluviométricos foram obtidos junto à Agência Pernambucana de Águas e Clima – APAC (tabelas 3 e 4).

Tabela 3 – Monitoramento Pluviométrico (mm) para os anos de 2018 (APAC)

| Posto | Janeiro | Fevereiro | Março | Abril | Maio | Junho | Julho | Agosto | Setembro | Outubro | Novembro | Dezembro |
|-----------------------------|---------|-----------|-------|-------|------|-------|-------|--------|----------|---------|----------|----------|
| Cedro | 29,5 | 309 | 18 | 243 | 20 | - | - | - | - | 69,9 | 4,5 | 125 |
| Salgueiro | 43,1 | 239,6 | 27,6 | 111 | 3,8 | 18,6 | - | - | - | 32,6 | - | 242,7 |
| Salgueiro (PCD) | 40,2 | 323,4 | 21 | 110 | 10,4 | 9,4 | 0,6 | 0,8 | - | 19,2 | - | 221 |
| Serrita | 5 | 229,3 | 38 | 125 | 10 | - | - | - | - | 47 | 2 | 154 |
| Serrita (Cartório) | - | - | - | - | - | - | - | - | - | - | - | - |
| Serrita (Santa Rosa) | 34,6 | 283,1 | 40,3 | - | - | - | - | - | - | - | - | - |

Fonte: Agência Pernambucana de Águas e Clima - APAC (2023).

Tabela 4 – Monitoramento Pluviométrico (mm) para os anos de 2023 (APAC)

| Posto | Janeiro | Fevereiro | Março | Abril | Maior | Junho | Julho | Agosto | Setembro | Outubro | Novembro | Dezembro |
|-----------------------------|---------|-----------|-------|-------|-------|-------|-------|--------|----------|---------|----------|----------|
| Cedro | 114 | 98 | 217 | 55 | 79 | 35 | 26 | - | - | - | 60 | 49 |
| Salgueiro | 40,1 | 34,5 | 167,2 | 35,6 | 42,3 | 22,5 | 8,8 | 0,9 | - | 2 | 18,8 | 57,7 |
| Salgueiro (PCD) | 30 | 23,4 | 129,4 | 46,6 | 35,6 | 23,6 | 10,8 | 1,2 | 2 | - | 31,6 | 35 |
| Serrita | 65 | 50 | 160 | 55 | 56 | 19,5 | 9 | - | - | - | 13 | 29 |
| Serrita (Cartório) | - | - | - | - | - | - | - | - | - | - | - | - |
| Serrita (Santa Rosa) | - | - | - | - | - | - | - | - | - | - | - | - |

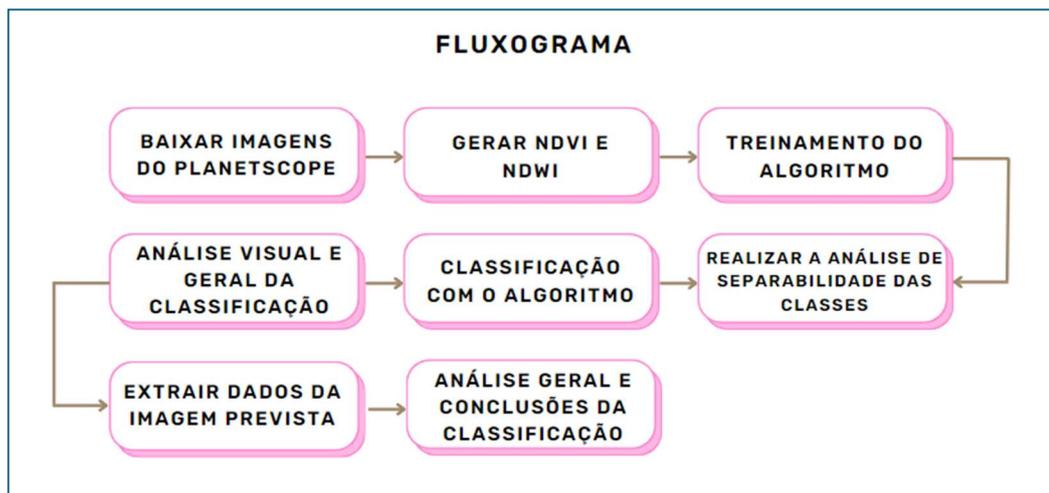
Fonte: Agência Pernambucana de Águas e Clima – APAC

4.3 Métodos

4.3.1 Fluxograma da Metodologia

O fluxograma metodológico deste trabalho delinea, de forma sequencial e detalhada, o processo empregado para efetuar a classificação da cobertura do solo utilizando o algoritmo K-Nearest Neighbors (KNN) (ver Figura 2).

Figura 2 – Fluxograma da Metodologia



Fonte: O Autor (2024)

4.3.2 Índices Espectrais

Após o pré-processamento das imagens do PlanetScope, os índices espectrais NDVI e NDWI foram calculados de acordo com suas respectivas operações e seus resultados que foram analisados por meio da análise da distância de Jeffries-Matusita (Jeffries e Matusita, 1967).

a) NDVI

O Índice de Vegetação por Diferença Normalizada (NDVI) serve como um indicativo eficaz da presença de biomassa vegetal ativa na fotossíntese ou, de outra forma, da vitalidade da vegetação. Desenvolvido por Rouse et al., em 1973, o NDVI oscila entre -1 e 1 e é obtido pela equação 1:

$$NDVI = \frac{(NIR - Red)}{(NIR + Red)} \quad (1)$$

Onde,

NIR: Reflectância na banda do infravermelho próximo;

Red: Reflectância na banda do vermelho visível.

Esse índice facilita a distinção entre áreas vegetadas e outros tipos de cobertura terrestre, como as artificiais, e permite avaliar a condição geral da vegetação (EOS DATA ANALYTICS, 2020). Além disso, o NDVI viabiliza a demarcação e observação das zonas de vegetação, bem como o reconhecimento de eventuais anomalias ou mudanças na área observada. Esse indicador é útil para o acompanhamento de variações sazonais na vegetação, embora sua eficácia esteja ligada às características de reflexão da superfície (Teodoro e Amaral, 2019).

b) NDWI

O Índice de Água por Diferença Normalizada (NDWI), utilizando as bandas do verde e do infravermelho próximo, é um indicador eficiente para monitorar a presença e distribuição de água em superfícies terrestres e aquáticas. Este índice é

particularmente eficaz para identificar corpos d'água e avaliar a umidade na vegetação, contribuindo para estudos de irrigação e gestão de recursos hídricos (McFeeters, 1996). O NDWI também auxilia na detecção de áreas inundadas e na análise da saturação de água no solo, sendo uma ferramenta para o planejamento ambiental e agrícola (Gao, 1996). A formulação do NDWI varia entre -1 e 1, sendo calculada pela equação 2:

$$NDVI = \frac{(Green-NIR)}{(Green+NIR)} \quad (2)$$

Onde,

Green: Reflectância na banda do verde visível;

NIR: Reflectância na banda do infravermelho próximo.

4.3.3 Distância de Jeffries-Matusita

A distância de Jeffries-Matusita (JMD) é uma métrica estatística utilizada para avaliar a separabilidade entre classes em dados de sensoriamento remoto. A JMD é particularmente útil para quantificar a distinção entre distribuições de probabilidade de classes, o que é crucial na classificação de imagens multiespectrais (Richards e Jia, 1999). A JMD é baseada na distância de Bhattacharyya, que mede a sobreposição entre duas distribuições estatísticas, e é transformada para o intervalo [0, 2] (Jeffries e Matusita, 1967). A fórmula para calcular a JMD entre duas classes é dada pela equação 3:

$$JMD = 2\sqrt{1 - e^{-B}} \quad (3)$$

Onde,

(B) é o índice (medida) de Bhattacharyya que quantifica a sobreposição entre duas distribuições probabilísticas. Essa medida é baseada nas médias e variâncias das características de cada classe dada pela equação 4.

$$B = \frac{1}{8}(\mu_1 - \mu_2)^T \Sigma^{-1}(\mu_1 - \mu_2) + \frac{1}{2} \ln \left(\frac{|\Sigma|}{\sqrt{|\Sigma_1||\Sigma_2|}} \right) \quad (4)$$

Onde,

μ representa a média, Σ a matriz de covariância média, e $|\Sigma|$ o determinante da matriz de covariância para cada classe.

Valores mais altos de JMD indicam maior separabilidade entre as classes, enquanto valores mais baixos sugerem uma sobreposição significativa, dificultando a distinção entre elas (Richards e Jia, 1999).

