



UEFS



PPGM

Programa de Pós-Graduação
em Modelagem em Ciências da
Terra e do Ambiente

**UNIVERSIDADE ESTADUAL DE FEIRA DE SANTANA
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM
EM CIÊNCIAS DA TERRA E DO AMBIENTE**

UDMILLA MOURA CONTES FORTUNATO

**DESEMPENHO DE ÍNDICES DE VEGETAÇÃO E ATRIBUTOS TEXTURAIS
NA ANÁLISE ESPAÇO-TEMPORAL E CLASSIFICAÇÃO DO USO E
COBERTURA DA TERRA EM ÁREAS DE ENCLAVES DE CAATINGA**

Feira de Santana/BA

2024

**UNIVERSIDADE ESTADUAL DE FEIRA DE SANTANA
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM
EM CIÊNCIAS DA TERRA E DO AMBIENTE**

UDMILLA MOURA CONTES FORTUNATO

**DESEMPENHO DE ÍNDICES DE VEGETAÇÃO E ATRIBUTOS TEXTURAIS
NA ANÁLISE ESPAÇO-TEMPORAL E CLASSIFICAÇÃO DO USO E
COBERTURA DA TERRA EM ÁREAS DE ENCLAVES DE CAATINGA**

Dissertação apresentada ao Programa de Pós-Graduação *Stricto Sensu* em Modelagem em Ciências da Terra e do Ambiente, da Universidade Estadual de Feira de Santana, como requisito para obtenção do grau de Mestre em Ciências Ambientais.

Orientador: Edson Eyji Sano

Coorientadora: Elane Fiúza Borges

Feira de Santana/BA

2024

Ficha Catalográfica - Biblioteca Central Julieta Carteadó - UEFS

F851d

Fortunato, Udmilla Moura Contes

Desempenho de índices de vegetação e atributos texturais na análise espaço-temporal e classificação do uso e cobertura da terra em áreas de enclaves da Caatinga / Udmilla Moura Contes Fortunato – 2024.

119 f.: il.

Orientador: Edson Eyji Sano

Coorientador: Elane Fiúza Borges

Dissertação (mestrado) – Universidade Estadual de Feira de Santana, Programa de Pós-Graduação em Modelagem em Ciências da Terra e do Ambiente, Feira de Santana, 2024.

1. Vegetação. 2. Sensoriamento remoto. 3. Bioma – Caatinga.
4. PlanetScope. 5. Mucugê, Chapada Diamantina. I. Sano, Edson Eyji, orient. II. Borges, Elane Fiúza, coorient. III. Universidade Estadual de Feira de Santana. IV. Título.

CDU 581(814.22)

Udmilla Moura Contes Fortunato

"Desempenho de índices de vegetação e atributos texturais na análise espaço-temporal e classificação do uso e cobertura da terra em áreas de enclaves de Caatinga"

Dissertação apresentada ao Programa de Pós-Graduação em Modelagem em Ciências da Terra e do Ambiente da Universidade Estadual de Feira de Santana.

Orientador: Prof. Dr. Edson Eyji Sano

Coorientadora: Prof.^a Dr.^a Elane Fiúza Borges

Linha de Pesquisa: Estudos Ambientais e Geotecnologias

Data de aprovação: 02 de agosto de 2024.

BANCA EXAMINADORA:

Documento assinado digitalmente



EDSON EYJI SANO

Data: 02/08/2024 14:39:11-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. Edson Eyji Sano - Orientador
Embrapa Cerrados

Documento assinado digitalmente



ELANE FIUZA BORGES

Data: 14/08/2024 14:48:54-0300

Verifique em <https://validar.iti.gov.br>

Prof.^a Dr.^a Elane Fiúza Borges - Coorientadora
Universidade Estadual de Feira de Santana - UEFS

Documento assinado digitalmente



TAMILIS ROCHA SILVA

Data: 02/08/2024 19:35:43-0300

Verifique em <https://validar.iti.gov.br>

Prof.^a Dr.^a TAMILIS ROCHA SILVA
GIZ Brasil

Documento assinado digitalmente



RODRIGO NOGUEIRA DE VASCONCELOS

Data: 06/08/2024 13:47:42-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. Rodrigo Nogueira de Vasconcelos
Universidade Estadual de Feira de Santana - UEFS

AGRADECIMENTOS

Ao meu Orí, pela escolha de retornar e poder vivenciar novas oportunidades. Pela persistência e crença de se tornar uma pessoa melhor. Referencio minha caminhada na tentativa de cumprir meu destino.

Aos Òrìṣàs e espíritos, pela força, pelo amparo, por enraizar em mim uma fé inabalável e por acompanhar o meu espírito nesta vida.

À Ìyámi Ọṣun, por me aceitar, me amar e fazer reconhecer a grande fortaleza que sou. A senhora dedico todos meus dias no àìye.

Aos meus pais, Tanildes e Wellington, por me concederem no mais puro afeto, carinho e amor. Por entenderem as ausências, estresses, birras e insatisfações. A minha irmã, Natália, por ser confidente e amiga, por me apoiar nos momentos difíceis e por engrandecer nos momentos felizes.

À minha Vó Vanda, a matriarca da família, agradeço a ti por ser base, exemplo de força, de humildade e de adoração. Às minhas tias-mães, Tânia, Branca, Telma e Adalgisa por serem exemplos de uma força incomum, por representarem aquilo que sempre almejei ser em vida. Obrigada pelo apoio, incentivo e por acreditarem em mim. O nosso reencontro nessa vida não foi por acaso.

À Talia, minha namorada, pelo apoio incondicional, pela companhia, pelo incentivo, pelo acalento e por acreditar em mim. É um privilégio dividir novamente a vida com você.

Ao meu orientador, Professor Dr. Edson Sano, pela orientação, paciência e pelas valiosas contribuições ao desenvolvimento deste trabalho. Seu conhecimento e dedicação foram fundamentais para a realização desta dissertação. Sair de cada orientação com uma coisa nova para fazer, apesar de não ter sido fácil, foi gratificante.

À minha coorientadora, Professora Dra. Elane Borges, por me guiar ao caminho da pesquisa e por me apresentar à iniciação científica, caminho que me trouxe até o mestrado. Agradeço também pela atenção, insistência, dedicação e paciência incansável.

Gostaria de expressar minha profunda gratidão à minha banca de dissertação, cujos conhecimentos e orientações foram fundamentais para o desenvolvimento deste trabalho. A Dra. Tamiris Rocha Silva e ao Professor Dr. Washington de Jesus Sant'Anna da Franca Rocha, agradeço imensamente por suas valiosas contribuições, críticas construtivas e sugestões que ajudaram a aprimorar minha pesquisa. O apoio e a experiência de vocês foram cruciais para a realização deste estudo e suas considerações ajudaram a enriquecer

o trabalho de maneira significativa. Agradeço pelo tempo dedicado à leitura e avaliação desta dissertação, bem como pelo apoio durante todo o processo.

Ao professor Ardemiro de Barros Silva, por me apresentar ao mundo do sensoriamento remoto, me despertar as diversas possibilidades de pesquisa nessa área.

Ao Programa de Pós-Graduação em Modelagem em Ciências da Terra e do Ambiente da Universidade Estadual de Feira de Santana, pela oportunidade.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil - (CAPES).

RESUMO

O estudo do desempenho de índices de vegetação e atributos texturais em áreas de enclaves de Caatinga permite uma análise mais precisa das dinâmicas de uso e cobertura da terra. A abordagem espaço-temporal, utilizando dados de sensoriamento remoto, possibilita a identificação de variações na vegetação ao longo do tempo. Nesse viés, analisar o desempenho de índices de vegetação e atributos texturais para discriminação e classificação de classes de uso e cobertura das terras de uma área de enclave da Caatinga, permite avaliar diferentes análises sobre a resposta do bioma às pressões antrópicas e climáticas contribuindo para um mapeamento mais detalhado e eficiente dessas áreas, que historicamente carecem de informações ambientais mais precisas. Para esta pesquisa, desenvolveu-se dois estudos científicos, em formato de artigos, tendo como área de estudo o município de Mucugê, na Chapada Diamantina, Bahia. O primeiro estudo, objetivou avaliar o desempenho de quatro bandas espectrais e três índices de vegetação derivados dos mosaicos mensais do PlanetScope na discriminação de diferentes fitofisionomias de enclaves de Caatinga e culturas agrícolas no município. E, o segundo, analisar o potencial de mosaicos mensais do satélite PlanetScope na classificação de culturas agrícolas temporárias e permanentes. No desenvolvimento dos artigos, utilizaram-se os mosaicos mensais do satélite PlanetScope, os índices de vegetação NDVI, EVI e NGRDI e atributos texturais. Além destes, dados de campo das diferentes fitofisionomias e culturas agrícolas presentes na área de estudo e classificadores supervisionados não-paramétricos, como CART e Random Forest. Os resultados obtidos no primeiro artigo, evidenciaram a sensibilidade dos índices de vegetação e das bandas às áreas de vegetação natural, mesmo durante o período seco. Nas lavouras temporárias, os perfis de IVs exibiram alta amplitude e ciclo de cultivo curto, enquanto nas lavouras permanentes, como o café, houve variações nos perfis devido a diferentes práticas agrícolas. No segundo artigo, os resultados obtidos mostraram alta acurácia global, especialmente durante o período seco, atingindo até 92,03% (AO), com erro estimado de 5,08%, bem como a importância de atributos texturais derivados das quatro bandas espectrais disponíveis (R, G, B, NIR) particularmente a média e a variância na classificação.

Palavras-chave: sensoriamento remoto; PlanetScope; classificação supervisionada; séries temporais; métricas de textura.

ABSTRACT

The study of the performance of vegetation indices and textural attributes in Caatinga enclave areas allows a more precise analysis of land use and land cover dynamics. The spatiotemporal approach, using remote sensing data, allows the identification of variations in vegetation over time. In this context, analyzing the performance of vegetation indices and textural attributes for the discrimination and classification of land use and land cover classes in an enclave area of the Caatinga allows for the evaluation of different analyses on the biome's response to anthropogenic and climatic pressures, contributing to a more detailed and efficient mapping of these areas, which historically lack more accurate environmental information. For this research, two scientific studies were developed, in the form of articles, with the municipality of Mucugê, in Chapada Diamantina, Bahia, as the study area. The first study aimed to evaluate the performance of four spectral bands and three vegetation indices derived from PlanetScope monthly mosaics in discriminating different phytophysognomies of Caatinga enclaves and agricultural crops in the municipality. The second study aimed to analyze the potential of monthly mosaics from the PlanetScope satellite in classifying temporary and permanent agricultural crops. In the development of the articles, the monthly mosaics from the PlanetScope satellite, the vegetation indices NDVI, EVI and NGRDI and textural attributes were used. In addition, field data on the different phytophysognomies and agricultural crops present in the study area and non-parametric supervised classifiers, such as CART and Random Forest, were used. The results obtained in the first article demonstrated the sensitivity of vegetation indices and bands to natural vegetation areas, even during the dry season. In temporary crops, the IV profiles exhibited high amplitude and a short crop cycle, while in permanent crops, such as coffee, there were variations in the profiles due to different agricultural practices. In the second article, the results obtained showed high overall accuracy, especially during the dry period, reaching up to 92.03% (AO), with an estimated error of 5.08%, as well as the importance of textural attributes derived from the four available spectral bands (R, G, B, NIR) particularly the mean and variance in the classification.

Keywords: remote sensing; PlanetScope; supervised classification; time series; texture metrics.

LISTA DE ABREVIACES E SIGLAS

ANN - *Artificial Neural Network*

ASM - Segundo momento angular

CART - *Classification and Regression Trees*

COR – Contraste

ENT – Entropia

ESA - Agncia Espacial Europeia

IBGE – Instituto Brasileiro de Geografia e Estatística

EVI - *Enhanced Vegetation Index*

GEE - *Google Earth Engine*

GLCM - *Gray Level Co-occurrence Matrix*

HOM – Homogeneidade

IAF - Índice de área foliar

IV – Índice de Vegeta

INMET - Instituto Nacional de Meteorologia

IPHAN - Instituto do Patrimnio Histrico e Artístico Nacional

KNN - *k-Nearest Neighbor*

MDE - Modelo digital de eleva

MODIS – *Moderate-Resolution Imaging Spectroradiometer*

MMA – Ministrio do Meio Ambiente

MLP – *Multilayer Perceptron*

MUX - Câmera Multiespectral Regular

NDVI – Índice de Vegeta por Diferena Normalizada

NIFCI - *Norway's International Climate Forests Initiative Satellite Data Program*

NIR - *Near infrared*

NGRDI – *Normalized Green/Red Difference Index*

OA - *Overall Accuracy*

OLI - *Operational Land Imager*

P - *Precision*

PS – *PlanetScope*

R - *Recall*

RF – *Random Forest*

SMA – Segundo momento angular

SNAP - *Sentinel Application Platform*

SEI – Superintendência de Estudos Econômicos e Sociais da Bahia

SR – Sensoriamento Remoto

SVM – *Support Vector Machine*

UEFS – Universidade Estadual de Feira de Santana

LISTA DE FIGURAS

Figura 2.1 - Localização do bioma Caatinga no território brasileiro.....	18
Figura 2.2 - Blocos-diagramas das fisionomias ecológicas da savana-estépica	21
Figura 2.3 - Respostas espectrais da constelação PlanetScope: (a) sensores Dove Classic PS2; (b) Dove-R PS2.SD; e (c) SuperDove PSB.SD.	23
Figura 3.1 – Fluxograma geral das etapas metodológicas desenvolvidas na pesquisa....	33
Figura 3.2 - Mapa de localização do município de Mucugê na Bahia.	34
Figura 3.3 - Climograma da série histórica do município de Mucugê.....	36
Figura 3.4 - Mapa das unidades geomorfológicas do município de Mucugê.	37
Figura 3.5 - Mapa da classificação de solos do município de Mucugê.	39
Figura 3.6 - Mapa de uso e cobertura da terra do município de Mucugê.	40
Figura 3.7 - Produção agrícola no município de Mucugê em 2022.	41
Figura 3.8 - Pontos visitados na campanha de campo e fotografias representativas das fitofisionomias encontradas no município de Mucugê	45
Figura 4.1 - Localização do município de Mucugê/BA no bioma Caatinga	61
Figura 4.2 - Fluxograma das principais etapas metodológicas utilizadas nesse estudo. Fonte:.....	62
Figura 4.3 - Fotografias registradas em trabalho de campo representativas das classes de uso e cobertura da terra encontradas na área de estudo: a) Lavoura Permanente – Café irrigado por gotejamento; b) Lavoura Temporária – batata-inglesa em pivô irrigado; c) Lavoura Temporária – arroz; d) Áreas agrícolas irrigadas com pivô central; e) Savana Estépica Arborizada; f) Savana Estépica Florestada; e g) Campo Rupestre	65
Figura 4.4 - Pontos representativos nos mosaicos mensais do satélite PlanetScope das classes de uso e cobertura da terra encontradas em campo em Mucugê/BA.....	66
Figura 4.5 - Climograma da série histórica de precipitação do município de Mucugê, Bahia.....	67
Figura 4.6 - Assinatura espectro-temporal de NDVI, EVI e NGRDI para fitofisionomia de Savana-Estépica Arborizada no município de Mucugê, Bahia, entre os anos de 2022 a 2024	69
Figura 4.7 - Assinatura espectro-temporal de NDVI, EVI e NGRDI para fitofisionomia de Savana Estépica-Florestada no município de Mucugê, Bahia, entre os anos de 2022 a 2024	70
Figura 4.8 - Assinatura espectro-temporal de NDVI, EVI e NGRDI para a fitofisionomia de Campo Rupestre no município de Mucugê, Bahia, entre os anos de 2022 a 2024. Fonte:	71

