

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DA BAHIA,
CAMPUS VITÓRIA DA CONQUISTA
COORDENAÇÃO DO CURSO DE ENGENHARIA AMBIENTAL**

**AVALIAÇÃO DO USO E COBERTURA DO SOLO UTILIZANDO IMAGENS DO
SATÉLITE SENTINEL-2 NO ESTUDO DE DESASTRES AMBIENTAIS: O CASO DO
ROMPIMENTO DA BARRAGEM DE BRUMADINHO-MG**

Kariny Moreira Rocha

Vitória da Conquista, BA

Fevereiro de 2024

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DA BAHIA,
CAMPUS VITÓRIA DA CONQUISTA
COORDENAÇÃO DO CURSO DE ENGENHARIA AMBIENTAL**

**AVALIAÇÃO DO USO E COBERTURA DO SOLO UTILIZANDO IMAGENS DO
SATÉLITE SENTINEL-2 NO ESTUDO DE DESASTRES AMBIENTAIS: O CASO DO
ROMPIMENTO DA BARRAGEM DE BRUMADINHO-MG**

Kariny Moreira Rocha

Trabalho de Conclusão de Curso apresentado à
Coordenação do Curso de Engenharia
Ambiental do Instituto Federal de Educação,
Ciência e Tecnologia da Bahia, Campus Vitória
da Conquista como requisito parcial para a
obtenção do título de Engenheiro Ambiental.

Orientadora: Dra. Lídia Raiza Sousa Lima Chaves Trindade

Vitória da Conquista, BA

Fevereiro de 2024

FICHA CATALOGRÁFICA ELABORADA PELO SISTEMA DE BIBLIOTECAS DO IFBA, COM OS
DADOS FORNECIDOS PELO(A) AUTOR(A)

R672a Moreira Rocha, Kariny

Avaliação do uso e cobertura do solo utilizando imagens do satélite Sentinel-2 no estudo de desastres ambientais: o caso do rompimento da barragem de Brumadinho-MG: / Kariny Moreira Rocha; orientadora Lídia Raiza Sousa Lima Chaves Trindade -- Vitória da Conquista: IFBA, 2024.

69 p.

Trabalho de Conclusão de Curso (Engenharia Ambiental) -- Instituto Federal da Bahia, 2024.

1. Sensoriamento Remoto. 2. Classificação Supervisionada. 3. Índices Espectrais. 4. Desastres Ambientais. I. Sousa Lima Chaves Trindade, Lídia Raiza, orient. II. TÍTULO.

KARINY MOREIRA ROCHA

**AVALIAÇÃO DO USO E COBERTURA DO SOLO UTILIZANDO
IMAGENS DO SATÉLITE SENTINEL-2 NO ESTUDO DE DESASTRES
AMBIENTAIS: O CASO DO ROMPIMENTO DA BARRAGEM DE
BRUMADINHO-MG**

A presente Monografia, apresentada em sessão pública realizada em dezenove de fevereiro de 2024, foi avaliada como adequada para obtenção do Grau de Bacharel em Engenharia Ambiental, julgada e aprovada em sua forma final pela Coordenação do Curso de Engenharia Ambiental do Instituto Federal de Educação, Ciência e Tecnologia da Bahia, Campus Vitória da Conquista.

Data da Aprovação: 19 de fevereiro de 2024

BANCA EXAMINADORA

Profª. Drª. Lídia Raiza Sousa Lima Chaves Trindade
Orientadora – IFBA Campus Vitória da Conquista

Profa. Drª Joseane Oliveira da Silva
IFBA Campus Vitória da Conquista

Eng. Amb. Victória Vilasboas L. Costa
UESB Campus Itapetinga

Vitória da Conquista, 19 de fevereiro de 2024

“Dedico este trabalho aos meus pais, meu irmão e minha tia, que sempre me apoiaram e incentivaram, em todos os momentos da minha vida”.

AGRADECIMENTOS

Agradeço primeiramente a Deus, que é a fonte de toda a minha força e esperança. Sem Ele nada seria possível.

Aos meus pais, Antonio e Marlene, agradeço por serem os melhores pais que eu poderia pedir, e por sempre trabalharem e dedicarem suas vidas em prol dos seus filhos.

Agradeço à minha tia Xinha e ao meu irmão Natanael, que sempre estiveram ao meu lado, compartilhando alegrias e tristezas comigo. E ao meu irmão Raonny, que mesmo de longe, sempre torceu pelo meu sucesso.

Agradeço à minha orientadora Dr^a Lídia Raiza, por dedicar o seu tempo em me ajudar na construção e desenvolvimento deste trabalho.

A todos os meus amigos de vida, especialmente Beatriz, Fabíola e Adriana, que sempre acreditaram em minha capacidade e tornaram este período muito mais leve e divertido.

Aos meus amigos que conheci durante a graduação, em especial Júlia, Victória, Talita, Geovanna, Érika, Yves Gabriel, Danyella, Sthefany e Andreza, que sempre se fizeram presentes e tornaram essa jornada de cinco anos muito mais fácil e significativa.

Aos amigos do Grupo de Oração Semente de Vida Nova, agradeço imensamente por todo o carinho, apoio e orações que vocês me ofereceram ao longo dos últimos anos.

Meu muito obrigada à Claudinha Lilian, minha professora, mentora e amiga, por todo o aprendizado adquirido dentro do GPA.

Agradeço ao Instituto Federal de Educação, Ciência e Tecnologia da Bahia (IFBA) – campus Vitória da Conquista, em sua totalidade, pela dedicação ao ensino.

Por fim, expresso minha gratidão a todos que, de maneira indireta, contribuíram para o meu desenvolvimento acadêmico. Muito obrigada!

“Só em Deus está o repouso da minha alma, Dele vem a minha salvação. Só Ele é minha rocha e minha salvação, o meu refúgio. Jamais vacilarei!” (Salmos 62:2-3).

RESUMO

O rompimento da barragem de rejeitos de minério B1 em Brumadinho-MG desencadeou um dos piores desastres ambientais no Brasil, afetando centenas de vidas e devastando uma área de 297 hectares. Com o intuito de avaliar as mudanças no uso e ocupação do solo após o desastre, este estudo teve como objetivo delimitar e avaliar a extensão do impacto da lama de rejeitos, além de realizar a classificação supervisionada do município antes e depois do rompimento da barragem, através de uma combinação de técnicas, incluindo imagens de sensoriamento remoto, ferramentas de geoprocessamento e o software RStudio. A análise dos índices espectrais NDVI, EVI e NDWI revelou um impacto significativo e adverso na região afetada, destacando a perda de vegetação. Ao realizar a classificação supervisionada, os algoritmos RF e SVM apresentaram desempenhos semelhantes, com acurácia global e kappa acima de 90%. No entanto, o RF se destacou como mais eficaz na identificação das diferentes áreas temáticas da superfície, ao utilizar imagens do satélite Sentinel-2. Esses resultados evidenciaram que os algoritmos de aprendizado de máquina, quando combinados com imagens de alta resolução espacial, oferecem uma análise precisa e confiável para estudos ambientais futuros. Essa abordagem permite uma rápida identificação e avaliação das mudanças na cobertura do solo após eventos catastróficos como o rompimento de barragens, facilitando a tomada de decisões e o planejamento adequado para a recuperação ambiental.

Palavras-Chave: Sensoriamento Remoto; Geoprocessamento; Índices Espectrais; Classificação Supervisionada; Rompimento de Barragens.

ABSTRACT

The rupture of the B1 ore tailings dam in Brumadinho-MG triggered one of the worst environmental disasters in Brazil, affecting hundreds of lives and devastating an area of 297 hectares. With the aim of assessing changes in land use and occupation after the disaster, this study aimed to delimit and evaluate the extent of the impact of tailings mud, as well as to perform supervised classification of the municipality before and after the dam rupture, through a combination of techniques, including remote sensing imagery, geoprocessing tools, and RStudio software. Analysis of spectral indices NDVI, EVI, and NDWI revealed a significant and adverse impact on the affected region, highlighting vegetation loss. When conducting supervised classification, the RF and SVM algorithms showed similar performances, with overall accuracy and kappa above 90%. However, RF stood out as more effective in identifying different thematic areas of the surface when using Sentinel-2 satellite images. These results showed that machine learning algorithms, when combined with high-resolution spatial images, provide precise and reliable analysis for future environmental studies. This approach enables rapid identification and assessment of changes in land cover following catastrophic events such as dam ruptures, facilitating decision-making and proper planning for environmental recovery.

Keywords: Remote Sensing; Geoprocessing; Spectral Indices; Supervised Classification; Dam Break.

LISTA DE FIGURAS

| | |
|--|----|
| Figura 1 - Etapas do processo de aquisição e distribuição das imagens de sensoriamento remoto..... | 20 |
| Figura 2 - Assinatura espectral da água, do solo e da vegetação desde a faixa do visível até o infravermelho de ondas curtas (0,4-2,5 μ m)..... | 22 |
| Figura 3 - Curva de reflectância das plantas..... | 26 |
| Figura 4 - Valores NDVI para análise da vegetação..... | 27 |
| Figura 5 - Área afetada pelo rompimento da barragem, em Brumadinho, Minas Gerais..... | 30 |
| Figura 6 - Delimitação da área afetada pela lama de rejeitos..... | 38 |
| Figura 7 - NDVI antes (a) e após (b) o rompimento da barragem de Brumadinho, Minas Gerais (Janeiro 2019 - Janeiro 2021)..... | 39 |
| Figura 8 - EVI antes (a) e após (b) o rompimento da barragem de Brumadinho, Minas Gerais (Janeiro 2019 - Janeiro 2021)..... | 41 |
| Figura 9 - NDWI antes (a) e após (b) o rompimento da barragem de Brumadinho, Minas Gerais (Janeiro 2019 - Janeiro 2021)..... | 42 |
| Figura 10 - Resultado da classificação supervisionada para os algoritmos RF (a) e SVM (b), no município de Brumadinho - MG, antes do rompimento da barragem..... | 47 |
| Figura 11 - Resultado da classificação supervisionada para os algoritmos RF (a) e SVM (b), no município de Brumadinho - MG, após o rompimento da barragem..... | 48 |

LISTA DE TABELAS

| | |
|--|----|
| Tabela 1 - Intervalos espectrais possíveis de serem usados pelos sensores remotos..... | 21 |
| Tabela 2 - Resultado da Acurácia global e Kappa para os algoritmos RF e SVM, utilizando imagem anterior ao rompimento da barragem (07/01/2019)..... | 45 |
| Tabela 3 - Resultado da Acurácia global e Kappa para os algoritmos RF e SVM, utilizando imagem posterior ao rompimento da barragem (31/01/2021)..... | 45 |
| Tabela 4 - Quantificação das classes temáticas de uso e cobertura da terra para os algoritmos RF e SVM no Município de Brumadinho-MG (07/01/2019)..... | 50 |
| Tabela 5 - Quantificação das classes temáticas de uso e cobertura da terra para os algoritmos RF e SVM no Município de Brumadinho-MG (31/01/2021)..... | 51 |
| Tabela 6 - Matriz de Confusão para o algoritmo RF da imagem datada do dia 07/01/2019..... | 52 |
| Tabela 7 - Acurácia do produtor e do usuário para o algoritmo RF..... | 53 |
| Tabela 8 - Matriz de Confusão para o algoritmo SVM da imagem datada do dia 07/01/2019..... | 53 |
| Tabela 9 - Acurácia do produtor e do usuário para o algoritmo SVM..... | 54 |
| Tabela 10 - Matriz de Confusão para o algoritmo RF da imagem datada do dia 31/01/2021..... | 54 |
| Tabela 11 - Acurácia do produtor e do usuário para o algoritmo RF..... | 55 |
| Tabela 12 - Matriz de Confusão para o algoritmo SVM da imagem datada do dia 31/01/2021..... | 55 |
| Tabela 13 - Acurácia do produtor e do usuário para o algoritmo SVM..... | 56 |

LISTA DE QUADROS E GRÁFICOS

| | |
|--|----|
| Quadro 1 - Alguns exemplos de índices espectrais empregados na literatura..... | 27 |
| Quadro 2 - Especificações técnicas do satélite Sentinel-2..... | 33 |
| Quadro 3 - Identificação das bandas espectrais do satélite Sentinel-2..... | 33 |
| Gráfico 1 - Comportamento espectral das classes datado do dia 07/01/2019..... | 43 |
| Gráfico 2 - Comportamento espectral das classes datado do dia 31/01/2021..... | 43 |

LISTA DE ABREVIATURAS E SIGLAS

ANM - Agência Nacional de Mineração

ANN - Artificial Neural Networks

CONAMA - Conselho Nacional do Meio Ambiente

EMBRAPA - Empresa Brasileira de Pesquisa Agropecuária

ESA - Agência Espacial Européia

EVI - Índice de Vegetação Melhorado

IBAMA - Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis

IBGE - Instituto Brasileiro de Geografia e Estatística

kNN - k-Nearest Neighbor

NDVI - Índice de Vegetação da Diferença Normalizada

NDWI - Índice de Água da Diferença Normalizada

MSI - Instrumento Multiespectral

PVI - Índice de Vegetação Perpendicular

QGIS - Quantum Geographic Information System

RF - Random Forest

RVI - Índice de Vegetação de Razão

SIG - Sistema de Informações Geográficas

SEMAD - Secretaria de Estado de Meio Ambiente e Desenvolvimento Sustentável de Minas Gerais

SIRGAS - Sistema de Referência Geocêntrico para as Américas

SVM - Support Vector Machine

SPOT - Satélite para Observação da Terra

USGS - Serviço Geológico dos Estados Unidos

SUMÁRIO

| | |
|--|----|
| 1 INTRODUÇÃO..... | 13 |
| 2 OBJETIVOS..... | 16 |
| 2.1 Objetivo Geral..... | 16 |
| 2.2 Objetivos Específicos..... | 16 |
| 3 REFERENCIAL TEÓRICO..... | 17 |
| 3.1 A atividade de mineração e o rompimento da barragem no município Brumadinho-MG.. | 17 |
| 3.2 Uso e cobertura do solo..... | 18 |
| 3.3 Sensoriamento Remoto..... | 20 |
| 3.4 Geoprocessamento | 22 |
| 3.5 Sensor MSI/Sentinel..... | 23 |
| 3.6 Índices Espectrais..... | 24 |
| 3.7 Classificação de Imagens Digitais..... | 27 |
| 4 MATERIAIS E METÓDOS..... | 30 |
| 4.1 Área de Estudo..... | 30 |
| 4.2 Classificação da Pesquisa..... | 31 |
| 4.3 Coleta de Dados..... | 31 |
| 4.4 Aquisição de Imagens..... | 32 |
| 4.5 Processamento Digital das Imagens..... | 34 |
| 4.6 Índices Espectrais..... | 34 |
| 4.6.1 Índice de Diferença Normalizada da Vegetação (<i>Normalized Difference Vegetation Index - NDVI</i>)..... | 34 |
| 4.6.2 Índice de Vegetação Melhorado (<i>Enhanced Vegetation Index - EVI</i>)..... | 35 |
| 4.6.3 Índice de Água da Diferença Normalizada (<i>Normalized difference water index - NDWI</i>)..... | 35 |
| 4.7 Classificação Supervisionada por Algoritmos de Aprendizado de Máquina..... | 36 |
| 5 RESULTADOS E DISCUSSÕES..... | 38 |
| 5.1 Determinação da extensão da região afetada pela lama de rejeitos..... | 38 |
| 5.2 Índices Espectrais..... | 39 |
| 5.3 Comportamento Espectral das Classes..... | 42 |
| 5.4 Classificação Supervisionada sobre o uso e cobertura do solo do município de Brumadinho-MG..... | 45 |
| 6 CONCLUSÕES..... | 58 |
| REFERÊNCIAS | 59 |

1. INTRODUÇÃO

As atividades de mineração envolvem a extração de minerais e recursos naturais do subsolo, que são utilizados em diversas indústrias e processos produtivos. A mineração é uma prática economicamente importante, pois gera empregos e contribui para o desenvolvimento de muitos países. Nesse contexto, a exploração de recursos minerais no Brasil tem suas origens na busca por ouro durante o período de ocupação do país. Ao longo desta época, os bandeirantes realizaram diversas expedições em busca de metais preciosos, que resultaram na definição de novas rotas para a ocupação do território. A exploração de ouro iniciou-se na região de Minas Gerais e, com o aumento da apropriação territorial do local e do conhecimento geológico, aconteceram novas descobertas de depósitos minerais (ANM, 2022).

A exploração de minério gera resíduos, que demandam a construção de barragens de rejeitos, e que nelas ficam os materiais indesejados. Esses resíduos são compostos por materiais indesejados ou de baixo valor comercial. Embora sejam uma forma comum de armazenamento de resíduos da mineração, as barragens de rejeitos apresentam riscos ambientais significativos, especialmente em caso de falhas ou rompimentos, que podem causar grandes impactos negativos à saúde humana e ao meio ambiente, e isso inclui a contaminação de rios, lagos e solos, além de danos à fauna e flora local. Há exemplos de casos recentes no Brasil que ilustram a gravidade dos desastres ambientais, como o ocorrido com a Samarco em 2015 e com a Vale em 2019. Esses rompimentos impactaram diretamente as cidades de Mariana e Brumadinho, em Minas Gerais, bem como muitas outras cidades, inclusive ultrapassando as fronteiras do estado (FREITAS *et al.*, 2019).

Em Brumadinho, a tragédia causou uma destruição ambiental significativa, o que afetou uma área de pelo menos 269,84 hectares. As consequências da ruptura revelaram que os resíduos da mineração causaram a devastação de 133,27 hectares da vegetação nativa da Mata Atlântica, além de 70,65 hectares das Áreas de Preservação Permanente (APP), localizadas ao longo dos corpos d'água impactados pela lama de rejeitos. A avaliação da área danificada foi realizada desde o trecho da barragem da mina Córrego do Feijão até o ponto em que ela se encontra com o rio Paraopeba (IBAMA, 2019). Diante disso, as consequências do desastre ainda não foram investigadas em sua totalidade.

Assim, para analisar extensas áreas, sem necessidade de contato físico e/ou visitas a campo, e ainda reduzir o tempo para elaboração dos dados e diminuição dos custos, se faz o emprego do sensoriamento remoto. Esse, utiliza imagens que medem a radiação

eletromagnética refletida ou emitida pelos objetos presentes na superfície terrestre, e disponibilizam essas informações em uma forma passível de serem interpretadas (LEOPOLDINO, 2020). Portanto, o uso de imagens de satélites tem sido cada vez mais frequente em estudos relacionados à análise de desastres ambientais. Um exemplo dessa aplicação é o trabalho de Freire *et al.* (2021), que adotou uma abordagem metodológica de sensoriamento remoto para monitorar os efeitos da contaminação do rio Paraopeba após o desastre ocorrido em Brumadinho-MG.

O desenvolvimento da tecnologia de sensoriamento remoto tem possibilitado o mapeamento do uso e da cobertura do solo mediante o uso de imagens orbitais desde a década de 70. A partir de um projeto conjunto entre a Agência Espacial Europeia (ESA) e a Comissão Europeia, em resposta ao Programa Copernicus, a série de satélites Sentinel foi lançada em 2014 e tem evoluído desde então (EMBRAPA, 2020).

De acordo Oliveira *et al.* (2014), o uso e cobertura do solo são indicadores importantes que revelam o estado ambiental e os efeitos da apropriação humana do patrimônio ambiental. Esses aspectos são cruciais para a compreensão da relação entre a sociedade e o meio ambiente, uma vez que a forma como a terra é utilizada pode ter impactos consideráveis na biodiversidade, nos ciclos hidrológicos, no clima e no âmbito socioeconômico. Para sintetizar informações sobre o uso, ocupação e cobertura do solo, é possível utilizar mapas que indicam a distribuição espacial dos padrões homogêneos de ação antrópica, identificáveis por meio de análise de imagens remotamente sensoriadas da superfície terrestre.

Para isso, existem técnicas de classificação que permitem o processamento das imagens de satélite, como por exemplo a classificação supervisionada utilizada neste trabalho. A classificação supervisionada é um método que emprega um conjunto de amostras de treinamento para identificar as classes existentes em uma imagem (INPE, 2006). As amostras de treinamento são regiões demarcadas na imagem que representam áreas no terreno caracterizadas por cada classe. Para determinar as classes a serem mapeadas e as áreas escolhidas como amostras de treinamento, é necessário que o analista possua conhecimento prévio da região retratada na imagem (QUARTAROLI; BATISTELLA, 2006).

Recentemente, em decorrência dos avanços na ciência da computação e nas tecnologias de Sistema de Informações Geográficas (SIG), houve uma ampla adoção dos métodos de classificação supervisionados. Esse aumento de popularidade se justifica pela notável robustez e precisão desses métodos em comparação com as abordagens não supervisionadas (JAMALI, 2019). Dentre os métodos supervisionados, estão os algoritmos de aprendizado de máquina

Random Forest (RF) e o Support Vector Machine (SVM), que têm apresentado desempenho positivo na classificação temática da paisagem (LI *et al.*, 2014).

O RF (BREIMAN, 2001), é um método de aprendizado conjunto para classificação e regressão que opera construindo várias árvores de decisão no momento do treinamento e produzindo a classe, que é o modo das saídas geradas por árvores individuais (SANTOS, 2020). Por sua vez, criado por Cortes & Vapnik (1995), o SVM demonstra habilidade para solucionar desafios de classificação e regressão, desenvolvendo a capacidade de generalização durante o processo de treinamento. O SVM procura identificar um plano de separação entre grupos que maximize a distância em relação aos elementos de cada grupo. Isso resulta em uma separação posicionada equidistantemente entre as duas classes (FONTANA, 2020).

