

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA
ENGENHARIA ELETRÔNICA E DE TELECOMUNICAÇÕES
CAMPUS PATOS DE MINAS

MARINA ALBERNAZ FERREIRA

**APLICAÇÃO DE TÉCNICAS DE DETECÇÃO DE
MUDANÇAS NO MAPEAMENTO DO BIOMA CERRADO NO
ALTO PARANAÍBA**

Patos de Minas - MG
2023

MARINA ALBERNAZ FERREIRA

**APLICAÇÃO DE TÉCNICAS DE DETECÇÃO DE
MUDANÇAS NO MAPEAMENTO DO BIOMA CERRADO NO
ALTO PARANAÍBA**

Trabalho de Conclusão de Curso apresentado à banca examinadora como requisito parcial de avaliação da disciplina de TCC2 da graduação em Engenharia Eletrônica e de Telecomunicações, da Faculdade de Engenharia Elétrica, da Universidade Federal de Uberlândia, Campus Patos de Minas.

Orientadora: Prof^a. Dr^a. Eliana Pantaleão

MARINA ALBERNAZ FERREIRA

**APLICAÇÃO DE TÉCNICAS DE DETECÇÃO DE
MUDANÇAS NO MAPEAMENTO DO BIOMA CERRADO NO
ALTO PARANAÍBA**

Trabalho de Conclusão de Curso apresentado à banca examinadora como requisito parcial de avaliação da disciplina de TCC2 da graduação em Engenharia Eletrônica e de Telecomunicações, da Faculdade de Engenharia Elétrica, da Universidade Federal de Uberlândia, Campus Patos de Minas.

Orientadora: Prof^a. Dr^a. Eliana Pantaleão

Banca examinadora:

Prof.^a Dr.^a Eliana Pantaleão – FACOM/UFU (Orientadora)

Prof. Dr. Rafael Augusto da Silva – FEELT/UFU (Membro 1)

Prof. Dr. Júlio César Coelho – FEELT/UFU (Membro 2)

Patos de Minas – MG
2022

RESUMO

O monitoramento dos recursos naturais tem se tornado tema de grandes discussões socioambientais nas últimas décadas, exigindo informações relevantes com alto grau de confiabilidade. O sensoriamento remoto está no centro da geração de dados ambientais, por meio de capturas multiespectrais, seja de satélites ou drones, demandando um alto poder de processamento e conhecimento na aplicação das técnicas computacionais de processamento de imagens. A aplicação de técnicas de sensoriamento remoto, que cooperem com o tratamento dos dados adquiridos e armazenados ao longo dos anos, é uma forma de gerar informações de interesse. Por isso, este trabalho se propõe a utilizar a detecção de mudanças, aplicada a imagens adquiridas via satélite, da macrorregião do Alto Paranaíba, em Minas Gerais, através da plataforma Google Earth Engine, que permite o processamento em nuvem, em busca de resultados que possam embasar futuras pesquisas. Embora não tenham sido totalmente proveitosos, os métodos apresentaram resultados positivos em certa medida e podem contribuir no mapeamento do Cerrado.

Palavras-chave: sensoriamento remoto, detecção de mudanças, Google Earth Engine, processamento de imagens, Cerrado.

ABSTRACT

The monitoring of natural resources has become the subject of great socio-environmental discussions in recent decades, requiring relevant information with a high degree of reliability. Remote sensing is at the center of environmental data generation, through multispectral captures, whether satellites or drones, demanding a high processing power and knowledge in the application of computational techniques of image processing. The application of remote sensing techniques, which cooperate with the processing of data acquired and stored over the years, is a way to generate information of interest. Thus, this work aims to use the detection of changes, applied to images acquired via satellite, from the Alto Paranaíba macro-region, in Minas Gerais, through the Google Earth Engine platform, which allows cloud processing, in search of results that may support future researches. Although not perfect, the methods showed positive results to some extent and may contribute to the mapping of the Cerrado.

Keywords: remote sensing, change detection, Google Earth Engine, image processing, Cerrado.

LISTA DE FIGURAS

| | |
|--|----|
| Figura 1.1 Distribuição dos biomas no território brasileiro de acordo com o IBGE. | 15 |
| Figura 2.1 Etapas de um sistema de processamento de imagens. | 18 |
| Figura 2.2 Vetores elétrico (E) e magnético (B) de uma onda eletromagnética de comprimento λ vistos em um determinado instante com propagação na direção x | 19 |
| Figura 2.3 Espectro Eletromagnético | 20 |
| Figura 2.4 Assinaturas espectrais da vegetação e da água | 23 |
| Figura 2.5 Sistema visual humano | 24 |
| Figura 2.6 Sistemas de cores aditivas | 25 |
| Figura 2.7 Estrutura de câmera digital colorida | 26 |
| Figura 2.8 Estrutura de uma câmera digital de infravermelho | 26 |
| Figura 2.9 Distribuição geográfica dos principais biomas do Brasil, destacando a área ocupada pelo Cerrado. | 29 |
| Figura 3.1 <i>Code Editor</i> | 32 |
| Figura 3.2 Demarcação da região do Alto Paranaíba – MG. | 34 |
| Figura 3.3 Imagens do <i>Landsat-8</i> , do Alto Paranaíba, de 2020 no período de 01 a 20 de Fevereiro nas bandas referentes ao espectro visível (bandas 4, 3 e 2). | 36 |
| Figura 3.4 Imagens do <i>Landsat-8</i> , do Alto Paranaíba, de 2020 no período de 01 de Julho a 30 de Setembro Fevereiro nas bandas referentes ao espectro visível (bandas 4, 3 e 2). | 36 |
| Figura 3.5 Imagens do <i>Landsat-8</i> , do Alto Paranaíba, de 2020 no período de 01 de Julho a 30 de Setembro, nas bandas (a) NIR, (b) SWIR 1 e (c) SWIR 2 | 38 |
| Figura 3.6 Recorte da imagem do <i>Landsat – 8</i> mostrando a cidade de Patos de Minas nas bandas (a) 4, 3, 2, (b) 5, 4, 3, (c) 7, 6, 4, (d) 6, 5, 4 e (e) 7, 5, 4. | 39 |
| Figura 3.7 - <i>Data Catalog</i> do GEE. | 42 |
| Figura 3.8 - Coleção selecionada referente à <i>Collection 2</i> , do <i>Landsat-8</i> , Reflectância da Superfície, <i>Tier 1</i> | 43 |
| Figura 3.9 - Marcação dos municípios do Alto Paranaíba com (a) delimitação aproximada do território e (b) cobertura de imagens. | 43 |
| Figura 3.10 - Exemplo de código com filtros de região e data aplicados à uma <i>ImageCollection</i> | 44 |
| Figura 3.11 - Subdivisão das microrregiões do estado de Minas Gerais. | 44 |
| Figura 3.12 - Imagens que cobrem o Alto Paranaíba limitadas à fronteira do estado de Minas Gerais. | 45 |

| | |
|---|----|
| Figura 3.13 - Exemplo de definição dos parâmetros de visualização das imagens em que (a) representa o espectro visível e (b) a combinação CIR. | 45 |
| Figura 3.14 - Menu de configurações dos parâmetros de visualização do GEE. | 46 |
| Figura 3.15 - Exemplo de subtração entre imagens de 2020 e 2013. | 46 |
| Figura 3.16 - Exemplo de código para o cálculo da diferença normalizada do índice de vegetação (NDVI). | 47 |
| Figura 3.17 - Exemplo de código da definição da região do Alto Paranaíba. | 48 |
| Figura 3.18 - Código correspondente ao filtro de nuvem. | 49 |
| Figura 3.19 – Exemplo de aplicação do filtro de nuvem, do período de 01/08/2020 a 30/08/2020. | 49 |
| Figura 3.20 - Exemplo de código com a seleção das imagens e resultados obtidos após as funções <i>mosaic</i> e <i>clip</i> , para os anos de 2013 e 2020, visualizadas em RGB. | 50 |
| Figura 3.21 - Código utilizado para isolar as bandas RGB em cada imagem. | 51 |
| Figura 3.22 - Resultado da subtração para a banda SR_B4 (vermelho) com parâmetro de visualização Stretch: 3σ | 51 |
| Figura 3.23 - Resultado da subtração para a banda SR_B3 (verde) com parâmetro de visualização Stretch: 3σ | 52 |
| Figura 3.24 - Resultado da subtração para a banda SR_B2 (azul) com parâmetro de visualização Stretch: 3σ | 52 |
| Figura 3.25 - Exemplo de aplicação do <i>stretch</i> a um histograma. | 53 |
| Figura 3.26 - Imagem resultante da subtração em que (a) é a imagem base e (b) a imagem com parâmetro de visualização com <i>stretch</i> de 1σ | 54 |
| Figura 3.27 - Histograma das bandas que compõem a imagem resultante da subtração. | 54 |
| Figura 3.28 - Utilização do <i>toolkit</i> do Mapbiomas de cobertura e uso da terra (<i>Land Use and Land Cover</i>) em que (a) são filtros utilizados e (b) o resultado de 2013. | 55 |
| Figura 3.29 - Código de aplicação das máscaras para retornar apenas valores válidos que sejam maiores que 2918 e menores que -947. | 56 |
| Figura 3.30 - Mapa experimental com destaque para os resultados obtidos da aplicação das máscaras com limiar de 10% dos valores de mínimo e máximo. | 57 |
| Figura 3.31 - Mapa verdade. | 58 |
| Figura 3.32 - Mapa experimental gerado com limiares de 256 e -256. | 59 |
| Figura 3.33 - Função aplicada para resposta de equivalência, com os resultados considerando a criação do mapa experimental com limiares de (a) -256 e 256, (b) -256 e 512 e (c) -256 e 1024. | 60 |

| | |
|--|----|
| Figura 3.34 - Função para o cálculo da quantidade de pixels em uma região, com uma escala de 30 metros e com o máximo de pixels de 1^9 | 60 |
| Figura 3.35 - Função aplicada para o retorno do mapa do cerrado natural classificado. | 62 |
| Figura 3.36 - Mapa do cerrado em 2013 gerado pela função descrita na Figura 3.35..... | 63 |
| Figura 3.37 - Mapa do cerrado em 2020 gerado pela função descrita na Figura 3.35..... | 63 |
| Figura 3.38 - Respostas da equivalência entre o mapa do cerrado de 2013 e o mapa experimental com limiares de (a) -256 e 256, (b) -256 e 512 e (c) -256 e 1024..... | 64 |
| Figura 3.39 - Respostas da equivalência entre os mapas da Figura 3.38 e o mapa do cerrado de 2020, sendo a operação inicial realizada para o mapa experimental com limiares de (a) -256 e 256, (b) -256 e 512 e (c) -256 e 1024..... | 64 |
| Figura 4.1 - Comparação visual entre a (a) resposta obtida para limiar inferior em -1024 e superior em 512 e (b) resposta esperada. | 69 |
| Figura 4.2 - Diferença entre as distribuições de pixels entre o (a) mapa obtido e o (b) mapa esperado..... | 70 |

LISTA DE ABREVIATURAS E SIGLAS

| | |
|-----------------|--|
| API | <i>Application Programming Interface</i> |
| CCD | <i>Charge-coupled device</i> |
| CIR | <i>Color Infrared</i> |
| ERTS | <i>Earth Resources Technology Satellite</i> |
| FM | <i>Frequency Modulation</i> |
| GEE | <i>Google Earth Engine</i> |
| IBGE | Instituto Brasileiro de Geografia e Estatística |
| IDE | <i>Integrated Development Environment</i> |
| MIR | <i>Mid Infrared</i> |
| NASA | <i>National Aeronautics and Space Administration</i> |
| NDVI | <i>Normalized Difference of Vegetation Index</i> |
| NIR | <i>Near Infrared</i> |
| OLI | <i>Operational Land Imager</i> |
| PAN | Pancromática |
| QA_PIXEL | <i>Pixel Quality Assessment Band</i> |
| REM | Radiação Eletromagnética |
| RGB | <i>Red, Green, Blue</i> |
| RT | <i>Real Time</i> |
| SBSR | Simpósio Brasileiro de Sensoriamento Remoto |
| SR | <i>Surface Reflectance</i> |
| ST | <i>Surface Temperature</i> |
| SWIR | <i>Shortwave Infrared</i> |
| TIR | <i>Thermal Infrared</i> |
| TIRS | <i>Thermal Infrared Sensor</i> |
| TOA | <i>Top of Atmosphere</i> |
| TV | Televisão |
| UFU | Universidade Federal de Uberlândia |
| USGS | <i>United States Geological Survey</i> |

LISTA DE SÍMBOLOS

| | |
|-----------|---|
| λ | Comprimento de onda |
| c | Velocidade da luz (3×10^8 m/s) |
| f | Frequência |
| n | Índice de refração |
| c_n | Velocidade da luz em uma substância |
| θ | Ângulo de refração/incidência |
| t | Tempo |
| D_{ijk} | Valor matemático do pixel na linha i, coluna j e banda k |
| x_{ijk} | Valor do pixel, na linha i, coluna j e banda k, em um determinado tempo |
| VD_{ij} | Valor da diferença de NDVI do pixel, na linha i e coluna j |

SUMÁRIO

| | |
|--|-----------|
| 1. INTRODUÇÃO..... | 12 |
| 1.1. TEMA DO PROJETO | 13 |
| 1.2. PROBLEMATIZAÇÃO | 13 |
| 1.3. HIPÓTESES | 14 |
| 1.4. OBJETIVOS | 14 |
| 1.5. JUSTIFICATIVAS..... | 14 |
| 1.6. CONSIDERAÇÕES FINAIS..... | 16 |
| 2. REFERENCIAL TEÓRICO | 17 |
| 2.1. SENSORIAMENTO REMOTO | 17 |
| 2.1.1. Radiação..... | 19 |
| 2.1.1.1. Radiação eletromagnética | 19 |
| 2.1.1.2. Espectro Eletromagnético | 20 |
| 2.1.1.3. Efeitos de interação da energia com a atmosfera e superfície | 21 |
| 2.1.1.4. Assinatura Espectral..... | 23 |
| 2.1.2. Captura de imagens | 24 |
| 2.1.2.1. Sistema de formação de cores | 24 |
| 2.1.2.2. Câmeras digitais..... | 25 |
| 2.1.2.3. Câmeras não - convencionais..... | 26 |
| 2.1.2.4. Geradores de Imagens Orbitais..... | 27 |
| 2.2. APLICAÇÕES DE SENSORIAMENTO REMOTO..... | 27 |
| 2.3. VEGETAÇÃO DO CERRADO | 29 |
| 2.4. CONSIDERAÇÕES FINAIS..... | 30 |
| 3. MATERIAIS E MÉTODOS | 31 |
| 3.1. MATERIAIS | 31 |
| 3.1.1. <i>Google Earth Engine</i> | 31 |
| 3.1.2. <i>Code Editor</i> | 31 |
| 3.1.3. <i>Landsat - 8</i> | 33 |
| 3.2. MÉTODOS..... | 33 |
| 3.2.1. Área de estudo | 33 |
| 3.2.2. Aquisição de imagens | 34 |
| 3.2.3. Pré-Processamento | 37 |
| 3.2.4. Identificação de bandas | 37 |

| | | |
|----------|--|----|
| 3.2.5. | Detecção de mudanças | 40 |
| 3.2.5.1. | Diferenciação de imagens | 40 |
| 3.2.5.2. | Diferenciação dos índices de vegetação..... | 40 |
| 3.2.5.3. | Comparação pós-classificação | 40 |
| 3.2.5.4. | Classificação multidata direta | 41 |
| 3.2.5.5. | Análise do vetor de mudança | 41 |
| 3.2.6. | Classificação das imagens..... | 41 |
| 3.3. | DESENVOLVIMENTO..... | 42 |
| 3.3.1. | Experimentação..... | 42 |
| 3.3.2. | Definição do escopo | 47 |
| 3.3.3. | Limitação da área de estudo..... | 48 |
| 3.3.4. | Seleção das imagens e pré-processamento | 48 |
| 3.3.5. | Separação das bandas | 50 |
| 3.3.6. | Subtração | 51 |
| 3.3.7. | Obtenção dos resultados | 54 |
| 3.3.7.1. | Aquisição das imagens já classificadas | 55 |
| 3.3.7.2. | Criação do mapa experimental e do mapa verdade | 56 |
| 3.3.7.3. | Visualização de equivalência..... | 59 |
| 3.3.7.4. | Cálculo de equivalência | 60 |
| 3.3.7.5. | Mapa classificado da vegetação do cerrado | 61 |
| 3.3.7.6. | Comparando as mudanças com os mapas do cerrado..... | 64 |
| 3.4. | CONSIDERAÇÕES FINAIS..... | 65 |
| 4. | RESULTADOS E DISCUSSÕES..... | 66 |
| 4.1. | RESULTADOS..... | 66 |
| 4.1.1. | Definição do limiar de mudanças..... | 66 |
| 4.1.2. | Comparação com o cerrado de 2013 | 68 |
| 4.1.3. | Comparação com o cerrado de 2020 | 71 |
| 4.2. | DISCUSSÕES | 74 |
| 4.3. | CONSIDERAÇÕES FINAIS..... | 75 |
| 5. | CONCLUSÃO E TRABALHOS FUTUROS | 76 |
| 5.1. | CONSIDERAÇÕES FINAIS..... | 77 |
| 6. | REFERÊNCIAS..... | 78 |

CAPÍTULO 1

INTRODUÇÃO

A vida no planeta Terra é baseada na exploração e manutenção dos recursos naturais, presentes na sua superfície e no seu interior. Conforme surgiu a necessidade do monitoramento de tais recursos, a tecnologia evoluiu, de modo a garantir que o homem tivesse acesso à informação suficiente para determinar o limiar de exploração deles. O monitoramento remoto, também conhecido como sensoriamento remoto, “é a arte e a ciência de obter informações sobre um objeto sem estar em contato físico” com ele (JENSEN, 2009, p. XIII). Inicialmente era conhecido como fotointerpretação aérea, utilizada na observação da natureza. Entretanto, o avanço dos instrumentos de coleta e interpretação de imagens, passou a abranger regiões além do espectro visível e tornou o nome obsoleto, pois não se tratava exclusivamente de fotos (fotografia = escrever com luz visível). Entre os anos 60 e início dos anos 70, foi promovido o nome de sensoriamento remoto em simpósios nos Laboratórios Willow Run, da Universidade de Michigan em conjunto com o National Research Council (JENSEN, 2009).

As técnicas de sensoriamento remoto têm sido desenvolvidas e aprimoradas por mais de 150 anos. Durante o período da I e II Guerras Mundiais, ocorreram picos de investimento em pesquisas científicas que deram origem a sofisticados sistemas eletro-ópticos multiespectrais, de infravermelho termal e de micro-ondas (radar). Os métodos e as áreas de análise foram se adaptando, saindo de um interesse puramente militar, para ser amplamente utilizado no monitoramento do ambiente terrestre (JENSEN, 2009).

No Brasil, o sensoriamento remoto da vegetação começou a ser implementado na década de 40, ainda com o sistema de fotointerpretação, em projetos bem específicos, sendo o mais significativo o projeto RADAMBRASIL, que abrangeu todo o território nacional. Esse projeto tinha o objetivo de caracterizar as fisionomias vegetais e aspectos de geologia, geomorfologia e solos (PONZONI e SHIMABUKURO, 2009). Nos tempos atuais, destacando a importância do monitoramento do território brasileiro para o estudo de alterações climáticas, há incentivos governamentais no desenvolvimento de satélites, sendo o Amazônia-1 o primeiro satélite nacional a ser lançado para esse fim (AERO, 2021).

Um sistema de sensoriamento remoto é constituído por sensores, alocados em satélites, drones, aviões, que captam informações de radiação e as enviam a uma base terrestre, para que possam ser processadas e interpretadas, resultando em mapas temáticos e outros tipos de recursos informativos (JOSEPH, 2005). Os dados fornecidos por esses sistemas permitem

uma visão de área muito extensa, quando comparado ao que é possível se ter visão, estando em solo. Algumas aplicações específicas que fazem uso de tal vantagem incluem as previsões climáticas, o monitoramento das imensas queimadas florestais, o acompanhamento do crescimento das cidades e alterações de vegetação ao longo do tempo (USGS, [S.D.]).

Partindo do lançamento do primeiro satélite destinado à coleta de dados de recursos naturais da Terra, em 1972, o chamado *Earth Resources Technology Satellite* (ERTS-1), posteriormente conhecido como *Landsat -1*, tornou-se possível obter informações de toda a superfície e atmosfera do planeta, através de imagens. Nestes 50 anos, a quantidade de dados de sensoriamento remoto coletados por satélites passa da casa dos *petabytes* (10^{15} bytes) (GOOGLE, 2017) e se manterá em um processo de contínuo crescimento, já que, novos satélites, com a mesma finalidade, ainda são lançados, abrigando melhorias na aquisição das informações, provendo imagens em alta resolução.

Tendo em vista a capacidade de obtenção de dados relevantes, este projeto visa a aplicação de técnicas de sensoriamento remoto, prioritariamente métodos de detecção de mudanças, no mapeamento da vegetação do cerrado, destacando as diferentes características do bioma, na região do Alto Paraíba, no estado de Minas Gerais, utilizando processamento digital de imagens através de ferramentas disponibilizadas *online*.

1.1. TEMA DO PROJETO

O tema abordado no projeto é a aplicação de métodos e técnicas de sensoriamento remoto, com ênfase em detecção de mudanças, no mapeamento da vegetação do bioma cerrado, presente na região do Alto Paranaíba em Minas Gerais, utilizando ferramentas disponibilizadas pelo Google®.

1.2. PROBLEMATIZAÇÃO

Dentro do cenário ambiental, a necessidade de obter conhecimento e de externalizar dados se tornou uma demanda básica para a tomada de decisões que vão desde a criação de políticas públicas, até a decisão de carregar um guarda-chuva na mochila. Neste contexto, estão inseridos métodos, em todas as escalas de análise, cujos resultados devem dar suporte às escolhas feitas pela sociedade e, portanto, devem apresentar elevado grau de confiabilidade, sendo respaldado por quem os aplica e demais pessoas que possuem o conhecimento para tal.

É natural que estes métodos sejam aprimorados, conforme o aumento da demanda por informações e, considerando o cenário atual em que presenciamos catástrofes ambientais, desmatamento desenfreado de áreas verdes, exploração em excesso de recursos naturais,

discussões sobre o aquecimento global antropogênico, dentre outros acontecimentos, essa demanda nunca esteve tão alta.

Portanto, a aplicação de técnicas, em diferentes extensões de áreas e localidades, utilizando diferentes tecnologias e métodos, é algo que agrega às pesquisas ambientais, ampliando a quantidade de meios para a aquisição de dados relevantes.

1.3. HIPÓTESES

A hipótese levantada é de que é possível a aplicação técnicas de detecção de mudanças no mapeamento da vegetação do cerrado no Alto Paranaíba, utilizando ferramentas *online*, para a obtenção de resultados relevantes, visando possíveis pesquisas ambientais.

1.4. OBJETIVOS

1.4.1 Objetivos Gerais

O objetivo principal deste projeto é o estudo e aplicação de técnicas de sensoriamento remoto, com o intuito de obter um resultado satisfatório no mapeamento da vegetação do cerrado no Alto Paranaíba, em Minas Gerais, utilizando *datasets* e ferramentas *online*.

1.4.2 Objetivos Específicos

- Fazer o levantamento de possíveis técnicas de detecção de mudanças aplicáveis, conforme os projetos semelhantes já existentes.
- Determinar as principais características da vegetação que serão mapeadas.
- Aplicar as técnicas viáveis, conforme as características do bioma.
- Documentar o resultado, destacando os pontos qualitativos das técnicas.