Figura 4.9 - Assinatura espectro-temporal de NDVI, EVI e NGRDI para Lavoura Temporária – cultura de arroz irrigado por gotejamento no município de Mucugê, Bahia, entre os anos de 2022 a 2024.....	72
Figura 4.10 - Assinatura espectro-temporal de NDVI, EVI e NGRDI para Lavoura Temporária – cultura de batata-inglesa em pivô irrigado no município de Mucugê, Bahia, entre os anos de 2022 a 2024.....	73
Figura 4.11 - Assinatura espectro-temporal de NDVI, EVI e NGRDI para Lavoura Permanente – café irrigado por gotejamento em área de fazenda no município de Mucugê, Bahia, entre os anos de 2022 a 2024.....	74
Figura 4.12 - Assinatura espectro-temporal de NDVI, EVI e NGRDI para Lavoura Permanente – café irrigado por gotejamento em área de agricultura familiar no município de Mucugê, Bahia, entre os anos de 2022 a 2024.).	75
Figura 4.13 - Dendograma derivado do algoritmo de classificação e regressão CART. Em que: Arborizada = Savana-Estépica Arborizada; Florestada = Savana-Estépica Florestada; Café_AFamiliar = Café Agricultura Familiar; Café_Fazenda = Café em área de fazenda	79
Figura 5.1 - Localização do município de Mucugê/BA no bioma Caatinga.....).	92
Figura 5.2 - Fluxograma das principais etapas metodológicas utilizadas nesse estudo. Fonte: Elaboração dos autores (2004). NCIFI = Norway's International Climate and Forests Initiative; NDVI = Índice de vegetação por diferença normalizada; EVI = Índice de vegetação.	93
Figura 5.3 - Mosaicos mensais do PlanetScope em composição colorida RGB das bandas 3 (vermelho), 4 (NIR), 2 (verde), para o município de Mucugê, Bahia, dos meses de (A) setembro e (B) março.	97
Figura 5.4 - Reflectância de superfície terrestre da classe lavoura temporária (a e b), lavoura permanente (c e d) e vegetação natural (e e f) nos períodos chuvoso e seco. As bandas B, G, R e NIR representam as bandas espectrais do satélite PlanetScope nas faixas azul, verde, vermelho e infravermelho próximo, respectivamente.	100
Figura 5.5 - Índice de vegetação realçado (EVI) da classe lavoura temporária (a e b), permanente (c e d) e vegetação natural (e e f) nos períodos chuvoso e seco.	102
Figura 5.6 - Ranking dos 10 atributos mais importantes para classificação Random Forest dos períodos chuvoso (a) e seco (b). NDVI = índice de vegetação por diferença normalizada; EVI = índice de vegetação realçado.....	103
Figura 5.7 - Resultado da classificação Random Forest para o município de Mucugê, Bahia, para os períodos chuvoso (5.7a) e seco (5.7b).	105
Figura 5.8 - Comparação entre a classificação RF dos dados PlanetScope para o período chuvoso e seco e a classificação do Projeto MapBiomias para o município de Mucugê, Bahia.....	107

LISTA DE TABELAS

Tabela 2.1 - Proposta de classificação de tipologia de Caatinga.....	20
Tabela 2.2 - Faixas espectrais dos sensores PlanetScope da primeira (PS2; lançamento: 2016), segunda (PS2.SD; 2018) e terceira (PSB.SD; 2020) geração.....	23
Tabela 2.3 - Métricas de texturas e características derivadas da GLCM proposta por Haralick <i>et al.</i> , (1973).....	28
Tabela 3.1 - Especificações padrões dos mosaicos de reflectância de superfície PlanetScope	42
Tabela 4.1 - Parâmetros para extração e análise das séries temporais a partir de mosaicos mensais do satélite PlanetScope.....	63
Tabela 4.2 - Resultados das regressões lineares múltiplas considerando as bandas espectrais, os índices de vegetação e as classes preditoras.....	78
Tabela 5.1 - Métricas de textura GLCM e características respectivas.	94
Tabela 5.2 - Parâmetros de entrada para classificaçãoRF	96
Tabela 5.3 - Resultados estatísticos da classificação Random Forest envolvendo quatro bandas espectrais, dois índices de vegetação e 10 combinações possíveis envolvendo os atributos texturais derivados da Matriz de Co-ocorrência de Nível de Cinza (GLCM).	102
Tabela 5.4 - Matriz de confusão da classificação RF do período chuvoso baseado no mosaico mensal de março de 2024 do PlanetScope, para o município de Mucugê, Bahia. Veg = Vegetação; Temp = Lavoura Temporária; Perm = Lavoura Permanente; O.E = erro de omissão; C.E = erro de comissão.	106
Tabela 5.5 - Matriz de confusão da classificação RF do período seco baseado no mosaico mensal de setembro de 2023 do PlanetScope, para o município de Mucugê, Bahia. Veg = Vegetação; Temp = Lavoura Temporária; Perm = Lavoura Permanente; O.E = erro de omissão; C.E = erro de comissão.	106

SUMÁRIO

1. CAPÍTULO 1.....	14
2. CAPÍTULO 2 - FUNDAMENTAÇÃO TEÓRICA	18
2.1. CAATINGA: UM BIOMA EXCLUSIVAMENTE BRASILEIRO	18
2.2. CONSTELAÇÃO DE SATÉLITES DO PLANETSCOPE	21
2.3. ÍNDICES DE VEGETAÇÃO	25
2.4. ATRIBUTOS TEXTURAIS	27
2.5. CLASSIFICADORES POR ÁRVORES DE DECISÃO.....	29
3. CAPÍTULO 3.....	32
REFERÊNCIAS	46
4. CAPÍTULO 4.....	57
4.1. INTRODUÇÃO	58
4.2. MATERIAIS E MÉTODOS	60
4.2.1. ÁREA DE ESTUDO	60
4.2.2. MÉTODOS	61
4.3 RESULTADOS E DISCUSSÃO.....	68
4.3.1. ASSINATURAS ESPECTRO-TEMPORAIS	68
4.3.2. REGRESSÃO LINEAR MÚLTIPLA – AVALIAÇÃO DOS MODELOS PREDITORES	76
4.3.3. AGRUPAMENTO E SEPARABILIDADE DAS CLASSES PREDITORAS	79
4. CONCLUSÃO	81
REFERÊNCIAS	82
5. CAPÍTULO 5.....	87
5.1. INTRODUÇÃO	88
5.2. MATERIAS E MÉTODO	91

5.2.1.	ÁREA DE ESTUDO.....	91
5.2.2.	MÉTODOS	92
5.3	RESULTADOS	98
5.3.1.	ASSINATURAS TEMPORAIS E ÍNDICES DE VEGETAÇÃO	98
5.3.2.	ATRIBUTOS TEXTURAIS	102
5.3.3.	CLASSIFICAÇÃO RANDOM FOREST	104
5.3.4.	AVALIAÇÃO DA ACURÁCIA.....	104
5.3.5.	COMPARAÇÃO COM CLASSIFICAÇÃO MAPBIOMAS.....	107
5.4.	DISCUSSÃO	108
5.5.	CONCLUSÃO.....	111
	REFERÊNCIAS	112
6.	CONSIDERAÇÕES FINAIS	116

1. CAPÍTULO 1

CONSIDERAÇÕES INICIAIS

1.1. CONTEXTUALIZAÇÃO

O sensoriamento remoto tem sido uma fonte primária de dados imprescindíveis para a discriminação, caracterização e mapeamento da vegetação nas mais diferentes escalas cartográficas e geográficas (Bayma; Sano, 2015; Ponzoni; Shimabukuro; Kuplich, 2015; Luz *et al.*, 2021; Hussain *et al.*, 2022; Moraes *et al.*, 2022; Silveira *et al.*, 2022). Atrelado a isto, os estudos de uso e cobertura da terra ganharam destaques em decorrência da crescente preocupação com as dinâmicas das alterações globais e a preservação do meio ambiente, fornecendo diversas contribuições para as análises e avaliações dos impactos ambientais, a citar os provenientes de desmatamentos, da perda da biodiversidade e das alterações climáticas (IBGE, 2013), constituindo-se em informações básicas para o entendimento das manifestações da sociedade, caracterizadas pela distribuição dos elementos biofísicos na superfície terrestre.

Apesar dos avanços no estudo da vegetação, principalmente por técnicas de sensoriamento remoto, a Caatinga é um dos biomas menos estudados pela comunidade científica do Brasil quando comparada com as florestas densas e úmidas (Santos *et al.*, 2011; Medeiros *et al.*, 2022), apesar da relevância e importância no que diz respeito à biodiversidade brasileira (Sobrinho *et al.*, 2016). Enquanto isso, é o terceiro bioma que mais se detectou desmatamento (MapBiomas, 2021), sendo o menos protegido dentre os biomas brasileiros (Santana *et al.*, 2021).

A Caatinga apresenta-se como o mais importante tipo de vegetação do semiárido do Nordeste brasileiro (Santana *et al.*, 2011). Particularidades acerca das condições ambientais e das adaptações das espécies encontradas fazem do bioma um ecossistema com elevada diversidade e endemismo (Japiassú *et al.*, 2016; Sobrinho *et al.*, 2016), haja vista a exclusividade ao território nacional (Trovão *et al.*, 2007). Soma-se a isso, as variações geomorfológicas, climáticas e topográficas que influenciam na constituição de uma paisagem diversificada (Andrade-Lima, 1981) e na ocorrência de ambientes de exceção.

De acordo com Souza e Oliveira (2006), no contexto do semiárido, representado pelas caatingas, os ambientes de exceção apresentam-se como enclaves úmidos e subúmidos, distribuídos de forma dispersa ao longo de superfícies topograficamente elevadas e que representam verdadeiras “ilhas verdes” no domínio morfoclimático da caatinga (Ab’Saber, 2003; Souza; Oliveira, 2006). No geral, tais áreas apresentam temperaturas amenas e melhores condições de umidade quando comparadas às áreas típicas do semiárido.

Ainda assim, os desmatamentos e queimadas ameaçam toda a Caatinga e fazem com que o bioma seja um dos mais sensíveis às alterações climáticas (IPCC, 2014; Ganem *et al.*, 2020), com redução das chuvas e intensificação dos eventos de secas (Barlow *et al.*, 2016). Como consequência de modificações associadas à degradação ambiental e perda de biodiversidade nas últimas décadas (Jardim *et al.*, 2022), a Caatinga apresenta grandes extensões onde a degradação ambiental já se encontra instalada (Souza; Artigas; Lima, 2015), oriunda da intensificação da agricultura, expansão urbana e do avanço de áreas de pastagem que substitui a vegetação natural (Marego; Torres; Alves, 2017; Jardim *et al.*, 2022).

Nesse seguimento, o mapeamento e classificação do uso e cobertura da terra na Caatinga por meio de dados de sensoriamento remoto é uma iniciativa ainda desafiadora, haja vista o seu início tardio e retardatário quando comparado a outros ecossistemas (Ganem *et al.*, 2020) e a variabilidade espacial e espectral das fisionomias. Ainda assim, diferentes ferramentas computacionais têm sido propostas para o processamento e classificação de dados de SR nesse ambiente, tais como os algoritmos de *Maching Learning*, Redes Neurais Artificiais (Silva; Souza; Bacani, 2019), Árvore de Decisão (DT), *Random Forest* (Cardoso *et al.*, 2021; Paula *et al.*, 2022) e *Support Vector Machine* (SVM) (Silva; Souza; Bacani, 2019).

Analogamente, destacam-se os índices de vegetação derivados de séries temporais de imagens para análise da dinâmica espaço-temporal e classificação de uso e cobertura da terra (Borges; Sano, 2014; Ruiz *et al.*, 2022). Associado a isso, as métricas de texturas – brilho, cor, tamanho e formato, vem sendo utilizadas para contornar as singularidades e distinguir feições que apresentem similaridades espectrais, de forma que a sua utilização pode melhorar e potencializar a acurácia de classificações (Sothe *et al.*, 2017; Gonçalves, 2021).

Adicionalmente, os recentes avanços das constelações de satélites, com evolução dos sensores de imageamento, abriram oportunidades para o desenvolvimento de novas

pesquisas neste contexto (Ganem, 2020; Ruiz, 2022). Como exemplo, tem-se a primeira geração da constelação de satélites PlanetScope - PS (*Planet Labs Inc. Dove satellites*), desenvolvendo satélites em miniatura, chamados *smallsats* ou *cubesats*, que podem ser produzidos e lançados mais rápido do que os satélites tradicionais (Frazier; Hemingway, 2021) e que apresentam alta resolução espacial e temporal.

Por essa perspectiva, presume-se que a combinação de dados e imagens de série temporal e alta resolução espacial oferecida pelos satélites da constelação PlanetScope, potencializam a classificação de fitofisionomias e culturas agrícolas inseridas em ambiente de Caatinga. Outrossim, as métricas de textura possibilitam a diferenciação entre as classes, uma vez que se utiliza de padrões essenciais para interpretação e análise de imagens provenientes do SR. Diante disso, os índices de vegetação (IVs) e as métricas texturais podem ser usados como variáveis de entrada para classificar as fitofisionomias naturais e antrópicas, usando, por exemplo, algoritmos de classificação, bem como analisar a dinâmica espaço-temporal das culturas e fitofisionomias. Apesar destas possibilidades, na medida em que se sabe, dados PS ainda não foram avaliados para a classificação das fitofisionomias de Caatinga no Brasil, tão pouco com base no uso de métricas texturais.

1.2. QUESTÃO CIENTÍFICA

Esta dissertação de mestrado pretende abordar a seguinte questão científica: Qual o desempenho de índices de vegetação e atributos texturais derivados de série temporal de imagens da constelação PlanetScope na análise espaço-temporal e classificação do uso e cobertura das terras em áreas de enclaves da Caatinga?

1.3. OBJETIVOS

O objetivo geral deste estudo é analisar o desempenho de índices de vegetação e métricas texturais derivadas das imagens adquiridas pelo satélite PlanetScope para discriminação e classificação de classes de uso e cobertura das terras de uma área de enclave da Caatinga. Como objetivos específicos, têm-se:

- Identificar a resposta sazonal das fitofisionomias da área de estudo a partir de índices de vegetação;

- Avaliar o desempenho de IVs na análise da dinâmica espaço-temporal na área de estudo;
- Analisar o desempenho de índices de vegetação e atributos de textura para a classificação das diferentes classes de culturas agrícolas.

2. CAPÍTULO 2 - FUNDAMENTAÇÃO TEÓRICA

2.1. CAATINGA: UM BIOMA EXCLUSIVAMENTE BRASILEIRO

A Caatinga corresponde a um tipo de domínio fitogeográfico que abrange a maior parte da área com clima semiárido da região Nordeste do Brasil, ocupa 11% do território nacional, 70% da região Nordeste e inclui parte dos estados do Piauí, Ceará, Rio Grande do Norte, Paraíba, Pernambuco, Alagoas, Sergipe, Bahia e Minas Gerais, caracterizando-se como bioma exclusivamente brasileiro (Trovão *et al.*, 2007; Ganem, 2017). A Caatinga faz limite com os biomas Cerrado e Mata Atlântica, o que condiciona a ocorrência de diferentes comunidades ecológicas (Figura 2.1).




Figura 2.1 - Localização do bioma Caatinga no território brasileiro.

O bioma Caatinga é diverso e complexo e tem sido estudado sobre várias perspectivas e abordagens metodológicas (Giulietti *et al.*, 2004; Leal *et al.*, 2005; Alves *et al.*, 2009; Sena, 2011). No entanto, ele ainda se apresenta como um dos biomas menos conhecidos no que diz respeito à sua biodiversidade e fitofisionomias, as quais têm sido descritas como pobres e de baixa relevância ecológica (Tabarelli *et al.*, 2018). Além disso,

ele tem sido um dos biomas menos protegidos por lei, especialmente na forma de unidades de conservação.

Outra característica da Caatinga é a sua carência de dados cartográficos atualizados e detalhados da cobertura vegetal, classificação vegetacional e diversidade biológica (Ganem, 2017), embora alguns estudos prévios tenham demonstrado a relevância da Caatinga para a conservação da biodiversidade brasileira (Leal *et al.*, 2003; 2005). Mesmo assim, a sua vegetação nativa vem sendo cada vez mais fragmentada por causa da acelerada conversão para coberturas antropizadas (Batista, 2011; Coelho *et al.*, 2014). A importância desse bioma se dá devido à heterogeneidade de suas fitofisionomias e da composição florística, identificada de diversas formas e nomenclaturas, tais como agreste, sertão e cariri (Ferri, 1980), os quais são imbricados com base nos fatores ambientais complexos (Rodal; Sampaio, 2002).

A variedade de fitofisionomias é influenciada pelo clima quente e seco e pelo índice pluviométrico baixo e irregular (Ganem, 2017; Fernandes *et al.*, 2021), compondo um mosaico de arbustos espinhosos e florestas secas, com presença de cactáceas e bromélias, plantas espinhosas e decíduais, as quais possuem relação direta com os efeitos da sazonalidade climática, retratado pelas variações nas colorações predominantemente cinza no período seco e verde no chuvoso (Ganem, 2017).

As espécies vegetais estão adaptadas fisiologicamente às condições de estresse hídrico (Trovão *et al.*, 2007; Gariglio *et al.*, 2010; Japiassú *et al.*, 2016), fazendo com que algumas espécies apresentem padrões fenológicos marcados pela rápida renovação das copas em períodos chuvosos e deciduidade de algumas espécies na estação seca. Conforme afirmaram Japiassú *et al.* (2016), a paisagem e a fisiologia das espécies não são tão uniformes quanto aparentam, haja vista que as características do meio físico produzem uma alta diversidade de fitofisionomias que variam desde o estrato gramíneo até o florestal.

De acordo com Silva e Cruz (2018), a Caatinga apresenta diversas classificações de tipologias vegetacionais, desde as que abordam os aspectos biológicos até as que abordam as classificações relacionando vegetação com ambiente. Dentre essas classificações, destaca-se a proposta por Chaves *et al.* (2008) que é baseada nas características morfoestruturais da vegetação. Essa classificação considera quatro níveis categóricos: tipo, grupo, classe e subclasse. Na Tabela 2.1, é possível observar que, nas categorias tipo e grupo, o porte da vegetação é o principal critério de separação dos grupos; e subclasses, que se referem à porcentagem de cobertura vegetal no substrato (Chaves *et al.*, 2008).