4.3.4 Classificação K-Nearest Neighbors (KNN)

O algoritmo de Classificação K-Nearest Neighbors (KNN) é um método simples, porém poderoso, utilizado para classificação e regressão. Introduzido por Cover e Hart (1967), o KNN opera sob o princípio de que amostras semelhantes tendem a estar próximas umas das outras no espaço de características, como destacam James et al. (2013). Esse algoritmo identifica os k vizinhos mais próximos de uma amostra desconhecida dentro do conjunto de treinamento, atribuindo à amostra a classe mais comum (ou a média das respostas) entre esses vizinhos.

A distância entre as amostras, fundamental para o funcionamento do KNN, pode ser calculada de várias maneiras. A mais comum é a distância Euclidiana, dada pela equação 5:

$$d(p, q) = \sqrt{\sum_{i=1}^m (p_i - q_i)^2} \quad (5)$$

Essa fórmula calcula a distância entre duas amostras, p e q , cada uma com m características, evidenciando como o espaço multidimensional é navegado pelo algoritmo.

A escolha do valor de k é um aspecto crítico que influencia diretamente o desempenho do algoritmo. Um k muito pequeno pode tornar o modelo excessivamente sensível ao ruído dos dados, enquanto um k muito grande pode

fazê-lo ignorar as nuances das distribuições de classe. Recomenda-se experimentar com vários valores de k e possivelmente utilizar métodos de validação, como a validação cruzada, para determinar o k ótimo.

A validação cruzada, conforme descrito por Kohavi (1995), é uma técnica utilizada para avaliar a capacidade de generalização de um modelo estatístico e para ajustar os hiperparâmetros, como o k no KNN. O método mais comum de validação cruzada é o k-fold, que divide o conjunto de dados em k subconjuntos. O modelo é treinado k vezes, cada vez utilizando $k-1$ subconjuntos para treinamento e o subconjunto restante para teste. O desempenho do modelo é então avaliado pela média dos resultados obtidos em cada uma das k iterações.

O KNN, juntamente com a validação cruzada, oferece uma abordagem robusta para a classificação de dados, aproveitando a simplicidade do algoritmo e a eficácia da validação cruzada para ajustar os hiperparâmetros e avaliar a capacidade de generalização do modelo para novos dados.

4.3.5 Amostras e treinamento

As amostras de treinamento foram retiradas de ambas as imagens de 2018 e 2023 gerando dois conjuntos de treinamento, cada conjunto representando 4 classes de interesse; Água, Construções, Vegetação e Solo Exposto. Para este processo inicial foi utilizado o software QGIS, versão 3.34.2-Prizren (QGIS Development Team, 2023), onde a preparação do treinamento envolveu a coleta de vários polígonos amostrais para cada classe. A seleção foi feita por meio da análise manual das imagens compostas (RGB). Após a interpretação visual, as máscaras foram salvas no formato shapefile, permitindo que fossem facilmente acessadas e processadas na etapa subsequente.

O treinamento foi realizado utilizando a linguagem R através do software RStudio (R CORE TEAM, 2016), a partir dos dois conjuntos de amostras das 4 classes, utilizou a validação cruzada, onde o conjunto de dados foi dividido aleatoriamente em 10 subconjuntos (ou "folds"), e o modelo foi treinado 10 vezes,

cada vez usando 9 dos subconjuntos para treinamento e o subconjunto restante para teste, para cada conjunto da amostra.

4.3.6 Análise de Erro de Comissão e Omissão

A utilização das métricas de Erro de Comissão e Omissão é fundamental para a avaliação do modelo de erro em sistemas de sensoriamento remoto, permitindo uma análise mais detalhada e precisa da capacidade do modelo em identificar corretamente os casos positivos e não classificar incorretamente os positivos. A métrica de Erro de Comissão é calculada pela proporção de falsos positivos em relação ao total de eventos classificados como positivos, enquanto a métrica de Erro de Omissão é calculada pela proporção de falsos negativos em relação ao total de eventos positivos reais.

Erro de Omissão é representado pela equação 6:

$$EO = \frac{\text{Falso Negativos (FN)}}{\text{Verdadeiros Positivos (TP)} + \text{Falsos Negativos (FN)}} \quad (6)$$

Erro de Comissão é representado pela equação 7:

$$EC = \frac{\text{Falsos Positivos (FP)}}{\text{Verdadeiros Positivos (TP)} + \text{Falsos Positivos (FP)}} \quad (7)$$

Essas métricas são importantes para monitorar a eficácia na previsão da ocorrência de eventos e são amplamente utilizadas na literatura de sensoriamento remoto, conforme destacado por Story (1986) e Sano et al. (2009)

4.3.7 Análise Quantitativa

Após o processo de classificação das imagens, cada pixel foi atribuído a uma das quatro classes predefinidas, onde o valor 1 corresponde à água, 2 a construções, 3 a solo exposto e 4 a vegetação. A análise quantitativa foi realizada somando os pixels de cada classe para os anos analisados. As imagens do satélite PlanetScope

possuem resolução espacial de 3x3 metros, o que implica uma área de 9 m² por pixel. Para facilitar a análise quantitativa, a área total de cada classe foi convertida de m² para km², o que permitiu uma comparação mais acessível das áreas classificadas entre os anos de 2018 e 2023.

5 RESULTADOS E DISCUSSÃO

5.1 Análise da distância de Jeffries-Matusita

A tabela 5 de separabilidade pela distância Jeffries-Matusita para o ano de 2023 oferece valores onde pode-se avaliar a separabilidade para todas as classes em combinações de duas em duas classes a nível de pixel puro entre os índices espectrais e bandas espectrais.

Para a Água x Vegetação (ano 2023): A maioria dos valores da JMD são maiores que 1 especialmente NDWI (1,996), indicando uma boa separabilidade entre Água e Vegetação. Isso sugere que a característica espectral NDWI é eficaz para distinguir entre estas duas classes.

Para a Construções x Vegetação (ano 2023): A separabilidade também boa maior que 1 para todas as variáveis, com valores de JMD próximos a 2 para a banda do vermelho Red (1,900), banda do infravermelho-próximo Nir (1,815), NDVI (1,816) e NDWI (1,178). Isso demonstra que tanto as bandas espectrais quanto os índices de vegetação são eficientes para discriminar Vegetação de áreas urbanizadas ou Construções.

Para o Solo Exposto x Vegetação (ano 2023): A distância de JMD entre essas classes é próximo de 2 para todas as variáveis analisadas, indicando que as características são eficazes na diferenciação entre Solo Exposto e Vegetação. A separabilidade é maior que 1,823 em todos os casos.

Tabela 5 – Distância de Jeffries-Matusita para cada índice e bandas espectrais para a imagem de 2023

| Classe 1 | Classe 2 | Blue | Green | Red | Nir | NDVI | NDWI |
|--------------|--------------|-------|-------|-------|-------|-------|-------|
| Água | Construções | 1,478 | 1,545 | 1,987 | 2,000 | 1,276 | 1,909 |
| Água | Solo Exposto | 1,911 | 1,880 | 1,991 | 1,999 | 1,591 | 1,957 |
| Construções | Solo Exposto | 0,154 | 0,129 | 0,053 | 0,262 | 0,213 | 0,245 |
| Água | Vegetação | 0,644 | 0,060 | 1,408 | 1,980 | 1,948 | 1,996 |
| Construções | Vegetação | 1,324 | 1,622 | 1,900 | 1,815 | 1,816 | 1,178 |
| Solo Exposto | Vegetação | 1,824 | 1,910 | 1,936 | 1,839 | 1,867 | 1,840 |

Fonte: O autor (2024).

A tabela 6 de separabilidade pela distância Jeffries-Matusita para o ano de 2018 também oferece percepção sobre quais características espectrais ou índices são mais eficazes para distinguir entre as classes a nível de pixel puro.

Para a Água x Vegetação (ano 2018): Os valores de JMD para NDVI (1,827), NDWI (1,953) e banda do infravermelho-próximo Nir (1,980) são notavelmente altos, indicando que esses índices são particularmente úteis para separar Água de Vegetação.

Para a Construções x Vegetação (ano 2018): Embora todos os valores de JMD mostrem uma boa separabilidade, mas, o índice de NDWI (0,904) foi notavelmente menor que 1, indicando que a distinção entre Construções e Vegetação pode ser menos consistente em comparação com a separação entre Água e Vegetação.