1.5. JUSTIFICATIVAS

Considerando um cenário próximo à localidade da Universidade Federal de Uberlândia (UFU) – *campus* Patos de Minas, na mesorregião do Triângulo Mineiro/Alto Paranaíba, tem-se que a vegetação é pertencente ao bioma do cerrado, o qual é o segundo maior, em cobertura de terra, no Brasil (Figura 1.1), sendo alvo do avanço desenfreado da agropecuária, e sofrendo com a redução da sua biodiversidade e aumento do desmatamento (LIMA, 2022), destacando-se como um bom objeto para aplicações de técnicas de sensoriamento remoto.

Figura 1.1 Distribuição dos biomas no território brasileiro de acordo com o IBGE.



Fonte: SOUZA (2020).

Atualmente, inúmeras pesquisas já foram realizadas no intuito de mapear regiões vegetativas no país e no mundo, sendo este um procedimento, de certo modo, contínuo, uma vez que o ambiente está em constante mudança.

Novas ferramentas vêm auxiliando nesses processos, como o *Google Earth Engine* (GEE). Além de abrigar uma biblioteca de imagens de satélite, o GEE também permite que elas sejam processadas através do *Google Cloud Platform*, um provedor de recursos de computação em nuvem, promovendo rapidez e automaticidade no processamento (GORELICK, HANCHER, *et al.*, 2017). Trabalhos semelhantes como o de SOUZA (2020) utilizam o GEE para avaliar mudanças na cobertura do solo.

A aplicação de técnicas de detecção de mudança é comum em análises temporais de cobertura vegetal, e vem sendo usada ao longo dos anos. Trabalhos semelhantes ao projeto proposto foram apresentados e revisados em SINGH (2010), além do trabalho de análise da cobertura vegetal de Manaus de MATOS e DA SILVA (2005), apresentado ao Simpósio Brasileiro de Sensoriamento Remoto (SBSR).

1.6. CONSIDERAÇÕES FINAIS

Neste capítulo, foram abordadas questões relativas aos problemas e motivações que justificam e embasam a aplicação de técnicas de sensoriamento remoto no mapeamento de vegetações, tal qual o bioma do cerrado. Também foram apresentados projetos semelhantes, com a utilização de métodos distintos, que se diferenciam nos objetivos e áreas às quais as técnicas foram aplicadas, porém, que podem ser reproduzidos ou adaptados neste projeto. No próximo capítulo será tratada a teoria que caracteriza o sensoriamento remoto.

CAPÍTULO 2

REFERENCIAL TEÓRICO

Para um melhor entendimento dos princípios que caracterizam esse estudo, este referencial aborda noções de sensoriamento remoto. Estão inclusas as principais características dos processos, como as faixas mais utilizadas do espectro eletromagnético, assim como as formas de capturas das imagens. Além disso, são discutidas possíveis análises e técnicas aplicáveis dentro do contexto de mapeamento vegetativo utilizando imagens de satélites. Um último ponto tratado são as características da vegetação do Cerrado, para uma possível classificação.

2.1. SENSORIAMENTO REMOTO

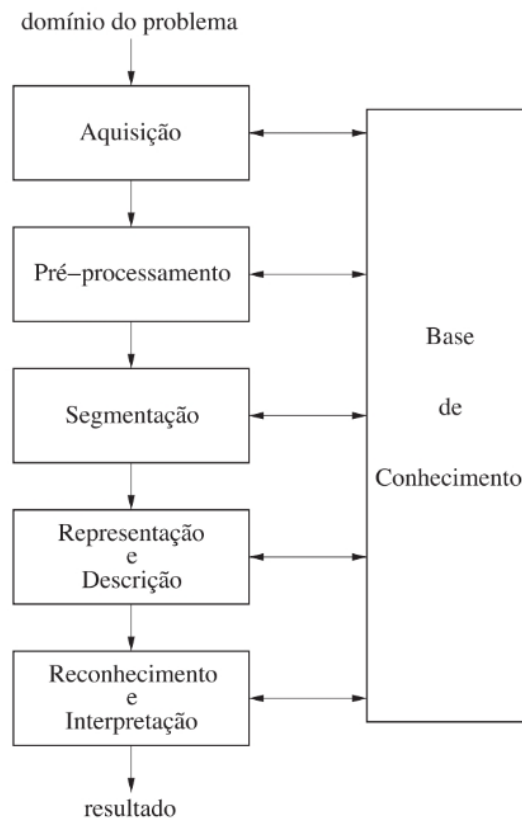
Para realizar uma análise, tratando de modo generalizado, é necessário que haja inicialmente a coleta dos dados. Existem formas diferentes de obtenção dos dados. Uma delas seria a coleta *in situ*, que demanda o deslocamento do cientista ao local de coleta, possibilitando a ele questionar o fenômeno de interesse, utilizar de alguma ferramenta para coletar a informação, dentre outros procedimentos (JENSEN, 2009).

Os dados coletados *in situ*, apesar de relevantes para pesquisas, podem ser acompanhados de erros produzidos durante o processo. Alguns deles se dão pela execução humana, ou são provenientes da calibração ou fabricação dos equipamentos. Outra forma de inserção de erros seria a intrusão do humano no ambiente de coleta (JENSEN, 2009). Para minimizar os erros discutidos, há o método de coleta de dados de forma remota. Partindo de um lugar distante e geograficamente privilegiado, sem que haja contato físico, é possível extrair informações de uma área geográfica ou objeto utilizando as técnicas de sensoriamento remoto (PONZONI e SHIMABUKURO, 2009).

A radiação eletromagnética, cuja interação com os objetos permite a extração de informações, é peça fundamental na aplicação do sensoriamento remoto. Esta interação é capturada na forma de imagens multiespectrais. A captura pode ser realizada por diferentes câmeras ou sensores, acopladas em veículos que promovam a visão privilegiada das respectivas áreas de análise, tais quais os aviões, drones, balões ou satélites (PONZONI e SHIMABUKURO, 2009).

Imagens adquiridas com o objetivo de análise passam por um pré-processamento, de acordo com o método utilizado para a captura. As etapas de processamento seguem conforme um escopo básico de processamento de imagens digitais apresentados na Figura 2.1.

Figura 2.1 Etapas de um sistema de processamento de imagens.



Fonte: PEDRINI e SCHWARTZ 2008.

O passo inicial para qualquer sistema de processamento de imagens é a definição do domínio do problema que determinará qual o resultado desejado. A aquisição corresponde à etapa de captura e transformação da imagem em uma representação que possibilite o processamento digital (PEDRINI e SCHWARTZ, 2008). A representação pode vir carregada de ruídos ou imperfeições que prejudicam a qualidade da imagem. O pré-processamento é a etapa que trata tais interferências, através de filtros de ruído, correções de contraste, dentre outros procedimentos (PEDRINI e SCHWARTZ, 2008).

A etapa seguinte consiste na segmentação da imagem, que consiste na extração e identificação de grupos ou objetos semelhantes, dentro da área de interesse. São utilizadas então, estruturas adequadas que representam tais grupos/objetos extraídos da imagem. No processo de descrição são definidas as características ou propriedades dos itens extraídos, de modo a ser possível discriminar um grupo de outro, encerrando assim a etapa de representação e descrição (PEDRINI e SCHWARTZ, 2008). O reconhecimento, também conhecido como classificação, atribui um valor que identifica o grupo, baseado nas características definidas na etapa de descrição. Já a interpretação é a etapa em que se atribui um significado ao grupo ou objeto (PEDRINI e SCHWARTZ, 2008). A base de conhecimento é variável de acordo com

o domínio do problema. Ela implica na identificação das melhores técnicas aplicáveis em cada tipo de análise guiando a comunicação entre os módulos (PEDRINI e SCHWARTZ, 2008).

A análise de imagens difere do processamento, sob uma visão computacional. O processamento envolve a aplicação de técnicas para capturar, representar e transformar as imagens com o intuito de melhorar a qualidade visual e permitir a interpretação automática por máquinas. A análise, por sua vez, possui um caráter multidisciplinar, sendo baseada na forma, na textura, nos níveis de cinza ou nas cores dos objetos pertencentes à imagem, demandando conhecimentos nas áreas da geometria computacional, estatística, teoria da informação, dentre outros (PEDRINI e SCHWARTZ, 2008).

Portanto, serão tratados nesta seção termos como radiação eletromagnética, captura de imagens multiespectrais e o processamento e análise dessas imagens, compondo assim um processo de sensoriamento remoto.


2.1.1. Radiação

A definição de radiação, em termos físicos, é a propagação da energia de um ponto a outro. Na natureza é possível encontrar variadas formas de energia, como mecânica, nuclear, elétrica, entre outras, sendo que, conforme a lei da conservação da energia, elas podem se transformar umas nas outras (JONES e VAUGHAM, 2010).

2.1.1.1. Radiação eletromagnética

A energia irradiada através do vácuo, sem a necessidade de um meio material, se propaga através de campos eletromagnéticos, sendo denominada então, radiação eletromagnética. Ela é gerada quando uma carga elétrica é acelerada, gerando um campo magnético. Portanto, sua composição inclui uma onda elétrica, ortogonal (ângulo de 90°) a uma onda magnética, descrita na Figura 2.2 (JENSEN, 2009). A velocidade de propagação nesse meio é a chamada velocidade da luz (c), que é uma constante de valor aproximado a 3×10^8 m/s.

Figura 2.2 Vetores elétrico (E) e magnético (B) de uma onda eletromagnética de comprimento λ vistos em um determinado instante com propagação na direção x .



Fonte: JOSEPH (2005).


A propagação da energia acontece em forma de ondas cíclicas. O comprimento de onda (λ) em cada ciclo é definido pela frequência da onda f , sendo um inversamente proporcional ao outro (Equação 1). Portanto, frequências maiores produzem comprimentos de onda pequenos e vice-versa (STEFFEN, 2006). O comprimento de onda é uma grandeza dada em metros, e a frequência em Hertz (Hz).

$$\lambda = \frac{c}{f} \quad (1)$$

2.1.1.2. Espectro Eletromagnético

Partindo de uma das principais características das ondas eletromagnéticas, a frequência, é possível destacar regiões específicas no espectro (Figura 2.3).

Figura 2.3 Espectro Eletromagnético



Fonte: LIRA ([S.D.]).

Os intervalos de frequência, ou comprimento de onda, no espectro eletromagnético, são chamados de bandas, canais ou regiões (JENSEN, 2009). Seguindo as divisões apresentadas na Figura 2.2, a luz visível ao olho humano ocupa apenas um curto espaço do espectro, localizado entre 750 e 400 nm. As frequências mais altas que ele (menores comprimentos de onda) abrigam as radiações mais energéticas como ultravioleta, raios x e raios gama. Do lado oposto, na região de frequências mais baixas que a luz visível, há a presença do infravermelho, que pode ser subdividido em: infravermelho próximo (NIR – *Near Infrared* de 700 nm a 1 μm); infravermelho médio (MIR – *Mid Infrared* de 1 - 4 μm) e infravermelho térmico (TIR – *Thermal Infrared* de 4 - 15 μm) (JONES e VAUGHAM, 2010), além das micro-ondas, ondas de TV (Televisão) e FM (*Frequency Modulation*) e ondas de rádio.

A subdivisão do infravermelho difere entre autores, tanto na porção do espectro, quanto na nomenclatura, incluindo o infravermelho longínquo, por exemplo, na faixa de 4-300 μm . Há também a divisão quanto ao comprimento de onda, separando em infravermelho de onda curta (SWIR – *Short Wavelength Infrared* de 0.9 – 1.7 μm), infravermelho de onda média (MWIR – *Middle Wavelength Infrared* de 3.0 - 5.0 μm), e infravermelho de onda longa (LWIR – *Long Wavelength Infrared* de 8.0 – 14 μm) (SWANSEY, [S.D.]).

2.1.1.3. Efeitos de interação da energia com a atmosfera e superfície

A radiação eletromagnética, ao entrar em contato com a atmosfera, pode sofrer alteração na velocidade e no seu comprimento de onda, assim como também na sua intensidade e sua distribuição espectral. Ela também pode ser afetada por desvios da sua direção original, devido à refração. Por sua vez, quando atinge a superfície terrestre, pode ser refletida, transmitida ou absorvida.

Quando a radiação, que viaja na velocidade da luz no vácuo (c), encontra substâncias com densidades diferentes, ela pode sofrer refração. Tal efeito é caracterizado pelo desvio da luz quando ela passa de um meio para outro, desde que estes tenham densidades distintas, o que é justificado pela desigualdade da velocidade que a radiação eletromagnética (REM) possui em cada meio (JENSEN, 2009).

O índice de refração (n) é dado pela razão entre a velocidade da luz vácuo (c) e a velocidade da luz em uma substância (c_n) (Equação 2).

$$n = \frac{c}{c_n} \quad (2)$$

A refração pode ser descrita pela Lei de Snell (Equação 3), que define que “para uma dada frequência da luz, o produto do índice de refração pelo seno do ângulo (θ) entre o raio e a linha normal à interface é constante” (JENSEN, 2009, p.49).

$$n_1 \text{sen}(\theta_1) = n_2 \text{sen}(\theta_2) \quad (3)$$

O espalhamento é um efeito da atmosfera que, diferente da refração, cuja direção é previsível, resulta um desvio da luz com direção imprevisível. Existem, essencialmente, três tipos de espalhamento: o Rayleigh, Mie e espalhamento não-seletivo. Todo espalhamento acontece com a absorção e reemissão de radiação, por átomos e moléculas, sendo impossível prever a direção em que emitirão um fóton (JENSEN, 2009).

O espalhamento Rayleigh ocorre em situações em que o diâmetro da matéria é muito menor que o comprimento de onda da REM incidente. Já o espalhamento Mie, acontece quando a matéria e o comprimento de onda são aproximadamente iguais, sendo observado nos 4,5 km inferiores da atmosfera e, a magnitude deste espalhamento é maior que a do Rayleigh, assim como os comprimentos de onda espalhados. Por fim, o espalhamento não-seletivo é notado onde há partículas mais de dez vezes maior que o comprimento de onda incidente, em porções mais baixas da atmosfera. O fato de ser não-seletivo, indica que todos os comprimentos de onda são espalhados. O espalhamento pode reduzir de forma significativa as informações e dados coletados, por sensoriamento remoto, tornando os objetos das imagens indistinguíveis (JENSEN, 2009).

A energia radiante que sofre o efeito de absorção, é transformada em outras formas de energia. Isso ocorre quando a energia incidente tem a mesma frequência que a frequência ressonante de um átomo ou molécula sendo absorvida, resultando em um estado de excitação. Nesse estado, é normal que ocorra a liberação de um fóton de mesma frequência. Porém, quando acontece de parte da energia ser transformada em calor e ser novamente irradiada com um comprimento de onda maior que o original, ocorre a absorção. Um exemplo de absorção é a clorofila, presente nas plantas, que absorve bastante dos comprimentos de onda vermelho e azul incidentes, para fins de fotossíntese (JENSEN, 2009).

A reflectância, por sua vez, exibe características fundamentais, que são de extrema importância na aplicação do sensoriamento remoto. Ela se caracteriza pelo processo em que a radiação resvala em um objeto ou matéria (JENSEN, 2009).

Existem diversos tipos de superfícies refletoras, sendo as superfícies essencialmente lisas responsáveis pela reflexão especular, na qual feições como corpos d'água calmos, se caracterizam como refletores especulares quase perfeitos. Superfícies rugosas dão origem à reflexão difusa, cujos raios refletidos vão em muitas direções e que não produz uma imagem

espelho, mas uma radiação difusa. A superfície Lambertiana é perfeitamente difusa, ou seja, o fluxo radiante que sai da superfície em questão, para qualquer ângulo de reflectância, é constante (JENSEN, 2009).


É possível realizar a medição da reflectância espectral a grandes distâncias, utilizando sistemas multiespectrais de sensoriamento remoto (JENSEN, 2009).

2.1.1.4. Assinatura Espectral

Quando há a interação da radiação com objetos, é possível traçar a assinatura espectral relativa ao objeto, baseado nas suas características físicas, que fornecem diferentes níveis de reflectância para cada banda do espectro.

Na Figura 2.4, é mostrada, de forma ilustrativa, a assinatura espectral característica da vegetação, em que há maior absorção nas bandas azul ($0,40 - 0,5 \mu\text{m}$) e vermelho ($0,65 - 0,70 \mu\text{m}$), e maior reflexão na banda verde ($0,5 - 0,6 \mu\text{m}$), devido à clorofila, assim como há uma alta reflexão na banda de infravermelho ($> 0,7 \mu\text{m}$), resultante da interação da radiação com a estrutura celular superficial da folha (STEFFEN, 2006).

Figura 2.4 Assinaturas espectrais da vegetação e da água




Fonte: CANADA CENTRE FOR REMOTE SENSING ([S.D.]).

Como é perceptível também na Figura 2.4, nas bandas do espectro visível, a água e a vegetação possuem comportamentos semelhantes. Porém, o comportamento de ambas, no infravermelho, é o completo oposto. Portanto, caso a comparação acontecesse em apenas um comprimento de onda, os resultados seriam camuflados. As assinaturas espectrais são variáveis, de forma que uma vegetação, no inverno, possui uma resposta espectral diferente, em relação a uma informação coletada no verão, demandando um entendimento para a interpretação correta das assinaturas espectrais, dos objetos de interesse (CANADA CENTRE FOR REMOTE SENSING, [S.D.]).

2.1.2. Captura de imagens

A estrutura ocular humana é mostrada na Figura 2.5. A luz refletida por um objeto, ao atingir o olho, atravessa a córnea e é focalizada pelo cristalino, sobre o fundo do olho, na retina, onde células especializadas codificam a imagem, que é “levada” ao cérebro pelo nervo óptico (GRUMMAN JUNIOR, [S.D.]). No cérebro acontece a interpretação da imagem com sensações de forma cor e brilho (STEFFEN, 2006).

Na retina estão presentes os cones e bastonetes. Os cones são células sensíveis às cores azul, verde e vermelho, que são excitadas conforme a informação de cor da luz refletida pelo objeto, enviando ao cérebro os sinais nervosos para que sejam interpretados. Já os bastonetes são células sensíveis à luminosidade fraca, sendo responsáveis pela visão noturna (STEFFEN, 2006).



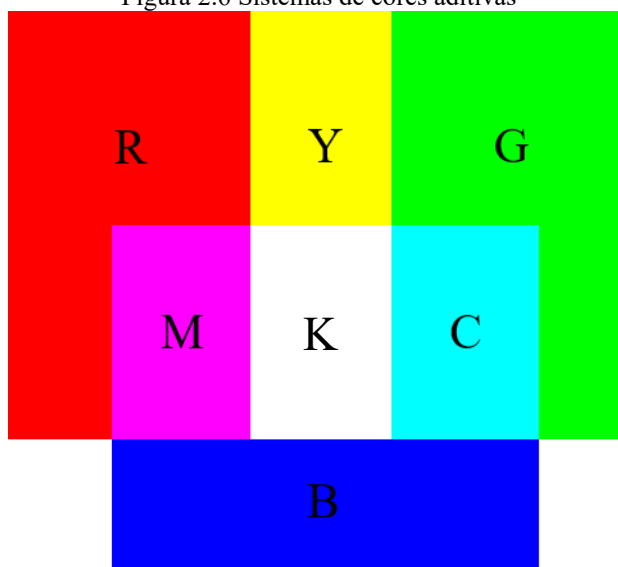
Fonte: GRUMMAN JUNIOR ([S.D.]).

As câmeras convencionais são baseadas no sistema visual humano, possuindo um filme, onde é armazenada a informação, um sistema ótico, que projeta sobre a superfície do filme uma imagem fotografada, um sistema obturador e um diafragma, que determinam a duração e o brilho da imagem captada e projetada sobre filme (ROSA, 2009).

2.1.2.1. Sistema de formação de cores

A junção de duas ou mais cores primárias, dentre o azul (B), o verde (G) e o vermelho (R), resulta no processo de formação aditiva de cores, dando origem às chamadas cores secundárias, sendo elas, o amarelo (Y), o magenta (M), o ciano (C), e o branco (K), para quando as três cores são somadas (Figura 2.6) (ROSA, 2009).

Figura 2.6 Sistemas de cores aditivas



Fonte: A autora.

2.1.2.2. Câmeras digitais


As câmeras digitais possuem o sistema óptico igual ao de uma câmera convencional, entretanto, as informações não são gravadas em um filme, e sim, em um chip chamado *charge-coupled device* (CCD), que é composto de milhares de pequenas células sensíveis à radiação, chamadas detectores, cuja disposição é em formato de matriz, com colunas e linhas. Eles armazenam as fotografias através de cargas elétricas proporcionais ao brilho da imagem captada (STEFFEN, 2006).

As imagens geradas digitalmente, quando lidas por um computador, são dispostas em um formato matricial, onde cada célula recebe o nome de pixel (de *Picture cell*). A informação de brilho captada pelo chip é transformada em um nível digital (STEFFEN, 2006), proporcionalmente, variando de 0 a 255 em imagens de 8 bits.

A qualidade da imagem digital está diretamente relacionada à resolução geométrica ou espacial da câmera, que é dependente da qualidade óptica do instrumento e do número de detectores do chip CCD (STEFFEN, 2006).

As câmeras que produzem imagens coloridas (Figura 2.7) possuem um dispositivo óptico, formado por prismas e filtros, que separa a luz entre vermelho, verde e azul, sendo cada uma dessas bandas projetada em um chip CCD, gerando três imagens monocromáticas, que posteriormente se tornam um único dado, colorido (STEFFEN, 2006).

Figura 2.7 Estrutura de câmera digital colorida




Fonte: STEFFEN (2006).

2.1.2.3. Câmeras não - convencionais

As imagens orbitais são obtidas através de sensores remotos. Eles são sistemas optoeletrônicos utilizados na geração, tanto de imagens, quanto de outros tipos de informações, que estão a grandes distâncias. Câmeras digitais geram informação apenas no espectro visível e, embora possam ser utilizadas como sensores remotos, a aplicação seria muito limitada (STEFFEN, 2006).

Para que a câmera digital seja capaz de captar a radiação infravermelha (Figura 2.8), é necessário a inserção de um chip CCD sensível a essa banda, e como ela não possui uma cor característica, já que não faz parte do espectro visível, a cor básica do azul passa a representar o verde, a cor verde passa a representar o vermelho e, a cor vermelha representa o infravermelho. Esse tipo de imagem gerada é chamada de falsa-cor (STEFFEN, 2006).

Figura 2.8 Estrutura de uma câmera digital de infravermelho



Fonte: STEFFEN (2006).

A banda infravermelha, como descrita nos tópicos acima, fornece uma gama de informações pertinentes a análises de sensoriamento remoto. Para a análise da imagem obtida, é necessário que se tenha o conhecimento da assinatura espectral do objeto de interesse.

2.1.2.4. Geradores de Imagens Orbitais

A obtenção de imagens a partir da órbita do planeta só é possível devido aos satélites artificiais, que são plataformas estruturadas para suportar o funcionamento de instrumentos para diversas finalidades.

O gerador de imagens orbitais é um sensor, capaz de produzir imagens da superfície terrestre, em diversas bandas espectrais, cujo funcionamento se aproxima bastante ao de uma câmera digital

Os satélites que possuem aplicações em Geociências têm órbitas de pequena inclinação em relação aos meridianos, garantindo uma trajetória sempre de norte a sul na parte do planeta que está iluminada pelo Sol, sempre cruzando o Equador no mesmo horário. Isso, permite que o satélite repasse, por uma mesma região, dentro de um período de alguns dias (STEFFEN, 2006).