Assim, ressalta-se o potencial do emprego do sensoriamento remoto na produção de dados cuja análise e interpretação podem apontar a dimensão de impactos ambientais e socioeconômicos. Dessa forma, o objetivo deste estudo é aplicar técnicas avançadas de classificação supervisionada, utilizando dados do satélite Sentinel-2, a fim de gerar informações capazes de analisar e interpretar os impactos socioambientais, por trabalhos futuros, decorrentes do vazamento de lama de rejeitos da barragem da Vale em Brumadinho, Minas Gerais, Brasil.

2. OBJETIVOS

2.1 Objetivo Geral

Identificar as mudanças no uso e cobertura do solo após o rompimento da barragem em Brumadinho, Minas Gerais, utilizando imagens do satélite Sentinel-2 por meio de classificação supervisionada.

2.2 Objetivos Específicos

- Delimitar a área impactada pela lama de rejeitos;
- Avaliar os índices espectrais NDVI, EVI e NDWI na região antes e após o rompimento da barragem;
- Realizar a classificação supervisionada do uso e cobertura do solo no município de Brumadinho;
- Comparar o desempenho dos algoritmos de aprendizado de máquina RF e SVM para determinar o mais eficaz na classificação de paisagens.

3. REFERENCIAL TEÓRICO

3.1 A atividade de mineração e o rompimento da barragem no município de Brumadinho-MG

A localização da cidade de Brumadinho está dentro da região metropolitana de Belo Horizonte, em Minas Gerais, que faz parte do “Quadrilátero Ferrífero”(COELHO, 2017). A área é caracterizada por uma forte presença da atividade mineradora, tanto dentro da cidade quanto em seus arredores. Em 1917, a Estação Brumadinho foi inaugurada junto com outras estações ferroviárias relevantes que foram estabelecidas entre 1917 e 1934. Essas novas estações causaram mudanças significativas no território, o que eventualmente contribuiu para a criação do município de Brumadinho em 1938. Dessa forma, o arranjo geográfico de Brumadinho, assim como o de outros municípios próximos, foi sendo progressivamente moldado pela atividade econômica de Minas Gerais e pelo sistema de transporte ferroviário, cujo crescimento estava relacionado à atração da riqueza mineral e à produção de café na região. A Mina do Córrego do Feijão iniciou suas primeiras atividades em 1941, por meio da empresa Companhia Mineração de Ferro e Carvão S.A., que possuía capital germânico, e que posteriormente passou a ser conhecida como Ferteco Mineração S.A. (COSTA, 2020).

A Ferteco Mineração utilizou o método de alteamento a montante para construir a barragem B1. Posteriormente, em abril de 2001, a mineradora Vale S.A. adquiriu a barragem. Com uma altura de 86 metros e comprimento de crista de 720 metros, a principal finalidade da barragem era armazenar resíduos do processo de beneficiamento úmido de minério de ferro, e a área ocupada pelos resíduos era de cerca de 250 mil metros quadrados. A segurança das barragens de rejeitos é um desafio para a engenharia, principalmente porque a construção de diques para armazenamento de rejeitos é feita com o material residual das atividades de mineração; a altura dos taludes da barragem é modificada à medida que a quantidade de rejeitos aumenta; falta de regulamentação para projetos de construção de barragens, especialmente em países em desenvolvimento; e há altos custos de manutenção após o fechamento da área de exploração (MINAS GERAIS, 2021).

Conforme Muñoz (2019), especialistas alertaram previamente sobre os perigos associados às barragens a montante, as quais não deveriam ser empregadas em países úmidos como o Brasil, em virtude do elevado risco de infiltração. O acidente registrado em Brumadinho ocorreu em uma barragem a montante, visto que, permite a ampliação vertical do dique mediante o próprio material descartado utilizado como base. Essa é uma das técnicas mais utilizadas no país para a construção de barragens, uma vez que é considerada mais econômica,

entretanto, é caracterizada por ser menos estável e mais propensa a acidentes (PASSARINHO, 2019). Mesmo diante dos avisos, houve o rompimento, e o desastre é considerado como um dos piores do país, devido à abrangência de pessoas afetadas e aos prejuízos causados ao meio ambiente.

A extensão da região afetada pelo derramamento da lama de rejeitos decorrente da ruptura da barragem foi de aproximadamente 290 hectares (SEMAD, 2019). Os resíduos de mineração consistem nos restos deixados após a extração do minério, ou seja, todos os detritos produzidos quando a água é usada para separar o minério, que não possuem valor comercial, podem ser definidos como rejeitos. Estes, são compostos de minúsculas partículas originárias do material explorado. A classificação do material pode ser feita com base em sua granulometria, sendo chamado de rejeitos granulares se for composto por materiais mais grossos ou lama se contiver partículas finas. Conseqüentemente, a lama que arrastou parte da mina da Vale, construções e estradas, apresentou perigos imediatos e futuros para a saúde daqueles que entraram em contato com o barro e para os moradores próximos ao rio Paraopeba (ODILLA, 2019).

O rompimento da barragem da mineradora Vale em Brumadinho resultou na perda trágica de 272 vidas humanas (GANDRA, 2022). Além das conseqüências fatais, o desastre que ocorreu na barragem B1 da mina Córrego do Feijão, controlada pela empresa Vale S/A, em 25 de janeiro de 2019, gerou impactos sociais, humanitários, ambientais e econômicos cuja extensão ainda não foi avaliada em sua totalidade. Esse acidente trouxe à tona a necessidade urgente de abordar questões que permanecem pendentes desde a ruptura da barragem de Fundão, em Mariana (MG), quatro anos antes (ANTUNES-ROCHA, 2020).

3.2 Uso e cobertura do solo

Conforme Carmo (2009), as mudanças feitas pelo homem na paisagem podem prejudicar a qualidade e disponibilidade dos recursos necessários para a sobrevivência, como solo, vegetação e corpos d'água. Nessa linearidade, aprender sobre as dinâmicas e transformações na utilização e cobertura do solo é importante para compreender questões de interesse histórico, ambiental, econômico, estrutural e/ou político para a tomada de decisões. Além disso, avaliar as mudanças e fatores que influenciaram e influenciam a paisagem é fundamental para subsidiar deliberações acerca da gestão do território.

De acordo com o IBGE (2022), é notória a facilidade de encontrar locais na superfície terrestre que não estejam imunes às transformações causadas por diversos fatores cotidianos.

Conforme aumenta a ocupação do solo, também surgem novas maneiras de identificar essas mudanças, como por exemplo, o uso de tecnologias de sensoriamento remoto e geoprocessamento. A coleta de informações sobre a cobertura e uso do solo é crucial para compreender a distribuição espacial das distintas formas de ocupação do espaço, e o monitoramento da cobertura e uso do solo. Aliado a isso, as atividades humanas no uso do solo podem modificar as condições naturais do meio ambiente, impactando a cobertura vegetal e gerando efeitos prejudiciais que precisam ser atentamente monitorados.

A percepção do meio ambiente e a criação de procedimentos para preservar e adquirir informações sobre o uso da terra baseiam-se na identificação e classificação precisa dessa utilização. As técnicas de sensoriamento remoto e sistemas de informações geográficas (SIGs) se converteram em instrumentos imprescindíveis para acompanhar a evolução das alterações no uso e ocupação do solo. Isso acontece porque essas técnicas permitem a atualização constante dos dados, processamento rápido e eficiência econômica (VAEZA *et al.*, 2010).

A elaboração de sistemas para classificar informações referentes ao uso do solo, coletadas por meio de técnicas de sensoriamento remoto, tem se desenvolvido cada vez mais. A qualidade e a variedade dos dados sobre o uso do solo são alteradas de acordo com a resolução espacial, radiométrica, espectral e temporal dos diferentes sistemas de sensores utilizados. A área mínima necessária para a descrição de uma categoria específica de uso do solo depende tanto da escala e da resolução dos dados originais, quanto das escalas de compilação e apresentação finais (VAEZA *et al.*, 2010).

A Resolução Espacial está ligada ao potencial que cada sensor possui em detectar os elementos existentes na superfície da terra. Nesse sentido, quanto maior for a resolução espacial, menor será o tamanho mínimo dos objetos que podem ser distinguidos pelo sensor. Aliado a isso, a Resolução Temporal, por sua vez, está associada ao intervalo de tempo em que as informações são coletadas, isto é, o período necessário para que um satélite retorne ao mesmo local. Normalmente, essa medida é expressa em dias, ou no caso de satélites geoestacionários, o tempo de revisita pode ser medido em minutos (LOBO, 2020).

A Resolução Espectral estabelece o número e a largura das faixas espectrais capturadas pelo sensor. Quanto maior a quantidade de bandas espectrais, maior será a resolução espectral. Geralmente, os sensores são classificados como multiespectrais (com algumas faixas espectrais, aproximadamente até 20) e hiper-espectrais, que possuem centenas de bandas por toda a extensão do espectro. Já a Resolução Radiométrica caracteriza a capacidade dos sensores em distinguir diferentes intensidades de radiação eletromagnética, ou seja, quantos níveis de cinza

o sensor é apto em detectar. Essa é explícita por 2^n , onde n é o número de bits especificado durante o desenvolvimento do sensor (LOBO, 2020).

3.3 Sensoriamento Remoto

Uma maneira abrangente de definir sensoriamento remoto é a obtenção de informações sobre um objeto ou alvo sem a necessidade de contato físico. Esse processo envolve a utilização da radiação eletromagnética gerada por fontes naturais, como o sol e a terra, ou por fontes artificiais, como o radar (RAMOS *et al.*, 2016).

Quartaroli *et al.* (2014), reforça que o sensoriamento remoto se refere à obtenção de informações sobre um determinado objeto por meio da análise de dados coletados por dispositivos que não estão fisicamente em contato com o objeto em estudo. E que, tais dispositivos, conhecidos como sensores remotos, têm a capacidade de captar a energia originária do objeto, transformá-la em um sinal que possa ser registrado e apresentá-lo em um formato apropriado para a extração de informações relevantes sobre o objeto em análise.

Figura 1 - Etapas do processo de aquisição e distribuição das imagens de sensoriamento remoto.



Fonte: ZANOTTA, 2019.

As imagens digitais provenientes do sensoriamento remoto são compostas por conjuntos de pixels, os quais descrevem a quantidade de energia que é emitida por uma determinada parte da superfície. Essa energia pode ser entendida como diferentes formas de ondas ou radiação eletromagnética, que possuem propriedades básicas e comportamentos previsíveis de acordo com as teorias físicas. A compreensão acerca dos alvos da superfície depende do conhecimento

prévio dessas interações, pois é a partir da quantidade de radiação que foi refletida ou emitida por eles que é possível realizar a interpretação (ZANOTTA, 2019).

De acordo com Moraes (2002), é possível observar a emissão de energia eletromagnética em corpos com temperatura superior a zero grau absoluto (0 Kelvin). Assim, é possível considerar qualquer objeto que possua uma temperatura maior do que zero como uma fonte de energia eletromagnética. É importante destacar que a energia eletromagnética não depende de um meio material para se propagar e se movimenta na forma de ondas eletromagnéticas com a velocidade da luz. Ao se propagar pelo espaço, a radiação eletromagnética pode interagir com superfícies ou objetos, sendo refletida, absorvida e/ou reemitida por estes. A quantidade de energia propagada depende das propriedades físico-químicas dos elementos irradiados, e o fluxo resultante pode fornecer informações valiosas sobre as características das superfícies ou objetos observados.

Conforme mencionado por Zanotta (2019), as diversas radiações emitidas pelo sol são comumente agrupadas em categorias específicas de comprimentos de onda que compartilham características semelhantes em relação à interação com a matéria ou sua aplicação prática na terra. Essa classificação é conhecida como espectro eletromagnético, sendo que sua divisão é subjetiva e pode variar de acordo com a aplicação e a referência utilizada. É importante destacar que cada comprimento de onda da radiação eletromagnética interage de maneira distinta e com intensidades diversas com os objetos terrestres. Dessa forma, a seleção dos comprimentos de onda das imagens a serem captadas é um dos aspectos mais importantes na determinação das propriedades de um sensor. Tais imagens não são delimitadas por um comprimento de onda individual, mas sim por intervalos estreitos conhecidos como bandas espectrais (MENESES; ALMEIDA, 2012).

Tabela 1 - Intervalos espectrais possíveis de serem usados pelos sensores remotos.

| 0,45 - 0,76 μ m <i>visível</i> | 0,76 - 1,2 μ m <i>infravermelho próximo</i> | 1,2 - 3,0 μ m <i>infravermelho de ondas curtas</i> | 3,0 - 5,0 μ m <i>infravermelho médio</i> | 5,0 μ m - 1mm <i>infravermelho termal</i> | 1mm - 100cm <i>micro-ondas</i> |
|---------------------------------------|--|---|---|--|-----------------------------------|
| toda faixa | 0,76 - 0,91 1,00 - 1,12 | 1,19 - 1,34 1,55 - 1,75 2,05 - 2,40 | 3,5 - 4,2 4,5 - 5,0 | 8,0 - 9,2 10,2 - 12,5 | 3,0 - 100 |

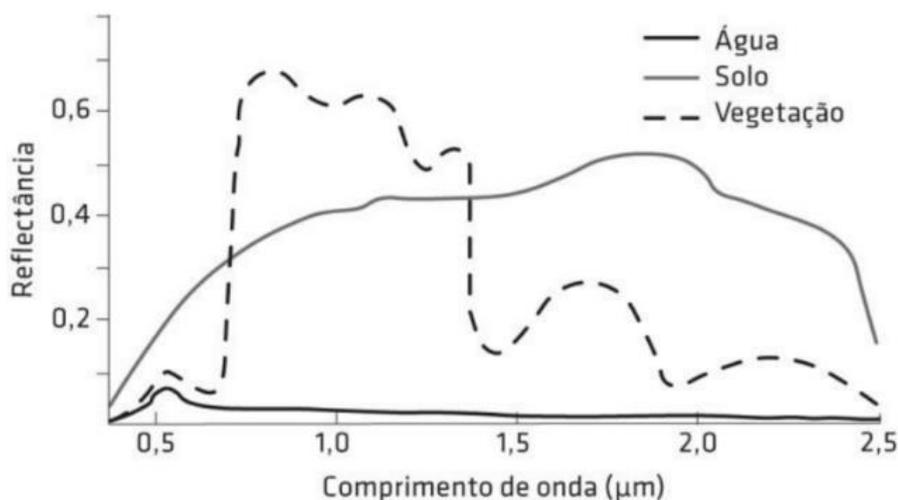
Fonte: MENESES E ALMEIDA (2012).

Meneses e Almeida (2012) sintetizam as principais particularidades dos intervalos espectrais empregados no sensoriamento remoto. A faixa visível é a região com elevada

intensidade de fluxo radiante e responsável pela interação com minerais e pigmentos da vegetação. O infravermelho próximo é transparente, mas apresenta algumas faixas de absorção, enquanto o infravermelho de ondas curtas é a região espectral geológica, pois é nesta faixa espectral que os vários minerais de alteração hidrotermal possuem suas características diagnósticas de absorção. O infravermelho médio é pouco usado, exceto para sensores meteorológicos e atmosféricos, e o infravermelho termal é excelente para detectar veios de quartzo nas rochas. Por último, a região de micro-ondas é utilizada com sensores ativos (radar), que conseguem operar em condições atmosféricas desfavoráveis, como nuvens ou chuvas, tanto de dia quanto à noite.

Segundo Zanotta (2019), a assinatura espectral é a curva que descreve a reflectância de um objeto em diferentes comprimentos de onda do espectro. A Figura 2 apresenta exemplos das assinaturas espectrais de água, solo e vegetação verde quando iluminadas por uma fonte de luz. Esse conceito é de extrema importância para o sensoriamento remoto, uma vez que as assinaturas espectrais dos objetos permitem a interpretação das imagens de satélite. Geralmente, as respostas espectrais em cada banda são comparadas com o conhecimento prévio das assinaturas espectrais dos diferentes objetos para identificar os alvos nas imagens.

Figura 2 - Assinatura espectral da água, do solo e da vegetação desde a faixa do visível até o infravermelho de ondas curtas (0,4-2,5 μ m).



Fonte: ZANOTTA, 2019.

3.4 Geoprocessamento

Segundo Rosa (2013), é possível conceituar o geoprocessamento como um conjunto de tecnologias voltadas para a coleta e processamento de dados espaciais, além da criação de

sistemas e aplicações com diferentes graus de complexidade. Em termos gerais, o termo geoprocessamento pode ser empregado para se referir a profissionais que lidam com cartografia digital, processamento digital de imagens e sistemas de informação geográfica. O processamento digital de imagens se refere ao conjunto de técnicas e procedimentos utilizados para manipular imagens digitais numericamente, com o objetivo de corrigir distorções e aprimorar a precisão na identificação de alvos. Já os sistemas de informação geográfica (SIGs) têm como função adquirir, armazenar, manipular, analisar e apresentar dados que estejam referenciados espacialmente. Exemplos de tais ferramentas incluem o ArcGIS, ArcVIEW, Qgis, Spring e Terraview.

Dentre as diversas ferramentas disponíveis no campo do geoprocessamento, uma das mais proeminentes é o Quantum GIS (QGIS), um software de Sistema de Informação Geográfica (SIG) de código aberto, livre e de uso gratuito. Com suas diversas funcionalidades, o QGIS permite a análise, visualização e gerenciamento de dados geoespaciais. O programa possibilita que os usuários criem mapas com múltiplas camadas, utilizando diversas projeções cartográficas, e que esses mapas tenham diferentes finalidades, como análises ambientais, urbanas, demográficas, entre outras (PEJOVIĆ *et al.*, 2014).

Existem diversos tipos de usos do geoprocessamento por meio de ferramentas de SIG, e cada um deles requer diferentes formas de manipulação de dados geográficos, que estão associados a diversas características e propriedades que variam no espaço e no tempo. Algumas dessas aplicações incluem a análise e o acompanhamento do crescimento urbano, mudanças de uso e cobertura do solo, monitoramento de recursos naturais, análise de vulnerabilidade ambiental e acompanhamento de eventos de precipitação, entre outros. Nessa perspectiva, alguns exemplos de trabalhos científicos que descrevem esse atual cenário foram elaborados por Dias (2021) e Cunha (2017). Os autores de ambos os artigos científicos fizeram uso do QGIS para elaboração de diferentes mapas.

3.5 Sensor MSI/Sentinel

A partir de 2014, a Agência Espacial Europeia (ESA) e a Comissão Europeia deram início ao lançamento da série de satélites Sentinel. Essa iniciativa foi desenvolvida para dar continuidade às missões antigas administradas pela ESA, com o objetivo de supervisionar os recursos naturais terrestres, o uso e a ocupação das terras, os ambientes marinhos, o clima e desastres naturais (EMBRAPA, 2020).

A missão consiste em utilizar pares de satélites especializados, cada um deles voltado para assuntos distintos. Os satélites Sentinel-1 têm a finalidade de monitorar tanto a terra quanto os oceanos e são equipados com dispositivos de radar. Os satélites Sentinel-2, por outro lado, foram projetados para monitorar a vegetação, solos e áreas costeiras e possuem um sensor óptico de alta precisão. Enquanto isso, a terceira série é específica para monitorar o ambiente marinho e possui sensores ópticos e radares especialmente projetados para essa finalidade. As séries 4 e 5, por sua vez, são utilizadas para monitorar a qualidade do ar (EMBRAPA, 2020).

Os objetivos do Sentinel-2 visam disponibilizar aquisições sistemáticas de imagens multiespectrais de alta definição em escala global, juntamente com uma frequência elevada de revisita. Aliado a isso, procura-se preservar a continuidade de imagens multiespectrais disponibilizadas pela série de satélites SPOT e pelo dispositivo USGS LANDSAT Thematic Mapper, apresentando informações de monitoramento para a nova geração de produtos operacionais, tais como cartografias de uso do solo, mapas de identificação de alterações no solo e variáveis geofísicas. Esses objetivos de alto nível, elaborados após consulta aos usuários, asseguram que o Sentinel-2 traga uma contribuição significativa para temas importantes do Copernicus, como a mudança climática, monitoramento de terras, gerenciamento de emergências e segurança (ESA, 2020).

Ainda de acordo com a Embrapa (2020), o Sentinel-2A, lançado em 2015 pela ESA, é o primeiro satélite óptico da série a ser operado pela agência. O satélite é equipado com o sensor multiespectral MSI, que possui 13 bandas espectrais que variam de 443 a 2190 nm. As bandas do visível possuem uma resolução espacial de 10m, enquanto as do infravermelho possuem 20m e as de correção atmosférica possuem 60m. O Sentinel-2A é usado no monitoramento da agricultura, das florestas, das áreas costeiras, dos recursos hídricos internos, dos fenômenos naturais e do uso e ocupação do solo. Seu sucessor, o Sentinel-2B, lançado em 2017, compartilha os mesmos objetivos e também é equipado com o sensor MSI.

Pesquisas têm sido desenvolvidas nesta área, como os estudos realizados por Freires *et al.* (2019) e Wolfer *et al.* (2020), os quais comprovam que imagens de satélite fornecem resultados satisfatórios para o mapeamento de uso e cobertura da terra.