Tabela 2.1 - Proposta de classificação de tipologia de Caatinga.

Tipo	Grupo	Subclasse
Vegetação natural de caatinga	Arbóreo (> 4,5 m de altura)	muito densa (> 80% de cobertura)
	Subarbóreo (3 – 4,5 m)	
	Arbustivo (1,5 – 3 m)	densa (60 – 80%)
	Subarbustivo (< 1,5 m)	aberta (40 – 60%); rala (20 – 40%); muito rala (< 20%)

Fonte: adaptado de Chaves *et al.* (2008).

Amplamente utilizada, a classificação proposta no Manual de Vegetação do Brasil (IBGE, 2012) diferencia a Caatinga em subgrupos de acordo com a fitofisionomia savana estépica, denominação também indicada para mencionar tipologias vegetais campestres em geral, com estrato lenhoso decidual e espinhoso.

Na Figura 2.2, é mostrado o perfil esquemático da savana-estépica e as fisionomias classificadas como: (i) Savana Estépica Florestada, estruturada fundamentalmente em dois estratos: superior, com predominância de nanofanerófitas, periodicamente decíduas e mais ou menos adensadas por grossos troncos em geral, profusamente esgalhados e espinhosos ou aculeados; e inferior, predominantemente gramíneo-lenhoso, geralmente descontínuo e de pouca expressão fisionômica; e (ii) Savana Estépica Arborizada, estruturada em um estrato arbustivo-arbóreo superior, esparsos, geralmente de características idênticas ao da Savana Estépica Florestada, e outro inferior, gramíneo-lenhoso e também com elevada importância fitofisionômica (IBGE, 2012).




Figura 2.2 - Blocos-diagramas das fisionomias ecológicas da savana-estépica. Fonte: IBGE (2012).

O subgrupo (iii) Savana Estépica Parque apresenta características fisionômicas muito típicas, com arbustos e pequenas árvores, em geral de mesma espécie, e distribuição bastante espaçada. Afigura-se como uma pseudo-ordenação de plantas lenhosas sobre denso tapete, principalmente de plantas herbáceas e gramíneas; e (iv) Savana Estépica Gramíneo-Lenhosa, também conhecido como campo espinhoso, apresenta características florísticas e fisionômicas bem típicas, ou seja, um extenso tapete gramíneo, salpicado de plantas lenhosas e espinhosas.

2.2. CONSTELAÇÃO DE SATÉLITES DO PLANETSCOPE

Os recentes avanços na observação da Terra proporcionaram o desenvolvimento de nanossatélites com o objetivo de contornar as limitações dos satélites tradicionais em termos de tempo de revisita e resolução espacial (Nagel *et al.*, 2020). Os nanossatélites surgiram do processo de miniaturização de tecnologias de sensores, denominados

CubeSats (Ruiz, 2022). O setor privado é o setor que tem investido no lançamento e operação de CubeSats, com destaque para a empresa americana Planet Labs, fundada em 2010 (Houborg; McCabe, 2018).

A empresa Planet já lançou mais de 200 nanosatélites, oferecendo, de forma pioneira e em escala global, imagens combinando alta resolução espacial e temporal (Cooley *et al.*, 2017; Nagel *et al.*, 2020). O imageamento é feito com visadas a nadir, faixa de imageamento de 24,6 km, resolução espacial de 3,7 m, resolução temporal de 24 horas, resolução radiométrica de 12 bits e vida útil de dois a três anos (Houborg; McCabe, 2018; PlanetLabs, 2022). Todos os satélites estão em órbita sincronizada com o Sol a 475 km e inclinação de 98°. Os satélites cruzam a linha do equador entre 9h30 e 11h30, horário local (Frazier; Hemingway, 2021).

As três primeiras gerações de sistemas ópticos da PlanetScope foram chamadas de Dove Classic, Dove-R e SuperDoves. A cada lançamento, foram efetuadas melhorias, principalmente na resolução espectral das bandas B (*Blue*), G (*Green*), R (*Red*) e NIR (*Near Infrared*). Em 2016, foi lançada a primeira geração de satélite PlanetScope, a Dove-Classic ou PS2, composta pelas bandas R, G, B e NIR, cobrindo as seguintes faixas espectrais: B (455–515 nm), G (500–590 nm), R (590–670 nm) e NIR (780–860 nm). No entanto, como indicado por Frazier e Hemingway (2021), é notória a falta de separação na resposta espectral para as bandas R, G e B (Figura 2.3; Tabela 2.2). A segunda geração de satélites PlanetScope, conhecido como Dove-R ou PS2.SD, foi lançada a partir de 2018. Apesar de ainda cobrirem uma faixa espectral ampla, a resolução espectral foi aprimorada.




Figura 2.3 - Respostas espectrais da constelação PlanetScope: (a) sensores Dove Classic PS2; (b) Dove-R PS2.SD; e (c) SuperDove PSB.SD. Fonte: Frazier & Hemingway (2021).

Tabela 2.2 - Faixas espectrais dos sensores PlanetScope da primeira (PS2; lançamento: 2016), segunda (PS2.SD; 2018) e terceira (PSB.SD; 2020) geração.

PS2	PS2.SD	PSB.SD	
Banda λ (nm)	Banda λ (nm)	Banda λ (nm)	Banda λ (nm)
B 455-515	B 464-517	CB 431-452*	Y 600-620*
G 500-590	G 547-585	B 465-515	R 650-680
R 590-670	R 650-682	GI 513-549*	RE 697-713*
NIR 780-860	NIR 846-888	GII 547-58	NIR 845-883

Fonte: Elaboração da autora (2024).

Em que: λ = Comprimento de onda em nanômetro; B = *Blue* (Azul); G = *Green* (Verde); R *Red* (Vermelho); CB = *Coastal Blue* (Azul costal); GI = *Green I* (Verde I); GII = *Green II* (Verde II); Y = *Yellow* (Amarelo); NIR = *Near Infrared* (Infravermelho próximo); RE = *Red-Edge* (Borda do vermelho); e * indica novas faixas espectrais na terceira geração de sensores PlanetScope. Fonte: adaptado de PlanetLabs (2022).

Em abril de 2019, foi lançado os sensores da terceira geração, o SuperDove ou PSB.SD, que operam com oito bandas. Quatro dessas bandas (Azul, Verde II, Vermelho e NIR) são compatíveis com as bandas do Dove-R (PS2.SD), embora as larguras e os posicionamentos não sejam exatamente os mesmos. As bandas adicionais estão localizadas na faixa do visível (Azul Costal, Verde I, Amarelo e Borda do Vermelho).

Atualmente, são disponibilizados os seguintes produtos derivados da constelação PlanetScope: *Basic Scene Product* (Nível 1B), processados para radiância no topo da atmosfera e com correções geométrica e radiométrica, tamanho de pixel entre 3 m a 4,2 m e acurácia em termos de raiz quadrada do erro médio (RMSE) de menos de 10 m. O segundo produto, o *Ortho Scene Product* (Nível 3B) refere-se ao produto de reflectância no topo da atmosfera ou reflectância da superfície, ortorretificado, com correção de cores e entregues como composições coloridas (RGB) analíticos.

As correções geométricas e radiométricas são disponibilizadas com base nos modelos digitais de elevação (MDE), modelo de transferência radiativa 6SV2.1 e parâmetros recuperados de dados MODIS. As cenas são ortorretificadas como blocos individuais de 25 km × 25 km e tamanho de pixel 3,125 m. O PlanetScope Ortho Tile Product corresponde ao produto de uma mescla de séries consecutivas de imagens individuais de um único satélite, com tamanho de pixel de 3,125 metros, correções radiométricas, imagens ortorretificadas e projetadas para projeção Universal Transversa de Mercator (UTM).

Dentre os diversos produtos disponibilizados pela empresa PlanetLabs, destacam-se também os mosaicos mensais que consistem em imagens ópticas de satélite de alta resolução dos trópicos disponíveis livremente através da *Norway's International Climate Forests Initiative Satellite Data Program* (NIFCI), uma iniciativa do governo norueguês voltada para a preservação das florestas tropicais e a redução das emissões de carbono resultantes do desmatamento e da degradação florestal.

Em suma, os mosaicos de reflectância de superfície PlanetScope são otimizados para análises científicas e quantitativas. Eles oferecem uma representação precisa dos dados, com efeitos atmosféricos e características dos sensores minimizados, proporcionando uma "verdade terrestre" analítica. Incluem uma quarta faixa no espectro próximo ao infravermelho, adequada para diversos índices de vegetação, como NDVI, EVI, e NDWI, sendo assim, considerados ideais para usuários que necessitam monitorar, interpretar ou analisar imagens de satélite cientificamente (PlanetTeam, 2022).

2.3. ÍNDICES DE VEGETAÇÃO

Elementos-chave para monitoramento da fenologia de superfície, os índices de vegetação correspondem a operações espectrais envolvendo razão de duas ou mais bandas espectrais obtidas principais nas faixas espectrais do vermelho e do infravermelho próximo com o objetivo de realçar áreas no terreno cobertas com vegetação (Huete *et al.*, 2002; Ponzoni; Shimabukuro, 2010; Borges, 2014). Esses índices são frequentemente utilizados para estimar parâmetros biofísicos relacionados ao estado da vegetação (biomassa verde, índice de área foliar - IAF, porcentagem de cobertura verde, teor de clorofila) e de mudanças no uso da terra (Jensen, 2009; Ponzoni; Shimabukuro, 2010; Sano *et al.*, 2019).

Com base no potencial e sensibilidade para revelar diferentes características da vegetação, como conteúdo de pigmentos fotossintetizantes, biomassa e estrutura da vegetação, o índice de vegetação por diferença normalizada (NDVI) e o índice de vegetação realçado (EVI) são os dois índices espectrais mais utilizados na literatura. O NDVI (Eq. 1) foi proposto por Rouse *et al.* (1973), tratando-se de uma medida radiométrica adimensional calculada a partir da razão normalizada entre as bandas do infravermelho próximo (NIR) e a banda do vermelho (RED), variando entre -1 e $+1$.

$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \quad (2.1)$$

Em que: $NDVI$ = Índice de Vegetação por Diferença Normalizada; ρ_{NIR} e ρ_{RED} são os fatores de reflectância bidirecional de superfície para as bandas do NIR e Red, respectivamente.

O NDVI apresenta capacidade de discriminar e monitorar mudanças sazonais e interanuais no desenvolvimento e atividade da vegetação, além de reduzir os ruídos

multiplicativos decorrentes das diferenças de iluminação solar e sombras de nuvens, dentre outros (Jensen, 2009). Ele é mais sensível à presença de pigmentos dos processos fotossintéticos, conteúdo de clorofila e estresse hídrico (Risso *et al.*, 2012) e pode ser aplicado em diferentes tipos de vegetação (Huete *et al.*, 1997; Ponzoni; Shimabukuro, 2010). O NDVI apresenta-se como um dos índices mais utilizados no mundo, pois tem boa correlação entre os valores identificados e a biomassa fotossinteticamente ativa (Borges; Sano, 2014). Além disso, o NDVI tem sido utilizado para detectar atividades sazonais e fenológicas, duração, crescimento, pico verde, mudanças fisiológicas das folhas e períodos de senescência (Ponzoni; Shimabukuro, 2010).

Em contrapartida, quando a vegetação se mostra mais densa, com biomassa elevada, o NDVI apresenta problema de saturação do sinal. Em contrapartida, para áreas com cobertura vegetal esparsa, o NDVI apresenta influência da resposta espectral dos solos (Jensen, 2009; Moreira, 2011; Ponzoni *et al.*, 2012). A fim de contornar as limitações presentes no NDVI, Huete *et al.* (2002) propuseram o EVI, expresso pela Equação 2.2, desenvolvido para reduzir a influência dos sinais do solo e da atmosfera.

$$EVI = G \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + C_1 * \rho_{RED} - C_2 * \rho_{BLUE} + L} \quad (2.2)$$

Em que: L = fator de ajuste do solo; G = fator de ganho; e C1 e C2 = coeficientes de ajuste para o efeito atmosférico. Os valores definidos empiricamente pelos autores no cálculo do EVI foram: G = 2,5; C1 = 6; C2 = 7,5; e L = 1 (Huete *et al.*, 1997; Justice *et al.*, 1998).

Por meio do EVI, é possível minimizar interferências atmosféricas, diminuindo as variações de fundo do dossel, tornando possível uma melhor discriminação e quantificação das áreas que contêm vegetações mais densas (Didan; Huete, 2006; Ponzoni; Shimabukuro, 2010), o que o torna favorável para análise de fitofisionomias da Caatinga, que apresenta fitofisionomias espaçadas e em geral dependentes da sazonalidade climática, isto é, com maior interferência do solo exposto (Justice *et al.*, 1998; Carvalho Júnior *et al.*, 2006).

Adicionalmente, tem-se o índice de Diferença Normalizada Verde-Vermelho (NGRDI), de modo geral o índice é indicado para avaliar a saúde da vegetação (Haddad, *et al.*, 2022). É amplamente aplicado ao tratamento de dados para classificação de culturas agrícolas (Sano, *et al.*, 2023), em sua metodologia destaca a diferença na reflectância da

vegetação, distinguindo-as através do estado de saúde das plantas. O índice apresenta alta sensibilidade as variações nos valores na cobertura vegetal, tais características o tornou indicado para manejo e monitoramento de diferentes culturas agrícolas (Freire, *et al.*, 2019). O NGRDI é calculado a partir das bandas espectrais do verde (G) e do vermelho (R) (Equação 3)

$$NGRDI = \frac{\rho G - \rho RED}{\rho G + \rho RED} \quad (2.3)$$

Dentre as aplicações, O NDRDI destaca-se no monitoramento da saúde das culturas de milho em diferentes estágios de crescimento (Johnson; Smith; Thompson, 2020). Os resultados mostraram a alta correlação entre o índice e as medidas de biomassa e índice de área foliar, permitindo a detecção precoce de estresse hídrico e deficiências nutricionais. Adicionalmente, Silva; Oliveira; Santos (2019) aplicaram o NGRDI em imagens de satélite para detectar mudanças na cobertura vegetal em uma floresta tropical. O estudo demonstrou que o NGRDI era eficaz na identificação de áreas desmatadas e na monitoração da recuperação da vegetação após atividades de reflorestamento.

2.4. ATRIBUTOS TEXTURAIS

A textura é um dos elementos de interpretação do sensoriamento remoto utilizado para identificar objetos e alvos de interesse nas imagens de satélite, podendo ser avaliada como lisa, irregular, rugosa e delineada, mostrando-se eficiente para explicar as diferenças espectrais observadas nas imagens por meio de diferenças nas formas de relevo e tipos de dosséis da vegetação (Meneses; Almeida, 2012).

Enquanto as características espectrais descrevem as variações tonais médias em diferentes bandas do espectro eletromagnético, as feições texturais contêm informações de distribuição espacial de níveis de cinza para cada banda, expressa pela variação periódica dos valores digitais, derivados da reflectância dos objetos (Haralick *et al.*, 1973; Meneses; Almeida, 2012). Haralick *et al.* (1973) indicaram que a textura é uma propriedade inata às superfícies e contém informações sobre o arranjo estrutural e sua relação com o ambiente circundante, de forma a se apresentar como útil para discriminação de diferentes alvos.

Dentre os métodos propostos para extrair tais atributos texturais, a matriz de co-ocorrência de níveis de cinza ou *Gray Level Co-occurrence Matrix* (GLCM) proposta por Haralick *et al.* (1973), está entre os mais utilizados (Meneses; Almeida, 2012) e baseia-se na dependência espacial dos níveis de cinza. Esta matriz considera a posição de um pixel em relação a outro pixel. A GLCM é calculada a partir da definição de parâmetros de distância e direção dos pixels (Haralick *et al.*, 1973), de forma que, para cada pixel na imagem, identifica-se o pixel vizinho de acordo com a distância e direção especificadas, de modo que se armazena a probabilidade de que dois valores de intensidades de cinza estejam envolvidos por uma determinada relação espacial. A partir da GLCM, várias métricas ou atributos de textura podem ser calculados. Alguns dos mais comuns e utilizados na literatura podem ser observados na Tabela 2.3.

Tabela 2.3 - Métricas de texturas e características derivadas da GLCM proposta por Haralick *et al.* (1973).

Métrica de textura	Característica	Equação
Contraste	Medida do contraste entre as intensidades de um pixel analisado e do pixel vizinho. A comparação é realizada em todos os pixels da imagem	$\sum_i \sum_j (i - j)^2 p(i, j)$
Homogeneidade	Medida da autocorrelação espacial	$\sum_i \sum_j \frac{p(i, j)}{(1 + i - j)}$
Segundo momento angular	Mede a uniformidade textural, ou seja, repetições em pares de pixels	$\sum_{i,j=0}^{N-1} P(i, j) \cdot (i - j)^2$
Entropia	Mede a informação contida em p, muitos valores nulos representam pouca informação	$-\sum_i \sum_j p(i, j) \log_2 p(i, j)$
Média	Média das intensidades de contraste presentes na matriz de coocorrência	$\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} P(i, j) \times i$
Variância	Mede a dispersão dos níveis de cinza no entorno do pixel central	$\sum_{i,j} p(i, j) (i - \mu_i)^2$

Correlação	A correlação mede a linearidade da relação entre os pixels, avaliando se as intensidades dos pixels variam de forma linear	$\sum_{i,j} \frac{(i-\mu_i)(j-\mu_j)P(i,j)}{\sigma_i\sigma_j}$
------------	--	--

Fonte: Adaptado de Haralick *et al.*, (1973).