Com o movimento do satélite, o gerador de imagens utiliza chips CCD lineares, produzindo linhas de imagens transversais, ou linhas de varredura, conforme se desloca na órbita. A varredura da superfície, feita pelo satélite, ocorre de forma gradual, e demanda um período maior, já que devido a interferências, como a de nuvens mais densas, a resposta da reflectância da superfície pode ser obliterada, necessitando mais de 1 ou 2 ciclos do satélite. Os dados coletados são, então, transportados a uma base terrestre, para processamento e análise de informações (STEFFEN, 2006).

2.2. APLICAÇÕES DE SENSORIAMENTO REMOTO

Aplicações de sensoriamento remoto variam de acordo com os sensores utilizados. Características como resolução espectral, espacial ou temporal, são demandadas de acordo com a necessidade da aplicação (CANADA CENTRE FOR REMOTE SENSING, [S.D.]).

Sensores ópticos possuem limitações quando operando sobre áreas com nuvens, não sendo possível “ver” através delas. Outros problemas incluem áreas com má iluminação solar, como o que ocorre nos polos, por exemplo. Esses detalhes não são empecilhos para a tecnologia dos radares, que produzem sua própria iluminação e são capazes de observar através de nuvens, neblinas ou fumaça. As possibilidades de abordagens são inúmeras, envolvendo, geralmente mais de um sensor na coleta dos dados, com o intuito de obter toda a

informação necessária para os fins da aplicação (CANADA CENTRE FOR REMOTE SENSING, [S.D.]).

Alguns exemplos de aplicações, sugeridos em CANADA CENTRE FR REMOTE SENSING, ([S.D.]) são:

- **Agricultura:**
 - Mapeamento do tipo de cultura;
 - Monitoramento de cultura.
- **Florestal:**
 - Mapeamento do desmatamento;
 - Identificação de espécies;
 - Mapeamento de queimadas.
- **Geologia:**
 - Mapeamento estrutural;
 - Unidades geológicas.
- **Hidrologia:**
 - Delineação de inundações;
 - Hidratação do solo.
- **Gelo Marinho:**
 - Tipo e concentração;
 - Movimento do gelo.
- **Cobertura terrestre:**
 - Mudanças rurais/urbanas;
 - Mapeamento de biomas.
- **Mapeamento:**
 - Planimetria;
 - DEMs (Digital Elevation Models, em português Modelo Digital de Elevação).
 - Mapeamento topográfico.
- **Costas e oceanos:**
 - Características dos oceanos;
 - Coloração dos oceanos;
 - Detecção de vazamento de óleo.

Dentro dessas possibilidades, há ainda uma vasta gama de técnicas aplicáveis. Trabalhos como o de MENDES *et al.* (2019) aplicaram a combinação de imagens de sensores

ópticos e radar no mapeamento do cerrado. Já o trabalho realizado por OLIVEIRA *et al.* (2020) faz uma revisão das iniciativas de sensoriamento remoto no mapeamento do cerrado.

Técnicas de detecção de mudanças foram aplicadas por MATOS e SILVA (2005) na identificação da vegetação de Manaus, ainda em 2005. Em 2023, GERMANO *et al.* (2023) apresentaram uma comparação de métodos de detecção de mudança no uso e cobertura da terra. Ainda neste ano foi publicado o artigo de NEGRI e FRER (2023), que discute uma estrutura geral para avaliação de técnicas de detecção de mudanças.

Dentre estes, existem muitos outros trabalhos que aplicam técnicas de sensoriamento remoto, abordando áreas da geografia, computação, dentre outros recursos.

2.3. VEGETAÇÃO DO CERRADO

A área de aplicação do projeto é coberta pelo Bioma Cerrado, o segundo maior bioma do país, abrangendo os estados de Mato Grosso, Mato Grosso do Sul, Rondônia, Goiás, Tocantins, Maranhão, Piauí, Bahia, Minas Gerais, São Paulo e Distrito Federal (Figura 2.9).

Figura 2.9 Distribuição geográfica dos principais biomas do Brasil, destacando a área ocupada pelo Cerrado.



Fonte: SANO, ALMEIDA e RIBEIRO (2008).

A vegetação do bioma Cerrado engloba formações florestais, savânicas e campestres. Em sentido fisionômico, ou seja, em relação ao aspecto da vegetação característica, as florestas representam, simplificadamente, áreas com predominância de espécies arbóreas com cobertura contínua ou descontínua. As savanas, áreas com arbustos e árvores espalhados sobre

grama sem cobertura contínua. Já os campos são referentes a áreas com espécies herbáceas e de arbustos, sem a presença de árvores (SANO, ALMEIDA e RIBEIRO, 2008).

O clima do bioma é caracterizado, em grande parte de sua área, pela estação chuvosa tendo início entre os meses de setembro e outubro. Os meses de dezembro a fevereiro apresentam as maiores médias de precipitação mensal, variando de 150 mm a 500 mm, com exceção de algumas regiões, com período chuvoso se estendendo até março e abril. A estação seca tem uma marcante redução na ocorrência de chuvas, tendo início entre abril e maio, registrando entre 5 a 6 meses de deficiência hídrica (SANO, ALMEIDA e RIBEIRO, 2008).

2.4. CONSIDERAÇÕES FINAIS

Neste capítulo foram abordados assuntos que embasam as técnicas que serão aplicadas neste trabalho, como os princípios da radiação eletromagnética e como, a partir dos efeitos sofridos por ela, no solo e na atmosfera, é possível a aquisição e interpretação de dados de interesse, além das características da vegetação em que tais técnicas serão aplicadas. No próximo capítulo, serão discutidas ferramentas e metodologias para a aplicação de técnicas de detecção de mudanças, no mapeamento do cerrado.

CAPÍTULO 3

MATERIAIS E MÉTODOS

O processo de sensoriamento remoto envolve o estabelecimento do problema, a coleta de dados, a conversão de dados para informação e a apresentação desta informação (JENSEN, 2009). Neste capítulo serão apresentados: a área de estudo, que estabelece um motivo que justifica a aplicação de técnicas de sensoriamento remoto; a aquisição de imagens, que são os dados com os quais serão trabalhados; o pré-processamento, que trata de forma inicial os dados; a identificação das bandas, que determina dados de interesse de cada imagem; a detecção de mudanças, que extrai informações de relevância dos dados; e a classificação das imagens, que classifica as informações para que elas sejam apresentadas. Além disso, serão abordadas ferramentas que permitam a execução do trabalho, desde a aquisição dos dados até a apresentação dos resultados finais.

3.1. MATERIAIS

3.1.1. *Google Earth Engine*

Para o desenvolvimento do projeto, o principal recurso utilizado será o *Google Earth Engine* (GEE), uma plataforma desenvolvida e disponibilizada pelo Google[®], para dados e análises científicas da Terra, que permite a utilização da infraestrutura computacional da própria empresa, o *Google Cloud Platform*, para execução das análises geoespaciais (GORELICK, HANCHER, *et al.*, 2017).

Um outro componente de destaque do GEE é a base de dados, que abriga petabytes de informações, divididas em: clima e tempo (água, atmosfera, clima, tempo); imagens de satélites (Landsat, Sentinel, MODIS, Imagens em alta resolução); e geofísica (terreno, cobertura da terra, terra de plantio, entre outros) (GOOGLE, 2017).

A interação com a plataforma pode acontecer de modo *online* ou *off-line*. Ambos os acessos se dão por meio de *Application Programming Interfaces* (APIs) de Python, REST ou JavaScript, que abrigam bibliotecas, as quais podem ser utilizadas no Ambiente de Desenvolvimento Integrado (*Integrated Development Environment* - IDE) de preferência do usuário. Para este trabalho, será utilizado a IDE online fornecida pela plataforma, o *Code Editor* (Editor de código), que utiliza JavaScript (GORELICK, HANCHER, *et al.*, 2017).

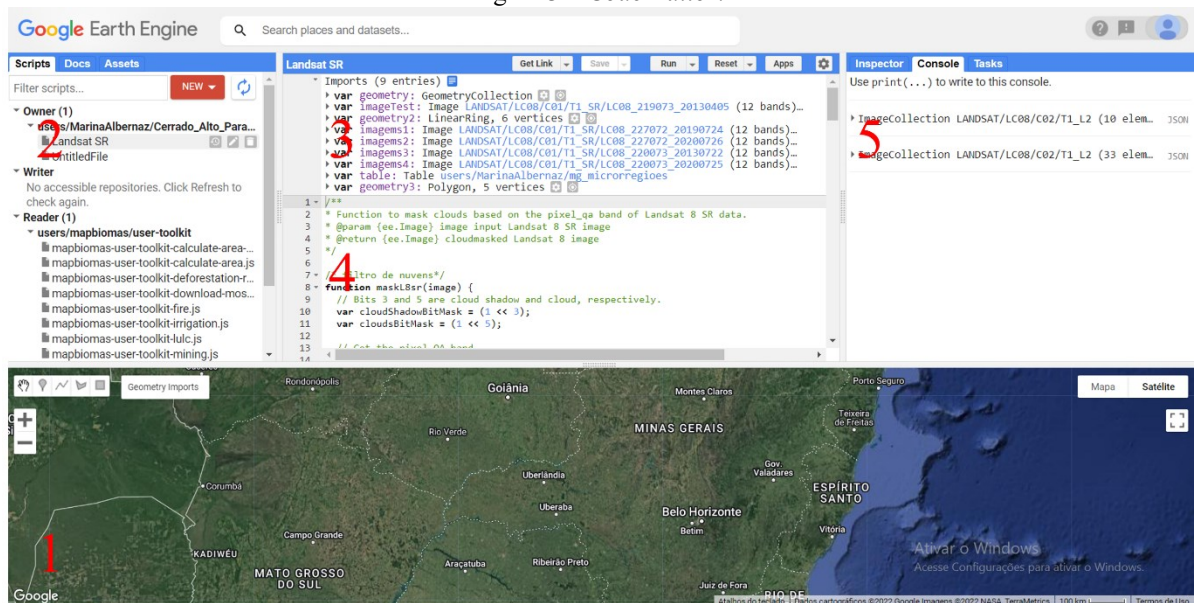
3.1.2. *Code Editor*

O *Code Editor* é um ambiente virtual de desenvolvimento para a API JavaScript do *Earth Engine*. As características desta ferramenta foram desenvolvidas para tornar o

desenvolvimento e a análise de informações geoespaciais, mais rápidas e práticas. As estruturas que o compõe estão representadas na Figura 3.1, sendo elas:

1. Mapa interativo;
2. Dados de *scripts*, documentação e *assets*;
3. *Imports*;
4. Editor de código;
5. Console, Inspetor e Tarefas.

Figura 3.1 Code Editor.



Fonte: A autora.

Pelo mapa interativo (1), é possível visualizar o resultante da implementação, abrangendo toda e qualquer área terrestre. Ele dispõe de opções como a definição de pontos e áreas específicas, adicionando marcadores e linhas a mão livre e, permite a alternância entre o formato de visualização por satélite ou mapa, conforme a necessidade da aplicação. É possível retornar múltiplos resultados para a mesma área, utilizando o sistema de camadas do mapa.

No segundo setor destacado (2), é possível ter acesso a todos os *scripts* criados pelo usuário, assim como às ferramentas já utilizadas nos projetos criados. A segunda aba deste setor, nomeada de “*Docs*”, garante o acesso à documentação das funções disponíveis para o desenvolvimento, enquanto a terceira aba, “*Assets*”, abriga todos os ativos adicionados aos projetos.

A área de *imports* (3), juntamente à de edição de código (4), representam a principal área de desenvolvimento. A primeira, é designada ao “armazenamento dos dados”, como uma imagem carregada ou uma área desenhada para uso posterior. Na segunda, ocorre o desenrolar

das linhas de código, onde são aplicadas as funções e o algoritmo do projeto. Acima dessas áreas é possível localizar os botões responsáveis pela execução da aplicação (*Run*), pelo salvamento (*Save*), pelo compartilhamento (*Get Link*), já que é uma plataforma integrada entre todos os usuários, e o de limpar o *script* (*Reset*), caso seja necessário.

Por fim, o último setor (5) abriga a aba de “*Console*”, que retorna a resposta do código, como erros ou informações que foram definidas para serem mostradas, a aba nomeada “*Inspector*” retorna as informações sobre as camadas do mapa, e a aba de “*Task*” permite o gerenciamento das tarefas definidas durante o desenvolvimento (GOOGLE, 2022).

3.1.3. *Landsat - 8*

O *Landsat-8* foi desenvolvido em uma colaboração da Administração Nacional de Aeronáutica e Espaço (*National Aeronautics and Space Administration - NASA*) e do Serviço Geológico dos Estados Unidos (*United States Geological Survey - USGS*) e, foi lançado em fevereiro de 2013 da Base Aérea de Vandenberg, na Califórnia. A carga útil do satélite é constituída pelo *Operational Land Imager* (OLI) e pelo *Thermal Infrared Sensor* (TIRS), os quais são imageadores da superfície terrestre, provendo imagens com resoluções de 15 m, 30 m ou 100 m, de acordo com a banda captada (LANDSAT 8, [S.D.]).

O satélite *Landsat-8* é responsável pela adição de 400 imagens, por dia, ao banco de dados da USGS, adquirindo diariamente 725 imagens, o que resulta em um aumento na probabilidade de capturar imagens limpas, ou seja, sem a presença de nuvens, já que seu antecessor, o *Landsat-7*, adquire apenas 438 cenas diárias. Sua faixa imageadora é de 185 km.

O sensor OLI passou por avanços que permitem ao *Landsat-8* a coleta de dados em duas bandas a mais que anterior, além de ter a largura de banda refinada para seis das bandas herdadas. O sensor TIRS também obteve aprimoramentos, coletando dados em duas bandas mais estreitas na região termal, o que para os *Landsats 4-7* era feito em uma única banda larga.

Tais sensores são imageadores de varredura, possuindo planos focais e longas matrizes de detectores através de faixas de alinhamento. Essas características proporcionam maior fidelidade geométrica, resolução radiométrica e sensibilidade para ruídos em comparação às tecnologias predecessoras.


3.2. MÉTODOS

3.2.1. Área de estudo

A área de estudo para aplicação dos métodos de sensoriamento remoto foi definida com base na localização do *campus* avançado da Universidade Federal de Uberlândia (UFU) em Patos de Minas, localizada na mesorregião do Triângulo Mineiro e Alto Paranaíba em

Minas Gerais. Considerando que a mesorregião possui uma área relativamente extensa, foi selecionada, para este projeto, apenas a área do Alto Paranaíba, Figura 3.2.

Figura 3.2 Demarcação da região do Alto Paranaíba – MG.



Fonte: Adaptado de DRUMMOND (2017).

Essa área é naturalmente coberta pela vegetação do cerrado, o qual é caracterizado pela presença de invernos secos e verões chuvosos, o que pode ser um fator determinante para a escolha do período de aquisição das imagens. Além disso, as fitofisionomias do bioma englobam formações florestais, savânicas e campestres (RIBEIRO e WALTER, 2008).

3.2.2. Aquisição de imagens

A base de dados disponibilizada pelo GEE abriga imagens desde o início da operação do Landsat-1 em 1972, até o Landsat-9, cuja operação se iniciou em 2021. Com o intuito de utilizar métodos de detecção de mudanças, é necessário que se tenha uma diferença relativamente longa entre as imagens estudadas, e que estas apresentem uma boa qualidade (GOOGLE, 2017).

Os dados gerados pelos satélites Landsat são organizados em Coleções, que determinam o nível de qualidade da imagem, tendo uma consistência garantida na classificação destas, independente dos instrumentos utilizados na aquisição (LANDSAT MISSIONS, [S.D.]).

Dentro das Coleções, existe ainda a classificação por *ranking*, com base na qualidade dos dados e no seu respectivo nível de processamento. Esse tipo de designação tem por

objetivo facilitar a identificação de quais dados serão mais adequados a cada aplicação (LANDSAT MISSIONS, [S.D.]).


Para este projeto, serão utilizadas imagens fornecidas pelo *Landsat-8*, cujo período de operação teve início em 2013, estando ativo ainda no ano presente, de 2022. Tais imagens são pertencentes à Coleção 2, Nível 1 (LANDSAT MISSIONS, [S.D.]).

Com a definição do conjunto a ser analisado, o próximo passo consiste em filtrá-lo, por área e período. É importante saber quanto tempo o satélite leva para completar um ciclo (retornar a um mesmo ponto no planeta), visto que são necessárias mais de uma imagem para cobrir uma área completa, conforme discutido no Capítulo 2. O *Landsat-8*, por sua vez, gasta 16 dias para repetir um ciclo (LANDSAT MISSIONS, [S.D]).

As imagens geradas por satélites podem sofrer com a presença de nuvens, portanto deve ser avaliado seu período de seleção. Como exemplo, um conjunto de imagens dos dias 01 a 20 de Fevereiro de 2020 (verão chuvoso), no espectro visível (bandas 4, 3 e 2, respectivamente), mostrado na Figura 3.2, apresenta uma elevada concentração de nuvens, e não cobre completamente a área de interesse, já que a área demarcada de laranja não foi preenchida.


Conforme apresentado no tópico Área de Estudo, deste capítulo, o ideal é a utilização de imagens no período de inverno, por ser caracteristicamente seco, uma vez que o objetivo do projeto não envolve análises dependentes do clima. Além disso, com a abrangência de um intervalo de tempo mais extenso, é possível uma cobertura completa da área de interesse, conforme apresentado na Figura 3.3, do inverno de 2020, entre 01 de julho a 30 de setembro, também nas respectivas bandas do espectro visível.

Figura 3.3 Imagens do *Landsat-8*, do Alto Paranaíba, de 2020 no período de 01 a 20 de Fevereiro nas bandas referentes ao espectro visível (bandas 4, 3 e 2).



Fonte: A autora.

Figura 3.4 Imagens do *Landsat-8*, do Alto Paranaíba, de 2020 no período de 01 de Julho a 30 de Setembro Fevereiro nas bandas referentes ao espectro visível (bandas 4, 3 e 2).



Fonte: A autora.

Uma outra característica relevante são as bandas do espectro das quais se têm informações, para cada imagem. O *Landsat-8* possui sensores que captam 11 bandas diferentes, sendo nove delas de aquisição do sensor OLI, ou Gerador Operacional de Imagens Terrestres, no qual cada pixel gerado é correspondente a 30 m² de extensão terrestre:

- Banda 1: Aerossol Costeiro (0.43 – 0.45 μm) 30 m;

- Banda 2: Azul (0.45 – 0.51 μm) 30 m;
- Banda 3: Verde (0.53 – 0.59 μm) 30 m;
- Banda 4: Vermelho (0.64 – 0.67 μm) 30 m;
- Banda 5: NIR (0.85 – 0.88 μm) 30 m;
- Banda 6: SWIR 1 (1.57 – 1.65 μm) 30 m;
- Banda 7: SWIR 2 (2.11 – 2.29 μm) 30 m;
- Banda 8: Pancromática (PAN) (0.50 – 0.68 μm) 15 m;
- Banda 9: Cirrus (1.36 – 1.38 μm) 30 m.

As outras 2 bandas são resultantes da presença do sensor TIRS, ou Sensor de Infravermelho Termal, que possui uma escala de 100 m² para 1 pixel:

- Banda 10: TIRS 1 (10.6 – 11.19 μm) 100 m;
- Banda 11: TIRS 2 (11.5 – 12.51 μm) 100 m.

Para o desenvolvimento do projeto, devem ser analisadas quais as bandas resultam em informações de relevância para o propósito apresentado, o que será tratado na Seção 3.4 deste Capítulo.

3.2.3. Pré-Processamento

As imagens utilizadas, provindas da base de dados do GEE, já possuem um pré-processamento, contendo correções de atmosfera, de refletância superficial e de temperatura da superfície terrestre, derivada dos dados produzidos pelos sensores.

Outra etapa de pré-processamento inclui um filtro de nuvens, em busca de minimizar a interferência de imagens com concentração delas no conjunto final de análise. Ele consiste, de forma simplificada, em transformar os bits que indicam a presença ou sombra de uma nuvem, em bits 0. Desse modo, imagens que cubram a mesma área, com valores válidos, vão sobrepor as áreas com nuvens.

Caso haja a necessidade, novas etapas de pré-processamento podem ser adicionadas, conforme o conjunto final definido para a análise.

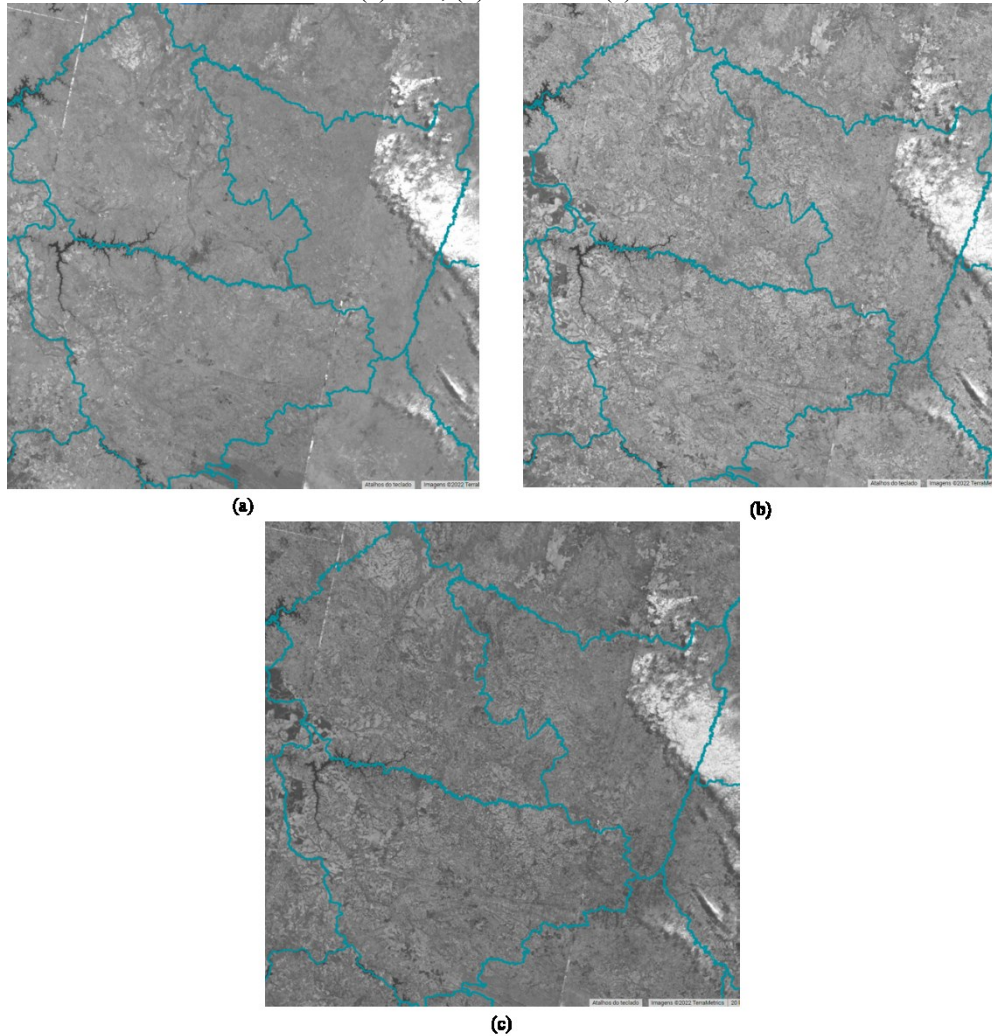
3.2.4. Identificação de bandas

Nesta etapa, são determinadas as bandas que tendem a fornecer informações relativas ao tipo de análise proposto. Conforme apresentado na Seção 3.2.3 deste Capítulo, cada imagem possui 11 bandas disponíveis. Porém, como foi definido que o objetivo é o mapeamento da vegetação, as bandas 1, 9, 10 e 11 podem ser retiradas da conta, já que elas são destinadas a análises que envolvam aerossóis (Banda 1), nuvens (Banda 9) e informações térmicas da

superfície (Bandas 10 e 11). A banda PAN não será utilizada, porque a resolução desejada para análise é de 30 m.

