

UNIVERSIDADE FEDERAL DE MINAS GERAIS
Instituto de Geociências
Programa de Pós-Graduação em Análise e Modelagem de Sistemas Ambientais

Cristiano Ferreira de Oliveira

**ANÁLISE DA EVOLUÇÃO DO DESMATAMENTO NO BIOMA CERRADO NO
ESTADO DE MINAS GERAIS UTILIZANDO SISTEMAS DE DETECÇÃO E
IMAGENS ORBITAIS GRATUITAS**

Belo Horizonte

2023

Cristiano Ferreira de Oliveira

**ANÁLISE DA EVOLUÇÃO DO DESMATAMENTO NO BIOMA CERRADO NO
ESTADO DE MINAS GERAIS UTILIZANDO SISTEMAS DE DETECÇÃO E
IMAGENS ORBITAIS GRATUITAS**

Dissertação apresentada ao Programa de Pós-Graduação em Análise e Modelagem de Sistemas Ambientais da Universidade Federal de Minas Gerais, como requisito parcial para obtenção do título de Mestre.

Orientador: Dr. Marcelo Antônio Nero

Belo Horizonte

2023

O48a
2023

Oliveira, Cristiano Ferreira de.

Análise da evolução do desmatamento no bioma Cerrado no estado de Minas Gerais utilizando sistemas de detecção e imagens orbitais gratuitas [manuscrito] / Cristiano Ferreira de Oliveira. – 2023.

90 f., enc. il. (principalmente color.)

Orientador: Marcelo Antônio Nero.

Dissertação (mestrado) – Universidade Federal de Minas Gerais, Instituto de Geociências, 2023.

Bibliografia: f. 68-78.

Inclui apêndices.

1. Modelagem de dados – Aspectos ambientais – Teses. 2. Sensoriamento remoto – Teses. 3. Cerrados – Teses. 4. Desmatamento – Teses. 5. Perícia ambiental – Teses. 6. Imagens de sensoriamento remoto – Teses. 7. Aprendizado do computador – Teses. I. Nero, Marcelo Antônio. II. Universidade Federal de Minas Gerais. Instituto de Geociências. III. Título.

CDU: 911.2:519.6(815.1)



UNIVERSIDADE FEDERAL DE MINAS GERAIS
INSTITUTO DE GEOCIÊNCIAS
COLEGIADO DE PÓS-GRADUAÇÃO DO PROGRAMA EM ANÁLISE E MODELAGEM DE SISTEMAS AMBIENTAIS

FOLHA DE APROVAÇÃO

ANÁLISE DA EVOLUÇÃO DO DESMATAMENTO NO BIOMA CERRADO NO ESTADO DE MINAS GERAIS UTILIZANDO SISTEMAS DE DETECÇÃO E IMAGENS ORBITAIS GRATUITAS

CRISTIANO FERREIRA DE OLIVEIRA

Dissertação de Mestrado defendida e aprovada, em 25 de agosto de 2023, pela Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Análise e Modelagem de Sistemas Ambientais da Universidade Federal de Minas Gerais constituída pelos seguintes professores:

Marcelo Antônio Nero (Orientador) - UFMG - (Doutor)

Marco Antônio Timbó Elmiro - UFMG - (Doutor)

João Rodrigues Tavares Junior - Universidade Federal de Pernambuco - (Doutor)

Belo Horizonte, 25 de agosto de 2023.



Documento assinado eletronicamente por João Rodrigues Tavares Junior, Usuário Externo, em 28/08/2023, às 09:50, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por Marcelo Antonio Nero, Professor do Magistério Superior, em 28/08/2023, às 10:52, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por Marcos Antonio Timbo Elmiro, Professor do Magistério Superior, em 28/08/2023, às 21:11, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufmg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador 2577396 e o código CRC 7BCFA4BD.

RESUMO

O Cerrado é considerado o segundo maior bioma do Brasil, abrangendo uma área de mais de 200 milhões de hectares em treze estados da Federação. Trata-se de uma área de grande importância para a biodiversidade da fauna e da flora brasileiras. No entanto, a transformação da sua vegetação tem sido acelerada nos últimos anos, principalmente, em função da necessidade da expansão de novas áreas para a produção agrícola e a formação de pastagens. No caso específico do Estado de Minas Gerais, o Bioma Cerrado ocupa mais de 54% do território e perpassa por regiões de grande importância para a produtividade agrícola. Diante disso, este trabalho propõe uma avaliação qualitativa do mapeamento temático em função da classificação supervisionada de imagens orbitais gratuitas (geradas pelo satélite brasileiro Amazônia-1), como uma estratégia viável para compreensão quanto à evolução nas mudanças do uso e cobertura do solo. Também são analisados os alertas de polígonos de desmatamento gerados pelo Sistema de Detecção de Desmatamentos em Tempo Real (DETER) do Instituto Nacional de Pesquisas Espaciais (INPE), bem como a aplicação de algoritmos e técnicas de aprendizado de máquina (*Machine Learning*, em inglês) que podem garantir a disponibilização dessas informações com maior celeridade e confiabilidade. Os resultados alcançados com o processamento das imagens demonstraram uma grande viabilidade para o emprego das metodologias utilizadas.

Palavras-chave: sensoriamento remoto; cerrado; desmatamento; fiscalização ambiental; geoprocessamento; imagens orbitais gratuitas; aprendizado de máquina.

ABSTRACT

The Cerrado is considered the second largest biome in Brazil, covering an area of more than 200 million hectares in thirteen states of the Federation. This is an area of great importance for the biodiversity of Brazilian fauna and flora. However, the transformation of its vegetation has been accelerated in recent years, mainly due to the need to expand new areas for agricultural production and the formation of pastures. In the specific case of the State of Minas Gerais, the Cerrado Biome occupies more than 54% of the territory and runs through regions of great importance for agricultural productivity. Therefore, this work proposes a qualitative assessment of thematic mapping based on the supervised classification of free orbital images (generated by the Brazilian satellite Amazônia-1), as a viable strategy for understanding the evolution of land use and land cover changes. Deforestation polygon alerts generated by the Real Time Deforestation Detection System of the National Institute for Space Research are also analyzed, as well as the application of machine learning algorithms and techniques (Machine Learning) that can guarantee the availability of this information with greater speed and reliability. The results achieved with the processing of the images demonstrated a great viability for the use of the used methodologies.

Keywords: remote sensing; cerrado; deforestation; environmental inspection; geoprocessing; free orbital images; machine learning.

LISTA DE ILUSTRAÇÕES

Figura 1 - Área de estudo, localizada no bioma Cerrado	18
Figura 2 - Caracterização visual dos indivíduos arbóreos suprimidos.	19
Figura 3 - Fluxograma dos procedimentos realizados.....	20
Figura 4 – Comparação visual das imagens.	21
Figura 5 – Composição colorida das bandas das imagens.....	22
Figura 6 – Dados NDVI derivados das imagens de sensoriamento remoto.....	23
Figura 7 – Imagens na composição banda simples falsa-cor.....	24
Figura 8 – Imagens temporais mostrando a redução de vegetação nativa e a progressão do desmatamento.	25
Figura 9 - Avaliação temporal do desmatamento na Área de Estudo.....	30
Figura 10 - Distribuição do Bioma Cerrado.	34
Figura 11 -Esquema geral da metodologia.	36
Figura 12 – Polígonos DETER (2018 a 2022)	37
Figura 13 – Pontos de Fiscalização – Mapa de calor (2018 a 2022).....	37
Figura 14 – Composição NDVI (realce falsa cor) com imagem do Amazônia-1.....	39
Figura 15 – Polígonos detectados no município de João Pinheiro (Ago a Nov – 2022).....	43
Figura 16 - Distribuição do bioma cerrado no território brasileiro.	46
Figura 17 – Município de João Pinheiro (Minas Gerais).	49
Figura 18 – Análise e processamento das imagens	51
Figura 19 – Histograma da composição colorida	52
Figura 20 – Índices vegetativos de cada banda da imagem do Amazônia-1	57
Figura 21 – Resposta espectral das amostras de cada classe em função das bandas	58
Figura 22 – Classificação supervisionada da imagem gerada pelo Satélite Amazônia-1.....	59

LISTA DE TABELAS

Tabela 1 - Mensuração das áreas desmatadas (em hectares).....	28
Tabela 2 - Pontos definidos para aferição da qualidade temática.....	28
Tabela 3 - Matriz de confusão - Classificação da imagem - 28.05.21.....	29
Tabela 4 - Matriz de confusão - Classificação da imagem - 30.06.21.....	29
Tabela 5 - Matriz de confusão - Classificação da imagem - 31.07.21.....	29
Tabela 6 - Estatísticas gerais da classificação	29
Tabela 7 - Acurácia do produtor e usuário - Classificação da imagem	30
Tabela 8 - Desmatamentos detectados pelo DETER no cerrado de Minas Gerais (2018-2022)	40
Tabela 9 – Ranking de municípios com maiores áreas e detecções (2018-2022).	40
Tabela 10 – Amostras definidas para análise da acurácia temática na imagem obtida com o classificador RF do complemento SCP.	54
Tabela 11 – Amostras definidas para análise da acurácia temática na imagem obtida com o classificador RF por meio do algoritmo de Linguagem R.	55
Tabela 12 - Matriz de confusão – Classificação Supervisionada (SCP)	60
Tabela 13 - Matriz de confusão – Classificação Supervisionada (Linguagem R)	61
Tabela 14 – Acurácia do usuário e do produtor.....	61
Tabela 15 - Matriz de confusão – Classificação Supervisionada (Algoritmo em Linguagem R)..	62
Tabela 16 – Acurácia do usuário e do produtor	63
Tabela 17 – Avaliação dos parâmetros da acurácia temática e desempenho	63

LISTA DE QUADROS

Quadro 1 - Modelo da matriz de erro (4 x 4) utilizada para a aferição da acurácia temática...	26
Quadro 2 - Níveis de exatidão de uma classificação, conforme o valor de índice Kappa.	27
Quadro 3 - Níveis de exatidão de uma classificação, conforme índice Kappa.	48
Quadro 4 – Especificações técnicas do satélite Amazônia-1	50
Quadro 5 – Amostras de treinamento selecionadas para a classificação supervisionada.....	52
Quadro 6 - Modelo da matriz de erro (4 x 4) para a acurácia temática.....	55
Quadro 7 – Método de análise e interpretação das amostras	64
Quadro 8 – Observações analisadas por meio da interpretação visual das amostras.....	64

LISTA DE GRÁFICOS

Gráfico 1 – Evolução do desmatamento em municípios do cerrado de Minas Gerais.....	41
Gráfico 2 – Representação das métricas das áreas classificadas na imagem do Amazônia-1	60

SUMÁRIO

1 INTRODUÇÃO	11
2 OBJETIVOS	13
2.1 Objetivo geral	13
2.2 Objetivos específicos	13
3 JUSTIFICATIVA.....	13
4 ESTRUTURAÇÃO.....	14
5 GEOPROCESSAMENTO E BASE DE DADOS OPEN SOURCE PARA A DETECÇÃO E MONITORAMENTO DE DESMATAMENTOS NA FISCALIZAÇÃO AMBIENTAL	16
5.1 Introdução.....	16
5.2 Material e métodos	18
5.2.1 Área de estudo	18
5.2.2 Material.....	19
5.2.3 Métodos	19
5.2.3.1 Imagens Planet.....	19
5.2.3.2 Procedimentos	20
5.2.3.3 Comparação visual	21
5.2.3.4 Composição colorida RGB432	22
5.2.3.5 Composição NDVI	23
5.2.3.6 Realce da banda simples falsa-cor.....	24
5.2.3.7 Classificação supervisionada (complemento DZETSAKA)	24
5.2.3.8 Avaliação da acurácia temática.....	25
5.3 Resultados.....	27
5.3.1 Mensuração das áreas desmatadas.....	27
5.3.2 Qualidade temática	28
5.3.3 Avaliação temporal do desmatamento	30
5.4 Conclusão	31
6 ANÁLISE DA EVOLUÇÃO DO DESMATAMENTO NO BIOMA CERRADO DO ESTADO DE MINAS GERAIS UTILIZANDO O SISTEMA DETER E IMAGENS DO SATÉLITE AMAZÔNIA-1.....	32
6.1 Introdução.....	32
6.2 Área de estudo	33

6.3 Material e métodos	34
6.3.1 Material.....	34
6.3.1.1 Polígonos de desmatamento	34
6.3.1.2 Pontos de fiscalização.....	35
6.3.1.3 Imagens orbitais.....	35
6.3.1.4 Análise e geoprocessamento	35
6.4 Métodos e procedimentos.....	36
6.4.1 Polígonos DETER e pontos de fiscalização	36
6.4.2 Composição NDVI	38
6.5 Resultados.....	39
6.6 Conclusão	43
7 ANÁLISE COMPARATIVA DA CLASSIFICAÇÃO DE IMAGENS DO CERRADO DE MINAS GERAIS GERADAS PELO SATÉLITE BRASILEIRO AMAZÔNIA-1 COM EMPREGO DO MÉTODO RANDOM FOREST E PROGRAMAÇÃO EM R (MACHINE LEARNING).....	45
7.1 Introdução.....	45
7.2 Metodologia.....	48
7.2.1 Área de estudo	48
7.2.2 Imagens orbitais.....	49
7.2.3 Análise e processamento das imagens	50
7.2.4 Classificação supervisionada.....	51
7.2.5 Acurácia temática (classificação supervisionada)	53
7.2.6 Acurácia temática calculada com Linguagem R.....	56
7.3 Resultados.....	58
7.3.4 Classificação comparativa realizada com algoritmo em Linguagem R (RStudio).....	62
7.4 Conclusão	65
8 CONSIDERAÇÕES FINAIS.....	67
REFERÊNCIAS	68
APÊNDICE A.....	79
APÊNDICE B.....	83
APÊNDICE C	87

1 INTRODUÇÃO

O Cerrado é considerado o segundo maior bioma do Brasil, com uma área total de aproximadamente 2.036.448 km² (IBF, s.d.), ou seja, mais de 200 milhões de hectares que correspondem a aproximadamente 22% de todo o território. Sua cobertura vegetal compreende basicamente três principais fisionomias: as formações florestais (espécies arbóreas de dossel contínuo ou não), as savânicas (árvores e arbustos espalhados em um estrato gramíneo, sem dossel contínuo) e as campestres (onde predominam as espécies herbáceas e arbustivas). Esta última, caracterizada pela ausência de árvores (RIBEIRO; WALTER, 2008).

Não obstante, a transformação da vegetação do cerrado nos últimos anos tem sido muito evidenciada, principalmente nas áreas situadas em regiões de expansão agrícola. De acordo com Klink e Machado (2005), a agricultura no Cerrado é lucrativa e sua expansão acontece em ritmo acelerado. As taxas de desmatamento desse bioma têm sido historicamente superiores às da floresta Amazônica, sendo que, o esforço de conservação é muito inferior. Apenas 2,2% da área do Cerrado encontra-se legalmente protegida (KLINK; MACHADO, 2005).

O Brasil, por sua vez, é um dos principais produtores mundiais de commodities agrícolas, o que incentiva a demanda crescente por novas áreas cultiváveis, principalmente àquelas inseridas no bioma Cerrado (MUELLER; MARTHA JUNIOR, 2008). Segundo Andrade et al. (2016) cerca de 53 milhões de hectares do Cerrado estão destinados às pastagens cultivadas, correspondendo à 55% da produção de carne bovina do país. A partir de cenários gerados, foi constatado que 80% da área de pastagens plantadas degradadas do bioma está concentrada somente nos estados de Goiás, Mato Grosso, Mato Grosso do Sul e Minas Gerais (ANDRADE et al., 2016).

No caso do Estado de Minas Gerais, o Cerrado abrange uma área total de 54% do território, situada na sua porção centro-ocidental. Assim como nos demais estados, a vegetação também sofre grande vulnerabilidade em função do desmatamento e dos incêndios florestais.

Diante da grande área que representa, o uso de técnicas de sensoriamento remoto (e geotecnologias) para o monitoramento do bioma Cerrado apresenta-se como uma importante estratégia para o monitoramento e a preservação ambiental. Nesse sentido, podem-se destacar os trabalhos desenvolvidos por Viana (2012) (na utilização de imagens ALOS-Palsar), Barroso, Sano e Freitas (2018) (utilização de Sensoriamento Remoto e técnicas de *Normalized Difference Vegetation Index*, em inglês, ou NDVI), Maciel, Alves e Sant'Anna (2021) (onde estes incluem a utilização de imagens de satélite de sensoriamento remoto na análise dos

processos de desmatamento e regeneração de unidades de conservação do Vale do Ribeira), Lopes, Nóbrega e Macedo (2022) (realizaram análise multitemporal com emprego de dados de sensoriamento por meio de imagens Landsat).

No entanto, tradicionalmente as pesquisas realizadas nesse campo exigem custos financeiros consideráveis. Portanto, este trabalho pretende analisar quanto à viabilidade da utilização, tanto de programas abertos do tipo FOSS (*Free Open-Source Software*-Programas de utilização sem custo e abertos), como demonstrado em GVSIG Asociación (2014), Calamito (2017), OSGeo (2019), Graziuso et al. (2022), bem como de bases de dados disponibilizadas gratuitamente (como por exemplo, as imagens orbitais do Satélite Amazônia-1).

Diante disso, este trabalho apresenta o mapeamento gerado pelo Sistema de Detecção de Desmatamento em Tempo Real (DETER) como principal fonte de dados de alertas de alteração na cobertura florestal do Bioma Cerrado. Assim, é importante ressaltar que esses dados têm sido utilizados para as estratégias de fiscalização e controle do desmatamento.

Não obstante, para apuração dessas informações foram selecionadas e recortadas imagens gratuitas (como por exemplo, as geradas pelo Satélite Amazônia-1, recentemente lançado no ano de 2021). Os arquivos *raster* de interesse foram extraídos na página do catálogo de imagens do Instituto Nacional de Pesquisas Espaciais (INPE). Lançado em 28 de fevereiro de 2021, o Amazônia-1 é o primeiro satélite estabilizado em 3 eixos, desenvolvido no Brasil e que utiliza uma câmera Imageadora de Campo Largo (*Wide Field Imaging*, em inglês, ou WFI) que captura imagens em 6 níveis.

As imagens selecionadas foram submetidas ao processo de classificação supervisionada, com o método classificador *Random Forest*, por meio do complemento *Semi-Automatic Classification Plugin* (SCP) e também por um algoritmo construído em Linguagem R. Para determinar a qualidade das informações obtidas com o processamento das imagens, foram coletadas amostras que possibilitaram calcular os índices de acurácia e identificar o processamento mais eficiente.

2 OBJETIVOS

2.1 Objetivo geral

O objetivo deste trabalho é avaliar a viabilidade da utilização do Sistema de Detecção (DETER) e imagens orbitais gratuitas (Amazônia-1) para análise da evolução do desmatamento no Bioma Cerrado, aplicando técnicas de geoprocessamento e avaliação da acurácia temática, que possam demonstrar a confiabilidade e a celeridade das informações geradas.

2.2 Objetivos específicos

Para alcançar essa proposta, foram delineados os seguintes objetivos específicos:

- I. Descrever as principais técnicas de geoprocessamento; fontes de dados de código aberto (*open source*, em inglês) para detecção e monitoramento de desmatamentos, com potencial aplicação na fiscalização ambiental; bem como os métodos mais consolidados para avaliação da acurácia temática em processos de classificação de imagens;
- II. Analisar a evolução do desmatamento no Bioma Cerrado do Estado de Minas Gerais a partir dos polígonos gerados pelo Sistema DETER e apresentar as imagens gratuitas disponibilizadas pelo Satélite Amazônia-1 como uma ferramenta eficaz para avaliação de conformidade dessas informações;
- III. Avaliar a qualidade temática das informações geradas a partir do processamento das imagens gratuitas utilizadas, por meio de uma abordagem metodológica técnica para comparação de dados estatísticos e representação gráfica.

3 JUSTIFICATIVA

O monitoramento de áreas desmatadas utilizando técnicas de sensoriamento remoto, depende de diversos fatores, afinal a supressão da vegetação é um tipo de intervenção com características dinâmicas que dificultam a resposta imediata dos órgãos de fiscalização ambiental.

São algumas dessas razões: a extensão das áreas (que demanda imagens de melhor resolução espacial), a rapidez com que são realizadas as destocas (com retirada de raiz, implicando na demanda por uma boa resolução temporal), a senescência foliar da vegetação, os acessos difíceis, dentre outras.

Diante desses aspectos, a fiscalização ainda tem recorrido frequentemente ao reconhecimento de campo, tanto para quantificar a supressão da vegetação, quanto para estimar o rendimento lenhoso decorrente de tais intervenções.

Assim, verifica-se a existência de uma grande demanda para desenvolvimento e aprimoramento de técnicas e ferramentas tecnológicas (eficientes e confiáveis) para análise de dados espaciais, a fim de que possam otimizar o emprego dos escassos recursos humanos e logísticos disponíveis para esse enfrentamento.

Nesse contexto, pode-se considerar que a utilização de dados disponibilizados gratuitamente (como é o caso das imagens orbitais que serão estudadas) tem se tornado cada vez mais recorrente. Por se tratar de fontes abertas, podem apresentar algumas restrições quanto às resoluções espacial e a temporal.

Não obstante, é preciso avaliar se tais imagens podem viabilizar uma análise mais robusta acerca das intervenções ambientais, principalmente nas supressões de vegetação.

4 ESTRUTURAÇÃO

O presente trabalho está organizado na forma de artigos científicos que foram preparados para o envio a revistas científicas com boa classificação no *Qualis* da CAPES mais recente e divulgado oficialmente para a área de ciências ambientais, conforme segue:

ARTIGO 1 - GEOPROCESSAMENTO E BASE DE DADOS OPEN SOURCE PARA A DETECÇÃO E MONITORAMENTO DE DESMATAMENTOS NA FISCALIZAÇÃO AMBIENTAL: Tem como objetivo descrever as principais técnicas de geoprocessamento; fontes de dados *Open Source* para detecção e monitoramento de desmatamentos, com potencial aplicação na fiscalização ambiental, bem como os métodos mais consolidados para avaliação da acurácia temática em processos de classificação de imagens.

ARTIGO 2 - ANÁLISE DA EVOLUÇÃO DO DESMATAMENTO NO BIOMA CERRADO DO ESTADO DE MINAS GERAIS UTILIZANDO O SISTEMA DETER E

IMAGENS DO SATÉLITE AMAZÔNIA-1: Tem como objetivo analisar a evolução do desmatamento no Bioma Cerrado do Estado de Minas Gerais a partir dos polígonos gerados pelo Sistema DETER e apresentar as imagens gratuitas disponibilizadas pelo Satélite Amazônia-1 como uma ferramenta eficaz para avaliação de conformidade dessas informações.

ARTIGO 3 - ANÁLISE COMPARATIVA DA CLASSIFICAÇÃO DE IMAGENS DO CERRADO DE MINAS GERAIS GERADAS PELO SATÉLITE BRASILEIRO AMAZÔNIA-1 COM EMPREGO DO MÉTODO RANDOM FOREST E PROGRAMAÇÃO EM R (MACHINE LEARNING): Visa analisar comparativamente a qualidade temática da classificação supervisionada de imagens do Bioma Cerrado de Minas Gerais geradas pelo satélite brasileiro Amazônia-1, com emprego do classificador Random Forest implementado no complemento SCP (instalado no QGIS) e por meio de programação em Linguagem R (*Machine Learning*).

5 GEOPROCESSAMENTO E BASE DE DADOS OPEN SOURCE PARA A DETECÇÃO E MONITORAMENTO DE DESMATAMENTOS NA FISCALIZAÇÃO AMBIENTAL

5.1 Introdução

De acordo com Ribeiro e Walter (2008) o Cerrado é o segundo maior bioma do território brasileiro, sendo superado apenas pela Floresta Amazônica. Abrange extensas áreas, ampliando sua vulnerabilidade quanto ao desmatamento, bem como queimadas, favorecidas pela fitofisionomia típica constituída predominantemente por arbustos e pequenas árvores esparsas. Em razão disso, algumas estratégias importantes têm sido mais empregadas pela fiscalização ambiental, tais como as aplicações com emprego de recursos do sensoriamento remoto, que têm tido grande destaque na identificação da supressão de vegetação nativa e dos incêndios florestais, possibilitando ações preventivas e repressivas com maior efetividade.

Estudos abordando essas intervenções exemplificadas, têm sido explorados em diversos trabalhos, tais como os de Oliveira e Nero (2012a, 2012b, 2013), Oliveira (2013), Souza et al. (2016), Anderson et al. (2017), Fragal e Gasparetto (2017), Leite et al. (2017), Nhongo et al. (2017), Oliveira et al. (2017a), Oliveira et al. (2017b), Rosan e Vedovato (2017), Salazar Latorre, Aragão e Anderson (2017), Salmona, Paiva e Matricardi (2017), Santos et al. (2017), Barroso, Sano e Freitas (2018), Fernandes et al. (2018), Fernandes et al. (2018a, 2018b), Moraes et al. (2018), Oliveira e Venturieri (2018), Paiva e Baptista (2018), Fernandes (2019), Conceição, Chaves e Mataveli (2020), Fernandes et al. (2020), Oliveira et al. (2020), Sano, Matricardi e Camargo (2020), Maciel, Alves e Sant'Anna (2021), Nero et al. (2021), Camargo et al. (2022), Lacerda et al. (2022), Rocha e Nascimento (2022), Tan e Feng (2023), Sinha et al. (2023), Trucchia et al. (2023), entre outros, o que evidencia a importância dessa área de pesquisa.

Oliveira (2013) e Oliveira et al. (2017b) desenvolveram um trabalho voltado para a predição de incêndios, de modo a preveni-los, tendo-se como área teste o Município de João Pessoa-PB, Brasil abrangendo as áreas rural e urbana do município. Os trabalhos citados utilizaram técnicas de análises multivariada, abordadas em Chuvieco e Congalton (1989), Chuvieco, et al. (1999, 2010), Chuvieco, Allgower e Salas (2010), e Ribeiro et al. (2008), as quais não consideraram as sazonalidades, caracterizadas pelos períodos chuvosos e de estiagem. Oliveira (2013) e Oliveira et al. (2017b), empregaram também no mesmo estudo técnicas de lógica fuzzy associadas às sazonalidades presentes nos períodos de estiagem e de chuva, bem como as variações integradas em todo o período, com base nas abordagens de Chuvieco, et al.

(2010) e Ribeiro et al. (2008). Os resultados produziram mapas temáticos de risco de incêndios que apontaram melhor qualidade temática quando associados a lógica fuzzy e considerando-se as sazonalidades. No processo de validação abordado em Oliveira (2013) e Oliveira et al. (2017b) foram analisados diferentes parâmetros de qualidade temática como os gráficos de espalhamento dos dados, o índice local de Moran, o p-value, a autocorrelação, o Teste do Qui-Quadrado, bem como o valor do R² e a sobreposição dos dados reais sobre os mapas temáticos de predição.

Já a pesquisa desenvolvida por Fernandes (2019) utilizou como área de estudo a Região Metropolitana de Belo Horizonte-MG, sendo aplicadas técnicas de redes neurais artificiais em conjunto com recursos de Geoprocessamento, para geração de mapas temáticos de predição de incêndio de periodicidade mensal. Os resultados submetidos ao teste p de Person para a validação temática foram considerados muito satisfatórios.

O monitoramento de áreas desmatadas utilizando recursos de sensoriamento remoto, por sua vez, requer fatores adicionais pois trata-se de um tipo de intervenção com características dinâmicas que dificultam a resposta imediata dos órgãos ambientais. Algumas dessas razões são: a extensão das áreas (que demanda imagens de melhor resolução espacial), a rapidez com que são realizadas as supressões (demanda por uma boa resolução temporal), a senescência foliar da vegetação, os acessos difíceis, dentre outras. Diante desses aspectos, a fiscalização ainda tem recorrido frequentemente ao reconhecimento de campo, tanto para quantificar a supressão da vegetação, quanto para estimar o rendimento lenhoso decorrente.

Diante desse contexto, percebe-se claramente uma grande demanda para desenvolvimento e aprimoramento de técnicas e ferramentas tecnológicas (eficientes e confiáveis) para análise de dados espaciais que possam otimizar o emprego dos escassos recursos humanos e logísticos disponíveis para esse enfrentamento. Com isso, a utilização das imagens disponibilizadas gratuitamente pela Iniciativa Internacional de Clima e Floresta da Noruega (NICFI¹, na sigla em inglês) através das plataformas *Planet Explorer*² e *Basemap Viewer*³, torna-se importante alternativa para subsidiar o desenvolvimento de novas pesquisas. Assim, este trabalho está integrado no contexto dessas demandas e para atingir seus objetivos a síntese teórica que abrange essa pesquisa, a área de estudo do experimento, o desenvolvimento prático, a análise dos resultados, bem como as considerações finais são apresentadas.