Ademais, na análise de imagens de satélites, a GLCM tem diversas aplicações, entre as quais se destacam a detecção de mudanças, análise do comportamento da vegetação, identificação de padrões geológicos e geomorfológicos, classificação de corpos d'água, monitoramento de desastres naturais e classificação de uso do solo e cobertura vegetal. Para estes últimos, Ramajot *et al.*, (2021) combinaram técnicas de sensoriamento remoto com a GLCM para a classificação de florestas. O estudo utilizou imagens de alta resolução e técnicas de aprendizado profundo para melhorar a precisão na classificação de diferentes tipos de vegetação, destacando a utilidade da GLCM na análise textural. Em consonância, Mohammadpour, Viegas e Viegas (2022) identificaram o aumento de 2% na precisão da classificação usando atributos de textura GLCM para mapeamento de vegetação em Portugal, indicando a capacidade das características de textura em detectar a variabilidade de espécies florestais.

2.5. CLASSIFICADORES POR ÁRVORES DE DECISÃO

Os algoritmos de árvores de decisão e aprendizado de máquina tem sido ferramentas metodológicas para tratamento de dados em trabalhos e pesquisas por classificação e regressão, a partir de árvore de decisão (Moore, *et al.*, 2019). Dentre os algoritmos disponíveis o CART (*Classification and Regression Trees*), se destaca por ter uma metodologia eficiente e relativamente simples, é usado tanto para prever uma classificação, quanto para regressão nesse o objetivo é estimar um valor contínuo (Breiman *et al.*, 1984).

O CART cria modelos preditivos sob a forma de árvores de decisão, dentre os parâmetros usados o algoritmo utiliza o índice Gini para a partição binária dos dados. Os nós que serão criados seguiram a variação de 0 a 1, sendo que o objetivo é que os nós estejam mais próximos de 0 do que de 1, os tornando mais homogêneos, assim fomenta a criação de modelos robustos para tarefas de classificação (Breiman *et al.*, 1984). O algoritmo opera de modo a dividir os dados originais em subgrupos, esses grupos irão representar uma hierarquia na árvore de decisão, e possui as seguintes propriedades: no

nó da raiz está todo o conjunto de dados; os subgrupos estarão distribuídos nos nós filhos; os nós folhas por sua vez carregam aqueles dados que não foram distribuídos nos demais subgrupos (Kass, 1980; Breiman *et al.*, 1984).

Em termos práticos, o algoritmo CART é amplamente utilizado em diversos setores. Por exemplo, na pesquisa de mapeamento realizada por Currihuinca *et al.* (2021), o CART foi comparado com outros dois algoritmos para determinar qual apresentava melhor desempenho na separação do Mar de Dunas do Atacama. Os autores relataram resultados variando de intermediários a muito bons nos testes e concluíram que o CART é o melhor algoritmo para a classificação supervisionada. Ainda nessa área, Sefla *et al.* (2021), utilizaram árvores de decisão com os algoritmos C5.0, SMV e CART. Ao final da pesquisa, verificaram que o CART apresentou um ótimo desempenho para a classificação, aumentando significativamente a precisão quando empregada a técnica de Validação Cruzada (CV). Aplicações nas áreas de saúde e ciências sociais também já utilizam da ferramenta como forma de validação, estatística e previsão de dados e fenômenos, a citar Teodoro *et al.* (2021), que abordam como o período da quarentena da Covid-19 afetou a saúde mental de estudante, com amostra de 1957 indivíduos.

Analogamente, o Random Forest (RF) é um algoritmo de aprendizagem de máquina supervisionado que utiliza um conjunto de árvores de decisão para realizar classificações e estimativas por meio de regressão (Breiman, 2001; Maxwell *et al.*, 2018). O RF é um classificador não-paramétrico, isto é, os dados não precisam seguir uma distribuição normal e, por isso, é amplamente utilizado em pesquisas de sensoriamento remoto (Belgiu; Dragut, 2016).

Na construção das árvores de decisão, dois parâmetros são definidos: o número de árvores de decisão a serem geradas (*mtree*) e número de variáveis a serem selecionadas e testadas para a melhor divisão durante o crescimento das árvores (*ntry*) (Belgiu; Dragut, 2016; Haddad, 2022). A construção de uma árvore RF ocorre sobre o nó inicial que contém o conjunto total de amostras divididas em amostras de treinamento e validação (Breiman, 2001). A classificação final é realizada sobre um sistema cujo comportamento das variáveis em associação levam a definição de qual classe determinada combinação de variáveis representa (Breiman, 2001).

O RF é comumente utilizado em mapeamento e classificação de diferentes ambientes e sob distintas metodologias. Como exemplo, pode-se citar o projeto de mapeamento anual do uso e cobertura da terra no Brasil (MapBiomias, 2022a), que utiliza

o classificador para gerar os mapas de diferentes classes de uso e cobertura da terra para todo território brasileiro, de forma que, para cada tema a ser classificado, as máquinas são “treinadas” com amostras dos alvos a serem classificados.

Sano *et al.* (2023) utilizaram o classificador RF para avaliar o uso de atributos texturais derivados do GLCM no mapeamento de sistemas de cultivo de segunda safra e outras classes de uso e cobertura da terra (pastagem cultivada, cana-de-açúcar e vegetação nativa) em ambiente de Cerrado, cujos resultados apontaram para a recomendação do classificador. Kruasilp *et al.* (2023) avaliaram a utilidade dos dados multi-sensor para monitorar mudanças em uso e cobertura da terra na província de Nan, Tailândia, usando um modelo de classificação a partir do RF e da plataforma *Google Earth Engine* (GEE).

Para Caatinga, Alba *et al.* (2022) compararam o potencial dos algoritmos de aprendizado de máquina *k-Nearest Neighbor* (kNN), RF, SVM e *Artificial Neural Networks* (ANN) na identificação das fitofisionomias da Caatinga, constatando que o uso de tais algoritmos é eficiente na identificação de fitofisionomias da Caatinga, com destaque para o RF, o qual englobou melhor a variação dos padrões espectrais dos usos, expressando resultados superiores quando aplicado à identificação de padrões espaciais. Lima *et al.* (2022) promoveram um mapeamento do uso e cobertura do solo na região de Ibiapaba, na Caatinga, utilizando o RF, tornando-se possível verificar a perda da cobertura vegetal entre os anos analisados.

3. CAPÍTULO 3

ABORDAGEM METODOLÓGICA

Na Figura 3.1 são mostradas as principais etapas desenvolvidas neste estudo. Na primeira etapa, destacam-se as disposições gerais da pesquisa, como a definição do tema, a seleção da área de estudo e a aquisição de dados. Essa etapa inclui a utilização de mosaicos mensais de imagens de satélite do PlanetScope e dados de campo, essenciais para a fundamentação teórica e elaboração do mapa de uso e cobertura das terras. Além disso, os índices de vegetação (NDVI, EVI, NGRDI) foram extraídos para compor a série temporal entre 2022 e 2024, fornecendo a base para as análises subsequentes.

Na segunda etapa, foi realizada a elaboração do primeiro artigo, intitulado “Bandas espectrais e índices de vegetação derivados de mosaicos mensais do Planetscope na discriminação de classes de uso e cobertura da terra no município de Mucugê, Chapada Diamantina, Bahia. Essa etapa envolveu a análise dos perfis temporais dos índices de vegetação (NDVI, EVI e NGRDI) extraídos dos mosaicos mensais, juntamente com dados de campo e de precipitação. Com o auxílio do algoritmo CART para classificação e regressão, e a construção de dendograma para o agrupamento de classes, foi possível distinguir as fitofisionomias naturais e as áreas de uso agrícola na Caatinga, utilizando as classes temáticas, como Savana-Estépica Arborizada, Savana-Estépica Florestada, Campo Rupestre, Lavoura Temporária e Lavoura Permanente, conforme mostrado na Figura 3.1.

A terceira etapa, aborda os processos de elaboração do segundo artigo intitulado, “Classificação de culturas agrícolas no município de Mucugê, Chapada diamantina, Bahia a partir de mosaicos mensais do satélite Planetscope”. Nesta etapa, a investigação foca no uso de imagens de satélite e na extração de atributos texturais para a classificação de áreas de uso e cobertura da terra. Foram utilizados dois mosaicos de imagens obtidos pelo satélite PlanetScope, capturados em duas diferentes estações climáticas (seca e chuvosa). A partir desses mosaicos, foram extraídos descritores texturais utilizando a matriz de coocorrência de nível de cinza (GLCM).

Para a classificação, foi aplicado o algoritmo Random Forest, que recebeu como parâmetros de entrada as bandas espectrais, índices de vegetação (NDVI e EVI) e os atributos texturais derivados da GLCM. A avaliação da acurácia foi conduzida através da comparação dos resultados usando a *overlay accuracy* e a matriz de confusão, com o objetivo de delimitar as áreas agrícolas e avaliar a precisão da classificação realizada.




Figura 3.1 – Fluxograma geral das etapas metodológicas desenvolvidas na pesquisa.

3.1. ÁREA DE ESTUDO

A área de estudo compreende o município de Mucugê, localizado na porção central do estado da Bahia (Figura 3.2), entre as coordenadas nos paralelos 13°25'19" S e 12°42'35" S e meridianos 41° 36' 12" O e 41° 25' 19" O, com altitudes que variam de 981 m a 1.568 m (Harley; Simmons, 1986; Roque *et al.*, 2016). Inserido na região da Chapada Diamantina e designada como um dos 27 Territórios de Identidade da BA, o município é limitado a leste com Andaraí, a sul com Ibicoara, a oeste com Abaíra, Piatã e Boninal e a norte com Lençóis, Palmeiras e Seabra. A área de estudo abrange importantes unidades de conservação, notadamente o Parque Municipal de Mucugê, a Reserva Particular do Patrimônio Natural Adília Paraguaçu Batista e o Parque Nacional da Chapada Diamantina (MMA, 2007), o qual abrange cerca de 32% do seu território (Bispo *et al.*, 2022).




Figura 3.2 - Mapa de localização do município de Mucugê na Bahia. Fonte: Autora (2023).

O município de Mucugê é um dos mais antigos da região da Chapada Diamantina (IBGE, 2022) e recebeu este nome, de origem Tupi, em função da vasta presença de uma

fruta de sabor adocicado, cujas árvores cresciam entre as rochas (Medrado, 1998; Amaral, 2022), porém, foram dizimadas pelo processo de intensificação da ação antrópica às margens do rio de mesmo nome (Borges, 2008). Devido à sua importância no processo de exploração de ouro e diamante e a materialização desses processos históricos na paisagem, o município de Mucugê teve o seu conjunto arquitetônico e paisagístico tombado pelo Instituto do Patrimônio Histórico e Artístico Nacional (IPHAN) (Brito, 2018).

Com uma área de aproximadamente 2.462 km² e população de 10.545 habitantes (IBGE, 2022), Mucugê é marcado por ciclos econômicos e sociais onde se destacam a exploração de diamante e ouro no período colonial; a coleta de flores popularmente conhecidas como sempre-vivas – solução imediata para o declínio da economia após a crise da exploração diamantífera; e o avanço do turismo devido às suas belezas cênicas e à grande biodiversidade florística e faunística (Bandeira, 2014).

Nos últimos anos, intensificado pelo estabelecimento do polo agrícola (Agropolo) Mucugê-Ibicoara após a construção da Barragem do Apertado, no Rio Paraguaçu, o agronegócio vem sendo o motor da economia do município, concentrado na produção agrícola de culturas permanentes e temporárias, a citar, hortaliças, batata-inglesa, tomate, cebola, repolho, morango, maracujá, abóbora e pimentão, com a utilização de técnicas e manejos agrícolas sofisticados, maquinários modernos e irrigação por pivô central com a disponibilidade hídrica assegurada principalmente pela barragem (Magalhães Júnior; Winkaler, 2020; IBGE, 2022).

O agronegócio avançou em Mucugê e em outros municípios circunvizinhos devido à combinação de condições sociais e ambientais propícias, tais como mão-de-obra barata, relevo plano, terras abundantes, clima ameno, solos profundos e disponibilidade de água. Sendo assim, a configuração da paisagem do município é resultante da dinâmica e interação entre as feições naturais e antrópicas. No entanto, deve-se destacar as problemáticas associadas a questões sociais e ambientais, de forma que a intensificação da produção agrícola também gera impactos negativos em decorrência do uso do solo e dos rios, distribuição de renda e concentração da propriedade fundiária.

A despeito de estar inserido no domínio morfoclimático da Caatinga (Ab'Saber, 2003), Mucugê não apresenta o clima semiárido como predominante, isto se dá principalmente por questões associadas ao relevo, com predomínio de altitudes elevadas, de forma que 60% da área do município encontra-se acima de 1.000 m de altitude (Borges, 2008). O clima de Mucugê é definido como tropical sub-quento a

subúmido, com pluviosidade anual entre 800 mm a 1.200 mm (Borges, 2008).

Destacam-se os meses de novembro a março, com maior concentração de precipitação e os meses de junho a setembro como os mais secos, mas ainda com regularidade de chuvas (Figura 3.3).




Figura 3.3 - Climograma da série histórica do município de Mucugê. Fonte: ClimaTempo (2023).

As condições topográficas, de umidade e temperatura condicionam um clima ameno, com ocorrência de temperaturas entre 7 °C e 20 °C no inverno e entre 22 °C e 30 °C no verão. As áreas relativamente mais baixas onde podem ser caracterizadas por um microclima relativamente mais quente que muito se assemelha às características do clima semiárido, composta por vegetação de caatinga.

No que tange às características geomorfológicas, pode-se indicar que a área de estudo está situada entre três grandes compartimentos geomorfológicos. Destaca-se a Serra do Sincorá (Figura 3.4), localizada na porção oeste de Mucugê e a segunda maior unidade geomorfológica em termos de extensão territorial, sendo o relevo mais expressivo da área de estudo. A Serra do Sincorá é composta por um conjunto de serras constituídas de blocos deslocados e por falhas da Chapada Diamantina. O relevo é montanhoso com altitudes quase sempre superiores a 800 m e entre 400 m a 600 m nos vales dos principais rios (Cordeiro, 2019).




Figura 3.4 - Mapa das unidades geomorfológicas do município de Mucugê. Fonte: IBGE (2021).

A Serra do Sincorá é marcada por alinhamento quase contínuo de escarpa adaptada à falha e é drenada por rios componentes da bacia do rio Paraguaçu (IBGE, 2021). Destaca-se uma área encravada na Serra do Sincorá, localizada a norte de Mucugê, o Vale do Pati, compartimento geomorfológico que apresenta altitude entre 500 m e 900 m, menor em termos de área, mas constituindo-se em uma feição bastante distinta das que ocorrem no seu entorno.

Observa-se a predominância do Pediplano Central da Chapada Diamantina que compreende grandes extensões de planaltos elevados de topos extensos, tabulares e uniformes, localizados na parte centro sul e oeste da Chapada Diamantina. Apesar de ser relativamente mais rebaixado, quando comparado à Serra do Sincorá, o pediplano apresenta cotas altimétricas de 1.000 m a 1.300 m. Apresenta ainda áreas aplainadas que proporcionam uma paisagem relativamente homogênea (Borges, 2008), sendo, por isso, denominado de Pediplano Cimeiro e de Planalto dos Geraes de Mucugê. Destacam-se os chapadões e platôs com relevo suave-ondulado a plano, cujas superfícies são dissecadas pelo fluxo intenso dos cursos fluviais (Cordeiro, 2019).

Um outro compartimento é a Serra da Borda Ocidental da Chapada Diamantina, situada na porção ocidental. Trata-se da unidade geomorfológica menos expressiva em

termos de extensão territorial na área de estudo. Apresenta relevo montanhoso com elevações residuais escavadas e suspensas cuja altitude é superior a 1.000 m (Cordeiro, 2019; IBGE, 2021). Destaca-se a presença da Serra do Bastião entre o pediplano cimeiro e a depressão, com altitude superior a 1.200 m. Também são notáveis as depressões, situadas entre Serra do Bastião e os Geraes, na região sudoeste do município de Mucugê, onde se encontram as menores altitudes de aproximadamente 500 m a 900 m, cuja vegetação predominante é a caatinga (Borges, 2008).