Para o Solo Exposto x Vegetação (ano 2018): Os valores de JMD são elevados, especialmente para Vermelho Red (1,649), indicando que esta característica é eficiente para separar Solo Exposto de Vegetação.

Tabela 6 – Distância de Jeffries-Matusita para cada índice e bandas espectrais para a imagem de 2018

| Classe 1 | Classe 2 | Blue | Green | Red | Nir | NDVI | NDWI |
|--------------|--------------|-------|-------|-------|-------|-------|-------|
| Água | Construções | 0,819 | 0,719 | 1,187 | 1,993 | 1,144 | 1,435 |
| Água | Solo Exposto | 0,983 | 0,819 | 1,022 | 1,992 | 1,452 | 1,770 |
| Construções | Solo Exposto | 0,165 | 0,108 | 0,116 | 0,024 | 0,273 | 0,330 |
| Água | Vegetação | 0,408 | 0,570 | 0,528 | 1,980 | 1,827 | 1,953 |
| Construções | Vegetação | 1,317 | 1,410 | 1,690 | 1,628 | 1,710 | 0,904 |
| Solo Exposto | Vegetação | 1,521 | 1,612 | 1,649 | 1,551 | 1,529 | 1,398 |

Fonte: O autor (2024).

Através das tabelas, observa-se que a banda do Nir e os índices NDVI e NDWI têm consistentemente valores elevados de JMD quando se trata de distinguir a classe Vegetação das outras classes (Richards e Jia, 1999). Isso sugere que eles são robustos indicadores para a classificação de vegetação em análises de sensoriamento remoto.

Comparando os anos de 2023 e 2018, percebe-se que, em geral, a separabilidade entre as classes tende a ser mais alta em 2023 para a maioria das variáveis. Isso pode ser devido a uma série de fatores, como mudanças no ambiente, melhorias na qualidade dos dados como a diferença dos instrumentos (sensores) utilizados que são *PSB.SD* para as imagens de 2023 e *PS2* para as imagens de 2018.

5.2 Treinamento do K-Nearest Neighbors (KNN)

Para o no de 2023 o K-vizinhos mais próximos apresentou um valor de ($K = 7$) e revelou uma acurácia global de 99,16% e um índice Kappa de 0,984 (gráfico 1). Esses resultados são indicativos de uma precisão e concordância notáveis na classificação realizada, reforçando a eficácia do modelo utilizado.

A acurácia de 99,16%, que teve um intervalo de confiança de 95% entre 0,991 e 0,992, demonstra que o modelo é extremamente preciso, produzindo resultados que estão muito próximos do valor real ou esperado. O intervalo de confiança estreito sugere que há uma alta probabilidade de que a acurácia real do modelo esteja dentro

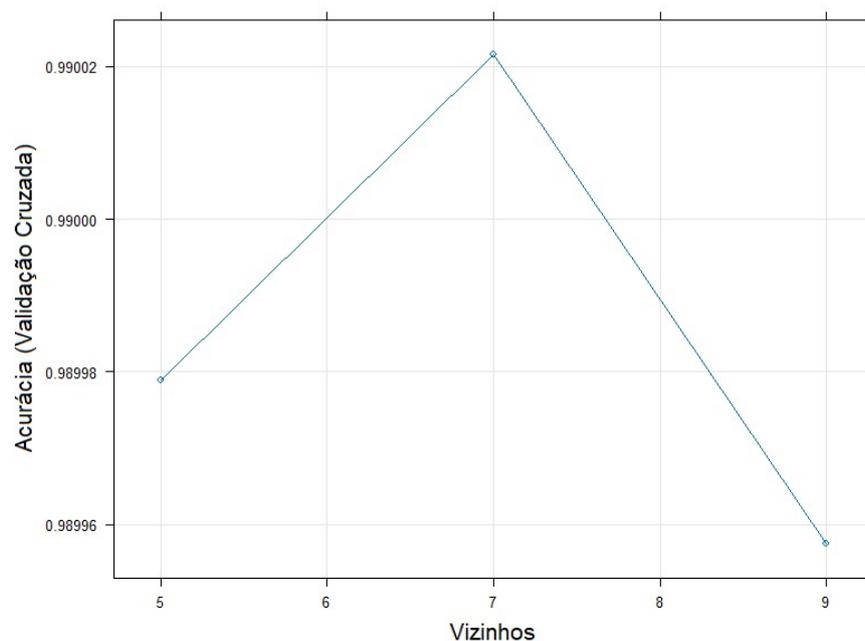
dessa faixa, o que é um indicativo de resultados consistentes (Lee, Lim e Schowengerdt, 2001).

O coeficiente Kappa de 0,984, que mede a concordância entre as classificações obtidas pelo modelo e as verdadeiras, ajustadas pelo acaso, está bem acima do limiar de 0,81, considerado como concordância quase perfeita segundo proposto por Landis e Koch (1977). Isso sugere que a classificação não só foi precisa, mas também consistente e confiável (Landis e Koch, 1977).

Já para 2018 o K-vizinhos mais próximos foi de (K = 5) revelando uma acurácia também excepcionalmente alta de 99,18% e um índice Kappa de 0,985 (gráfico 2). Esses resultados semelhantes a 2023 também são indicativos de uma precisão e concordância notáveis na classificação realizada.

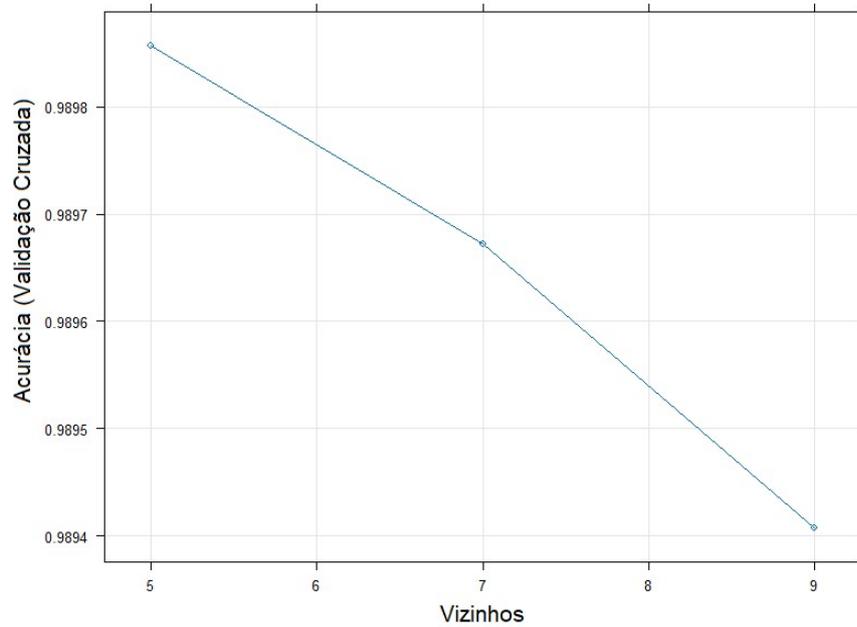
Portanto, os valores obtidos para 2018 e 2023, que incluem acurácia e Kappa, bem como o intervalo de confiança, reforçam a validade do modelo de classificação empregado. Isso indica que o modelo é eficaz para a tarefa designada e que os resultados se apresentam confiáveis para aplicações práticas ou para fundamentar decisões baseadas nesses dados.

Gráfico 1 – Comparação entre Acurácia (Validação Cruzada) e Vizinhos do treinamento do ano de 2023.



Fonte: O autor (2024).

Gráfico 2 – Comparação entre Acurácia (Validação Cruzada) e Vizinhos do treinamento do ano de 2018.



Fonte: O autor (2024).

5.3 Análise de Erro de Comissão e Omissão

Após o treinamento dos modelos, procedeu-se à análise dos erros de comissão e omissão para cada classe referente aos anos de 2018 e 2023. A Tabela 7 destaca que, em 2018, a classe Água não exibiu erros de Omissão (EO) nem de Comissão (EC), demonstrando uma classificação perfeita. Em contraste, a classe Construções apresentou um EO considerável de 24,67% e um EC de 2,57%, indicando que muitos elementos verdadeiros foram omitidos e alguns falsos positivos foram erroneamente identificados. A classe Solo Exposto teve um EO de 0,37% e um EC de 2,02%, enquanto a classe Vegetação registrou um EO de 0,29% e um EC de 0,19%. O notável EO na classe Construções sugere que o modelo falhou em detectar uma quantidade significativa de casos verdadeiros, o que aponta para a necessidade de aprimoramento ou ajuste do modelo a fim de elevar sua sensibilidade e diminuir a incidência de falsos negativos.