3.6 Índices Espectrais

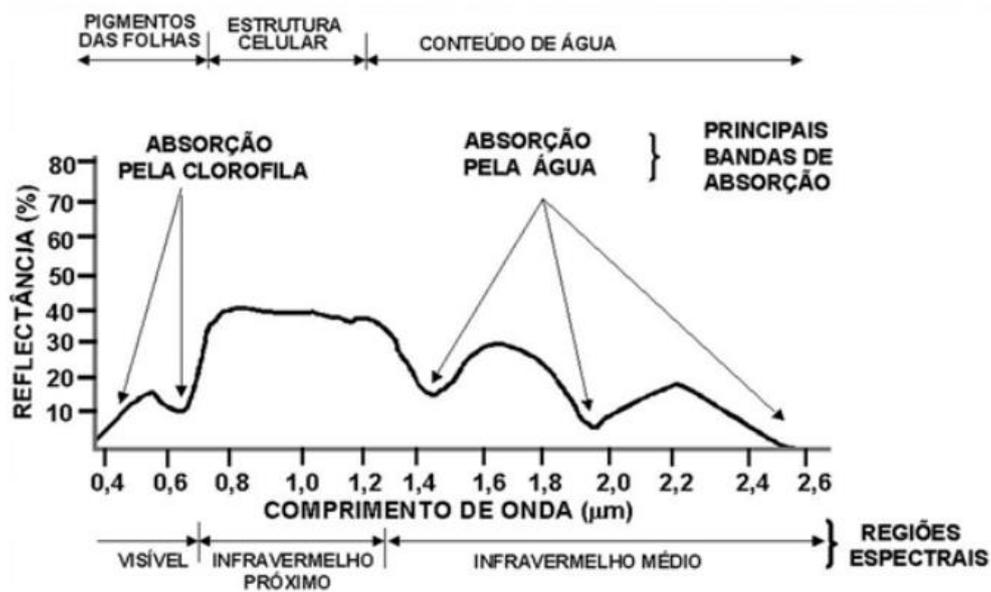
Os índices espectrais derivados de imagens de satélite são obtidos através de cálculos matemáticos que envolvem os valores numéricos dos pixels das diferentes bandas da imagem. Esses índices fornecem uma avaliação qualitativa e quantitativa da superfície terrestre, o que os torna uma ferramenta valiosa para análises ambientais por meio do sensoriamento remoto

(OLIVEIRA *et al.*, 2009). Segundo Silva *et al.* (2019), os índices são empregados em diversas aplicações ambientais, principalmente na identificação de diferentes objetos presentes em imagens de satélite. Os índices, tais como o Índice de Vegetação da Diferença Normalizada (NDVI) e o Índice de Água da Diferença Normalizada (NDWI), são relevantes ferramentas para monitorar as mudanças naturais ou humanas que ocorrem nas superfícies terrestres.

A vegetação passa por diferentes fases fenológicas que afetam sua estrutura e pigmentação, dependendo do estágio de crescimento e saúde da planta. Essas variações impactam diretamente a resposta espectral do alvo (NOVO, 2010). As folhas exibem características espectrais distintas nos comprimentos de onda do espectro eletromagnético visível e infravermelho próximo. É possível, portanto, utilizar essa peculiaridade para destacar a presença de vegetação em imagens, empregando certos os índices.

A vegetação é identificada pela sua baixa capacidade de refletir luz visível, devido à absorção da radiação pelos pigmentos fotossintéticos, e alta capacidade de refletir luz infravermelha próxima, graças à propagação da radiação dentro das folhas devido à sua estrutura celular. No entanto, no infravermelho médio, a capacidade de reflexão diminui novamente devido à alta absorção de água. Assim, quanto mais densa for a vegetação em uma determinada área, menor será a sua capacidade de refletir luz visível e maior a sua capacidade de refletir luz infravermelha próxima. A maioria dos índices de vegetação é baseada nas regiões espectrais do vermelho e infravermelho próximo, que apresentam um comportamento oposto. Quando a densidade da cobertura vegetal é maior, há uma menor capacidade de reflexão na luz visível devido à maior presença de pigmentos fotossintéticos e uma maior capacidade de reflexão do infravermelho próximo devido à estrutura da planta saudável (PONZONI *et al.*, 2012; LUCCHETTA; OLIVEIRA, 2020).

Figura 3 - Curva de reflectância das plantas.

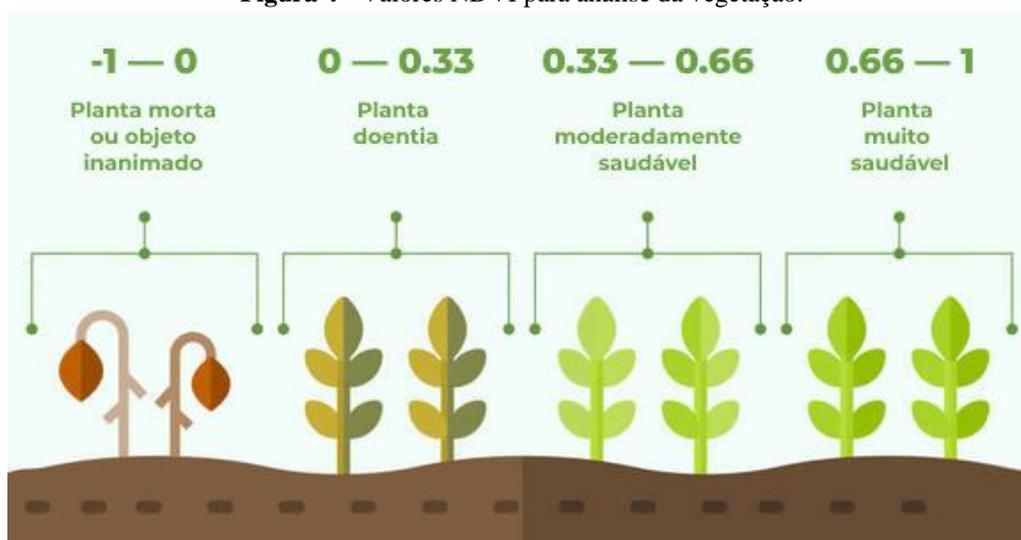


Fonte: BERTONI *et al.*, 2020.

Os índices de vegetação são amplamente aplicáveis e têm sido desenvolvidas várias equações com diferentes níveis de complexidade. O RVI (Índice de Vegetação de Razão), que consiste na razão direta entre a banda do infravermelho próximo e a banda do vermelho, é o índice mais simples. Já o PVI (Índice de Vegetação Perpendicular), que leva em consideração a emissividade do solo, é o índice mais complexo. O NDVI (Índice de Vegetação por Diferença Normalizada) é o índice mais comumente utilizado, pois normaliza a razão entre as bandas do infravermelho próximo e a banda do vermelho (SILVA, 2014).

O índice mencionado por último tem uma escala que varia de -1 a +1, sendo que valores acima de 0 indicam a presença de vegetação. Quanto mais elevado o valor do índice de vegetação por diferença normalizada (NDVI), maior a quantidade ou o vigor da vegetação na área em estudo. A fórmula utilizada para calcular o NDVI, de acordo com Rouse, J.W. et al (1973), é a seguinte: $NDVI = (NIR - Vermelho) / (NIR + Vermelho)$, sendo que o NIR é uma luz infravermelha e o Vermelho é uma luz visível de cor vermelha.

Figura 4 - Valores NDVI para análise da vegetação.



Fonte: EOS, 2019.

Ao efetuar os cálculos dos índices de vegetação, é comum empregar a banda do vermelho e infravermelho próximo. A banda do vermelho é onde ocorre uma significativa absorção da radiação eletromagnética pela clorofila. Já a faixa do infravermelho próximo está relacionada com a vitalidade e estrutura da vegetação devido à sua elevada reflectância. Dessa forma, a vegetação em boas condições apresentará baixa reflectância no vermelho e alta reflectância no infravermelho próximo.

Quadro 1 - Alguns exemplos de índices espectrais empregados na literatura.

| Índices de Vegetação | | Equação | Referência |
|----------------------|---|--|-------------------------------------|
| SR | Razão Simples | NIR/RED | Jordan, C. F. (1969) |
| NDVI | Índice de Vegetação por Diferença Normalizada | $\frac{NIR - RED}{NIR + RED}$ | Rouse, J.W. <i>et al.</i> (1973) |
| EVI | Índice de Vegetação Melhorado | $2,5 * \frac{(NIR - RED)}{(NIR + 6RED - 7,5BLUE + 1)}$ | Justice, C. O. <i>et al.</i> (1998) |
| NDWI | Índice de Água da Diferença Normalizada | $\frac{GREEN - SWIR}{GREEN + SWIR}$ | Gao, B.C (1996) |

Fonte: Autoria própria, 2023.

3.7 Classificação de Imagens Digitais

Segundo Meneses e Almeida (2012), as técnicas de classificação digital de imagens têm facilitado a extração de informações das imagens sem exigir interpretação subjetiva dos

indivíduos e com isso, um menor esforço por parte do analista. O resultado dessa categorização é uma imagem digital que funciona como um mapa de pixels classificados, e os padrões homogêneos das diferentes classes de objetos são representados em polígonos (mapa digital temático).

Para Machado (2020), a classificação é um método que envolve extrair dados de imagens para reconhecer padrões e objetos similares. Essa técnica é amplamente empregada no campo do sensoriamento remoto com o propósito de mapear áreas da superfície terrestre que correspondem a temas específicos de interesse. Como apontado por Costa *et al.* (2016), a aplicação dessas tecnologias possibilita a inclusão de informações espaciais de maior escala, que viabiliza o aperfeiçoamento de diversos mapas temáticos.

Ao utilizar a classificação digital, o mapeamento é realizado pelo reconhecimento de objetos semelhantes e padrões representados por um agrupamento de pixels. Os algoritmos responsáveis pela classificação digital são chamados de “classificadores” e a categorização pode ser feita pixel a pixel ou região/objeto (JENSEN, 2011; REX *et al.*, 2018).

Os métodos utilizados para classificação de imagens digitais são diversos, e podem ser separados de acordo com diferentes critérios: classificação espectral e espacial, classificação paramétrica e não-paramétrica e classificação supervisionada ou não supervisionada (MENESES; ALMEIDA, 2012). Dentre os métodos mencionados, a classificação supervisionada possui maior exatidão, visto que geralmente é obtida por meio dos dados de campo e fundamento prévio sobre a área e ocupação do solo que se pretende investigar e classificar (OLIVEIRA *et al.*, 2014).

A técnica de classificação supervisionada é usada na análise de dados espaciais e emprega algoritmos de aprendizado de máquina para identificar e caracterizar áreas em imagens de satélite. Nessa técnica, o usuário seleciona alguns pixels que correspondem às classes desejadas e delega ao computador a responsabilidade de localizar todos os demais pixels que pertencem a essas classes, com base em uma regra estatística predefinida. Essa abordagem permite a identificação e análise de transformações no uso e cobertura do solo ao longo do tempo, tendo como base a diferenciação de várias classes com comportamentos espectrais distintos (VALE, 2018).

Logo, os procedimentos automatizados no processamento são capazes de identificar todos os pixels com valores iguais ou similares nas imagens, a fim de produzir um mapa digital automático de vegetação. Ao finalizar o processo de categorização, o resultado é uma imagem digital que consiste em um mapa de "pixels" classificados, representados por meio de gráficos, símbolos ou cores (MENESES; ALMEIDA, 2012). Esta constatação encontra respaldo no

estudo desenvolvido por Alves *et al.* (2023), no qual os pesquisadores realizaram a classificação supervisionada utilizando imagens de satélite para a identificação de alvos ambientais em uma região específica. Os resultados da classificação foram posteriormente representados por meio de mapas.

Os métodos supervisionados abrangem algoritmos paramétricos, como máxima verossimilhança, distância mínima e classificadores Bayesianos, além de algoritmos não paramétricos, como aqueles associados ao aprendizado de máquina (PHIRI; MORGENROTH, 2017). Dentro do conjunto de algoritmos de aprendizado de máquina, estão o Random Forest (RF) e a Support Vector Machine (SVM).

De acordo com Holanda (2021), o RF é um tipo de classificador que se baseia em conjuntos de árvores de decisão, incorporando aleatoriedade em sua abordagem. Em termos práticos, o algoritmo realiza a divisão de cada nó da árvore utilizando o melhor preditor escolhido a partir de um subconjunto aleatório de características disponíveis para esse nó específico. Ao criar um novo conjunto de dados por meio de amostragem com reposição do conjunto original, o RF desenvolve uma árvore de decisão através da seleção aleatória de recursos.

Já o SVM tem a capacidade de resolver problemas de separação linear e não-linear, sendo aplicável tanto em tarefas de regressão quanto de classificação. O objetivo do algoritmo é identificar um hiperplano ótimo que maximize a separação entre dados pertencentes a diferentes classes. Esse hiperplano é importante para determinar a margem, que representa a distância entre o hiperplano e a instância mais próxima de cada classe. A margem influencia diretamente na eficiência da separação entre as duas classes, sendo um fator determinante para a qualidade do modelo (OLIVEIRA, 2017).

4. MATERIAIS E MÉTODOS

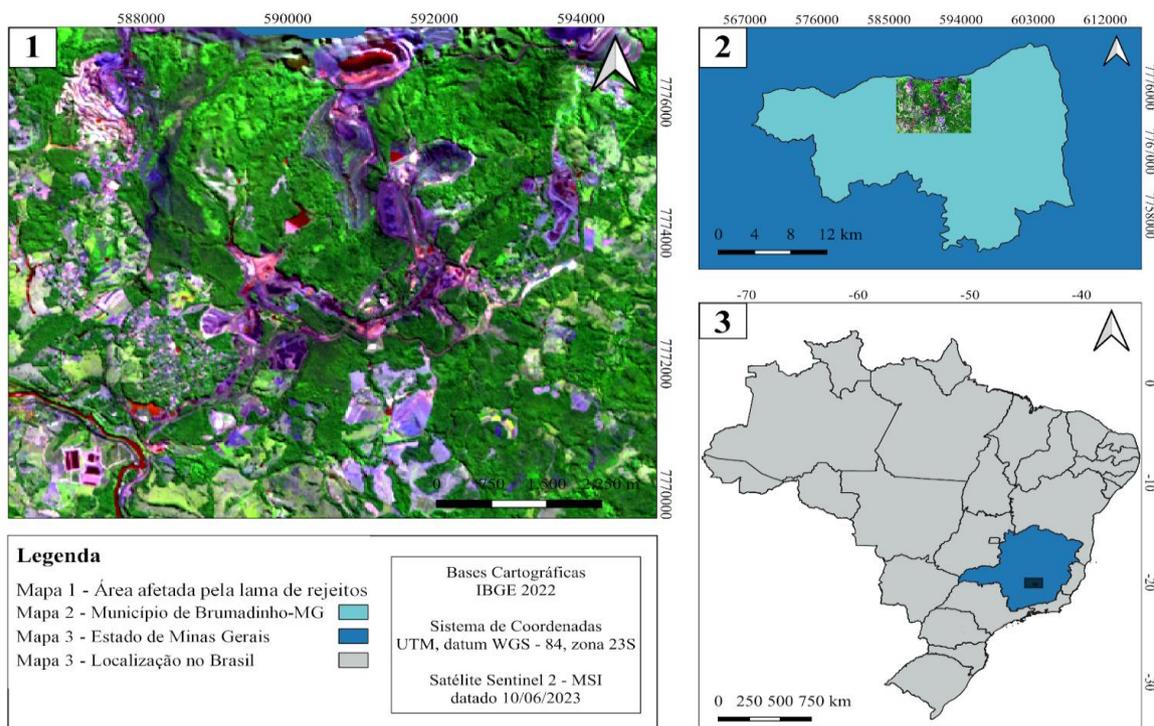
4.1 Área de Estudo

O estudo abrange a área atingida pela lama de rejeitos do rompimento da barragem B1 da Mina do Córrego do Feijão, em Brumadinho, Minas Gerais. Essa área se estende desde a barragem até o Rio Paraopeba, e compreende as coordenadas (20°07' 00 "S, 44°07' 02"W) e (20°09' 25 "S, 44°09' 32"W) (Google Earth, 2023).

O conjunto de barragens da mina Córrego do Feijão, da mineradora Vale, estava localizado acima da cidade de Brumadinho, na região Metropolitana de Belo Horizonte. O desastre resultou no deslocamento de aproximadamente 12 milhões de metros cúbicos de rejeitos (MINAS GERAIS, 2021).

A extensão afetada pela lama de rejeitos de mineração abrangeu aproximadamente 290 hectares, desde a área próxima à barragem até o ponto de encontro com o Rio Paraopeba, equivalente a cerca de 300 campos de futebol. Posteriormente, essa lama seguiu o curso do Rio Paraopeba. Além das instalações administrativas da empresa de mineração, o desastre impactou diretamente bairros residenciais, comunidades vizinhas, estabelecimentos de hospedagem, áreas usadas para cultivo e pastagens, além de estradas e vias rurais (SEMAD, 2019). A Figura 5 representa o mapa da área de estudo.

Figura 5 - Área afetada pelo rompimento da barragem, em Brumadinho, Minas Gerais.



Fonte: Autoria própria, 2023.

Em Brumadinho, os solos predominantes são os do tipo Latossolo Vermelho e Latossolo Vermelho-Amarelo. Em menor quantidade, também são encontrados Cambissolos Háplicos e Cambissolos Húmicos, cujas variações estão associadas ao relevo local (COELHO *et al.*, 2017).

De acordo com Sousa e Lobato (2021) os Latossolos Vermelhos e Vermelho-Amarelos se destacam pela sua profundidade, porosidade e permeabilidade. Essas características os tornam propícios para a agricultura e pastagens. Já os Cambissolos Háplicos e Húmicos apresentam heterogeneidade, variando em suas características de acordo com o local. São solos bem drenados a imperfeitamente drenados, com profundidade variável e coloração bruna ou bruno-amarelada (CUNHA *et al.*, 2021).

A floresta estacional semidecidual é a vegetação típica na região. O bioma principal é o Cerrado, no entanto, a área mais próxima ao município de Brumadinho pertence à Mata Atlântica, abrigando a maior parte das unidades de conservação (EMBRAPA, 2019). Quanto ao clima, caracteriza-se como Cwa, um clima temperado úmido, com períodos secos no inverno e verões quentes, acompanhado por um relevo montanhoso (COELHO *et al.*, 2017).

4.2 Classificação da Pesquisa

A presente pesquisa adota uma abordagem quali-quantitativa. A utilização de técnicas como análise de imagens de satélite, cálculo de índices espectrais e classificação supervisionada do uso e cobertura do solo oferece uma base quantitativa, fornecendo dados numéricos sobre as mudanças observadas. Por outro lado, a interpretação dos resultados, a análise das causas e consequências das mudanças e a discussão em relação à literatura existente são abordagens qualitativas que enriquecem a compreensão do fenômeno estudado.

Além disso, a pesquisa é descritiva, pois seu principal objetivo é descrever as mudanças no uso e cobertura do solo após o rompimento da barragem de Brumadinho.

4.3 Coleta de Dados

Para determinar a extensão afetada pela lama de rejeitos, foi obtido o dado vetorial (shapefile) datado de 29 de janeiro de 2019, fornecido pelo IBGE (2019). Inicialmente, o vetor estava em formato de linhas, sendo essencial convertê-lo em um polígono para viabilizar o cálculo da área, expressa em hectares. Esse processo foi executado por meio do software de código aberto QGIS na versão 3.28.6, utilizando a funcionalidade específica de conversão de linhas para polígonos disponível no programa. Além disso, o cálculo da área foi realizado dentro

da tabela de atributos, por meio da função calculadora de campo, considerando o sistema de referência SIRGAS 2000 para garantir precisão nos resultados.

A delimitação do polígono que representa a extensão afetada pelos rejeitos da barragem de Brumadinho, foi realizada por meio da interpretação de imagens orbitais. Os metadados das imagens utilizadas para essa análise correspondem aos dados capturados no ano de 2019, precisamente em 29 de janeiro, pelo sensor GeoEye-1, com resolução espacial de 0,50 metros (IBGE, 2019).

O GeoEye-1 é um satélite de observação da terra de alta resolução, lançado em 2008. Ele possui dois sensores: um pancromático, com resolução espacial de 46 cm, e um multiespectral, com resolução espacial de 1,84 m. O satélite é capaz de adquirir imagens de grandes áreas do planeta, com intervalos de revisita de até 3 dias. Essa capacidade permite o mapeamento de fenômenos distribuídos em extensas áreas, em escalas cartográficas grandes (EMPRAPA, 2019).

4.4 Aquisição de Imagens

Para analisar a região afetada pela lama de rejeitos, foram utilizadas duas imagens obtidas gratuitamente do site Copernicus (<https://www.copernicus.eu/en>). Essas imagens foram adquiridas pelo Sensor MSI a bordo do satélite Sentinel-2, no nível 2A, dispensando a necessidade de correção radiométrica e atmosférica. Uma das imagens foi capturada em 07 de janeiro de 2019, antes do desastre do rompimento da barragem, enquanto a segunda é datada de 31 de janeiro de 2021, aproximadamente dois anos após o ocorrido. A escolha delas e de seus períodos correspondentes baseou-se na qualidade das imagens disponíveis no site, considerando a ausência de nuvens. Ambas as capturas foram realizadas durante o verão, na mesma estação do ano, garantindo assim uma comparação mais precisa e significativa.

As imagens utilizadas no estudo possuem uma resolução espacial de 20 metros para as nove bandas espectrais B02, B03, B04, B05, B06, B07, B8A, B11 e B12. Aliado a isso, o satélite Sentinel-2 possui uma capacidade de revisita de 10 dias. Os quadros 2 e 3 apresentam as especificações técnicas do satélite Sentinel-2 e a identificação das bandas espectrais, respectivamente.