As bandas correspondentes ao vermelho, verde e azul retornam a cor real da imagem, no sistema *Red, Green, Blue* (RGB), que foi apresentado nas Figuras 3.3 e 3.4. As bandas NIR, SWIR 1 e SWIR 2 estão representadas em escala de cinza na Figura 3.5 (a), (b) e (c).


Figura 3.5 Imagens do *Landsat-8*, do Alto Paranaíba, de 2020 no período de 01 de Julho a 30 de Setembro, nas bandas (a) NIR, (b) SWIR 1 e (c) SWIR 2



Fonte: A autora.

Para a implementação, é necessário a combinação das bandas, visando o tipo de informação gerada, de acordo com o propósito da aplicação. As combinações ocorrem, geralmente, entre três bandas, sendo cada arranjo adequado a um tipo de análise. Para o *Landsat-8*, utilizando o sensor OLI, algumas combinações comuns (LANDSAT MISSIONS, 2021) são apresentadas na Figura 3.6.

Figura 3.6 Recorte da imagem do *Landsat* – 8 mostrando a cidade de Patos de Minas nas bandas (a) 4, 3, 2, (b) 5, 4, 3, (c) 7, 6, 4, (d) 6, 5, 4 e (e) 7, 5, 4.



Fonte: A autora.

Na Figura 3.6 (a) é apresentada a cor real de captura, nas bandas do espectro visível, ou seja, RGB. Já na segunda Figura, a 3.6 (b), há a presença da banda NIR, sendo essa a representação da imagem no infravermelho, chamada de *Color Infrared* (CIR). Como visto no Capítulo 2, a banda NIR interage com as estruturas das plantas, tornando esta combinação um importante adendo na análise da saúde da vegetação. A 3.6 (c) utiliza das bandas de SWIR e da banda do vermelho, para retornar uma “cor falsa” com tonalidade verde, destacando as vegetações densas das escassas (WORLD OF TECH, 2019). As outras duas Figuras, 3.6 (d) e 3.6 (e), também utilizam das bandas de SWIR, sendo a primeira combinação designada para análise da vegetação, e a segunda, designada como *Shortwave Infrared* (LANDSAT MISSIONS, 2021).

Além dos exemplos apresentados, existem outras formas de agrupamento, que oferecem alguma perspectiva de implementação neste projeto, tais quais a combinação das bandas 5, 6 e 4, adequada para a diferenciação entre corpos de água e extensões de terra (BUTLER, 2013), e também a combinação 6, 5 e 2 utilizada principalmente na agricultura, na verificação das plantações, uma vez que, com a combinação das bandas NIR e SWIR é possível obter informações sobre a saúde da vegetação e com a banda azul, obtém-se áreas com solo descoberto (WORLD OF TECH, 2019).

3.2.5. Detecção de mudanças

Com a finalidade de mapear o Cerrado, de modo que as técnicas estudadas possam ser replicadas em experimentos futuros, foi selecionado o método de detecção de mudanças, o qual possibilitará a comparação da vegetação entre os anos de 2013 e 2020. Existem várias técnicas para este objetivo, portanto, serão destacados, neste projeto, algumas técnicas básicas de detecção de mudanças.

3.2.5.1. Diferenciação de imagens

Esta técnica utiliza duas imagens espaciais, registradas no tempo t_1 e t_2 , fazendo a subtração entre elas, pixel a pixel, resultando em uma nova imagem, que representa sua diferença. Um valor matemático é atribuído a cada pixel D_{ijk} , obtido pela Equação 4, onde x_{ijk} é o valor do pixel na banda k , na linha i e na coluna j , sendo C uma constante para produzir um valor digital positivo.

$$D_{ijk} = x_{ijk}(t_2) - x_{ijk}(t_1) + C \quad (4)$$

Partindo do histograma gerado da imagem resultante, é definido um limiar que indique quais pixels sofreram mudanças, sendo este um ponto crítico, já que o limiar define o resultado final (SINGH, 2010).

3.2.5.2. Diferenciação dos índices de vegetação

A diferença de vegetação entre duas imagens pode ser calculada pelo índice de vegetação por diferença normalizada (*Normalized Difference Vegetation Index* - NDVI), que representa a quantificação da vegetação, com base na radiação infravermelha refletida em contraste com a radiação vermelha absorvida, de cada uma delas, conforme apresentado na Equação 5 (GISGEOGRAPHY, 2022).

$$VD_{ij} = NDVI_{ij}(t_2) - NDVI_{ij}(t_1) \quad (5)$$

Em que o valor de cada pixel (VD_{ij}) é dado pela diferença entre os NDVI da imagem nos tempos t_1 e t_2 .

3.2.5.3. Comparação pós-classificação

Essa técnica faz uso de imagens que já passaram pelo processo de classificação, que será descrito na Seção 3.6 deste Capítulo. A partir de duas imagens, classificadas em diferentes datas, quando comparadas, é possível produzir um mapa de mudanças, o que pode minimizar os problemas pré classificação, que possam existir nas imagens, como a normalização atmosférica ou diferença entre os sensores. Porém, caso haja erro na classificação de alguma delas, o que ocorre é a geração de um indicador de mudanças errôneo, tornando esta técnica muito dependente da precisão da classificação (SINGH, 2010).

3.2.5.4. Classificação multidata direta

Nesta técnica duas ou mais imagens, coletadas em datas distintas, são combinadas, para a definição das áreas que tiveram mudanças. A combinação resulta em uma imagem com a soma das bandas das imagens originais. Por exemplo, para duas imagens com 6 bandas cada, a resultante teria 12 bandas, classificadas em uma única vez, utilizando método supervisionado ou não-supervisionado. Para ambos os métodos, é importante que as classes que definam a existência de mudança e a inexistência de mudança sejam significativamente, distintas (SINGH, 2010).

3.2.5.5. Análise do vetor de mudança

Já esta técnica exige uma análise de espectro. Mudanças físicas na vegetação geram mudanças nas respostas espectrais. É possível representar tal fato por um vetor de mudanças, que nada mais é que um descritor de direção e magnitude da variação no espectro. Quando este vetor ultrapassa um limiar de magnitude pré definido, é detectada uma mudança, sabendo que a direção do vetor indica o tipo de mudança ocorrida (SINGH, 2010).

3.2.6. Classificação das imagens

A classificação é um processo dividido em duas etapas, a de reconhecimento das categorias de objetos reais, como florestas, savanas e corpos d'água, e a de rotulagem das entidades (pixels) que serão classificados, atribuindo, por exemplo, o nome "1" para os pixels que indicam floresta e "2" para os que indicam savana. Outra opção para rotular os pixels, é o processo de *clustering*, em português, agrupamento, que não requer a definição de categorias, como a descrição do tipo de terreno. Este é um processo exploratório, que define o número para terrenos diferentes, mas não os identifica (MATHER, 2004).

As formas distintas de enumerar os pixels são conhecidas na literatura de sensoriamento remoto como procedimento de classificação supervisionado e não-supervisionado, respectivamente (MATHER, 2004).

Um padrão é definido quando se têm um conjunto de valores, em escala de cinza, para um único pixel, medido em várias bandas espectrais. O processo de classificação é também conhecido como uma forma de reconhecimento de padrões, em que se identifica o padrão associado a cada pixel de uma imagem, em relação às características materiais presentes na área de análise (MATHER, 2004).

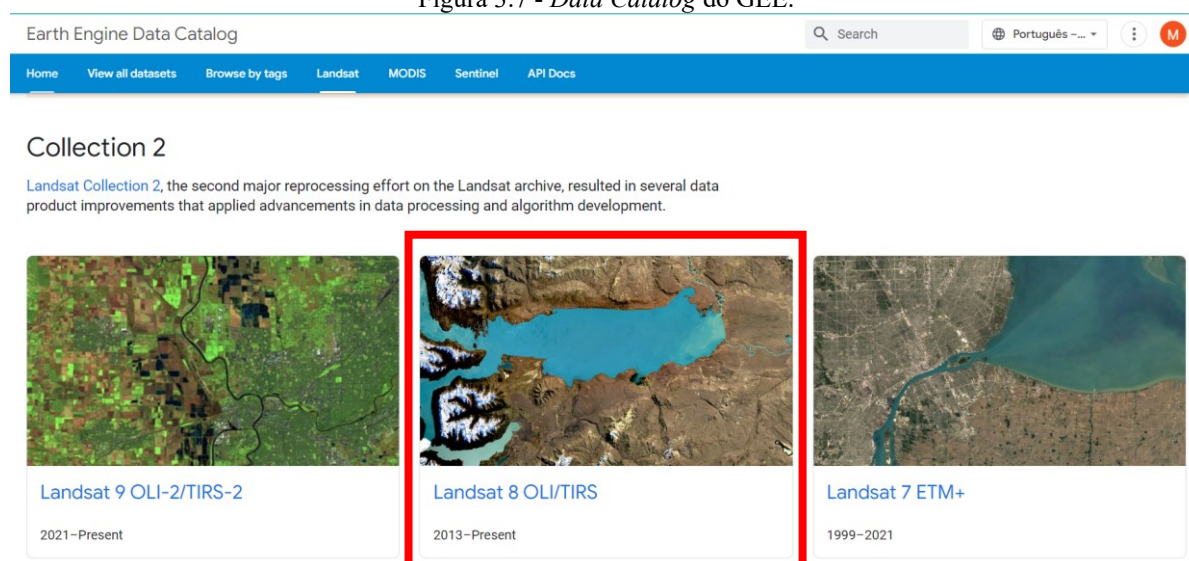
3.3. DESENVOLVIMENTO

3.3.1. Experimentação

O primeiro passo para o desenvolvimento do projeto, com a plataforma do GEE definida, foi fazer experimentações. Os testes iniciais consistiam em selecionar imagens de coleções, as chamadas *ImageCollections* (em português, Coleção de Imagens), e determinar filtros que satisfizessem um quesito básico. Como a área de estudo definida é o Alto Paranaíba, o primeiro quesito abordado foi a cobertura dessa região.

As imagens da coleção devem ser definidas antes do processo de filtragem. Foi determinado a utilização do satélite *Landsat-8*, e do sensor OLI. Acessando o *Data Catalog* (em português, Catálogo de Dados) do GEE é possível ter acesso às coleções disponíveis de todos os *Landsats*. Selecionando a que condiz com o caso atual, conforme a Figura 3.7, podemos acessar a *Collection 2* (em português, Coleção 2) do *Landsat 8* com sensores OLI/TIRS, disponíveis de 2013 até o presente.

Figura 3.7 - *Data Catalog* do GEE.



Fonte: GOOGLE.

Dentro dessa coleção existe uma subdivisão das imagens, agrupadas em: reflectância da superfície (em inglês, *Surface Reflectance - SR*), corrigidas atmosféricamente; reflectância calibrada do topo da atmosfera (em inglês, *Top of Atmosphere - TOA*); e imagens “cruas”. Cada subdivisão é classificada entre duas a três categorias que determinam a qualidade das imagens, podendo ser *Tier 1*, *Tier 2* (em português, Nível 1, Nível 2) ou RT (*Real Time*, em português, Tempo Real). Para este projeto foi selecionada a coleção de reflectância da superfície, categoria *Tier 1*, descrita brevemente na Figura 3.8.

Figura 3.8 - Coleção selecionada referente à *Collection 2*, do *Landsat-8*, Reflectância da Superfície, *Tier 1*.

USGS Landsat 8 Level 2, Collection 2, Tier 1



Dataset Availability

2013-03-18T15:58:14Z–2023-04-27T13:30:23

Dataset Provider

USGS

Earth Engine Snippet

```
ee.ImageCollection("LANDSAT/LC08/C02/T1_L2")
```

Fonte: GOOGLE.

Essa coleção inclui imagens de ambos sensores OLI/TIRS, portanto além da série SR, podem estar presentes as bandas de temperatura da superfície (em inglês *Surface Temperature - ST*), que não são de interesse para este projeto.

Explorando a documentação do *Code Editor* é possível ter acesso às funções e filtros que podem ser utilizados para este tipo de coleção. Para filtrar a região é possível que se use dados do tipo *GeometryCollection* (Coleção de Geometrias), marcando, no mapa interativo do editor, pontos que delimitem a área de estudo. Com base nos municípios pertencentes ao Alto Paranaíba, foi possível criar um polígono semelhante à divisão política da mesorregião, conforme a Figura 3.9 (a). É importante lembrar que, apesar de cobrir toda a área designada, as imagens não se atinham às bordas do polígono, como mostrado na Figura 3.9 (b).

Figura 3.9 - Marcação dos municípios do Alto Paranaíba com (a) delimitação aproximada do território e (b) cobertura de imagens.



(a)

(b)

Fonte: A autora.

Além da área, é possível filtrar por data (Figura 3.10). Considerando que um ciclo desse satélite possui 16 dias, foram testados intervalos cíclicos em diferentes meses, além de intervalos maiores, abrangendo cerca de 3 meses, o que seria uma estação do ano, por

exemplo. Outras variações de intervalos também foram abordadas no intuito de avaliar diferentes resultados.

Figura 3.10 - Exemplo de código com filtros de região e data aplicados à uma *ImageCollection*.

```

/*coleção de imagens - pega todas as imagens da data e área determinada*/
var dataset2013 = ee.ImageCollection('LANDSAT/LC08/C02/T1_L2')
    .filterBounds(geometry)
    .filterDate('2013-06-21', '2013-09-21');

var dataset2021 = ee.ImageCollection('LANDSAT/LC08/C02/T1_L2')
    .filterBounds(geometry)
    .filterDate('2021-06-01', '2021-06-16');

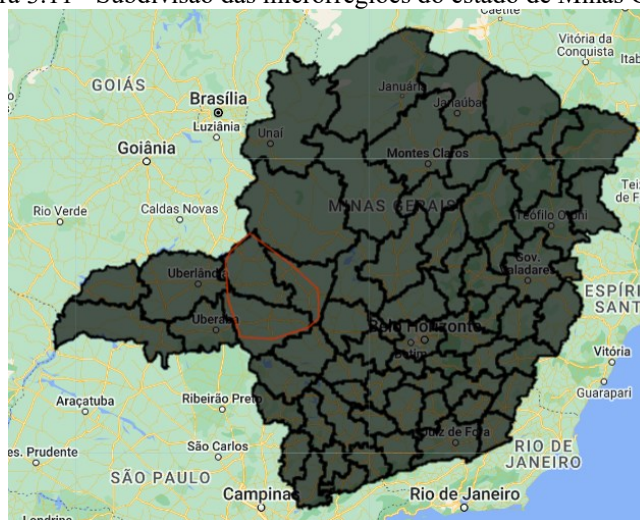
```

Fonte: A autora.

Os conjuntos resultantes retornam uma quantidade de imagens equivalente ao filtro utilizado. Essas imagens são individuais e sobrepostas, ficando “por cima” sempre a mais recente. Com o objetivo de transformá-las em uma única imagem, foi utilizada a função *mosaic*.

Em busca de uma determinação mais fiel da região trabalhada, um *asset* (em português, ativo) com o *shapefile* (formato de dados geográficos e vetoriais) da subdivisão das microrregiões de Minas Gerais foi adicionado ao projeto em forma de uma *FeatureCollection* (Coleção de características/recursos), mostrada na Figura 3.11.

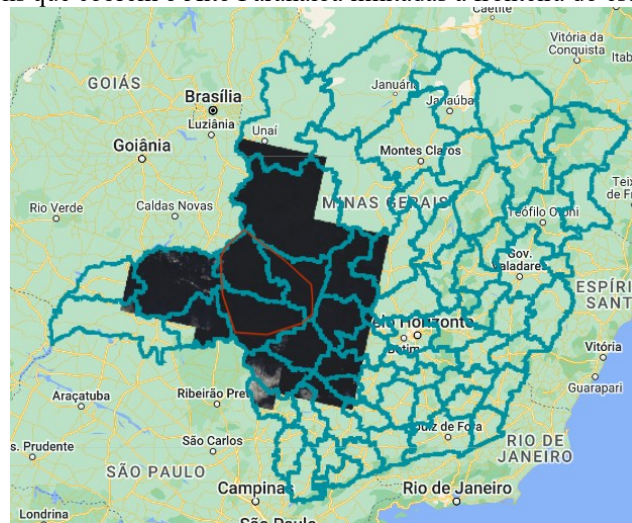
Figura 3.11 - Subdivisão das microrregiões do estado de Minas Gerais.



Fonte: A autora.

Apesar do *asset* abranger todo o estado, com a geometria definida anteriormente, foi possível manter a cobertura das imagens apenas na região desejada. Desse modo, aplicando a função *clip*, com o argumento da *FeatureCollection*, a imagem foi recortada para se manter apenas dentro dos limites do estado, conforme a Figura 3.12.

Figura 3.12 - Imagens que cobrem o Alto Paranaíba limitadas à fronteira do estado de Minas Gerais.



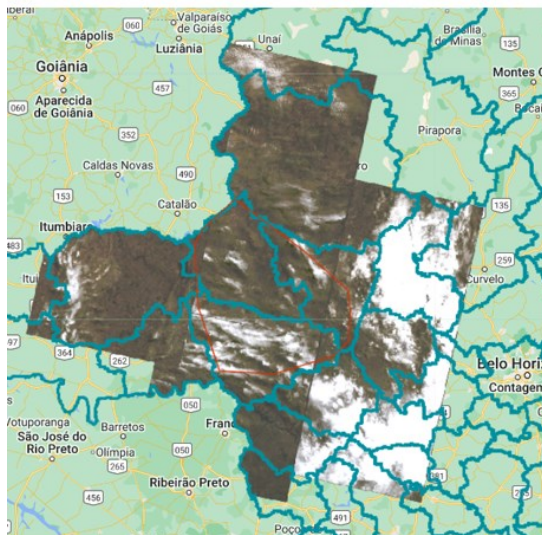
Fonte: A autora.

Ainda na etapa de experimentação, sabendo que as imagens são formadas por diversas bandas espectrais, foram variados os parâmetro de visualização, conforme o código apresentado na Figura 3.13.

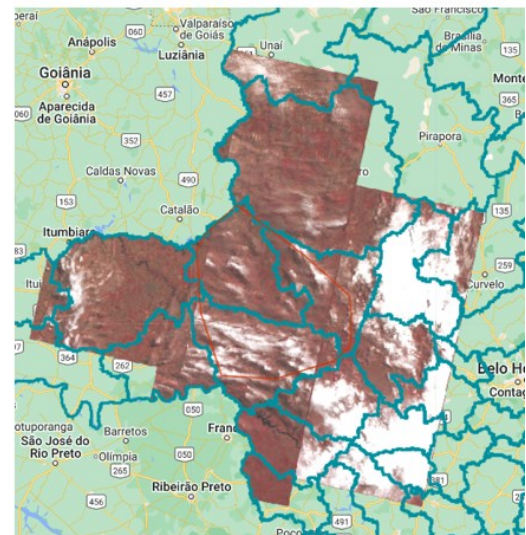
Figura 3.13 - Exemplo de definição dos parâmetros de visualização das imagens em que (a) representa o espectro visível e (b) a combinação CIR.

```
var visParams = {
  bands: ["SR_B4", "SR_B3", "SR_B2"],
  min: 0,
  max: 30000,
};
```

```
var visParams = {
  bands: ["SR_B5", "SR_B4", "SR_B3"],
  min: 0,
  max: 30000,
};
```



(a)



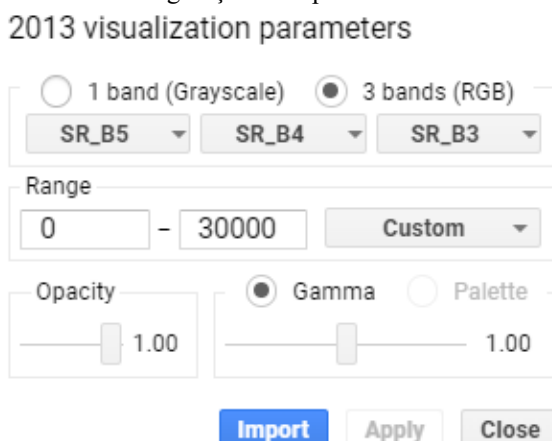
(b)

Fonte: A autora.

O parâmetro *bands* define como o conjunto de bandas da imagem será mostrado. Ele pode receber até três valores, sendo o primeiro destinado à visualização em cor vermelha, o segundo, na cor verde e o terceiro, azul. Quando as bandas de RGB são adicionadas nas posições equivalentes, tem-se a visualização do espectro visível (Figura 3.13 (a)). Já nos casos

em que se deseja ver a resposta de uma das bandas de infravermelho, por exemplo, há a visualização de “cor falsa” (Figura 3.13 (b)). Os valores de “min” e “max” indicam o valor dos níveis de pixel que serão considerados 0 e 255 respectivamente. É possível ainda controlar outros fatores de visualização, mas que não foram testados via código, e sim, via menu de configurações do GEE, apresentado na Figura 3.14 (GOOGLE).

Figura 3.14 - Menu de configurações dos parâmetros de visualização do GEE.

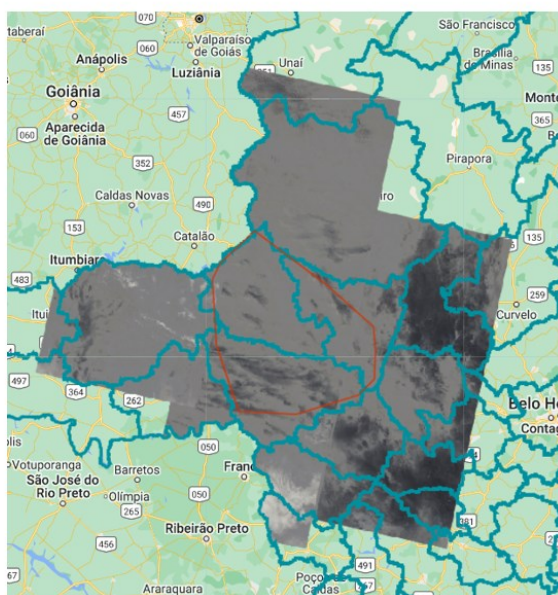


Fonte: A autora.

Após explorar diferentes combinações de bandas, o próximo passo dado foi focar na aplicação de operações básicas com imagens. O objetivo é detectar mudanças temporais, portanto, é importante a utilização de dados com datas distintas. A função *subtract* do GEE realiza subtração das bandas de uma imagem, pelas equivalentes da outra. O código da Figura 3.15 é um exemplo da aplicação, utilizando uma imagem de 2013 e outra de 2020.

Figura 3.15 - Exemplo de subtração entre imagens de 2020 e 2013.

```
var result1 = imagem2020.subtract(imagem2013);
```



Fonte: A autora.

A Figura 3.15 mostra uma das bandas obtidas após a subtração, uma imagem com escala em cinza, cujos valores de pixel variam entre preto, que são os menores resultados da subtração, níveis intermediários de cinza, e branco, onde a subtração apresentou os maiores valores. Também foram testadas subtrações com valores de NDVI.