Tabela 7 – Erro de Comissão e Omissão para o modelo de 2018

| Classes | EO | EC |
|--------------|--------|--------|
| Água | 0,0000 | 0,0000 |
| Construções | 0,2467 | 0,0257 |
| Solo Exposto | 0,0037 | 0,0202 |
| Vegetação | 0,0029 | 0,0019 |

Fonte: O autor (2024).

A Tabela 8 ilustra os resultados de classificação para o ano de 2023. A classe Água não apresentou EO, indicando uma identificação precisa dos casos verdadeiros, mas registrou um pequeno EC de 0,07%, refletindo algumas identificações incorretas. Em contraste, a classe Construções mostrou um significativo EO de 22,10% e um EC de 6,18%, sugerindo que muitos elementos verdadeiros não foram detectados e alguns falsos positivos foram identificados. Para a classe Solo Exposto, foram observados um EO de 0,60% e um EC de 2,53%, indicando uma baixa taxa de omissão. A classe Vegetação teve um EO quase nulo de 0,01% e um EC inexistente de 0,00%, demonstrando alta precisão na classificação.

O elevado EO na classe Construções revela que o modelo falhou em identificar corretamente muitos casos positivos reais, enquanto o EC alto indica que o modelo classificou erroneamente alguns casos como pertencentes à classe quando não pertenciam. Esses resultados apontam para a necessidade de melhorias ou ajustes no modelo para aumentar a sensibilidade e especificidade, reduzindo tanto a taxa de falsos negativos quanto a de falsos positivos.

Tabela 8 – Erro de Comissão e Omissão para o modelo de 2018

| Classes | EO | EC |
|--------------|--------|--------|
| Água | 0,0000 | 0,0007 |
| Construções | 0,2210 | 0,0618 |
| Solo Exposto | 0,0060 | 0,0253 |
| Vegetação | 0,0001 | 0,0000 |

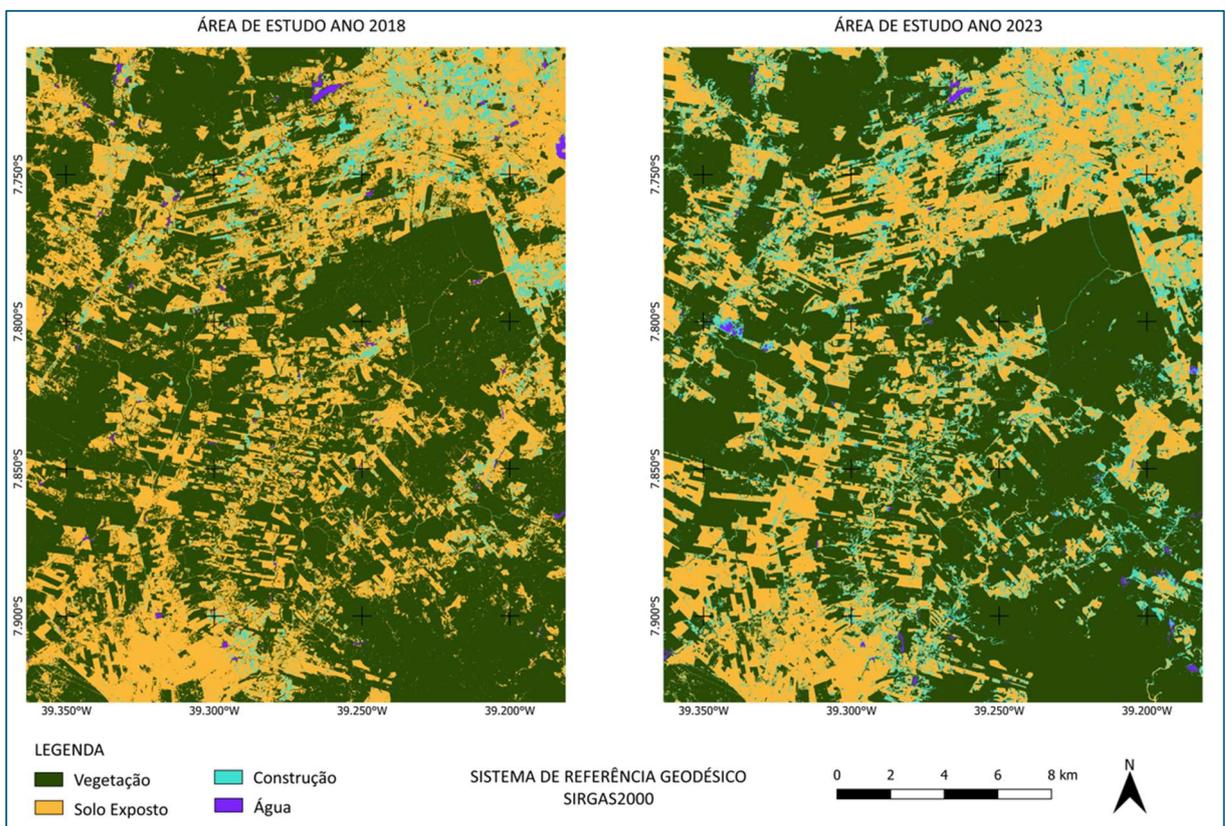
Fonte: O autor (2024).

5.4 Análise por fotointerpretação

Após a classificação das imagens dos anos de 2018 e 2023, foi possível realizar a análise de fotointerpretação dessas classificações (Figuras 3 e 4).

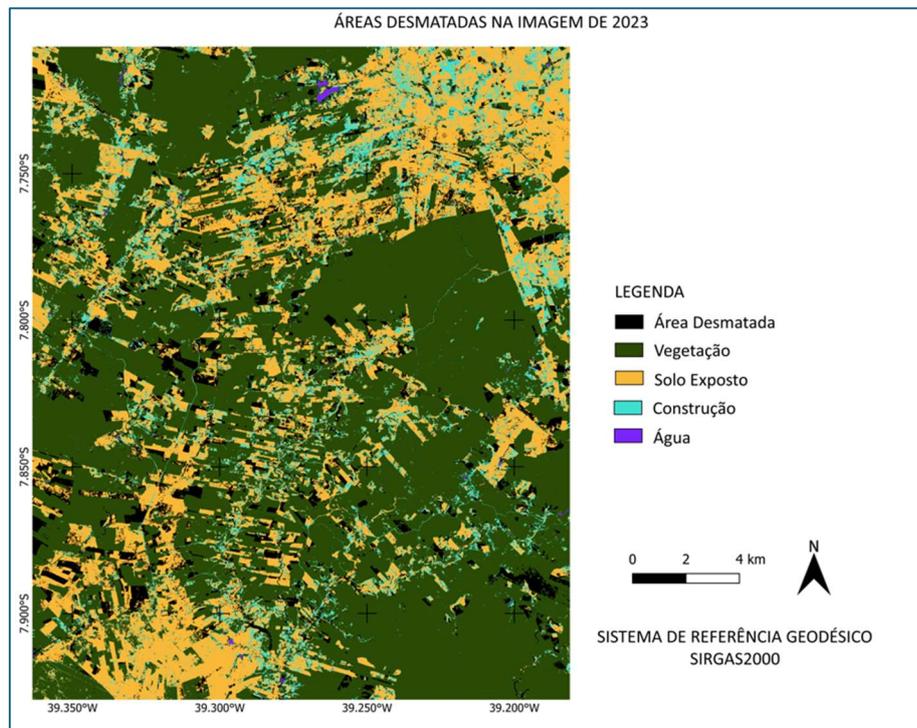
Analisando as imagens de 2018 e 2023, nota-se uma transformação significativa na área estudada.