Quadro 2 - Especificações técnicas do satélite Sentinel-2.

| | |
|--------------------------------------|---|
| Órbita | Circular, heliossíncrona, descendente, 98.5623° de inclinação |
| Altitude | 786 Km |
| Alcance espectral | 443 a 2190 nanômetros |
| Cobertura espectral | 13 bandas espectrais |
| Cobertura de repetição | 10 dias, 5 dias no Equador |
| Resolução Radiométrica - Quantização | 12 bits por pixel |

Fonte: Adaptado de ENGESAT, 2015.

Quadro 3 - Identificação das bandas espectrais do satélite Sentinel-2.

| Nº da Banda | Nome da Banda | Comprimento de Onda Central (nanômetros) | Resolução Espacial (metros) |
|--------------------|----------------------------------|---|------------------------------------|
| B01 | Aerossols (Aerossol) | 443 | 60 |
| B02 | Blue (Azul) | 490 | 10 |
| B03 | Green (Verde) | 560 | 10 |
| B04 | Red (Vermelho) | 665 | 10 |
| B05 | Red Edge 1 (Borda do vermelho 1) | 705 | 20 |
| B06 | Red Edge 2 (Borda do vermelho 2) | 740 | 20 |
| B07 | Red Edge 3 (Borda do vermelho 3) | 783 | 20 |
| B08 | NIR | 842 | 10 |
| B08A | Red Edge 4 (Borda do vermelho 4) | 865 | 20 |
| B09 | Water Vapor (Vapor d'água) | 940 | 60 |
| B10 | Cirrus | 1375 | 60 |
| B11 | SWIR 1 | 1610 | 20 |
| B12 | SWIR 2 | 2190 | 20 |

Fonte: Adaptado de ENGESAT, 2015.

4.5 Processamento Digital das Imagens

Após o download das imagens provenientes do satélite Sentinel-2, disponíveis no site Copernicus, os arquivos raster correspondentes foram abertos no software R, na versão 4.3.1 (RStudio versão 2023.09.1), por meio do pacote *raster* (HIJMANS, 2023). Com o auxílio desse pacote, foi viável utilizar a função *stack* para carregar e agrupar todas as bandas espectrais (B02, B03, B04, B05, B06, B07, B8A, B11, B12) em um único arquivo, fundamental para a realização do estudo.

Em seguida, dentro do RStudio, foram carregados os pacotes *rgdal* (BIVAND *et al.*, 2023) e *sp* (BIVAND *et al.*, 2013). Posteriormente, o arquivo shapefile referente ao município de Brumadinho, Minas Gerais, baixado do site do Instituto Brasileiro de Geografia e Estatística (IBGE), foi importado utilizando a função *readOGR* para abrir o arquivo vetorial. Para garantir a mesma projeção geográfica, a função *spTransform* foi aplicada a ambos os arquivos. Isso possibilitou o recorte adequado do arquivo raster, contendo as bandas, para a área de interesse definida pelo shapefile do município de Brumadinho. O processo de recorte foi realizado por meio da função *crop*, uma ferramenta do R usada para recortar um objeto geográfico, neste caso, o arquivo raster. Essas etapas de processamento digital das imagens realizadas no RStudio foram fundamentais para organizar as informações necessárias ao cálculo dos índices espectrais.

4.6 Índices Espectrais

4.6.1 Índice da Diferença Normalizada da Vegetação (Normalized Difference Vegetation Index - NDVI)

O NDVI é uma ferramenta valiosa para medir a cobertura vegetal. Ele pode ser usado para mapear a cobertura vegetal, estimar a produtividade agrícola, monitorar a vitalidade das plantas e detectar mudanças na cobertura vegetal ao longo do tempo.

Para calcular o NDVI proposto por ROUSE *et al.* (1973), foi aplicada a seguinte Equação (1) dentro do ambiente do RStudio:

$$\text{NDVI} = (\text{B8A} - \text{B04}) / (\text{B8A} + \text{B04}) \quad (1)$$

O NDVI é a diferença normalizada entre a faixa do infravermelho próximo (B8A) e a faixa do vermelho (B04).

4.6.2 Índice de Vegetação Melhorado (*Enhanced Vegetation Index - EVI*)

Para calcular o EVI proposto por Justice, C. O. *et al.* (1998), foi empregada a Equação (2) no ambiente do RStudio:

$$EVI = (2.5*((B8A-B04)/10000))/(B8A/10000+6*B04/10000-7.5*B02/10000+1) \quad (2)$$

O EVI é projetado para avaliar a vigorosidade e densidade da vegetação, representando uma melhoria em relação ao NDVI. Essa adaptação torna o EVI particularmente eficaz em regiões com vegetação densa, superando as limitações do NDVI, que ocasionalmente não consegue captar de maneira adequada essas áreas mais densas. Seu cálculo requer as bandas de infravermelho próximo (B8A), a faixa do vermelho (B04), e a faixa do azul (B02). O valor 10000 inserido na Equação (2) foi utilizado no RStudio para normalizar os dados. Assim, um valor de EVI de -1 indica ausência de vegetação na superfície, enquanto um valor de EVI de 1 indica uma cobertura por vegetação densa.

4.6.3 Índice de Água da Diferença Normalizada (*Normalized difference water index - NDWI*)

Para calcular o NDWI proposto por Gao, B.C (1996), foi aplicada a Equação (3) no ambiente do RStudio:

$$NDWI = (B03-B12) / (B03+B12) \quad (3)$$

O NDWI é utilizado para separar áreas que são água de áreas que não são água. Para o cálculo deste índice são utilizadas as bandas do SWIR 2 (Infravermelho de ondas curtas) (B12) e a faixa do verde (B03). Valores positivos do NDWI indicam áreas com alta reflectância da água, o que sugere a presença de água. Enquanto que, valores negativos ou próximos de zero apontam para superfícies como solo ou vegetação, o que indica baixa reflectância da água e sugere a ausência de água na área estudada.

Após o cálculo dos índices espectrais relevantes para a pesquisa, as duas imagens processadas no RStudio, de antes e após o rompimento da barragem, foram importadas para o software livre QGIS versão 3.28.6 para que fosse realizada a coleta das amostras de treinamento das classes de uso e cobertura do solo. Para a realização da amostragem foi criado um arquivo vetorial contendo polígonos correspondentes a sete classes temáticas, sendo essas Agricultura, Água, Vegetação, Pastagem, Solo Exposto, Área Urbana e Área de Mineração. Ao todo, foram coletadas 50 amostras de treinamento para cada uma das classes.

4.7 Classificação Supervisionada por Algoritmos de Aprendizado de Máquina

Para a realização da classificação supervisionada das duas imagens, uma anterior ao acidente e outra posterior, utilizou-se dois algoritmos de aprendizado de máquina, sendo eles o Random Forest (RF) e o Support Vector Machine (SVM). Para tanto, foram utilizados os pacotes *caret* (KUHN, 2008), *rgdal* (BIVAND *et al.*, 2023), *raster* (HIJMANS, 2023), *dplyr* (WICKHAM *et al.*, 2023), *caTools* (TUSZYNSKI, 2021), *randomForest* (LIAW & WIENER, 2002) e *e1071* (MEYER, 2023) disponíveis no software R versão 4.3.1, utilizando o RStudio (versão 2023.09.1).

Inicialmente, foram carregadas na interface gráfica do RStudio as bandas espectrais do satélite Sentinel-2, sendo estas B2, B3, B4, B5, B6, B7, B8A, B11 e B12, juntamente com os índices espectrais (NDVI, EVI e NDWI) em um único arquivo, previamente calculados. A partir do arquivo vetorial que continha informações sobre as 7 classes amostrais, foi gerada uma planilha contendo os valores dos pixels (Números Digitais) correspondentes a cada banda e índice espectral. Os valores resultantes da correlação entre o arquivo contendo as bandas e índices espectrais e os respectivos tipos de uso e cobertura do solo, presentes no arquivo com as 7 classes temáticas, formaram a base de dados para o treinamento dos algoritmos. Para realizar essa associação entre os arquivos e obter os pixels relacionados a cada classe de interesse, foi utilizada a função *merge*. Em seguida, realizou-se uma análise exploratória das classes por meio da criação de um gráfico que relaciona a reflectância com o comprimento de onda.

O método de validação cruzada k-fold é amplamente reconhecido e empregado. Essa abordagem envolve a divisão do conjunto de dados em subgrupos, cada um contendo uma quantidade aproximadamente igual de amostras. Posteriormente, um dos subgrupos é separado para ser utilizado como grupo de validação ou teste. Os demais subgrupos são empregados para treinar o modelo, que é então aplicado ao grupo de teste para comparar os resultados e calcular a taxa de erro (MENDES, 2019). Neste contexto, a partir da planilha contendo as amostras, foi preciso realizar uma divisão para a construção de um conjunto destinado ao treinamento do modelo e outro para validar sua eficácia. Para tal, no ambiente RStudio, procedeu-se com a segregação dos dados em dois conjuntos distintos: o primeiro, correspondente a 70% do conjunto total, foi reservado para treinar o algoritmo, enquanto os restantes 30% foram alocados para validar o desempenho do algoritmo.

A separação dos dados de treinamento e validação foi realizada de maneira aleatória, visando à representatividade das amostras. Para assegurar a reprodutibilidade dos resultados,

foi empregada a função *set.seed(1234)*. A separação das amostras foi conduzida usando a função *sample.split*, a qual oferece a vantagem de preservar proporções equivalentes de dados por classes durante a divisão. Posteriormente, uma planilha em formato CSV foi gerada, contendo as amostras destinadas aos conjuntos de treinamento e validação. Essa etapa viabilizou a continuação do processo de classificação supervisionada.

Com base nos conjuntos de dados de treino e validação, foram aplicados dois métodos de Aprendizado de Máquina, o RF e o SVM. Estes métodos, reconhecidos por sua robustez, viabilizaram a realização do estudo mesmo diante de um grande volume de dados. Para tanto, a execução dos algoritmos incluiu a utilização da função *set.seed(1234)* para assegurar a aleatoriedade das amostras. Além disso, empregaram-se as funções *randomForest* e *SVM* correspondentes a cada método. Na sequência, procedeu-se à validação dos modelos por meio da função *predict*, permitindo a geração das matrizes de confusão.

A escolha da acurácia global como parâmetro se deu devido ao seu papel em indicar o grau de precisão e ausência de erros em um determinado valor, tornando-se um critério importante na avaliação de imagens classificadas. Seu cálculo envolve a razão entre o número de pixels classificados corretamente e o número total de pixels da imagem.

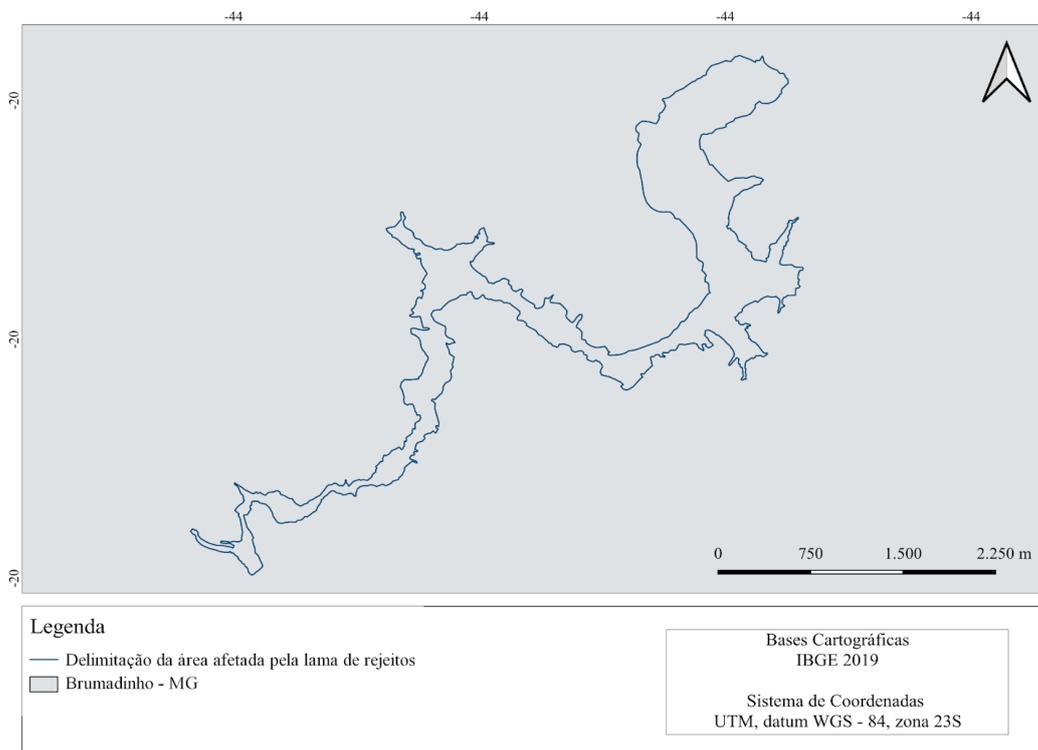
5. RESULTADOS E DISCUSSÕES

Através das análises realizadas foi delimitada a área afetada pela lama de rejeitos, proporcionando uma compreensão acerca da extensão do impacto, corroborando com os resultados encontrados na literatura. A utilização dos índices espectrais foi essencial para interpretar as mudanças ocorridas no solo após o rompimento da barragem. O comportamento espectral das classes temáticas revelou variações específicas em diferentes áreas da região de estudo. A classificação supervisionada mostrou transformações no uso e cobertura do solo ao longo dos dois anos, isso permite uma análise a respeito das implicações socioeconômicas e ambientais.

5.1 Determinação da extensão da região afetada pela lama de rejeitos

O cálculo da área afetada foi conduzido como parte essencial da análise, buscando quantificar numericamente a extensão do impacto causado pela lama de rejeitos. A transformação de linhas para polígonos permitiu delimitar de forma precisa a área de interesse. Em seguida, procedeu-se ao cálculo preciso da área afetada, expressa em hectares, fornecendo uma medida mais tangível e compreensível da extensão do impacto ambiental. A Figura 6 representa a área de interesse afetada pela lama de rejeitos.

Figura 6 - Delimitação da área afetada pela lama de rejeitos.



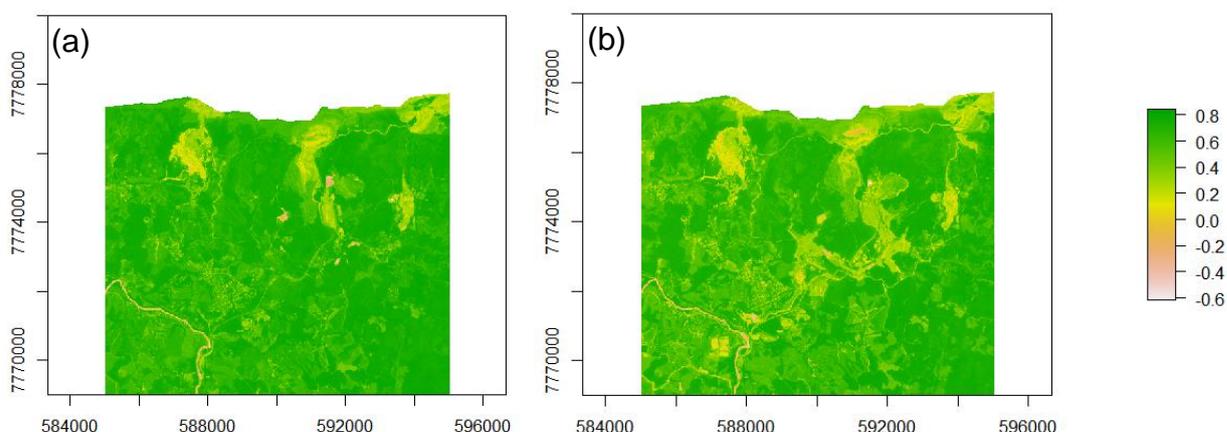
Fonte: Autoria própria, 2023.

A área calculada a partir do arquivo vetorial (.shp) disponibilizado pelo IBGE (2019) foi de aproximadamente 298,55 hectares. Este resultado se assemelha ao encontrado por Pereira *et al.* (2019). De acordo com os pesquisadores, os rejeitos cobriram uma extensão de 297,28 hectares de terras, predominantemente áreas de baixa altitude e relativamente planas, localizadas nas proximidades dos leitos de cursos d'água. Ademais, segundo dados oficiais do IBGE (2019 apud LUCCHETTA; OLIVEIRA, 2020), a área impactada é de 297 hectares. A discrepância equivale a cerca de 0,52% da área calculada a partir do arquivo vetorial. É importante ressaltar que essa diferença na área está associada a uma possível inclusão de uma parcela do polígono, proveniente da conversão do vetor linha para o vetor polígono, disponibilizado pelo IBGE.

5.2 Índices Espectrais

Os cálculos dos Índice de Vegetação por Diferença Normalizada (NDVI), Índice de Vegetação Aprimorado (EVI) e Índice de Água por Diferença Normalizada (NDWI), realizados no ambiente do RStudio, revelaram um significativo impacto adverso na região de estudo após o acidente do rompimento da barragem de minério em Brumadinho-MG. Essa constatação foi obtida ao comparar as imagens anterior e posterior ao desastre.

Figura 7 - NDVI antes (a) e após (b) o rompimento da barragem de Brumadinho, Minas Gerais (Janeiro 2019 - Janeiro 2021).



Fonte: Autoria própria, 2023.

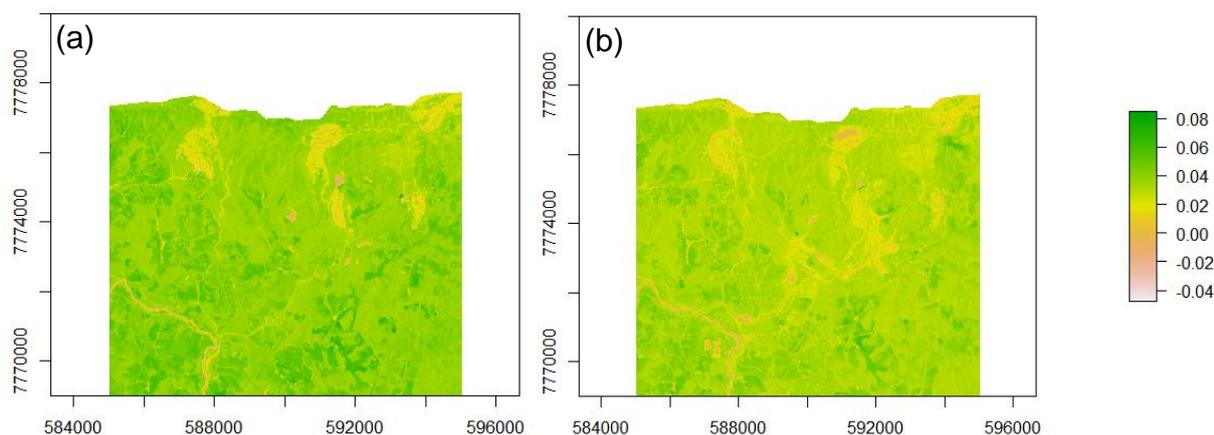
Na primeira figura, nota-se que a região de Brumadinho apresentava um NDVI elevado antes do acidente, os valores mantiveram-se acima de 0,6, indicando uma presença significativa de vegetação. Entretanto, na figura posterior ao rompimento, são evidenciados valores reduzidos do NDVI, inferiores a 0,2 no trecho afetado pela lama de rejeitos, mesmo após dois anos do rompimento da barragem. Esse cenário indica que a vitalidade da vegetação foi comprometida. O NDVI varia de -1 a +1. Valores negativos indicam áreas de água, aqueles muito próximos de 0 representam superfícies não vegetadas e, quanto mais próximo de 1, maior é a densidade da vegetação (PONZONI *et al.*, 2012). Neste contexto, os valores mais elevados do NDVI se concentram em regiões com vegetação densa, enquanto os valores mais baixos são encontrados em áreas de pastagem, corpos d'água, zonas urbanas, locais de mineração e áreas com solo exposto.

Por meio da avaliação do NDVI pode-se perceber, principalmente nas áreas mais próximas da barragem, os efeitos da lama de rejeitos no solo, ao se espalhar pela região, a lama soterrou grande parte da vegetação existente. Esse soterramento impede a realização da fotossíntese e respiração pelas plantas, levando à morte ou danos severos.

Outro fator a ser considerado é que as substâncias tóxicas, como metais pesados e produtos químicos, contidas na lama de rejeitos contaminaram o solo, comprometendo a qualidade e a capacidade do solo de sustentar o crescimento das plantas. Essa situação é evidenciada em uma pesquisa realizada por Ramos *et al.* (2021), na qual os pesquisadores destacam que análises do solo em Brumadinho revelaram a presença de vários contaminantes em concentrações superiores às estabelecidas pelo Conselho Nacional do Meio Ambiente (CONAMA). Além disso, foram identificados poluentes altamente tóxicos tanto para o solo quanto para os seres humanos quando em excesso, como ferro, manganês, cobre, bário, chumbo e mercúrio. É importante ressaltar que os metais pesados possuem elevada toxicidade e persistem por longos períodos no ambiente devido à sua baixa degradabilidade.

Além do NDVI, com o objetivo de avaliar áreas com vegetação de maior densidade, o EVI também foi analisado nos dois períodos (Figura 8).

Figura 8 - EVI antes (a) e após (b) o rompimento da barragem de Brumadinho, Minas Gerais (Janeiro 2019 - Janeiro 2021).