¹ <https://planet.com/nicfi/>

² <https://planet.com/explorer/>

³ <https://planet.com/basemaps/>


5.2 Material e métodos

5.2.1 Área de estudo

O polígono de desmatamento analisado neste estudo está situado no Oeste do Estado de Minas Gerais (Brasil), onde predomina a vegetação típica do bioma Cerrado. A área total delimitada possui aproximadamente 51 hectares com a presença de três diferentes classes de uso e cobertura da terra denominadas vegetação, desmatamento e solo.

A supressão de vegetação constatada ocorreu sem autorização dos órgãos ambientais competentes, razão pela qual a intervenção provocada resultou na aplicação de penalidades administrativas pela Polícia Militar de Meio Ambiente do Estado de Minas Gerais. No entanto, em cumprimento à Lei nº 13.709, de 14 de agosto de 2018 (Lei Geral de Proteção de Dados Pessoais – LGPD, Brasil, 2018), tanto o nome do município, quanto as informações específicas da propriedade (coordenadas geográficas) não podem ser divulgadas, sendo o local da infração genericamente denominado "Área de estudo", conforme descrito na Figura 1.

Figura 1 - Área de estudo, localizada no bioma Cerrado, com presença de árvores distribuídas em padrão aleatório, sem um dossel contínuo.




Fonte: Adaptado de Google Earth⁴ (2021)

O polígono delimitado neste estudo, trata-se de uma formação savânica cuja fitofisionomia principal é o cerrado sentido estrito (*strictu sensu*), em função da presença de estratos arbóreos e arbustivo-herbáceos distribuídos aleatoriamente em diferentes densidades, sem formação de um dossel contínuo.

⁴ <http://earth.google.com>

Figura 2 - Caracterização visual dos indivíduos arbóreos suprimidos.



Fonte: Comando de Policiamento de Meio Ambiente da Polícia Militar de Minas Gerais (2021).

Um dos Autos de Infração em relação ao desmatamento ilegal constatado, foi lavrado pela Polícia Militar de Meio Ambiente no dia 01 de julho de 2021 e descreveu o corte de 76 árvores esparsas na área, sem a retirada do material. Conforme verifica-se na Figura 2, durante a fiscalização foram avaliadas as características dos indivíduos arbóreos derrubados a fim de se determinar o estágio sucessional da vegetação.

5.2.2 Material

Para elaboração do trabalho foram utilizados os seguintes recursos: a) três imagens orbitais (georreferenciadas) de épocas distintas da Área de Estudo, inserida no Bioma Cerrado; b) software QGIS versão "3.16.5 Hannover" (QGIS, 2021) com o complemento "GRASS 7.8.5" instalado; c) complemento para análise de acurácia AcATaMa (Llano, 2019); d) instalado no QGIS para classificação de dados de sensoriamento remoto Dzetsaka (Karasiak, 2016).

5.2.3 Métodos

5.2.3.1 Imagens Planet

As imagens orbitais utilizadas nesta pesquisa abrangem dados dos dias 28 de maio, 30 de junho e 31 de julho de 2021, obtidas através das plataformas "*Planet Explorer*" e "*Basemap Viewer*" (NICFI) para monitoramento das mudanças em florestas tropicais, disponibilizados gratuitamente (mediante cadastro na plataforma). Especificações técnicas: área de varredura para regiões tropicais globais, resolução espacial: 4,77 m, resolução espectral visual R, G, B (3-bandas), análise-ready R, G, B, NIR (4-bandas), resolução temporal abrangendo dezembro de 2015, agosto de 2020 (Bianual) e monitoramento (setembro de 2020 adiante) e mensalmente.

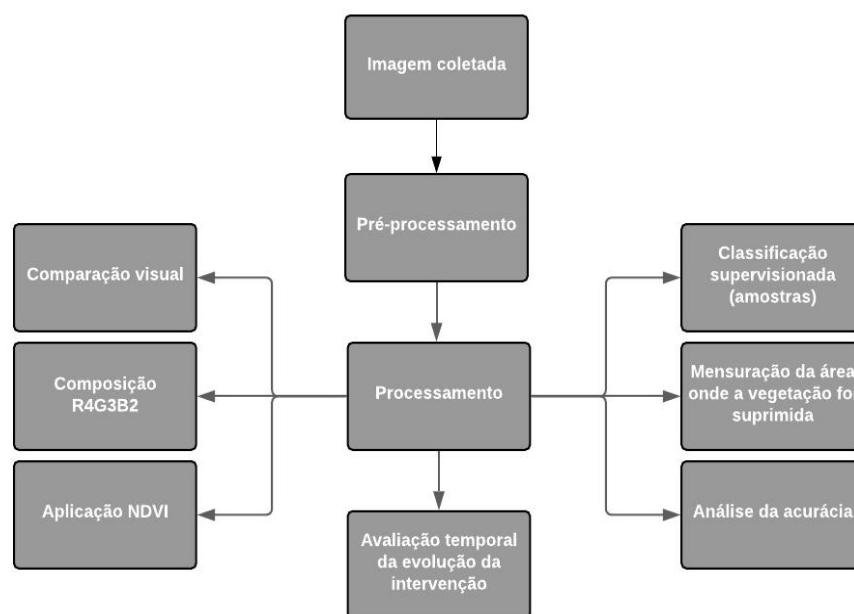
5.2.3.2 Procedimentos

Para o desenvolvimento do estudo foram estabelecidas três etapas que consistem no pré-processamento, processamento e a avaliação temporal quanto à evolução da intervenção, conforme fluxograma descrito na Figura 3.

Na fase de pré-processamento, foram selecionadas as cenas com o menor percentual de cobertura de nuvens no período (mensal) disponíveis na plataforma. Através de procedimentos computacionais do QGIS (QGIS, 2021), as imagens orbitais escolhidas foram recortadas, delimitando-se apenas o perímetro da área onde ocorreu a supressão.

Na etapa de processamento, as imagens foram analisadas de três formas distintas: visualmente (evolução da intervenção), em composição colorida das bandas para RGB432 (realce de florestas) e para o índice NDVI (*Normalized Difference Vegetation Index* – Índice de Vegetação da Diferença Normalizada), utilizado para destacar o vigor da vegetação. A renderização das bandas das imagens NDVI foi alterada para o estilo banda simples falsa-cor, com gradiente de cores espectrais de 5 classes. Em seguida, foi realizada a classificação supervisionada nas 3 imagens com o complemento Dzetsaka (KARASIAK, 2016) pelo classificador GMM (*Gaussian Mixture Model*) ou Modelo de Mistura Gaussiana. Assim, em cada imagem foram coletadas 30 amostras de treinamento (10 para cada classe), de modo que nesta etapa foi possível reconhecer as áreas de vegetação, desmate e solo exposto.

Figura 3 - Fluxograma dos procedimentos realizados.



Fonte: Os autores (2021).

Para avaliação da qualidade temática, foi utilizado o complemento AcATaMa (LLANO, 2019). Através do método estatístico de amostragem estratificada por classes, com 292 pontos aleatoriamente distribuídos, que foram analisados por interpretação visual usando a imagem orbital e a imagem classificada. Esse procedimento possibilitou a obtenção da matriz de confusão, a Acurácia Global e o Índice Kappa.

Finalmente, os resultados obtidos foram analisados para compreender a evolução temporal da intervenção ambiental.


5.2.3.3 Comparação visual

As três imagens utilizadas neste estudo foram coletadas em períodos distintos, cobrindo o mesmo polígono de desmatamento. Através da análise visual, verificou-se que a supressão dos indivíduos arbóreos ocorreu de forma seletiva e superficial (técnica conhecida como corte raso), ou seja, não houve a imediata remoção (destoca) das raízes junto ao solo. Tal intervenção (corte raso), em que ainda pode ocorrer o escoamento do material ou a sua incorporação ao solo, tem sido uma prática recorrente dentre os infratores ambientais para dificultar o reconhecimento da vegetação suprimida e a mensuração do respectivo rendimento lenhoso. Portanto, a comparação visual das imagens (Figura 4) em relação às intervenções provocadas possibilitou uma melhor compreensão quanto à evolução do desmatamento na área de estudo, permitindo definir uma estratégia mais adequada para emprego da técnica de classificação.

Figura 4 – Comparação visual das imagens.



(28 de maio de 2021)



(30 de junho de 2021)



(31 de julho de 2021)


Fonte: Os autores (2021)

Para identificação e quantificação das informações relativas à alteração do uso do solo, foi realizado o procedimento de classificação supervisionada das imagens com o complemento (plugin) denominado Dzetsaka (KARASIAK, 2016), instalado no programa QGIS (QGIS, 2021). Previamente, foi criada uma camada vetorial contendo 10 pequenos polígonos de contornos das amostras para cada tipo de classe de cobertura definida.

5.2.3.4 Composição colorida RGB432

Para melhor visualização das diferentes feições da superfície foi realizado um procedimento de composição colorida das imagens (Figura 5), ajustando as bandas para os canais RGB: a banda 4 com o RED (vermelho), a banda 3 com o GREEN (verde) e a banda 2 com o BLUE (azul).

Figura 5 – Composição colorida das bandas das imagens.



(28 de maio de 2021)

(30 de junho de 2021)

(31 de julho de 2021)

Fonte: Os autores (2021)

Como pode ser percebido na Figura 5, esse tipo de composição realça a vegetação e a copa das árvores com a cor vermelha, sendo identificado na última imagem coletada (31/07/2021) a possível realização de queimada na área de estudo - destaque dado por uma cor escura.


5.2.3.5 Composição NDVI

O NDVI⁵ é um índice espectral que destaca a resposta espectral da vegetação, sendo calculado pela diferença entre a banda do infravermelho próximo e a banda do vermelho, dividida pela soma de ambas as bandas. Este índice é muito utilizado para demonstrar a diferença entre plantas (sob estresse hídrico, o estágio do ciclo de vida, além de outros estratos da vegetação) e outros elementos como corpos de água e solo exposto⁶. Seu valor varia de -1 a 1, sendo que quanto maior o valor, melhor é a resposta espectral e, portanto, maior a atividade fotossintética da vegetação. Aplicações do NDVI são descritas em muitos estudos como os de Pereira e Tavares Júnior (2017), Moraes et al. (2018), Cambraia Filho, Brites e Souza Bias (2020), este último utilizando imagens de *Remotely Piloted Aircrafts* (RPAs). Assim, os dados de NDVI foram obtidos das bandas dos espectros infravermelho e vermelho, conforme descrito na Equação 1:


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

Para retratar a supressão de vegetação nessa área do Bioma Cerrado e o consequente aumento na exposição do solo, optou-se pela extração e análise dos dados NDVI, conforme Figura 6.


Figura 6 – Dados NDVI derivados das imagens de sensoriamento remoto.



(28 de maio de 2021)



(30 de junho de 2021)



(31 de julho de 2021)

Fonte: Os autores (2021)

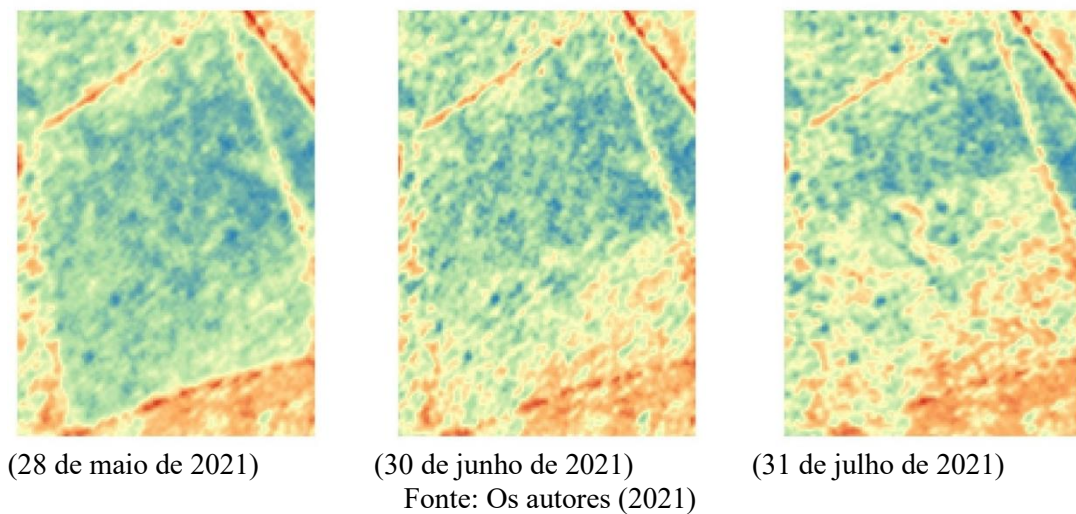
⁵ <https://www.indexdatabase.de/db/i-single.php?id=58>

⁶ <https://developers.planet.com/tutorials/calculate-ndvi/>

5.2.3.6 Realce da banda simples falsa-cor

Para proporcionar uma melhor visualização da resposta espectral da vegetação, os dados NDVI derivados das imagens foram fatiados em cinco classes de intervalos iguais, conforme Figura 7. Essa representação favoreceu o reconhecimento da vegetação presente decorrente da maior atividade fotossintética, bem como realçou as áreas de solo exposto.

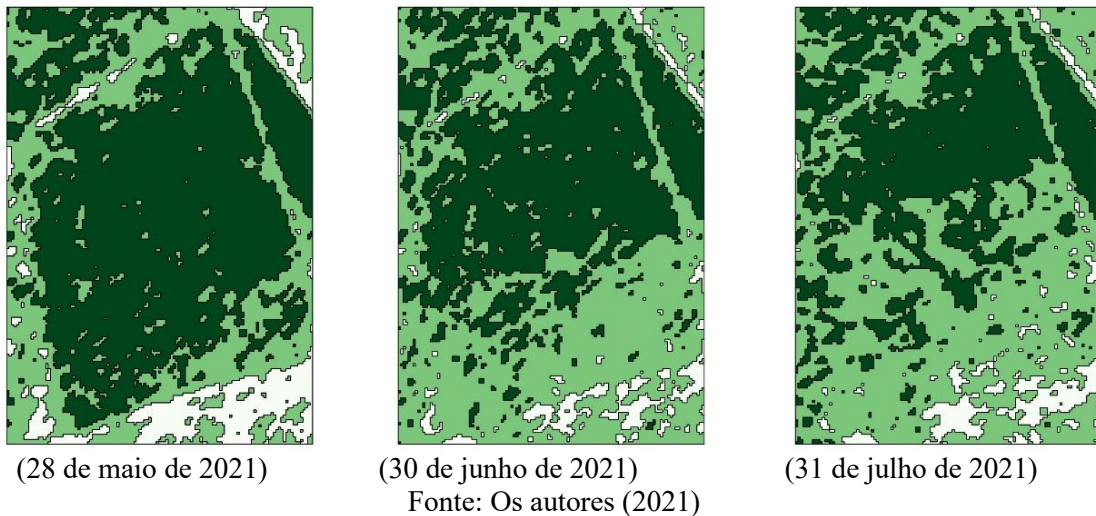
Figura 7 – Imagens na composição banda simples falsa-cor.



5.2.3.7 Classificação supervisionada (complemento DZETSAKA)

Para realização da classificação supervisionada das imagens, foi escolhido o complemento (plugin) Dzetsaka, desenvolvido por Kasariak (2016) e que utiliza o algoritmo do Modelo de Mistura Gaussiana. Os resultados demonstraram uma redução significativa da vegetação nativa (verde escuro) e um aumento do desmatamento (verde claro), conforme apresentado na Figura 8.

Figura 8 – Imagens temporais mostrando a redução de vegetação nativa e a progressão do desmatamento.



5.2.3.8 Avaliação da acurácia temática

No presente trabalho foram utilizados apenas programas computacionais de uso livre/gratuito, denominados programas de códigos abertos (FOSS - *Free Open Source Software* – Programas de Código Aberto) de interesse especial para a utilização da comunidade científica (maiores detalhes em Calamito, 2017 e OSGeo, 2019). Tais programas incluem o GVSIG (GVSIG Asociación, 2014), bem como o QGIS (OSGeo, 2019) que foi utilizado nessa pesquisa. Ambos os programas são voltados para o ambiente de Sistemas de Informação Geográfica, possibilitando a manipulação de dados vetoriais e matriciais, bem como a integração e desenvolvimento de códigos em linguagens de programação comerciais ou livres.

Um exemplo de aplicativo é o plugin AcATaMa versão 19.11.21 (LLANO, 2019), o qual é empregado nessa pesquisa e executado no suporte do QGIS (QGIS, 2021). Este aplicativo permite a obtenção de amostragem aleatória ou proporcional por área, onde o usuário fornece o tamanho amostral (n , vide equação 2), obtido de acordo com a teoria estatística de amostragem independente, utilizando-se a formulação apresentada em See et. al. (2017) e Ariza-López (2002) (vide equação 2). Finalmente, confrontando as amostras obtidas com dados de referência representativos da verdade terrestre é gerada a matriz de confusão e o índice global de acurácia.

$$n = \frac{Z_{\alpha/2}^2 \cdot p \cdot q}{E^2} \quad \text{Equação (2)}$$

Onde:

p: probabilidade de acerto;

q: probabilidade de erro (1-p);

$Z_{\alpha/2}$: valor crítico correspondente ao nível de confiança desejado;

E: Limite de erro.

Após a obtenção do tamanho da amostra, a sua distribuição espacial e os dados da matriz de erros, se aplica a estatística Kappa que permite avaliar de forma comparativa a qualidade dos mapas obtidos por meio do sensoriamento remoto (LANDIS & KOCH, 1977). A matriz de erros utilizada para a aferição da acurácia temática foi construída segundo o modelo apresentado no Quadro 1, onde a linha representa os dados de referência e as colunas os dados do mapa de classificação. A partir desse mesma matriz de erros são obtidas as seguintes estatísticas: índice Kappa (Equação 3), exatidão global (Equação 4), as acurácias do produtor (Equação 5) e do usuário (Equação 6).

Quadro 1 - Modelo da matriz de erro (4 x 4) utilizada para a aferição da acurácia temática

Classes	A	B	C	D	Soma das Linhas
A	n11	n12	n13	n1k	n1+
B	n21	n22	n23	n2k	n2+
C	n31	n32	n33	n3k	n3+
D	n41	n42	n43	n4k	nK+
Soma das Colunas	n+1	n+2	n+3	n+K	n

Fonte: Adaptado de Congalton e Green (2009) e Santos (2010).

– Índice Kappa:
$$\frac{\sum_{i=1}^k n_{ii} - \sum_{i=1}^K n_{i+} + n_{+i}}{n^2 - \sum_{i=1}^K n_{i+} + n_{+i}}$$
 Equação (3)

– Exatidão Global:
$$\frac{\sum_{i=1}^k n_{ij}}{n}$$
 Equação (4)

– Acurácia do Produtor j:
$$\frac{n_{ij}}{n_{+j}}$$
 Equação (5)

– Acurácia do Usuário: $\frac{n_{ii}}{n_{i+}}$ Equação (6)

A qualidade da classificação, associada aos valores da estatística Kappa, pode ser avaliada conforme Fleiss, Cohen e Everitt (1969), Congalton e Green (2019) (baseado em Landis e Koch, 1977) e Monserud e Leemans, (1992), sendo demonstrada por Foody (2020) de acordo com o observado no Quadro 2.

Quadro 2 - Níveis de exatidão de uma classificação, conforme o valor de índice Kappa.

	Congalton e Green (2019)	Fleiss, Cohen e Everit (1969)	Monserud e Leemans (1992)	
Kappa	> 0,8 a 1,0	Quase Perfeito	Excelente	
	> 0,6 a 0,8		Substancial	Muito Bom
		> 0,4 a 0,8		Moderado
	> 0,2 a 0,4		Suficiente	
	> 0,0 a 0,2	Leve	Pobre	Pobre
	0,0	Pobre		Muito Pobre
				Nenhuma

Fonte: Adaptado (FOODY, 2020)

5.3 Resultados

5.3.1 Mensuração das áreas desmatadas

Para determinação da área desmatada a partir das três imagens classificadas, foi utilizada a função "Reporta camada raster de valor único" do QGIS (QGIS, 2021) que calcula

a área e a contagem de pixels gerados por classes. Os resultados de áreas obtidos para as três diferentes classes avaliadas são apresentados na Tabela 1.

Tabela 1 - Mensuração das áreas desmatadas (em hectares)

Classe	28.05.21	30.06.21	31.07.21
Vegetação	29,25	22,20	19,86
Desmate	16,74	26,21	27,92
Solo exposto	5,08	2,66	3,28
Total	51,07	51,07	51,07

Fonte: Os autores (2021)

5.3.2 Qualidade temática

Utilizou-se a Equação 2 para se definir o tamanho amostral mais adequado para avaliação da qualidade temática com uso do complemento AcATaMa, admitindo-se para as variáveis os valores de p : 0,95; q : 0,05; $Z_{\alpha/2}$: 1,96; e E : 0,025.

Assim, chegou-se ao total de 292 pontos amostrais, sendo que a divisão dos pontos em função de cada classe foi ajustada de acordo com o percentual de área correspondente, conforme apresentado na Tabela 2.

Tabela 2 - Pontos definidos para aferição da qualidade temática

Data da Imagem	Classe definida	Área (ha)	Área (%)	Número de Pontos
28.05.21	Vegetação	29,25	57,28	167
	Desmate	16,74	32,78	96
	Solo	5,08	9,94	29
30.06.21	Vegetação	22,20	43,47	127
	Desmate	26,21	51,32	150
	Solo	2,66	5,21	15
31.07.21	Vegetação	19,86	38,89	114
	Desmate	27,92	54,68	160
	Solo	3,28	6,43	19

Fonte: Os autores (2021)

Finalmente, para cada uma das três imagens classificadas foram construídas as respectivas matrizes de confusão, conforme resultados apresentados nas Tabelas 3, 4 e 5.

Tabela 3 - Matriz de confusão - Classificação da imagem - 28.05.21

Classe	Vegetação	Desmate	Solo	Total
Vegetação	160	7	0	167
Desmate	9	84	3	96
Solo	0	2	27	29
Total	169	93	30	292

Fonte: Os autores (2021)

Tabela 4 - Matriz de confusão - Classificação da imagem - 30.06.21

Classe	Vegetação	Desmate	Solo	Total
Vegetação	117	10	0	127
Desmate	10	127	13	150
Solo	0	5	10	15
Total	127	142	23	292

Fonte: Os autores (2021)

Tabela 5 - Matriz de confusão - Classificação da imagem - 31.07.21

Classe	Vegetação	Desmate	Solo	Total
Vegetação	23	2	1	26
Desmate	4	124	7	135
Solo	0	13	118	131
Total	27	139	126	292

Fonte: Os autores (2021)

Para cada uma das três imagens classificadas foi calculado o desempenho global da avaliação (fornecido pelo complemento AcATaMa) e o Índice Kappa (obtido a partir da Equação 3). Os resultados da acurácia obtidos foram muito satisfatórios e demonstraram um bom desempenho do processo utilizado, conforme apresentado na Tabela 6.

Tabela 6 - Estatísticas gerais da classificação

Imagem classificada	Desempenho global	Índice Kappa
28.05.21	92,82%	87,02%
30.06.21	86,97%	76,64%
31.07.21	90,94%	84,01%

Fonte: Os autores (2021)

As acurácias do produtor e do usuário, definidas nas Equações 5 e 6, também foram calculadas e são apresentadas na Tabela 7.

Tabela 7 - Acurácia do produtor e usuário - Classificação da imagem


Imagem	Exatidão	Vegetação	Desmate	Solo
28.05.21	Produtor	94,67%	90,32%	90%
	Usuário	95,80%	87,5%	93,10%
30.06.21	Produtor	92,12%	89,43%	43,48%
	Usuário	92,12%	84,67%	66,67%
31.07.21	Produtor	85,18%	89,21%	93,65%
	Usuário	88,46%	91,85%	90,08%

Fonte: Os autores (2021)

5.3.3 Avaliação temporal do desmatamento

O processamento das imagens orbitais coletadas possibilitou verificar que o desmatamento na Área de Estudo avançou significativamente no período de 28 de maio a 30 de junho, alcançando um percentual de 56,57% (equivalente a 26,21 hectares) da área total desmatada. No mesmo intervalo, o corte raso dos indivíduos arbóreos (prática utilizada pelos infratores para realizar a supressão) representou uma redução da vegetação nativa existente de 29,25 para 22,20 hectares. Em 01 de julho de 2021, ocorreu uma fiscalização realizada pelo Policiamento de Meio Ambiente no local do desmatamento, sendo constatada a derrubada de 76 árvores da vegetação nativa do Cerrado. No entanto, com auxílio do processamento das imagens foi possível verificar que, após essa data, houve uma provável paralisação das intervenções ambientais, uma vez que houve um decréscimo na taxa de desmatamento, conforme demonstrado no gráfico da Figura 9.

Figura 9 - Avaliação temporal do desmatamento na Área de Estudo.



Fonte: Os autores (2021)

Conforme demonstrado na Figura 6 (bandas RGB432), aparentemente houve queimada em uma porção da Área de Estudo, o que, na prática, pode representar um método alternativo de intervenção sem supressão direta da vegetação. Para efeitos da classificação supervisionada, essa alteração foi incluída na classe do desmatamento.

5.4 Conclusão

A utilização de imagens orbitais para avaliação de intervenções ambientais tem se caracterizado como uma importante estratégia para otimização do planejamento e resposta dos órgãos de fiscalização ambiental. No presente estudo, verificou-se que, tanto a resolução espacial quanto a temporal, são determinantes para esses tipos de análises, de modo que, quanto menor o intervalo de disponibilização das imagens, mais efetiva será a resposta contra os infratores ambientais. E, nesse sentido, as imagens disponibilizadas gratuitamente pela Iniciativa Internacional de Clima e Floresta da Noruega (NICFI), ainda que tenham uma temporalidade mensal e se restrinjam às florestas tropicais, podem se tornar uma importante ferramenta para o monitoramento e fiscalização de desmatamentos devido à qualidade das resoluções espacial e temporal.

Para validação dos processos e confiabilidade das informações processadas a partir dessas imagens, é indispensável aplicar procedimentos de avaliação da qualidade temática, para que as estatísticas de qualidade da classificação alcancem os resultados satisfatórios. Isso ficou provado nos resultados de qualidade obtidos da estimativa do índice Kappa. Podem ser aplicados outros índices de estimativa de qualidade, tal como o coeficiente de Pearson, análises de espalhamento de dados, além de outros disponíveis. Vale ressaltar ainda que os testes podem ser confrontados com imagens de melhor resolução espacial e de resolução temporal compatível, como é o caso das imagens de VANTs (Veículos Aéreos Não Tripulados), de modo a consolidar a metodologia aqui empregada.

6 ANÁLISE DA EVOLUÇÃO DO DESMATAMENTO NO BIOMA CERRADO DO ESTADO DE MINAS GERAIS UTILIZANDO O SISTEMA DETER E IMAGENS DO SATÉLITE AMAZÔNIA-1

6.1 Introdução

O bioma Cerrado é considerado o segundo maior bioma do Brasil, com uma área total de aproximadamente 2.036.448 km² (IBF, 2020), ou seja, mais de 200 milhões de hectares que correspondem a aproximadamente 22% de todo o território. Sua vegetação apresenta três fisionomias principais: as formações florestais, com presença de espécies arbóreas de dossel contínuo ou não; as savânicas, em que árvores e arbustos estão espalhados em um estrato gramíneo (sem dossel contínuo) e as campestres, onde predominam as espécies herbáceas e arbustivas, com ausência de árvores (RIBEIRO; WALTER, 2008).

No entanto, a transformação da vegetação do cerrado nos últimos anos tem sido muito evidenciada, principalmente nas áreas situadas em regiões de expansão agrícola. De acordo com Klink e Machado (2005), a agricultura no Cerrado é lucrativa e sua expansão acontece em ritmo acelerado. Nos últimos anos, as taxas de desmatamento desse bioma têm sido historicamente superiores às da floresta Amazônica, sendo que, o esforço de conservação é muito inferior. Apenas 2,2% da área do Cerrado encontra-se legalmente protegida (KLINK; MACHADO, 2005).