Figura 3 – Classificação realizada pelo Algoritmo K-Nearest Neighbors (KNN)



Fonte: O Autor (2024)

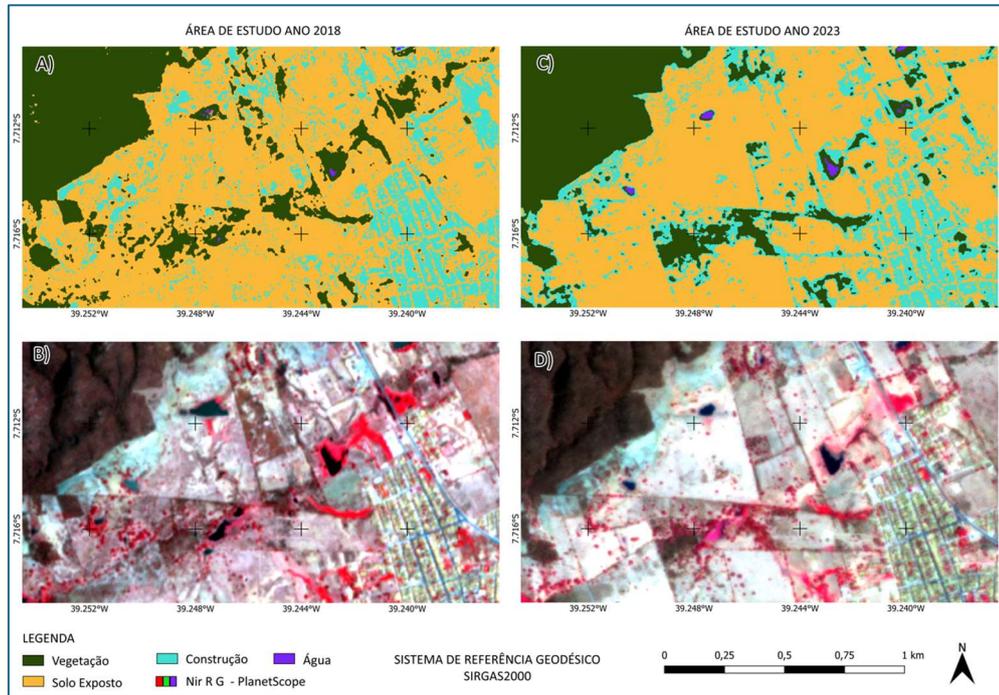
Figura 4 – Áreas desmatadas na imagem de 2023



Fonte: O Autor (2024)

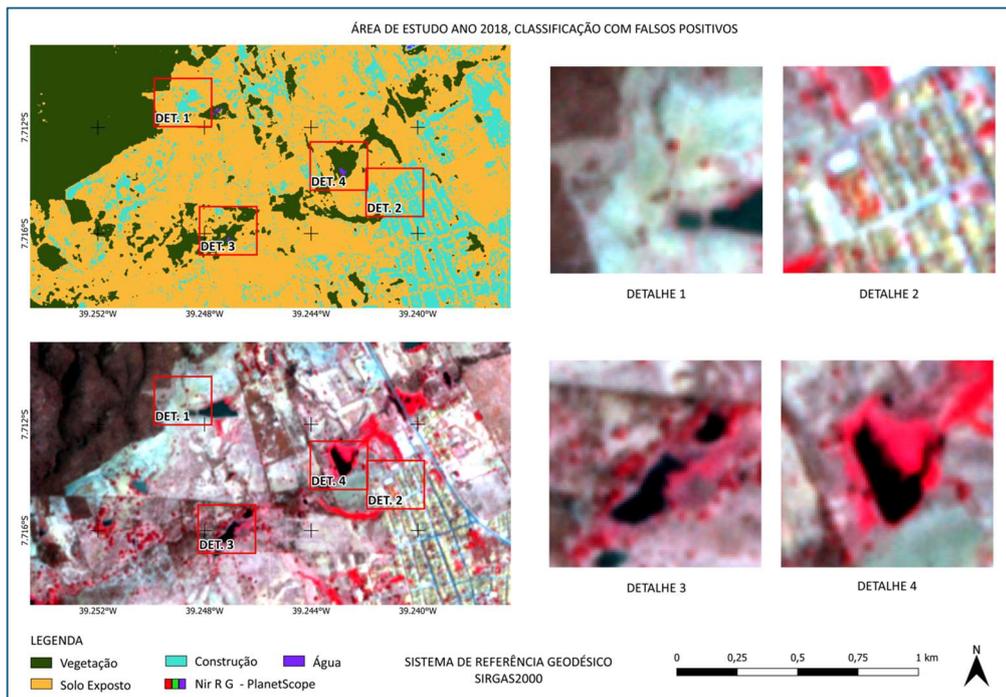
Em 2018, a região apresentava uma maior cobertura vegetal, indicada pela cor verde em relação a 2023, esse desmatamento foi destacado na figura 4, também podemos ver que existi em ambos os anos construções, cor turquesa, onde deveria ser apenas solo exposto na cor amarelo (figuras 5 e 6), isso já era de se esperar após a análise de distância de Jeffries-Matusita (tabelas 5 e 6), onde a distância de Jeffries-Matusita apresenta uma baixa separabilidade entre as construções e o solo exposto para cada índice e bandas espectrais. Além disso, há uma mudança visível nas áreas de água, azul, sugerindo alterações no uso do solo ao longo dos cinco anos. Essas mudanças podem estar relacionadas a fatores como políticas de uso do solo e pressões ambientais. É de extrema importância considerar esses aspectos ao planejar o desenvolvimento sustentável da região.

Figura 5 – Análise entre as classificações KNN de 2018 e 2023 a noroeste da cidade de Cedro-PE.



Fonte: O Autor (2024)

Figura 6 – Análise de Classificação com falsos positivos em 2018 a noroeste da cidade de Cedro-PE.

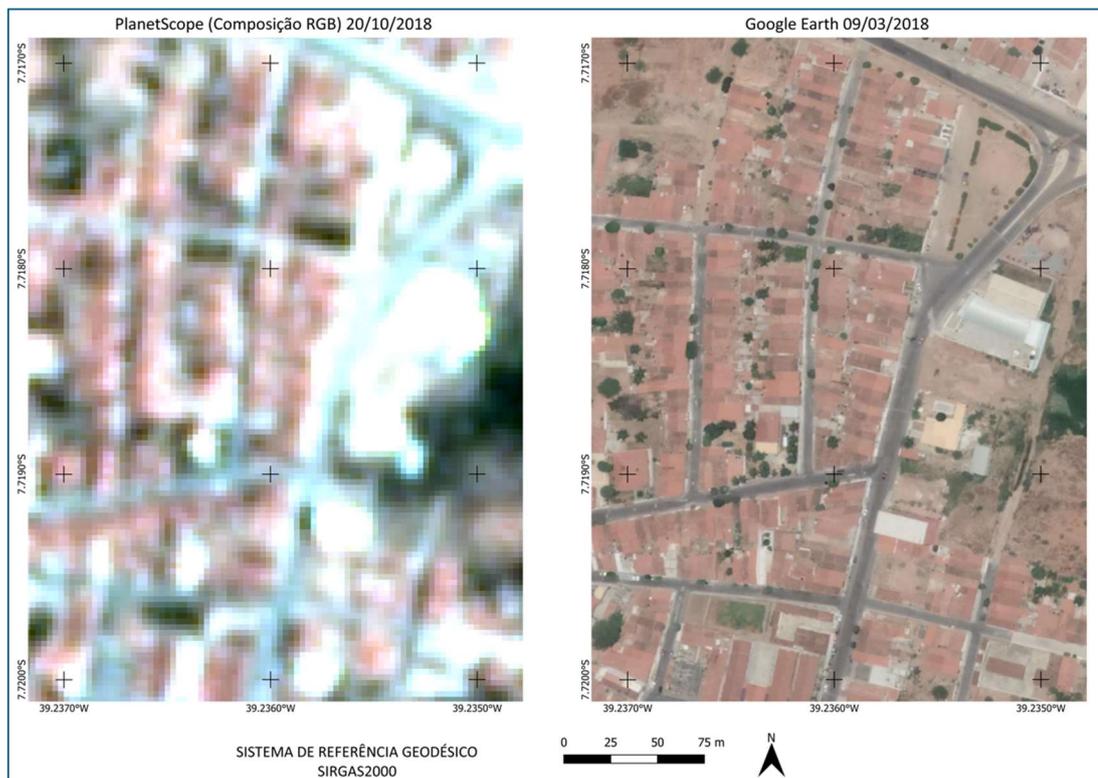


Fonte: O Autor (2024)

A figura 6 ilustra áreas que, embora desprovidas de construções, foram erroneamente classificadas como tal. Esses falsos positivos gerados na classificação podem ser atribuídos às características dos materiais usados nos telhados das construções que é predominantemente de argila, na figura 7 podemos visualizar a cobertura das construções através de imagens do PlanteScope e Google Earth. As amostras de treinamento para a classe de construção foram retiradas da cidade de Cedro-PE.