No que tange às características pedológicas, na área de estudo, são encontrados, em predominância, Latossolos Vermelho-Amarelos, Latossolos Amarelos, Argissolos e Neossolos Litólicos (Figura 3.6). Os Latossolos Vermelho-Amarelos são os de maior abrangência, caracterizados por serem solos bastante intemperizados, profundos, muito evoluídos e apresentam a sequência de horizontes A, B e C (Santos *et al.*, 2018). São, em geral, solos fortemente ácidos, devido à concentração residual de ferro e alumínio, o que implica em baixa fertilidade. Os Latossolos ocorrem em topografias planas a levemente onduladas, principalmente na área do pediplano cimeiro denominada de Geraes de Mucugê. Os Latossolos Amarelos, em geral, apresentam as mesmas características qualificadas principalmente pela coloração que dá nome a esta classe, pela presença de argila. A textura mais comum é a argilosa ou muito argilosa, por isso apresentam boas condições físicas de retenção de umidade e boa permeabilidade (Santos *et al.*, 2018).

Geralmente os Argissolos Vermelho-Amarelos compreendem solos constituídos por material mineral que têm, como características diferenciais, a presença de horizonte B textural derivado da alta concentração de argila. A transição entre os horizontes A e Bt é usualmente clara, abrupta ou gradual, com cores vermelho-amareladas devido à presença da mistura dos óxidos de ferro hematita e goethita (Santos *et al.*, 2018). Em contrapartida, os Neossolos Litólicos são pouco evoluídos, constituídos por material mineral ou por material orgânico, não apresentando nenhum tipo de horizonte B diagnóstico. São, portanto, solos rasos, apresentando alta pedregosidade e porosidade devido ao predomínio do intemperismo físico (Borges, 2008; Santos *et al.*, 2018). Os solos litólicos apresentam contato lítico ou lítico fragmentário, de forma que o horizonte A assenta diretamente sobre a rocha ou sobre um horizonte C.





Figura 3.5 - Mapa da classificação de solos do município de Mucugê. Fonte: IBGE (2021).

A relação entre os conjuntos de elementos apresentados, litologia, compartimentos geomorfológicos e tipologia dos solos, adicionados à hidrografia do município, garantem o estabelecimento e ocorrência das principais classes de uso e cobertura das terras (Figura 3.5). A Formação Savânica destaca-se pela ocorrência de espécies com dossel semi-contínuo, também classificadas como Savana-Estépica Arborizada e Savana Arborizada, essa última caracterizada pela fitofisionomia rala, predominante na região dos Geraes de Mucugê. A Formação Campestre abrange, em maioria, o limiar da Serra do Sincorá, apresentando-se também como vegetação de Refúgio Vegetacional Montano, com predomínio de espécies herbáceas. Espacializada de forma descontínua, a Formação Florestal apresenta vegetação com predomínio de dossel contínuo - Savana-Estépica Florestada, Floresta Estacional Semi-Decidua e Decidua, ocorrendo nas áreas mais elevadas do município.



<https://docs.google.com/document/d/1-H7lcVly3AhBENopcmntThipyzWZA2lRyoBcrBqT-dc/edit> Figura 3.6 - Mapa de uso e cobertura da terra do município de Mucugê. Fonte: MapBiomas (2022a).

As classes antrópicas predominam na parte central, onde existem condições propícias para sua ocorrência, isto é, o relevo homogêneo dos Geraes de Mucugê e o predomínio dos Latossolos. A partir da classificação do Projeto MapBiomas, as classes se subdividem em Pastagem vinculadas à atividade agropecuária; Mosaicos de usos - áreas de uso agropecuário (pastagem e agricultura); Outras lavouras temporárias - áreas ocupadas com cultivos agrícolas de curta ou média duração, geralmente com ciclo vegetativo inferior a um ano, que após a colheita necessitam de novo plantio para produzir; e Outras lavouras perenes - áreas ocupadas com cultivos agrícolas de ciclo vegetativo longo (mais de um ano), que permitem colheitas sucessivas, sem necessidade de novo plantio.

O município apresenta uma diversidade expressiva entre culturas agrícolas (IBGE, 2022). No que tange às culturas permanentes, destacam-se o maracujá e o café, com produção anual de 6.610 t e 4.425 t, respectivamente (Figura 3.7). Apesar de apresentar a maior quantidade produzida em 2021, o maracujá ocupou uma área de plantio menor do que a do café. Quanto às culturas temporárias, em 2021, destaca-se a batata-inglesa, com 277.695 t, fazendo do município o segundo maior produtor do tubérculo no país

(IBGE, 2022). O tomate e a cebola também apresentam destaque, com 68.970 t e 29.028 t, respectivamente.




Figura 3.7 - Produção agrícola no município de Mucugê em 2022. Fonte: IBGE (2023).

3.2. AQUISIÇÃO DOS DADOS PLANETSCOPE E PROCESSAMENTO DA SÉRIE TEMPORAL

Os produtos utilizados nesta pesquisa são os mosaicos do PlanetScope convertidos em reflectância de superfície (Tabela 3.1), os quais incluem correções geométrica, atmosférica e radiométrica (PlanetTeam, 2020). Os mosaicos foram adquiridos por meio do site <https://www.planet.com/> e disponibilizados gratuitamente pela *Norway's International Climate and Forest Initiative* (NICFI), um projeto de parceria da Planet e Noruega - *Planet & NICFI Basemaps for Tropical Forest Monitoring*, que permite o acesso a imagens de alta resolução para áreas tropicais.

Tabela 3.1 - Especificações padrões dos mosaicos de reflectância de superfície PlanetScope.

	Resolução espacial	Resolução espectral	Etapas de processamento	Bits
NORMALIZED ANALYTIC			Normalização	16
	4,77 m	Azul, Verde, Vermelho, Infravermelho	Remoção da linha de costura	
		Próximo	Correção atmosférica	

Fonte: Adaptado de Pandey *et al.* (2023).

Os mapas bases do *analytic normalized* usam os dados de refletância de superfície do PlanetScope como entrada. Um processamento adicional é aplicado para melhorar a consistência espacial e temporal. O PlanetScope usa dois métodos independentes para isso: normalização para reduzir a variabilidade cena a cena e remoção da linha de costura para minimizar os limites da cena para criar os mapas base de refletância de superfície normalizada (Pandey *et al.*, 2021).

A etapa inicial de preparação dos dados consistiu na análise visual das imagens e metadados, com avaliação da presença ou não de nuvens e sombras de nuvens sobre a área de estudo. Adquiriu-se uma série temporal de dois anos, um total de 24 imagens entre os meses de outubro de 2020 a outubro de 2022.

3.3. MAPA DE USO E COBERTURA DAS TERRAS

Para compor a análise da variabilidade espacial das fitofisionomias junto às séries temporais, foram utilizados dados de uso e cobertura da terra provenientes da coleção 8 do Projeto de Mapeamento Anual da Cobertura e Uso do Solo do Brasil (Projeto MapBiomias). Todos os dados e mapas são disponibilizados de forma aberta e gratuita (www.mapbiomas.org), com imagens do acervo derivadas dos satélites Landsat 5, 7 e 8, com resolução espacial de 30 m. O MapBiomias utiliza processamento em nuvem e classificadores automatizados desenvolvidos e operados a partir da plataforma *Google Earth Engine*, tendo melhor aplicação em escalas de até 1:100.000 (MapBiomias, 2022a).

Foram utilizadas as classes de uso e ocupação da terra provenientes do projeto disponíveis para os municípios, sendo elas: Formação Florestal, Formação Savânica, Formação Campestre, Pastagem, Mosaicos de Usos, Área Urbanizada, Outras áreas não vegetadas, Corpo d'água, Lavoura Perene, Outras lavouras perenes e temporárias.

3.4. EXTRAÇÃO DOS ATRIBUTOS TEXTURAIS

Os atributos texturais foram extraídos a partir da série temporal. Como dados de entrada utilizaram-se as quatro bandas disponíveis no Planet (R, G, B e NIR) e os dois índices de vegetação calculados – NDVI e EVI. Para cada imagem foram testadas e geradas os seguintes atributos, Contraste, Dissimilaridade, Homogeneidade, Segundo momento angular (ASM), Máxima probabilidade, Energia, Média, Variância e Correlação derivados da matriz de co-ocorrência dos níveis de cinza (*Grey Level Cooccurrence Matrix* - GLCM). O software SNAP foi utilizado para extração de métricas texturais. No segundo momento, com apoio da literatura (Haralick *et al.*, 1973), identificaram-se os atributos de maior relevância para serem utilizados na classificação.

3.5. ANÁLISE DOS DADOS

O Capítulo 4 objetiva identificar a resposta sazonal das fitofisionomias da área de estudo a partir de índices de vegetação e avaliar o desempenho de IVs na análise da dinâmica espaço-temporal na área de estudo, para tal, realizou-se uma análise exploratória dos perfis espectro-temporais do NDVI e do EVI para cada fitofisionomia durante a estação de crescimento pré-definida. Para avaliar estatisticamente os valores das séries temporais dos índices de vegetação associados às classes, utilizou-se o algoritmo de Classificação e Regressão (CART) (Breiman *et al.*, 1984), que se baseia em uma árvore de decisão. Esse algoritmo examina diferentes formas de particionar os dados

localmente, dividindo-os em segmentos menores (Breiman et al., 1984). De forma complementar, os valores de precipitação acumulada foram utilizados para avaliar as taxas de variação dos índices de vegetação em função dos primeiros eventos de chuva registrados.

No Capítulo 5, foi analisado o desempenho dos índices de vegetação e dos atributos de textura para a discriminação entre diferentes classes de culturas agrícolas. A classificação foi conduzida na linguagem de programação R, utilizando o pacote *randomForest* (Liaw; Wiener, 2002; Breiman, 2001). Os parâmetros *ntree* e *mtry* foram ajustados conforme as variáveis envolvidas, como bandas espectrais, índices de vegetação e atributos de textura. Para a avaliação da classificação das áreas agrícolas, foram testados dois cenários sazonais distintos: 1 – período seco e 2 – período chuvoso.

3.6. VALIDAÇÃO

O desempenho dos modelos do CART foi avaliado por meio de regressão linear múltipla, considerando bandas espectrais, índices de vegetação e classes preditoras. Além disso, foi gerado um dendograma para representar graficamente a árvore de decisão, facilitando a visualização das divisões de dados realizadas pelo modelo.

Para classificação Random Forest, a validação teve como a comparação visual entre a classificação obtida e o mapa de referência de vegetação da área de estudo. A partir do conjunto de pixels de validação, obteve-se as matrizes de confusão, acurácia global, *recall*, *precision* e *F1-score*.

A acurácia global representa a porcentagem total de pixels corretamente classificados. *Recall* compreende a probabilidade de um pixel de determinada classe ser classificado corretamente (erros de omissão). *Precision* é a probabilidade de um pixel atribuído a uma classe ser realmente da classe (erros de comissão) e *F1-score* configura a média harmônica entre *precision* e *recall*, ou seja, a razão entre os erros de comissão e omissão. Essas métricas representam a capacidade da classificação em prever corretamente as classes.

3.7. CAMPANHA DE CAMPO E DADOS DE USO E COBERTURA DA TERRA

Para subsidiar a análise do desempenho da classificação realizou-se uma campanha de campo na área de estudo. A Figura 3.2 apresenta os pontos visitados e algumas feições de uso e cobertura das terras encontradas pelo município. Foram visitados 200 pontos, entre eles, culturas agrícolas de café, cebolas, batata-inglesa e arroz e feições naturais de campo rupestre, savana florestada, arborizada e arbustiva.




Figura 3.8 - Pontos visitados na campanha de campo e fotografias representativas das fitofisionomias encontradas no município de Mucugê. Fonte: Elaboração dos autores. (2024).

Em seguida, para complementar os dados de campo gerou-se um mapa de uso e ocupação das terras, tendo como base coleção 8 do Projeto anual de uso e cobertura do solo Brasil – MapBiomas, com imagens do acervo derivadas dos satélites Landsat 5, 7 e 8, cuja resolução espacial é de 30 m. O MapBiomas utiliza processamento em nuvem e classificadores automatizados desenvolvidos e operados a partir da plataforma *Google Earth Engine*, tendo melhor aplicação em escalas de até 1:100.000 (MapBiomas, 2019).

O projeto nasce da necessidade e possibilidade de mapeamento e de produção de mapas anuais para todo o Brasil de forma significativamente mais barata, rápida e atualizada quando comparado às outras metodologias. Com a capacidade de processamento sem precedentes e um alto grau de automatização do processo, além da participação de uma comunidade de especialistas em cada bioma e temas transversais, o

MapBiomas é hoje um dos maiores contribuidores para o entendimento da dinâmica do uso do solo no Brasil e até mesmo de outros países tropicais (MapBiomas, 2019).

REFERÊNCIAS

AB’SABER, A. N. **Domínios da Natureza**. São Paulo: Ateliê Editorial, 2003.

ALBA, E.; ALEXANDRE, M. L. S.; MARCHESAN, J.; SOUZA, L. S. B.; BEZERRA, A. C.; SILVA, E. A. Comparação entre algoritmos de aprendizado de máquina para a identificação de floresta tropical sazonalmente seca. **Anuário do Instituto de Geociências**, v. 45, 40758, 2022.

ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; GONÇALVES, J. L. M.; SPAVOREK, G. Köppen’s climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2014.

ALVES *et al.* Degradação da Caatinga: Uma investigação ecogeográfica. **Revista Caatinga**, v. 22, n. 3, p. 126-135, 2009.

AMARAL, F. D. A. **O popular em xeque: Arquitetura popular e prática de preservação na cidade de Mucugê, Bahia** (dissertação em mestrado em Arquitetura e Urbanismo). Salvador: Universidade Federal da Bahia, 2022.

ANDRADE-LIMA, D. The caatingas dominium. **Revista Brasileira de Botânica**, v. 4, n. 2, p. 149-153, 1981.

BARLOW, J.; LENNOX, G. D.; FERREIRA, J.; BERENGUER, E.; LEES, A. C.; NALLY, R. M.; THOMSON, J. R.; FERRAZ, S. F. B.; LOUZADA, J.; OLIVEIRA, V. H. F.; et al. Anthropogenic disturbance in tropical forests can double biodiversity loss from deforestation. **Nature**, v. 535, p. 144–147, 2016.

BAYMA, A. P.; SANO, E. E. Séries temporais de índices de vegetação (NDVI e EVI) do sensor MODIS para detecção de desmatamentos no bioma Cerrado. **Boletim de Ciências Geodésicas**, v. 21, p. 797-813, 2015.

BATISTA, J. L. O. Detecção de mudanças da cobertura e uso do solo a partir de índices espectrais de vegetação em ambiente semiárido: Enfoque para o município de Teofilândia, Bahia (dissertação de mestrado em Modelagem em Ciência da Terra e do Ambiente), Feira de Santana: Universidade Estadual de Feira de Santana, 2011, 153 f.

de BEURS, K. M.; HENEGBRY, G. M. Spatio-temporal statistical methods for modelling land surface phenology. In: HUDSON, I. L.; KENTLEY, M. R. (Eds.). **Phenological Research**, Cap. 9, 2010, p. 177-208.

BELGIU, M.; DRAGUT, L. Random Forest in remote sensing: A review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24-31, 2016.

BISPO, C. S.; SANTOS, R. C. G.; MAGALHÃES, R. S.; SANTOS, A. M.; OLIVEIRA, E.; SANTOS, P. S.; LISBOA, G. S.; SILVA, V. A. Dinâmica da ocorrência dos incêndios florestais no Parque Nacional da Chapada Diamantina, Bahia, Brasil. **Conjecturas**, v. 22, n. 13, p. 135–158, 2022.

BRITO, P. V. S.; SANTOS, T. O.; MORAIS, Y. C. B. Análise da sazonalidade da vegetação de Caatinga do município de Petrolina (Pernambuco) a partir de imagens do satélite Landsat 8–OLI. **Revista Brasileira de Sensoriamento Remoto**, v. 1, n. 1, p. 29–37, 2020.

BORGES, E. F. **Aplicação das geotecnologias para a definição do zoneamento geoambiental do município de Mucugê – BA** (dissertação de mestrado em Modelagem de Ciências da Terra e do Ambiente). Feira de Santana: Universidade Estadual de Feira de Santana, 2008, 147 p.

BORGES, E. F.; FORTUNATO, U. M. C.; FERNANDES, L. A. Séries temporais de dados de sensoriamento remoto no estudo do comportamento fenológico no polo de desertificação de Jeremoabo-BA. **Revista Brasileira de Geografia Física**, v. 15, n. 1, p. 443–464, 2022.

BORGES, E. F.; SANO, E. E. Séries temporais de EVI do MODIS para o mapeamento de uso e cobertura vegetal do oeste da Bahia. **Boletim de Ciências Geodésicas**, v. 20, p. 526–547, 2014.

BOTREL, R. T.; BRITO, D. R. S.; SOUSA, W. C.; SOUZA, A. M.; HOLANDA, A. C. Fenologia de uma espécie arbórea em ecótono Caatinga/Cerrado no sul do Piauí. **Revista Verde de Agroecologia e Desenvolvimento Sustentável**, v. 10, n. 3, p. 7–12, 2015.

BREIMAN, L. Random forests. **Machine Learning**, v. 45, p. 5–32, 2001.

BRITO, C. M. S. Os discursos preservacionistas do processo de patrimonialização de Mucugê e do cemitério Santa Isabel. **Revista Outras Fronteiras**, v. 4, n. 2, p. 41–57, 2018.