Pelo GEE é possível calcular a diferença normalizada de uma imagem, passando as respectivas bandas, como mostrado na Figura 3.16. Para o cálculo específico do índice de vegetação, são utilizadas as bandas de NIR e vermelho (SR_B5 e SR_B4, respectivamente). A subtração de duas imagens NDVI resulta em algo semelhante à Figura 3.15.

Figura 3.16 - Exemplo de código para o cálculo da diferença normalizada do índice de vegetação (NDVI).

```
var getNDVI = function(image) {
  return image.normalizedDifference(['SR_B5', 'SR_B4']);
};
```

Fonte: A autora.

3.3.2. Definição do escopo

Finalizado o período de experimentação, foi definido um escopo simples de etapas para obtenção de um resultado mínimo esperado. As etapas consistiam, de modo geral em:

- Área de estudo:
 - Limitar a área apenas ao Alto Paranaíba.
- Aquisição de imagens:
 - Selecionar imagens de 2013 e 2020 em período de inverno com cobertura total da área.
- Pré-processamento:
 - Implementar filtro de nuvens.
- Identificação de bandas:
 - Utilização inicial apenas do espectro visível RGB (SR_B4, SR_B3, SR_B2).
- Detecção de mudanças:
 - Fazer a subtração simples de cada uma das bandas definidas.
- Classificação das imagens:
 - Não haverá classificação.
- Obtenção dos resultados:
 - Gerar um mapa utilizando a subtração, definindo um limiar de mudanças baseado no histograma da imagem;
 - Utilizar uma imagem já classificada de 2013, e fazer uma interseção com o mapa de mudanças, indicando onde ocorreram mudanças;

- O resultado da interseção deve então ser comparado com uma imagem de 2020, para evidenciar o que não é mais cerrado;
- Por fim, um novo mapa será gerado.

3.3.3. Limitação da área de estudo

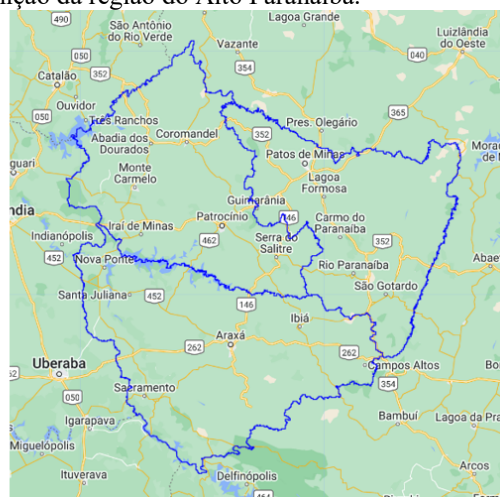
Iniciando a primeira etapa, para limitar a área de estudo, o *asset* de microrregiões foi transformado em um formato de lista (*List*), em que cada um dos componentes correspondia a uma das regiões do estado. Posteriormente, foram selecionados para uma lista menor apenas os itens equivalentes às microrregiões de Patos de Minas, Araxá e Patrocínio, que compõem o Alto Paranaíba. Essa lista foi posteriormente retornada para o tipo *FeatureCollection*. A Figura 3.17 ilustra todo o processo descrito.

Figura 3.17 - Exemplo de código da definição da região do Alto Paranaíba.

```
var altoP = table.toList(66);

var listaAP = ee.List([altoP.get(40),
                      altoP.get(41),
                      altoP.get(48)]);

var AP = ee.FeatureCollection(listaAP);
```



Fonte: A autora.

3.3.4. Seleção das imagens e pré-processamento

Para a seleção das imagens, com uma definição de área bem específica, restava a determinação da data de coleta. Conforme informações já discutidas, o inverno é um período mais seco. Considerando essa informação e as observações na experimentação, que indicaram imagens entre inverno e primavera contendo poucas nuvens, foram selecionadas datas entre julho e setembro. Juntado as etapas de pré-processamento à seleção de imagens, foi possível reduzir o período para cerca de um mês em cada coleção.

Nesta etapa foi determinada a aplicação apenas do filtro de nuvens (Figura 3.18). Para a implementação foi utilizado um exemplo do próprio GEE. O filtro utiliza as informações da Banda de Avaliação de Qualidade de Pixel (em inglês, *Pixel Quality Assessment Band - QA_PIXEL*) que contém dados estatísticos de qualidade dos pixels e informação da máscara de nuvens presentes na imagem (LANDSAT MISSIONS). Portanto, foi necessário separar

da imagem de estudo, a banda em questão, utilizando a função *select*, para que fossem aplicadas as devidas operações.

Os bits 3 e 5 presentes nessa banda indicam a presença de nuvem ou da sombra dela. Foram então criadas duas máscaras de bits, uma para nuvem e uma para sombra. A banda possui 8 bits, ou 1 byte, sendo alocado o valor 1 para o terceiro bit (contando da esquerda pra direita) na primeira máscara, e 1 para o quinto bit, no caso da segunda. A resposta em bits das máscaras foi 0000100 e 0010000, respectivamente.

Posteriormente, foi criada uma nova máscara, agora com o objetivo de aplicação na imagem final. Para determinar onde realmente havia nuvens ou sombras, foi realizada uma operação lógica (AND) a nível de bit (função *bitWiseAnd*), entre a imagem de banda única QA_PIXEL, e a máscara de bits criada anteriormente. Os resultados iguais a 0, ou seja, sem interferência, foram retornados. Quando aplicada à imagem de estudo, foram criados “buracos” onde há a presença de nuvens ou sombras como na (Figura 3.19). Dessa forma, foi possível definir onde não havia cobertura suficiente e ajustar o intervalo de tempo da coleta.

Figura 3.18 - Código correspondente ao filtro de nuvem.

```

/***** Pré-processamento *****/
//Filtro de nuvens padrão

function maskL8sr(image) {
  // Bits 3 and 5 are cloud shadow and cloud, respectively.
  var cloudShadowBitMask = (1 << 3);
  var cloudsBitMask = (1 << 5);

  // Get the pixel QA band.
  var qa = image.select('QA_PIXEL');

  // Both flags should be set to zero, indicating clear conditions.
  var mask = qa.bitwiseAnd(cloudShadowBitMask).eq(0)
    .and(qa.bitwiseAnd(cloudsBitMask).eq(0));
  return image.updateMask(mask);
}

```

Fonte: A autora.

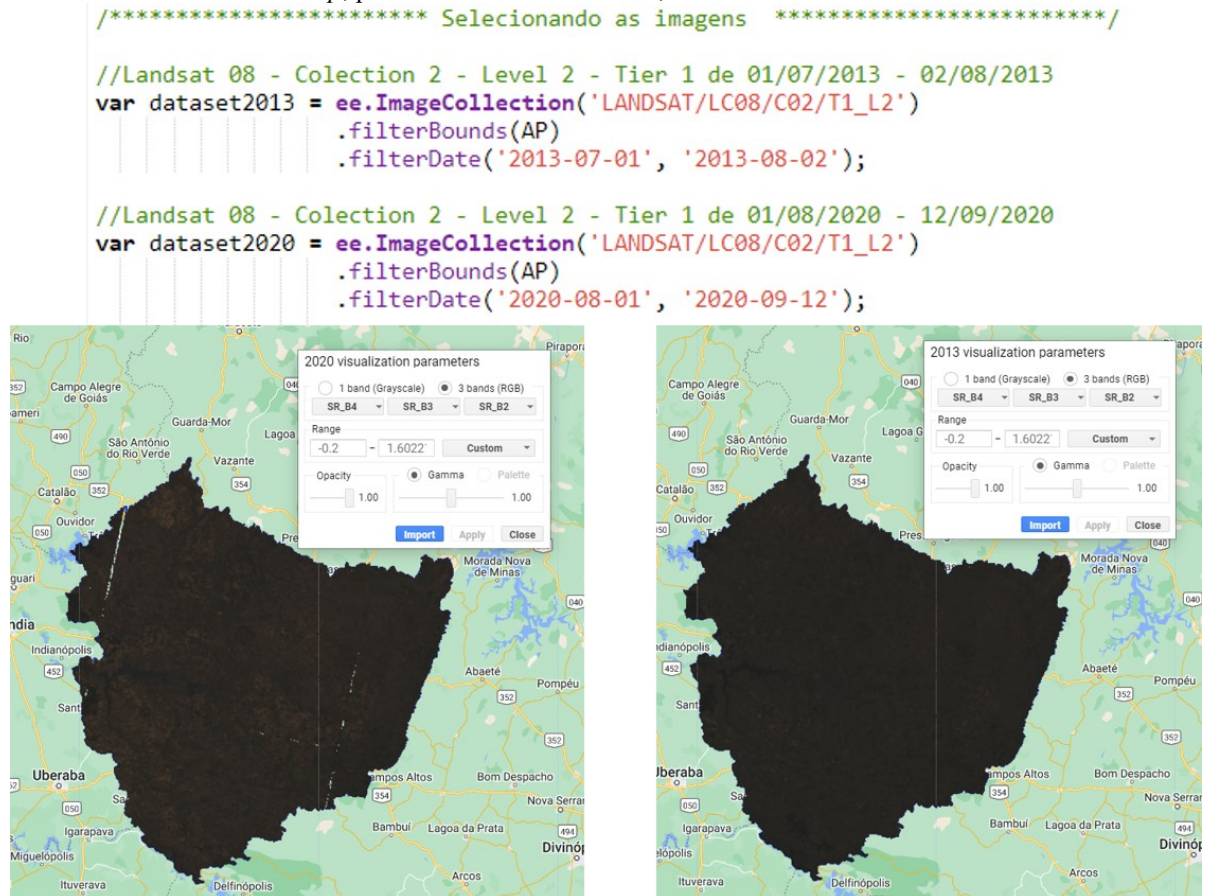
Figura 3.19 – Exemplo de aplicação do filtro de nuvem, do período de 01/08/2020 a 30/08/2020.



Fonte: A autora.

As respostas para 2013 e 2020, em relação à cobertura das imagens, foram bem distintas para datas iguais. Portanto, foram definidas datas dentro do especificado, mas com uma pequena diferença entre os intervalos de cada ano. Para 2013 o intervalo foi de 01/07/2013 a 02/08/2013, e para 2020 foi de 01/08/2020 a 12/09/2020. As imagens da Figura 3.20 são resultantes da seleção, após a aplicação das funções de *mosaic* e *clip*.

Figura 3.20 - Exemplo de código com a seleção das imagens e resultados obtidos após as funções *mosaic* e *clip*, para os anos de 2013 e 2020, visualizadas em RGB.



Fonte: A autora.

3.3.5. Separação das bandas

Até o momento as imagens foram trabalhadas contendo todas as bandas disponíveis, sendo ajustadas apenas para visualização. Para a etapa de definição do RGB, é necessário que se tenha o isolamento das bandas SR_B2, SR_B3 e SR_B4, com índices correspondentes, na lista de bandas, à 1, 2 e 3, respectivamente. Elas foram isoladas separadamente usando a função *select*, conforme a Figura 3.21, resultando em uma imagem na banda azul, uma na verde e outra na vermelha, para cada um dos anos.

Figura 3.21 - Código utilizado para isolar as bandas RGB em cada imagem.

```

/**** Separando as bandas RGB****/

var red2013 = conjuntoImagem2013.select(3);
var red2020 = conjuntoImagem2020.select(3);

var green2013 = conjuntoImagem2013.select(2);
var green2020 = conjuntoImagem2020.select(2);

var blue2013 = conjuntoImagem2013.select(1);
var blue2020 = conjuntoImagem2020.select(1);

```

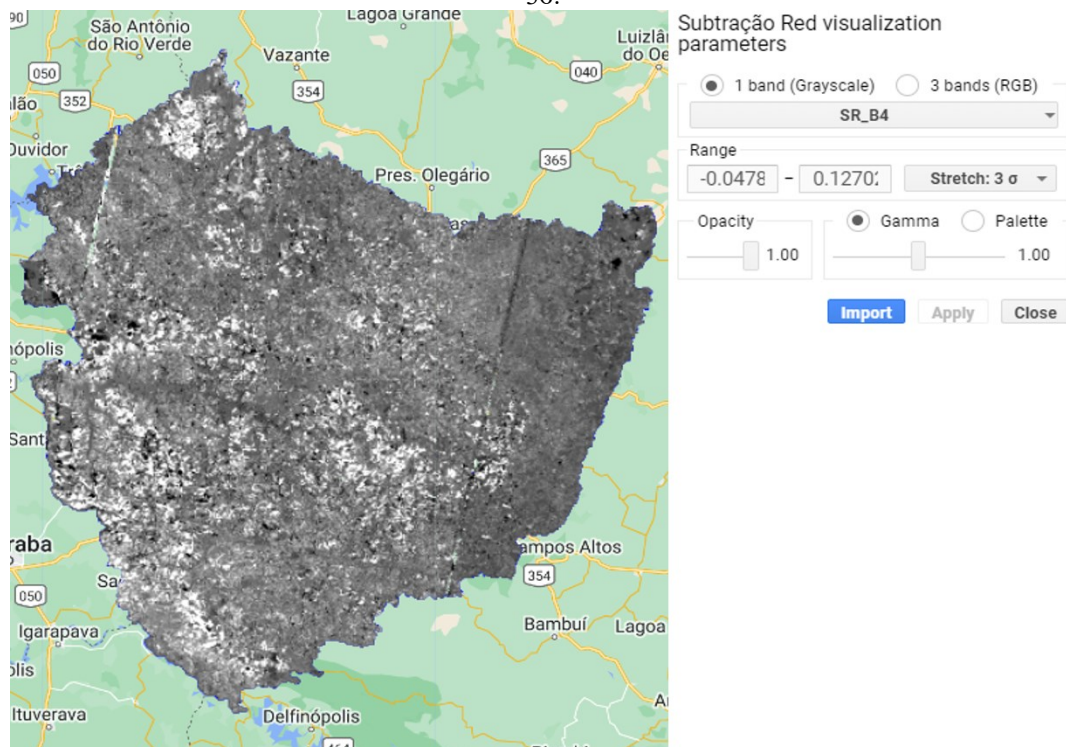
Fonte: A autora.

3.3.6. Subtração

Com as bandas separadas, o próximo passo definido foi a detecção de mudanças pelo método da subtração. Esta etapa e a anterior poderiam ser invertidas, já que a função *subtract* é usada banda a banda. Logo, aplicando a subtração antes, a separação das bandas se reverteria nos resultados individuais da operação de cada uma. Contudo, foi opcional seguir a sequência de métodos descrita na seção anterior.

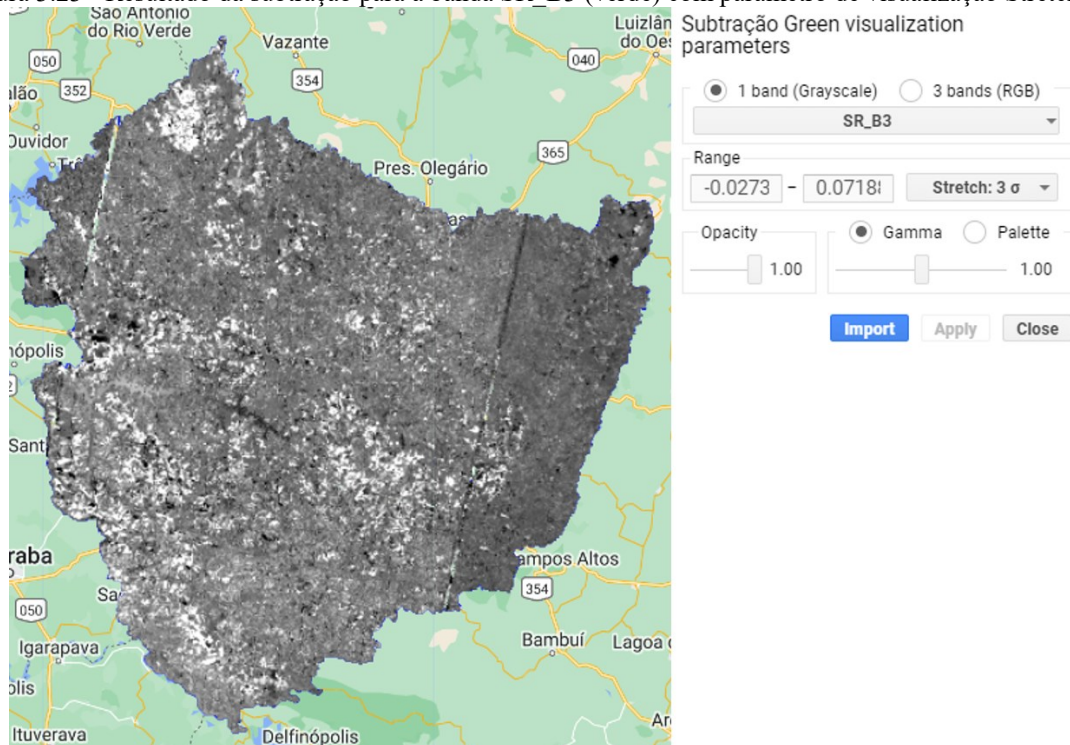
A operação foi executada subtraindo as imagens de 2020 pelas de 2013. O resultado de cada subtração é mostrado nas Figura 3.22, Figura 3.23 e Figura 3.24 com ajustes de visualização.

Figura 3.22 - Resultado da subtração para a banda SR_B4 (vermelho) com parâmetro de visualização Stretch: 3σ .



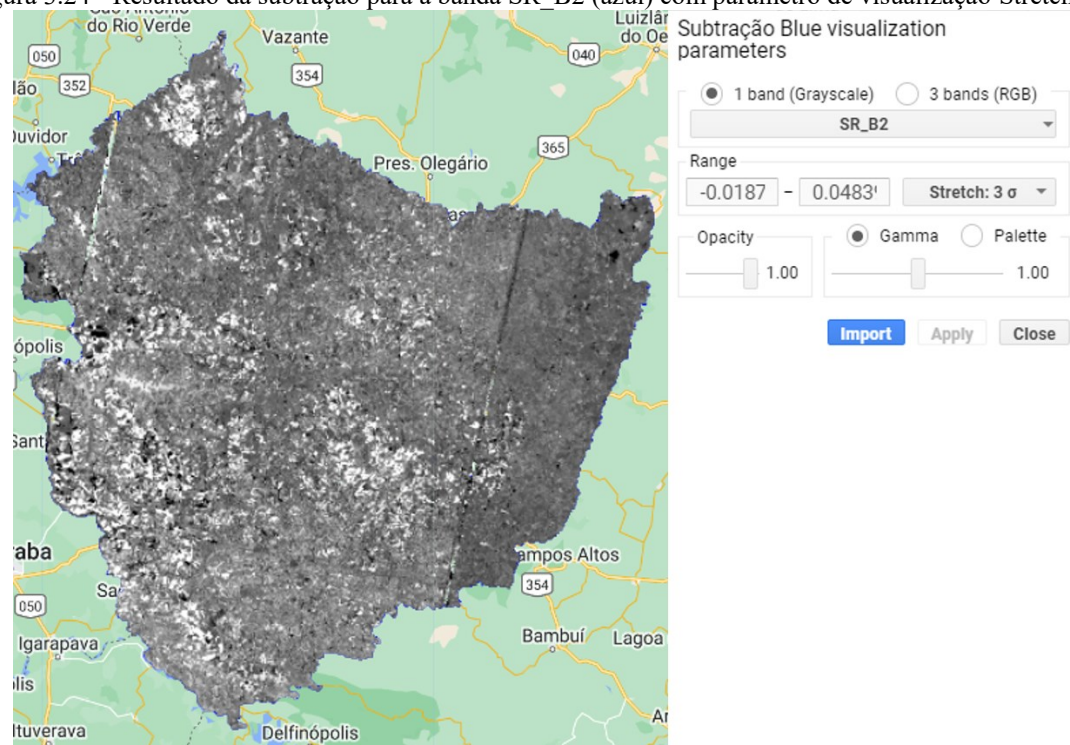
Fonte: A autora.

Figura 3.23 - Resultado da subtração para a banda SR_B3 (verde) com parâmetro de visualização Stretch: 3σ .



Fonte: A autora.

Figura 3.24 - Resultado da subtração para a banda SR_B2 (azul) com parâmetro de visualização Stretch: 3σ .




Fonte: A autora.

O parâmetro *Range* (em português, intervalo), no menu de visualizações, permite alterações na distribuição do histograma da imagem. É possível definir um valor mínimo e máximo para o pixel que assumirá 0 e 255 respectivamente, de modo manual, assim como

discutido anteriormente nessa seção. Outra opção é a utilização do *stretch* (em português, esticar) que determina o *range* automaticamente, de acordo com a necessidade da aplicação (Figura 3.25).

Figura 3.25 - Exemplo de aplicação do *stretch* a um histograma.

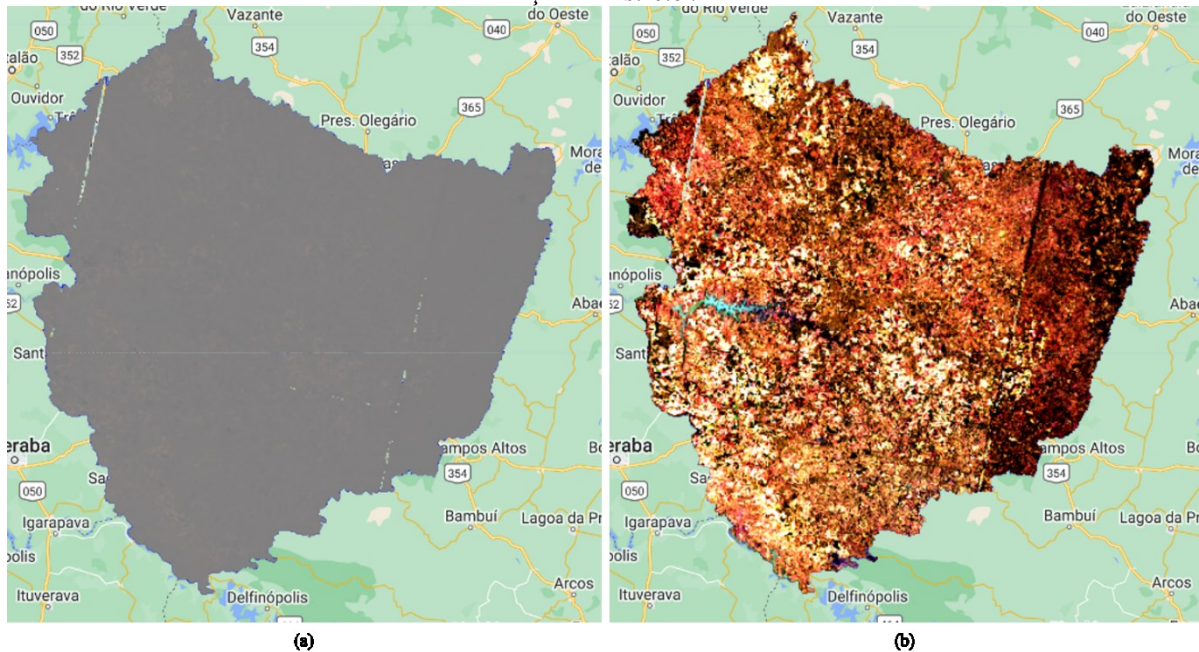


Fonte: WHAT-WHEN-HOW ([S.D.]).

Dentre as opções do *stretch* estão as que incluem a função Sigmoidal (um curva em formato de S), cujo objetivo é obter mais contraste entre os valores intermediários. O valor que acompanha o sigma, indica quanto da curva Sigmoidal será utilizado (ESRI). Quanto maior o valor mais contraste será aplicado. As demais opções são em porcentagens de 90, 98 e 100. Essas opções foram utilizadas em caráter de visualização, apenas.