Podemos observar que, no ano de 2018 (figura 6), há ocorrências de erros de mistura espectral, onde conforme o estudo de Novo et al. (2005), diferentes tipos de cobertura do solo apresentam assinaturas espectrais únicas, detectáveis por sensores remotos. Contudo, a semelhança entre essas assinaturas em certas condições pode causar erros de classificação, resultando na confusão entre áreas inundáveis e vegetação densa. Essa similaridade espectral é um desafio conhecido no sensoriamento remoto, exigindo métodos refinados de análise para uma classificação precisa.

Figura 7 – Cidade de Cedro-PE, Imagem do PlanteScope e Google Earth.

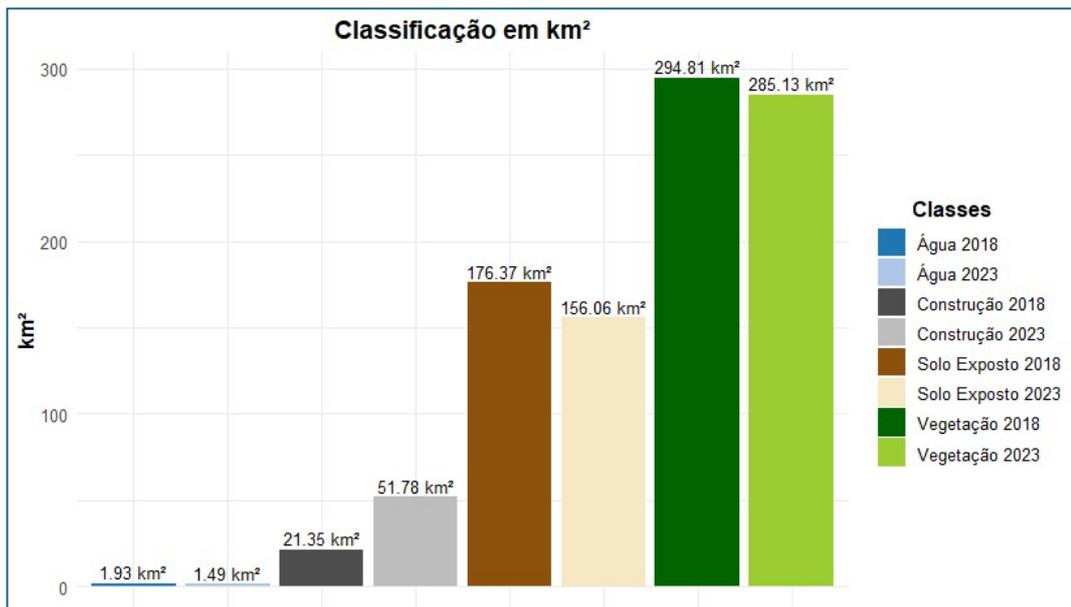


Fonte: O Autor (2024)

5.3 Análise quantitativa

Em 2023, houve uma redução na cobertura de vegetação de 9,68 km², o que representa uma redução de 3,28% em comparação com 2018. As áreas de água e solo exposto também apresentaram diminuição no mesmo período, com reduções de 0,44 km² (22,78%) e 20,31 km² (11,51%), respectivamente (figura 8). Em contraste, a classe de construção apresentou um aumento de 30,43 km², o que corresponde a um crescimento de 142,53% de 2018 para 2023. Essas variações podem ser parcialmente atribuídas a classificações incorretas das superfícies de solo exposto e construções, devido à semelhança entre os objetos, como discutido no item 5.3 deste trabalho. Quanto às áreas de água, o item 5.3, também sugere a ocorrência de má classificação. Contudo, ao considerarmos as variações quantitativas entre 2018 e 2023, observamos que as mudanças nas áreas de água não exercem uma influência significativa na classificação da vegetação.

Figura 8 – Comparação da classificação em km².

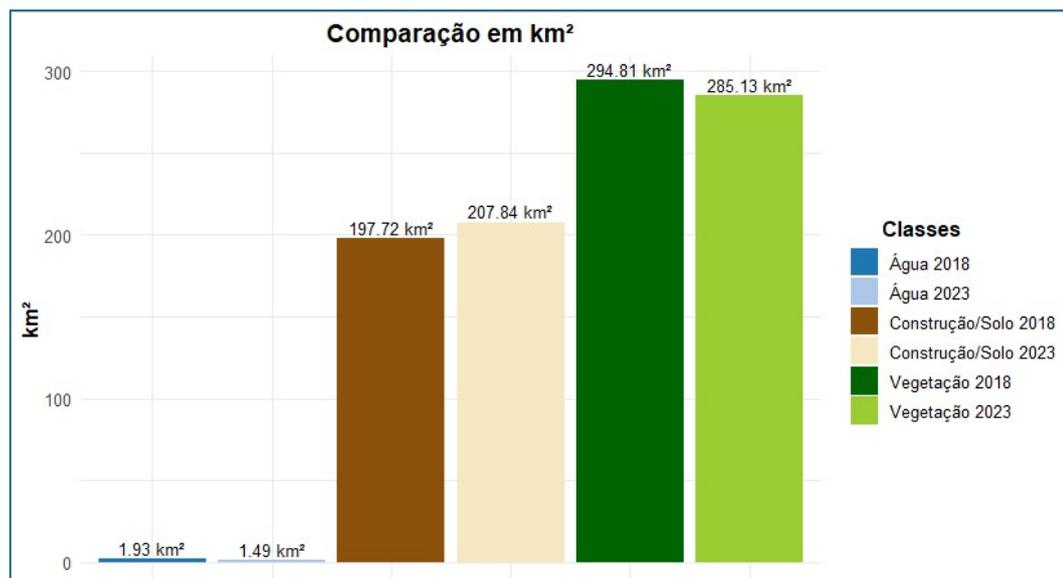


Fonte: O autor (2024).

Para aprimorar a comparação quantitativa e torná-la visualmente mais clara, propõe-se a unificação das áreas de solo exposto e construção em uma única classe. Essa abordagem tem o objetivo de mitigar os erros de classificação entre essas duas

categorias, já que o foco do estudo está nas variações da cobertura vegetal. Com essa unificação, simplificamos a análise e destacamos as alterações mais relevantes no que se refere à vegetação (Figura 9).

Figura 9 – Comparação da classificação em km² com unificação das classes de Construção e Solo Exposto.



Fonte: O autor (2024).

Adotando esta nova metodologia de análise, identifica-se que a área combinada de Construção/Solo Exposto teve um incremento de 10,12 km², o que representa um aumento de 5,12% em relação ao ano de 2018. Essa observação permite concluir que a redução da cobertura vegetal, equivalente a 9,68 km², está diretamente relacionada ao crescimento observado na nova classe unificada, que foi de 10,12 km².

Uma observação preocupante é a diminuição significativa da área de água em 0,44 km², o que representa uma redução de 22,78%. É importante notar que a imagem de 2018 apresentou problemas de classificação relacionados às áreas inundáveis e vegetação densa, conforme descrito por Novo et al. (2005). Entretanto, na imagem de 2023, esses erros não foram tão evidentes quanto na imagem anterior, sugerindo que a diminuição real da área de água pode ter sido ainda maior do que a registrada. Ambas as imagens foram capturadas no mês de outubro, o que elimina a variabilidade sazonal como causa para a discrepância observada.

Ao analisar os dados pluviométricos fornecidos pela Agência Pernambucana de Águas e Clima – APAC (tabelas 3 e 4), constatou que, para o mês de outubro de 2023, não houve precipitação significativa, diferentemente do observado no mesmo mês do ano de 2018, onde ocorreu chuva. Isso sugere que as chuvas esperadas em outubro poderiam ter contribuído para uma maior presença de água nas classificações do ano de 2023, influenciando assim na detecção da classe de água.

6 CONCLUSÃO

A metodologia implementada neste estudo, que combina a classificação KNN com os índices espectrais NDVI e NDWI, demonstrou ser uma técnica robusta para a análise espaço-temporal da cobertura do solo em áreas de mineração. A avaliação do modelo foi realizada por meio de várias métricas, incluindo acurácia global, índice Kappa, e análise de erro de comissão e omissão, todas indicando resultados precisos. A acurácia global superior a 99% e o índice Kappa próximo de 1 confirmam a eficácia do modelo. A análise de erro de comissão e omissão forneceu percepção adicionais sobre a confiabilidade das classificações, destacando áreas onde o modelo pode ser aprimorado. A distância de Jeffries-Matusita também foi utilizada para avaliar a separabilidade entre as classes, fornecendo uma compreensão mais profunda da capacidade do modelo de diferenciar entre categorias similares.