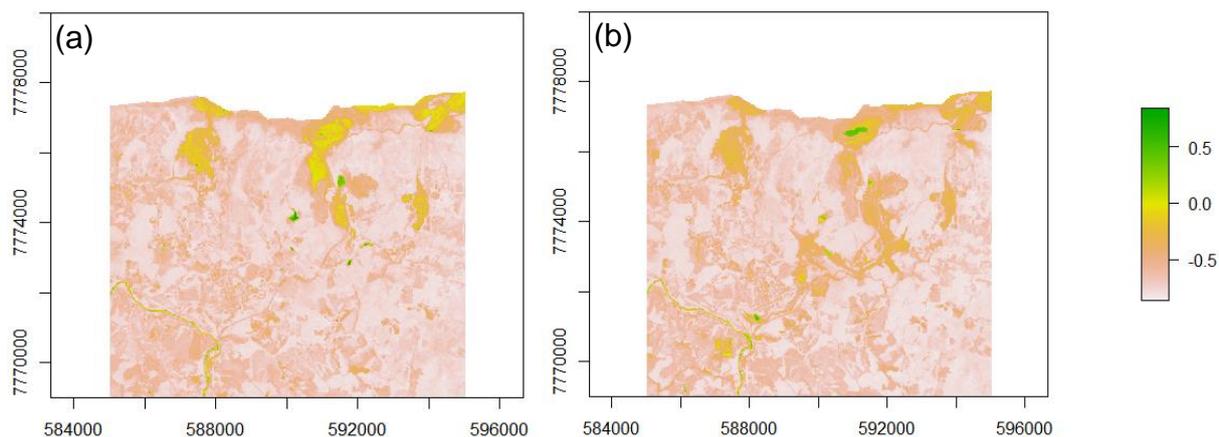
Fonte: Autoria própria, 2023.

O EVI é uma melhoria do NDVI. Ele foi desenvolvido para aprimorar a detecção da vegetação, especialmente em áreas com maior densidade de biomassa. Seu propósito inclui reduzir a interferência do sinal proveniente do solo e da atmosfera na resposta do dossel vegetativo (PONZONI *et al.*, 2012). Sob essa análise, foi notável que a região em questão, conforme mostrada nas imagens acima, não possui uma cobertura vegetal muito densa, como é o caso da densidade na floresta Amazônica. Isso se evidencia pelos valores superiores de EVI alcançando apenas 0,08, o que é considerado baixo. Ademais, semelhante ao cálculo do NDVI, a comparação entre as duas figuras revela o impacto significativo do rompimento da barragem na vegetação local. A propagação da lama de rejeitos cobriu e destruiu a vegetação, resultando em uma redução no índice EVI, chegando a valores inferiores a 0,02.

Considerando que o EVI é capaz de lidar melhor com a complexidade estrutural da vegetação, fornecendo uma avaliação mais precisa da densidade e vitalidade das plantas, o índice representou maior ausência de áreas de vegetação. Por outro lado, o NDVI evidenciou melhor as áreas de solo exposto, devido à presença de vegetação bem marcada em algumas áreas.

No intuito de avaliar as áreas de superfície alagada e úmida, o NDWI também foi avaliado, conforme apresentado na Figura 9.

Figura 9 - NDWI antes (a) e após (b) o rompimento da barragem de Brumadinho, Minas Gerais (Janeiro 2019 - Janeiro 2021).



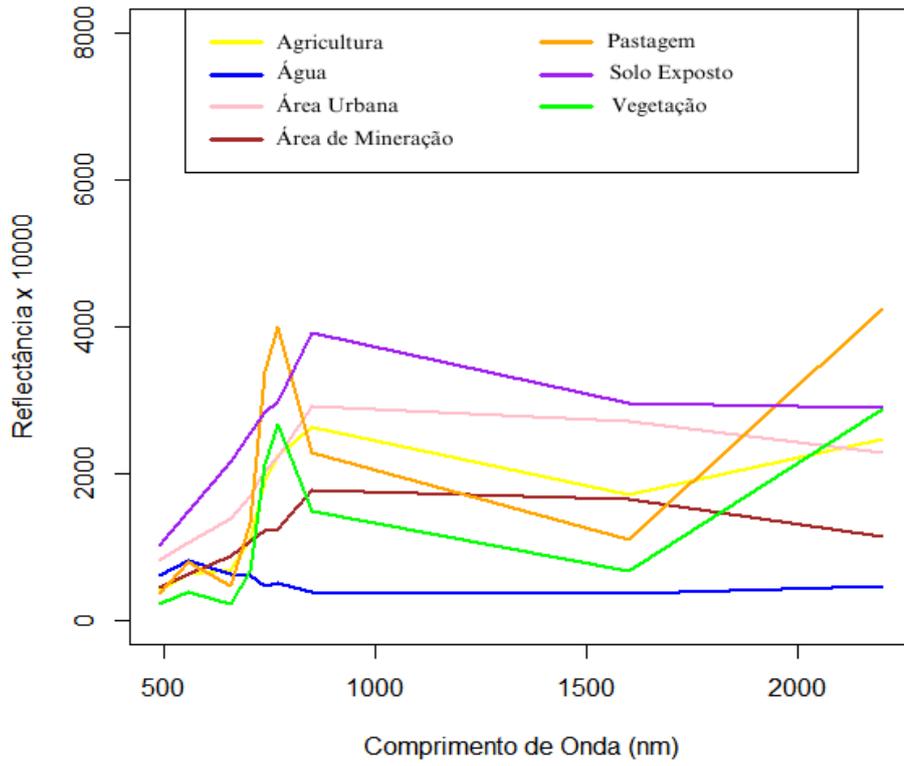
Fonte: Autoria própria, 2023.

Nas imagens apresentadas, o cálculo do NDWI foi empregado para realçar as áreas que contém água, e sua escala varia de -1 a +1. Os valores positivos do índice espectral, indicados pela cor verde, representam a presença de água. Por outro lado, valores inferiores a zero denotam áreas de solo exposto, vegetação, regiões de mineração e ambientes urbanos. Valores próximos de zero identificam áreas de transição entre a presença de água e outras classes. Na figura que antecede o acidente, é perceptível a presença da barragem da Mina Córrego do Feijão, que posteriormente sofreu o rompimento.

5.3 Comportamento Espectral das Classes

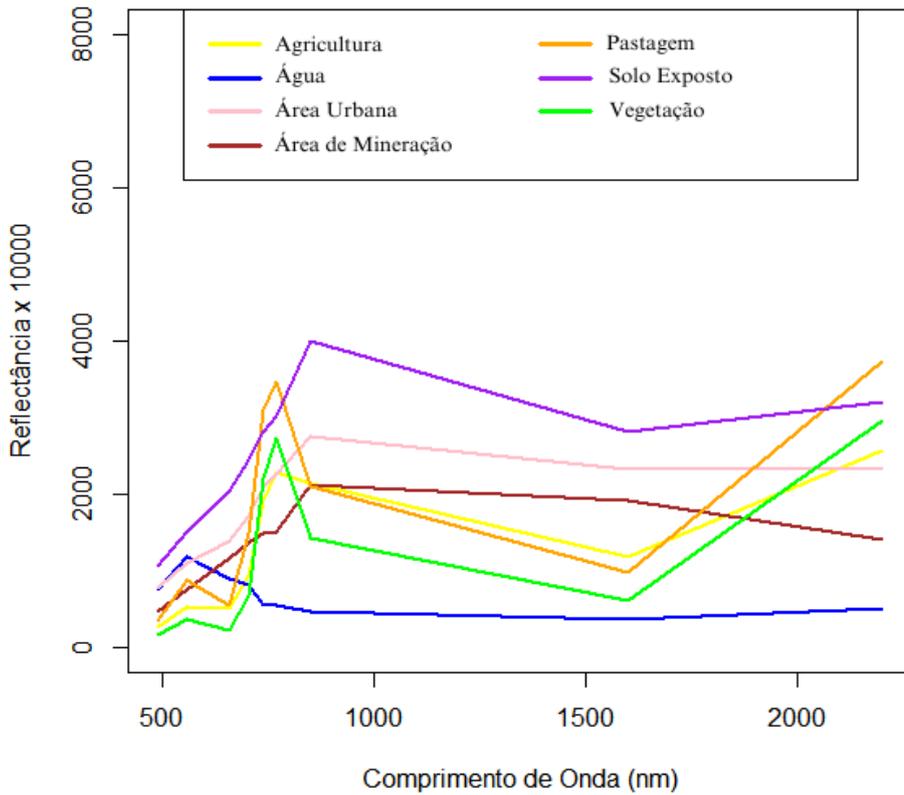
Para analisar o comportamento espectral das classes agricultura, água, área urbana, área de mineração, pastagem, solo exposto e vegetação no ambiente do RStudio, foram empregados os comprimentos de ondas centrais das imagens provenientes do satélite Sentinel-2, descritos no Quadro 3 - Identificação das bandas espectrais do satélite Sentinel-2.

Gráfico 1 - Comportamento espectral das classes datado do dia 07/01/2019.



Fonte: Autoria própria, 2023.

Gráfico 2 - Comportamento espectral das classes datado do dia 31/01/2021.



Fonte: Autoria própria, 2023.

O comportamento espectral é influenciado, por diversos fatores, como pela radiância do objeto, a radiância difusa da atmosfera, a estação do ano e a geometria de observação e medição. Quando as características físico-químicas de um objeto mudam, sua radiância também é afetada. Alvos semelhantes exibem padrões parecidos de refletância e absorvância para diferentes comprimentos de onda da radiação incidente, mesmo que a quantidade de reflectância seja diferente (ALCÂNTARA, 2016).

A região do visível (400 - 700 nm) é caracterizada pela absorção da radiação solar pela clorofila, pigmento presente nas folhas das plantas. Por esse motivo, áreas com vegetação, como agricultura e pastagem, exibem baixa reflectância nesta faixa de comprimento de onda. Especificamente, a pastagem mostra um pico de reflectância maior na região visível (700 nm) em comparação com as classes agricultura e vegetação, conforme observado em ambos os gráficos. Por outro lado, áreas desprovidas de vegetação, como água, área urbana, área de mineração e solo exposto, demonstram uma reflectância considerável na região do espectro visível.

Para a região do infravermelho próximo (700 - 1400 nm) nos dois gráficos, as classes vegetação, agricultura e pastagem, apresentam alta reflectância nesta região do espectro. A classe solo exposto também demonstra uma boa capacidade de reflexão. Por outro lado, a água se destaca por ter a menor reflectância entre todas as classes. A água, por natureza, absorve a radiação na região do infravermelho próximo. Portanto, apresenta a menor reflectância nessa faixa do espectro.

Na região do infravermelho de ondas curtas (1400 - 2500 nm) a classe água volta a apresentar uma leve reflectância. As classes vegetação, agricultura e pastagem novamente exibem baixa reflectância, seguida por um pico característico. Já as demais classes, área urbana, área de mineração e solo exposto a reflectância diminui ligeiramente nessa faixa. Esse comportamento reflete as características espectrais distintas de cada categoria, contribuindo para a análise diferenciada das superfícies terrestres na região do infravermelho de ondas curtas.

Apesar das respostas espectrais serem semelhantes entre as classes nas duas imagens, observa-se uma certa diferença entre os alvos. Essa disparidade mínima pode ser atribuída a uma variedade de fatores, os quais são relevantes destacar, tais como: diferenças nas condições atmosféricas durante a aquisição das imagens, variações na posição solar durante a captura das imagens, pois podem influenciar a quantidade de luz solar incidente, e principalmente, mudanças nas características da superfície da área que podem resultar em diferentes níveis de reflectância.

5.4 Classificação Supervisionada sobre o uso e cobertura do solo do município de Brumadinho-MG.

No ambiente RStudio, realizou-se a classificação do uso e cobertura do solo para as duas imagens do satélite Sentinel-2, uma capturada antes do acidente e outra posterior ao rompimento. Para esse propósito, foi empregado os dois algoritmos de aprendizado de máquina, o Random Forest (RF) e o Support Vector Machine (SVM). As tabelas 2 e 3 apresentam os valores de acurácia global e kappa gerados pela classificação desses algoritmos, considerando o conjunto de dados de validação. Vale ressaltar que os dados de validação são usados para avaliar o desempenho dos modelos treinados.

Tabela 2 - Resultado da Acurácia global e Kappa para os algoritmos RF e SVM, utilizando imagem anterior ao rompimento da barragem (07/01/2019).

| Algoritmos | Acurácia global | Kappa |
|-------------------|------------------------|--------------|
| RF | 0,9939 | 0,9895 |
| SVM | 0,9749 | 0,9562 |

Fonte: Autoria própria, 2023.

Tabela 3 - Resultado da Acurácia global e Kappa para os algoritmos RF e SVM, utilizando imagem posterior ao rompimento da barragem (31/01/2021).

| Algoritmos | Acurácia global | Kappa |
|-------------------|------------------------|--------------|
| RF | 0,9924 | 0,984 |
| SVM | 0,9755 | 0,947 |

Fonte: Autoria própria, 2023.

A análise das tabelas indica que os algoritmos RF e SVM apresentaram desempenhos semelhantes em termos de acurácia global e kappa, quando utilizados para identificar os diferentes usos e cobertura do solo a partir de um conjunto de dados disponibilizados. Neste contexto, em seu estudo, Rosa (2018) realizou uma comparação entre algoritmos de aprendizado de máquina para classificar a área urbana da cidade de São Paulo, utilizando

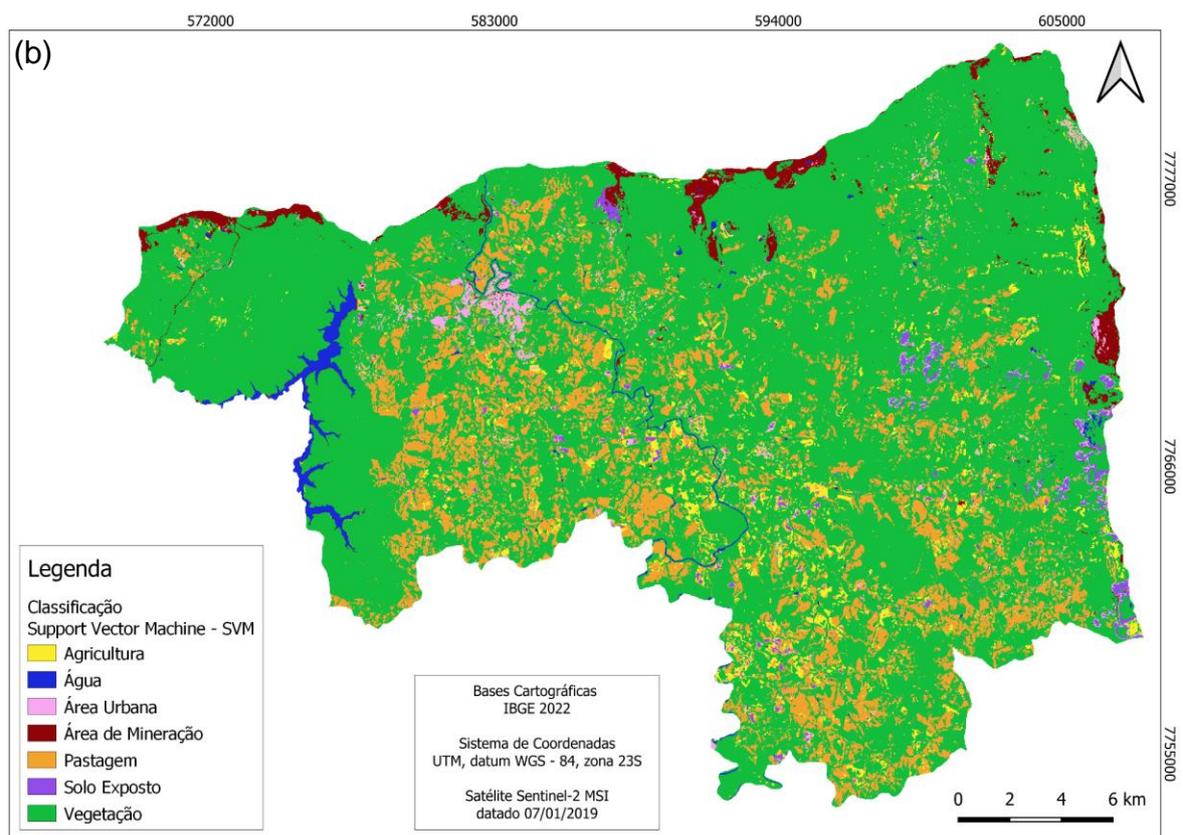
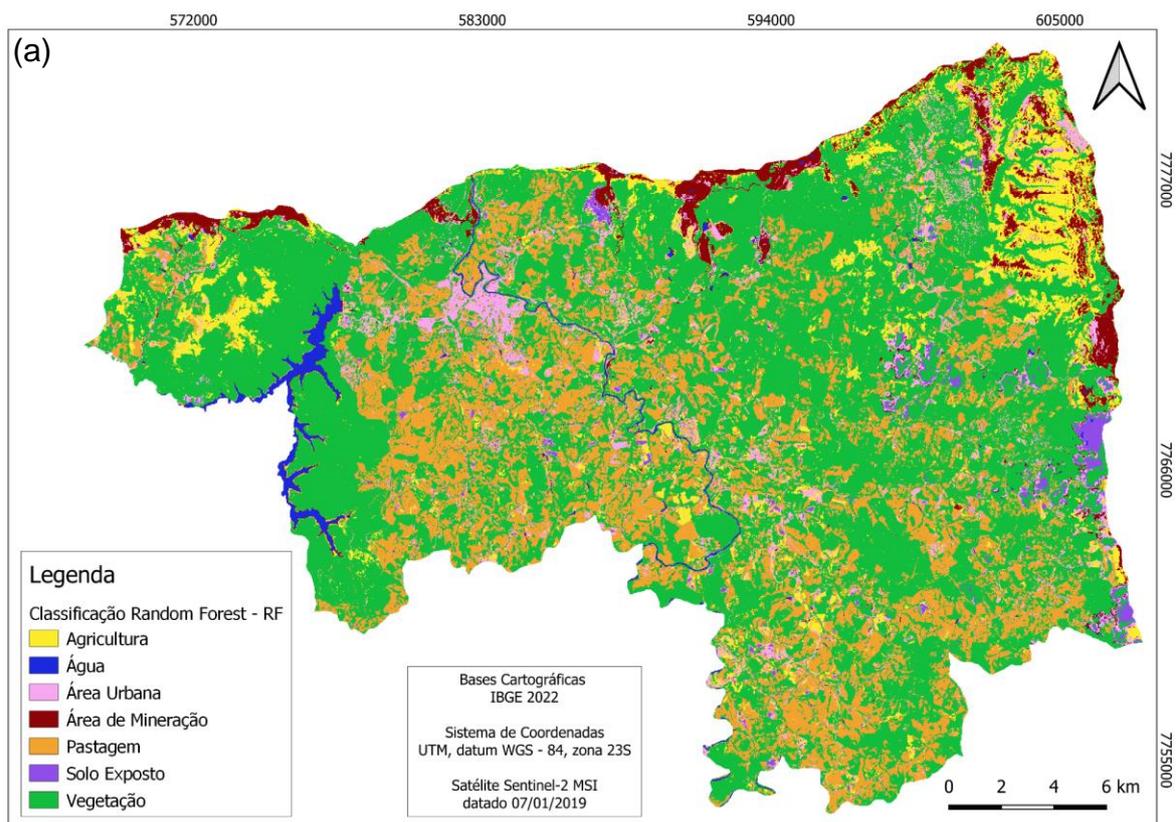
imagens MSI/Sentinel-2A como base. Os resultados revelaram que o algoritmo RF apresentou valores de Acurácia Global e Kappa superior em relação ao SVM, com valores de 0,872, 0,8578 e 0,843, 0,8256 respectivamente. Esses valores se alinham com os resultados encontrados nesta pesquisa, reforçando o melhor desempenho do algoritmo RF quando aplicado a imagens do Sentinel-2.

Com base nos resultados obtidos, nos quais foram alcançados valores de acurácia global e kappa superiores a 90%, é plausível afirmar que tanto o algoritmo RF quanto o SVM demonstraram eficácia na classificação do uso e cobertura da terra. Essa constatação sugere que esses algoritmos podem ser aplicados de maneira efetiva na análise de imagens do satélite Sentinel-2 em regiões que compartilham características semelhantes às da área de estudo, considerando a heterogeneidade da superfície.

Alves *et al.* (2023) identificou diferentes áreas como plantações, corpos aquáticos, áreas urbanas, matas, solo exposto e pastagens em Minas Gerais, Brasil. Foram empregadas informações de imagem dos satélites Landsat-8, Sentinel-1 e Sentinel-2. Distintos métodos de classificação supervisionada, como RF, rpart1SE e svmLinear2, foram testados. Os valores mais elevados de acurácia e kappa foram observados para o algoritmo RF, seguido por svmLinear2 e rpart1SE. O que demonstra a eficácia do RF para gerar mapeamento de paisagem temática da superfície terrestre.