Os resultados obtidos individualmente das bandas verde e azul, foram adicionados à banda vermelha por meio da função *addBands*. Tal recurso copia todas as bandas da imagem de origem e adiciona a ela, as bandas selecionadas das outras imagens designadas. Dessa forma, o resultado final foi uma imagem RGB. A Figura 3.26 (a) representa o resultado base da subtração, com todas as bandas, enquanto em (b) é mostrado o resultado com parâmetros de visualização apresentados anteriormente.

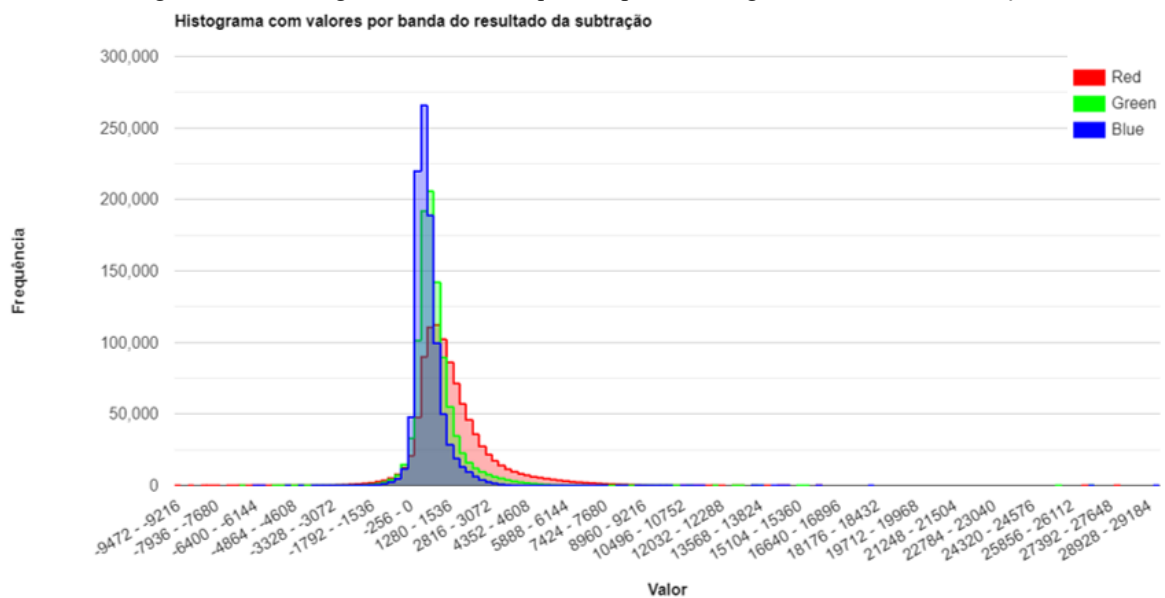
Figura 3.26 - Imagem resultante da subtração em que (a) é a imagem base e (b) a imagem com parâmetro de visualização com *stretch* de 1σ .



Fonte: A autora.

Posteriormente foi gerado o histograma do resultado obtido, apresentado na Figura 3.27. Os valores de pixel de cada banda foram dispostos nas respectivas cores das bandas, em blocos de 256 valores. Eles variaram de -9472 a 29184, sendo que quanto mais próximo a 0, menor a mudança registrada.

Figura 3.27 - Histograma das bandas que compõem a imagem resultante da subtração.



Fonte: A autora.

3.3.7. Obtenção dos resultados

Para a obtenção dos resultados foi necessário a obtenção das imagens já classificadas, que serviram como verdade em termos comparativos. O limiar de mudanças foi definido com

base experimental e comparativa. Foram obtidos resultados para mais de um cenário dentro dos fatores explorados.

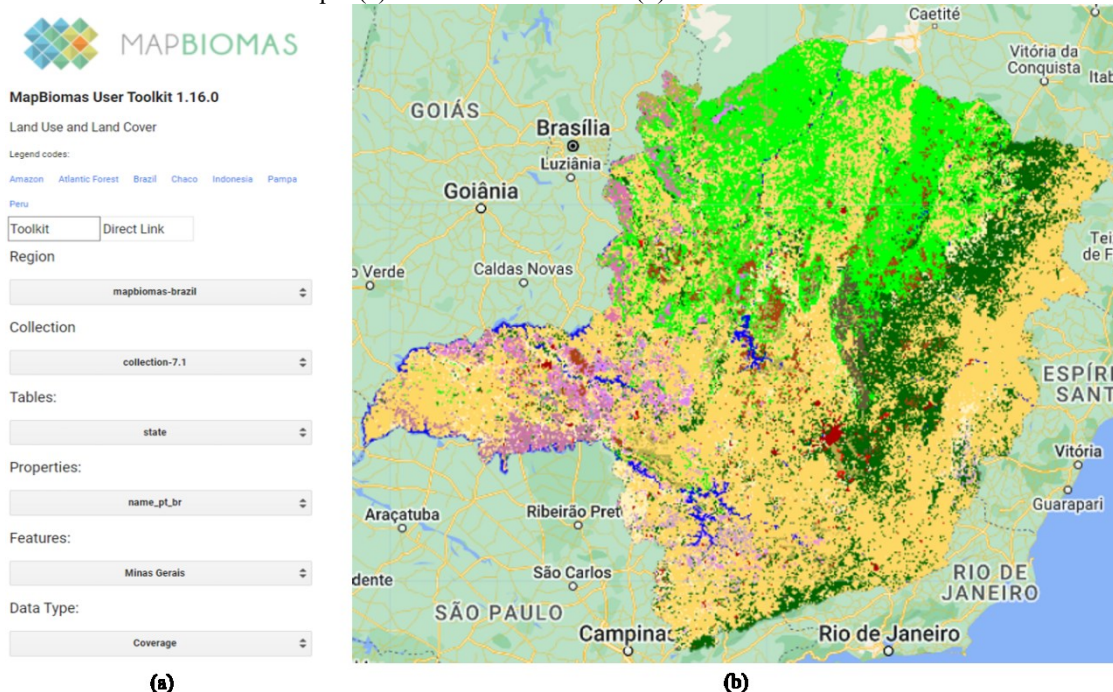
3.3.7.1. Aquisição das imagens já classificadas

Para gerar uma imagem verdade, como objetivo de comparação para validar o resultado obtido, é necessário que se tenha uma imagem já classificada. O Mapbiomas possui uma plataforma com diversas coleções de cobertura terrestre, tanto do Brasil quanto de outras regiões, com disponibilidade de *download* (MAPBIOMAS, 2019).

Em caráter de adquirir imagens que satisfaçam as necessidades do projeto, foi utilizado o *toolkit* (em português, kit de ferramentas) de cobertura da terra e uso da terra, que a plataforma disponibiliza no próprio GEE. Ela permite a obtenção de dados a partir de 1985 até o ano presente.

A Figura 3.28, apresenta alguns dos filtros utilizados para seleção do conjunto de imagens através do *toolkit*. Somados aos filtros apresentados, há a seleção do ano, o qual se deseja obter da imagem. Para o projeto em questão foram selecionados 2013 e 2020. O Mapbiomas também disponibiliza a legenda da classificação, para identificação das classes, que será utilizado posteriormente.

Figura 3.28 - Utilização do *toolkit* do Mapbiomas de cobertura e uso da terra (*Land Use and Land Cover*) em que (a) são filtros utilizados e (b) o resultado de 2013.



Fonte: A autora.

Como uma opção, os arquivos gerados para cada ano foram diretamente adicionados como *cloud assets* do projeto, ficando armazenados apenas em nuvem, sem a necessidade de *download* das imagens.

3.3.7.2. Criação do mapa experimental e do mapa verdade

Com todas as imagens coletadas, foi realizada uma subtração entre as já classificadas, gerando uma mapa de mudanças, chamado aqui de “mapa verdade”. O objetivo é comparar a um mapa gerado pela subtração das imagens estudadas previamente, que será tratado como “mapa experimental”, avaliando a precisão da operação e permitindo o ajuste do valor do limiar de mudança, definido através do histograma.

O mapa experimental foi gerado utilizando duas máscaras que retornam apenas os valores que atendem seus critérios, sendo eles os limiares superior e inferior do histograma. Inicialmente, com propósito de teste, foram definidos limiares de 10% dos valores máximo e mínimo, como critérios para as máscaras. A Figura 3.29 mostra a utilização da função *updateMask* juntamente à *gte* (*greater than or equal* em português, maior ou igual que) e *lte* (*less than or equal* em português, menor ou igual que) que geraram duas imagens. Sequencialmente as imagens foram transformadas em uma coleção de imagens, e unificadas pela função *mosaic*, retornando o mapa experimental da Figura 3.30.

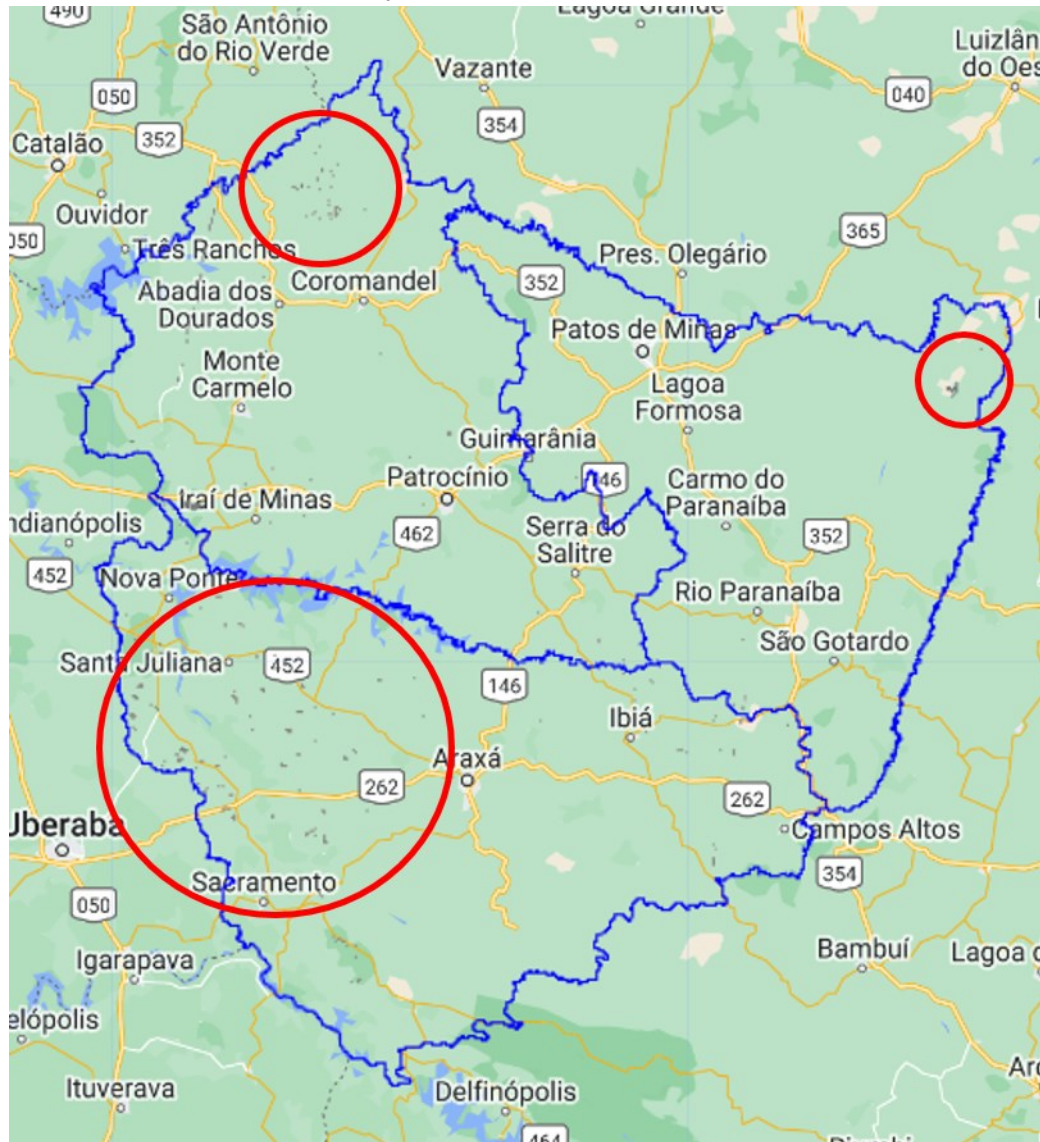
Figura 3.29 - Código de aplicação das máscaras para retornar apenas valores válidos que sejam maiores que 2918 e menores que -947.

```
var mapaSup = resultado.updateMask(resultado.gte(2918))
var mapaInf = resultado.updateMask(resultado.lte(-947))

var mapaExperimental = ee.ImageCollection([resultadoSup, resultadoInf]).mosaic()
```

Fonte: (A autora)

Figura 3.30 - Mapa experimental com destaque para os resultados obtidos da aplicação das máscaras com limiar de 10% dos valores de mínimo e máximo.



Fonte: A autora.

O mapa verdade seguiu o mesmo processo de criação, porém, como as imagens já foram classificadas, o 0 é o único valor que indica que não houve mudanças. Portanto o limiar definido são os valores acima e abaixo de 0, sem incluí-lo. O retorno está descrito na Figura 3.31.

Figura 3.31 - Mapa verdade.

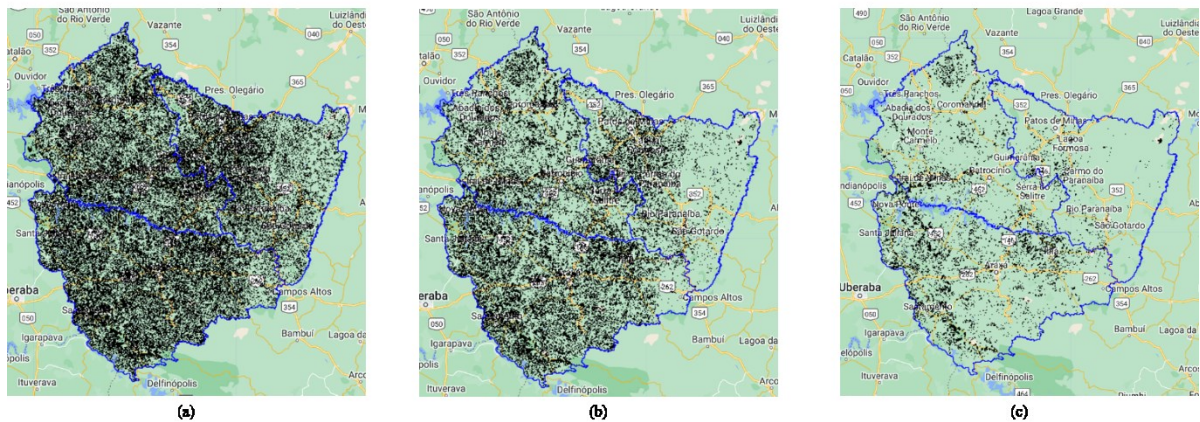


Fonte: A autora.

Visualmente, o mapa experimental da Figura 3.30 apresentou uma resposta pequena, em termos de área com mudanças, se comparado com a resposta do mapa verdade. Quando utilizados limiares mais próximos ao zero, o retorno foi de um mapa muito mais preenchido, porém visualmente com excessos, em relação ao mapa verdade, conforme a Figura 3.32.

Figura 3.33 - Função aplicada para resposta de equivalência, com os resultados considerando a criação do mapa experimental com limiares de (a) -256 e 256, (b) -256 e 512 e (c) -256 e 1024

```
var igualdade = resultadoExperimental.eq(mapaVerdadeFinal)
```



Fonte: A autora.

3.3.7.4. Cálculo de equivalência

Na determinação de um valor que represente a equivalência, de fato, foi necessário o cálculo da quantidade de pixels obtidos pela função apresentada na Figura 3.33. Com esse intuito, uma função do tipo Reducer foi aplicada à região de estudo (Figura 3.34). A aplicação do *count* retornou o número de valores não nulos da área, portanto, a quantidade de pixels válidos.

Figura 3.34 - Função para o cálculo da quantidade de pixels em uma região, com uma escala de 30 metros e com o máximo de pixels de 1^9 .

```
function pixelQuantidade(imageC){
    var dictionary = imageC.reduceRegion({
        reducer: ee.Reducer.count(),
        geometry: AP,
        scale: 30,
        maxPixels: 1e9
    });
    print(dictionary)
}
```

Fonte: A autora.

Contudo, a equivalência foi obtida em três bandas (RGB), devido a função inicial envolver o mapa experimental, calculado nessas bandas. Esse tipo de resposta não é interessante, já que os pixels podem estar sobrepostos em bandas diferentes, gerando um resultado incorreto. Visando uma única banda, elas foram somadas através da função *add*, aplicada ao resultado experimental.

Para uma resposta comparativa, a mesma função foi aplicada às imagens do mapa experimental, agora em uma única banda, e o mapa verdade.

3.3.7.5. Mapa classificado da vegetação do cerrado

Com a definição de meios para a determinação da equivalência entre dois mapas, o passo seguinte exigia o estabelecimento, dentro da classificação, da informação de interesse. A classificação do mapa foi feita com base na Coleção 7 de dados do Mapbiomas. A documentação dessa coleção abriga as classes conforme a Tabela 1. Cada ID indica o valor que o pixel assume de acordo com a classe pertencente (MAPBIOMAS, 2022). Esses dados contemplam todo o objetivo da coleção, que traz informações de cobertura de todo o país, além de outras regiões.

Na divisão, os valores de índices 1 e 2 indicam áreas florestais ou arborizadas, assim como áreas não florestais, mas de formação natural, como pantanais ou prados. O índice 3 foi designado para o uso da terra com agropecuária, como pastos, plantações de culturas temporárias ou perenes, dentre outras. Com índice 4 estão as áreas não vegetadas, como área urbana ou de mineração, e com o 5 os corpos d'água. O índice 6 indica áreas não observadas.

Tabela 1 - Classes e suas especificidades da Coleção 7 do Mapbiomas.

| ID | Classes Coleção 7 | Natural/ Antrópico | Cobertura/ Uso da terra | Bioma/ Tema |
|----|--|-----------------------|----------------------------|----------------|
| 1 | 1. Floresta | NATURAL | COBERTURA | - |
| 3 | 1.1 Formação florestal | NATURAL | COBERTURA | BIOMA |
| 4 | 1.2 Formação de savana | NATURAL | COBERTURA | BIOMA |
| 5 | 1.3 Mangue | NATURAL | COBERTURA | TEMA |
| 49 | 1.4 Vegetação de restinga arborizada | NATURAL | COBERTURA | BIOMA |
| 10 | 2. Formações Naturas Não-Florestais | NATURAL | COBERTURA | - |
| 11 | 2.1 Pantanal | NATURAL | COBERTURA | BIOMA |
| 12 | 2.2 Formação de prados | NATURAL | COBERTURA | BIOMA |
| 32 | 2.3 Deserto de sal | NATURAL | COBERTURA | BIOMA |
| 29 | 2.4 Afloramento rochoso | NATURAL | COBERTURA | BIOMA |
| 50 | 2.5 Vegetação herbácea de restinga | NATURAL | COBERTURA | BIOMA |
| 13 | 2.6 Outras formações não florestais | NATURAL | COBERTURA | BIOMA |
| 14 | 3. Agropecuária | ANTRÓPICO | USO | - |
| 15 | 3.1 Pasto | ANTRÓPICO | USO | TEMA |
| 18 | 3.2 Agricultura | ANTRÓPICO | USO | TEMA |
| 19 | 3.2.1 Cultura Temporária | ANTRÓPICO | USO | TEMA |
| 39 | 3.2.1.1 Soja | ANTRÓPICO | USO | TEMA |
| 20 | 3.2.1.2 Cana de açúcar | ANTRÓPICO | USO | TEMA |
| 40 | 3.2.1.3 Arroz | ANTRÓPICO | USO | TEMA |
| 62 | 3.2.1.4 Algodão | ANTRÓPICO | USO | TEMA |
| 41 | 3.2.1.5 Outras culturas temporárias | ANTRÓPICO | USO | TEMA |

| | | | | |
|----|------------------------------------|-----------------------|-------------------|-------|
| 36 | 3.2.2 Cultura Perene | ANTRÓPICO | USO | TEMA |
| 46 | 3.2.2.1 Café | ANTRÓPICO | USO | TEMA |
| 47 | 3.2.1.1 Cítricos | ANTRÓPICO | USO | TEMA |
| 48 | 3.2.1.1 Outras culturas perenes | ANTRÓPICO | USO | TEMA |
| 9 | 3.3 Plantação de floresta | ANTRÓPICO | USO | TEMA |
| 21 | 3.2 Mosaico de usos | ANTRÓPICO | USO | TEMA |
| 22 | 4. Áreas não vegetadas | NATURAL/ ANTRÓPICO | COBERTURA/ USO | - |
| 23 | 4.1 Praia, duna ou mancha de areia | NATURAL | COBERTURA | TEMA |
| 24 | 4.2 Área urbana | ANTRÓPICO | USO | TEMA |
| 30 | 4.3 Mineração | ANTRÓPICO | USO | TEMA |
| 25 | 4.4 Outras áreas não vegetadas | NATURAL/ ANTRÓPICO | COBERTURA/ USO | BIOMA |
| 26 | 5. Água | NATURAL/ ANTRÓPICO | COBERTURA/ USO | - |
| 33 | 5.1 Rio, lago e oceano | NATURAL | COBERTURA | BIOMA |
| 31 | 5.2 Aquicultura | ANTRÓPICO | USO | TEMA |
| 27 | 6. Não observado | NENHUM | NENHUM | - |

Fonte: MAPBIOMAS (2022).

O Alto Paranaíba é completamente coberto pelo bioma do cerrado, logo, não se faz necessário uma separação de tipos de vegetação. Portanto, para a determinação da informação de interesse, foram isolados todos os IDs que continham informações de cobertura apenas natural, independente da vegetação característica do cerrado. Dessa forma, foi gerado um novo mapa para 2013 e 2020, chamados aqui de “mapa do cerrado 2013” e “mapa do cerrado 2020”, representados nas Figura 3.36 e Figura 3.37, utilizando a função apresentada na Figura 3.35.

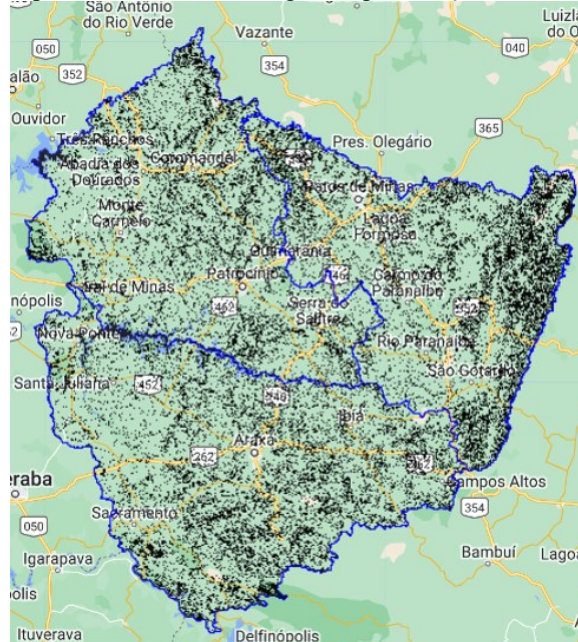
Figura 3.35 - Função aplicada para o retorno do mapa do cerrado natural classificado.

```
function selectNaturalClass(imagem, vetorValue){
    var mapaVddCerrado = []
    for(var i = 0; i<vetorValue.length; i++){
        mapaVddCerrado[i] =imagem.updateMask(imagem.eq(vetorValue[i]))
    }
    mapaVddCerrado = ee.ImageCollection(mapaVddCerrado).mosaic()
    return mapaVddCerrado;
}
var cerrado2013 = selectNaturalClass(image,[1,3,4,5,49,10,11,12,32,29,50,13,33])
var cerrado2020 = selectNaturalClass(image2,[1,3,4,5,49,10,11,12,32,29,50,13,33])
```

Fonte: A autora.