O Brasil é um dos principais produtores mundiais de commodities agrícolas, o que incentiva a demanda crescente por novas áreas cultiváveis, principalmente àquelas inseridas no bioma Cerrado (MUELLER; MARTHA JUNIOR, 2008), o que pode favorecer a degradação e o desmatamento nessa região.

Outro importante fator, conforme Andrade *et al.* (2016) é o fato de cerca de 53 milhões de hectares do Cerrado serem destinados às pastagens cultivadas, correspondendo à 55% da produção de carne bovina do país. A partir de cenários gerados, foi constatado que cerca de 80% da área de pastagens plantadas degradadas do deste bioma está concentrada somente nos estados de Goiás, Mato Grosso, Mato Grosso do Sul e Minas Gerais (ANDRADE *et al.*, 2016). Deve-se ressaltar que no caso do estado de Minas Gerais, o bioma Cerrado abrange uma área total de 54% do território, situada na porção centro-ocidental. Assim como na maioria dos demais estados, a vegetação também sofre grande vulnerabilidade em função do desmatamento e os incêndios florestais.

Diante da grande área que representa, o uso de técnicas de sensoriamento remoto (e

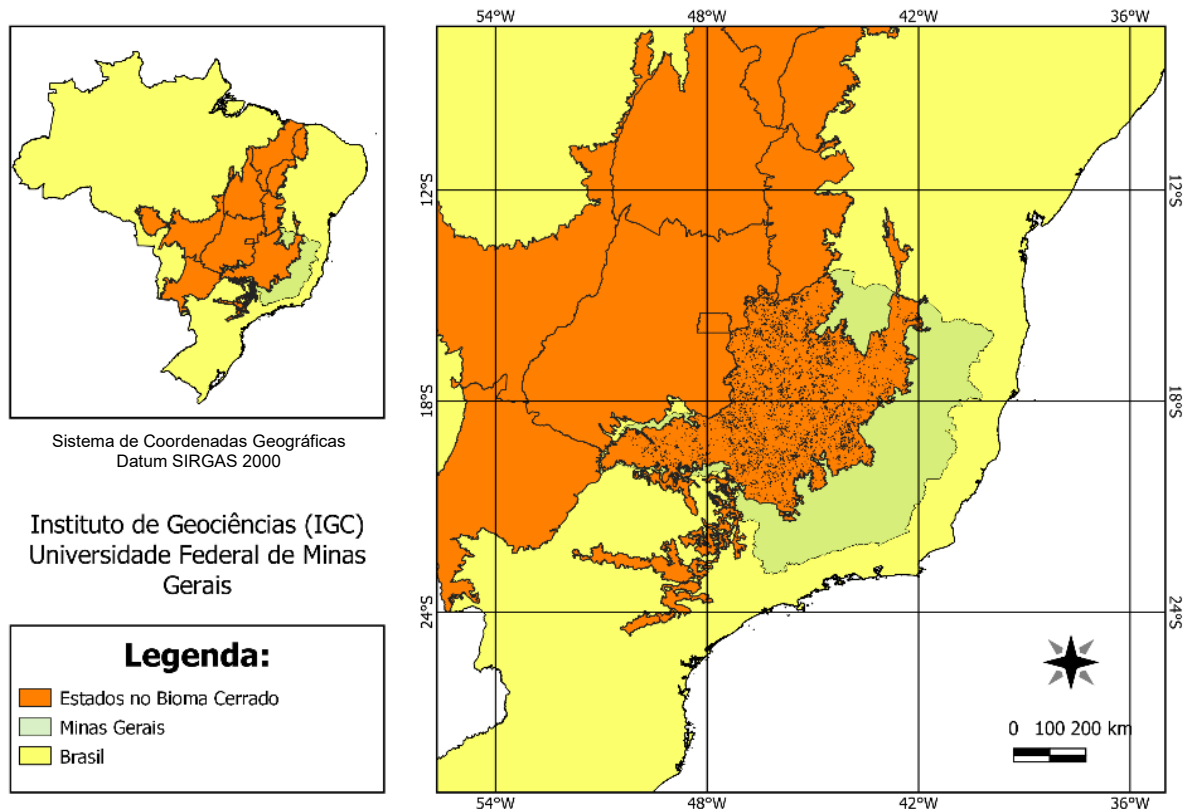
geotecnologias) para o monitoramento do bioma Cerrado tem sido uma importante estratégia para o monitoramento e a preservação ambiental. Nesse sentido, podemos destacar os trabalhos desenvolvidos por Viana (2012) (na utilização de imagens ALOS-Palsar), Barroso, Sano e Freitas (2018) (utilização de Sensoriamento Remoto e técnicas de NDVI), Maciel, Alves e Sant'Anna (2021) (onde estes incluem a utilização de imagens de satélite de sensoriamento remoto na análise dos processos de desmatamento e regeneração de unidades de conservação do Vale do Ribeira), Lopes, Nóbrega e Macedo (2022) (realizam análise multitemporal com emprego de dados de sensoriamento por meio de imagens Landsat), Maia et al. (2023) (estudam a recuperação de áreas degradadas por incêndio na Região do Pantanal). No entanto, tradicionalmente as pesquisas realizadas nesse campo exigem custos financeiros consideráveis. Assim, no presente artigo pretende-se demonstrar a viabilidade da utilização tanto de programas abertos do tipo FOSS (*Free Open-Source Software*, em inglês, ou Programas de Código Aberto Gratuitos), como demonstrado em GVSIG Asociación (2014), Calamito (2017), OSGeo (2019), Graziuso et al. (2022), Ogli e Murodilov (2023), bem como de bases de dados disponibilizadas gratuitamente.

Valendo-se desses conceitos apresentados e do apanhado bibliográfico abordado anteriormente, é que se justifica o presente artigo científico, o qual abrange a definição da área de estudo, materiais e métodos (incluindo a definição dos polígonos de desmatamento, dos pontos de fiscalização ambiental, obtenção das imagens orbitais gratuitas, análise via geoprocessamento), análise dos resultados por meio de abordagem histórica e gráficos comparativos e finalmente, as conclusões.

6.2 Área de estudo

O Bioma Cerrado tem abrangência territorial presente nos estados de Goiás, Tocantins, Distrito Federal, Bahia, Ceará Maranhão, Piauí, Mato Grosso, Mato Grosso do Sul, Minas Gerais, Paraná, Rondônia e São Paulo. Nesta pesquisa foi abordado o referido bioma no Estado de Minas Gerais, conforme descrito na Figura 10.

Figura 10 - Distribuição do Bioma Cerrado.



Fonte: Os autores (2023).

6.3 Material e métodos

6.3.1 Material

6.3.1.1 Polígonos de desmatamento

Os polígonos de desmatamento foram extraídos a partir das detecções (vetores) coletadas gratuitamente na plataforma Terra Brasilis⁷, disponibilizada pelo Instituto Nacional de Pesquisas Espaciais (INPE) através do Sistema de Detecção do Desmatamento em Tempo Real (DETER). Ressalta-se as abordagens de Teures e Castilho (2011) e de Diniz et al. (2015), em que os autores tratam dos dados do Sistema.

O programa DETER foi desenvolvido pelo Instituto Nacional de Pesquisas Espaciais (INPE) para geração de alertas de evidências quanto à alteração da cobertura vegetal. Inicialmente, destinado apenas à Amazônia, o sistema utiliza imagens dos sensores WFI, do satélite Satélite Sino-Brasileiro de Recursos Terrestres (CBERS-4), com resolução espacial de

⁷<http://terrabilis.dpi.inpe.br/>

64 metros e uma taxa de revisita de três dias conforme explica De Almeida et al. (2021). Com a utilização de imagens do satélite CBERS-4/PAN (banda da faixa do pancromático, resolução espacial de 5 m, com o emprego de 5 a 15 pontos de controle de campo), Akiyama et al. (2021) conseguiu gerar imagens com uma acurácia posicional bem confiável (entre 10 e 15 metros).

A partir de junho de 2022, as detecções do sistema DETER também passaram a ser obtidas com o satélite Amazônia-1 (utilizadas em recentes trabalhos, tais como em Barbosa, Ferreira e Júnior (2023), Silva e Loureiro (2023)), sendo que 180 polígonos analisados neste estudo foram coletados pelo novo sensor. O equipamento utiliza uma câmera WPI (Wide Field Imaging Camera) para capturar imagens em 6 níveis e é considerado o primeiro satélite com estabilização em 3 eixos totalmente desenvolvido no Brasil.

6.3.1.2 Pontos de fiscalização ambiental

Os dados referentes às fiscalizações ambientais, por sua vez, foram coletados diretamente na plataforma IDESISEMA⁸, disponibilizada na Internet pela Secretaria de Estado de Meio Ambiente (SEMAD) do Estado de Minas Gerais.

6.3.1.3 Imagens orbitais

As imagens orbitais (raster) foram geradas pelo Amazônia-1, as quais foram utilizadas recentemente também por Barbosa, Ferreira e Júnior (2023), Silva e Loureiro (2023), tendo sido extraídas na página do catálogo de imagens do INPE⁹. As imagens utilizadas foram somente as de Nível 4 (L4) ortorretificadas, ou seja, aquelas disponibilizadas com correção radiométrica e correção geométrica de sistema, com uso de pontos de controle e modelo digital de elevação do terreno (INPE, 2021).

6.3.1.4 Análise e geoprocessamento

Os arquivos (vetoriais e raster) gerados foram processados utilizando o programa QGIS versão "3.16.5 Hannover" (QGIS, 2021). Os gráficos e análises foram obtidos com uso do programa Microsoft Excel 365 (2021).

⁸<https://idesisema.meioambiente.mg.gov.br/webgis>

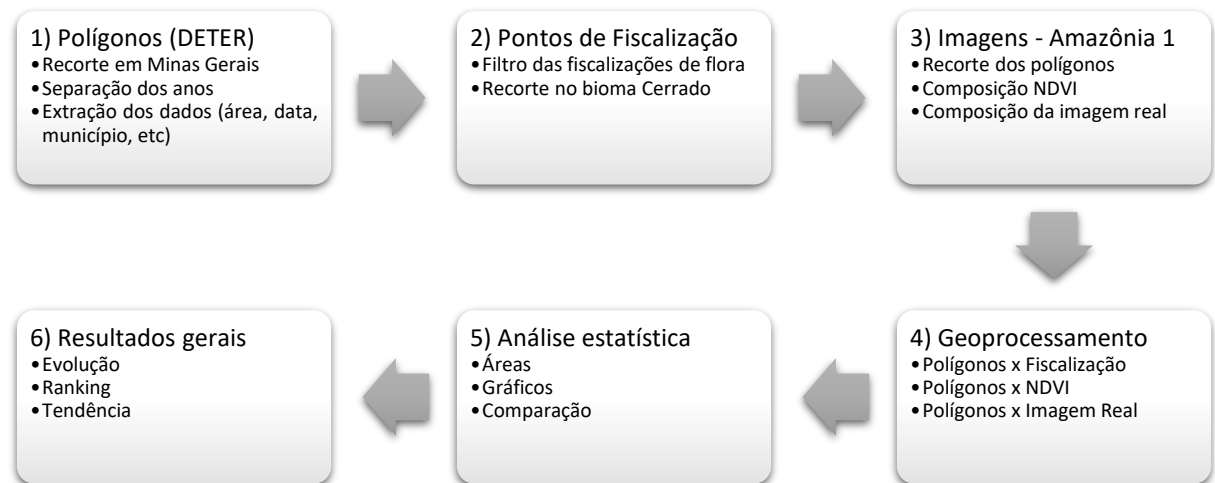
⁹<http://www2.dgi.inpe.br/catalogo/explore>

6.4 Métodos e procedimentos

Para delimitação cronológica, foi estipulado um período de cinco anos para análise da evolução dos desmatamentos no bioma Cerrado de Minas Gerais, compreendendo, portanto, os anos de 2018, 2019, 2020, 2021 e 2022. Esse período coincide com a disponibilidade de informações existentes na plataforma de Infraestrutura de Dados Espaciais (IDESISEMA).

Para obtenção dos resultados pretendidos neste estudo, foram realizados os procedimentos descritos na Figura 11.

Figura 11 -Esquema geral da metodologia.

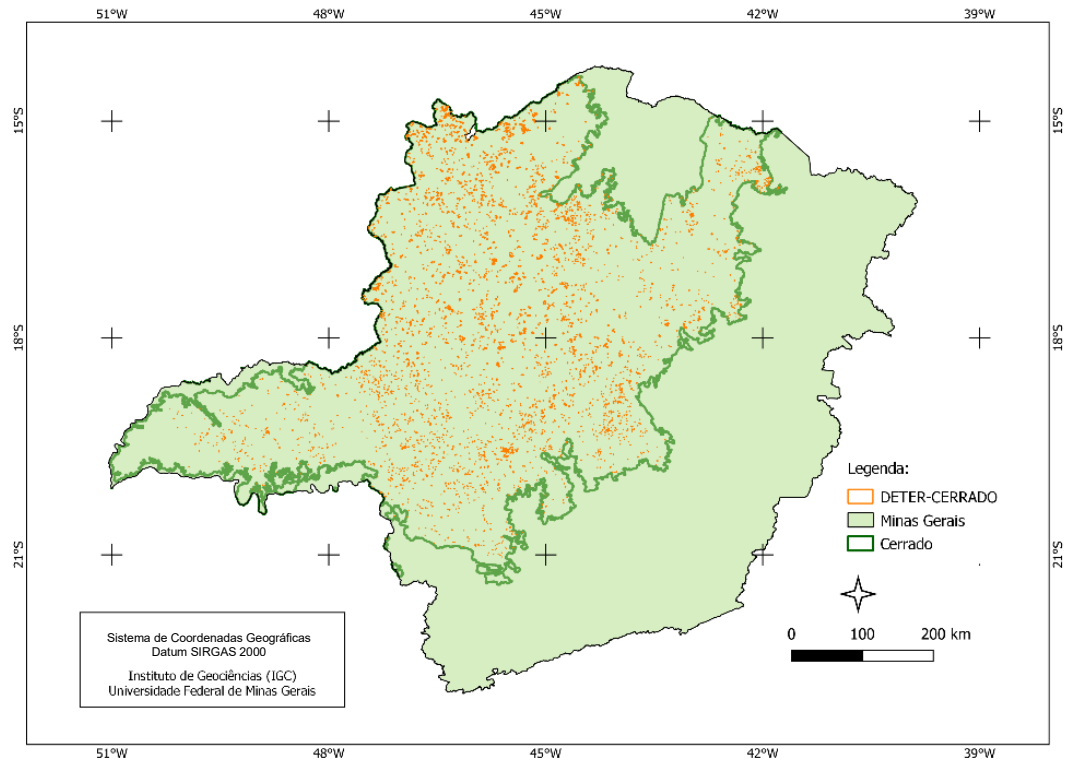


Fonte: Os autores (2023).

6.4.1 Polígonos DETER e pontos de fiscalização

Os polígonos de alerta (DETER) e os pontos referentes à fiscalização do período de 2018 a 2023, na vegetação do Cerrado em Minas Gerais, foram extraídos e recortados conforme apresentado nas Figuras 12 e 13.

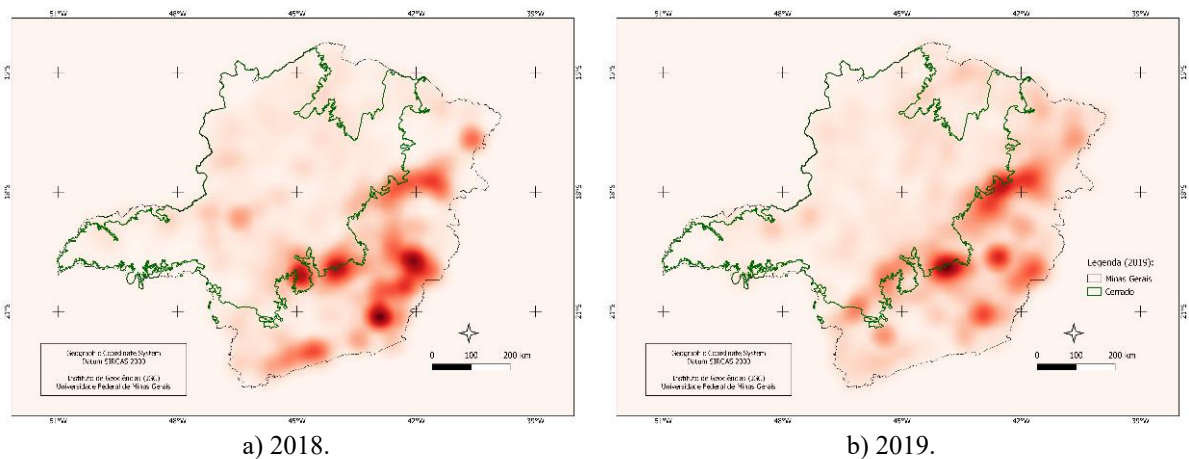
Figura 12 – Polígonos DETER (2018 a 2022)

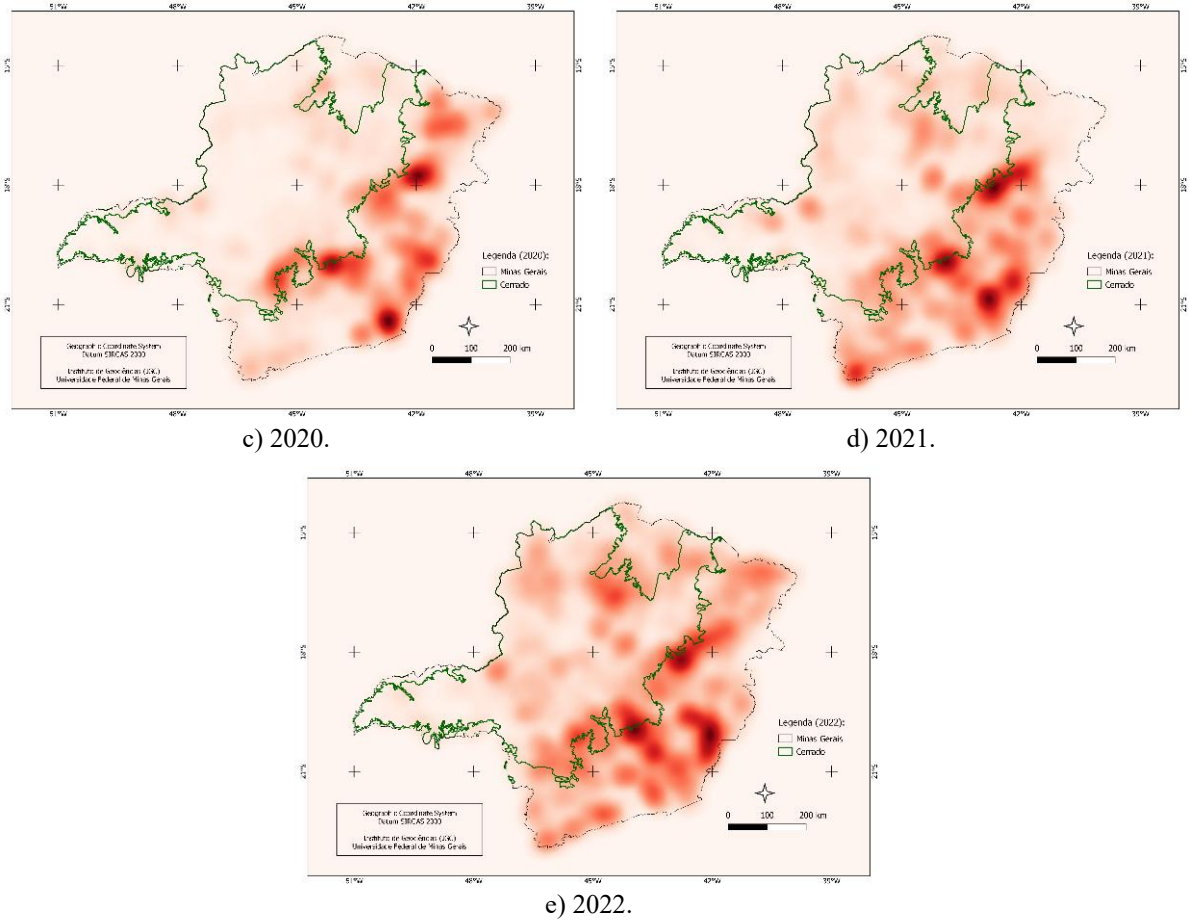


Fonte: Os autores (2023).

Para uma melhor visualização e compreensão acerca da evolução das fiscalizações, os pontos foram convertidos e apresentados em forma de mapa de calor.

Figura 13 – Pontos de Fiscalização – Mapa de calor (2018 a 2022)





Fonte: Os autores (2023).

6.4.2 Composição NDVI

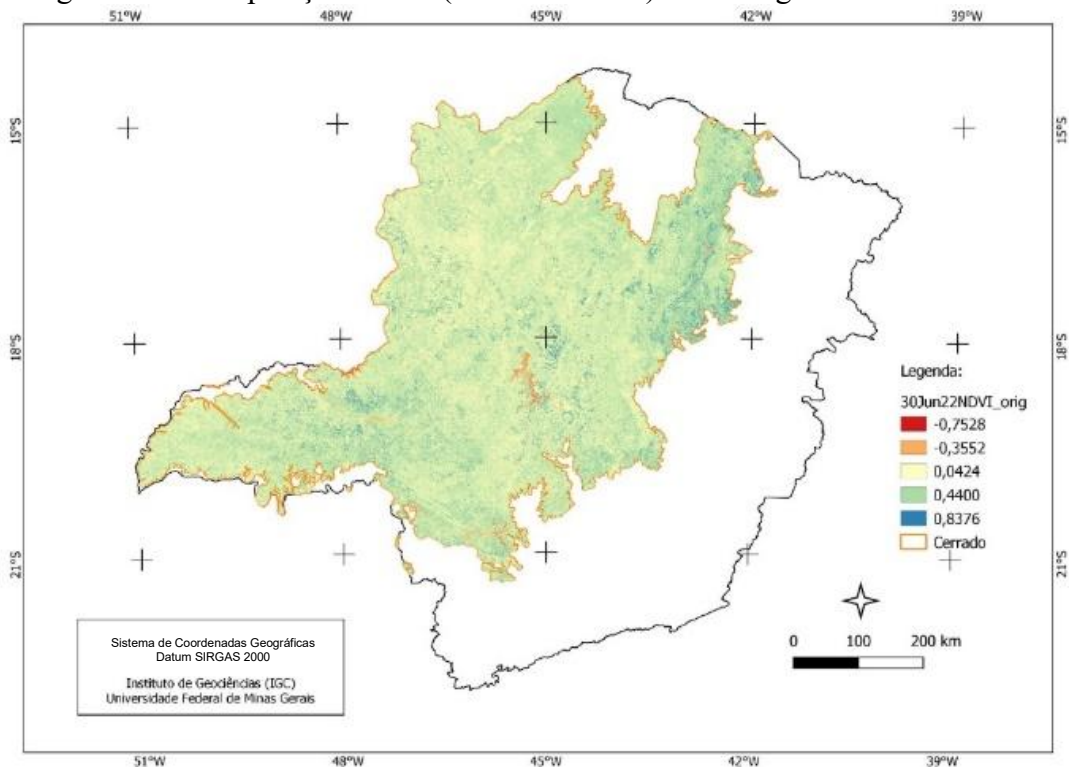
O NDVI (*Normalized Difference Vegetation Index*) é um índice que corresponde à resposta espectral da vegetação, sendo calculado pela diferença da banda do infravermelho próximo e a banda vermelha normalizada, dividida pela soma de ambas as bandas. Este índice é muito utilizado para demonstrar a diferença entre plantas (sob estresse hídrico, o estágio do ciclo de vida, etc) e outros elementos como o solo exposto. Varia de -1 a 1, sendo que quanto maior o contraste, melhor é a resposta espectral, portanto, a representatividade da atividade fotossintética. Aplicações com utilização do NDVI são descritas nos estudos de Pereira e Tavares Júnior (2017), Barroso, Sano e Freitas (2018), Moraes et al. (2018), Cambraia Filho, Brites e Souza Bias (2020), Mabunda et al. (2021), Silva Júnior et al (2021), Herrmann, Nascimento e Freitas (2022), Maia et al. (2023).

As imagens foram obtidas através da manipulação das bandas do infravermelho e vermelho das imagens do satélite Amazônia-1, conforme descrito na Equação 7:

$$NDVI = \frac{\rho_{NIR} - \rho_{Red}}{\rho_{NIR} + \rho_{Red}} \quad \text{Equação (7)}$$

Considerando que as imagens retratam polígonos de supressão de vegetação em uma área do Bioma Cerrado e a respectivo aumento na exposição do solo, também foi representada em uma composição NDVI conforme Figura 14.

Figura 14 – Composição NDVI (realce falsa cor) com imagem do Amazônia-1.



Fonte: Os autores (2023).

6.5 Resultados

Os mapas gerados permitiram analisar quantitativamente quanto à evolução do desmatamento no bioma Cerrado no Estado de Minas Gerais, entre os anos de 2018 e 2022, conforme representado na Tabela 8. Ao todo foram detectados 6.100 polígonos de desmatamento no período, que correspondem a uma área total de 1.607,02 hectares (ha), com média de 0,26 hectares por detecção.

Tabela 8 - Desmatamentos detectados pelo DETER no cerrado de Minas Gerais (2018-2022)

Ano	Detecções	Área (ha)	Média (ha)	Menor (ha)	Município	Maior (ha)	Município
2018	2243	441,42	0,20	$6,67 \times 10^{-5}$	Luz	4,23	Buritizeiro
2019	1484	350,32	0,24	$1,67 \times 10^{-7}$	Formoso	7,91	João Pinheiro
2020	861	236,69	0,27	$2,15 \times 10^{-7}$	Felixlândia	7,34	Bonito de Minas
2021	904	321,60	0,36	$1,19 \times 10^{-5}$	Itapeçerica	8,55	Senador Modestino Gonçalves
2022	608	256,96	0,42	$2,21 \times 10^{-4}$	Araçuaí	7,16	Formoso
Total	6.100	1.606,02	0,26	-	-	-	-

Fonte: Os autores (2023)

No ano de 2018 ocorreu o maior número de desmatamentos numa área total de 441,42 ha (um total de 2.243 polígonos), contra 350,32 ha em 2019 (1.484 detecções), 236,69 ha em 2020 (861), 321,60 ha em 2021 (904) e 256,96 ha em 2022 (608). Isso permite afirmar que houve uma redução significativa no número de intervenções ambientais ao longo do período, com aumento apenas no período 2020 a 2021. Quanto ao tamanho dos polígonos, verificou-se que a maior área (8,55 ha) foi detectada no município de Senador Modestino Gonçalves, em 2021, enquanto a menor ($2,15 \times 10^{-7}$ ha) ocorreu em Felixlândia, no ano de 2020.

No intuito de avaliar os municípios com a maior quantidade de polígonos e área desmatada ao longo no período de 2018 a 2022, foram ranqueados os quatro primeiros, conforme apresentado na Tabela 9. Destaca-se que o município de João Pinheiro apresentou o maior número total de detecções (243) e, também, a maior área total desmatada com 108,96 ha.

Tabela 9 – Ranking de municípios com maiores áreas e detecções (2018-2022).