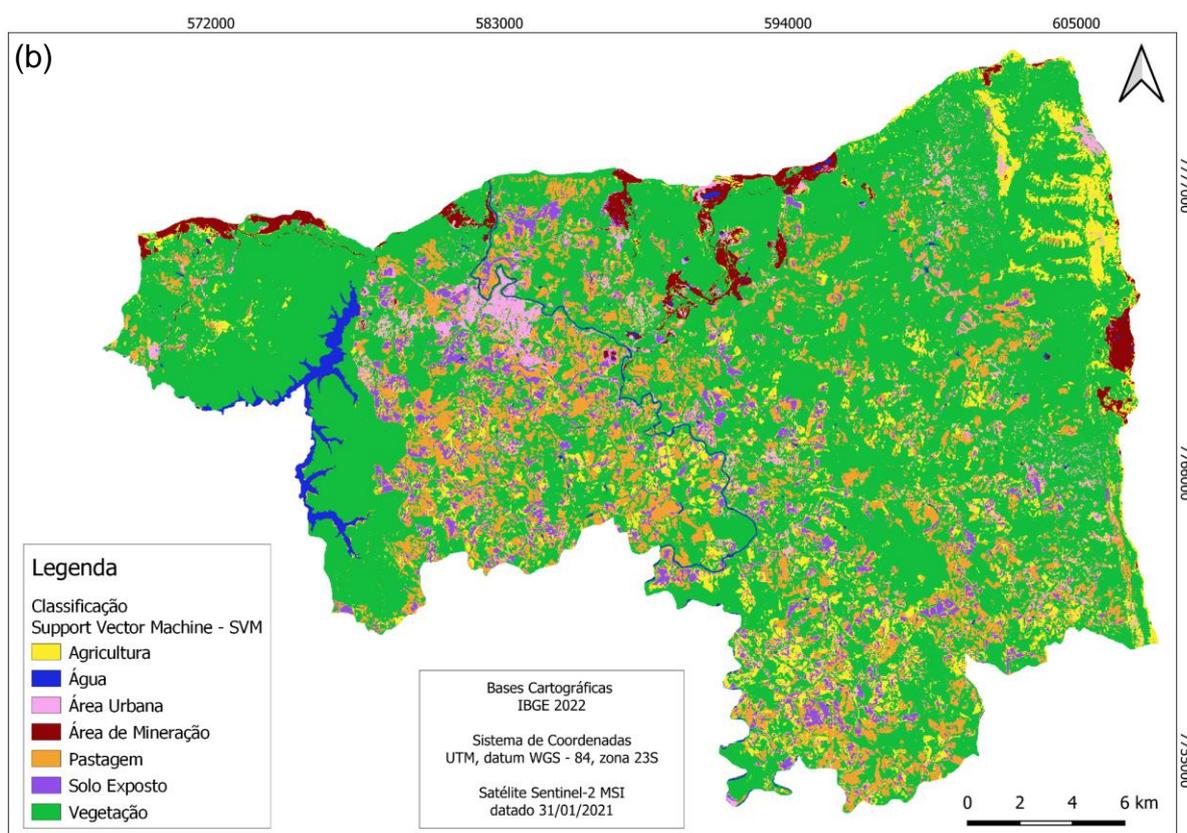
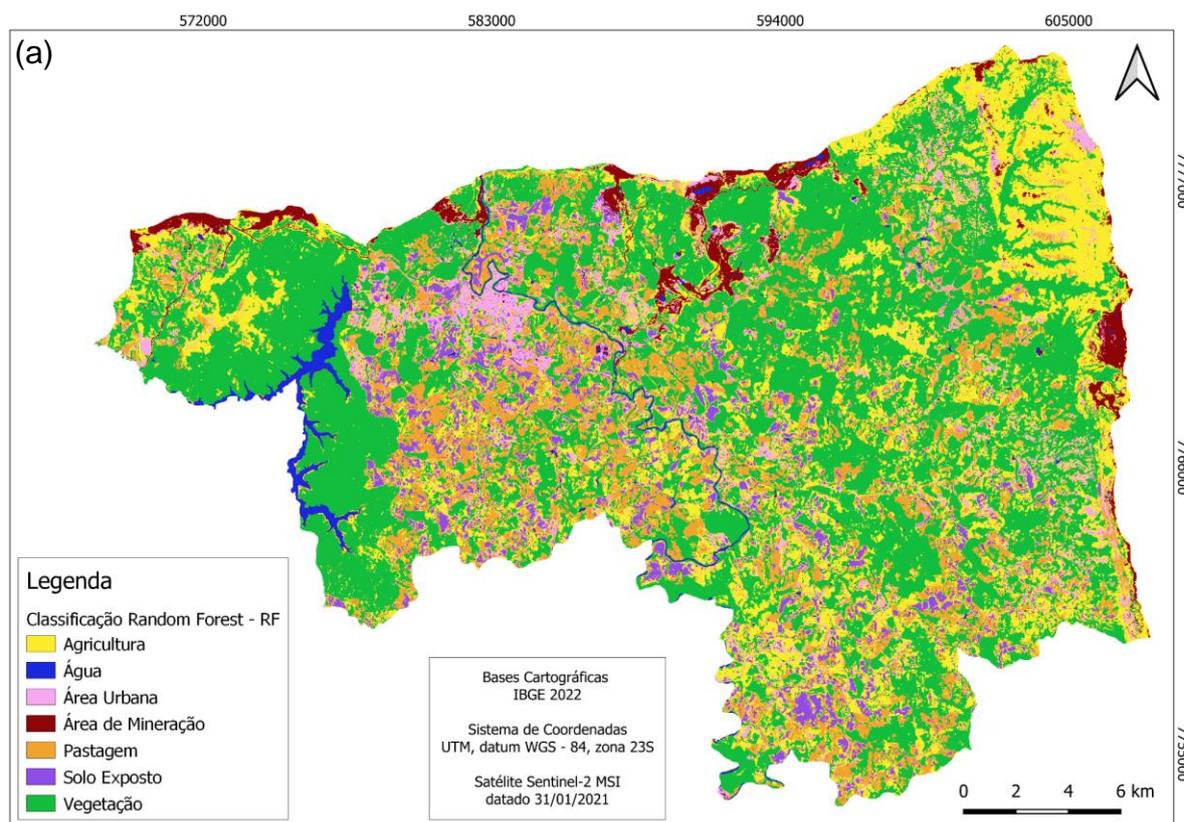
Os mapas abaixo (Figuras 10a, 10b, 11a e 11b) representam o resultado da classificação supervisionada, obtendo as sete classes de uso e cobertura da terra mapeadas neste estudo. Por meio do mapeamento foi possível obter a quantificação das classes temáticas, antes e após o rompimento da barragem em Brumadinho, para cada algoritmo (Tabelas 4 e 5).

Figura 10 - Resultado da classificação supervisionada para os algoritmos RF (a) e SVM (b), no município de Brumadinho - MG, antes do rompimento da barragem.



Fonte: Autoria própria, 2024.

Figura 11 - Resultado da classificação supervisionada para os algoritmos RF (a) e SVM (b), no município de Brumadinho - MG, após o rompimento da barragem.



Fonte: Autoria própria, 2024.

Com base nos valores de acurácia e na análise dos mapas anteriores e posteriores ao rompimento apresentados acima, é válido afirmar que o modelo RF demonstrou um desempenho superior na classificação das amostras de treinamento em comparação ao SVM. Essa conclusão é corroborada pela observação das matrizes de confusão apresentadas nas Tabelas 6, 8, 10 e 12. Portanto, para este estudo, o RF se mostra mais adequado para gerar um mapeamento temático da paisagem, especialmente pela sua capacidade de distinguir de maneira mais eficiente as áreas de vegetação em comparação ao algoritmo SVM.

Ao comparar com as imagens reais de satélite, os resultados divergentes evidenciam a ocorrência de confusão pelo algoritmo RF, tanto na imagem de 2019 quanto na de 2021, ao classificar áreas de agricultura, pastagem, área urbana, solo exposto e vegetação. Neste contexto, algumas regiões de vegetação e solo exposto foram erroneamente classificadas como agricultura e pastagem, respectivamente, enquanto áreas de mineração foram incorretamente associadas a solo exposto. Essas discrepâncias decorrem, em parte, da semelhança nos valores digitais dos pixels em determinadas regiões das imagens.

O algoritmo SVM, tanto na imagem de 2019 quanto na de 2021, também apresentou confusão em algumas classes temáticas. Houve uma sobreposição entre áreas urbanas, solo exposto e áreas de mineração, além de algumas regiões de vegetação que foram confundidas como áreas de agricultura e pastagem, devido à presença de relevo acidentado em determinadas áreas.

De maneira geral, ambos os algoritmos demonstraram uma boa capacidade de classificação da classe água. O RF se destacou na identificação de áreas de mineração em comparação ao SVM. Isso pode ocorrer devido às características específicas do RF, que pode ser mais sensível a certos padrões de dados relacionados à mineração. No entanto, é importante notar que o RF também pode cometer erros, como classificar erroneamente áreas escuras de solo exposto, como áreas de mineração.

Além disso, tanto o RF quanto o SVM apresentaram confusão na classificação de áreas de vegetação como áreas de agricultura. Esse problema pode ser atribuído à semelhança na aparência dessas áreas, especialmente quando a topografia do terreno e a densidade da vegetação são variáveis. Isso demonstra que, embora ambos os algoritmos sejam eficazes em geral, cada um pode ter suas próprias nuances e limitações, e a escolha entre eles pode depender das características específicas do conjunto de dados e dos objetivos do projeto.

O SVM apresentou um desempenho menos satisfatório na classificação da classe agricultura, com diversas áreas agrícolas classificadas erroneamente como vegetação. Além disso, o algoritmo não conseguiu classificar algumas áreas urbanas para a imagem anterior ao

rompimento (Figura 10b), o que justifica o valor encontrado na quantificação da Tabela 4. Por outro lado, o SVM demonstrou uma precisão superior na identificação de áreas de solo exposto em comparação ao RF.

Embora o RF tenha demonstrado uma precisão superior na identificação de classes específicas, é importante não desconsiderar a contribuição do SVM, uma vez que, de forma geral, ele obteve valores de acurácia superiores a 90%. O estudo conduzido por Wolfer *et al.* (2020) investigou o desempenho de algoritmos de aprendizado de máquina na classificação supervisionada de usos e cobertura da terra, empregando imagens do MSI/Sentinel-2A. Os resultados revelaram a eficiência dos algoritmos, com ênfase para o RF e SVM, os quais demonstraram os mais altos níveis de acurácia. Entretanto, o RF ainda apresentou um desempenho ligeiramente superior ao SVM quando considerado os valores de acurácia. Estudo elaborado por Alba (2022) teve como propósito examinar a capacidade dos algoritmos de aprendizado de máquina k-Nearest Neighbor (kNN), Random Forest (RF), Support Vector Machine (SVM) e Artificial Neural Networks (ANN) na detecção das características da vegetação da Caatinga utilizando imagens OLI/Landsat 8. Entre esses algoritmos, o RF se destacou como sendo o mais adequado para a realização do estudo, demonstrando os melhores resultados em comparação com os outros métodos avaliados.

É necessário destacar que, ao analisar os mapas após o rompimento da barragem (Figuras 11a e 11b), é evidente um aumento nas áreas de mineração. Contudo, cabe ressaltar que esse aumento não foi devidamente quantificado nas Tabelas 4 e 5, devido aos erros cometidos pelos algoritmos, nos quais áreas de solo exposto com tonalidades mais escuras foram confundidas com áreas de mineração.

Tabela 4 - Quantificação das classes temáticas de uso e cobertura da terra para os algoritmos RF e SVM no Município de Brumadinho-MG (07/01/2019).

| Classes Temáticas | RF | | SVM | |
|----------------------|------------------|------------|------------------|------------|
| | ha | % | ha | % |
| Agricultura | 5.616,29 | 8,78 | 2.358,77 | 3,69 |
| Água | 734,15 | 1,15 | 735,99 | 1,15 |
| Área Urbana | 3.704,46 | 5,79 | 916,92 | 1,43 |
| Área de Mineração | 2.473,14 | 3,87 | 1.339,53 | 2,09 |
| Pastagem | 14.373,21 | 22,48 | 9.302,10 | 14,55 |
| Solo Exposto | 769,58 | 1,20 | 667,27 | 1,04 |
| Vegetação | 36.270,38 | 56,72 | 48.620,60 | 76,04 |
| Total | 63.941,19 | 100 | 63.941,19 | 100 |

Fonte: Autoria própria, 2024.

Tabela 5 - Quantificação das classes temáticas de uso e cobertura da terra para os algoritmos RF e SVM no Município de Brumadinho-MG (31/01/2021).

| Classes Temáticas | RF | | SVM | |
|----------------------|------------------|------------|------------------|------------|
| | ha | % | ha | % |
| Agricultura | 15.788,28 | 24,69 | 6.420,84 | 10,04 |
| Água | 928,74 | 1,45 | 854,14 | 1,34 |
| Área Urbana | 3.614,83 | 5,65 | 1.945,97 | 3,04 |
| Área de Mineração | 1.980,51 | 3,10 | 1.472,04 | 2,30 |
| Pastagem | 8.850,72 | 13,84 | 8.463,91 | 13,24 |
| Solo Exposto | 3.455,33 | 5,40 | 3.240,10 | 5,07 |
| Vegetação | 29.322,80 | 45,86 | 41.544,19 | 64,97 |
| Total | 63.941,19 | 100 | 63.941,19 | 100 |

Fonte: Autoria própria, 2024.

Na tabela e nos mapas referentes ao dia 07 de janeiro de 2019, é evidente uma disparidade mais significativa nos resultados dos algoritmos para as classes temáticas agricultura, área urbana, pastagem e vegetação. Notavelmente, a maior discrepância entre os algoritmos ocorre na classe vegetação, com uma diferença de 19,32% entre ambos. Já na tabela e nos mapas correspondentes ao dia 31 de janeiro de 2021, ocorreu uma discrepância maior nos resultados dos algoritmos para as classes temáticas agricultura, área urbana e vegetação. Mais uma vez, a maior disparidade ocorre na classe vegetação, com uma diferença de 19,11% entre os dois algoritmos.

Apesar das confusões identificadas, é perceptível uma diminuição na cobertura vegetal ao comparar os anos de 2019 e 2021. Ainda, nota-se um aumento nas áreas agricultáveis e de solo exposto durante esse período. Com base na quantificação, as classes temáticas água, área de mineração e solo exposto representadas nas Figuras 10a e 10b apresentaram resultados próximos para ambos os algoritmos. Nas Figuras 11a e 11b, os resultados foram semelhantes aos das Figuras 10a e 10b, com exceção da classe pastagem, que também registrou resultados próximos para os dois algoritmos. Este fato pode estar relacionado com bandas específicas presentes nas imagens do Sentinel-2 e também com os índices espectrais calculados, os quais podem ter contribuído para a semelhança nas discriminações.

A matriz de confusão permite visualizar o desempenho de um algoritmo de classificação, fornecendo informações sobre a precisão e os erros cometidos (HOLANDA, 2021). Conforme Mendes (2019), cada coluna na matriz representa as instâncias preditas em uma classe, ao passo que cada linha representa as instâncias reais em uma classe (ou vice-versa).

O termo "matriz de confusão" deriva da facilidade em identificar se o sistema está confundindo duas classes, ou seja, rotulando erroneamente uma como sendo outra.

Ao analisar as matrizes de confusão, apresentadas nas Tabelas 6, 8, 10 e 12, geradas pelos algoritmos, é possível identificar os pixels classificados de forma equivocada, os quais se dividem em erros de omissão ou comissão. Esses erros têm impacto direto nos resultados das acurácias. Segundo Vieira *et al.* (2009), um erro de comissão ocorre quando uma área é erroneamente incluída em uma classe à qual não pertence na realidade. Em contrapartida, um erro de omissão ocorre quando uma área é excluída da classe à qual ela realmente pertence. A acurácia do usuário ou do consumidor está relacionada ao erro de comissão, enquanto a acurácia do produtor está associada ao erro de omissão. Esses erros podem ter sido influenciados pela qualidade e quantidade de amostras coletadas para o treinamento do modelo, resolução das imagens, cobertura de nuvens, dentre outros motivos. Portanto, é importante considerar esses aspectos ao interpretar os resultados de uma classificação utilizando algoritmos de aprendizado de máquina.

Tabela 6 - Matriz de Confusão para o algoritmo RF da imagem datada do dia 07/01/2019.

| Predição | Agricultura | Água | Área Urbana | Área de Mineração | Pastagem | Solo Exposto | Vegetação |
|-------------------|-------------|------|-------------|-------------------|----------|--------------|-----------|
| Agricultura | 127 | 0 | 0 | 0 | 0 | 0 | 1 |
| Água | 0 | 416 | 0 | 0 | 0 | 0 | 0 |
| Área urbana | 0 | 0 | 186 | 2 | 0 | 6 | 0 |
| Área de Mineração | 0 | 0 | 5 | 325 | 0 | 1 | 0 |
| Pastagem | 0 | 0 | 0 | 0 | 277 | 0 | 2 |
| Solo exposto | 5 | 0 | 1 | 0 | 0 | 115 | 0 |
| Vegetação | 0 | 0 | 0 | 0 | 0 | 1 | 2440 |

Fonte: Autoria própria, 2024

A Tabela 7 exibe a acurácia do produtor e do usuário do algoritmo RF, calculadas com base na matriz de confusão acima.

Tabela 7 - Acurácia do produtor e do usuário para o algoritmo RF.

| | Agricultura | Água | Área urbana | Área de Mineração | Pastagem | Solo Exposto | Vegetação |
|----------------------|-------------|------|-------------|-------------------|----------|--------------|-----------|
| Produtor/ Omissão | 0.96212 | 1 | 0.96875 | 0.99388 | 1 | 0.93496 | 0.9988 |
| Usuário/ Comissão | 0.99974 | 1 | 0.99785 | 0.99833 | 0.99945 | 0.99842 | 0.9993 |

Fonte: Autoria própria, 2024.

Para o algoritmo RF, foram identificados erros de omissão nas classes de agricultura, área urbana, área de mineração, solo exposto e vegetação. Por outro lado, os erros de comissão ocorreram nas classes de agricultura, área urbana, área de mineração, pastagem, solo exposto e vegetação. Em termos gerais, o algoritmo demonstrou um desempenho satisfatório, com uma quantidade reduzida de pixels classificados de forma incorreta.

A Tabela 8 proporciona uma avaliação detalhada da matriz de confusão gerada pelo algoritmo SVM.

Tabela 8 - Matriz de Confusão para o algoritmo SVM da imagem datada do dia 07/01/2019.

| Predição | Agricultura | Água | Área Urbana | Área de Mineração | Pastagem | Solo Exposto | Vegetação |
|-------------------|-------------|------|-------------|-------------------|----------|--------------|-----------|
| Agricultura | 77 | 0 | 3 | 0 | 0 | 0 | 0 |
| Água | 0 | 416 | 0 | 0 | 0 | 0 | 0 |
| Área Urbana | 0 | 0 | 172 | 2 | 0 | 6 | 1 |
| Área de Mineração | 0 | 0 | 12 | 324 | 0 | 0 | 0 |
| Pastagem | 0 | 0 | 0 | 0 | 266 | 0 | 2 |
| Solo Exposto | 6 | 0 | 2 | 0 | 0 | 117 | 0 |
| Vegetação | 49 | 0 | 3 | 1 | 11 | 0 | 2440 |

Fonte: Autoria própria, 2024.

A matriz de confusão permitiu o cálculo da acurácia do produtor e do usuário para o algoritmo SVM, conforme apresentado na Tabela 9.

Tabela 9 – Acurácia do produtor e do usuário para o algoritmo SVM.

| | Agricultura | Água | Área Urbana | Área de Mineração | Pastagem | Solo Exposto | Vegetação |
|----------------------|-------------|------|-------------|-------------------|----------|--------------|-----------|
| Produtor/ Omissão | 0.58333 | 1 | 0.89583 | 0.99083 | 0.96029 | 0.95122 | 0.9988 |
| Usuário/ Comissão | 0.99921 | 1 | 0.99758 | 0.99665 | 0.99945 | 0.99789 | 0.9564 |

Fonte: Autoria própria, 2024.

No caso do algoritmo SVM, foram identificados erros de omissão nas classes de agricultura, área urbana, área de mineração, pastagem, solo exposto e vegetação. Os erros de comissão ocorreram, por sua vez, nas classes de agricultura, área urbana, área de mineração, pastagem, solo exposto e vegetação. Apesar de o algoritmo ter mostrado um desempenho satisfatório na classificação de pixels em geral, o modelo SVM obteve uma acurácia do produtor de aproximadamente 58% para a classe agricultura. Isso significa que uma parte da área agrícola foi excluída da classe à qual ela realmente pertence.

A matriz de confusão do algoritmo RF após o rompimento pode ser observada na Tabela 10.

Tabela 10 - Matriz de Confusão para o algoritmo RF da imagem datada do dia 31/01/2021.

| Predição | Agricultura | Água | Área Urbana | Área de Mineração | Pastagem | Solo Exposto | Vegetação |
|-------------------|-------------|------|-------------|-------------------|----------|--------------|-----------|
| Agricultura | 286 | 1 | 1 | 0 | 0 | 2 | 1 |
| Água | 0 | 365 | 0 | 0 | 0 | 0 | 0 |
| Área Urbana | 1 | 0 | 141 | 6 | 1 | 7 | 0 |
| Área de Mineração | 0 | 0 | 4 | 486 | 0 | 1 | 0 |
| Pastagem | 0 | 0 | 0 | 0 | 300 | 1 | 0 |
| Solo Exposto | 1 | 0 | 5 | 2 | 0 | 155 | 0 |
| Vegetação | 13 | 0 | 0 | 0 | 0 | 0 | 4428 |

Fonte: Autoria própria, 2024.

A matriz de confusão da Tabela 10 serviu de base para o cálculo da acurácia do produtor e do usuário do algoritmo RF, cujos resultados estão na Tabela 11.