A função tem como argumentos uma imagem e um vetor de valores, utilizados para a definição da equivalência. Neste caso, a imagem recebe o mapa classificado, de 2013 ou 2020, e o vetor, os valores dos IDs com característica natural sendo eles, na ordem da Tabela 1: 1; 3; 4; 5; 49; 10; 11; 12; 32; 29; 50; 13; 33. Após a aplicação da máscara, que compara o valores da imagem aos valores do vetor, elas são agrupadas em uma coleção de imagens, e unificadas com a função *mosaic*.

Figura 3.36 - Mapa do cerrado em 2013 gerado pela função descrita na Figura 3.35.



Fonte: A autora.

Figura 3.37 - Mapa do cerrado em 2020 gerado pela função descrita na Figura 3.35.



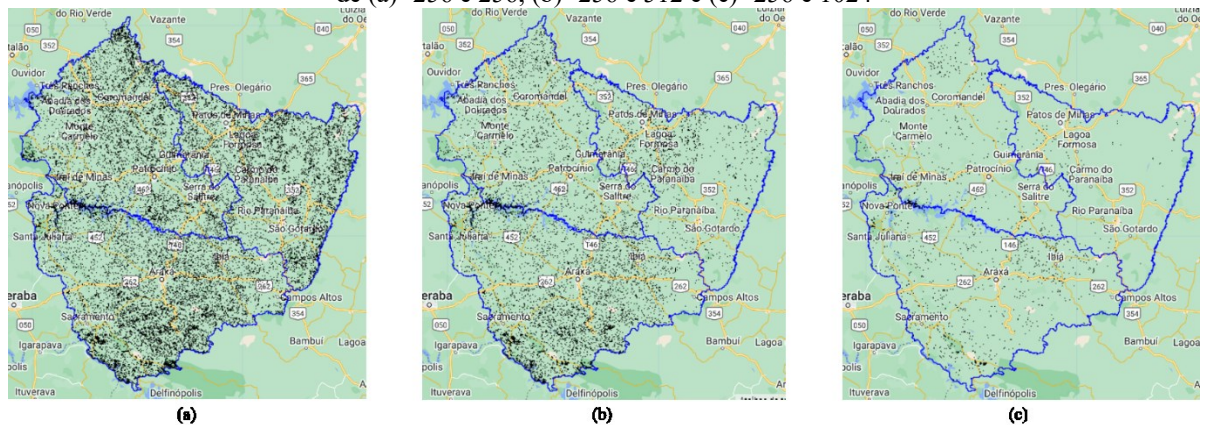
Fonte: A autora.

3.3.7.6. Comparando as mudanças com os mapas do cerrado

Já com todos os mapas definidos, os passos finais da aplicação envolveram o comparativo entre o mapa experimental e os mapas do cerrado, conforme exposto no escopo, na Seção 3.3.2. Em ambos os casos, foi feito o uso das funções já discutidas previamente neste capítulo.

Equiparar o mapa do cerrado de 2013 com o mapa experimental, novamente com o emprego de vários limiares, possibilitou a visualização de diferentes respostas, dispostas na Figura 3.38. Além disso, também foram repetidos os cálculos de quantidade de pixels válidos, considerando estes cenários.

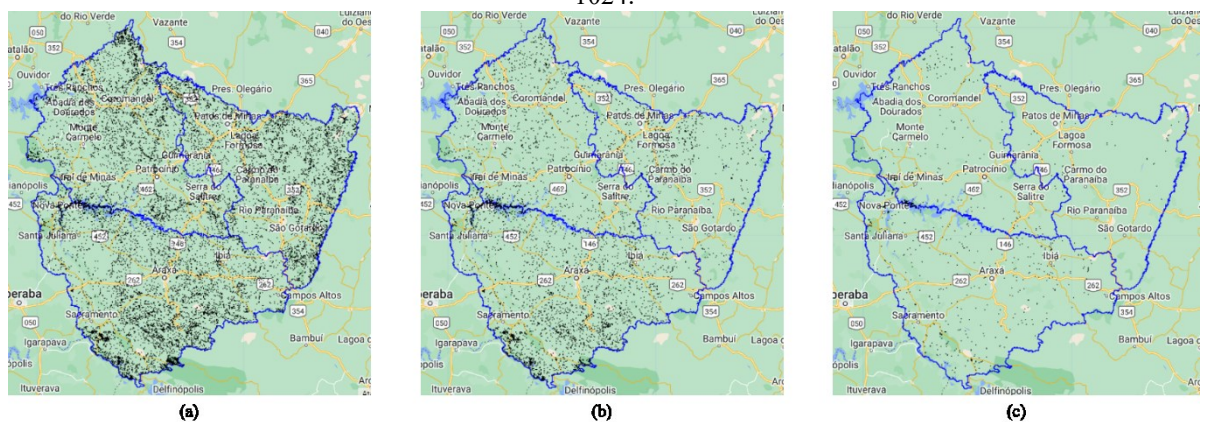
Figura 3.38 - Respostas da equivalência entre o mapa do cerrado de 2013 e o mapa experimental com limiares de (a) -256 e 256, (b) -256 e 512 e (c) -256 e 1024



Fonte: A autora.

Sequencialmente, de forma análoga, a resposta dessa operação foi comparada ao mapa do cerrado de 2020, resultando nas imagens vistas na Figura 3.39.

Figura 3.39 - Respostas da equivalência entre os mapas da Figura 3.38 e o mapa do cerrado de 2020, sendo a operação inicial realizada para o mapa experimental com limiares de (a) -256 e 256, (b) -256 e 512 e (c) -256 e 1024.



Fonte: A autora.

Para alcançar o objetivo final, foram calculados a quantidade de pixels em todas as etapas e, por meio de operações matemáticas, tornou-se possível a obtenção dos resultados numéricos de precisão e área, que serão discutidos no Capítulo 4.

3.4. CONSIDERAÇÕES FINAIS

Neste capítulo foram abordadas as ferramentas que serão utilizadas no trabalho, sendo o principal componente, o *Google Earth Engine*, que abriga tanto os dados quanto as ferramentas de desenvolvimento, necessários para a execução e análise do projeto proposto. Também, a metodologia proposta para execução do projeto e o decorrer do desenvolvimento deste. No capítulo subsequente, serão apresentados os resultados obtidos conforme implementação das técnicas de detecção de mudanças, discorridas no item 3.3 Desenvolvimento.

CAPÍTULO 4

RESULTADOS E DISCUSSÕES

Os resultados obtidos, provenientes da execução do código fonte do projeto, foram explorados e analisados, em quantidade pixels válidos, para cada imagem gerada, sendo expostos e comparados em tabelas no decorrer deste Capítulo. Continuamente, foram discutidos de modo teórico, com a exposição do que era esperado, do que atendeu as expectativas ou mesmo do que deixou a desejar. Também foram sugeridas pequenas melhorias.

4.1. RESULTADOS

4.1.1. Definição do limiar de mudanças

O mapa experimental, discutido no Capítulo 3, é o resultado da subtração entre as imagens selecionadas do *Landsat 8*, nos anos de 2013 e 2020, no perímetro da região do Alto Paranaíba. Para avaliar a precisão da detecção de mudanças, foram arbitrados limiares inferiores e superiores que pudessem indicar mudanças válidas. Como discutido previamente, valor igual ou próximo a 0 indica que não houve mudanças, ou que não sofreram grandes alterações, enquanto valores altos indicam mudanças mais significativas. As respostas foram comparadas com o mapa verdade.

Inicialmente, foi considerado um escopo geral de análise, em que toda a região foi levada em conta. Foram levantadas as informações de quantidade de pixels válidos do mapa experimental, quantidade de pixels válidos que possuem equivalência com o mapa verdade, porcentagem dessa equivalência e, a porcentagem do mapa verdade presente no mapa experimental.

O processo foi realizado para três valores fixos de limiar inferior, escolhidos arbitrariamente com base no histograma (Figura 3.27), considerando pequenas e grandes mudanças, sendo eles: -100; -256 e -1024. Os limiares superiores também foram escolhidos arbitrariamente, e por ter um intervalo cerca de três vezes maior que o inferior, foram definidos nove valores: 64; 256; 512; 768; 1024; 1536; 2048; 4096; 8192. O mapa verdade possui uma quantidade de pixels igual a 10.416.988. Os dados coletados estão dispostos nas Tabelas 2, 3 e 4.

Tabela 2 - Resultados do mapa experimental para o limiar inferior igual a -100.

| Limiar Superior | Experimenta l (px) | Equivalência (px) | Mapa Verdade Presente (%) | Aproveitament o dos pixels (%) |
|------------------------|-------------------------------|------------------------------|--------------------------------------|---|
| 64 | 39.345.447 | 9.442.178 | 90,64 | 24,00 |

| | | | | |
|-------------|------------|-----------|-------|-------|
| 256 | 30.040.560 | 7.989.831 | 76,70 | 26,60 |
| 512 | 18.982.928 | 5.969.051 | 57,30 | 31,44 |
| 768 | 11.458.863 | 4.377.255 | 42,02 | 38,20 |
| 1024 | 7.345.444 | 3.259.762 | 31,29 | 44,38 |
| 1536 | 3.947.918 | 1.870.893 | 17,96 | 47,39 |
| 2048 | 2.474.196 | 1.127.481 | 10,82 | 45,57 |
| 4096 | 1.232.035 | 520.975 | 5,00 | 42,29 |
| 8192 | 1.226.638 | 518.671 | 4,98 | 42,28 |

Fonte: A autora.

Tabela 3 - Resultados do mapa experimental para o limiar inferior igual a -256.

| Limiar Superior | Experimenta l (px) | Equivalência (px) | Mapa Verdade Presente (%) | Aproveitament o dos pixels (%) |
|------------------------|---------------------------|--------------------------|----------------------------------|---------------------------------------|
| 64 | 38.417.594 | 9.089.326 | 87,25 | 23,66 |
| 256 | 29.449.085 | 7.752.084 | 74,42 | 26,32 |
| 512 | 18.509.812 | 5.777.795 | 55,47 | 31,21 |
| 768 | 11.010.900 | 4.197.635 | 40,30 | 38,12 |
| 1024 | 6.905.707 | 3.083.992 | 29,61 | 44,66 |
| 1536 | 3.512.732 | 1.697.152 | 16,29 | 48,31 |
| 2048 | 2.039.755 | 954.109 | 9,16 | 46,78 |
| 4096 | 797.588 | 347.604 | 3,34 | 43,58 |
| 8192 | 792.365 | 345.377 | 3,32 | 43,59 |

Fonte: A autora.

Tabela 4 - Resultados do mapa experimental para o limiar inferior igual a -1024.

| Limiar Superior | Experimenta l (px) | Equivalência (px) | Mapa Verdade Presente (%) | Aproveitament o dos pixels (%) |
|------------------------|---------------------------|--------------------------|----------------------------------|---------------------------------------|
| 64 | 37.487.438 | 8.675.119 | 83,28 | 23,14 |
| 256 | 28.691.732 | 7.413.191 | 71,16 | 25,84 |
| 512 | 17.812.105 | 5.467.103 | 52,48 | 30,69 |
| 768 | 10.327.495 | 3.894.009 | 37,38 | 37,71 |
| 1024 | 6.226.158 | 2.781.918 | 26,71 | 44,68 |
| 1536 | 2.835.191 | 1.396.090 | 13,40 | 49,24 |
| 2048 | 1.362.518 | 653.203 | 6,27 | 47,94 |
| 4096 | 120.504 | 46.737 | 0,45 | 38,78 |
| 8192 | 115.301 | 44.513 | 0,43 | 38,61 |

Fonte: A autora.

Nos três casos avaliados, a equivalência com o mapa verdade apresenta um valor abaixo de 50%, indicando que mais da metade dos pixels resultantes da subtração não representavam alteração de classe. Ou seja, poderiam ter alterações físicas, como a mudança de culturas por exemplo, mas em ambos os anos, seriam classificadas na classe agricultura. Pixels que não mudaram de classe, não representam uma mudança de fato, para o intuito deste projeto.

Outro ponto para discussão, é que o pico de equivalência com o mapa verdade é atingido no valor de 1536, em todos os casos. Apesar disso, a representatividade do mapa verdade nesse limiar é muito baixa, sendo no melhor dos casos, cerca de 18%.

A presença do mapa verdade é inversa à quantidade de pixels totais do mapa experimental. Isso mostra que as mudanças foram no geral, relativamente pequenas, sendo que valores acima de 512 apresentam menos de 50% de presença do mapa verdade.

Em contrapartida, com o limiar superior definido em 64, entre 80% a 90% do mapa verdade está presente no experimental. A proximidade com a totalidade seria um valor adequado, porém, para este mesmo limiar, aproximadamente 76% do mapa experimental não representa uma mudança de interesse nos três casos abordados.

Levantando um último ponto, ainda que o maior valor de limiar superior válido seja 29183, valores como 4096 ou 8192 apresentam um indício de estabilidade. Isso porque a quantidade de pixels neste intervalo, acima de 4096, já não é suficientemente relevante para apresentar diferenças significativas entre eles, mesmo abrigando as maiores mudanças.

O limiar de mudanças é definido, no geral, empiricamente, com base em experimentações. Para este caso, inicialmente, foram selecionados os valores que continham até, pelo menos, 50% do mapa verdade presente.

4.1.2. Comparação com o cerrado de 2013

O mapa experimental não permite o isolamento do que é vegetação pertencente ao cerrado, uma vez que não foi classificado. Portanto, sua resposta sempre será igual ao apresentado nas tabelas do tópico 4.1.1. Comparando com o mapa do cerrado de 2013, para a identificação das mudanças, obteve-se os resultados apresentados nas Tabelas 5, 6 e 7.

Para confrontá-los, a mesma comparação foi realizada com o mapa verdade, revelando que 1.103.395 pixels mudaram de classe entre 2013 e 2020. O mapeamento do cerrado de 2013 possui 11.177.701 pixels.

Tabela 5 - Resultados do mapa experimental, para o limiar inferior igual a -100, comparado ao mapa do cerrado.

| Limiar Superior | Experimental (px) | Mudanças detectadas (px) | Comparação com o resultado do mapa verdade (%) |
|------------------------|--------------------------|---------------------------------|---|
| 64 | 39.345.447 | 9.685.905 | 878 |
| 256 | 30.040.560 | 5.251.386 | 476 |
| 512 | 18.982.928 | 2.037.835 | 185 |

Fonte: A autora.

Tabela 6 - Resultados do mapa experimental, para o limiar inferior igual a -256, comparado ao mapa do cerrado.

| Limiar Superior | Experimental (px) | Mudanças detectadas (px) | Comparação com o resultado do mapa verdade (%) |
|------------------------|--------------------------|---------------------------------|---|
| 64 | 38.417.594 | 9.558.659 | 866 |
| 256 | 29.449.085 | 5.178.440 | 469 |
| 512 | 18.509.812 | 1.981.065 | 180 |

Fonte: A autora.

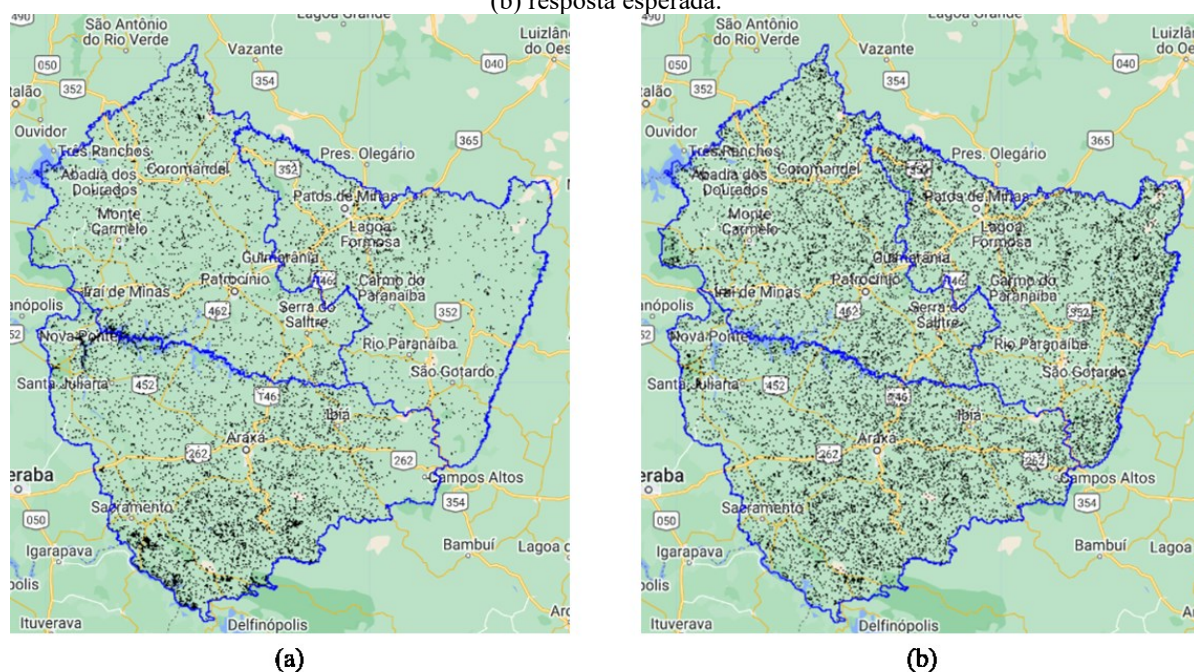
Tabela 7 - Resultados do mapa experimental, para o limiar inferior igual a -1024, comparado ao mapa do cerrado.

| Limiar Superior | Experimental (px) | Mudanças detectadas (px) | Comparação com o resultado do mapa verdade (%) |
|------------------------|--------------------------|---------------------------------|---|
| 64 | 37.487.438 | 9.483.703 | 859 |
| 256 | 28.691.732 | 5.124.617 | 464 |
| 512 | 17.812.105 | 1.931.182 | 175 |

Fonte: A autora.

Como descrito anteriormente, o mapa experimental corresponde à todas as mudanças detectadas, enquanto o mapa verdade, apenas às mudanças de classe. Fazendo um paralelo entre os resultados de ambos, no melhor dos casos, o mapa experimental apresentou 75% a mais de informações detectadas, podendo chegar oito vezes do valor esperado, no pior dos casos. A Figura 4.1 mostra a diferença entre o esperado e o obtido para o melhor caso.

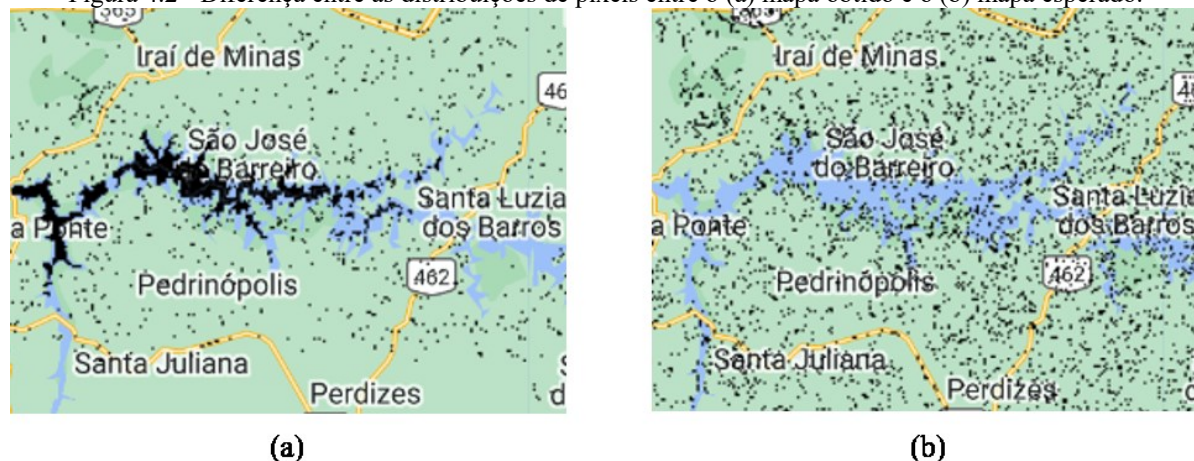
Figura 4.1 - Comparação visual entre a (a) resposta obtida para limiar inferior em -1024 e superior em 512 e (b) resposta esperada.



Fonte: A autora.

Neste cenário, mesmo que a quantidade de pixels alcance a igualdade entre o esperado e o obtido, não há a certeza de que sejam os mesmos. A Figura 4.2 mostra um exemplo dessa ocorrência, utilizando os mapas da Figura 4.1.

Figura 4.2 - Diferença entre as distribuições de pixels entre o (a) mapa obtido e o (b) mapa esperado.



Fonte: A autora.

Alterações de cor de corpos d'água, vegetação, rochas, dentre outros, são detectados como mudanças. Por isso, uma análise apenas quantitativa não é suficiente para determinar a precisão do limiar de mudanças. Neste caso então, foi aplicada a função de equivalência entre os mapas obtidos e o desejado, resultando nas Tabelas 8, 9 e 10.

Tabela 8 – Equivalência entre o mapa obtido e o mapa desejado, para a variação do limiar superior, considerando o limiar inferior do mapa experimental igual a -100.

| Limiar Superior | Equivalência entre o desejado e o obtido (%) |
|------------------------|---|
| 64 | 87,45 |
| 256 | 66,54 |
| 512 | 38,84 |

Fonte: A autora.

Tabela 9 – Equivalência entre o mapa obtido e o mapa desejado, para a variação do limiar superior, considerando o limiar inferior do mapa experimental igual a -256.

| Limiar Superior | Equivalência entre o desejado e o obtido (%) |
|------------------------|---|
| 64 | 90,96 |
| 256 | 69,14 |
| 512 | 41,16 |

Fonte: A autora.

Tabela 10 – Equivalência entre o mapa obtido e o mapa desejado, para a variação do limiar superior, considerando o limiar inferior do mapa experimental igual a -1024.

| Limiar Superior | Equivalência entre o desejado e o obtido (%) |
|------------------------|---|
| 64 | 89,18 |
| 256 | 68,02 |
| 512 | 40,23 |

Fonte: A autora.

A resposta que apresentou maior equivalência é decorrente do menor limiar (64). Novamente há o indício de que as mudanças que ocorreram entre 2013 e 2020 foram, em sua maioria, pequenas, mesmo quando isolada apenas a área de cobertura natural.

Todos os resultados para o limiar inferior em -100, se mostraram piores quando comparados aos outros dois limiares. Eles apresentaram uma equivalência menor, mesmo possuindo mais informações. Portanto, serão desconsiderados para análises futuras.

Os resultados para o limiar inferior em -256, apresentaram as maiores equivalências. Contudo, também possuem mais informações dispensáveis, quando comparados com os resultados do limiar em -1024. Por isso, ambos serão analisados nas próximas etapas, com o intuito de definir o quanto tais informações interferem no resultado final.

4.1.3. Comparação com o cerrado de 2020

Neste ponto, já foram definidos em quais locais ocorreram ou foram detectadas mudanças, no cerrado em 2013, com relação ao ano de 2020. Essa segunda comparação foi realizada com o intuito de definir quais foram as mudanças encontradas.