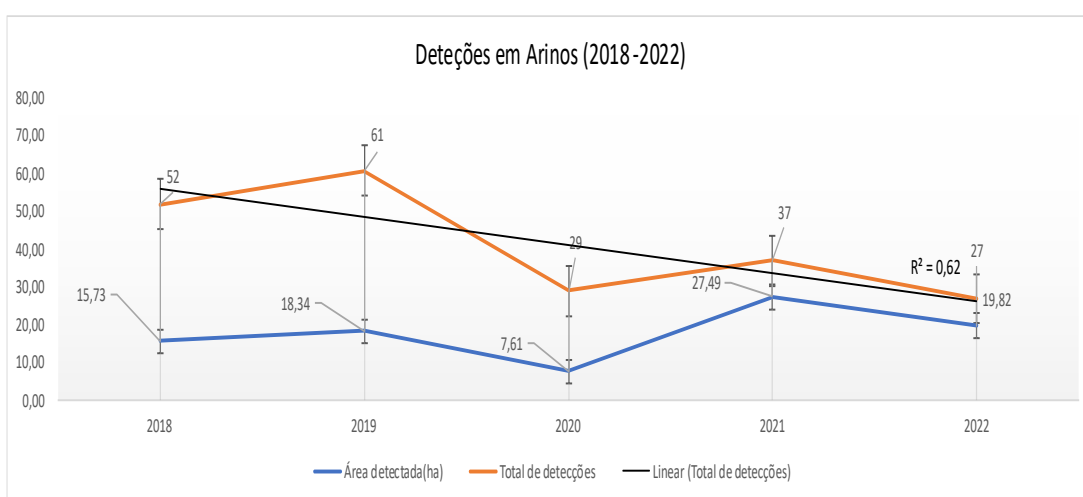

Ranking	Municípios	Área total (ha)	Detecções	Média (ha)
1º	João Pinheiro	108,96	243	0,45
2º	Arinos	88,99	206	0,43
3º	Buritizeiro	79,85	180	0,44
4º	Formoso	73,65	161	0,46
	Total	351,45	790	1,78

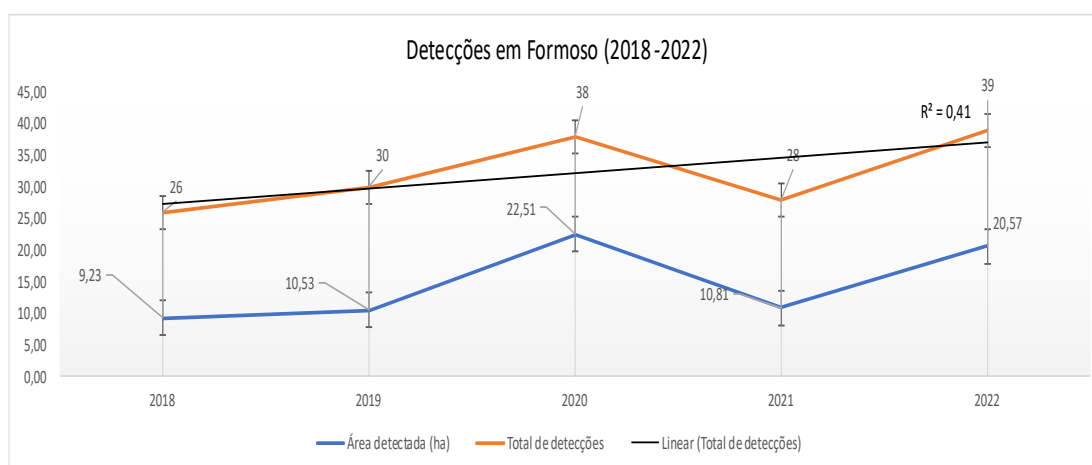

Fonte: Os autores (2023)

Diante dos resultados, foram construídos os Gráficos 1, 2, 3 e 4 para demonstrar a evolução do desmatamento em cada um desses municípios. Apesar de possuir o maior valor acumulado no período 2018 a 2022, o número total de detecções e a área detectada no município de João Pinheiro demonstram uma tendência de redução ($R^2 = 0,82$). Da mesma forma, apesar

de um ligeiro aumento entre os biênios 2018-2019 e 2020-2021, também foi observada uma redução no município de Arinos ($R^2 = 0,62$). O município de Buritizeiro (c), apesar do aumento acumulado na área desmatada, houve uma manutenção no número de detecções ($R^2 = 0,03$). Já no município de Formoso (d), embora tenha apenas 161 detecções, observou-se no mesmo período um aumento progressivo tanto na área acumulada, quanto no número de detecções ($R^2 = 0,41$), o que corrobora a informação de que a média de hectare desmatado é proporcionalmente maior (0,46 ha/deteção).

Gráfico 1 – Evolução do desmatamento em municípios do cerrado de Minas Gerais a partir dos polígonos detectados pelo sistema DETER (2018-2022).





Fonte: Os autores (2023)

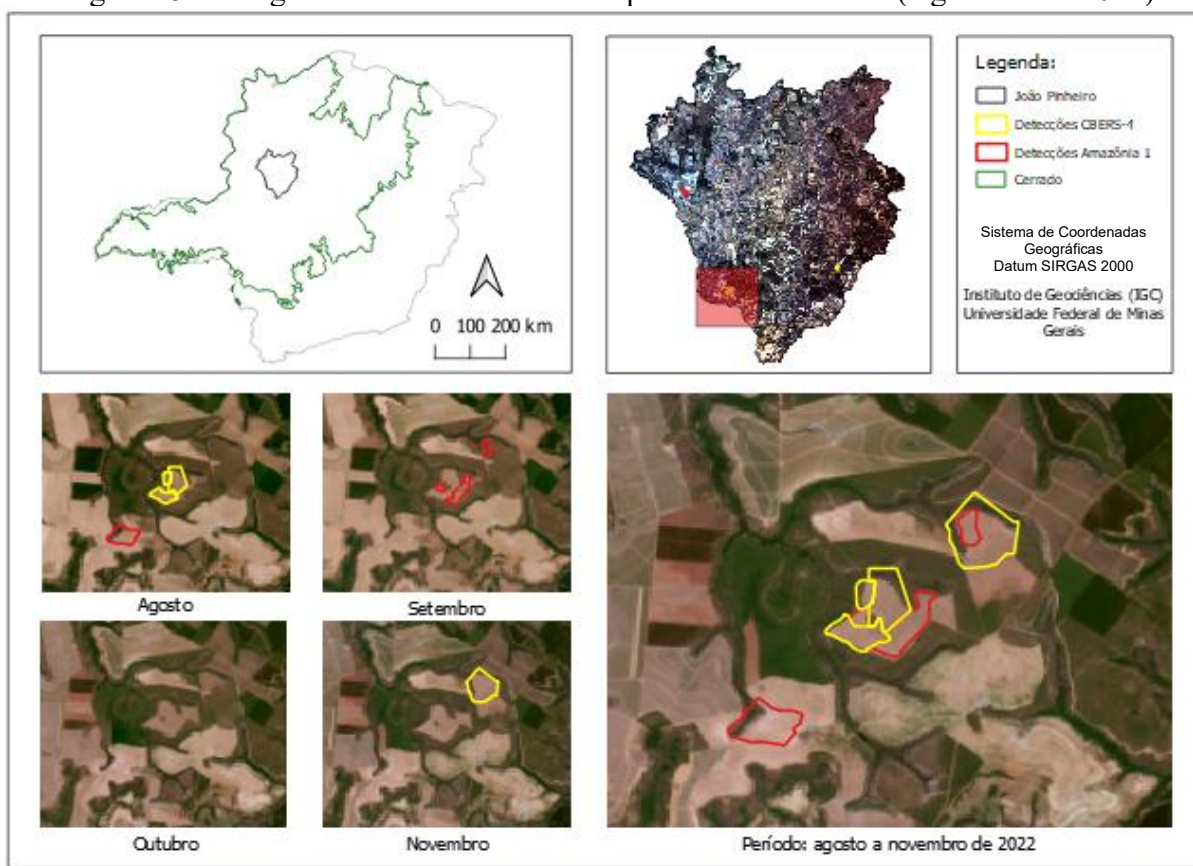
Considerando que a partir de junho de 2022, os polígonos de desmatamento do sistema DETER também passaram a ser detectados com o satélite Amazônia-1 (além do CBERS-4). Diante disso, foi escolhida uma área no município de João Pinheiro, monitorada por ambos os satélites, conforme representado na Figura 15. A análise demonstrou que apesar de em determinados momentos as detecções se sobreporem, há uma excelente correspondência entre as áreas desmatadas e os polígonos detectados. Para esse procedimento, foi utilizada uma imagem de alta resolução (disponibilizada gratuitamente pela Iniciativa Internacional de Clima e Floresta da Noruega (NICFI¹⁰, na sigla em inglês), obtida através das plataformas *Planet Explorer*¹¹ e *Basemap Viewer*¹²).

¹⁰ <https://planet.com/nicfi/>

¹¹ <https://planet.com/explorer/>

¹² <https://planet.com/basemaps/>

Figura 15 – Polígonos detectados no município de João Pinheiro (Ago a Nov – 2022)



Fonte: Os autores (2023)

6.6 Conclusão

A utilização de imagens orbitais para avaliação das intervenções ambientais tem se caracterizado como uma importante estratégia para otimização do planejamento e resposta dos órgãos de fiscalização ambiental. No presente estudo, verificou-se que, tanto a resolução espacial quanto a temporal, são determinantes para esses tipos de análises, sendo que, quanto menor o intervalo de disponibilização das imagens, mais efetiva será a resposta contra os infratores ambientais.

Ainda neste contexto, a utilização de imagens recentemente disponibilizadas pelo sensor do satélite Amazônia-1, lançado recentemente pelo Brasil (em 2021) e abordado no presente trabalho, pode ser considerada como uma metodologia inovadora. Futuramente, com a geração de acervo temporal e, conseqüentemente com a maior quantidade de imagens desse sensor, novos estudos futuros poderão ser realizados e resultando na redução significativa de custos, pois as referidas imagens são disponibilizadas gratuitamente. Adicionalmente a esse aspecto da pesquisa ressalta-se a utilização de programas sem custo, tal como o QGIS e os seus aplicativos, que são disponibilizados gratuitamente e também foram empregados nessa pesquisa.

Os polígonos disponibilizados pelo DETER, demonstraram uma grande relevância para o monitoramento e planejamento das ações de fiscalização ambiental. Os mapas gerados ratificaram que não houve aumento do desmatamento no cerrado e, paralelamente, não ocorreu sobrecarga significativa nas ações de fiscalização, que puderam concentrar em outras regiões críticas.

Não obstante, é importante ressaltar que uma análise prévia dos mapas gerados a partir dos polígonos do DETER, principalmente no bioma Cerrado, pode viabilizar uma avaliação mais efetiva e com maior rapidez para identificação e fiscalização de áreas desmatadas. Esses aspectos viabilizam a maior efetividade do planejamento para as ações preventivas, bem como combativas.

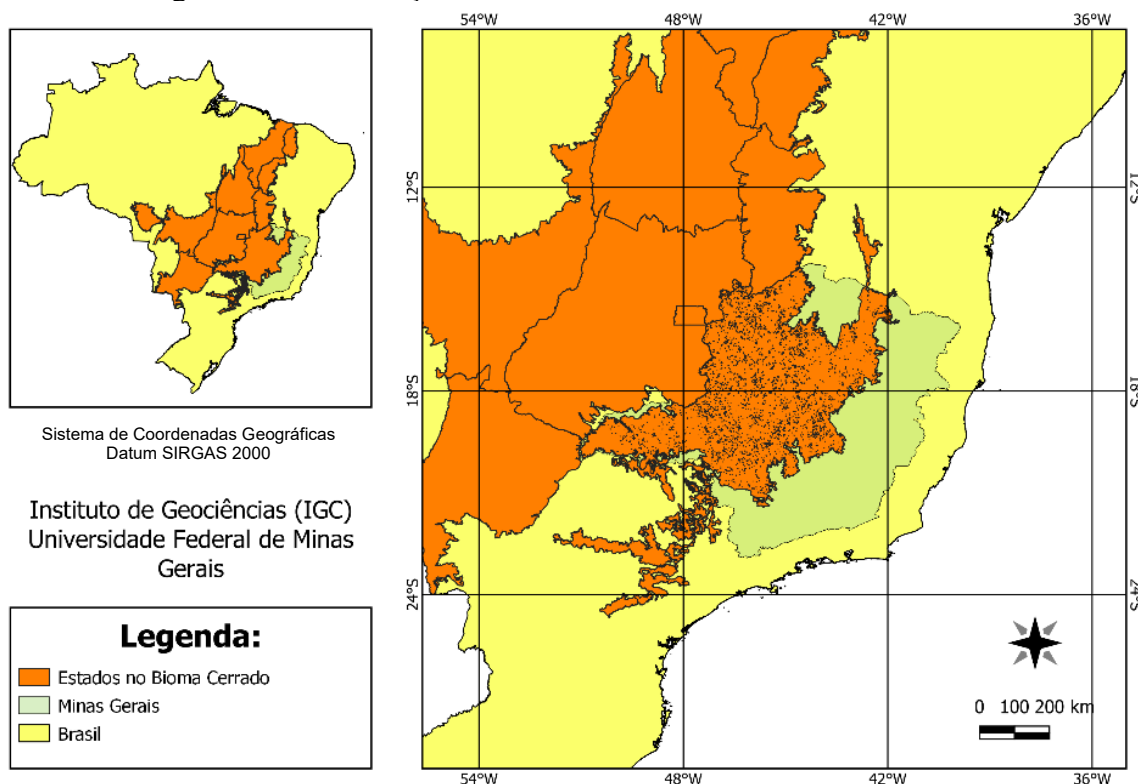
7 ANÁLISE COMPARATIVA DA CLASSIFICAÇÃO DE IMAGENS DO CERRADO DE MINAS GERAIS GERADAS PELO SATÉLITE BRASILEIRO AMAZÔNIA-1 COM EMPREGO DO MÉTODO RANDOM FOREST E PROGRAMAÇÃO EM R (MACHINE LEARNING)

7.1 Introdução

O bioma Cerrado é considerado o segundo maior bioma do Brasil, com uma área total de 2.036.448 km² (IBF, 2020), com mais de 200 mil hectares que correspondem a aproximadamente 22% de todo o território. Sua vegetação apresenta três fisionomias principais, a saber: as formações florestais, com presença de espécies arbóreas de dossel contínuo ou não; as savânicas, em que árvores e arbustos estão espalhados em um estrato gramíneo (sem dossel contínuo) e as campestres, onde predominam as espécies herbáceas e arbustivas, com ausência de árvores (RIBEIRO; WALTER, 2008). Com relação ainda ao Bioma Cerrado, Mota Júnior et al. (2023) utilizaram as geotecnologias no processo de análise da ocorrência do processo histórico de ocupação de territórios indígenas tradicionais no Sudeste Mato-grossense e, como estes transformaram o uso e cobertura da terra em áreas circunvizinhas entre 1998 e 2018. Para tanto, esses mesmos autores realizaram o mapeamento do uso e cobertura da terra por meio de imagens do satélite Landsat 8/OLI e Landsat5/TM. Após essa análise demonstrou-se que essas áreas se encontram com pouca cobertura vegetal e com grande fragmentação de remanescentes florestais, deixando as terras indígenas isoladas e cercadas em meio a atividade da agropecuária. Já Mendes et al. (2022) avaliaram o cumprimento da legislação ambiental referente às áreas de Reserva Legal de imóveis rurais localizados no Cerrado brasileiro, sob o aspecto do cumprimento do percentual mínimo exigido pela Lei nº 12.651/2012 (Brasil, 2012).

Vale ressaltar ainda que a abrangência territorial do Bioma Cerrado compreende os estados de Goiás, Tocantins, Distrito Federal, Bahia, Ceará Maranhão, Piauí, Mato Grosso, Mato Grosso do Sul, Minas Gerais, Paraná, Rondônia e São Paulo. Nesta pesquisa foi considerada a faixa territorial correspondente ao Estado de Minas Gerais, conforme descrito na Figura 16. No entanto, foi selecionado no presente estudo o município de João Pinheiro-MG, o que será mais detalhado e justificado no decorrer deste trabalho.

Figura 16 - Distribuição do bioma cerrado no território brasileiro.



Fonte: Os autores, 2023.

É importante ressaltar que o Brasil é um dos principais produtores mundiais de commodities agrícolas, o que incentiva essa demanda crescente por novas áreas cultiváveis, principalmente àquelas inseridas no Bioma Cerrado (MUELLER; MARTHA JÚNIOR, 2008), o que pode favorecer à ocorrência de desmatamentos ilegais. Não obstante, para o monitoramento das intervenções ambientais, em 2004, foi criado o Sistema de Detecção de Desmatamento em Tempo Real (DETER), de modo a apoiar a fiscalização ambiental, mapeando a supressão e a degradação florestal na Amazônia, bem como nas formações savânicas e florestais do bioma Cerrado Vale). A metodologia utilizada pelo DETER considera as imagens da Câmera Imageadora de Campo Largo (*Wide Field Imaging*, em inglês, ou WFI) a bordo dos satélites CBERS-4, 4A e, mais recentemente (a partir de 2021), também com o satélite Amazônia-1 (descrito, por exemplo, em DINIZ et al., 2018). A resolução espacial desses satélites é de 56 e 64 metros, o que possibilita a detecção de avisos de desmatamentos em áreas de até 3 hectares. Vale ressaltar pesquisas recentes e que utilizam do DETER (INPE, 2023), bem como de imagens do satélite Amazônia-1 (INPE, 2021), tais como nas pesquisas realizadas por BARBOSA, FERREIRA e JÚNIOR (2023), KIYOHARA e SANO (2023), PAZ (2023).

No caso específico do Estado de Minas Gerais, entre os anos de 2018 e 2022, o monitoramento da evolução do desmatamento no Bioma Cerrado a partir dos alertas detectados pelo DETER (INPE, 2023), identificou-se cerca de 6.100 polígonos de desmatamento, que correspondem a uma área total de 1.607,02 hectares (ha), com média de 0,26 ha por detecção. Durante esse período, dentre todos os municípios mineiros circunscritos no Bioma Cerrado, somente no território do município de João Pinheiro-MG foram contabilizados 243 polígonos, o que equivale a uma área total de 108,96 ha.

Por sua vez, o emprego de técnicas de geoprocessamento como a classificação de imagens de satélite (agrupamento de pixels, mediante características específicas, a partir de classes pré-definidas ou não pelo usuário) possibilita uma melhor compreensão acerca do mapeamento do uso e cobertura do solo, bem como suas tendências (NASCIMENTO, 2013). Tais informações são importantes pois subsidiam a análise de áreas degradadas, como por exemplo aquelas onde ocorrem desmatamentos ou outros tipos de intervenção ambiental, como os incêndios florestais. Vale destacar ainda os trabalhos realizados por OLIVEIRA e NERO (2013), OLIVEIRA et al. (2017), FERNANDES et al. (2018a, 2018b, 2020), NERO et al. (2021).

É possível afirmar, portanto, que a classificação de imagens, tem como objetivo categorizar automaticamente os pixels em uma imagem para possibilitar essa avaliação. Segundo Lillesand e Kiefer (2000), são três as técnicas gerais para classificação de imagens: supervisionada (algoritmo baseado na análise de amostras representativas de cada classe para treinamento), não-supervisionada (o algoritmo identifica as classes sendo fornecido o número de classes e a quantidade de iterações) e híbrida (associação dos dois métodos para uma estratificação temática mais detalhada).

Esses processos são construídos a partir de modelos matemáticos e algoritmos de aprendizado de máquina, Machine Learning (ML), ou de aprendizagem profunda, Deep Learning (DL). A utilização de ML e DL tem se mostrado como uma opção bastante relevante para a preparação, análise e predição de dados espaciais (TAQUARY, 2019; BRAGAGNOLO, 2021; DOMINGUEZ, 2022; BARBOSA, FERREIRA e JÚNIOR, 2023).

Um desses algoritmos mais comumente utilizado é o Random Forest (RF), proposto por Breiman (2001). Trata-se de um modelo de aprendizado de máquina utilizado para classificação de imagens (OLIVEIRA, MORAIS e NERO, 2022), cujo método é composto por um conjunto de árvores de decisão, construídas a partir de uma amostra aleatória de dados de treinamento que permite determinar a atribuição de uma classe final (SILVA JUNIOR, SILVA JUNIOR e PACHECO, 2021).

Apesar de existirem outros algoritmos para classificação de imagens, para que alcancem a confiabilidade quanto aos dados gerados, é importante que sejam realizados procedimentos de avaliação de desempenho e qualidade temática do mapeamento. Alguns desses parâmetros a serem observados são a matriz de confusão, a acurácia global e o índice Kappa, conforme Fleiss, Cohen e Everitt (1969), Congalton e Green (2019) (baseado em Landis e Koch, 1977) e Monserud e Leemans, (1992), sendo demonstrada por Foody (2020) apresentado no Quadro 3.

Quadro 3 - Níveis de exatidão de uma classificação, conforme índice Kappa.

	Congalton e Green (2019)	Fleiss, Cohen e Everitt (1969)	Monserud e Leemans (1992)	
Kappa	> 0,8 a 1,0	Quase Perfeito	Excelente	
	> 0,6 a 0,8	Substancial	Excelente	Muito Bom
			Suficientemente bom	Bom
	> 0,4 a 0,8	Moderado		Suficiente
	> 0,2 – 0,4	Suficiente	Pobre	Pobre
	> 0,0 a 0,2	Leve		Muito Pobre
	0,0	Pobre		Nenhuma

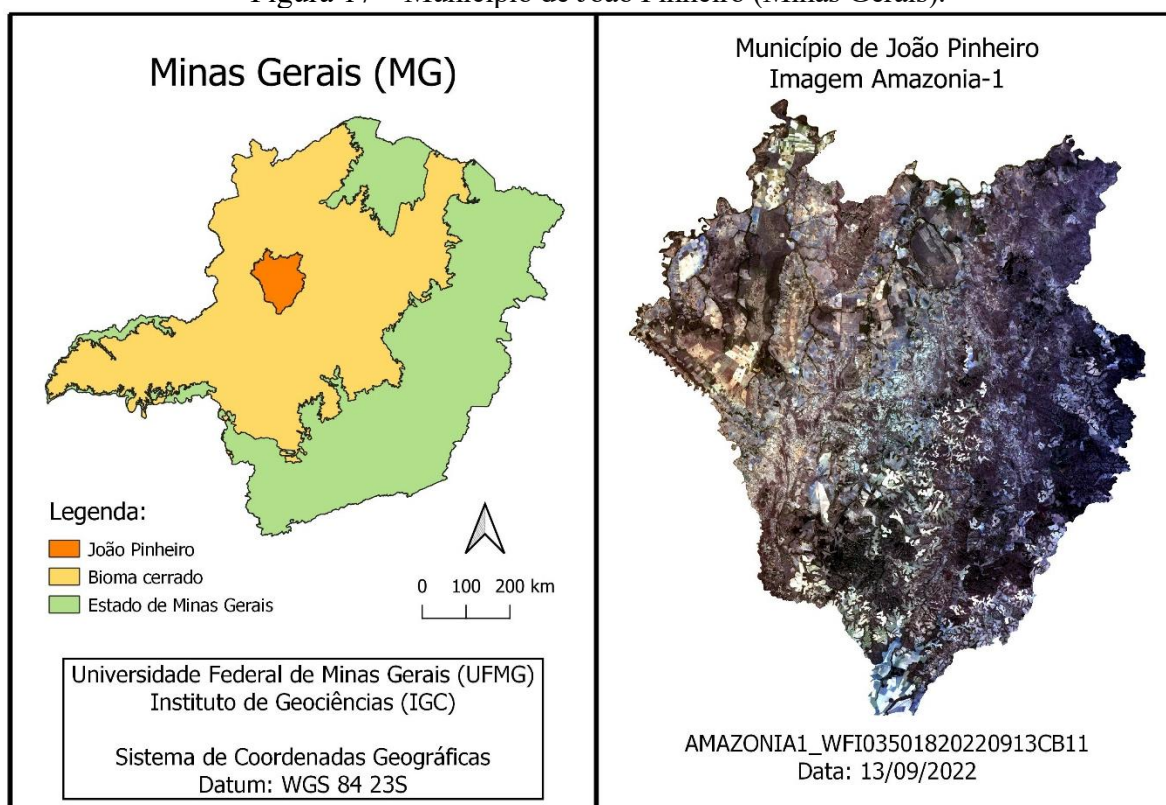
Fonte: Adaptado (FOODY, 2020)

7.2 Metodologia

7.2.1 Área de estudo

Considerando as análises da evolução do desmatamento no Bioma Cerrado no Estado de Minas Gerais, foi delimitado como objeto desse estudo o território de João Pinheiro, conforme apresentado na Figura 17. Trata-se do maior município mineiro, com uma área territorial de 10.727,097 km² e está integralmente situado no Bioma Cerrado (BRASIL, 2023).

Figura 17 – Município de João Pinheiro (Minas Gerais).



Fonte: Os autores, 2023.

7.2.2 Imagens orbitais

As imagens orbitais utilizadas (disponibilizadas gratuitamente) foram geradas pelo satélite Amazônia-1, tendo sido extraídas na página do catálogo de imagens do Instituto Nacional de Pesquisas Espaciais (INPE)¹³. Optou-se por utilizar somente as de Nível 4 (L4) pois já estão ortoretificadas e possuem as correções radiométricas e geométricas de sistema, com uso de pontos de controle e modelo digital de elevação do terreno (INPE, 2021). Essas imagens são disponibilizadas em 4 bandas e suas faixas espectrais são apresentadas no Quadro 4. A resolução espacial é de 64 metros (com uma faixa imageada de 850 km) e a resolução temporal é de 5 dias.

¹³ <http://www.dgi.inpe.br/catalogo/explore>

Quadro 4 – Especificações técnicas do satélite Amazônia-1

Sensor Imageador	Banda	Faixa espectral	Quantização	Dimensão do pixel
WFI (<i>Wide Field Imager</i>)	1	Blue (0.45-0.52 μm)	16 bit	64 m
	2	Green (0.52-0.59 μm)		
	3	Red (0.63-0.69 μm)		
	4	NIR (0.77-0.89 μm)		

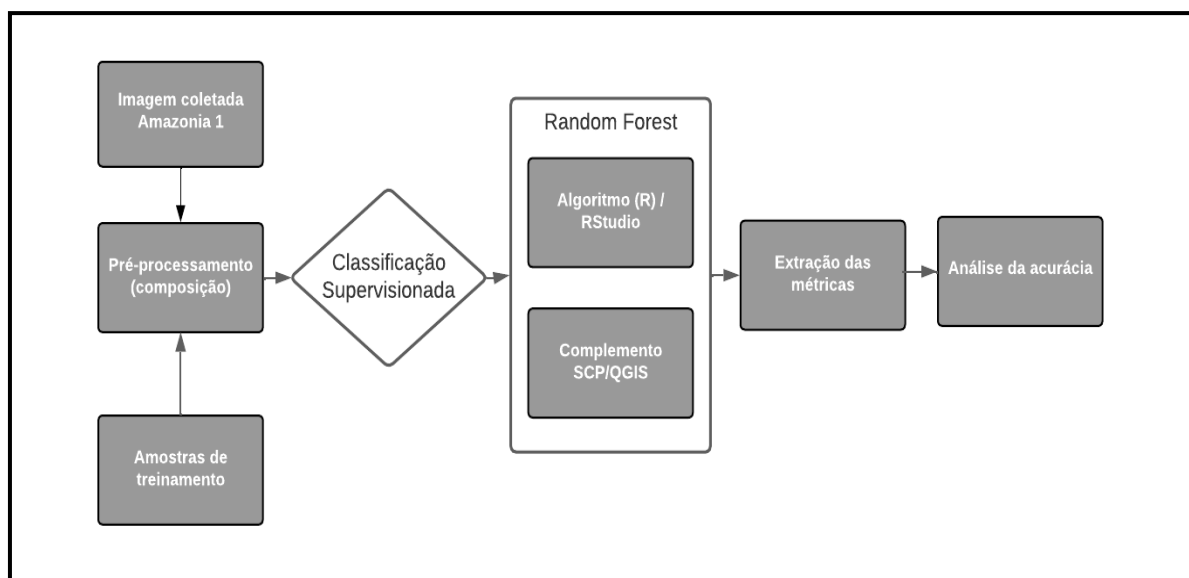
Fonte: Santos, 2022. Adaptação: os autores

Para evitar a interferência causada pela eventual cobertura de nuvens nos processos de classificação supervisionada, foi selecionada - dentre os arquivos pesquisados - a cena capturada no dia 13 de setembro de 2022 (denominada “AMAZONIA1_WFI03501820220913CB11”).

7.2.3 Análise e processamento das imagens

Os arquivos (vetoriais e raster) utilizados foram processados com o programa QGIS versão "3.16.5 Hannover" e o complemento "GRASS 7.8.5" (QGIS, 2023). A classificação supervisionada foi realizada com o complemento *Semi-automatic Classification Plugin* (SCP) (CONGEDO, 2023) para QGIS. Para utilização do SCP também foi necessário instalar e configurar o complemento executável ESA SNAP GPT (2023). As informações sobre a acurácia temática foram avaliadas com o complemento AcATaMa (LLANO, 2019). Já a classificação supervisionada comparativa foi realizada com o algoritmo de Linguagem R (bem como a respectiva acurácia temática, além da plotagem de dados e mapas) por meio do programa RStudio (2023.06.1) (AHMAD et al., 2023; R, 2021). Em todos os processamentos foi utilizado o método classificador *RandomForest* (RF). Os gráficos e análises estatísticas foram construídos com uso do programa Microsoft Excel 365 (2021). Os arquivos classificados foram interpretados e as métricas obtidas foram analisadas conforme ilustrado na Figura 18.