CARDOSO, P. V.; SEABRA, V. S.; XAVIER, R. A.; RODRIGUES, E. M.; GOMES, A. S. Mapeamento de áreas de Caatinga através do Random Forrest: Estudo de caso na Bacia do Rio Taperoá. **Revista Geoaraguaia**, v. 11, p. 55–68, 2021.

CAPARROS-SANTIAGO, J. A.; RODRIGUEZ-GALIANO, V.; DASH, J. Land surface phenology as indicator of global terrestrial ecosystem dynamics: A systematic review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 171, p. 330–347, 2021.

CARVALHO JÚNIOR, O. A.; HERMUCHE, P. M.; GUIMARÃES, R. F. Identificação regional da floresta estacional decidual na bacia do Rio Paranã a partir da análise multitemporal de imagens MODIS. **Revista Brasileira de Geofísica**, v. 24, n. 3, p. 319–332, 2006.

CHAVES, I. B.; LOPES, V. L.; FOLLIOTT, P. F.; PAES-SILVA, A. P. Uma classificação morfo-estrutural para descrição e avaliação da biomassa da vegetação da caatinga. **Revista Caatinga**, v. 21, n. 2, p. 204-213, 2008.

CHENG, Y.; VRIELING, A.; FAVA, F.; MERONI, M.; MARSHALL, M.; GACHOKI, S. Phenology of short vegetation cycles in a Kenyan rangeland from PlanetScope and Sentinel-2. **Remote Sensing of Environment**, v. 248, e112004, 2020.

CLIMA TEMPO. Climatologia em Mucugê: Climatologia e histórico de previsão do tempo em Mucugê, BR. Disponível em: <https://www.climatempo.com.br/climatologia/3402/mucuge-ba>. Acesso em: 10 agosto 2023.

COELHO, V. H. R.; MONTENEGRO, S. M. G. L.; ALMEIDA, C. N.; LIMA, E. R. V.; RIBEIRO NETO, A.; MOURA, G. S. S. Dinâmica do uso e ocupação do solo em uma bacia hidrográfica do semiárido brasileiro. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, p. 64-72, 2014.

COOLEY, S. W.; SMITH, L. C.; STEPAN, L.; MASCARO, J. Tracking dynamic northern surface water changes with high-frequency planet CubeSat imagery. **Remote Sensing**, v. 9, n. 12, 1306, 2017.

CORDEIRO, C. M. **Evolução da rede de drenagem na Bacia do Alto Rio Paraguaçu: Capturas fluviais, drenagem transversa e pirataria de bacias** (tese de doutorado em Geografia). Belo Horizonte: Universidade Federal de Minas Gerais, 2019, 183 f.

CUNHA, J.; NÓBREGA, R. L. B.; RUFINO, I.; ERASMI, S.; GALVÃO, C.; VALENTE, F. Surface albedo as a proxy for land-cover clearing in seasonally dry forests: Evidence from the Brazilian Caatinga. **Remote Sensing of Environment**, v. 238, 111250, 2020.

DIDAN, K.; HUETE, A. **Modis vegetation index product series collection 5 change summary**. Arizona: The University of Arizona, 2006.

FERNANDES, L. A.; FORTUNATO, U. M. C.; BORGES, E. F. Aplicação do índice topográfico de umidade (TWI) e métricas fenológicas na análise temporal do comportamento da cobertura vegetal na mesorregião do Nordeste da Bahia. **Journal of Hyperspectral Remote Sensing**, v. 11, p. 213-221, 2021.

FERRI, M. G. **Vegetação Brasileira**. Belo Horizonte: Editora Itatiaia, 1980. 157 p.

FORKEL, M.; CARVALHAIS, N.; VERBESSELT, J.; MAHECHA, M.; NEIGH, C.; REICHSTEIN, M. Trend change detection in NDVI time series: Effects of inter-annual variability and methodology. **Remote Sensing**, v. 5, n. 5, p. 2113–2144, 2013.

FORKEL, M.; MIGLIAVACCA, M.; THONICKE, K.; REICHSTEIN, M.; SCHAPHOFF, S.; WEBER, U.; CARVALHAIS, N. Codominant water control on global interannual variability and trends in land surface phenology and greenness. **Global Change Biology**, v. 21, n. 9, p. 3414–3435, 2015.

FORKEL, M.; WUTZLER, T. **GreenBrown - land surface phenology and trend analysis**. A package for the R software. Version 2.2, 2015. Disponível em: <<http://greenbrown.r-forge.r-project.org/>>. Acesso em: 12 abril 2022.

FRAZIER, A. E.; HEMINGWAY, B. L. A technical review of Planet smallsat data: Practical considerations for processing and using PlanetScope imagery. **Remote Sensing**, v. 13, 3930, 2021.

FREIRE-SILVA, J.; PAZ, Y. E., LIMA-SILVA, P. P., PEREIRA, J. A. Índices de vegetação do Sensoriamento Remoto para processamento de imagens na faixa do visível (RGB). **Journal of Hyperpectral Remote Sensing**, v.9, n. 4, p. 228-239, 2019.

GANEM, R. S. **Caatinga: Estratégias de Conservação**. Brasília: Consultoria Legislativa, 2017, 105 p.

GANEM, K. A.; DUTRA, A. C.; OLIVEIRA, M. T.; FREITAS, R. M.; GRECCHI, R. C.; VIEIRA, R. M. S. P.; ARAI, E.; SILVA, F. B.; SAMPAIO, C. B. V.; DUARTE, V.; SHIMABUKURO, Y. E. Mapeamento da vegetação da Caatinga a partir de dados ópticos de observação da terra – oportunidades e desafios. **Revista Brasileira de Cartografia**, v. 72, p. 829–854, 2020.

GANGULY, S.; FRIEDL, M. A.; TAN, B.; ZHANG, X.; VERMA, M. Land surface phenology from MODIS: Characterization of the Collection 5 global land cover dynamics product. **Remote Sensing of Environment**, v. 114, n. 8, p. 1805–1816, 2010.

GAO, X.; HUETE, A. R.; NI, W.; MIURA, T. Optical-biophysical relationships of vegetation spectra without background contamination. **Remote Sensing of Environment**, v. 74, p. 609-620, 2000.

GARIGLIO, M. A.; SAMPAIO, E. V. S. B.; CESTARO, L. A.; KAGEYAMA, P. Y. (Orgs.). **Uso Sustentável e Conservação dos Recursos Florestais da Caatinga**. Brasília: Serviço Florestal Brasileiro, 2010, 367 p.

GIULIETTI, A. M.; BOCAGE NETA, A. L.; CASTRO, A. A. J. F.; GAMARRA-ROJAS, C. F. L.; SAMPAIO, E. V. S. B.; VIRGÍNIO, J. F.; QUEIROZ, L. P.; FIGUEIREDO, M. A.; RODAL, M. J. N.; BARBOSA, M. R. V.; HARLEY, R. M. Diagnóstico da vegetação nativa do bioma Caatinga. In: MMA. **Biodiversidade da Caatinga: Áreas e Ações Prioritárias para a Conservação**. Brasília, 2004, p. 48-90.

GONÇALVES, G. C. **Contribuição de métricas de textura em classificação pixel-a-pixel para identificar áreas construídas de cidades amazônicas** (Dissertação de mestrado em Sensoriamento Remoto). São José dos Campos: Instituto Nacional de Pesquisas Espaciais, 2021.

HADDAD, I.; GALVÃO, L. S.; BREUNIG, F. M.; DALAGNOL, R.; BOURSCHEIDT, V.; JACON, A. D. On the combined use of phenological metrics derived from different PlanetScope vegetation indices for classifying savannas in Brazil. **Remote Sensing Applications: Society and Environment**, v. 26, 100764, 2022.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, H. Textural features for image classification. **IEEE Transactions on Systems, Man and Cybernetics**, v. 3, n. 6, p. 610-621, 1973.

HARLEY, R. M.; SIMMONS, N. A. **Flórula de Mucugê, Chapada Diamantina, Bahia, Brazil**. Royal Botanic Gardens, 1986, 228 p.

HOUBORG, R.; McCABE, M. F. Daily retrieval of NDVI and LAI at 3 m resolution via the fusion of CubeSat, Landsat, and MODIS data. **Remote Sensing**, v. 10, n. 6, 890, 2018.

HUETE, A. R.; LIU, H. Q.; BATCHILY, K.; van LEEUWEN, W. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sensing of Environment**, v. 59, p. 440- 451, 1997.

HUETE, A. R.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E. P.; GAO, X.; FERREIRA, L. G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, n. 1-2, p. 195-213, 2002.

HUSSAIN, S.; QIN, S.; NASIM, W.; BUKHARI, M. A.; MUBEEN, M.; FAHAD, S.; ASLAM, M. Monitoring the dynamic changes in vegetation cover using spatio-temporal remote sensing data from 1984 to 2020. **Atmosphere**, v. 13, n. 10, 1609, 2022.

IPCC. **Intergovernmental Panel on Climate Change. Climate change 2014: impacts, adaptation, and vulnerability. Summary for Policymakers**. Cambridge: Cambridge University Press, 2014, 32 p.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Manual Técnico da Vegetação Brasileira**. Rio de Janeiro: IBGE, 2ª ed., 2012, 275 p.

IBGE - Instituto Brasileiro de Geografia e Estatística. **Manual Técnico de Uso da Terra**. Número 1, 3a ed. Rio de Janeiro: IBGE, 172 p., 2013.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Bases cartográficas contínuas - Brasil**. 2019. Disponível em: <https://acesse.one/kOjVR>. Acesso em: 15 fev. 2023.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Banco de Dados de Informações Ambientais na escala 1:250.000**. IBGE: Rio de Janeiro, 2021.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Produção Agrícola Municipal 2021**. Rio de Janeiro: IBGE, 2022.

JARDIM, A. M. R. F.; ARAÚJO JÚNIOR, G. N.; SILVA, M. V.; SANTOS, A.; SILVA, J. L. B.; et al. Using remote sensing to quantify the joint effects of climate and land use/land cover changes on the Caatinga biome of Northeast Brazilian. **Remote Sensing**, v. 14, n. 8, 1911, 2022.

JAPIASSÚ, A.; LOPES, K. P.; DANTAS, J. G.; NÓBREGA, J. S. Fenologia de quatro espécies arbóreas da Caatinga no semiárido paraibano. **Revista Verde de Agroecologia e Desenvolvimento Sustentável**, v. 11, n. 4, p. 34-43, 2016.

JENSEN, J. R. Remote Sensing of the Environment: An Earth Resource Perspective. In: EPIPHÂNIO, J. C. N.; FORMAGGIO, A. R.; SANTOS, A. R.; RUDORFF, B. F. T.; ALMEIDA, C. M.; GALVÃO, L. S. (trans.). **Sensoriamento Remoto do Ambiente: Uma Perspectiva em Recursos Terrestres**. São José dos Campos: Parêntese, 2009.

JOHNSON, A.; SMITH, B.; THOMPSON, C. Monitoring crop health using the Normalized Green-Red Difference Index (NGRDI). **Agricultural Remote Sensing Journal**, p. 123-135. 2020.

MAGALHÃES JÚNIOR, W. S.; WINKALER, E. U. Agrotóxicos e Chapada Diamantina: Consumo e saúde de pequenos agricultores do agropolo de Mucugê e Ibicoara, Bahia. **Research, Society and Development**, v. 9, n. 12, e5491210788, 2020.

JUSTICE, C. O.; VERMOTE, E.; TOWNSHEND, J. R. G.; DeFRIES, R.; ROY, D.P.; et al. The moderate resolution imaging spectroradiometer (MODIS): Land remote sensing for global change research. **IEEE Transactions on Geoscience and Remote Sensing**, v. 36, p. 1228-1249, 1998.

KASS, G. Una técnica exploratoria para investigar grandes cantidades de datos categóricos. **Revista de la Royal Statistical Society: Serie C (Estadísticas aplicadas)**, v. 29, n. 2, p. 119-127, 1980.

KRUASILP, J.; PATTANAKIAT, S.; PHUTTHAI, T.; VARDHANABINDU, P.; NAKMUENWAI, P. Evaluation of land use land cover changes in Nan Province, Thailand, using multi-sensor satellite data and Google Earth Engine. **Environment and Natural Resources Journal**, v. 21, n. 2, p. 186-197, 2023.

LEAL, *et al.* **Ecologia e conservação da Caatinga**. Editora Universitária, Universidade Federal de Pernambuco, Recife, Brasil. 2003.

LEAL, I. R.; SILVA, J. M. C.; TABARELLI, M.; LACHER Jr., T. E. Changing the course of biodiversity conservation in the Caatinga of northeastern Brazil. **Conservation Biology**, v. 19, n. 3, p. 701-706, 2005.

LIAW, A.; WIENER, M. Classification and regression by Random Forest. **R News**, n. 2, p. 8-22, 2002.

LIETH, H. Introduction to phenology and the modeling of seasonality. In: LIETH, H. (ed.), **Phenology and Seasonality Modeling**. Berlin: Springer Verlag, p. 3-19, 1974.

LIMA, S. S.; CORDEIRO, J. L.; TEIXEIRA, L. P.; MAIA, R. P.; SILVA, M. V. C.; MORO, M. F. Caracterização geográfica e dinâmica de uso da terra da Ibiapaba e seu entorno, Domínio fitogeográfico da Caatinga. **Revista Brasileira de Geografia Física**, v. 15, n. 5, p. 2500-2524, 2022.

LUZ, L. R.; GIONGO, V.; SANTOS, A. M.; LOPES, R. J. C.; LIMA JÚNIOR, C. Biomass and vegetation index by remote sensing in different Caatinga forest areas. **Ciência Rural**, v. 52, n. 2, e20201104, 2022.

MA, X. Q.; LENG, P.; LIAO, Q. Y.; GENG, Y. J.; ZHANG, X.; SHANG, G. F.; SONG, X.; SONG, Q.; LI, Z. L. Prediction of vegetation phenology with atmospheric reanalysis over semiarid grasslands in Inner Mongolia. **Science of the Total Environment**, v. 812, 152462, 2022.

MAPBIOMAS. **MapBiomas Alerta**. Disponível em: <<http://alerta.mapbiomas.org/>>. Acesso em: 18 julho 2022.

MAPBIOMAS. **MapBiomas v. 7.0**. Disponível em: <<https://mapbiomas.org/>>. Acesso em: 20 junho 2022.

MOORE, M. M.; SLONIMSKY, E.; LONG, A. D.; SZE, R. W.; IYER, R. S. Machine learning concepts, concerns and opportunities for a pediatric radiologist. **Pediatric Radiology**, v. 49, n. 4, p. 509-516, 2019.

MOREIRA, M. A. **Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação**. Viçosa: Editora UFV, 2011, 422 p.

ICMBio. Instituto Chico Mendes de Conservação da Biodiversidade. **Plano de Manejo para o Parque Nacional da Chapada Diamantina**. Brasília: ICMBio, 2007, 506 p.

MARENGO, J. A.; TORRES, R. R.; ALVES, L. M. Drought in Northeast Brazil - past, present, and future. **Theoretical and Applied Climatology**, v. 129, n. 3–4, p. 1189–1200, 2017.

MAXWELL, A. E.; WARNER, T. A.; FANG, F. Implementation of machine-learning classification in remote sensing: An applied review. **International Journal of Remote Sensing**, v. 39, n. 9, p. 2784-2817, 2018.

MEDRADO, H. **Mucugê e sua História**. Salvador, 1998.

MENESES, P. R.; ALMEIDA, T. (eds). **Introdução ao Processamento de Imagens de Sensoriamento Remoto**. Brasília: Universidade de Brasília, 2012.

MOON, M.; RICHARDSON, A. D.; FRIEDL, M. A. Multiscale assessment of land surface phenology from harmonized Landsat 8 and Sentinel-2, PlanetScope, and PhenoCam imagery. **Remote Sensing of Environment**, v. 266, 112716, 2021.

MORAES, A. A. L.; KUPLICH, T. M.; TRINDADE, P. M. P.; PEIXOTO, D. W. B. Evapotranspiração instantânea e sua relação com temperatura de superfície, índice de vegetação e tipos de cobertura da terra na bacia hidrográfica dos Rios Vacacaí-Vacacaí Mirim – Pampa Brasileiro. **Revista Brasileira de Climatologia**, v. 30, n. 18, p. 571–590, 2022.

MORELLATO, L. P. C. Phenological data, networks, and research: South America. In: SCHWARTZ, M. D. (Org.). **Phenology: An Integrative Environmental Science**. Dordrecht: Kluwer Academic Publishers, p. 75-92, 2003.

NAGEL, G. W.; NOVO, E. M. L. M.; KAMPEL, M. Nanosatellites applied to optical Earth observation: A review. **Revista Ambiente e Água**, v. 15, n. 3, e2513, 2020.

NEVES, E. L.; FUNCH, L. S.; VIANA, B. F. Comportamento fenológico de três espécies de *Jatropha* (*Euphorbiaceae*) da Caatinga, semi-árido do Brasil. **Revista Brasileira de Botânica**, v. 33, p. 155-166, 2010.

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**, n. 69/6, p. 1175-1187, 2017.