As informações dispostas nas Tabelas 11 e 12 representam as mudanças em relação à 2013 e o quanto dessas mudanças são equivalentes ao cerrado de 2020. Os pixels equivalentes revelam que não houve a mudança de classe, permanecendo como cerrado. Já a diferença indica o que supostamente deixou de ser cerrado.

Tabela 11 – Equivalência entre as mudanças detectadas e o mapa do cerrado em 2020, assim como a diferença entre eles, para a variação do limiar superior, considerando o limiar inferior do mapa experimental igual a -256.

| Limiar Superior | Mudanças cerrado 2013 | Equivalência das mudanças com 2020 (px) | Diferença (px) |
|------------------------|------------------------------|--|-----------------------|
| 64 | 9.558.659 | 8.736.030 | 822.629 |
| 256 | 5.178.440 | 4.514.616 | 663.824 |
| 512 | 1.981.065 | 1.569.468 | 411.597 |

Fonte: A autora.

Tabela 12 – Equivalência entre as mudanças detectadas e o mapa do cerrado em 2020, assim como a diferença entre eles, para a variação do limiar superior, considerando o limiar inferior do mapa experimental igual a -1024.

| Limiar Superior | Mudanças cerrado 2013 | Equivalência das mudanças com 2020 (px) | Diferença (px) |
|------------------------|------------------------------|--|-----------------------|
| 64 | 9.483.703 | 8.676.074 | 807.629 |
| 256 | 5.124.617 | 4.473.895 | 650.722 |
| 512 | 1.931.182 | 1.532.023 | 399.159 |

Fonte: A autora.

Dentre as mudanças identificadas, utilizando o mapa verdade, 206.190 pixels se mantiveram dentro das classes naturais. Por outro lado, 897.205 pixels apresentaram mudanças de classe, sendo identificados em classes com influência antrópica.

Novamente, a avaliação quantitativa não permitiu a comparação completa da informação. Para avaliar qualitativamente, foi necessário encontrar os pontos equivalentes entre as informações, caracterizadas como “não cerrado”, e as diferenças experimentais obtidas. As Tabelas 13 e 14 apresentam estes resultados.

Tabela 13 – Equivalência da diferença com o “não cerrado”, para a variação do limiar superior, considerando o limiar inferior do mapa experimental igual a -256.

| Limiar Superior | Equivalência com o "não cerrado" (%) |
|------------------------|---|
| 64 | 91,69 |
| 256 | 73,99 |
| 512 | 45,88 |

Fonte: A autora.

Tabela 14 – Equivalência da diferença com o “não cerrado”, para a variação do limiar superior, considerando o limiar inferior do mapa experimental igual a -1024.

| Limiar Superior | Equivalência com o "não cerrado" (%) |
|------------------------|---|
| 64 | 90,02 |
| 256 | 72,53 |
| 512 | 44,49 |

Fonte: A autora.

No processo de análise, todos os pixels encontrados na diferença, apresentaram igualdade com o valor esperado. Portanto, fazendo as devidas comparações, foi encontrado até 91,7% das mudanças antrópicas. Apesar de retornar um valor aceitável, as mudanças antrópicas representaram apenas uma pequena parte das mudanças detectadas. As Tabelas 15 e 16 apresentam essa diferença, além de destacarem quanto das mudanças são realmente verdadeiras.

Tabela 15 – Equivalência com as mudanças verdadeiras no cerrado e as mudanças antrópicas em relação ao todo, para a variação do limiar superior, considerando o limiar inferior do mapa experimental igual a -256.

| Limiar Superior | Equivalência com as mudanças verdadeiras do cerrado (%) | Mudanças antrópicas em relação ao todo (%) |
|------------------------|--|---|
| 64 | 78,2 | 8,6 |
| 256 | 42,0 | 12,8 |
| 512 | 15,7 | 20,8 |

Fonte: A autora.

Tabela 16 – Equivalência com as mudanças verdadeiras no cerrado e as mudanças antrópicas em relação ao todo, para a variação do limiar superior, considerando o limiar inferior do mapa experimental igual a -1024.

| Limiar Superior | Equivalência com as mudanças verdadeiras do cerrado (%) | Mudanças antrópicas em relação ao todo (%) |
|------------------------|--|---|
| 64 | 76,3 | 8,5 |
| 256 | 40,5 | 12,7 |
| 512 | 14,2 | 20,7 |

Fonte: A autora.

As mudanças antrópicas tiveram representações próximas, comparando as respostas dos limiares inferiores, tendo maior representação para o limiar superior de 512, em ambos os casos. Apesar das mudanças do cerrado representarem a menor porção do total de mudanças, a equivalência com o valor encontrado é muito baixa, sendo o melhor valor 78,2%. Considerando que as respostas com limite inferior em -1024 foram menores, elas não foram avaliadas na análise final.

Por fim, então, foram analisados quanto da resposta obtida indica de fato uma mudança, o quanto da resposta verdadeira está presente na resposta final e o quanto de informação inutilizada está presente no resultado. A Tabela 17 abriga essas informações.

Tabela 17 – Porcentagem de mudanças verdadeiras com base no total de pixels encontrados, porcentagem de mudanças presentes no resultado final e porcentagem do total que representam informações inutilizáveis, para a variação do limiar superior, considerando o limiar inferior do mapa experimental igual a -256.

| Limiar Superior | Mudanças verdadeiras em relação ao todo (%) | Mudanças verdadeiras identificadas no total (%) | Informações encontradas não utilizadas (%) |
|------------------------|--|--|---|
| 64 | 10,29 | 89,2 | 89,71 |
| 256 | 14,49 | 68,0 | 85,51 |
| 512 | 22,41 | 40,2 | 77,59 |

Fonte: A autora.

Como observação, os valores adquiridos para os limiares superiores em 256 poderiam ser descartados para análise, por não apresentarem uma resposta melhor em nenhum dos quesitos. Porém, foram mantidas para uma avaliação de comportamento.

4.2. DISCUSSÕES

A aplicação do método de diferenciação de imagens na detecção de mudanças, neste caso utilizando as bandas do RGB, não se mostrou eficiente. Ele resultou em um mapa muito abrangente para o tipo de aplicação desejada, englobando todos os tipos de mudança, sem nenhuma discriminação.

Os limiares analisados apresentaram no geral um baixo aproveitamento dos pixels. Os valores mais baixos abrigaram maior porcentagem do mapa verdade. Entretanto, essa informação representava muito pouco do total, ou seja, a quantidade de informações indesejadas era muito maior que as de interesse.

O esperado neste ponto, era um resultado que mesmo apresentando baixa presença do mapa verdade, obtivesse um grande aproveitamento. Isso indicaria um resultado menor, no ponto de vista da quantidade de mudanças, porém preciso. A expectativa era que as maiores mudanças, ou seja, valores maiores de limiar, tivessem esse comportamento. Porém, partindo do valor de 1536, o comportamento apresentado foi decrescente.

Destacou-se, então, os limiares que abrigavam a maior presença do mapa verdade, já que o aproveitamento dos limiares não alcançou os 50%. Aplicando as análises comparativas com o mapa de 2013 do cerrado, o resultante foi uma alta correlação entre o obtido e o esperado, para os limites menores (-256, 64 e -1024,64). Porém, em uma análise quantitativa, foi possível identificar que a quantidade de pixels era muito maior, que o gerado pelo mapa verdade.

A diferença na quantidade de pixels era esperada, pela determinação inicial do limiar. Tanto o mapa verdade quanto o experimental foram aplicados em equivalência com o mapa do cerrado de 2013. Porém, como demonstrado, a subtração não capta apenas mudanças de classe, apresentado também, as mudanças no cerrado que não caracterizam uma interferência exatamente antrópica. Por isso, apesar da drástica redução na quantidade total de pixels, há ainda uma forte presença de falsos positivos.

O valor que apresentou menor quantidade de pixels (-1024, 512) também apresentou uma correlação, relativamente baixa. No entanto, pela quantidade de informação extra ser cerca de sete vezes menor, ela permaneceu no escopo de análises, assim como os demais valores apresentados para o limiar de -1024 e de -256. Os valores da Tabela 5 não se

mostraram melhores em nenhum dos fatores, portanto foram descartados para as futuras análises.

Na comparação com o cerrado de 2020, as mudanças já haviam sido definidas. Desse modo, foi possível diferir quais das mudanças detectadas, tiveram alteração de classe, mas permaneceram dentro da definição de natural. As demais, formaram o conjunto de mudanças de interesse, que possuem influência antrópica.

O comportamento na análise quantitativa permaneceu o mesmo, em relação à comparação anterior, o que era esperado. Analisando inicialmente as mudanças definidas como alteração humana, a resposta foi consideravelmente próxima ao resultado verdadeiro, considerando o melhor cenário. Porém, a quantidade de pixels, que permaneceram como naturais, foi muito menor que os valores experimentais.

Dentre as mudanças de interesse, ou seja, que deixaram de ser classificadas como cerrado, a resposta mais próxima equivale à uma área de 24.678.870 m². Já resposta esperada equivale à 26.916.150 m². Porém, com este método, só foi possível essa definição devido ao mapa verdade, utilizado como comparativo. Esse valor obtido é correspondente à apenas 8,6% de todas as mudanças detectadas. Em um cenário em que há uma maior correspondência com o todo (20,8%), o valor obtido não atinge 50% de equivalência com o desejado.

Já para os resultados que se mantiveram como cerrado, a expectativa é que fossem menores que as mudanças de interesse. Contudo, o retorno foi de um valor consideravelmente maior e com pouca equivalência, em relação ao desejado. Com esse valor adicionado ao todo, seria, provavelmente, impraticável a separação do que permaneceu cerrado e o que mudou de fato, sem um processo de classificação, ou um comparativo como neste caso.

As mudanças verdadeiras, em relação à totalidade de mudanças detectadas por esse método, foram muito baixas, representando apenas 10,29%, no cenário que apresentou o resultado mais próximo. Isso conclui que quase 90% das informações de resposta foram inutilizadas.

4.3. CONSIDERAÇÕES FINAIS

Neste capítulo foram apresentados os resultados numéricos, provenientes da aplicação do método de diferenciação de imagens através, do GEE, e qual o significado dos números obtidos. O próximo capítulo conclui este trabalho e apresenta possíveis trabalhos futuros.

CAPÍTULO 5

CONCLUSÃO E TRABALHOS FUTUROS

Os resultados obtidos neste trabalho mostraram-se úteis em certos aspectos, embora não tenham sido totalmente efetivos. Os métodos aqui apresentados e discutidos, formam uma base para a implementação de novos projetos. Uma gama de melhorias e ajustes podem ser feitos buscando um resultado mais satisfatório. O projeto é compartilhável via GEE e ficará disponível para futuros aprimoramentos.

Dentre os métodos de detecção de mudanças discutidos no Capítulo 3, foram utilizados dois deles, sendo o pós-classificação, apenas o comparativo para determinar a precisão do método de diferenciação. Porém, o processo de classificação não foi efetuado dentro do desenvolvimento deste projeto. Portanto, um dos possíveis trabalhos futuros inclui a aplicação do processo de classificação para a determinação das diferenças entre os anos, em um critério pós-classificatório.

Além disso, a diferenciação de imagens foi aplicada apenas em um conjunto de bandas. Outros conjuntos discutidos no Capítulo 3 podem ser explorados, em busca de uma redução das informações falso positivas. A utilização de outras bandas também pode afetar na determinação do limiar de mudanças, facilitando ou dificultando o processo.

A detecção de mudanças abrange um leque de metodologias, que podem ser aplicados individualmente ou em conjunto. Outras possibilidades de trabalhos incluem utilização de NDVI, classificação multidata, análise espectral das mudanças, dentre outros.

O fato de ser processado em nuvem foi um dos pontos altos do projeto. A análise de imagens por si só, é pesada, em termos de processamento. Apesar disso, todo o projeto desenvolvido foi executado em segundos. A aplicação de máscaras às imagens, permitindo a soma das bandas e, tendo o retorno apenas de pixels que podiam conter informações de interesse, também facilitou o processamento.

Apesar do resultado impreciso, a hipótese levantada no Capítulo 1 se mostrou verdadeira. A base comparativa do projeto segue todas as etapas que foram propostas, apesar da classificação não ter sido realizada dentro desse escopo, e válida a hipótese. Existem também meios viáveis para reduzir a imprecisão da metodologia, como, por exemplo, a classificação do resultado. Portanto, é sim possível a aplicação técnicas de detecção de mudanças, no mapeamento da vegetação do cerrado no Alto Paranaíba, utilizando ferramentas *online*, para a obtenção de resultados relevantes, visando possíveis pesquisas ambientais.

Por fim, como apresentado nos tópicos que compõem este trabalho, em vista da decorrente necessidade de monitoramento do ambiente em geral, novas técnicas computacionais vêm sendo aprimoradas em busca de resultados confiáveis, assim como as novas ferramentas caminham para um maior poder de processamento. Com essa visão, este trabalho promove a aplicação de técnicas já conhecidas, no tópico de sensoriamento remoto, aliado ao processamento em nuvem, provido pela Google, com a finalidade de obter resultados confiáveis e replicáveis, no âmbito de mapeamentos vegetais.

5.1. CONSIDERAÇÕES FINAIS

Este capítulo finaliza o presente trabalho, destacando como os componentes apresentados no decorrer do corpo textual justificam e objetificam a execução do projeto em questão.

REFERÊNCIAS

- AERO. Mapeamento e Topografia, 20 abr. 2021. Disponível em: <<https://aeroengenharia.com/sensoriamento-remoto-no-brasil-e-as-novas-perspectivas/>>. Acesso em: 31 maio 2022.
- BELTRAME, E.; BITTENCOURT, H. R.; JANSEN, S. L. Uma proposta para a detecção de mudanças pós-classificação. **Anais XIV Simpósio Brasileiro de Sensoriamento Remoto**, Natal, 25-30 abr. 2009. 1261-1266.
- BUTLER, K. Band Combinations for Landsat 8. **esri: ArcGIS blog**, 2013. Disponível em: <<https://www.esri.com/arcgis-blog/products/product/imagery/band-combinations-for-landsat-8/?rmedium=redirect&rsource=blogs.esri.com/esri/arcgis/2013/07/24/band-combinations-for-landsat-8>>. Acesso em: 29 nov. 2022.
- CANADA CENTRE FOR REMOTE SENSING. **Fundamentals of Remote Sensing: A** Canada Centre for Remote Sensing Tutorial. Ottawa: Natural Resources Canada, [S.D.].
- DRUMMOND, J. Minas Geras lança mapa de fiscalização para o ano de 2017. **Peservar: Consultoria Ambiental**, 2017. Disponível em: <<http://www.preservambiental.com.br/noticia/minas-gerais-lanca-mapa-de-fiscalizacao-para-o-ano-de-2017/70>>. Acesso em: 29 jun. 2022.
- ESRI. ArcGis Pro: Stretch Function. **esri**. Disponível em: <<https://pro.arcgis.com/en/pro-app/latest/help/analysis/raster-functions/stretch-function.htm#>>. Acesso em: mai. 2023.
- GERMANO, A. D. et al. Comparação de métodos detecção de mudança no uso e cobertura da terra. **Anais XX Simpósio Brasileiro de Sensoriamento Remoto**, Florianópolis, 2-5 abr. 2023. 1570-1573.
- GISGEOGRAPHY. What is NDVI (Normalized Difference Vegetation Index)? **GISGeography**, 2022. Disponível em: <<https://gisgeography.com/ndvi-normalized-difference-vegetation-index/>>. Acesso em: dez. 2022.
- GOOGLE. Earth Engine Data Catalog, 2017. Disponível em: <<https://developers.google.com/earth-engine/datasets>>. Acesso em: 06 junho 2022.
- GOOGLE. Code Editor. **Google Earth Engine**, 2022. Disponível em: <<https://code.earthengine.google.com/>>. Acesso em: dez. 2022.
- GOOGLE. Image Visualization. **Google Earth Engine**. Disponível em: <https://developers.google.com/earth-engine/guides/image_visualization>. Acesso em: 23 mai. 2023.

- GOOGLE. Landsat Collections. **Earth Engine Data Catalog**. Disponível em: <<https://developers.google.com/earth-engine/datasets/catalog/landsat>>. Acesso em: mai. 2023.
- GOOGLE. USGS Landsat 8 Level 2, Collection 2, Tier 1. **Earth Engine Data Catalog**. Disponível em: <https://developers.google.com/earth-engine/datasets/catalog/LANDSAT_LC08_C02_T1_L2>. Acesso em: mai. 2023.
- GORELICK, N. et al. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, 2017. Disponível em: <<https://developers.google.com/earth-engine>>. Acesso em: 06 Junho 2022.
- GRUMMAN JUNIOR, D. A. Como funciona o olho humano? **Hospital da Visão Santa Catarina**, [S.D.]. Disponível em: <<https://www.hospitalvisaosc.com.br/artigo/11/como-funciona-o-olho-humano->>. Acesso em: 15 jun. 2022.
- JENSEN, J. R. **Sensoriamento Remoto do Ambiente**: Uma perspectiva em recursos terrestres. São José dos Campos: Parêntese, 2009.
- JONES, H. G.; VAUGHAM, R. A. **Remote Sensing of Vegetation**: Principles, Techniques, and Applications. Nova York: Oxford University Press Ink., 2010.
- JOSEPH, G. **Fundamentals of Remote Sensing**. 2^a. ed. Delhi: Universities Press (India) Private Limited, 2005.
- LANDSAT 8. Landsat 8. **NASA**: Landsat Science, [S.D.]. Disponível em: <<https://landsat.gsfc.nasa.gov/satellites/landsat-8/>>. Acesso em: 29 nov. 2022.
- LANDSAT MISSIONS. Landsat Collection 1, [S.D.]. Disponível em: <<https://www.usgs.gov/landsat-missions/landsat-collection-1>>. Acesso em: 13 jun. 2022.
- LANDSAT MISSIONS. Landsat 8, [S.D.]. Disponível em: <<https://www.usgs.gov/landsat-missions/landsat-8>>. Acesso em: 13 Junho 2022.
- LANDSAT MISSIONS. Common Landsat Band Combinations. **USGS**: science for a changing world, 2021. Disponível em: <<https://www.usgs.gov/media/images/common-landsat-band-combinations>>. Acesso em: 29 nov. 2022.
- LANDSAT MISSIONS. Landsat Collection 2 Quality Assessment Bands. **USGS science for a changing world**. Disponível em: <<https://www.usgs.gov/landsat-missions/landsat-collection-2-quality-assessment-bands>>. Acesso em: 02 jun. 2023.
- LIMA, J. Avanço da agropecuária reduz biodiversidade no Cerrado e na Amazônia, 23 Fevereiro 2022. Disponível em: <<https://observatorio3setor.org.br/noticias/avanco-da-agropecuaria-reduz-biodiversidade-no-cerrado-e-na-amazonia/#:~:text=O%20avan%C3%A7o%20da%20agropecu%C3%A1ria%2C%20princip>>

alimento%20para%20a%20produ%C3%A7%C3%A3o,anf%C3%ADbios%2C%20118%20m am%C3%ADferos%2>. Acesso em: 13 junho 2022.

LIRA, M. R. D. Ondas Eletromagnéticas, [S.D.]. Disponível em: <<https://www.coladaweb.com/fisica/ondas/ondas-eletromagneticas>>. Acesso em: 16 maio 2022.

MAPBIOMAS. Downloads. **MAPBIOMAS**, 2019. Disponível em: <<https://mapbiomas.org/download>>. Acesso em: 23 mai. 2023.

MAPBIOMAS. **MapBiomass General “Handbook”**: Algorithm Theoretical Basis Document (ATBD) Collection 7. [S.l.]: [s.n.], v. 1, 2022.

MATHER, P. M. **Computer Processing of Remotely-Sensed Images: An Introduction**. [S.l.]: John Wiley & Sons, Ltd, 2004.

MATOS, F. D. D. A.; DA SILVA, K. E. Detecção de mudanças na cobertura vegetal na cidade de Manaus e seu entorno. **Anais XII Simpósio Brasileiro de Sensoriamento Remoto**, Goiânia, 16-21 Abril 2005. 609-616.

MATOS, F. D. D. A.; SILVA, K. E. D. Detecção de mudanças na cobertura vegetal na cidade de Manaus e seu entorno. **Anais XII Simpósio Brasileiro de Sensoriamento Remoto**, Goiânia, GO, 16-25 abr. 2005. 609-616.

MENDES, F. D. S. et al. Optical and SAR Remote Sensing Synergism for Mapping Vegetation Types in the Endangered Cerrado/Amazon Ecotone of Nova Mutum—Mato Grosso. **Remote Sensing**, 15 mai. 2019.

NEGRI, R. G.; FRER, A. C. A general and extensible framework for assessing change detection techniques. **Computers and Geosciences**, 2023.

OLIVEIRA, M. T. D. et al. Mapeamento da Vegetação do Cerrado – Uma Revisão das Iniciativas de. **Revista Brasileira de Cartografia**, v. 72, n. Especial 50 anos, p. 1250-1274, nov. 2020. ISSN ISSN 1808-0936 | <https://doi.org/10.14393/revbrascartogr>.

PEDRINI, H.; SCHWARTZ, W. R. **Análise de imagens digitais: princípios, algoritmos e aplicações**. São Paulo: Cengage Learning, 2008.

PONZONI, F. J.; SHIMAKUBURO, Y. E. **Sensoriamento Remoto no Estudo da Vegetação**. São José dos Campos : Arêntese, 2009.

RIBEIRO, J. F.; WALTER, B. M. T. Capítulo 6: As Principais Fitofisionomias do Bioma Cerrado. In: _____ **Cerrado: Ecologia e Flora**. Brasília: Embrapa, 2008. p. 152-212.

ROSA, R. **Introdução ao Sensoriamento Remoto**. 7ª. ed. Uberlândia: EDUFU, 2009.

SANO, S. M.; ALMEIDA, S. P. D.; RIBEIRO, J. F. **Cerrado: Ecologia e Flora**. Brasília: Embrapa Infomação Tecnológica, v. 1, 2008.

SINGH, A. (. Review Article Digital change detection techniques using remotely-sensed data. **International Journal of Remote Sensing**, v. 10, n. 6, p. 989-1003, 2010.

SOUZA, C. M. E. A. Reconstructing Three Decades of Land Use and Land Cover Changes in Brazilian Biomes with Landsat Archive and Earth Engine. **Remote Sensing**, v. 12, p. 2735, 2020.

STEFFEN, C. A. INTRODUÇÃO AO SENSORIAMENTO REMOTO. **INPE**, 2006? Disponível em: <<http://www3.inpe.br/unidades/cep/atividadescep/educasere/apostila.htm>>. Acesso em: 16 maio 2022.

SWANSEY, E. What are SWIR, MWIR, and LWIR – And what do they mean? **Dronegenuity**, [S.D.]. Disponível em: <<https://www.dronegenuity.com/what-are-swir-mwir-and-lwir-and-what-do-they-mean/>>. Acesso em: 06 jun. 2023.

USGS. What is remote sensing and what is it used for?, [S.D.]. Disponível em: <<https://www.usgs.gov/faqs/what-remote-sensing-and-what-it-used>>. Acesso em: 13 junho 2022.

WHAT-WHEN-HOW. Point Processing (Introduction to Video and Image Processing) Part 2. **what-when-how**: In Depth Tutorials and Information, [S. D.]. Disponível em: <<http://what-when-how.com/introduction-to-video-and-image-processing/point-processing-introduction-to-video-and-image-processing-part-2/>>. Acesso em: mai. 2023.

WORLD OF ITECH. Landsat 8 Bands Combinations. **Worldofitech**: World of Information Technology, 2019. Disponível em: <<https://www.worldofitech.com/landsat-8-bands-combinations/>>. Acesso em: 29 nov. 2022.