Figura 18 – Análise e processamento das imagens



Fonte: Os autores, 2023.

7.2.4 Classificação supervisionada

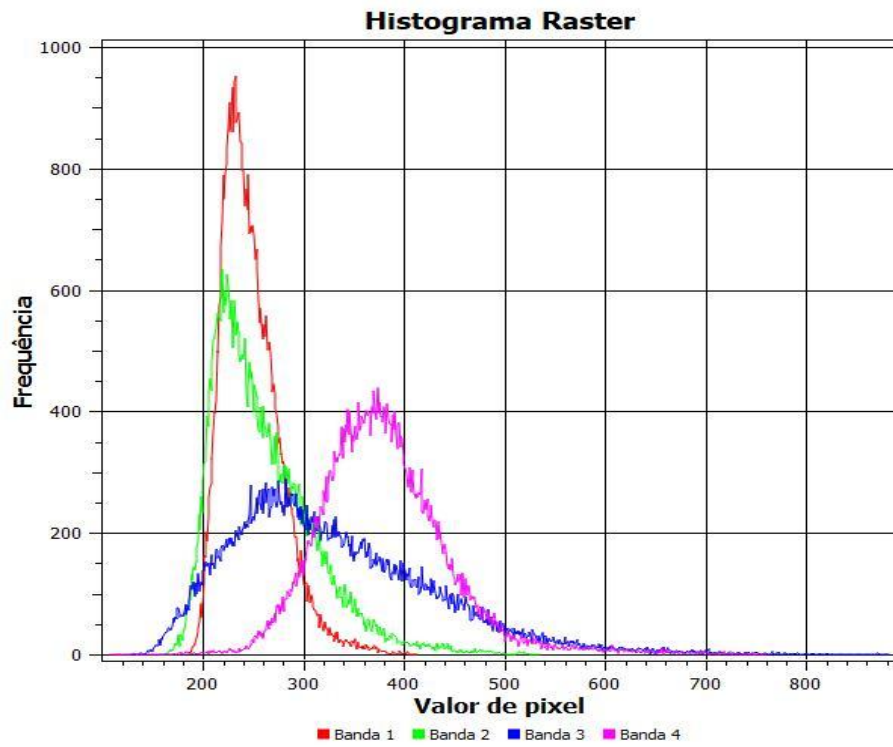
Inicialmente, a imagem do satélite Amazonia-1 foi processada no QGIS para combinação das 4 bandas espectrais (R/G/B/NIR) em uma composição colorida por meio do empilhamento das quatro bandas (TOMAZONI e GUIMARÃES, 2022). O histograma dessa composição obtida está representado na Figura 19.

Para realizar a classificação supervisionada, foi criado um arquivo vetorial (*shapefile*) contendo amostras de 10 diferentes classes referentes aos diversos usos do solo, a saber: Agricultura1, Agricultura2, Agricultura3, Água, Cerrado1, Cerrado2, Pousio, Solo exposto, Urbana e Vegetação arbórea. Para as amostras de cada uma dessas classes foram coletados 5 polígonos representativos para treinamento, com exceção da classe “água” (em que foi possível coletar somente 4), contabilizando um total de 49 amostras.

No intuito de inspecionar e validar comparativamente os polígonos definidos, foi utilizada uma imagem da constelação Planet Scope¹⁴ (PLANET TEAM, 2023), de melhor resolução espacial, disponibilizada gratuitamente pela Iniciativa Internacional do Clima e Florestas da Noruega (NICFI, 2023). O Quadro 5 apresenta as classes estabelecidas e alguns dos respectivos recortes comparativos para interpretação visual das amostras.

¹⁴ As imagens Planet Scope são coletadas diariamente por meio de uma constelação de 180 nanosatélites, com resolução espacial de 3,5 a 4m (GSD de 3,7 m). As bandas espectrais são o Blue (455-515 nm), o Green (500-590 nm), o Red (590-670 nm) e o NIR (780-860 nm). A capacidade de imageamento é de 340 milhões de km² por dia.




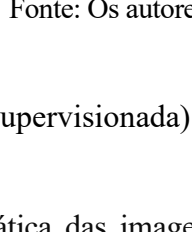

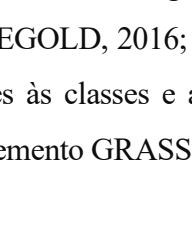
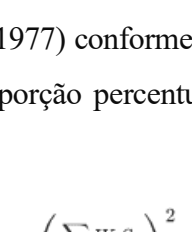
Figura 19 – Histograma da composição colorida (bandas empilhadas).



Fonte: Os autores, 2023.

Quadro 5 – Regiões de coleta das amostras de treinamento selecionadas para a classificação supervisionada

CLASSE	NOME	IMAGEM AMAZONIA-1	IMAGEM PLANET SCOPE
1	Agricultura1		
2	Agricultura2		
3	Agricultura3		
4	Água		
5	Cerrado1		
6	Cerrado2		

7	Pousio		
8	Solo exposto		
9	Urbana		
10	Vegetacao arbórea		

Fonte: Os autores, 2023.

7.2.5 Acurácia temática (classificação supervisionada)

Para avaliação da acurácia temática das imagens geradas foi calculado o tamanho da amostra em função de cada estrato (FINEGOLD, 2016; COCHARAN, 1977) conforme Equação 8. O tamanho das áreas correspondentes às classes e a respectiva proporção percentual foram obtidos com a função *R.report* do complemento GRASS.

$$\text{Equação (8) - tamanho da amostra: } n = \frac{(\sum w_i s_i)^2}{[s(\hat{\theta})]^2 + (1/N) \sum w_i s_i^2} \approx \left(\frac{\sum w_i s_i}{s(\hat{\theta})} \right)^2$$

Onde:

W_i = proporção da área mapeada da classe i ;

S_i = desvio padrão do estrato i ;

S_o = desvio padrão esperado da precisão geral (assumiu-se o valor de $S_o = 0,01$);

O desvio padrão do estrato (S_i) de cada classe foi calculado em função dos valores da precisão do usuário (U_i), conforme descrito na Equação 9. Para tanto, foram utilizadas as referências: 0,50 para as classes de cultura (Agricultura1, Agricultura2 e Agricultura3); 0,60 para Água; 0,95 para Cerrado1, Cerrado2 e Vegetação Arbórea; 0,90 para Pousio; 0,70 para Solo exposto e 0,90 para Urbano (baseado em Olofsson et al., 2014).

$$\text{Equação (9) – desvios padrão dos estratos: } S_i = \sqrt{U_i(1 - U_i)}$$

O número de amostras estratificado, N_i (vide Equação 10), a ser coletado em cada classe foi definido considerando o valor médio entre a distribuição normal e distribuição ponderada dessas amostras (CONGEDO, 2023).

$$\text{Equação (10) – número de amostras estratificado: } N_i = \left(\frac{N}{c} + N * W_i \right) / 2$$

Onde:

N = número total de amostras;

c = número total de classes;

W_i = proporção da área mapeada da classe i ;

Dessa forma, utilizando as equações demonstradas, foi calculado o total de amostras necessárias para avaliação da acurácia temática de cada imagem classificada. Os valores estão representados nas Tabelas 10 e 11, bem como os demais respectivos parâmetros utilizados para definição das amostras estratificadas.

Tabela 10 – Amostras definidas para análise da acurácia temática na imagem obtida com o classificador RF do complemento SCP.

Classe	Descrição	Area (Km ²)	Wi	Ui	Si	Wi*Si	N*Wi	N/c	Ni
1	Agricultura1	27,44	0,0026	0,50	0,5	0,0013	2	89	46
2	Agricultura2	286,15	0,0267	0,50	0,5	0,0133	24	89	56
3	Agricultura3	1.592,74	0,1486	0,50	0,5	0,0743	132	89	111
4	Água	66,43	0,0062	0,60	0,5	0,0030	6	89	47
5	Cerrado1	2.491,07	0,2323	0,95	0,2	0,0506	207	89	148
6	Cerrado2	2.643,39	0,2466	0,95	0,2	0,0537	220	89	154
7	Pousio	2.694,44	0,2513	0,90	0,3	0,0754	224	89	156
8	Solo_exposto	293,47	0,0274	0,70	0,5	0,0125	24	89	57
9	Urbana	189,99	0,0177	0,90	0,3	0,0053	16	89	52
10	Vegetação arborea	436,34	0,0407	0,95	0,2	0,0089	36	89	63
	Total	10.721,46	-	-	-	0,2984	-	-	891

Fonte: Os autores, 2023.

Tabela 11 – Amostras definidas para análise da acurácia temática na imagem obtida com o classificador RF por meio do algoritmo de Linguagem R.

Classe	Descrição	Area (Km ²)	Wi	Ui	Si	Wi*Si	N*Wi	N/c	Ni
1	Agricultura1	30,12	0,0028	0,50	0,5	0,0014	2	78	40
2	Agricultura2	209,77	0,0196	0,50	0,5	0,0098	15	78	47
3	Agricultura3	917,00	0,0855	0,50	0,5	0,0428	67	78	73
4	Água	22,43	0,0021	0,60	0,5	0,0010	2	78	40
5	Cerrado1	2.695,82	0,2514	0,95	0,2	0,0548	197	78	138
6	Cerrado2	3.222,67	0,3006	0,95	0,2	0,0655	235	78	157
7	Pousio	2.959,04	0,2760	0,90	0,3	0,0828	216	78	147
8	Solo_exposto	356,24	0,0332	0,70	0,5	0,0152	26	78	52
9	Urbana	28,15	0,0026	0,90	0,3	0,0008	2	78	40
10	Vegetação arborea	280,23	0,0261	0,95	0,2	0,0057	20	78	49
Total		10.721,46	-	-		0,2798	-	-	783

Fonte: Os autores, 2023.

Após definição do número total de amostras e sua distribuição por classe, foi aplicada a estatística Kappa, sendo este um método que permite analisar de forma comparada os resultados das análises dos mapas obtidos por meio do sensoriamento remoto, dentro de certo limite (LANDIS e KOCH, 1977). A matriz de erro utilizada para a aferição da acurácia temática foi construída segundo o modelo apresentado no Quadro 6, pela qual foram obtidas as seguintes informações estatísticas: índice Kappa (Equação 4), acurácia global (Equação 5), acurácias do produtor (Equação 6) e do usuário (Equação 7).

Quadro 6 - Modelo da matriz de erro (4 x 4) para a acurácia temática

Classes	A	B	C	D	Soma das Linhas
A	n11	n12	n13	n1k	n1+
B	n21	n22	n23	n2k	n2+
C	n31	n32	n33	n3k	n3+
D	n41	n42	n43	n4k	nK+
Soma das Colunas	n+1	n+2	n+3	n+K	n

Fonte: Adaptado de Congalton e Green (2009) e Santos (2010).

$$\text{Equação (11) – índice Kappa: } \frac{\sum_{i=1}^k n_{ii} - \sum_{i=1}^K n_{i+} + n_{+i}}{n^2 - \sum_{i=1}^K n_{i+} + n_{+i}}$$

$$\text{Equação (12) – Acurácia Global: } \frac{\sum_{i=1}^k n_{ij}}{n}$$

$$\text{Equação (13) – Acurácia do Produtor: } \frac{n_{ij}}{n_{+j}}$$

$$\text{Equação (14) – Acurácia do Usuário: } \frac{n_{ii}}{n_{i+}}$$

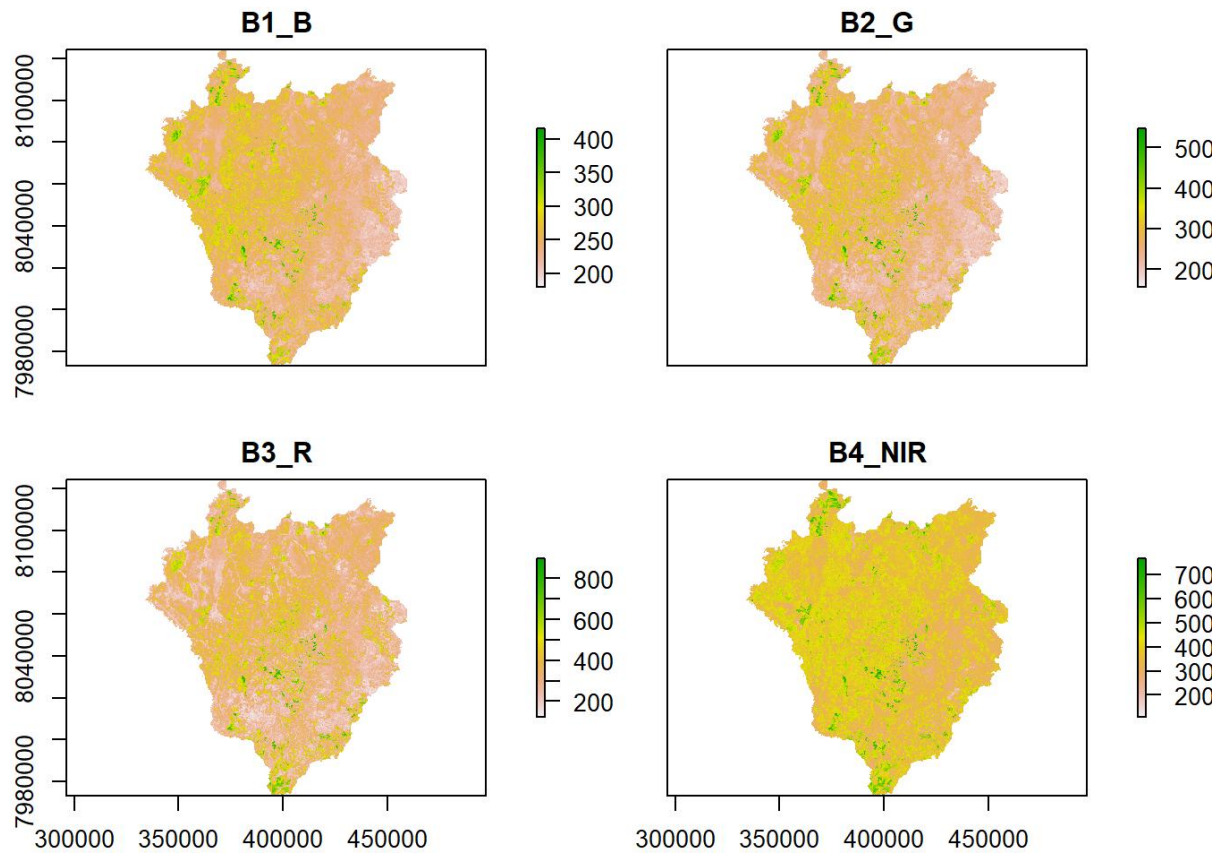
Os dados calculados foram utilizados para avaliar a performance de cada um dos métodos empregados. Para tanto, os procedimentos de validação das amostras estratificadas foram realizados com o complemento AcATaMa (Llano, 2019). Os resultados obtidos possibilitaram a construção das respectivas matrizes de confusão, bem como os índices de Acurácia Global e Kappa.

7.2.6 Acurácia temática calculada com Linguagem R

A Linguagem R (RSTUDIO TEAM, 2020 e R CORE TEAM, 2021) é uma ferramenta *open source* (código aberto), desenvolvida na década de 90, que tem como finalidade expressar ideias e operações estatísticas em um ambiente para análise interativa de dados. O RStudio, por sua vez, é um Ambiente de Desenvolvimento Integrado (*Integrated Development Environment - IDE*, em inglês) utilizado para esse tipo de programação em Linguagem R (FARIA, 2020).

No algoritmo desenvolvido neste trabalho (APÊNDICE A) para classificação supervisionada utilizou-se a mesma imagem do Satélite Amazônia-1 e as mesmas amostras de treinamento anteriores. Para auxiliar no processo de classificação, a resposta espectral dos índices vegetativos de cada banda da imagem (R/G/B/NIR) foi gerada utilizando-se a função *plot* (Figura 20).

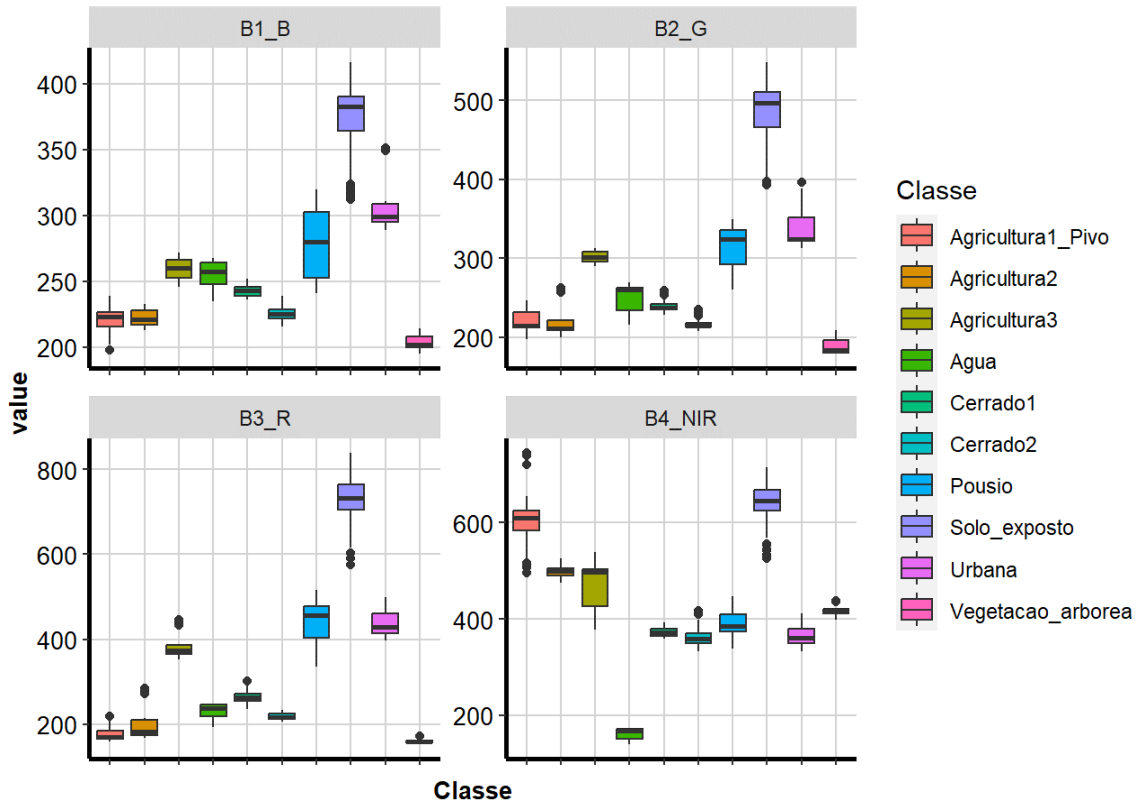
Figura 20 – Índices vegetativos de cada banda da imagem do Amazônia-1



Fonte: Os autores, 2023.

Com a função *melt()* do pacote *reshape2*, foi construído o gráfico do espectro de reflectância médio para cada uma das classes em função das bandas da imagem (Figura 21).

Figura 21 – Resposta espectral das amostras de cada classe em função das bandas existentes na imagem analisada



Fonte: Os autores, 2023.

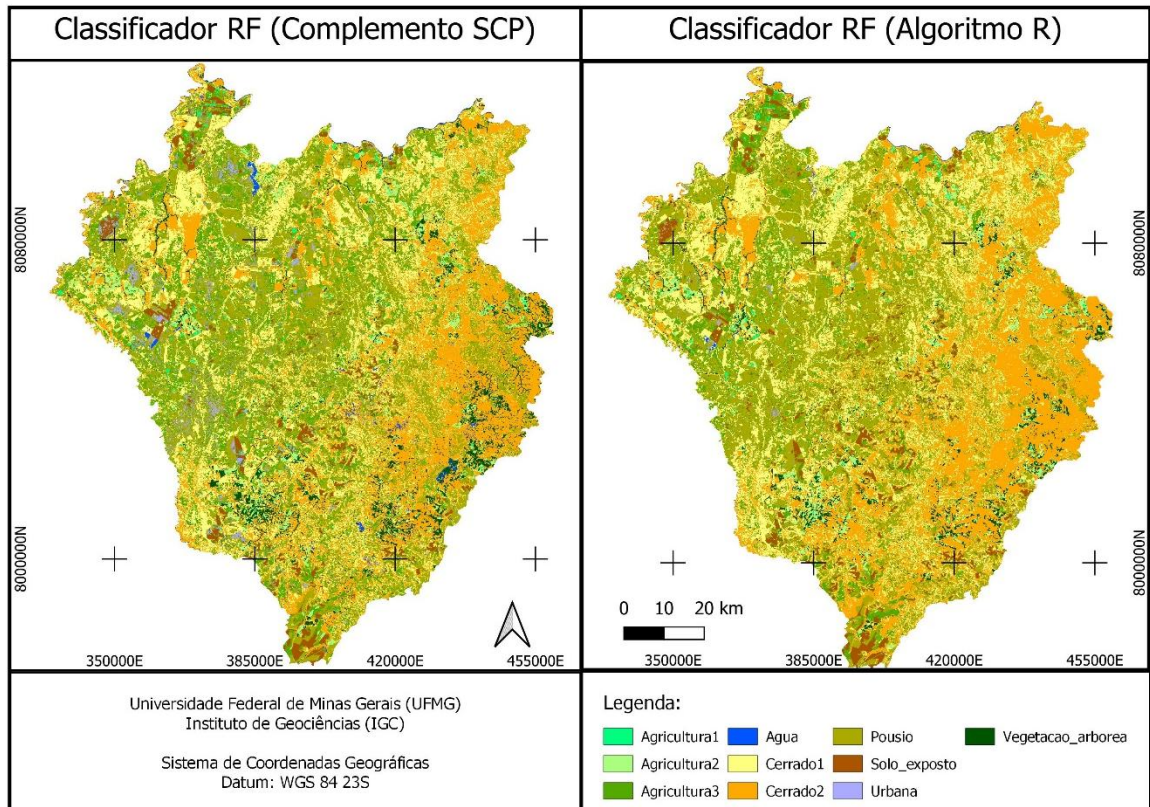
Para a realização do treinamento e do teste do algoritmo (ML), por opção do analista, foram selecionadas amostras aleatórias de treinamento/teste na proporção de 70%/30% para o processo de classificação supervisionada com a função *RandomForest*. Conforme já explicado o classificador RF baseia-se no modelo de árvores para tomada de decisão, sendo que quanto maior o valor, mais complexo fica o modelo, porém mais preciso. Para a escolha da melhor classificação foram testados valores 5 e 1000 árvores (*n tree*), sendo escolhido o segundo modelo devido ao seu melhor desempenho.

7.3 Resultados

A Figura 22 ilustra os mapas temáticos que foram gerados com emprego do método de classificação *Random Forest*, implementado por meio do complemento SCP, bem como pelo algoritmo desenvolvido em Linguagem R (construído no RStudio). Conforme descrito no Quadro

3, as dez classes representativas para uso e cobertura do solo foram estabelecidas a partir da interpretação das características específicas presentes no Bioma Cerrado.

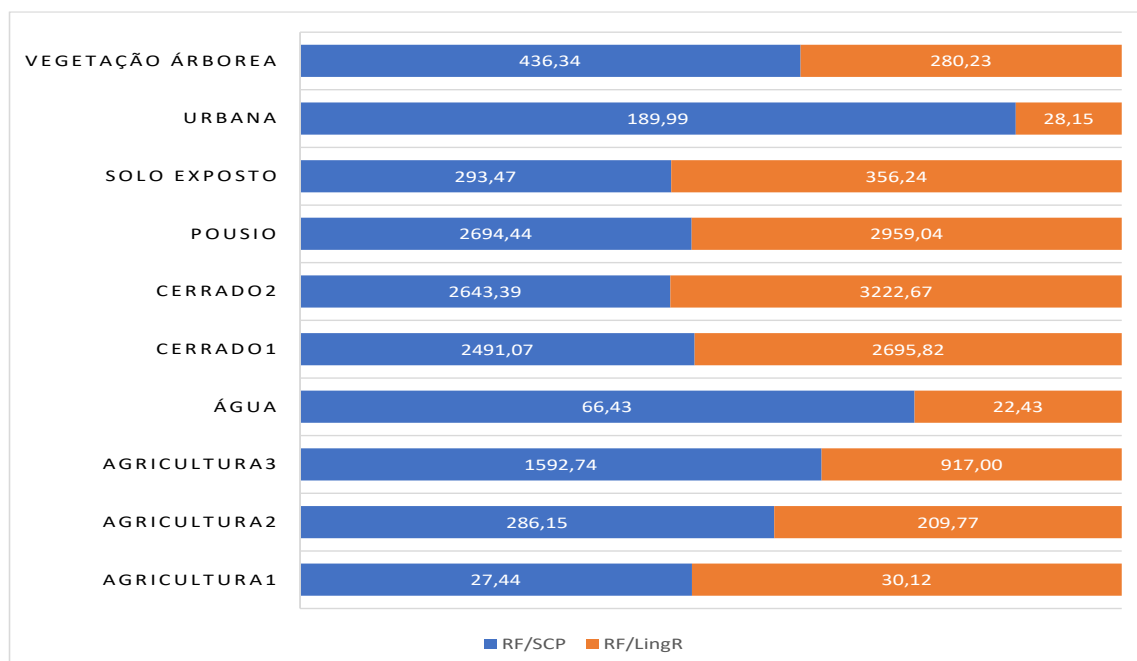
Figura 22 – Classificação supervisionada da imagem gerada pelo Satélite Amazônia-1.



Fonte: Os autores, 2023.

Conforme pode ser observado nos mapas temáticos gerados, algumas classes apresentaram áreas muito divergentes em relação às imagens classificadas. Dentre essas, destaca-se principalmente as classes de vegetação arbórea, urbana e água, conforme representado no Gráfico 2. Essa divergência possivelmente está relacionada ao processo de classificação, o que ensejou a necessidade de uma avaliação da qualidade temática.

Gráfico 2 – Representação das métricas das áreas classificadas na imagem do Amazônia-1



Fonte: Os autores, 2023.

Considerando os dados apresentados nas Tabelas 10 e 11, foram construídas as matrizes de confusão para avaliação quanto à qualidade temática das classificações realizadas. Para a imagem classificada com o RF do complemento SCP, foram inspecionadas 891 amostras com o complemento AcATaMA (LLANO, 2019) sendo obtidos os valores descritos na Tabela 3. A acurácia global alcançada foi de 0,7838 ($\sigma = 0,0129$) e o Índice Kappa foi 0,6966.

Tabela 12 - Matriz de confusão – Classificação Supervisionada (SCP)

Classe		1	2	3	4	5	6	7	8	9	10	Total
Agricultura1	1	44	2	0	0	0	0	0	0	0	0	46
Agricultura2	2	2	41	1	0	10	1	0	0	0	1	56
Agricultura3	3	0	0	38	0	9	7	54	1	1	1	111
Água	4	0	0	0	21	8	17	1	0	0	0	47
Cerrado1	5	0	0	0	0	124	24	0	0	0	0	148
Cerrado2	6	0	0	0	0	9	145	0	0	0	0	154
Pousio	7	0	0	2	0	14	1	138	0	1	0	156
Solo exposto	8	0	0	1	0	0	0	0	56	0	0	57
Urbana	9	0	1	1	0	0	0	46	3	1	0	52
Vegetação arbórea	10	0	3	0	0	1	10	0	0	0	50	64
Total		46	47	43	21	175	205	239	60	3	52	891

Fonte: Os autores, 2023.

Na classificação supervisionada da imagem gerada com o algoritmo *Random Forest* programado em Linguagem R, foi realizado o mesmo procedimento, sendo analisadas 783 amostras que resultaram nos valores descritos na Tabela 13. A acurácia global alcançada foi de 0,9473 ($\sigma = 0,0078$) e o Índice Kappa foi 0,9474.

Tabela 13 - Matriz de confusão – Classificação Supervisionada (Linguagem R)

Classe		1	2	3	4	5	6	7	8	9	10	Total
Agricultura1	1	37	1	0	0	1	0	0	0	0	1	40
Agricultura2	2	0	47	0	0	0	0	0	0	0	0	47
Agricultura3	3	0	0	49	1	11	2	10	0	0	0	73
Água	4	0	0	0	34	2	3	1	0	0	0	40
Cerrado1	5	0	0	0	0	134	2	1	0	0	1	138
Cerrado2	6	0	0	0	0	0	154	2	0	0	1	157
Pousio	7	0	0	2	0	1	1	143	0	0	0	147
Solo exposto	8	0	0	0	0	0	0	0	52	0	0	52
Urbana	9	0	0	0	0	1	0	35	0	4	0	40
Vegetação arbórea	10	0	1	0	0	0	1	0	0	0	47	49
Total		37	49	51	35	150	163	192	52	4	50	783

Fonte: Os autores, 2023.