PANDEY, P.; KINGTON, J.; KANWAR, A.; SIMMON, R.; ABRAHAM, L. **Planet Basemaps for NICFI Data Program. Addendum to Basemaps Product Specifications**, 2023. Disponível em: https://assets.planet.com/docs/NICFI_Basemap_Spec_Addendum.pdf. Acesso em: 01 abril 2023.

PAULA *et al.* Comparando algoritmos de aprendizado de máquina para predição de multimorbidade: um exemplo do estudo Elsa-Brasil. **Plos ONE**, 2022.

SEFLA, P.; ROBERTO, O.; RIVERA, H.; MAIANA, S. Aplicación de algoritmos de clasificación para la estimación de carbono orgánico del suelo en la provincia de Chimborazo. Ecuador, FIGEMPA: **Investigación Y Desarrollo**, 2021.

SOUSA Jr., V. P. S.; SPARACINO, J.; ESPINDOLA, G. M.; ASSIS, R. J. S. Land-use and land-cover dynamics in the Brazilian Caatinga dry tropical forest. **Conservation**, v. 2, n. 4, p. 739-752, 2022.

PLANET. **Planet Imagery Product Specifications**, 2002a, 101 p. Disponível em: https://assets.planet.com/docs/Planet_Combined_Imagery_Product_Specs_letter_screen.pdf. Acesso em: 31 jun 2022.

PLANET. **Planet Surface Reflectance Version 2.0**, 2002b. Disponível em: https://assets.planet.com/marketing/PDF/Planet_Surface_Reflectance_Technical_White_Paper.pdf. Acesso em: 31 jun 2022.

PENATTI, N. C. **Geobotânica e fenologia da superfície terrestre no estudo da diversidade do Pantanal: Uma abordagem multi-sensor** (Tese de doutorado em Recursos Minerais e Meio Ambiente). São Paulo: Universidade de São Paulo, 2014, 231 f.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento remoto no estudo da vegetação**. São José dos Campos, SP: Parêntese, 2010.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da vegetação**. São José dos Campos: Oficina de Textos, 2012. 135 p.
PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da vegetação**. Oficina de Textos, 2015.

REDO, D.; AIDE, T. M.; CLARK, M. L. Vegetation change in Brazil's dryland ecoregions and the relationship to crop production and environmental factors: Cerrado,

Caatinga, and Mato Grosso, 2001-2009. **Journal of Land Use Science**, v. 8, n. 2, p. 123–153, 2013.

RODAL, M. J. N.; SAMPAIO, E. V. S. B. **A vegetação do bioma Caatinga**. APNE/CNIP, p.11-24. Recife, PE, 2002.

ROQUE, N.; OLIVEIRA, E. C.; MOURA L.; QUARESMA A. S.; OGASAWARA H. A.; ALVES M.; SANTANA F. A.; HEIDEN G.; CAIRES T. A.; BASTOS N. G.; LIM G. M.; BAUTISTA, H. P. *Asteraceae* no município de Mucugê, Chapada Diamantina, Bahia, Brasil. **Rodriguésia**, v. 67, p. 125-202, 2016.

ROUSE, J. W. et al. **Monitoring vegetation systems in the Great Plains with ERTS**, Third ERTS Symposium, NASA SP-351 I, p. 309- 317, 1973.

RISSO, J. et al. Índices de vegetação MODIS aplicados na discriminação de áreas de soja. **Pesquisa Agropecuária Brasileira**, v. 47, p. 1317-1326, 2012.

RUIZ, I. H. **Uso de métricas fenológicas calculadas de diferentes índices de vegetação da constelação de satélites PlanetScope para classificação de fitofisionomias do Cerrado**. Dissertação (Mestrado em Sensoriamento Remoto). São José dos Campos: Instituto Nacional de Pesquisas Espaciais, 2022.

SANO, S. M., DE ALMEIDA, S. P., RIBEIRO, J. F., SEMIRAMIS PEDROSA DE ALMEIDA, P. A. C. (2008). **Cerrado: ecologia e flora**. Brasília, DF: Embrapa Informação Tecnológica; Planaltina, DF: Embrapa Cerrados, 2008.

SANO, E. E.; BOLFE, É. L.; PARREIRAS, T. C.; BETTIOL, G. M.; VICENTE, L. E.; SANCHES, I. D.; VICTORIA, D. C. Estimating double cropping plantations in the Brazilian Cerrado through PlanetScope monthly mosaics. **Land**, v. 12, n. 3, 581, 2023.

SÁNCHEZ, L. E.; CHAVES, J. M.; FRANCA-ROCHA, W. J. S.; LOBÃO, J. S. B.; FALCÃO, P. M. Identificação das dunas do Atacama (Norte do Chile) a partir da avaliação de três algoritmos no Google Earth Engine. **Revista Brasileira de Geografia Física**, v. 14 n. 6, 2021.

SANTANA, D. F. Y.; LIRA, M. A.; SANTOS, M. V. F.; FERREIRA, M. A.; SILVA, M. J. A.; MARQUES, K. A.; MELLO, A. C. L.; SANTOS, D. C. Caracterização da Caatinga e da dieta de novilhos fistulados, na época chuvosa, no semiárido de Pernambuco. **Revista Brasileira de Zootecnia**, v. 40, n. 1, p. 69–78, 2011.

SANTANA, J. A. S.; ZACCHARIAS, A. F. S.; SILVA, A. B.; FREIRE, A. S. M.; ZACCHARIAS, E. G. Florística, fitossociologia e índices de diversidade da Caatinga em assentamento rural no Rio Grande do Norte, Brasil. **Biodiversidade Brasileira**, v. 11, n. 1, p. 1-13, 2021.

SANTOS, J. C.; LEAL, I. R.; ALMEIDA-CORTEZ, J. S.; FERNANDES, G. W.; TABARELLI, M. Caatinga: The scientific negligence experienced by a dry tropical forest. **Tropical Conservation Science**, v. 4, n. 3, p. 276-286, 2011.

SANTOS, H. G., JACOMINE, P. K. T., ANJOS, L. H. C., OLIVEIRA, V. A., LUMBRERAS, J. F., COELHO, M. R., ... & CUNHA, T. J. F. (2018). **Sistema Brasileiro de Classificação de Solos**. Brasília, DF: Embrapa, 2018.

SANTOS, J. M.; PESSOA, M. M. L.; FERREIRA, R. L. C.; SILVA, E. A. Land-use and coverage in the structure of the landscape in a tropical dry forest in northeast Brazil. **Journal of Environmental Analysis and Progress**, v. 5, n. 1, p. 88-97, 2020.

SANTOS, H. G.; JACOMINE, P. K. T.; ANJOS, L. H. C.; OLIVEIRA, V. A.; LUMBRERAS, J. F.; COELHO, M. R.; ALMEIDA, J. A.; ARAUJO FILHO, J. C.; OLIVEIRA, J. B.; CUNHA, T. J. F. **Sistema Brasileiro de Classificação de Solos**. Rio de Janeiro: Embrapa Solos, 2018, 5ª ed., 356 p.

SENA, L. M. M (ed). **Conheça e Conserve a Caatinga. O Bioma Caatinga**. Fortaleza: Associação Caatinga, 2011, 54 p.

SINGH, R.; PATEL, N. R.; DANODIA, A. Deriving phenological metrics from Landsat-OLI for sugarcane crop type mapping: A case study in North India. **Journal of the Indian Society of Remote Sensing**, v. 50, n. 6, p. 1021–1030, 2022.

SILVA, R., OLIVEIRA, L.; SANTOS, M. Detecting vegetation changes in tropical forests using NGRDI. **Journal of Environmental Monitoring**, v. 21, n. 4, p. 245-258, 2019.

SILVA, L. F.; SOUZA, B. I.; BACANI, V. M. Desempenho comparativo entre classificadores supervisionados no mapeamento de áreas de ecótono em região de Caatinga. **Caderno de Geografia**, v. 29, n. 59, p. 1083-1105, 2019.

SILVA, D. V. S.; CRUZ, C. B. M. Tipologias de Caatinga: Uma revisão em apoio a mapeamentos através de sensoriamento remoto orbital e GEOBIA. **Revista do Departamento de Geografia**, v. 35, p. 113-120, 2018.

SILVEIRA, H. L. F.; GALVÃO, L. S.; SANCHES, I. D.; SÁ, I. B.; TAURA, T. A. Use of MSI/Sentinel-2 and airborne LiDAR data for mapping vegetation and studying the relationships with soil attributes in the Brazilian semi-arid region. **International Journal of Applied Earth Observation and Geoinformation**, v. 73, p. 179-190, 2019.

SILVEIRA, N. T.; SANTOS, T. O.; TIBÚRCIO, I. M.; GALVÍNCIO, J. D. Aplicação do índice de vegetação por diferença normalizada (NDVI) para a análise espaço-temporal da Bacia Hidrográfica do rio Terra Nova, Pernambuco, Brasil. **Revista Brasileira de Sensoriamento Remoto**, v. 3, n. 3, p. 20-29, 2022.

SOBRINHO *et al.* Uso da terra, pousio e recuperação de uma floresta de Caatinga. **Biotropica**, v. 48, p. 586-597, 2016.

SOTHE, C.; LIESENBERG, V.; ALMEIDA, C. M.; SCHIMALSKI, M. B. Abordagens para classificação do estágio sucessional da vegetação do Parque Nacional de São Joaquim empregando imagens Landsat-8 e RapidEye. **Boletim de Ciências Geodésicas**, v. 23, n. 3, p. 389-404, 2017.

SOUZA, M. J. N.; OLIVEIRA, V. P. V. Os enclaves úmidos e sub-úmidos do Nordeste brasileiro. **Mercator**, v. 5, n. 9, p. 85-102, 2006.

SOUZA, B. I.; ARTIGAS, R. C.; LIMA, E. R. V. Caatinga e desertificação. **Mercator**, v. 14, n. 1, p. 131-150, 2015.

TABARELLI, M.; LEAL, I. R.; SCARANO, F. R.; SILVA, J. M. C. Caatinga: Legado, trajetória e desafios rumo à sustentabilidade. **Ciência e Cultura**, v. 70, n. 4, p. 25-29, 2018.

TEODORO, M.L.M.T; TEODORO, J.A; PEIXOTO, C.B; PEREIRA, E.B; DINIZ, M.L.N; FREITAS, S.K.P; RIBEIRO, P.C.C; GOMES, C.M.A; ALVES, M.M. Saúde mental em estudantes universitários durante a pandemia de COVID-19. **Revista Família, Ciclos de Vida e Saúde no Contexto Social**, vol. 9, n. 2, pp. 372-382, 2021.

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

VIEIRA, R. M. S. P.; TOMASELLA, J.; ALVALÁ, R. C. S.; SESTINI, M. F.; AFFONSO, A. G.; et al. Identifying areas susceptible to desertification in the Brazilian Northeast. **Solid Earth**, v. 6, p. 347–360, 2015.

ZHAO, Y.; LEE, C. K. F.; WANG, Z.; WANG, J.; GU, Y.; XIE, J.; LAW, Y. K.; SONG, G.; BONEBRAKE, T. C.; YANG, X.; NELSON, B. W.; WU, J. Evaluating fine-scale phenology from PlanetScope satellites with ground observations across temperate forests in eastern North America. **Remote Sensing of Environment**, v. 283, Paper 113310, 2022.

XIE, Q.; CLEVERLY, J.; MOORE, C. E.; DING, Y.; HALL, C. C.; et al. Land surface phenology retrievals for arid and semi-arid ecosystems. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 185, p. 129–145, 2022.

4. CAPÍTULO 4

ARTIGO 1: BANDAS ESPECTRAIS E ÍNDICES DE VEGETAÇÃO DERIVADOS DE MOSAICOS MENSAIS DO PLANETSCOPE NA DISCRIMINAÇÃO DE CLASSES DE USO E COBERTURA DA TERRA NO MUNICÍPIO DE MUCUGÊ, CHAPADA DIAMANTINA, BAHIA

Resumo: A análise espectral de diferentes fitofisionomias do bioma Caatinga a partir de assinaturas espectro-temporais de índice de vegetação amplia a possibilidade de monitoramento do uso e cobertura da terra desse bioma que é marcado pelo avanço intensivo da agropecuária, do processo de ocupação acelerado e escassez de dados e informações relevantes para análise ambiental. Neste estudo, objetivou-se analisar a resposta espectral sazonal de fitofisionomias e culturas agrícolas da Caatinga a partir da análise de séries temporais de índices de vegetação derivados de mosaicos mensais do satélite PlanetScope. Para tal, utilizaram-se mosaicos mensais normalizados de março de 2022 a fevereiro de 2024. A partir desses mosaicos, extraíram-se três índices de vegetação, o índice de vegetação por diferença normalizada (NDVI), o índice de vegetação realçado (EVI) e o índice de vegetação por diferença normalizada do verde-vermelho (NGRDI). Em conjunto, foram utilizados dados da pesquisa de campo realizada, em que se visitou 200 pontos entre fitofisionomias naturais e culturas agrícolas, bem como informações adicionais, padrões de uso da terra, práticas agrícolas adotadas e condições de manejo. Realizou-se a classificação e regressão dados a partir do algoritmo CART e criação de dendograma de agrupamento. Os resultados alcançados indicaram que as bandas e os índices de vegetação estudados apresentam sensibilidade às áreas com vegetação nativa, mesmo no período seco. Em áreas de lavoura temporária, os perfis de IVs apresentam elevada amplitude e curto comprimento no ciclo de cultivo. Já nas lavouras permanentes, notaram-se variações entre os perfis analisados de mesmo cultivo (café), mas para práticas agrícolas distintas. Quando submetidos regressão múltiplas, o modelo final apresentou R^2 de 0,75, correspondendo a relação de 75% entre as variáveis preditoras e categóricas, de forma a evidenciar as bandas espectrais e índices com alta significância. Outrossim, ao realizar o agrupamento das classes, tornou-se distinguir as fitofisionomias das lavouras a partir da variável $G < 0.06995$, no entanto, tornou-se necessário mais variáveis para diferenciar as fitofisionomias entre si.

Abstract: The spectral analysis of different phytophysiologicals of the Caatinga biome based on spectro-temporal signatures of the vegetation index expands the possibility of monitoring the use and land cover of this biome, which is marked by the intensive advance of agriculture, the accelerated occupation process and the scarcity of data and information relevant to environmental analysis. In this study, the objective was to analyze the seasonal spectral response of phytophysiologicals and agricultural crops in the Caatinga based on the analysis of time series of vegetation indices derived from monthly mosaics from the PlanetScope satellite. To this end, normalized monthly mosaics were used from March 2022 to February 2024. From these mosaics, three vegetation indices were extracted: the normalized difference vegetation index (NDVI), the enhanced vegetation index (EVI) and the normalized green-red difference vegetation index (NGRDI). Together, data from the field research carried out were used, in which 200 points were visited between natural phytophysiologicals and agricultural crops, as well as additional information, land use patterns, adopted agricultural practices and management conditions. Data classification and regression were carried out using the CART algorithm and a cluster dendrogram was created. The results achieved indicated that the vegetation indices studied are sensitive to areas with native vegetation, even in the dry period. In areas of temporary farming, the profiles have high amplitude and short length in the cultivation cycle. In permanent crops, variations were noted between the analyzed profiles of the same crop (coffee), but for different agricultural practices. When subjected to multiple regression, the final model presented an R^2 of 0.75, corresponding to a 75% relationship between the predictor and categorical variables, in order to highlight the spectral bands and indices with high significance. Furthermore, when grouping the classes, it became possible to distinguish the phytophysiologicals of the crops based on the variable $G < 0.06995$, however, more variables became necessary to differentiate the phytophysiologicals from each other.

4.1. INTRODUÇÃO

A caracterização, discriminação e mapeamento da vegetação por meio do sensoriamento remoto têm sido realizada em diferentes perspectivas (Oliveira *et al.*, 2020; Silva *et al.*, 2020). Atrélado a isso, a extração de dados por meio das imagens de

satélites tem fornecido subsídio para análise da vegetação em diferentes escalas (Veiga *et al.*, 2020; Santos *et al.*, 2024). Com relação aos estudos vinculados à discriminação de culturas agrícolas (Risso *et al.*, 2012; Ide e Baptista, 2018) e ao uso e cobertura da terra (Filgueiras *et al.*, 2019; Picolo *et al.*, 2018), as séries temporais constituídas por essas imagens fornecem dados essenciais para avaliação do perfil temporal e dos componentes de tendência e sazonalidade da vegetação.