A análise dos resultados revelou uma diminuição significativa na cobertura vegetal e nas áreas de água entre 2018 e 2023, com um aumento correspondente na área de construção/solo exposto. Essas mudanças refletem o impacto das atividades humanas e sugerem uma pressão crescente sobre os ecossistemas locais. A dificuldade em distinguir entre certas categorias ressalta a complexidade da classificação em áreas de mineração e a importância de refinar as técnicas de sensoriamento remoto para melhorar a precisão.

Este trabalho proporcionou um entendimento aprofundado das alterações espaço-temporais na cobertura do solo, enfatizando a importância do sensoriamento remoto e da análise de dados espaciais no monitoramento ambiental. Para futuras pesquisas, sugere-se a expansão do conjunto de dados de treinamento e a exploração de outras técnicas de aprendizado de máquina para aprimorar a classificação. Além disso, recomenda-se a realização de estudos adicionais para investigar o impacto das

políticas de uso do solo e das mudanças climáticas na dinâmica da cobertura vegetal em áreas de mineração, visando contribuir para estratégias de conservação e desenvolvimento sustentável.

REFERÊNCIAS

- ADAMI, Marcos; VALERIANO, Dalton de Morisson; SAITO, Narayan. O sensoriamento remoto e sua importância para o monitoramento ambiental e gestão territorial. **Revista Brasileira de Cartografia**, [S.l.], v. 69, n. 7, p. 1231-1246, 2017.
- AGÊNCIA NACIONAL DE MINERAÇÃO (ANM). **Áreas para prospecção de ouro, diamante e agrominerais no Norte e Nordeste irão a leilão**. 2023. Disponível em: <https://www.gov.br/anm/pt-br/assuntos/noticias/areas-para-prospeccao-de-ouro-diamante-e-agrominerais-no-norte-e-nordeste-irao-a-leilao>. Acesso em: 10 mar. 2024.
- Agência Pernambucana de Águas e Clima - APAC. (2023). **Monitoramento pluviométrico**. Disponível em: <http://old.apac.pe.gov.br/meteorologia/monitoramento-pluvio.php>. Acesso em: 10 mar. 2024.
- ALBA, E. et al. Comparação entre Algoritmos de Aprendizado de Máquina para a Identificação de Floresta Tropical Sazonalmente Seca. **Anuário do Instituto de Geociências - UFRJ**, [S.l.], v. 45, n. 3, 2022.
- ALBUQUERQUE, A.W.; LOMBARDI, N.F.; SRINIVASAN, V.S. Efeito do desmatamento da caatinga sobre as perdas de solo e água de um Luvisolo em Sumé (PB). **Revista Brasileira de Ciência do Solo**, 25(1), 121-128, 2001.
- ALPAYDIN, Ethem. **Machine learning**. Cambridge, MA: MIT Press, 2016.
- BEZERRA, J. J. L.; LIRA, W. B.; SILVA, T. da C. Impactos ambientais causados pela mineração: uma análise da percepção de pequenos mineradores do município de Frei Martinho – PB. **Revista Monografias Ambientais**, v. 19, e8, 2020.
- BRASIL. **Lei nº 6.938, de 31 de agosto de 1981**. Dispõe sobre a Política Nacional do Meio Ambiente, seus fins e mecanismos de formulação e aplicação, e dá outras providências. Diário Oficial [da] República Federativa do Brasil, Brasília, DF, 02 set. 1981. Disponível em: https://www.planalto.gov.br/ccivil_03/Leis/L6938.htm. Acesso em: 10 mar. 2024.
- BRASIL. **Decreto-Lei nº 227, de 28 de fevereiro de 1967**. Institui o Código de Mineração. Diário Oficial da União, Brasília, DF, 28 fev. 1967. Disponível em: https://www.planalto.gov.br/ccivil_03/decreto-lei/del0227.htm. Acesso em: 10 mar. 2024.
- CAPACIA, A.T.M. et al. Uso do algoritmo k-Nearest Neighbors (k-NN) na classificação e segmentação de plantas daninhas em pastagens. **Journal of Weed Science**, 31(2), pp. 345-356, 2023.
- COVER, T. M.; HART, P. E. Nearest neighbor pattern classification. **IEEE Transactions on Information Theory**, v.13, n.1, p.21-27, 1967.

DEPARTAMENTO NACIONAL DA PRODUÇÃO MINERAL. **Projeto Serrita-Cedro: Fase I**. 2. ed. Recife, 1995. Disponível em: https://www.dnpm-pe.gov.br/Trabalhos/Projeto_Serrita_I.pdf. Acesso em: 15 dez. 2023.

EOS DATA ANALYTICS. NDVI: perguntas frequentes para compreender o índice. **EOS Data Analytics**, 25 set. 2020. Disponível em: <http://eos.com/pt/blog/ndvi-faq/>. Acesso em: 4 jul. 2023.

FERNANDES, A.M.R. **Inteligência artificial: Noções gerais**. Visual Books, Florianópolis, 2003.

FRANCO-LOPEZ, H.; EK, A. R.; BAUER, M. E. (2001). Estimation and mapping of forest stand density, volume, and cover type using the k-nearest neighbors (kNN) method. **Remote Sensing of Environment**, 77(3), 251-274.

HUANG, S.; TANG, L.; HUPY, J. P.; WANG, Y.; SHAO, G. (2021). A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing. **Journal of Forestry Research**, 32(1), 1-6. <https://doi.org/10.1007/s11676-020-01155-1>

IBRAM (2020). **Informações sobre a economia mineral brasileira 2020** – Ano base 2019. 1.ed. Brasília: IBRAM, 2020. 80p. ISBN: 978-65-990386-3-1. Disponível em: <https://ibram.org.br/wp-content/uploads/2021/02/Economia-Mineral-Brasileira-IBRAM-2020.pdf>. Acesso em: 20 jan. 2024.

IBRAM (2021). **Trilha Gold revalida pesquisas em Serrita (PE) e amplia estimativa de produção para 120 mil onças de ouro por ano**. Disponível em: <https://ibram.org.br/noticia/trilha-gold-revalida-pesquisas-em-serrita-pe-e-amplia-estimativa-de-producao-para-120-mil-oncas-de-ouro-por-ano/>. Acesso em: 20 jan. 2024.

INPE (2024). Projeto SAD Caatinga. **Monitoramento ambiental por satélites na Amazônia**. São José dos Campos, SP: Instituto Nacional de Pesquisas Espaciais. Disponível em: <https://www.fundoamazonia.gov.br/pt/projeto/Monitoramento-Ambiental-por-Satelites-no-Bioma-Amazonia/>. Acesso em: 20 jan. 2024.

JAMES, G.; WITTEN, D.; HASTIE, T.; TIBSHIRANI, R. **An Introduction to Statistical Learning**. Springer, New York, NY, USA, 2013.

JEFFRIES, N.; MATUSITA, K. On some properties of distance functions and their application to pattern recognition. **IEEE Transactions on Information Theory**, v.13, n.4, p.462-475, 1967.

KOHAVI, R. **A study of cross-validation and bootstrap for accuracy estimation and model selection**. In: IJCAI'95 Proceedings of the 14th international joint conference on Artificial intelligence, v.2, p.1137-1145, 1995.

LANDIS, J. R.; KOCK, G. G. The measurement of observer agreement for categorical data. **Biometrics**, v. 33, n. 1, p. 159-174, 1977.

LEE, J.; LIM, C.; SCHOWENGERDT, R. A. Hyperspectral image processing for target detection and classification. **Analytical Chemistry**, v. 73, n. 9, p. 2594-2602, 2001.

LEITE, J. F. R. Mineração no Nordeste do Brasil: importância econômica e seus desafios socioambientais. **Anais do Conapesc**, Recife, v. 5, n. 1, p. 1-15, out. 2020.

MANZOLLI, B. et al. **Legalidade da produção de ouro no Brasil**. Belo Horizonte: UFMG/Lagesa; Brasília: MPF/4CCR/PRDF/PRRR/PRPA/PRMT/PRRO/PRAP/PRAM/PRTO/PRGO/PRSP/PRMS/PRSC/PREDF/PREPA/PREMT/PREAP/PREAM/PRETO/PREGO/PRESP/PREMS/PRESC; São Paulo: Greenpeace Brasil; Belém: Instituto Socioambiental (ISA), 2021.