Os valores referentes à acurácia do usuário (Equação 7) e acurácia do produtor (Equação 6) das duas imagens classificadas também foram calculados pelo AcATaMa (LLANO, 2019) e estão descritos na Tabela 14.

Tabela 14 – Acurácia do usuário e do produtor.

Classe	Classificação SCP		Classificação Linguagem R	
	Usuário	Produtor	Usuário	Produtor
Agricultura1	0,9565	0,7197	0,0304	0,1409
Agricultura2	0,7321	0,8923	0,0597	0,0467
Agricultura3	0,3423	0,9184	0,0452	0,0403
Água	0,4468	1,0000	0,0733	0,0000
Cerrado1	0,8378	0,7783	0,0304	0,0275
Cerrado2	0,9416	0,8008	0,0190	0,0236
Pousio	0,8846	0,7162	0,0257	0,0215
Solo exposto	0,9825	0,9193	0,0175	0,0457
Urbana	0,0192	0,1036	0,0192	0,1074
Vegetação arbórea	0,7813	0,9460	0,0521	0,0400

Fonte: Os autores, 2023.

7.3.4 Classificação comparativa realizada com algoritmo em Linguagem R (RStudio)

Utilizando funções específicas de ML, especificamente o algoritmo *Random Forest* - programação em Linguagem R, também foram calculados os valores referentes à classificação supervisionada. A matriz de confusão foi gerada com a função *confusionMatrix*, sendo selecionadas aleatoriamente 435 amostras conforme apresentado na Tabela 15. Observa-se que a acurácia global alcançada foi ainda maior, no valor de 0,9793 ($\sigma = 0,0112$) e o Índice Kappa foi 0,9708.

Tabela 15 - Matriz de confusão – Classificação Supervisionada (Algoritmo em Linguagem R)

Classe		1	2	3	4	5	6	7	8	9	10	Total
Agricultura1	1	31	1	0	0	0	0	0	0	0	0	32
Agricultura2	2	0	22	0	0	0	0	0	0	0	0	22
Agricultura3	3	0	0	16	0	0	0	1	0	0	0	17
Água	4	0	0	0	8	0	0	0	0	0	0	8
Cerrado1	5	0	0	0	0	36	4	0	0	0	0	40
Cerrado2	6	0	0	0	0	0	35	0	0	0	0	35
Pousio	7	0	0	0	0	0	0	45	0	3	0	48
Solo exposto	8	0	0	0	0	0	0	0	220	0	0	220
Urbana	9	0	0	0	0	0	0	0	0	5	0	5
Vegetação arbórea	10	0	0	0	0	0	0	0	0	0	8	8
Total		31	23	16	8	36	39	46	220	8	8	435

Fonte: Os autores, 2023.

Os valores referentes à acurácia do usuário (variável *Pos Pred Value*) e à acurácia do observador (variável *Sensitivity*) obtidos através do processamento do algoritmo também foram calculados e estão transcritos na Tabela 16.

Tabela 16 – Acurácia do usuário e do produtor

	Algoritmo (Linguagem R)	
	Usuário	Produtor
Agricultura1	0,9688	1,0000
Agricultura2	1,0000	0,9565
Agricultura3	0,9412	1,0000
Água	1,0000	1,0000
Cerrado1	0,9000	1,0000
Cerrado2	1,0000	0,8974
Pousio	0,9375	0,9783
Solo exposto	1,0000	1,0000
Urbana	1,0000	0,6250
Vegetação arbórea	1,0000	1,0000

Fonte: Os autores, 2023.

Os parâmetros de qualidade temática estudados, principalmente a acurácia global e o índice Kappa, para os dois processos de classificação supervisionada estão apresentados na Tabela 17. Apesar de utilizarem os mesmos métodos de classificação (supervisionada) e método classificador (RF), o complemento SCP apresentou menor valor para a acurácia global e para o Índice Kappa. Já a imagem classificada com o algoritmo RF (programado em Linguagem R) apresentou um valor maior para o mesmo índice calculado, que é considerado como “quase perfeito” nos termos das faixas estabelecidas no Quadro 3. Mesmo com esse resultado superior, o número de amostras utilizado para avaliação da qualidade temática foi significativamente menor que o primeiro. Essa análise é corroborada pelos resultados da acurácia global e Índice Kappa, obtidos pela classificação comparativa do algoritmo RF programado em Linguagem R.

Tabela 17 – Avaliação dos parâmetros da acurácia temática e desempenho

	Parâmetro	SCP	Linguagem R
1	Tipo de Classificação	Supervisionada	Supervisionada
2	Classes da Amostra	10	10
3	Total de amostras (N)	891	783
4	Classificador	RF	RF
5	Acurácia Global	0,7838 ($\sigma = 0,0129$)	0,9474 ($\sigma = 0,0078$)
6	Kappa	0,6966	0,9474
7	Avaliação (Quadro 1)	Substancial	Quase perfeito

Fonte: Os autores, 2023.

Para compreender as razões prováveis quanto à divergência das métricas calculadas nos procedimentos de classificação, foi realizada uma interpretação visual analítica a partir dos pontos de amostragem gerados pelo complemento AcATaMa (LLANO, 2019). Para tanto, também foram consideradas simultaneamente as imagens do próprio arquivo *raster* gerado pelo Satélite Amazônia-1 e a imagem de melhor resolução espacial (da constelação Planet), referente ao mesmo período. As imagens foram analisadas e organizadas por classes (conforme APÊNDICES B e C), tendo sido utilizado o layout comparativo para análise das amostras do Quadro 7.

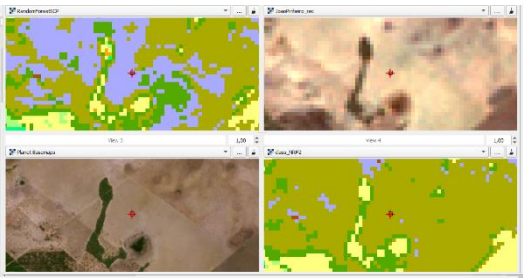

Quadro 7 – Método de análise e interpretação das amostras

Amostra da classificação RF com o complemento SCP / Algoritmo R	Imagem satélite Amazônia-1
Avaliação na cena Planet Scope	Amostra da classificação RF com o Algoritmo R / complemento SCP

Fonte: Os autores, 2023.

Alguns desses exemplos de inconsistência recorrentemente observados são: a identificação equivocada de polígonos da classe Água em áreas de vegetação do Bioma Cerrado e a presença de polígonos classificados como sendo áreas urbanizadas (classe Urbana) em áreas que na verdade correspondem à classe Pousio. Algumas dessas observações estão ilustradas no Quadro 8.

Quadro 8 – Observações analisadas por meio da interpretação visual das amostras

Comparação (AcATaMa)	Classificação	Situação real
	<p>A área classificada pelo SCP sugere a presença de edificações urbanas.</p>	<p>Trata-se de uma área de pousio, ou seja, local onde a cultura foi interrompida para melhorar a fertilidade do solo.</p>
	<p>O pixel classificado pelo SCP na cor azul sugere a presença de água.</p>	<p>Conforme as imagens, trata-se de uma área com vegetação típica do Bioma Cerrado.</p>

	<p>Na área foi classificada pelo SCP, o ponto analisado está contido numa área de vegetação do Bioma Cerrado.</p>	<p>No entanto, trata-se exclusivamente de um reservatório de água.</p>
	<p>Tanto a classificação do SCP quanto a do algoritmo programado identificaram uma grande área como sendo urbana.</p>	<p>A área identificada na verdade trata-se de uma região de pousio.</p>

Fonte: Os autores, 2023.

Portanto, considerando os apontamentos da classificação supervisionada, bem como da avaliação da situação real, observa-se que apesar da elevada assertividade, ainda assim ocorrem erros relevantes que demandam procedimentos de interpretação visual realizada por parte dos analistas.

7.4 Conclusão

O uso de imagens orbitais para o emprego nas diferentes análises e modelagens de dados ambientais tem se tornado imprescindível para compreensão de fenômenos ambientais, tais como o desmatamento e os incêndios florestais.

Nesse sentido, as imagens do satélite Amazônia-1 (disponibilizadas gratuitamente pelo INPE), demonstraram um grande potencial para emprego nas aplicações de mapeamento do uso e cobertura do solo. No entanto, que devido a restrição no que tange principalmente à resolução espacial, limitada à 64 metros, é imprescindível que os dados gerados sejam analisados antes de qualquer avaliação qualitativa mais apurada.

Já as imagens de melhor resolução espacial (Planet) utilizadas, apesar da restrição que impossibilita a realização de operações na sua versão gratuita, possuem uma excelente aplicação para o processo de validação das amostras analisadas com o complemento AcATaMa.

Por sua vez, os procedimentos para inspeção remota de áreas tem sido cada vez mais utilizados nas análises ambientais, principalmente em função da variedade das diversas fontes de imagens orbitais disponíveis, possibilitando uma redução nos custos associados às visitas de

campo. As imagens da constelação Planet, por exemplo, possuem uma taxa de revisita diária o que aumenta a efetividade no desenvolvimento de estratégias para combater as intervenções ambientais.

Quanto à classificação supervisionada (com classificador *Random Forest*) analisada neste trabalho, se demonstrou como um método bastante efetivo para o mapeamento da cobertura e identificação dos diferentes usos do solo. No entanto, o procedimento realizado com algoritmo programado em Linguagem R (utilizando técnicas de ML) alcançou uma qualidade temática bastante superior aos resultados obtidos com o complemento SCP. Considerando os critérios estabelecidos no Quadro 3, o Índice Kappa calculado através da programação foi considerado no nível de quase perfeição.

O grande sucesso dos resultados alcançados pelo algoritmo RF programado em Linguagem R deve-se possivelmente à respectiva metodologia de processamento utilizada para tomada de decisão, ou seja, quanto maior o número de árvores de decisão definidas para validação das amostras de treinamento/teste, maior a assertividade do mapeamento e melhores serão os parâmetros relativos à qualidade temática.

Como sugestão para desenvolvimento de novos trabalhos, sugere-se a implementação e análise dos procedimentos de classificação em função de técnicas de aprendizado profundo (*Deep Learning*, em inglês, ou DL) e redes neurais convolucionais (*Convolutional Neural Networks*, em inglês, ou CNN), a fim de avaliar os resultados referentes à qualidade temática.

8 CONSIDERAÇÕES FINAIS

Este trabalho avaliou a utilização de informações alusivas às supressões vegetais, a partir de polígonos (dados vetoriais) gerados pelo sistema DETER, que é a principal ferramenta gratuita para monitoramento do desmatamento no Bioma Cerrado. Ressalta-se que esse sistema passou a utilizar, a partir do mês de junho de 2022, as imagens geradas pelo Satélite brasileiro Amazônia-1. Os dados coletados pelo novo sensor tornam-se fundamentais e imprescindíveis para a identificação de regiões mais susceptíveis, bem como a localização e mensuração dessas áreas. Com isso é possível estabelecer estratégias de monitoramento e ação para combater o desmatamento.

No caso específico do Estado de Minas Gerais, o número de alertas baseado em polígonos de desmatamento ao longo do período de 2018 a 2022, apresentou uma redução que pode estar relacionada à maior distribuição espacial das ações de fiscalização realizadas pelos órgãos públicos de proteção ambiental.

Ainda, de acordo com o estudo, foi possível verificar que a resolução espacial do Amazônia-1 é relativamente restrita e não possibilita necessariamente uma representatividade de elevada confiabilidade para áreas menores. Tal situação foi comprovada em função das análises decorrentes da classificação supervisionada das imagens, principalmente quanto à detecção de algumas classes como Solo exposto, Urbana e Água.

Não obstante, também se concluiu que a classificação supervisionada realizada mediante programação com Linguagem R mostrou-se comparativamente ligeiramente mais assertiva do que o procedimento automatizado realizado pelo complemento SCP. O grande sucesso dos resultados alcançados pelo algoritmo RF programado (ML) deve-se provavelmente à metodologia de processamento considerando que foram utilizadas 1000 árvores para tomada de decisão. Portanto, quanto maior o número de árvores de decisão definidas para validação das amostras de treinamento/teste, maior a assertividade do mapeamento e melhores serão os parâmetros relativos à qualidade temática.

Como proposta para o desenvolvimento de novos trabalhos, sugere-se a implementação e análise de procedimentos de classificação em função de técnicas de aprendizado profundo (*Deep Learning*, em inglês, ou DL) e redes neurais convolucionais (*Convolutional Neural Networks*, em inglês, ou CNN), a fim de avaliar os resultados referentes à qualidade temática. Outra sugestão é a repetição da metodologia desenvolvida a fim de avaliar imagens com melhor resolução espacial, que sejam disponibilizadas gratuitamente, conforme tendência que tem se tornado mais comum.

REFERÊNCIAS

- AHMAD, W. M.; Amir, W.; GHAZALI, F. M. M.; YAQOOB, M. A. **Basic Statistical Analysis Using RStudio Software**. Penerbit USM, 2023.
- AKIYAMA, T. S.; MARCATO JUNIOR, J.; TOMMASSELLI, A. M. G.; RODRIGUES, T. L.; ESTRABIS, N. V. Orientação Exterior de Imagens CBERS-4/PAN Utilizando Modelos Rigorosos. **Revista Brasileira de Cartografia**, [S. l.], v. 73, n. 2, p. 329–339, 2021. DOI: 10.14393/rbcv73n2-50008. Disponível em: <https://seer.ufu.br/index.php/revistabrasileiracartografia/article/view/50008>. Acesso em: 28 fev. 2022.
- ALMEIDA, C. A. et al. **Metodologia utilizada nos sistemas Prodes e DETER - 2ª edição** (atualizada). 2022.
- ANDERSON, L. O.; YAMAMOTO, M.; CUNNINGHAM, C.; FONSECA, M. G.; FERNANDES, L. K.; PIMENTEL, A.; BROWN, F.; SILVA JUNIOR, C. H. L.; LOPES, E. S. S.; MOREIRA, D. S.; SALAZAR, N.; ANDERE, L.; ROSAN, T. M.; REIS, V.; Utilização de dados orbitais de focos de calor para caracterização de riscos de incêndios florestais e priorização de áreas para a tomada de decisão. **Revista Brasileira de Cartografia**, [S. l.], v. 69, n. 1, 2017. DOI: 10.14393/rbcv69n1-44038. Disponível em: <https://seer.ufu.br/index.php/revistabrasileiracartografia/article/view/44038>. Acesso em: 6 jun. 2023
- ANDRADE, Ricardo Guimarães et al. Recuperação de pastagens no cerrado. **Agroanalysis**, v. 36, n. 2, p. 30-32, 2016.
- ARAGÃO, L. E. Utilização de dados orbitais de focos de calor para caracterização de riscos de incêndios florestais e priorização de áreas para a tomada de decisão. **Revista Brasileira de Cartografia**, v. 69, n. 1, 7 jan. 2017. <http://www.seer.ufu.br/index.php/revistabrasileiracartografia/article/view/44038/23289>
- ARIZA-LÓPEZ, F. J. **Calidad en la Producción Cartográfica**. 1. ed. Madrid, Espanha: Editora Ra-Ma, 2002. 389p.
- BARBOSA, I. M.; FERREIRA, M. G. V.; JÚNIOR, M. F. C. The Application of Machine learning to Amazonia-1 satellite power subsystem telemetry prediction. In: **Journal of Physics: Conference Series**. IOP Publishing, 2023. p. 012012. Disponível em: <<https://iopscience.iop.org/article/10.1088/1742-6596/2512/1/012012/pdf>> Acesso em: 11 ago. 2023.
- BARROSO, A. G.; SANO, E. E.; FREITAS, D. M. DE. Identificação de desmatamentos recentes no cerrado utilizando as técnicas de diferença de imagens e índice de queimada por diferença normalizada. **Revista Brasileira de Cartografia**, v. 69, n. 7, 3 ago. 2018. <http://www.seer.ufu.br/index.php/revistabrasileiracartografia/article/view/43996/23247>
- BRAGAGNOLO, Lucimara. **Redes neurais totalmente convolucionais aplicadas à identificação de focos de desmatamento**. 2021.
- BRASIL, I. B. G. E. **Instituto Brasileiro de Geografia e Estatística**. Área territorial brasileira 2022. Rio de Janeiro: IBGE, 2023.

BRASIL. **Lei Geral de Proteção de Dados Pessoais (LGPD)**. Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2015-2018/2018/lei/113709.htm> Acesso em: 13/09/2022.

BRASIL. **Lei nº 12.651, de 25 de maio de 2012**. Disponível em: <http://www.planalto.gov.br/ccivil_03/_Ato2011-2014/2012/Lei/L12651.htm>. Acesso em: 31 jan. 2023.

BREIMAN, Leo. **Random forests**. *Machine learning*, v. 45, p. 5-32, 2001.

CALAMITO, A. **A history of open source GIS, from humble beginnings to world changing applications**, 2017. Disponível em: <https://thenewstack.io/humble-beginnings-world-changing-applications-history-open-source-gis/>. Acesso em: 28/02/2023.

CAMARGO, L. S.; SILVA, C.; PIMENTEL, L. C. G.; SILVA, R. W.; BASQUES SOBRINHO, M. A.; LANDAU, L. Geotechnologies as decision support strategies for the identification of fire-susceptible areas in Rio de Janeiro State. **Environmental monitoring and assessment**, v. 194, n. 8, p. 557, 2022.

CAMBRAIA FILHO, Dácio José; BRITES, Ricardo Seixas; DE SOUZA BIAS, Edilson. Potencialidades de aplicação dos índices de vegetação Baseados na Porção Visível do Espectro das Radiações Eletromagnéticas. **Anuário do Instituto de Geociências**, v. 42, n. 4, p. 83-93, 2020.

CHUVIECO, E. A.; YEBRA, I.; NIETO M.; SALAS, H.; MARTIN, J.; VILAR, M.P.; MARTÍNEZ, L.; MARTÍN, J.; IBARRA, S.; DE LA RIVA, P.; BAEZA, J.; RODRIGUEZ, J.; MOLINA, F.; HERRERA, J. R.; ZAMORA, M. A. Development of a framework for fire risk assessment using remote sensing and geographic information system Technologies. **Ecological Modelling** 221: 46-58, 2010.

CHUVIECO, E.; ALLGOWER, B.; SALAS, F. J. Integration of Physical and Human factors in fire danger assessment. In: Chuvieco, E. (Ed.) *Wildland Fire Danger Estimation and Mapping*. **The role of Remote Sensing Data**. World Scientific Publishing, Singapore. Pp. 197 – 218, 2003.

CHUVIECO, E.; CONGALTON, R. G. Application of remote sensing and geographic information systems to forest fire hazard mapping. **Remote Sensing of Environment**. New York, v. 29. p. 147-159, 1989

CHUVIECO, E.; SALAS, F. J.; RODRIGUEZ, J.; SILVA, L. Integrated fire risk mapping. In Chuvieco, E. (Ed.). **Remote Sensing of Large Wildfires in the European Mediterranean Basin**. Berlin, Springer-Verlag. Pp 61-84, 1999.

COCHRAN, William G. **Sampling techniques**. John Wiley & Sons, 1977.

CONCEIÇÃO, K. V. DA; CHAVES, M. E. D.; MATAVELI, G. A. V. Land Use and Land Cover Mapping in a Priority Municipality for Deforestation Control Actions in the Amazon using GEOBIA. **Revista Brasileira de Cartografia**, v. 72, n. 4, p. 574-587, 14 nov. 2020. <http://www.seer.ufu.br/index.php/revistabrasileiracartografia/article/view/53192>

CONGALTON, R.G.; GREEN, K. **Assessing the Accuracy of Remotely Sensed Data: Principles and Practices**. 3a Ed.; Nova York, Boca Raton: CRC Press, 328 p.; 2019.

CONGEDO, L. Semi-Automatic Classification Plugin: A Python tool for the download and processing of remote sensing images in QGIS. **Journal of Open Source Software**, v. 6, n. 64, p. 3172, 2021. Disponível em: < <https://doi.org/10.21105/joss.03172> >. Acesso em: julho de 2023.

DINIZ, Cesar Guerreiro et al. DETER-B: The new Amazon near real-time deforestation detection system. **IEEE Journal of selected topics in applied earth observations and remote sensing**, v. 8, n. 7, p. 3619-3628, 2015.

DOMINGUEZ, David et al. Forecasting amazon rain-forest deforestation using a hybrid machine learning model. **Sustainability**, v. 14, n. 2, p. 691, 2022.

FALEIRO, F.G; NETO, A.L.F. **Savanas: desafios e estratégias para o equilíbrio entre sociedade, agronegócio e recursos naturais**, Planaltina, DF: Embrapa Cerrados, 2008. p.104-169

FARIA, Pedro Duarte; PARGA, João Pedro Figueira Amorim. **Introdução à Linguagem R**. 2020.

FERNANDES, L. C. ; ELMIRO, M. A. T. ; NERO, M. A. ; TEMBA, P. C. . The use of remote sensing techniques by Modis (MCD45A1) images using to identify and evaluate burned areas in the metropolitan region of Belo Horizonte - MG, Brazil. **SUSTENTABILIDADE EM DEBATE**, v. 11, p. 143-157, 2020.

FERNANDES, L. C. ; FERNANDES, R. S. C. ; NERO, M. A. ; TEMBA, P. C. . Fire Risk Modeling Using Artificial Neural Networks. In: Rodrigues, H. C.; Herskovits, J. ; Mota Soares, C. M. ; Araújo, A. L. ; Guedes, J. M.; Folgado, J. O.; Moleiro, F.; Madeira, J. F. A.. (Org.). Eng Opt 2018 Proceedings of the 6th International Conference on Engineering Optimization. 1ed. Cham, **Switzerland: Springer Nature** Switzerland AG, 2018a, v. 1, p. 938-948.

FERNANDES, L. C. ; FERNANDES, R. S. C. ; NERO, M. A. ; TEMBA, P. C. . **Modelagem de risco de incêndio utilizando Redes Neurais Artificiais**. In: XXVI JORNADAS DE JÓVENES INVESTIGADORES DE LA AUGM, 2018, Mendoza-Argentina. XXVI JORNADAS DE JÓVENES INVESTIGADORES DE LA AUGM. Mendoza-Argentina: AUGM, 2018b. v. 0. p. 0-0.

FERNANDES, L. C. ; NERO, M. A. ; TEMBA, P. C. ; SOARES FILHO, B. S. **Modelagem De Risco De Incêndios Florestais: Uma Visão Geral**. SODEBRÁS, v. 13, p. 79-84, 2018c.

FERNANDES, L. C.; ELMIRO, M. A. T.; NERO, M. A.; TEMBA, P. C. The use of remote sensing techniques by Modis (MCD45A1) images using to identify and evaluate burned areas in the metropolitan region of Belo Horizonte - MG, Brazil. **Sustentabilidade em Debate**, v. 11, p. 143-172, 2020.

<https://search.ebscohost.com/login.aspx?direct=true&profile=ehost&scope=site&authtype=crawler&jrnl=21777675&AN=145748519&h=tQAxeyXDlvG1lzXgAyKIRzdp5YRK0KgYgdlm%2FyiJqc%2BWtFlbwubmN4CgEnpS6rOxYhgrdKvLLW0NZgm75hPkaw%3D%3D&cr=c>

FERNANDES, L. C.; FERNANDES, R. S. C.; NERO, M. A.; TEMBA, P. C. Fire Risk Modeling Using Artificial Neural Networks In: EngOpt 2018 Proceedings of the 6th

International Conference on Engineering Optimization. 1 ed. Cham, **Switzerland: Springer Nature** Switzerland AG, 2018a, v.1, p. 938-948.

FINEGOLD, Y. et al. Map accuracy assessment and area estimation: a practical guide. Rome: **Food and Agriculture Organization of the United Nations**, 2016.

FLEISS, J. L.; COHEN, J.; EVERITT, B. S. Large sample standard errors of kappa and weighted kappa. **Psychological Bulletin**, v. 72, n. 5, p. 323–327, 1969.

FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS. **Map Accuracy Assessment and Area Estimation: A Practical Guide**. 2016.

FOODY, G. M. Explaining the unsuitability of the kappa coefficient in the assessment and comparison of the accuracy of thematic maps obtained by image classification. **Remote Sensing of Environment**, v. 239, n. January, p. 111630, 2020.

FRAGAL, E.H.; GASPARETTO, N. V. L. Análise comparativa de dados e produtos de sensoriamento remoto com resolução espacial moderada para detecção de áreas queimadas no Parque Nacional de Ilha Grande entre 2007 e 2009. **Boletim Goiano de Geografia**, Goiânia, v. 37, n. 2, 2017. DOI: 10.5216/bgg.v37i2.49156. Disponível em: <https://revistas.ufg.br/bgg/article/view/49156>. Acesso em: 5 jun. 2023.

GRAZIUSO, G. et al. Open-source software tools for strategic noise mapping: a case study. In: **Journal of Physics: Conference Series**. IOP Publishing, 2022. p. 012014. Disponível em: <https://iopscience.iop.org/article/10.1088/1742-6596/2162/1/012014/pdf>. Acesso em: 28 fev. 2023.

GVSIG Asociación. **Manual de Usuário: GVSIG 2.2**. Valencia, Espanha, 2014. 419p. Disponível em: [<http://downloads.gvsig.org/download/gvsig-desktop/dists/2.2.0/docs/gvsig-2.2.0-doc-1.0.0-pt.pdf>]. Acesso em: 28 fev. 2023.

HERRMANN, P. B.; NASCIMENTO, V. F.; FREITAS, M. W. D. de. Sensoriamento Remoto Aplicado à Análise de Fogo em Formações Campestres: Uma Revisão Sistemática. **Revista Brasileira de Cartografia**, [S. l.], v. 74, n. 2, p. 437–458, 2022. DOI: 10.14393/rbcv74n2-63739. Disponível em: <https://seer.ufu.br/index.php/revistabrasileiracartografia/article/view/63739>. Acesso em: 19 jul. 2023.

INSTITUTO BRASILEIRO DE FLORESTAS - IBF. **Bioma Cerrado**. Disponível em: <https://www.ibflorestas.org.br/bioma-cerrado>. Acesso em: 20 jan. 2023.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **AMAZONIA 1: Descritivo da Missão e do Satélite**. São José dos Campos: Instituto Nacional de Pesquisas Espaciais, 2021.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Coordenação Geral de Observação da Terra – DETER**. Disponível em: <http://www.obt.inpe.br/OBT/assuntos/programas/amazonia/deter/deter>. Acesso em: 11 ago. 2023.

JORDANI, Allan Valezi. **Análise diagnóstica do desmatamento em comparação com resultados da fiscalização do IBAMA na região oeste do estado de Mato Grosso**.

KARASIAK, Nicolas. **Dzetsaka Qgis Classification plugin**, 2016. Disponível em: <https://plugins.qgis.org/plugins/dzetsaka/>

KIYOHARA, B. H.; SANO, E. E. Avaliação de dados polarimétricos e de atributos de textura em imagens SAR para discriminar a floresta secundária em uma área de domínio de floresta amazônica. **Ciência Florestal**, v. 33, n. 2, p. e71235-e71235, 2023. Disponível em: <<https://periodicos.ufsm.br/cienciaflorestal/article/download/71235/61102>> Acesso em: 11 ago. 2023.

KLINK, C. A.; MACHADO, R.B. A conservação do Cerrado brasileiro. **Megadiversidade**, v. 1, n. 1, p.147-155, 2005. Disponível em: <https://www.researchgate.net/profile/Ricardo-Machado-4/publication/228342037_A_conservacao_do_Cerrado_brasileiro/links/553a78670cf29b5ee4b64c2f/A-conservacao-do-Cerrado-brasileiro.pdf> Acesso em: 25 jan. 2023.

LACERDA, H. C.; FARIA, A. L. L.; TORRES, F. T. P.; FONSECA, H. P.; SOARES, W. O.; SILVA, M. A. S. Susceptibility to wildfire in a conservation unit located in the transition region of Cerrado and Atlantic Forest Biomes, Brazil. **Ciência Florestal**, Santa Maria, v. 32, n. 1, p. 451-473, 2022. DOI 10.5902/1980509864171. Disponível em: <https://doi.org/10.5902/1980509864171>.