Tabela 11 – Acurácia do produtor e do usuário para o algoritmo RF.

| | Agricultura | Água | Área Urbana | Área de Mineração | Pastagem | Solo Exposto | Vegetação |
|----------------------|-------------|---------|-------------|-------------------|----------|--------------|-----------|
| Produtor/ Omissão | 0.95017 | 0.99727 | 0.93377 | 0.98381 | 0.99668 | 0.93373 | 0.9998 |
| Usuário/ Comissão | 0.99915 | 1 | 0.99752 | 0.99912 | 0.99983 | 0.99868 | 0.9927 |

Fonte: Autoria própria, 2024.

Para o algoritmo RF, observou-se a presença de erros de omissão em todas as classes. Em contrapartida, os erros de comissão ocorreram nas classes de agricultura, área urbana, área de mineração, pastagem, solo exposto e vegetação. De forma geral, o algoritmo apresentou um desempenho satisfatório na classificação, registrando uma quantidade reduzida de pixels classificados erroneamente.

Para o algoritmo SVM, a matriz de confusão após o rompimento pode ser analisada na Tabela 12.

Tabela 12 - Matriz de Confusão para o algoritmo SVM da imagem datada do dia 31/01/2021.

| Predição | Agricultura | Água | Área Urbana | Área de Mineração | Pastagem | Solo Exposto | Vegetação |
|-------------------|-------------|------|-------------|-------------------|----------|--------------|-----------|
| Agricultura | 186 | 1 | 4 | 0 | 0 | 0 | 0 |
| Água | 0 | 364 | 0 | 0 | 0 | 0 | 0 |
| Área Urbana | 0 | 0 | 142 | 6 | 0 | 2 | 0 |
| Área de Mineração | 0 | 1 | 2 | 488 | 0 | 2 | 0 |
| Pastagem | 0 | 0 | 0 | 0 | 290 | 5 | 0 |
| Solo Exposto | 2 | 0 | 3 | 0 | 0 | 157 | 0 |
| Vegetação | 113 | 0 | 0 | 0 | 11 | 0 | 4429 |

Fonte: Autoria própria, 2024.

Com base na matriz de confusão supracitada, a acurácia do produtor e do usuário para o algoritmo SVM foi calculada e está detalhada na Tabela 13.

Tabela 13 - Acurácia do produtor e do usuário para o algoritmo SVM.

| | Agricultura | Água | Área Urbana | Área de Mineração | Pastagem | Solo Exposto | Vegetação |
|----------------------|-------------|---------|-------------|-------------------|----------|--------------|-----------|
| Produtor/ Omissão | 0.61794 | 0.99454 | 0.94040 | 0.98785 | 0.96346 | 0.94578 | 1 |
| Usuário/ Comissão | 0.99915 | 1 | 0.99868 | 0.99912 | 0.99915 | 0.99917 | 0.9303 |

Fonte: Autoria própria, 2024.

No caso do algoritmo SVM, foram identificados erros de omissão nas classes de agricultura, água, área urbana, área de mineração, pastagem e solo exposto. Já os erros de comissão ocorreram nas classes de agricultura, área urbana, área de mineração, pastagem, solo exposto e vegetação. Embora o algoritmo tenha apresentado um bom desempenho geral na classificação de pixels, o modelo SVM obteve uma acurácia do produtor de aproximadamente 61% para a classe agricultura. Isso significa que uma parte da área agrícola foi excluída da classe à qual ela realmente pertence.

Considerando tudo que foi abordado nesta pesquisa, é válido salientar que os índices espectrais NDVI, EVI e NDWI são ferramentas relevantes para o processo de monitoramento da vitalidade e vigorosidade da vegetação e a cobertura terrestre como um todo, visto que os índices contribuem para o fornecimento de informações para diversas áreas como estudos climáticos, gestão ambiental, desastres ambientais e hidrologia. Diante disso, foi possível avaliar as modificações ocorridas na região, antes e após o rompimento da barragem de mineração em Brumadinho-MG.

Cada índice utilizado neste estudo possui características e aplicações específicas, isso os tornou complementares na análise de dados de sensoriamento remoto. Ademais, cabe afirmar que o uso dos índices em conjunto com as bandas espectrais do satélite Sentinel-2, colaborou para que a classificação fosse feita de maneira mais precisa, beneficiando-se da excelente resolução espectral oferecida pelo satélite. Ghosh e Behera (2018) afirmam que os índices ópticos, obtidos pela relação entre diferentes combinações de dados espectrais dos alvos, contribuem para aprimorar a precisão da classificação final. Como resultado, são produzidos mapas específicos de vegetação, solo, água e outros.

De acordo com Rex *et al.* (2018), as imagens do satélite Sentinel-2/MSI apresentam grande potencial para a classificação do uso e cobertura do solo, podendo este conjunto oferecer melhorias para o monitoramento da superfície terrestre. Os resultados de sua pesquisa revelaram uma precisão mais elevada da acurácia na classificação das imagens do Sentinel-2/MSI ($k = 0,98$), em comparação com as do Landsat-8/OLI ($k = 0,88$).

Diante do exposto, as imagens do satélite Sentinel-2, com resolução de 20 metros, utilizadas neste estudo, se mostraram adequadas para a realização da classificação supervisionada para mapeamento temático de superfícies. Essa resolução permitiu a identificação precisa de objetos e características na superfície terrestre, como diferentes tipos de cobertura vegetal, áreas urbanas, áreas de mineração e corpos d'água.

Além da classificação temática, o uso de imagens do satélite Sentinel-2 possibilita o acompanhamento de desastres ambientais, como desmatamentos, incêndios florestais, inundações, derramamentos de óleo, e, no caso deste estudo, rompimentos de barragens de minério. Em seu estudo sobre a detecção de áreas queimadas por incêndios florestais utilizando imagens do Sentinel-2, Seydi *et al.* (2022) ressaltam a importância crítica de um mapeamento preciso e oportuno dessas áreas para a gestão pós-incêndio, o planejamento e as ações subsequentes. Güvel *et al.* (2022) investigaram o desempenho de técnicas de sensoriamento remoto e sistemas de informação geográfica na análise de eventos de inundação em áreas agrícolas utilizando imagens do satélite Sentinel-2.

Cabe ressaltar ainda que este estudo analisou o desempenho dos algoritmos de aprendizado de máquina Random Forest (RF) e Support Vector Machine (SVM) na classificação supervisionada do uso e cobertura do solo no município de Brumadinho, Minas Gerais, utilizando imagens do satélite Sentinel-2. Os resultados demonstraram que ambos os algoritmos foram adequados, apresentando parâmetros de acurácia satisfatórios. No entanto, estatisticamente, o RF superou o SVM, sugerindo que o mesmo pode ser uma escolha mais eficiente para a classificação do uso e cobertura do solo em áreas semelhantes à estudada.

6. CONCLUSÕES

As imagens do Sentinel-2, datadas de 07 de janeiro de 2019 e 31 de janeiro de 2021, permitiram identificar as mudanças no uso e cobertura do solo após o rompimento da barragem de Brumadinho, MG. A área afetada foi calculada em cerca de 298,55 hectares, usando dados vetoriais do IBGE.

Os cálculos dos índices NDVI, EVI e NDWI revelaram um significativo impacto adverso na região após o acidente. Os valores reduzidos do NDVI indicam comprometimento na vitalidade da vegetação devido à contaminação do solo pelos resíduos tóxicos da lama de rejeitos, comprometendo a qualidade e a capacidade do solo de sustentar o crescimento das plantas. O EVI mostrou menor presença de áreas de vegetação, enquanto o NDWI indicou satisfatoriamente a presença de água.

Os algoritmos RF e SVM apresentaram desempenhos semelhantes, com acurácia global e kappa acima de 90%. O RF demonstrou um desempenho ligeiramente superior, especialmente na classificação da vegetação.

Houve uma diminuição na cobertura vegetal entre 2019 e 2021, com aumento de áreas agricultáveis e de solo exposto. Um aumento nas áreas de mineração foi observado, embora não tenha sido quantificado adequadamente devido a erros nos algoritmos.

Ambos os algoritmos foram adequados, mas o RF superou estatisticamente o SVM, sugerindo maior eficiência na classificação do uso e cobertura do solo. Mínimas disparidades nos comportamentos espectrais foram detectadas, mas podem ser atribuídas a diferenças nas condições atmosféricas, posição solar e mudanças na superfície da área.

O estudo demonstrou métodos eficazes para a classificação supervisionada do solo utilizando a combinação do software R e algoritmos de aprendizado de máquina. A combinação de R com imagens de alta resolução espacial do satélite Sentinel-2 mostrou-se rápida e efetiva para estudos ambientais, destacando o potencial dessas ferramentas para futuras pesquisas e tomada de decisões no planejamento da área.

REFERÊNCIAS

- AGÊNCIA NACIONAL DE MINERAÇÃO - ANM. **Anuário Mineral Brasileiro 2022: Relatório Preliminar**. Brasília, DF: Agência Nacional de Mineração, 2022. Disponível em: <https://www.gov.br/anm/pt-br/centrais-de-conteudo/publicacoes/serie-estatisticas-e-economia-mineral/anuario-mineral/anuario-mineral-brasileiro/PreviaAMB2022.pdf>. Acesso em: 13 mar. 2023.
- ALBA, Elisiane; ALEXANDRE, Marta Laura de Souza; MARCHESAN, Juliana; SOUZA, Luciana Sandra Bastos de; BEZERRA, Alan César; SILVA, Emanuel Araújo. Comparação entre Algoritmos de Aprendizado de Máquina para a Identificação de Floresta Tropical Sazonalmente Seca. **Anuário do Instituto de Geociências**, vol. 45, 2022, pp. 1-10 Universidade Federal do Rio de Janeiro. Disponível em: <https://www.redalyc.org/articulo.oa?id=695375056009>. Acesso em: 04 fev. 2024.
- ALCÂNTARA, Enner. **Comportamento Espectral de Alvos**. São Paulo-SP. 2016. Departamento de Cartografia Universidade Estadual Paulista Presidente Prudente. Disponível em: https://www2.fct.unesp.br/docentes/cartoenner/PPGCC/Comportamento%20Espectral%20de%20Alvos/Aulas/CEA_Aula_3-Quantidade_reflectancia.pdf. Acesso em: 21 dez. 2023.
- ALVES, Marcelo de Carvalho; SANCHES, Luciana; MENEZES, Fortunato Silva de; TRINDADE, Lídia Raiza Sousa Lima Chaves. Multisensor analysis for environmental targets identification in the region of Funil dam, state of Minas Gerais, Brazil. **Applied Geomatics**, [S.L.], v. 15, n. 4, p. 807-827, 19 set. 2023. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s12518-023-00523-w>.
- ANTUNES-ROCHA, Maria Isabel; HUNZICKER, Adriane Cristina de Melo; FANTINEL, Lúcia Maria. **O rompimento da barragem B1 da Mina Córrego do Feijão e os desafios para a educação**. Cienc. Cult. vol.72 no.2 São Paulo Apr./June 2020. Disponível em: http://cienciaecultura.bvs.br/scielo.php?script=sci_arttext&pid=S0009-67252020000200007&tlng=pt. Acesso em: 17 mar. 2023.
- BERTONI, Bruno Gomez Leguizamon; SÍGOLO, Joel Barbujianni. **Utilização de técnicas de sensoriamento remoto nas imagens CBERS 4 a para a avaliação de aspectos da qualidade da água (macrófitas e clorofila a): estudo no reservatório Biritiba-Mirim – SP**. Vigilância e Saúde Ambiental: no contexto da educação. Disponível em: <https://downloads.editoracientifica.org/articles/210504728.pdf>. Acesso em: 27 maio 2023.
- BIVAND R, KEITT T, ROWLINGSON B. (2023). *_rgdal: Bindings for the 'Geospatial' Data Abstraction Library_*. R package version 1.6-7, <<https://CRAN.R-project.org/package=rgdal>>.
- BIVAND R, PEBESMA E, GOMEZ-RUBIO V (2013). *_Applied spatial data analysis with R, Second edition_*. Springer, NY. <<https://asdar-book.org/>>.
- BREIMAN, L. Random Forests. *Machine Learning* 45, 5–32 (2001). <https://doi.org/10.1023/A:1010933404324>
- CARMO, Valeria Amorim. **A contribuição da Etnopedologia para o planejamento das terras: estudo de caso de uma comunidade de agricultores do entorno do Parque Nacional do Caparaó**. 2009. 197p. Tese (Doutorado em Geografia) – Instituto de Geociências, Universidade Federal de Minas Gerais, Belo Horizonte, 2009. Disponível em: <http://hdl.handle.net/1843/MPBB-7SAH32>. Acesso em: 25 mai. 2023.

COELHO, Maurício Rizzato; VASQUES, Gustavo de Mattos; TASSINARI, Diego; SOUZA, Zélio Resende de; OLIVEIRA, Aline Pacobahyba de; MOREIRA, Fátima Maria de Souza. **Solos do Quadrilátero Ferrífero sob Diferentes Coberturas Vegetais e Materiais de Origem**. Rio de Janeiro, RJ. 2017. Embrapa Solos. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/172437/1/CNPS-BPD-264-2017.pdf>. Acesso em: 15 mar. 2023.

COPERNICUS. Disponível em: <https://www.copernicus.eu/en>. Acesso em: 10 jun. 2023.

CORTES, C., VAPNIK, V. Support-vector networks. *Mach Learn* 20, 273–297 (1995). <https://doi.org/10.1007/BF00994018>

COSTA, E. M.; ANTUNES, M. A. H; DEBIASSI, P.; ANJOS, L. H. C. Processamento de imagens RapidEye no mapeamento de uso do solo em ambiente de Mar de Morros. **Pesq. agropec. bras., Brasília**, v. 51, n. 9, 2016. Disponível em: <https://doi.org/10.1590/s0100-204x2016000900040>. Acesso em: 12 Maio 2020.

COSTA, Marco Aurélio; ALMEIDA, Luiz Felype Gomes de; GUERRA, Maria de Fátima Lage; GARCIA, João Paulo Gonzaga; SANTOS, Rodrigo Marques dos. **Uma investigação sobre a minero-dependência em brumadinho-mg: as metáforas do processo de formação e da dinâmica econômica local**. 2020. Instituto de Pesquisa Econômica Aplicada-IPEA, Brasília. Disponível em: https://repositorio.ipea.gov.br/bitstream/11058/10292/1/td_2603.pdf. Acesso em: 14 mar. 2023.

CUNHA, Joyce Priscilla de Souza; LUCENA, Roberta Cristina Félix de; SOUSA, Cynthia Alves Félix de. Monitoramento do uso e ocupação de Áreas de Preservação Permanentes urbanas com o apoio de geotecnologias: O caso do rio Jaguaribe em João Pessoa-PB. **Revista Nacional de Gerenciamento de Cidades**, [s. l], v. 05, n. 30, p. 42-50, 01 mar. 2017. ISSN 2318-8472. Disponível em: https://scholar.archive.org/work/6watjwggwze37dvu4nxqytkv54/access/wayback/https://www.amigosdanatureza.org.br/publicacoes/index.php/gerenciamento_de_cidades/article/download/1538/1541. Acesso em: 29 maio 2023.

CUNHA, Tony Jarbas Ferreira; SÁ, Iedo Bezerra; PETRERE, Vanderlise Giongo; TAURA, Tatiana Ayako. **Cambissolos**. 2021. Embrapa. Disponível em: <https://www.embrapa.br/agencia-de-informacao-tecnologica/tematicas/bioma-caatinga/solos/cambissolos#:~:text=S%C3%A3o%20solos%20fortemente%2C%20at%C3%A9%20imperfettamente,atividade%20qu%C3%ADmica%20da%20fra%C3%A7%C3%A3o%20coloidal>. Acesso em: 20 fev. 2024.

DIAS, Lázaro Cezar. Desenvolvimento regional e sustentabilidade: mapeando o potencial verde do estado do Espírito Santo em 2018. **Informe Econômico (Ufpi)**, [s. l], p. 42-57, 15 mar. 2021. Ano 23 -Volume 42 -Número 1 -Janeiro-Junho, 2021. Disponível em: <https://periodicos.ufpi.br/index.php/ie/article/view/874/762>. Acesso em: 18 maio 2023.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (EMBRAPA). **Embrapa avalia contexto territorial da área afetada pelo rompimento da barragem de Brumadinho**. 2019. Estudos socioeconômicos e ambientais Geotecnologia Gestão ambiental e territorial. Disponível em: <https://www.embrapa.br/busca-de-noticias/>

/noticia/41938448/embrapa-avalia-contexto-territorial-da-area-afetada-pelo-rompimento-da-barragem-de-brumadinho#:~:text=Na%20regi%C3%A3o%2C%20predomina%20o%20bioma,pouco%20mais%20de%2053%20hectares. Acesso em: 15 dez. 2023.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (EMBRAPA). **Satélites de Monitoramento: GeoEye**. 2019. Disponível em: <https://www.embrapa.br/satelites-de-monitoramento/missoes/geoeeye>. Acesso em: 26 nov. 2023.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (EMBRAPA). **SENTINEL - Missão Sentinel**. 2020. Disponível em: <https://www.embrapa.br/satelites-de-monitoramento/missoes/sentinel>. Acesso em: 17 mar. 2023.

EUROPEAN SPACE AGENCY (ESA). **User Guides - Sentinel-2 MSI - Revisit and 63 Coverage - Sentinel Online**. 2020. Disponível em: <https://sentinel.esa.int/web/sentinel/userguides/sentinel-2-msi/revisit-coverage>. Acesso em: 22 maio 2023.

FONTANA, Éliton. **Introdução aos Algoritmos de Aprendizagem Supervisionada**. 2020. Universidade Federal do Paraná. Departamento de Engenharia Química. Apostila. Disponível em: https://fontana.paginas.ufsc.br/files/2018/03/apostila_ML.pdf. Acesso em: 14 dez. 2023.

FREIRE, Neison Cabral Ferreira; PACHECO, Admilson da Penha; QUEIROZI, Vinícius D'Lucas Bezerra. **Uma abordagem metodológica de Sensoriamento Remoto para o monitoramento da contaminação do rio Paraopeba pós-desastre de Brumadinho-MG**. *Ciência e Natura*, Santa Maria, v. 43, e36, 2021. Disponível em: <https://periodicos.ufsm.br/cienciaenatura/article/download/43632/pdf/314890>. Acesso em: 12 mar. 2023.

FREIRES, Eduardo Viana et al. COMPARAÇÃO DE IMAGENS OLI/LANDSAT-8 E MSI/SENTINEL-2 NO MAPEAMENTO DE COBERTURA E USO DA TERRA NO MACIÇO DE URUBURETAMA, CEARÁ. **Anuário do Instituto de Geociências - UFRJ** ISSN 0101-9759 e-ISSN 1982-3908 - Vol. 42 - 4 / 2019 p. 427-442. Disponível em: <https://revistas.ufrj.br/index.php/aigeo/article/view/31379>. Acesso em: 20 mar. 2023.

FREITAS, C., BARCELLOS, C., Asmus C., et al. **Da Samarco em Mariana à Vale em Brumadinho: desastres em barragens de mineração e Saúde Coletiva**. *Cad. Saúde Pública*. 2019. Disponível em: <https://www.scielo.br/j/csp/a/5p9ZRBrGkfrmtPBtSLcs9j/?lang=pt&format=pdf>. Acesso em: 16 mar. 2023.

GANDRA, Alana. **Polícia Civil de MG identifica 267ª vítima do rompimento de Brumadinho**. Agência Brasil, Brasília, 13 dez. 2022. Disponível em: <https://agenciabrasil.ebc.com.br/geral/noticia/2022-12/policia-civil-de-mg-identifica-267a-vitima-do-rompimento-de-brumadinho>. Acesso em: 14 mar. 2023.

GAO, B.C. NDWI – A Normalized Difference Water Index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, v.58, p.257-266, 1996.

GHOSH, Sujit Madhab; BEHERA, Mukunda Dev. Aboveground biomass estimation using multi-sensor data synergy and machine learning algorithms in a dense tropical forest. **Applied**

Geography, [S.L.], v. 96, p. 29-40, jul. 2018. Elsevier BV.
<http://dx.doi.org/10.1016/j.apgeog.2018.05.011>. Disponível em:
<https://www.sciencedirect.com/science/article/abs/pii/S0143622818303114?via%3Dihub>.
Acesso em: 04 fev. 2024.

GOOGLE. **Google Earth website**. Disponível em: <https://www.google.com/intl/pt-BR/earth/about/>. Acesso em: 20 dez. 2023.

GOVERNO DO ESTADO MINAS GERAIS. **Histórico do rompimento das barragens da Vale na Mina Córrego do Feijão**. 20 dez. 2021. Disponível em: <https://www.mg.gov.br/probrumadinho/pagina/historico-do-rompimento-das-barragens-da-vale-na-mina-corrego-do-feijao>. Acesso em: 18 dez. 2023.

GÜVEL, Şerife Pınar; AKGÜL, Mehmet Ali; AKSU, Hakan. Flood inundation maps using Sentinel-2: a case study in berdan plain. **Water Supply**, [S.L.], v. 22, n. 4, p. 4098-4108, 2 fev. 2022. IWA Publishing. <http://dx.doi.org/10.2166/ws.2022.039>. Disponível em: <https://iwaponline.com/ws/article/22/4/4098/86830/Flood-inundation-maps-using-Sentinel-2-a-case>. Acesso em: 02 fev. 2024.

HIJMANS R (2023). *_raster: Geographic Data Analysis and Modeling_*. R package version 3.6-23, <<https://CRAN.R-project.org/package=raster>>.