MapBiomas (2022). **Relatório Anual de Desmatamento 2022**. Projeto de Mapeamento Anual da Cobertura e Uso do Solo no Brasil. Disponível em: <https://brasil.mapbiomas.org/2023/06/12/desmatamento-nos-biomas-do-brasil-cresceu-223-em-2022/>. Acesso em: 20 jan. 2024.

MASHALA, M. J.; DUBE, T.; MUDERERI, B. T.; AYISI, K. K.; RAMUDZULI, M. R. (2023). A Systematic Review on Advancements in Remote Sensing for Assessing and Monitoring Land Use and Land Cover Changes Impacts on Surface Water Resources in Semi-Arid Tropical Environments. **Remote Sensing**, 15(16), 3926. doi:10.3390/rs15163926

McFEETERS, S. K. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. **International Journal of Remote Sensing**, v.17, n.7, p.1425-1432, 1996.

MEDEIROS, N. S. R. de et al. **Análise do desempenho do algoritmo K-Nearest Neighbors na classificação de patologias de coluna vertebral**. 2019. Disponível em: <https://editorarealize.com.br/artigo/visualizar/56476>. Acesso em: 19 jan. 2024.

MINÉRIOS & MINERALES. **As 200 maiores minas brasileiras**. São Paulo: Lithos Ed. Ltda., n. 355, out.2013. Disponível em: https://revistamineros.com.br/wp/wp-content/uploads/2021/12/MM_355_SITE.pdf. Acesso em: 10 mar. 2024.

NOVO, Evlyn Márcia Leão de Moraes et al. Técnicas avançadas de sensoriamento remoto aplicadas ao estudo de mudanças climáticas e ao funcionamento dos ecossistemas amazônicos. **Revista Brasileira de Cartografia**, v. 35, n. 2, p. 259-272, 2005.

PACHECO, A.P. et al. Assessment of k-Nearest Neighbor and Random Forest Classifiers for Mapping Forest Fire Areas in Central Portugal Using Landsat-8, Sentinel-2, and Terra Imagery. **Remote Sensing**, [S.L.], v.13, n.7, p.1345-1364, 1 abr. 2021. Disponível em: <https://doi.org/10.3390/rs13071345>. Acesso em: 25 mar. 2024.

PHAN, T. N.; KAPPAS, M.. **Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery**. *Sensors*, [S.l.], v. 18, n. 18, p. 1-20, 2018.

Piovesan, P.; Araújo, L. B. de; Dias, C. T. dos S. Validação cruzada com correção de autovalores e regressão isotônica nos modelos de efeitos principais aditivos e interação multiplicativa. **Ciência Rural**, Santa Maria, v.39, n.4, p.1018-1023, jul. 2009.

PlanetScope (2024). **PlanetScope last updated**: February 05, 2024. Disponível em: <https://developers.planet.com/docs/data/planetscope/>. Acesso em: 9 de março de 2024.

QGIS Development Team. **Geographic Information System**. QGIS Development Team, 2023. [S.l.]: Open Source Geospatial Foundation Project. Disponível em: https://qgis.org/pt_BR/site/. Acesso em: 15 dez. 2023.

R CORE TEAM. **A language and environment for statistical computing**. Vienna: R Foundation for Statistical Computing, 2023. Disponível em: <https://posit.co/download/rstudio-desktop/>. Acesso em: 15 dez. 2023.

RAMOS, A.D.; MARINHO, H.E. (1980). **Estudo da erodibilidade de um solo litólico sem cobertura vegetal e sob duas condições de pastagens nativa de caatinga**. Embrapa, Boletim de Pesquisa, nº 02, p. 16. Sobral: Empresa Brasileira de Pesquisa Agropecuária. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/36449/1/BP-02.pdf>. Acesso em: 1 mar. 2024.

REVISTA MINERAÇÃO. Trilha Gold Capital investe na mineração de ouro em Pernambuco. 2021. Disponível em: <https://revistamineracao.com.br/2021/02/02/trilha-gold-capital-investe-na-mineracao-de-ouro-em-pernambuco/>. Acesso em: 30 set. 2023

RICHARDS, J. A.; JIA, X. **Remote Sensing Digital Image Analysis: An Introduction**. Springer-Verlag, Berlin, Germany, 1999.

ROUSE, J.W. et al. Monitoring Vegetation Systems in the Great Plains, With ERTS. In: **Third ERTS Symposium, NASA SP-351 I**. 309-317, 1973.

SAITO, Narayan; ADAMI, Marcos; FERREIRA, Maurício. Práticas sustentáveis na mineração: o papel do sensoriamento remoto. **Revista de Geologia Aplicada à Mineração**, [S.l.], v. 26, n. 4, p. 489-503, 2011.

SANO, E. E.; ROSA, R.; BRITO, J. L. S.; FERREIRA, L. G. Land cover mapping of the tropical savanna region in Brazil. **Environmental Monitoring and Assessment**, v. 166, p. 113–124, 2010. doi:10.1007/s10661-009-0988-4.

SIQUEIRA-GAY, J.; SÁNCHEZ, L. E. The outbreak of illegal gold mining in the Brazilian Amazon boosts deforestation. **Environmental Science & Policy**, v. 123, p. 1-9, 2021.

SOUSA, A.R.; NUNES, F.A.B.; SILVA, A.B.; Mafra, R.C. (1993). **Efeito da cobertura vegetal em relação a erosão num solo Bruno Não-Cálcico de Serra Talhada (PE)**. In: Congresso Brasileiro de Ciência do Solo, 24., Goiânia, 1993. Resumos. Goiânia: Sociedade Brasileira de Ciência do Solo, 1993. p.169-170.

SOUZA, K. V.; TEIXEIRA, N. S.; LIMA, M. H. M. R.; BEZERRA, M. S. **Os Arranjos Produtivos Locais (APLs) de base mineral e a sustentabilidade**. In: FERNANDES, F. R. C.; ENRIQUEZ, M. A. R. S.; ALAMINO, R. C. J. (Eds.). Recursos Minerais e Sustentabilidade Territorial v.2, p. 69- 88. Rio de Janeiro: CETEM/MCTI, 2011.

SOUZA, K.V. de et al. **Mineração na Região Nordeste do Brasil: quadro atual e perspectivas**. In: Recursos Minerais e Sociedade: impactos humanos – socioambientais – econômicos. Rio de Janeiro: CETEM, 2014.

STORY, M. Accuracy assessment: A user's perspective. **Photogrammetric Engineering and Remote Sensing**, v. 52, p. 397-399, 1986.

TEODORO, A.; AMARAL, A. A **Statistical and Spatial Analysis of Portuguese Forest Fires in Summer 2016 Considering Landsat 8 and Sentinel 2A**. In: Environments [S.l.], v.6,n.3,p36,2019. Disponível em: <https://doi.org/10.3390/environments6030036>. Acesso em: 04 jul. 2023.

VALERIANO, D.M.; ROSSETTI, D.A.; ADAMI, M.. Dinâmica da cobertura vegetal e uso da terra na Amazônia: avanços no sensoriamento remoto. **Revista Brasileira de Geografia Física**, [S.l.], v. 5, n. 5, p. 851-867, 2012.

VASCONCELOS, C. H.; NOVO, E. M. L. M. Mapeamento do uso e cobertura da terra a partir da segmentação e classificação de imagens – fração solo sombra e vegetação derivadas do modelo linear de mistura aplicado a dados do sensor TM/Landsat5 na região do reservatório de Tucuruí - PA. **Revista Brasileira de Cartografia**, 56(3), 487-493, 2004.

GOMES, João Paulo Silva; SILVA, Valdenildo Pedro da. **Recuperação de áreas degradadas sobre o bioma Caatinga: uma análise bibliométrica**. Geoambiente On-line, Goiânia, n. 46, 2023.

REZENDE, Vanessa Leite. A mineração em Minas Gerais: uma análise de sua expansão e os impactos ambientais e sociais causados por décadas de exploração. **Sociedade & Natureza**, Belo Horizonte, v. 28, n. 3, p. 469-482, nov. 2016. DOI: <http://dx.doi.org/10.1590/1982-451320160304>.

TABARELLI, Marcelo et al. **Caatinga: legado, trajetória e desafios rumo à sustentabilidade**. Ciência e Cultura, São Paulo, v. 70, n. 4, out./dez. 2018

TROVÃO, D. M. de B. M.; FERNANDES, P. D.; ANDRADE, L. A. de; DANTAS NETO, J. Variações sazonais de aspectos fisiológicos de espécies da Caatinga. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 11, n. 3, p. 307-311, 2007.