LANDIS, J. R.; KOCH, G. G. The Measurement of Observer Agreement of Categorical **Data. Biometrics**, v. 33, n. 1, p. 159–174, 1977.

LEITE, C. C. S. DE S.; SANTOS, S. M. B. DOS; FRANCA ROCHA, W. DE J. S.; SILVA, A. DE B.; BAPTISTA, G. M. DE M. Análise dos incêndios ocorridos no Parque Nacional da Chapada Diamantina-Bahia em 2008 e 2015 com suporte em índices espectrais de vegetação. **Revista Brasileira de Cartografia**, v. 69, n. 6, 15 jun. 2017. <http://www.seer.ufu.br/index.php/revistabrasileiracartografia/article/view/44315/23397>

LEWIS, K., DE V. BARROS, F., CURE, M. B., DAVIES, C. A., FURTADO, M. N., HILL, T. C., ROWLAND, L. Mapping native and non-native vegetation in the brazilian cerrado using freely available satellite products. **Scientific Reports**, v. 12, n. 1, p. 1588, 2022. Disponível em: <https://www.nature.com/articles/s41598-022-05332-6.pdf> <https://doi.org/10.1038/s41598-022-05332-6>. Acesso em: 22 jun. 2023.

LILLESAND, T. M., KIEFER, R. W. **Remote Sensing and Image Interpretation**, John Wiley & Sons, inc., 2000.

LLANO, X. C. AcATaMa - **QGIS plugin for Accuracy Assessment of Thematic Maps**, 2019, version 3.6.2-Noosa. Disponível em: <https://plugins.qgis.org/plugins/AcATaMa/>, acessado em: julho de 2023.

LOPES, D. de S.; NÓBREGA, R. A. de A.; MACEDO, D. R. Rumo à uma Abordagem Robusta para um Conjunto de Dados de Cobertura Vegetal Multitemporal: 3 Décadas de Mudanças no Piauí, Brasil. **Revista Brasileira de Cartografia**, [S. l.], v. 74, n. 1, p. 197–213, 2022. Disponível em: <https://seer.ufu.br/index.php/revistabrasileiracartografia/article/view/62751>. Acesso em: 28 fev. 2023.

MABUNDA, I. R. dos S.; GUASSELLI, L. A.; NHONGO, E. J. S.; BANDEIRA, B. Estimativa da Biomassa Florestal para Fins Energéticos Utilizando Índices de Vegetação e

Dados de Campo, Distrito de Mabalane – Moçambique. **Revista Brasileira de Cartografia**, [S. l.], v. 73, n. 1, p. 313–328, 2021. DOI: 10.14393/rbcv73n1-46828. Disponível em: <https://seer.ufu.br/index.php/revistabrasileiracartografia/article/view/46828>. Acesso em: 19 jun. 2023.

MACIEL, A. L.; ALVES, D.; SANT'ANNA, S. Análise dos Processos de Desmatamento e Regeneração nas Unidades de Conservação Pertencentes no Vale do Ribeira (SP/PR) por Meio de Classificações de Imagens de Sensoriamento Remoto. **Revista Brasileira de Cartografia**, v. 73, n. 1, p. 261-277, 19 fev. 2021. <http://www.seer.ufu.br/index.php/revistabrasileiracartografia/article/view/55435/31009>

MAIA, F. C.; ALMEIDA, T.; OLIVEIRA, P. L. G. de; FERREIRA, D. V. P.; MÁ, J. C.; CICERELLI, R. E. Avaliação Temporal da Dinâmica de Regeneração da Vegetação em Áreas Queimadas no Pantanal. **Revista Brasileira de Cartografia**, [S. l.], v. 75, 2023. DOI: 10.14393/rbcv75n0a-66772. Disponível em: <https://seer.ufu.br/index.php/revistabrasileiracartografia/article/view/66772>. Acesso em: 22 jun. 2023.

MENDES, R. M.; MATRICARDI, E. A. T.; COUTO JUNIOR, A. F.; PASSO, D. P.; LUIZ, C. H. P.; MIGUEL, E. P. Regularidade ambiental das áreas de reserva legal do Cerrado Brasileiro. **Caminhos de Geografia**, Uberlândia, v. 23, n. 85, p. 330–349, 2022. DOI: 10.14393/RCG238558017. Disponível em: <https://seer.ufu.br/index.php/caminhosdegeografia/article/view/58017>. Acesso em: 11 ago. 2023.

MINAS GERAIS. Polícia Militar. **Comando de Policiamento de Meio Ambiente**. Belo Horizonte, 2022.

MONSERUD, R. A.; LEEMANS, R. Comparing global vegetation maps with the Kappa statistic. **Ecological Modelling**, v. 62, n. 4, p. 275–293, 1992.

MORAES, D. R. V.; FERREIRA NETO, L. C.; COSTA, M. DO S. S.; DE LIMA, A. M. M.; VIEIRA, I. C. G.; FILHO, J. L.; ADAMI, M. Monitoramento de áreas embargadas por desmatamento ilegal. **Revista Brasileira de Cartografia**, v. 70, n. 5, p. 1595-1617, 31 dez. 2018. <http://www.seer.ufu.br/index.php/revistabrasileiracartografia/article/view/44566/pdf>

MOTA JUNIOR, E. R.; TRENTIN, C. B.; SILVA, E. B. da. Expansão de fronteiras agrícolas e transformações no uso e cobertura da terra em áreas circunvizinhas a terras indígenas no Sudeste Mato-grossense. **Caminhos de Geografia**, Uberlândia, v. 24, n. 91, p. 272–286, 2023. DOI: 10.14393/RCG249162476. Disponível em: <https://seer.ufu.br/index.php/caminhosdegeografia/article/view/62476>. Acesso em: 11 ago. 2023.

MUELLER, Charles C.; MARTHA JÚNIOR, Geraldo Bueno. **A agropecuária e o desenvolvimento socioeconômico recente do Cerrado**. SIMPÓSIO NACIONAL CERRADO, v. 9, p. 1-41, 2008.

NASCIMENTO, R. F. F. et al. An assessment of the support vector machine for a CBERS-2 CCD image classification: a case study of a tropical reservoir in Brazil. **Revista Brasileira de Cartografia**, v. 65, p. 431-439, 2013.

NERO, M. A.; FERNANDES, L. C.; FRANCO, D. S. M.; Temba P. C.; **Mapping Forest fire risk areas near conservation units in the metropolitan region of Belo Horizonte-MG and your application in the public politic.** SODEBRÁS, v. 16, p. 115-130, 2021.

https://www.researchgate.net/profile/Marcelo-Nero-2/publication/356764102_MAPPING_FOREST_FIRE_RISK_AREAS_NEAR_CONSERVATION_UNITS_IN_THE_METROPOLITAN_REGION_OF_BELO_HORIZONTEMG_AND_YOUR_APPLICATION_IN_THE_PUBLIC_POLITIC/links/61e01ed75c0a257a6fe6a8d0/MAPPING-FOREST-FIRE-RISK-AREAS-NEAR-CONSERVATION-UNITS-IN-THE-METROPOLITAN-REGION-OF-BELO-HORIZONTEMG-AND-YOUR-APPLICATION-IN-THE-PUBLIC-POLITIC.pdf

NHONGO, E. J. S.; FONTANA, D. C.; GUASSELLI, L. A.; ESQUERDO, J. C. D. M. Caracterização fenológica da cobertura vegetal com base em série temporal NDVI/MODIS na Reserva do Niassa - Moçambique. **Revista Brasileira de Cartografia**, v. 69, n. 6, 15 jun. 2017. <http://www.seer.ufu.br/index.php/revistabrasileiracartografia/article/view/44319/23401>

NORWAY'S INTERNATIONAL CLIMATE AND FOREST INITIATIVE SATELLITE DATA PROGRAM (NICFI) - **Iniciativa Internacional do Clima e Florestas da Noruega.**

Disponível em <<https://www.nicfi.no/>>

OGLI, J. N. O.; MURODILOV, K. T. Use of geo-information systems for monitoring and development of the basis of Web-maps. **Galaxy International Interdisciplinary Research Journal**, v. 11, n. 4, p. 685-689, 2023. Disponível em: <https://giirj.com/index.php/giirj/article/download/5108/5006>. Acesso em: 22 jun. 2023.

OLIVEIRA, A. L. S. ; NERO, M. A. . Application of Fuzzy Logic in Prediction of Fire in João Pessoa City - Brazil. **Communications in Computer and Information Science** (Print), v. 399, p. 323-334, 2013.

OLIVEIRA, A. L. S. ; NERO, M. A. ; TAVARES JUNIOR, J. R. ; CANDEIAS, A. L. B. ; NÓBREGA, R. A. A . Comparação e validação da modelagem espacial de riscos de incêndios considerando diferentes métodos de predição. **Boletim de Ciências Geodésicas**, v. 23, p. 556-577, 2017b.

OLIVEIRA, A. L. S. ; NERO, M. A. **Mapa de análise de risco de incêndios florestais: estudo de caso no município de João Pessoa – Paraíba - Brasil.** In: 9º SINAGEO - Simpósio Nacional de Geomorfologia, 2012, Rio de Janeiro-RJ. Anais do 9º SINAGEO - Simpósio Nacional de Geomorfologia. Rio de Janeiro-RJ, 2012a.

OLIVEIRA, A. L. S. ; NERO, M. A. **Mapeamento de risco de incêndio com a utilização de imagens CBERS e dados vetoriais: estudo de caso em João Pessoa - PB.** In: VI Simpósio Regional de Geoprocessamento e Sensoriamento Remoto (GEONORDESTE), 2012, Aracaju-SE. Anais do VI Simpósio Regional de Geoprocessamento e Sensoriamento Remoto (GEONORDESTE). Aracaju-SE: Editora, 2012b. v. 1. p. 1-1.

OLIVEIRA, A. L. S. **Modelagem espacial de predição de riscos de incêndios com lógica fuzzy, comparação e validação.** 2013. Tese de Doutorado. Dissertation. Federal University of Pernambuco.

<https://repositorio.ufpe.br/bitstream/123456789/10235/1/DISSERTA%c3%87%c3%83O%20Andr%c3%a9%20Lu%c3%adz%20S%c3%a1%20de%20Oliveira.pdf>

OLIVEIRA, A. L. S.; NERO, M. A. Application of Fuzzy Logic in Prediction of Fire in João Pessoa City - Brazil. **Communications in Computer and Information Science (print)**, v.399, p.323 - 334, 2013.

OLIVEIRA, A. L. S.; NERO, M. A.; TAVARES JUNIOR, J. R.; CANDEIAS, A. L. B.; NÓBREGA, R. A. A. Comparação e validação da modelagem espacial de riscos de incêndios considerando diferentes métodos de predição. **Boletim de Ciências Geodésicas**, v. 23, p. 556-577, 2017. <https://www.scielo.br/j/bcg/a/cCmZ54NR87nzKQNGCT7Qsxr/?lang=pt>

OLIVEIRA, G. DE; MORAES, E. C.; SHIMABUKURO, Y. E.; ARAGÃO, L. E. O. E C. DE; MATAVELI, G. A. V. Dados de sensoriamento remoto para o estudo das interações biosfera-atmosfera em ecossistemas amazônicos: uma revisão. **Revista Brasileira de Cartografia**, v. 69, n. 6, 16 jun. 2017a. <http://www.seer.ufu.br/index.php/revistabrasileiracartografia/article/view/44320/23402>

OLIVEIRA, M. T. DE; CASSOL, H. L. G.; GANEM, K. A.; DUTRA, A. C.; PRIETO, J. D.; ARAI, E.; SHIMABUKURO, Y. E. Mapeamento da Vegetação do Cerrado – Uma Revisão das Iniciativas de Sensoriamento Remoto. **Revista Brasileira de Cartografia**, v. 72, p. 1250-1274, 30 dez. 2020. <http://www.seer.ufu.br/index.php/revistabrasileiracartografia/article/view/56591/30760>

OLIVEIRA, R. R. S.; VENTURIERI, A. Mapeamento Automatizado de Tipologias de Paisagem: Mineração de Dados Utilizando o Plugin GeoDMA. **Revista Brasileira de Cartografia**, v. 70, n. 1, p. 258-289, 31 mar. 2018. <http://www.seer.ufu.br/index.php/revistabrasileiracartografia/article/view/45256/24142>

OLIVEIRA, W. L.de;MORAIS, B. R.;NERO, M. A. Avaliação da eficiência dos classificadores de imagem de sensoriamento remoto com variação na resolução espacial. *InterEspaço: Revista de Geografia e Interdisciplinaridade*, v. 8, e202204, 2022. Disponível em: <<http://dx.doi.org/10.18764/2446-6549.e202204>>. Acesso em: 28 out. 2022.

OLOFSSON, Pontus et al. Boas práticas para estimar a área e avaliar a precisão da mudança da terra. **Sensoriamento remoto do ambiente**, v. 148, p. 42-57, 2014.

OSGeo. **Open source GIS history**, 2019. Disponível em: https://wiki.osgeo.org/wiki/Open_Source_GIS_History. Acesso em: 28/02/2022.

PAIVA, Y. R. Y. DE; BAPTISTA, G. M. DE M. Avaliação do Desmatamento em Assentamentos Rurais e Terras Indígenas na Amazônia Legal em 2015, por meio de Modelagem Espectral de Sequestro de Carbono. **Revista Brasileira de Cartografia**, v. 69, n. 7, 3 ago. 2018. <http://www.seer.ufu.br/index.php/revistabrasileiracartografia/article/view/43998/23249>

PAZ, A. M. M. **O povo indígena Yanomami e a sua luta contra a vulnerabilidade**. 2023. Tese de Doutorado. Disponível em: <<https://bibliotecadigital.fgv.br/dspace/bitstream/handle/10438/33843/TESE%20PARA%20ENVIO.pdf?sequence=1>> Acesso em: 11 ago. 2023.

PEREIRA, J. A. S.; TAVARES JUNIOR, J. R. Classificação supervisionada e saldo de radiação para discriminação de alvos de superfície no entorno do reservatório de Itaparica-PE.

Revista Brasileira de Cartografia, v. 69, n. 6, 2017.

<http://www.seer.ufu.br/index.php/revistabrasileiracartografia/article/view/44321/23403>

PLANET TEAM et al. **Planet application program interface**: In space for life on Earth. San Francisco, 2023. Disponível em <<https://www.planet.com/products/basemap/>>

QGIS. **QGIS versão “3.16.5 Hannover”**. Disponível em:

<https://qgis.org/en/site/forusers/alldownloads.html> Acesso em: 10/08/2021.

R CORE TEAM et al. R: **Uma linguagem e ambiente para computação estatística**. Viena, Áustria: R Foundation for Statistical Computing. 2021.

RIBEIRO, José Felipe; WALTER, Bruno Machado Teles. As principais fitofisionomias do bioma Cerrado. **Cerrado: ecologia e flora**, v. 1, p. 151-212, 2008.

https://www.researchgate.net/publication/283072910_As_principais_fitofisionomias_do_bioma_Cerrado/link/5628c21f08ae04c2aeab5d9/download

RIBEIRO, L. A. **Pressão Antrópica e os Riscos de Incêndios Florestais no Município de Novo Mundo, Amazônia Mato-Grossense**. 2009. 132 f. Tese de Doutorado. Universidade Federal do Paraná, Curitiba. 2009.

RIBEIRO, L.; KOPROSKI, L.; STOLLE, L.; LINGNAU, C.; SOARES, R.; BATISTA, A. **Zoneamento de Riscos de Incêndios Florestais para a Fazenda Experimental do Canguiri, Pinhais (PR)**. FLORESTA, Curitiba, PR, v. 38, n. 3, jul./set. 2008.

ROCHA, M. I. S.; NASCIMENTO, D. T. F. Padrões e tendências espaço-temporais da ocorrência de queimadas no Cerrado entre 1999 e 2018. **Boletim Goiano de Geografia**, Goiânia, v. 42, n. 01, 2022. DOI: 10.5216/bgg.v42.70659. Disponível em:

<https://revistas.ufg.br/bgg/article/view/70659>. Acesso em: 5 jun. 2023.

ROSAN, T. M.; ANDERSON, L. O.; VEDOVATO, L. Avaliação da origem de focos de calor em anos de extremos climáticos na Amazônia Brasileira. **Revista Brasileira de Cartografia**, v. 69, n. 4, 8 abr. 2017.

<http://www.seer.ufu.br/index.php/revistabrasileiracartografia/article/view/44331/23413>

RStudio Team. Boston RStudio: **Integrated Development for R**. RStudio, PBC, 2020. Disponível em: <<http://www.rstudio.com/>>

SALAZAR LATORRE, N.; ARAGÃO, L. E. O. E C. DE; ANDRESON, L. O. Impactos de queimadas sobre diferentes tipos de cobertura da terra no leste da Amazônia Legal Brasileira. **Revista Brasileira de Cartografia**, v. 69, n. 1, 7 jan. 2017.

<http://www.seer.ufu.br/index.php/revistabrasileiracartografia/article/view/44039/23290>

SALMONA, Y. B.; PAIVA, A. O.; MATRICARDI, E. A. T. Estimativas futuras de desmatamento e emissões de CO² equivalente no oeste baiano. **Revista Brasileira de Cartografia**, v. 68, n. 7, 20 ago. 2017.

<http://www.seer.ufu.br/index.php/revistabrasileiracartografia/article/view/44367/23446>

SANO, E. E.; MATRICARDI, E. A. T.; CAMARGO, F. F. Land Use and Land Cover Mapping in a Priority Municipality for Deforestation Control Actions in the Amazon using GEOBIA. **Revista Brasileira de Cartografia**, v. 72, p. 1458-1483, 30 dez. 2020.

<http://www.seer.ufu.br/index.php/revistabrasileiracartografia/article/view/56568/30734>

SANTOS, A. R. S.; PELUZIO, T. M. O.; SAITO, N. S. Spring 5.1.2 **Passo a passo: Aplicações práticas**. Alegre, ES: CAUFES, 2010. 153p.

SANTOS, A. R., BARBOSA, M. A., BOLLELI, T., ANJINHO, P. S., ROQUE, R., MAUAD, F. F. **Assessment of Water Ecosystem Integrity (WEI) in a Transitional Brazilian Cerrado–Atlantic Forest Interface**. *Water*, v. 15, n. 4, p. 775, 2023. Disponível em: <https://doi.org/10.3390/w15040775> Acesso em: 22 jun. 2023.

SANTOS, S. M. B. DOS; FRANCA-ROCHA, W. DE J. S.; BENTO-GONÇALVES, A. J.; BAPTISTA, G. M. DE M. Quantificação e avaliação dos focos de calor no Parque Nacional da Chapada Diamantina e entorno no período de 2007 a 2016. **Revista Brasileira de Cartografia**, v. 69, n. 4, 8 abr. 2017. <http://www.seer.ufu.br/index.php/revistabrasileiracartografia/article/view/44329/23411>

SEE, L.; BAYAS, J. L.; SCHEPASCHENKO, D.; PERGER, C.; DRESEL, C.; MAUS, V.; SALK, C.; WEICHSELBAUM, J.; LESIV, M.; MCCALLUM, I. LACO-Wiki: a new online land cover validation tool demonstrated using globeland30 for Kenya. **Remote Sensing**, [S.L.], v. 9, n. 7, p. 754, 22 jul. 2017.

SILVA JÚNIOR, Juarez Antonio; SILVA JÚNIOR, Ubiratan Joaquim; PACHECO, Admilson. Análise de acurácia para o mapeamento de áreas queimadas utilizando uma cena VIIRS 1Km e classificação por Random Forest. **Revista Brasileira de Geografia Física**, v. 14, n. 6, p. 3225-3240, 2021.

SILVA JUNIOR, U. J. da; GONÇALVES, R. M. .; OLIVEIRA, L. M. M. de .; SILVA JÚNIOR, J. A. da. Sensibilidade Espectral dos Índices de Vegetação: GNDVI, NDVI e EVI na Mata Ciliar do Reservatório de Serrinha II – PE, Brasil. **Revista Brasileira de Cartografia**, [S. l.], v. 73, n. 1, p. 17–35, 2021. DOI: 10.14393/rbcv73n1-55252. Disponível em: <https://seer.ufu.br/index.php/revistabrasileiracartografia/article/view/55252>. Acesso em: 19 jul. 2023.

SILVA, A. C. P. ; LOUREIRO, G. Simultaneous and collaborative development of satellites and Information Systems to support their lifecycle processes. **Information Systems**, v. 111, p. 102125, 2023. <https://doi.org/10.1016/j.is.2022.102125>. Acesso em: 22 jun. 2023.

SILVA, Marco Aurélio Oliveira da; LIPORACE, Frederico dos Santos. Detecção automática de nuvem e sombra de nuvem em imagens de sensoriamento remoto. **Boletim de Ciências Geodésicas**, v. 22, p. 369-388, 2016.

SINHA, A.; NIKHIL, S.; AJIN, R.S.; DANUMAH, J.H.; SAHA, S.; COSTACHE, R.; RAJANEESH, A.; SAJINKUMAR, K.S.; AMRUTHA, K.; JOHNY, A.; Marzook, F.; Mammen, P. C.; Abdelrahman, K.; Fnais, M. S.; Abioui, M. **Wildfire risk zone mapping in contrasting climatic conditions: An approach employing AHP and F-AHP models**. *Fire*, v. 6, n. 2, p. 44, 2023. <https://doi.org/10.3390/fire6020044>

SOUZA, G. M.; GURGEL, H. C.; CIAMP, P. M. Análise sazonal da vegetação do cerrado por meio de dados do sensor MODIS no Distrito Federal (Brasil). DOI 10.5216/bgg.v36i3.44555. **Boletim Goiano de Geografia**, Goiânia, v. 36, n. 3, p. 502–520, 2016. DOI: 10.5216/bgg.v36i3.44555. Disponível em: <https://revistas.ufg.br/bgg/article/view/44555>. Acesso em: 5 jun. 2023.

TAN, C.; FENG, Z. **Mapping Forest Fire Risk Zones Using Machine Learning Algorithms in Hunan Province, China.** Sustainability, v. 15, n. 7, p. 6292, 2023. <https://doi.org/10.3390/su15076292>

TAQUARY, Evandro Carrijo et al. **Deep learning para identificação precisa de desmatamentos através do uso de imagens satelitárias de alta resolução.** 2019.

TEURES, Renata Aquinoga; CASTILHO, ACdC. **Relação entre Autos de Infração lavrados pelo IBAMA e detecções do sistema DETER no estado de Mato Grosso.** Proceedings of the Anais XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Curitiba, Brazil, April, v. 30, p. 2980, 2011.

TOMAZONI, Julio Caetano; GUIMARÃES, Elisete. **Introdução ao QGIS: OSGeo4W-3.22.** 7. Oficina de Textos, 2022.

TRUCCHIA, A.; MESCHI, G., FIORUCCI, P.; PROVENZALE, A.; TONINI, M.; PERNICE, U. Wildfire hazard mapping in the eastern Mediterranean landscape. **International Journal of Wildland Fire**, 2023. <https://doi.org/10.1071/WF22138>

VIANA, Silvia Nascimento. **Análise de imagens do satélite ALOS PALSAR para discriminar fitofisionomias do bioma Cerrado: estudo de caso no Parque Nacional da Chapada dos Veadeiros.** 2012.

APENDICE A - Classificação supervisionada em Linguagem R (RStudio)

```

# Classificação Supervisionada de Imagem do Satélite Amazonia-1 utilizando Machine Learning e
linguagem R

# PARTE 1

# 1º ETAPA: ORGANIZAR OS RECURSOS DE TRABALHO

# 1.1 Definir o diretório de trabalho
setwd("C:/Users/... ")

# 1.2 Visualizar o diretório de trabalho
getwd()

# 1.3 Instalar os pacotes
require(reshape2) # Pacote para organização dos dados
require(raster) # Pacote para processamentos de dados espaciais
require(rgdal) # Pacote para processamentos de dados espaciais
require(rgeos) # Pacote para processamentos de dados espaciais
require(ggplot2) # Pacote para elaboração de gráficos
require(dplyr) # Pacote organização e filtro do banco de dados

# 1.4 Importar a imagem para classificação, neste caso denominada "JoaoPinheiro_rec.tif"
img_joaopinheiro = raster::stack("Imagens/JoaoPinheiro_rec.tif") ##abrir com o botão 'tab'

# 1.5 Configurar os nomes das bandas
names(img_joaopinheiro) = c("B1_B", "B2_G", "B3_R", "B4_NIR")

# 1.6 Importar as amostras das classes
amostras = rgdal::readOGR("Amostras/Treinamento.shp")

# 1.7 Apresentar as feições (classes) criadas
plot(amostras)

# 1.8 Plotar as bandas da imagem
plot(img_joaopinheiro)

# 1.9 Informações do datum
print(img_joaopinheiro)

# 1.10 Feições da camada
amostras@data

# 1.11 União dos polígonos por classe, ou seja, usei a coluna Classes
uniao = rgeos::gUnaryUnion(sgeom = amostras, id = amostras$Classe)
print(uniao)

# 2º ETAPA: PRÉ-PROCESSAMENTO DAS AMOSTRAS DE TREINAMENTO

# Extrair as amostras/pixels de cada feição de amostra que foi mapeada no QGis

# 2.1 Definir os arquivos a serem extraídos para atributo
atributos = extract(x = img_joaopinheiro, y = uniao)

# 2.2 Visualizar o atributo
View(atributos[[1]])

# 2.3 Organizar as amostrar em uma tabela
names(uniao) #sempre coloca em ordem alfabética

Agricultura1_Pivo = data.frame(Classe = "Agricultura1_Pivo", atributos[[1]])
Agricultura2 = data.frame(Classe = "Agricultura2", atributos[[2]])

```

```

Agricultura3 = data.frame(Classe = "Agricultura3", atributos[[3]])
Agua = data.frame(Classe = "Agua", atributos[[4]])
Cerrado1 = data.frame(Classe = "Cerrado1", atributos[[5]])
Cerrado2 = data.frame(Classe = "Cerrado2", atributos[[6]])
Pousio = data.frame(Classe = "Pousio", atributos[[7]])
Solo_exposto = data.frame(Classe = "Solo_exposto", atributos[[8]])
Urbana = data.frame(Classe = "Urbana", atributos[[9]])
Vegetacao_arborea = data.frame(Classe = "Vegetacao_arborea", atributos[[10]])

# 2.4 Testar uma classe
print(head(Agua,10))

# 2.5 Compor o arquivo das amostras
amostra_final = rbind(Agricultura1_Pivo, Agricultura2, Agricultura3, Agua, Cerrado1, Cerrado2,
Pousio, Solo_exposto, Urbana, Vegetacao_arborea)

# 2.6 Criar o arquivo já no diretório
write.csv(amostra_final, "Amostras/amostras_extraidas.csv")

# 3º ETAPA: ANÁLISE EXPLORATÓRIA DOS DADOS

# 3.1 Criar a variável
dados_melt = melt(amostra_final)

# 3.2 Plotar os gráficos Boxplot das classes em relação à cada uma das bandas
ggplot(data = dados_melt, aes(Classe, value, fill = Classe)) +
  geom_boxplot() +
  facet_wrap(~variable, scale = "free") +
  theme(panel.grid.major = element_line(colour = "#d3d3d3"),
        panel.grid.minor = element_blank(),
        panel.border = element_blank(),
        panel.background = element_blank(),
        text = element_text(family = "Tahoma"),
        axis.title = element_text(face = "bold", size = 10),
        axis.text.x = element_text(colour = "white", size = 0),
        axis.text.y = element_text(colour = "black", size = 10),
        axis.line = element_line(size = 1, colour = "black")) +
  theme(plot.margin = unit(c(1,1,1,1), "lines"))

# PARTE 2

# 4º ETAPA: INSTALAR OS PACOTES
require(raster) # Possui ferramentas para manipulação e processamento em dados espaciais
require(leaflet) # Possui ferramentas para criação de representação gráfica (mapa cartográfico)
require(randomForest) # Possui as funções para a análise de dados com o algoritmo RandomForest
require(e1071) # Possui as funções para a análise de dados com o algoritmo Support Vector Machine
require(caret) # Possui as funções para a análise de dados com outras ferramentas de machine
learning
require(caTools) # Possui ferramentas que auxiliam na separação de amostras de treinamento e
teste (validação)
require(ggplot2) # Possui ferramentas para elaboração de gráficos

# 5º ETAPA: IMPORTAÇÃO DAS AMOSTRAS PARA TREINAMENTO E TESTE

# 5.1 Importar o arquivo com as amostras
dados = read.table ("C:/Users/.../amostras_extraidas.csv", header = TRUE, sep = ",")[-1]

# 5.2 A função head() mostra as primeiras linhas da tabela de atributos
head(dados)

# 5.3 Checar os tipos de variáveis do banco de dados com a função str()
str(dados)

# Onde está chr, o formato é "character", onde está int, é "integer"