HOLANDA, C. E. F. **Avaliação do desempenho estatístico dos algoritmos de classificação random forest (rf), decision tree (dt) e support vector machine (svm) para imagens de satélites com diferentes cubos de dados: estudo de caso no bioma cerrado**. Dissertação. Belo Horizonte. 2021. Programa de Pós-Graduação do Departamento de Geografia do Instituto de Geociências da Universidade Federal de Minas Gerais. Disponível em: <https://repositorio.ufmg.br/bitstream/1843/43270/1/Avalia%C3%A7%C3%A3o%20do%20desempenho%20estat%C3%ADstico%20dos%20algoritmos%20de%20classifi%C3%A7%C3%A3o%20Random%20Forest%20%28RF%29%2C%20Decision%20Tree%20%28DT%29%20e%20Support%20Vector%20Machine%20%28SVM%29%20para%20imagens%20de%20sat%C3%A9lite%20com%20diferentes%20cubos%20de%20dados%20estudo%20de%20caso%20no%20bioma%20cerrado.pdf>. Acesso em: 26 nov. 2023.

INPE. **SPRING: Tutorial de Geoprocessamento**. S40 José dos Campos: INPE, 2006. Disponível em: <http://www.dpi.inpe.br/spring/portugues/tutorial/index.html>. Acesso em: 30 nov. 2023.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Monitoramento da Cobertura e Uso da Terra do Brasil**. 2022. Rio de Janeiro. Disponível em: <https://biblioteca.ibge.gov.br/visualizacao/livros/liv101966.pdf>. Acesso em: 26 abr. 2023.

INSTITUTO BRASILEIRO DE GEOGRAFIA E Estatística (IBGE). **Novos dados geoespaciais mostram área atingida pelo rompimento da barragem**. 2019. Agência IBGE notícias. Disponível em: <https://agenciadenoticias.ibge.gov.br/agencia-noticias/2012-agencia-de-noticias/noticias/23808-novos-dados-geoespaciais-mostram-area-atingida-pelo-rompimento-da-barragem>. Acesso em: 24 nov. 2023.

INSTITUTO BRASILEIRO DO MEIO AMBIENTE E DOS RECURSOS NATURAIS RENOVÁVEIS - IBAMA. **Rompimento de barragem da Vale em Brumadinho (MG) destruiu 269,84 hectares**. 2019. Ministério de Meio Ambiente. Disponível em:

<https://www.ibama.gov.br/ultimas-2/1881-rompimento-de-barragem-da-vale-em-brumadinho-mg-destruiu-269-84-hectares>. Acesso em: 14 mar. 2023.

JAMALI, A. Evaluation and comparison of eight machine learning models in land use/land cover mapping using Landsat 8 OLI: a case study of the northern region of Iran. *SN Appl. Sci.* 1, 1448 (2019). <https://doi.org/10.1007/s42452-019-1527-8>.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos: Parêntese, 2011.

JORDAN, C. F. **Derivation of leaf area index from quality of light on the Forest floor**. *Ecology*, 50:663-666, 1969.

JUSTICE, C.O.; VERMOTE, E.; TOWNSHEND, J.R.G.; DEFRIES, R.; ROY, D.P.; HALL, D.K.; SALOMONSON, V.V.; PRIVETTE, J.L.; RIGGS, G.; STRAHLER, A.; LUCHT, W.; MYNENI, R.B.; KNYAZIKHIN, Y.; RUNNING, S.W.; NEMANI, R.R.; ZHENGMING, W.; HUETE, A.R.; VAN LEEUWEN, W.; WOLFE, R.E.; GIGLIO, L.; MULLER, J.; LEWIS, P.; BARNESLEY, M.J. The Moderate Resolution Imaging Spectroradiometer (MODIS): land remote sensing for global change research. **IEEE Transactions on Geoscience and Remote Sensing**, v.36, p.1228-1249, 1998.

KUHN, M. (2008). Building Predictive Models in R Using the caret Package. *Journal of Statistical Software*, 28(5), 1–26. <https://doi.org/10.18637/jss.v028.i05>.

LEOPOLDINO, J. de C.; DOS ANJOS, C. S.; SIMÕES, D. P.; FERNANDES, L. F. R. Spatial and temporal analysis of the collapse of the tailings dam in Brumadinho, Brazil. **Revista Agrogeoambiental**, [S. l.], v. 12, n. 3, 2020. DOI: 10.18406/2316-1817v12n320201483. Disponível em: <https://agrogeoambiental.ifsuldeminas.edu.br/index.php/Agrogeoambiental/article/view/1483>. Acesso em: 22 mar. 2023.

LIAW A. AND WIENER M. (2002). Classification and Regression by randomForest. *R News* 2(3), 18--22. <<https://CRAN.R-project.org/doc/Rnews/>>.

LI, Congcong; WANG, Jie; WANG, Lei; HU, Luanyun; GONG, Peng. Comparison of Classification Algorithms and Training Sample Sizes in Urban Land Classification with Landsat Thematic Mapper Imagery. **Remote Sensing**, [S.L.], v. 6, n. 2, p. 964-983, 24 jan. 2014. MDPI AG. <http://dx.doi.org/10.3390/rs6020964>.

LOBO, Felipe de Lucia; RAMALHO, Edgar; SINOTTI, Juliano. **Introdução ao Google Earth Engine**. 2020. Universidade Federal de Pelotas (UFPel). Disponível em: <https://wp.ufpel.edu.br/geotechidrica/files/2021/05/ApostilaGEE2020.pdf>. Acesso em: 20 maio 2023.

LUCCHETTA, Beatriz Cirino; OLIVEIRA, Fernanda Silva. **Uso de imagens do OLI/LANDSAT 8 no estudo de desastres ambientais: Estudo de caso do rompimento da barragem em Brumadinho – MG**. 2020. 65 f. TCC (Graduação) - Curso de Engenheiro Ambiental, Universidade Estadual Paulista – Unesp – Campus de Presidente Prudente., Presidente Prudente, 2020. Disponível em: https://repositorio.unesp.br/bitstream/handle/11449/216304/lucchetta_bc_tcc_prud.pdf?sequence=3&isAllowed=y. Acesso em: 25 maio 2023.

MACHADO, Adilson Matheus Borges. COMPARAÇÃO DE IMAGENS OLI/LANDSAT-8 E MSI/SENTINEL-2 NO MAPEAMENTO DE USO E COBERTURA DA TERRA NA ILHA DO MARANHÃO. **Revista Equador (Ufpi)**, [s. l], v. 9, n. 3, p. 209-232, jul. 2020. Disponível em: <https://revistas.ufpi.br/index.php/equador/article/view/10451/6342>. Acesso em: 31 maio 2023.

MENDES, Kreisler Brenner. **Comparativo de algoritmos clássicos de aprendizado de máquina em um problema de reconhecimento de faces**. Patos de Minas-MG. 2019. Disponível em: <https://repositorio.ufu.br/bitstream/123456789/28614/1/ComparativoAlgoritmosCl%C3%A1ssicos%20.pdf>. Acesso em: 02 dez. 2023.

MENESES, Paulo Roberto; ALMEIDA, Tati de. **Introdução ao Processamento de Imagens em Sensoriamento Remoto**. Brasília, 2012. Disponível em: <https://cnpq.br/documents/10157/56b578c4-0fd5-4b9f-b82a-e9693e4f69d8>. Acesso em 20 de maio de 2023.

MEYER D, DIMITRIADOU E, HORNİK K, WEINGESSEL A, LEISCH F (2023). *_e1071: Misc Functions of the Department of Statistics, Probability Theory Group (Formerly: E1071), TU Wien_*. R package version 1.7-13, <<https://CRAN.R-project.org/package=e1071>>.

MORAES, E.C. **Fundamentos do sensoriamento remoto**. Capítulo 1. INPE-8984-PUD/62. São José dos Campos, 2002.

MUÑOZ, Rafael. **O que podemos aprender com a catástrofe de Brumadinho?** Ambiente Brasil, São Paulo, 25 fev. 2019. Disponível em: <https://noticias.ambientebrasil.com.br/clipping/2019/02/25/150644-o-que-podemos-aprender-com-a-catastrofe-de-brumadinho.html>. Acesso em: 17 mar. 2023.

NOVO, E. M. L. M. **Sensoriamento remoto: princípios e aplicações**. 4 ed. São José dos Campos, SP: Blucher, 2010. 388 p.

ODILLA, Fernanda. **Tragédia em Brumadinho: o perigo à saúde que vem da lama**. BBC News Brasil, São Paulo, 25 jan. 2019. Disponível em: <https://www.bbc.com/portuguese/brasil-47054189>. Acesso em: 18 mar. 2023.

OLIVEIRA, Guilherme de Castro; MARTINS, Vitor Souza; FERNANDES FILHO, Elpídio Inácio; XAVIER, Flávia Vieira. Classificação supervisionada como ferramenta para avaliação da dinâmica do uso e cobertura do solo. **Enciclopédia Biosfera, Centro Científico Conhecer**, Goiânia, v. 10, n. 18, p. 924-935, 1 jul. 2014. Disponível em: <https://www.conhecer.org.br/enciclop/2014a/AGRARIAS/Classificacao%20supervisionada.pdf>. Acesso em: 20 maio 2023.

OLIVEIRA, Larissa Lages. **Uma Análise de Algoritmos de Aprendizagem de Máquina Aplicados em Técnicas de Localização Indoor para Diferentes Tipos de Smartphones**. Trabalho de Graduação. 2017. Universidade Federal de Pernambuco Centro de Informática - Cin. Disponível em: https://www.cin.ufpe.br/~tg/2017-1/llo_tg.pdf. Acesso em: 20 dez. 2023.

OLIVEIRA, Wagner Máximo de; CHAVES, Iêde de Brito; LIMA, Eduardo Rodrigues Viana de. **Índices espectrais de vegetação de caatinga em um neossolo litólico do semiárido paraibano**. In: Simpósio Brasileiro de Sensoriamento Remoto, 14, 2009, Natal. Anais... Natal: INPE, 2009. p.2103-2110. Disponível em:

<http://mar.te.sid.inpe.br/col/dpi.inpe.br/sbsr@80/2008/11.17.00.32/doc/2103-2110.pdf>. Acesso em: 27 maio 2023.

PASSARINHO, Nathalia. **Tragédia com barragem da Vale em Brumadinho pode ser a pior no mundo em 3 décadas**. 2019. Disponível em: <https://www.bbc.com/portuguese/brasil-47034499>. Acesso em 16 mar. 2023.

PEJOVIĆ, Milutin; GOSPAVIĆ, Zagorka; MILOVANOVIĆ, Branko; ARSIĆ, Igor. Solving a surveying problem by using R and QGIS - Setting out of a land expropriation zone. **Geonauka**, [S.L.], v. 02, n. 02, p. 12-18, 28 jun. 2014. Serbian Union of Surveyors. Disponível em: <http://dx.doi.org/10.14438/gn.2014.11>. Acesso em: 21 maio 2023.

PEREIRA, L. F.; CRUZ, G. B.; GUIMARÃES, R. M. F. Impactos do rompimento da barragem de rejeitos de Brumadinho, Brasil: uma análise baseada nas mudanças de cobertura da terra. **Journal of Environmental Analysis and Progress**, Pernambuco, v. 04, n. 02, p. 122-129, 2019.

PHIRI, D. & MORGENROTH, J. 2017. Developments in Landsat Land Cover Classification Methods: A Review. **Remote Sensing**, 9(9): 1-25. Disponível em: <https://www.mdpi.com/2072-4292/9/9/967>. Acesso em: 30 nov. 2023.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPPLICH, T. M. Sensoriamento Remoto da Vegetação. 2 Ed. Atualizada e revisada. ISBN 978-85-7975-053-3. **São Paulo: Oficina de Textos**, 2012.

QUARTAROLI, Carlos Fernando; BATISTELLA, Mateus. **Classificação digital de imagens de sensoriamento remoto: tutorial básico**. 2006. Embrapa Territorial. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/102831/1/DOC-56-06.pdf>. Acesso em: 17 nov. 2023.

QUARTAROLI, Carlos Fernando; VICENTE, Luiz Eduardo; ARAÚJO, Luciana Spinelli de. **Sensoriamento Remoto**. 2014. Embrapa. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/103388/1/Cap.-4.pdf>. Acesso em: 16 mar. 2023.

RAMOS, Matheus Augusto de Oliveira; RAMOS, Vania Aparecida Alves; BAÚ, Rosana Zanetti. **Proposta de recuperação do solo da cidade de Brumadinho - MG**. 2021. Universidade São Francisco; Campus Bragança Paulista. Disponível em: <https://www.usf.edu.br/galeria/getImage/768/8568966429326170.pdf>. Acesso em: 18 jan. 2024.

RAMOS, Renilson Pinto da Silva; DEUS, Rodolfo Alexandre da Silva Gomes de; SILVA, Fernando Alexandre da; GOMES, Daniel Dantas Moreira; GOLDFARB, Mauricio Costa; MONTEIRO, Geovana de Oliveira. **Geoprocessamento e Sensoriamento Remoto utilizados para o mapeamento e identificação do uso e ocupação dos solos da bacia hidrográfica do rio Paraíba do Meio**. 2016. 4º GeoAlagoas – Simpósio sobre as geotecnologias e geoinformação no Estado de Alagoas. Disponível em: https://www.researchgate.net/publication/327424561_Geoprocessamento_e_Sensoriamento_Remoto_utilizados_para_o_mapeamento_e_identificacao_do_uso_e_ocupacao_dos_solos_da_bacia_hidrografica_do_Rio_Paraiba_do_Meio. Acesso em: 22 maio 2023.

R CORE TEAM (2023). *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria. <<https://www.R-project.org/>>.

REX, Franciel; KÄFER, Pâmela; DEBASTIANI, Aline; KAZAMA, Verônica. POTENCIAL DE IMAGENS MSI (SENTINEL-2) PARA CLASSIFICAÇÃO DO USO E COBERTURA DA TERRA. **Enciclopédia Biosfera**, [S.L.], v. 15, n. 27, p. 219-231, 20 jun. 2018. Centro Científico Conhecer. http://dx.doi.org/10.18677/encibio_2018a67. Disponível em: <https://www.conhecer.org.br/enciclop/2018a/agrar/potencial%20de%20imagens.pdf>. Acesso em: 06 fev. 2024.

REX, Franciel Eduardo; KÄFER, Pâmela Suélen; SPOHR, Renato Beppler; SANTOS, Renato Souza. CLASSIFICAÇÃO SUPERVISIONADA DE COPAS DE ÁRVORES EM IMAGEM DE ALTA RESOLUÇÃO ESPACIAL. **Biofix Scientific Journal**, [s. l.], v. 3, n. 2, p. 216-223, 2018. Universidade Federal do Paraná. Disponível em: <https://revistas.ufpr.br/biofix/article/view/59563/35664>. Acesso em: 31 maio 2023.

ROSA, M.R. 2018. Classificação do Padrão de Ocupação Urbana de São Paulo Utilizando Aprendizagem de Máquina e Sentinel-2. **Revista do Departamento de Geografia**, Volume Especial: 15-21. Disponível em: <https://www.revistas.usp.br/rdg/article/view/145784/147220>. Acesso em: 28 dez. 2023.

ROSA, Roberto. **Introdução ao Geoprocessamento**. 2013. Universidade Federal de Uberlândia. Instituto de Geografia. Laboratório de geoprocessamento. Disponível em: https://edisciplinas.usp.br/pluginfile.php/5595356/mod_resource/content/2/Apostila_Geop_rosa.pdf. Acesso em: 28 maio 2023.

ROUSE, J.W.; HAAS, R.H.; SCHELL, J.A.; DEERING, D.W. **Monitoring vegetation systems in the great plains with ERTS**. In: Third ERTS Symposium, Proceedings, NASA SP-351, NASA, Washington, DC, v. 1, p. 309-317, 1973.

SANTOS, Gustavo Carvalho. **Algoritmos de machine learning para previsão de ações da b3**. 2020. 94 f. Dissertação (Mestrado) - Curso de Ciências, Programa de Pós-Graduação da Faculdade de Engenharia Elétrica, Universidade Federal de Uberlândia, Uberlândia, 2020. Disponível em: <https://repositorio.ufu.br/bitstream/123456789/29897/7/AlgoritmosMachineLearning.pdf>. Acesso em: 02 dez. 2023.

SECRETARIA DE ESTADO DE MEIO AMBIENTE E DESENVOLVIMENTO SUSTENTÁVEL DE MINAS GERAIS (SEMAD). **NOTA DE ESCLARECIMENTO SEMAD - Área impactada entre Barragem B1 e Rio Paraopeba**. 2019. Governo do Estado de Minas Gerais. Disponível em: <https://www.sindsemamg.com.br/nota-de-esclarecimento-semad-area-impactada-entre-barragem-b1-e-rio-paraopeba/>. Acesso em: 20 nov. 2023.

SEYDI, Seyd Teymoor; HASANLOU, Mahdi; CHANUSSOT, Jocelyn. Burnt-Net: wildfire burned area mapping with single post-fire sentinel-2 data and deep learning morphological neural network. **Ecological Indicators**, [S.L.], v. 140, p. 108999, jul. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.ecolind.2022.108999>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1470160X22004708>. Acesso em: 01 fev. 2024.

SILVA, Osny Ferreira da. **Análise de imagens multitemporais do sensor TM LANDSAT-2 da vegetação do cerrado, utilizando técnicas de NDVI, no Parque Nacional das Emas-Goiás**. 2014. 98 f. Dissertação (Mestrado) - Curso de Tecnologia de Processos Sustentáveis, Pró-Reitoria de Pesquisa e Pós-Graduação, Instituto Federal de Educação, Ciência e Tecnologia de Goiás, Goiânia, 2014. Disponível em:

https://www.ifg.edu.br/attachments/article/5213/Disserta%C3%A7%C3%A3o_Processos%20Sustent%C3%A1veis_Osny%20Ferreira%20da%20Silva.pdf. Acesso em: 30 maio 2023.

SILVA, Rita de Cássia Ferreira da; SOUSA, Jocy Ana Paixão de; AMORIM, Amanda Trindade; LOPES, Elfany Reis do Nascimento; LOURENÇO, Roberto Wagner; FILHO3, Jose Luiz Albuquerque. **Análise comparativa de índices espectrais para a extração automática da lâmina d'água em imagem do satélite Landsat 8oli**. 2019. Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto ISBN: 978-85-17-00097-3. INPE, Santos-SP. Disponível em: <https://proceedings.science/sbsr-2019/papers/analise-comparativa-de-indices-espectrais-para-a-extracao-automatica-da-lamina-d-agua-em-imagem-do-satelite-landsat-8oli?lang=pt-br>. Acesso em: 17 mar. 2023.

Soluções em imagens de satélite e geoprocessamento (Engesat). **Sentinel-2**. 2015. Disponível em: <https://www.engesat.com.br/sentinel-2/>. Acesso em: 20 dez. 2023.

SOUSA, Djalma Martinhão Gomes de; LOBATO, Edson. **Latossolos**. 2021. Embrapa. Disponível em: <https://www.embrapa.br/agencia-de-informacao-tecnologica/tematicas/bioma-cerrado/solo/tipos-de-solo/latossolos>. Acesso em: 20 fev. 2024.

TUSZYNSKI J (2021). `_caTools`: Tools: Moving Window Statistics, GIF, Base64, ROC AUC, etc_. R package version 1.18.2, <https://CRAN.R-project.org/package=_caTools>.

VAEZA, Rafael Franco; OLIVEIRA FILHO, Paulo Costa de; MAIA, Adelena Golçalves; DISPERATI, Atílio Antonio. 2010. Uso e Ocupação do Solo em Bacia Hidrográfica Urbana a Partir de Imagens Orbitais de Alta Resolução. **Floresta e Ambiente**. 17(1): 23-29. Disponível em: <https://www.floram.org/article/10.4322/floram.2011.003/pdf/floram-17-1-23.pdf>. Acesso em: 15 abr. 2023.

VIEIRA, Tatiana Grossi Chquiloff; ALVES, Helena Maria Ramos; VOLPATO, Margarete Marin Lordelo; BERNARDES, Tiago; SANTOS, Éder Ribeiro dos. **Avaliação de classificadores automáticos no mapeamento de áreas cafeeiras da região de Guaxupé, Minas Gerais**. 2009. VI Simpósio de Pesquisa dos Cafés do Brasil. Disponível em: <https://www.alice.cnptia.embrapa.br/alice/handle/doc/880315>. Acesso em: 02 jan. 2024.

WICKHAM H, FRANÇOIS R, HENRY L, MÜLLER K, VAUGHAN D (2023). `_dplyr`: A Grammar of Data Manipulation_. R package version 1.1.4, <<https://CRAN.R-project.org/package=dplyr>>.

WOLFER, Matheus Frigo; MARCHESAN, Juliana; ALBA, Elisiane; SCHUH, Mateus; HONNEF, Dionatas Henrique; OLIVEIRA, Helena Silva; PEREIRA, Rudiney Soares. Análise do Uso e Cobertura da Terra Utilizando Imagens Sentinel-2A e Inteligência Artificial. **Anuário do Instituto de Geociências** - UFRJ ISSN 0101-9759 e-ISSN 1982-3908 - Vol. 43 - 4 / 2020 p. 395-403. Disponível em: <https://revistas.ufrj.br/index.php/aigeo/article/view/35620/22010>. Acesso em: 18 mar. 2023.

ZANOTTA, Daniel Capella; FERREIRA, Matheus Pinheiro; ZORTEA, Maciel.
Processamento de imagens de satélite. Campinas. São Paulo. Oficina de Textos, 2019. 320
p.