```

```

# 5.4 Transformar a variável "Classe" em factor
dados$Classe = as.factor(dados$Classe)

str(dados)

# 5.5 Seleção aleatória dos dados

set.seed(123) # É a semente para iniciar a geração inicial de números pseudo-aleatórios.

# A função "sample.split" realiza uma separação do banco de dados de forma proporcional
considerando as classes.
selecao_aleatoria = caTools::sample.split(dados$Classe, SplitRatio = 0.7)

# É criado um vetor de TRUE e FALSE, onde está TRUE, as amostras são para treinamento (70%), e
FALSE, para teste (30%).
print(head(selecao_aleatoria, 50))

# 5.6 Separar os dados e salvar
treino = dados[selecao_aleatoria == F,] # O objeto "treino" guarda todas as linhas que são "TRUE"
para treinamento.
teste = dados[selecao_aleatoria,] # O objeto "teste" guarda todas as linhas que são "TRUE" para
treinamento.

print(treino)
print(teste)

# 5.7 Salvar os dados de treino e teste
write.csv(treino, "C:/Users/.../Amostras/dados_treino.csv")
write.csv(teste, "C:/Users/.../Amostras/dados_teste.csv")

# 5.8 Treinar o modelo RF
set.seed(123)

RF1 = randomForest(Classe ~ ., data = treino, ntree = 5, mtry = 3, importance = T)
# utilização de 5 árvores
RF2 = randomForest(Classe ~ ., data = treino, ntree = 1000, mtry = 3, importance = T)
# utilização de 1000 árvores

# 6ª ETAPA: ANÁLISE DAS VARIÁVEIS DO MODELO RF

# 6.1 Importância das Variáveis dos modelos RF
varImpPlot(RF1)
varImpPlot(RF2)

# 7ª ETAPA: VALIDAÇÃO DOS MODELOS

# 7.1 Predição dos modelos
# A função predict() do próprio R serve para prever uma variável resposta a partir de um modelo
específico.
pred_RF1 = predict(RF1, teste)
pred_RF2 = predict(RF2, teste)

# 7.2 Criar a Matriz de Confusão para o modelo Random Forest 1
CM_RF1 = confusionMatrix(data = pred_RF1, reference = teste$Classe)
print(CM_RF1)

# 7.3 Criar a Matriz de Confusão para o modelo Random Forest 2
CM_RF2 = confusionMatrix(data = pred_RF2, reference = teste$Classe)
print(CM_RF2)

# 8ª ETAPA: PREDIZER O MODELO PARA A ÁREA DE ESTUDO

# 8.1 Importar a imagem
img_joaopinheiro = raster::stack("C:/Users/.../Imagens/JoaoPinheiro_rec.tif")

```

```
# 8.2 Identificar os nomes
names(img_joaopinho)

# 8.3 Modificar os nomes das bandas
names(img_joaopinho) = c("B1_B", "B2_G", "B3_R", "B4_NIR")

# 9º ETAPA: PREDIZER EM ARQUIVO RASTER

# 9.1 Criar o raster do arquivo com melhor resultado
RF1_raster = predict(img_joaopinho, RF1)
RF2_raster = predict(img_joaopinho, RF2)

# 9.2 Salvar a melhor classificação em raster
## O melhor resultado obtido foi a classificação do arquivo "RF2.tif"
writeRaster(RF1_raster, "Modelos/class_RF1.tif")
writeRaster(RF2_raster, "Modelos/class_RF2.tif")
```

APÊNDICE B - Avaliação das amostras com o complemento ACATAMA

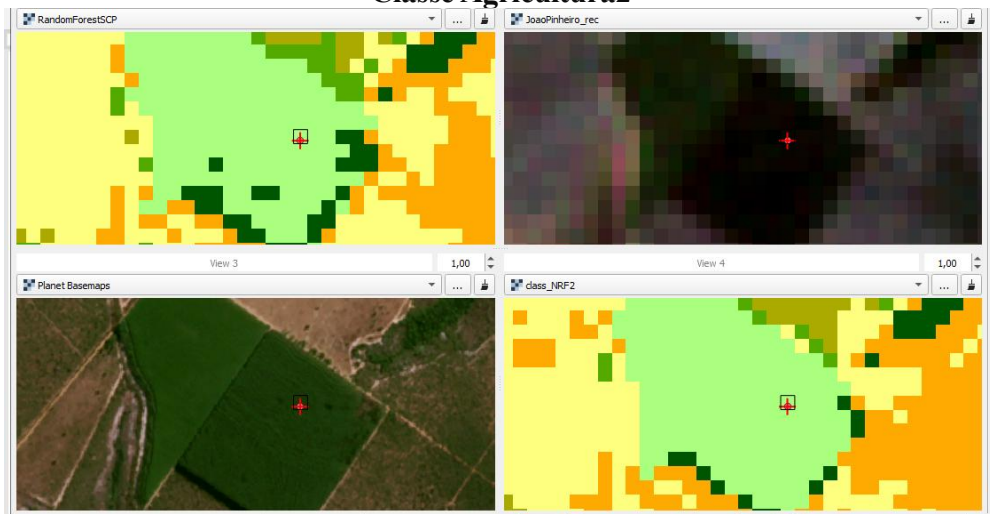
(Classificação com o complemento SCP)

Classe Agricola1



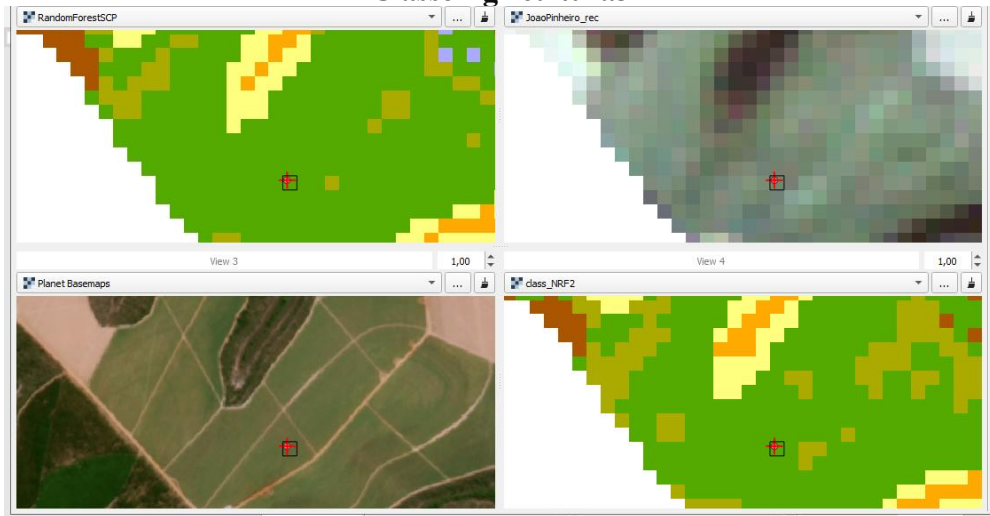
Fonte: Os autores, 2023.

Classe Agricola2



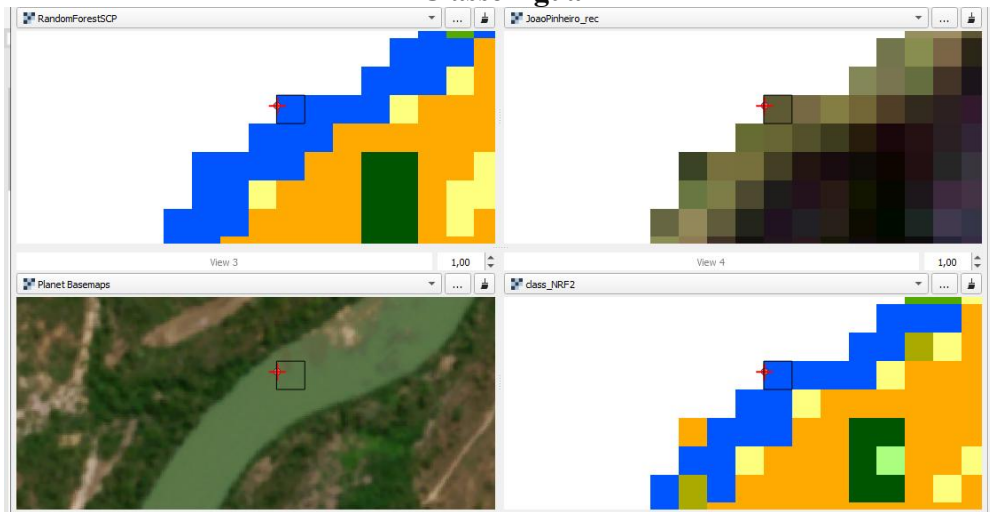
Fonte: Os autores, 2023.

Classe Agricultura3



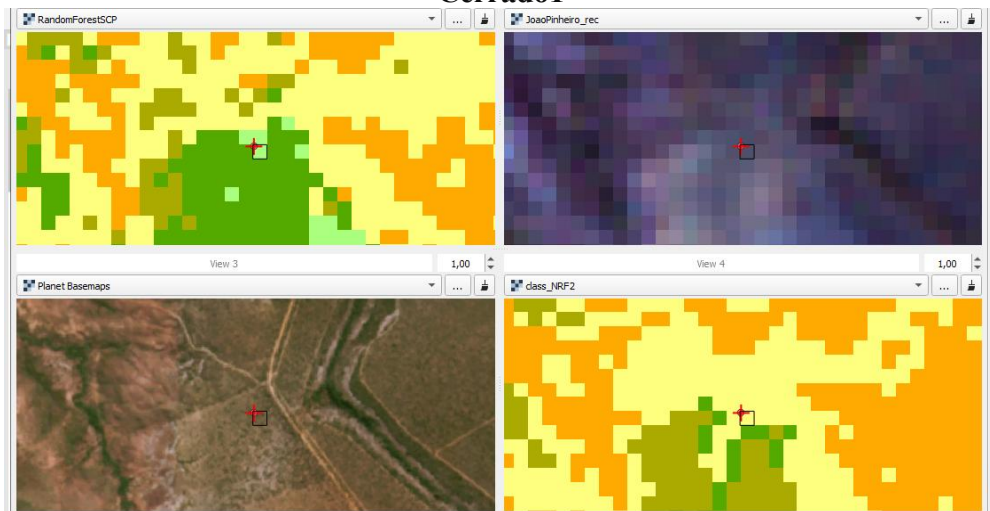
Fonte: Os autores, 2023.

Classe Água



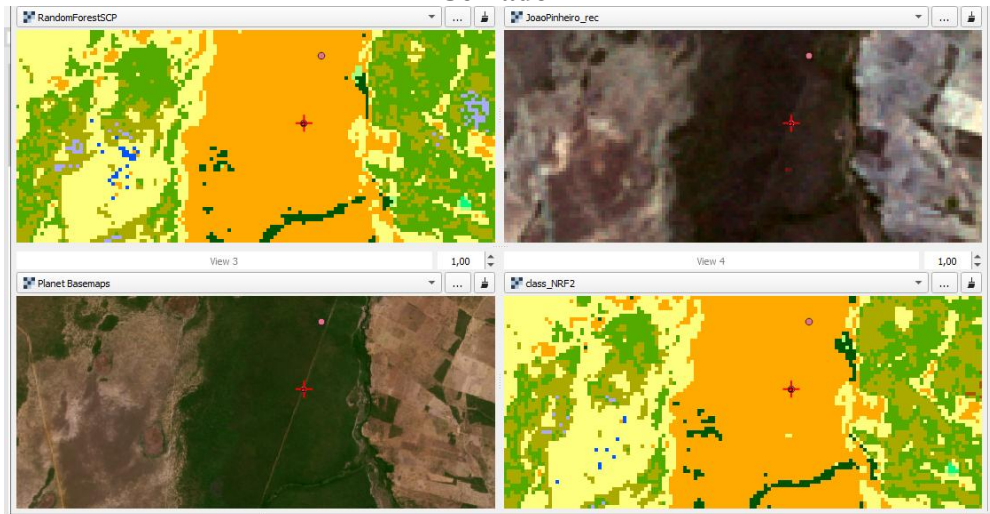
Fonte: Os autores, 2023.

Cerrado1



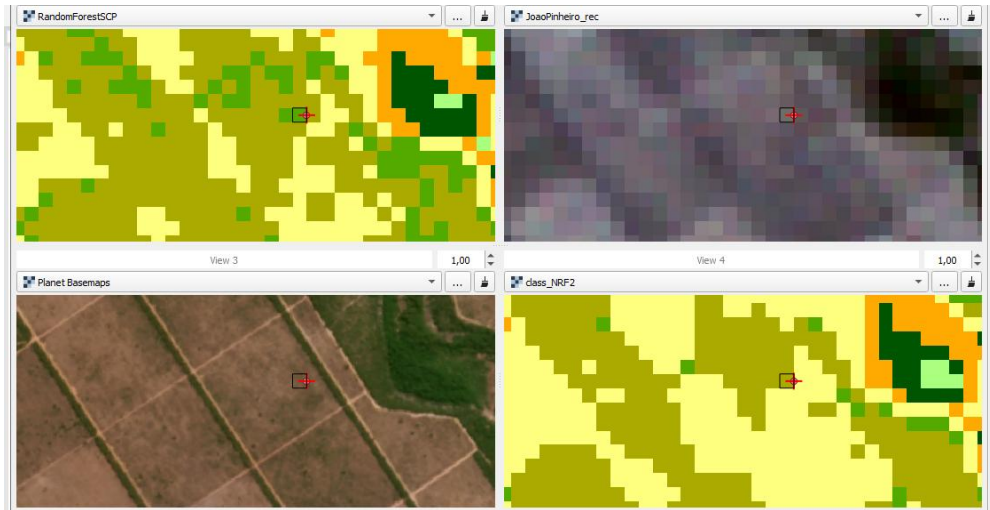
Fonte: Os autores, 2023.

Cerrado2



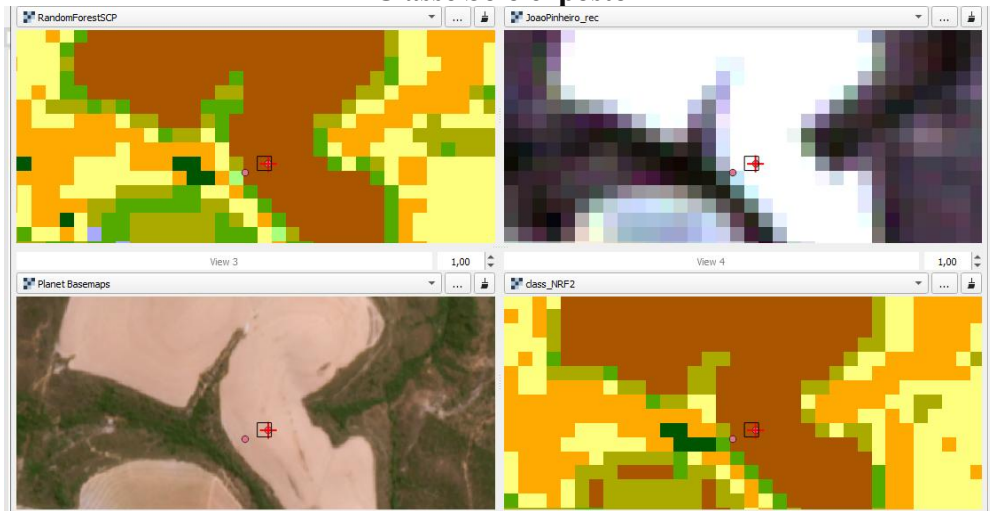
Fonte: Os autores, 2023.

Classe Pousio




Fonte: Os autores, 2023.

Classe Solo exposto



Fonte: Os autores, 2023.

Classe Vegetação arbórea




Fonte: Os autores, 2023.

APÊNDICE C - Avaliação das amostras com o complemento ACATAMA

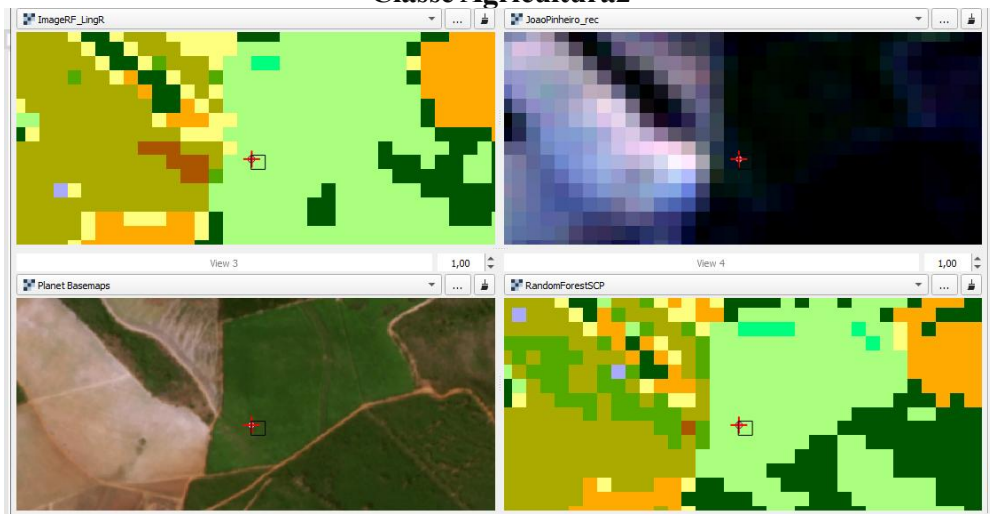
(Classificação com Linguagem R)

Classe Agrícola1



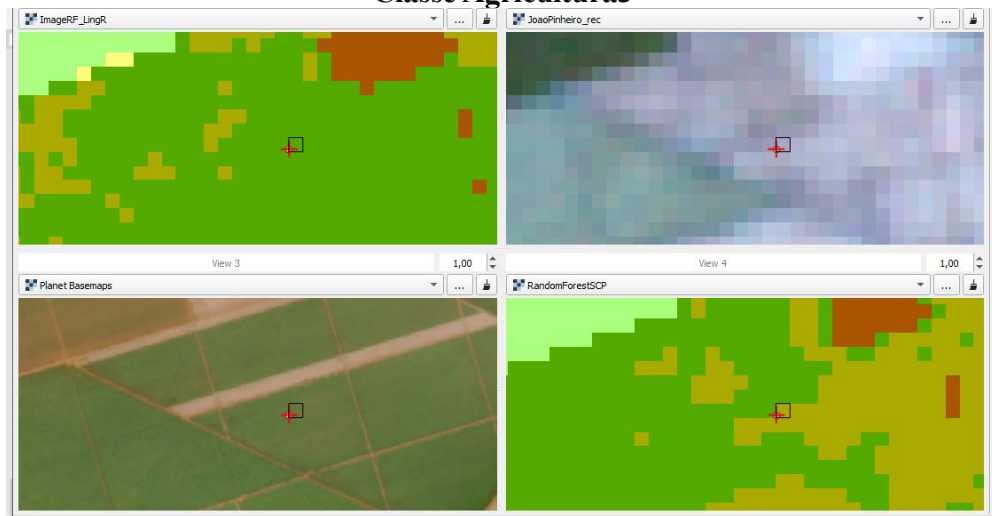
Fonte: Os autores, 2023.

Classe Agrícola2



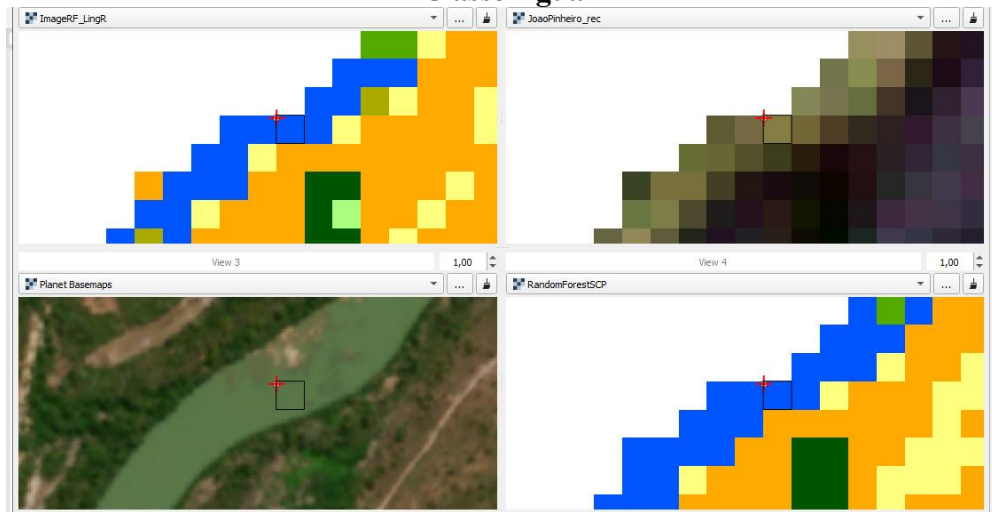
Fonte: Os autores, 2023.

Classe Agricultura3



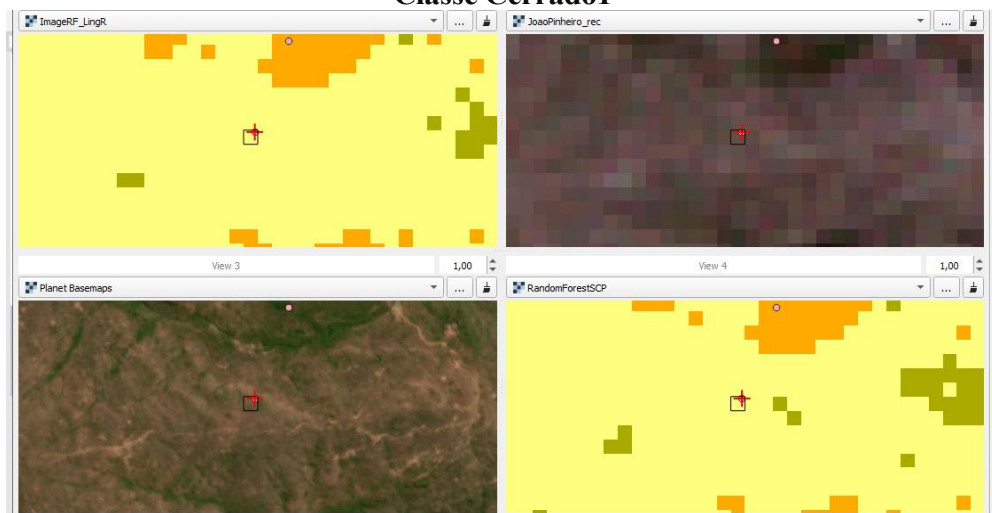
Fonte: Os autores, 2023.

Classe Água



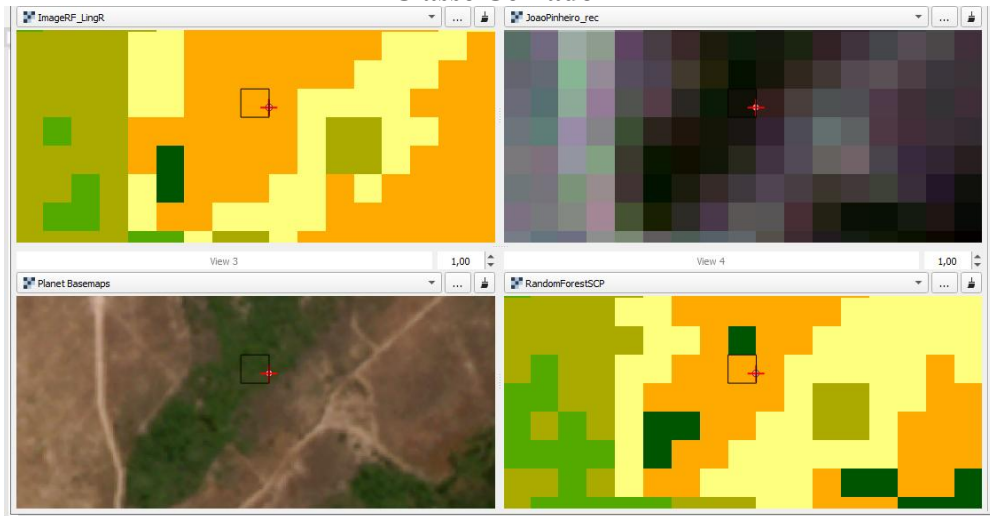
Fonte: Os autores, 2023.

Classe Cerrado1



Fonte: Os autores, 2023.

Classe Cerrado2



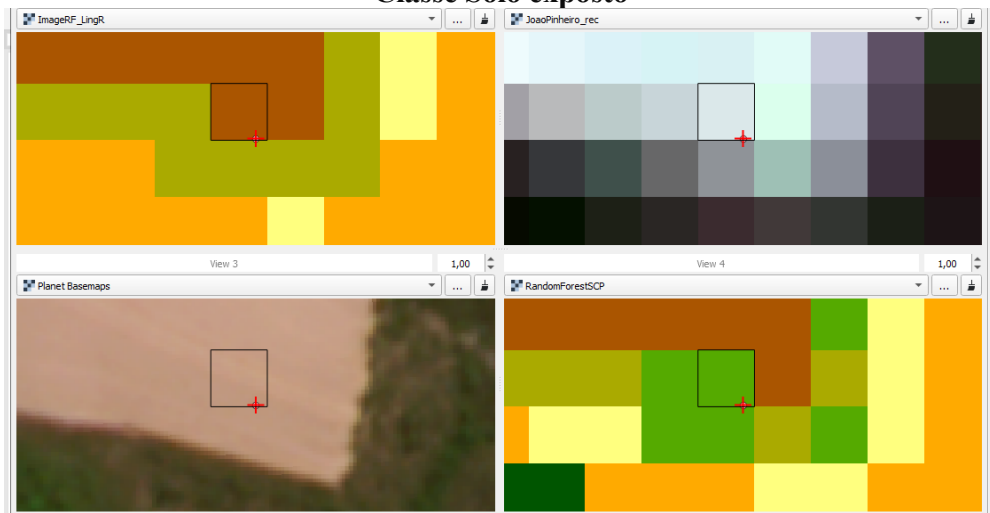
Fonte: Os autores, 2023.

Classe Pousio



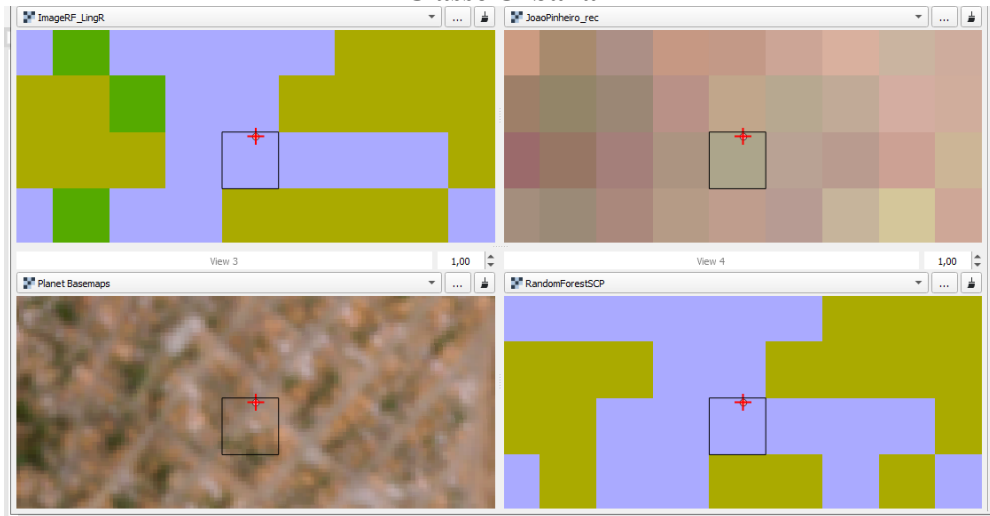
Fonte: Os autores, 2023.

Classe Solo exposto



Fonte: Os autores, 2023.

Classe Urbana



Fonte: Os autores, 2023.

Classe Vegetação arbórea



Fonte: Os autores, 2023.