Arelado a isto, a composição dessas séries com diferentes bandas espectrais de satélites desempenha um papel fundamental no processo de identificação e discriminação de alvos, como vegetação, solo e corpos d'água, haja vista que, cada alvo na superfície terrestre reflete ou absorve energia eletromagnética de forma específica (Florenzano, 2002; Meneses; Almeida, 2012), conforme suas propriedades físicas e químicas. As bandas espectrais capturam essa resposta em diferentes comprimentos de onda (Meneses; Almeida, 2012), permitindo a distinção entre tipos de vegetação, estados fenológicos e cobertura do solo. Outrossim, é a partir dessas bandas que se realizam diferentes razões espectrais, como os índices de vegetação, que amplificam as diferenças na reflectância, facilitando o monitoramento e a análise de padrões. Os índices de vegetação (IVs) são caracterizados por realces espectrais que envolvem razões de duas ou mais bandas e que são sensíveis à intensidade de absorção da radiação eletromagnética pela vegetação em diferentes faixas espectrais (Huete *et al.*, 2002; Jensen, 2009), possibilitando comparações espaciais e temporais da atividade fotossintética terrestre (Silveira *et al.*, 2022). Os IVs têm sido frequentemente utilizados para estimar os parâmetros biofísicos relacionados ao estado da vegetação (Santos *et al.*, 2020), tais como biomassa, índice de área foliar (IAF), porcentagem da cobertura verde, teor de clorofila, biomassa verde e mudanças no uso da terra, permitindo monitorar e caracterizar a cobertura vegetal (Barros *et al.*, 2020; Costa, Ribeiro e Albuquerque, 2020), bem como inferir sobre padrões climáticos, geológicos e fenológicos (Trindade *et al.*, 2019) de uma dada região.

Entre as tecnologias de sensoriamento remoto disponíveis, quando se remete à construção de séries temporais, o sensor MODIS tem importância destacada por conta do tempo de revisita e fornecimento de composições de imagens de 8 ou 16 dias (Caron; Minuzzi, 2022; Gouveia; Nascimento, 2022). Apesar da ampla utilização das séries temporais do sensor MODIS, elas também apresentam limitações associadas a possível baixa qualidade radiométrica dos pixels – com interferência de cobertura de nuvens,

elevado ângulo de visada e/ou a presença de ruídos resultantes de fatores atmosféricos (nuvens, geleiras e neve), sombra e ângulo de elevação solar (Borges; Sano, 2014).

Nesse contexto, os satélites de alta resolução espacial e temporal, como o PlanetScope (PS), têm se destacado pela sua capacidade de adquirir imagens com frequente cobertura temporal e detalhamento espacial (Roy *et al.*, 2021; Pandey *et al.*, 2023). Essa capacidade permite a construção de mosaicos mensais essenciais para o monitoramento contínuo e detalhado das dinâmicas de uso e cobertura da terra (Sano *et al.*, 2023; Welsink *et al.*, 2023). Tais mosaicos configuram-se como composições de imagens de satélite que cobrem uma área específica durante um mês, reduzindo os efeitos de variações atmosféricas e nuvens (Pandey *et al.*, 2023). Tal abordagem facilita a observação de mudanças sazonais e anuais, oferecendo uma visão mais clara das tendências da vegetação. Diante desse cenário, objetivou-se avaliar o desempenho de quatro bandas espectrais e três índices de vegetação derivados dos mosaicos mensais do PlanetScope na discriminação de diferentes fitofisionomias de enclaves de Caatinga e culturas agrícolas no município de Mucugê, Bahia.

4.2. MATERIAIS E MÉTODOS

4.2.1. Área de Estudo

A área de estudo compreende o município de Mucugê, localizado na porção central do estado da Bahia e inserido no domínio morfoclimático da Caatinga (Ab'Saber, 2003), no limite norte da Cadeia do Espinhaço (Freitas *et al.*, 2016) (Figura 4.1). Esse município é caracterizado por apresentar padrões ambientais (topografia, umidade e temperatura) que condicionam a ocorrência de clima ameno, configurando-se como um enclave subúmido da Caatinga, ou seja, um verdadeiro ambiente de exceção (Borges, 2008).




Figura 4.1 - Localização do município de Mucugê/BA no bioma Caatinga. Fonte: Elaboração dos autores (2024).

O clima de Mucugê é Tropical, com verões quentes e úmidos e invernos secos – Aw no sistema de classificação climática de Köppen (Alvares *et al.*, 2014). Quanto à vegetação, as predominâncias são de campo rupestre, que ocorre nas áreas mais elevadas e de superfícies rochosas. A leste, ocorrem os campos gerais, florestas semidecíduas e ombrófilas, caatinga e vegetação de brejos (Harley; Simmons, 1986; Roque *et al.*, 2016). Quanto às feições antrópicas, o MapBiomas indicou a ocorrência de 32,47% de Agropecuária no município em 2022.

4.2.2. Métodos

Na Figura 4.2, são mostradas as principais etapas metodológicas desenvolvidas. Foram utilizados mosaicos mensais entre os anos de março de 2022 a fevereiro de 2024 do PlanetScope que foram convertidos em três índices de vegetação, o índice de vegetação por diferença normalizada (NDVI) e o índice de vegetação realçado (EVI) e o índice de Diferença Normalizada Verde-Vermelho (NGRDI). Os mosaicos mensais, conhecidos como mosaicos analíticos normalizados, são produzidos e disponibilizados

através da iniciativa *Norway's International Climate and Forest Initiative* (NCIFI) na plataforma *Google Earth Engine* (Gorelick *et al.*, 2017). Esses mosaicos incluem correções geométrica, atmosférica e radiométrica e são compostos pelas bandas do azul (455-515 nm), verde (500-590 nm), vermelho (590-670 nm) e infravermelho próximo (780-860 nm). Esses mosaicos são baseados nos dados de reflectância da superfície do PS e são normalizados para reduzir a variabilidade radiométrica entre cenas (Pandey *et al.*, 2023).




Figura 4.2 - Fluxograma das principais etapas metodológicas utilizadas nesse estudo.

Fonte: Elaboração dos autores (2024).

Pandey *et al.* (2023) indicaram que os mosaicos fornecem uma representação analítica ou informativa do terreno com dados espaciais precisos, minimizando os efeitos das características atmosféricas e dos sensores. Destaca-se também a cobertura espacial desses mosaicos que cobrem regiões entre 30° N e 30° S, correspondentes às áreas tropicais, pois objetivam apoiar a redução e reversão da perda de florestas tropicais, contribuindo para combater a mudança climática e conservar a biodiversidade (Pandey *et al.*, 2023). Através dos mosaicos mensais, foram extraídos os valores das bandas espectrais. Somado a isto, foram calculados os índices NDVI (Rouse *et al.*, 1973; Jensen, 2009) (Equação 4.1), EVI (Huete *et al.*, 2002) (Equação 4.2) e NGRDI (Hunt *et al.*, 2005).

$$NDVI = \frac{\rho_{NIR} - \rho_{Red}}{\rho_{NIR} + \rho_{Red}} \quad 4.1$$

$$EVI = 2.5 \times \frac{\rho_{NIR} - \rho_{Red}}{\rho_{NIR} + 6 \times \rho_{Red} - 7.5\rho_{Blue} + 1} \quad 4.2$$

$$NGRDI = \frac{\rho_{Green} - \rho_{Red}}{\rho_{Green} + \rho_{Red}} \quad 4.3$$

Onde ρ é a reflectância da superfície nas bandas espectrais do azul, vermelho e NIR.

Estes índices foram escolhidos devido à sua sensibilidade a diferentes atributos biofísicos. O NDVI trata-se de uma medida radiométrica adimensional calculada a partir da razão normalizada entre as bandas do infravermelho próximo e a banda do vermelho, variando entre -1 e 1 e é sensível à presença de pigmentos de clorofila (Risso *et al.*, 2012; Ponzoni, Shimabukuro; Kuplich, 2015). Desse modo, é um dos índices mais utilizados no mundo, com boa correlação entre os valores identificados e a biomassa fotossinteticamente ativa (Borges; Sano, 2014; Ning *et al.*, 2015).

O EVI foi utilizado para garantir a discriminação do estrato superior da vegetação, haja vista que foi desenvolvido com o objetivo de otimizar o sinal da vegetação, melhorando a sensibilidade em regiões com maiores densidades de biomassa (Huete *et al.*, 2002). Sendo assim, em ambientes de Caatinga, a estrutura da vegetação pode ser melhor realçada pelo EVI, pois o mesmo reduz as influências do sinal de fundo do dossel e da atmosfera (Justice *et al.*, 1998). Por outro lado, o NGRDI (Índice de Diferença Green-Red) é calculado a partir da reflectância das bandas verde e vermelha. Este índice é uma opção para análise de dados no espectro visível, permitindo inferências sobre a relação entre a vegetação e o solo (Hunt *et al.*, 2005; Jannoura *et al.*, 2014), bem como detecção de mudanças sazonais na vegetação nativa e em cultivos (Sano *et al.*, 2023; Haddad *et al.*, 2022). A Tabela 4.1 indica os parâmetros utilizados para extração e análise das séries temporais do NDVI, EVI e NGRDI.

Tabela 4.1 - Parâmetros para extração e análise das séries temporais a partir de mosaicos mensais do satélite PlanetScope.

Parâmetros	Descrição
Resolução espacial	4,77 m

Nível de processamento	Mosaicos analíticos normalizados com correções atmosféricas
Mosaicos mensais	Março de 2022 a fevereiro de 2024
Bandas espectrais	Azul (0,455–0,515 μm), Verde (0,500–0,590 μm), Vermelho (0,590–0,670 μm) e Infravermelho próximo (0,780–0,860 μm)
Índices de vegetação	NDVI, EVI e NGRDI

Fonte: Elaboração pelos autores (2024).

As classes naturais e antrópicas foram escolhidas com base no trabalho de campo realizado no município durante o período seco (junho de 2023), em que foram visitados 200 pontos envolvendo diferentes fitofisionomias e culturas agrícolas. Para cada ponto, foram registradas as coordenadas geográficas, além do registro fotográfico panorâmico por meio de uma câmera digital RGB convencional e da anotação da classe de uso e cobertura da terra. Para esta pesquisa, as classes temáticas consideradas foram a Lavoura Permanente, Lavoura Temporária, Savana Estépica-Arborizada, Savana Estépica Florestada e Campo Rupestre (Figura 4.3). Como as classes Lavoura Permanente e Lavoura Temporária apresentaram diferentes culturas e ciclos vegetativos, selecionaram-se pontos correspondentes às culturas de café com irrigação por gotejamento, arroz, batata-inglesa e cebola.



(a)



(b)



(c)



(d)



(e)



(f)



(g)

Figura 4.3 - Fotografias registradas em trabalho de campo representativas das classes de uso e cobertura da terra encontradas na área de estudo: a) Lavoura Permanente – Café irrigado por gotejamento; b) Lavoura Temporária – batata-inglesa em pivô irrigado; c) Lavoura Temporária – arroz; d) Áreas agrícolas irrigadas com pivô central; e) Savana Estépica Arborizada; f) Savana Estépica Florestada; e g) Campo Rupestre.

Somando a isto, foram selecionados pontos representativos nos mosaicos mensais do PlanetScope para compor a análise de perfis temporais de IVs para identificar uma padronização dos principais usos e coberturas identificados no município, de forma a estabelecer uma biblioteca de valores temporais de EVI, NDVI e NGRDI (Figura 4.4).

Fitofisionomia/ Cultura	Coordenadas Geográficas	RGB Planet (Março, 2024)
Lavoura Permanente Cultivo de café por gotejamento	13° 07' 02,29" S 41° 28' 59,37" O	
Lavoura Permanente Cultivo de café irrigado por gotejamento em agricultura familiar	13° 14' 21,47" S 41° 21' 13,35" O	




Lavoura Temporária Cultivo de batata-inglesa em pivô irrigado	13° 06' 05,69" S 41° 14' 50,18" O	
Lavoura Temporária Cultivo de arroz por gotejamento	13° 11' 47,53" S 41° 34' 56,50" O	
Vegetação Natural Savana-Estépica Florestada	12° 59' 36,02" S 41° 22' 57,02" O	
Vegetação Natural Campo Rupestre	13° 07' 20,34" S 41° 34' 39,98" O	
Vegetação Natural Savana-Estépica Arborizada	13° 07' 32,68" S 41° 35' 41,53" O	

Figura 4.4 - Pontos representativos nos mosaicos mensais do satélite PlanetScope das classes de uso e cobertura da terra encontradas em campo em Mucugê/BA.

Adicionalmente, como forma de identificar as estações chuvosa e seca para o e delinear as culturas temporárias e permanentes no município de Mucugê, utilizou a série histórica de dados pluviométricos (Figura 4.5), em que se pode observar a correspondência de regularidade e maior disponibilidade de chuva entre novembro a março e estiagem de maio a outubro.




Figura 4.5 - Climograma da série histórica de precipitação do município de Mucugê, Bahia. Fonte: Climatempo (2022).

Como forma de avaliar estatisticamente os valores das bandas espectrais e das séries temporais de índices de vegetação associados às classes naturais e antrópicas, utilizou-se o algoritmo de classificação e regressão – *Classification and Regression Trees* (CART) (Breiman *et al.*, 1984), baseado em árvore de decisão que funciona examinando várias maneiras de particionar ou dividir dados localmente em segmentos menores (Breiman *et al.*, 1984).

O classificador do algoritmo CART divide as amostras em vários subconjuntos (Sartorio *et al.*, 2023), utilizando de análise de regressão múltipla, com objetivo de explicar a ocorrência das classes de interesse (variável resposta), a partir do conjunto das variáveis explicativas (bandas e índices) (Hosmer; Lemeshow; Sturdivant, 2013), neste caso, as amostras das classes introduzidas são subdivididas pela resposta espectral, através dos índices e das bandas dos dados PS. Além disso, as árvores de decisão raramente selecionam variáveis preditoras irrelevantes. Isso ocorre porque o algoritmo de construção da árvore recursiva estima a melhor variável para dividir em cada etapa, o que significa que preditores não relacionados às variáveis de resposta tendem a não ser escolhidos para a divisão (Sartorio *et al.*, 2023; Li *et al.*, 2023).

Somado a isto, considerando que o algoritmo CART facilita o estabelecimento das relações hierárquicas entre essas classes, a partir o pacote “*tree*” do programa estatístico R (<https://cran.r-project.org/web/packages/tree>) (Ripley, 2023), gerou-se um dendograma para a representação gráfica da árvore de decisão, construída considerando o conjunto de treino (70%) e conjunto de teste (30%). Esse dendograma detalha como os dados foram agrupados ou separados em cada etapa do processo de divisão (Breiman *et al.*, 1984; Hastie; Tibshirani; Friedman, 2009), mostrando visualmente as bifurcações baseadas nos índices de vegetação e bandas espectrais. Cada divisão no dendograma representa uma decisão tomada pelo modelo, indicando quais variáveis foram usadas para separar as classes e como essas separações contribuíram para a classificação final das amostras (Breiman *et al.*, 1984).

Para discriminar as classes, realizou-se um modelo de regressão linear múltipla. No primeiro momento, gerou-se regressões lineares simples para cada banda espectral (R, G, B, NIR) e índice de vegetação (NDVI, EVI e NGRDI) individualmente, que foram utilizados como variáveis independentes e, as classes de uso e cobertura da terra, utilizados como variáveis dependentes e incluem Lavoura Permanente, com o cultivo de café por gotejamento e o cultivo de café irrigado por gotejamento em agricultura familiar, Lavoura Temporária, com o cultivo de batata-inglesa em pivô irrigado e o cultivo de arroz por gotejamento, além de Vegetação Natural, representada pela Savana-Estépica Florestada, Campo Rupestre e Savana-Estépica Arborizada.


Esses modelos avaliam o impacto individual de cada banda ou índice na variável da classe. Em seguida, foi gerado um modelo de regressão múltipla, no qual as bandas espectrais e os índices de vegetação foram incluídos conjuntamente na análise. A fim de garantir a acurácia dos modelos gerados, foi avaliado o coeficiente de determinação (R^2), além da análise dos resíduos e da verificação da significância estatística dos modelos a um nível de 95% de probabilidade. Esses métodos permitiram verificar a robustez das predições, assegurando que as relações identificadas fossem significativas e representassem adequadamente a separação entre as diferentes classes.

4.3 RESULTADOS E DISCUSSÃO

4.3.1. Assinaturas espectro-temporais

Na Figura 4.6, observa-se o comportamento dos perfis de NDVI, EVI e NGRDI para a fitofisionomia de Savana-Estépica Arborizada, tipo florestal mais comum no bioma e caracterizado por um estrato arbustivo-arbóreo (IBGE, 2012), localizada na porção oeste do município. Os valores máximos e mínimos variaram entre 0,56 a 0,66 para NDVI, de 0,27 a 0,36 para EVI e de 0,62 a 0,73 para o NGRDI. A ocorrência dos valores elevados dos índices está diretamente associada ao mês de dezembro de 2022 e fevereiro 2024, períodos chuvosos na região. No mês de dezembro, a fitofisionomia alcançou valores de 0,66 (NDVI), 0,36 (EVI) e 0,71 (NGRDI) para uma precipitação de 148 mm e fevereiro 0,65 (NDVI), 0,33 (EVI) e 0,73 (NGRDI). Nota-se que, apesar de comportamento condicionado a precipitação, a Savana-Estépica Arborizada garante um padrão regular nas assinaturas espectrais, pois, mesmo com a redução da distribuição de chuvas, os valores dos índices de vegetação não se reduzem abruptamente, o que já era esperado para o comportamento de uma feição natural.

Figura 4.6 - Assinatura espectro-temporal de NDVI, EVI e NGRDI para fitofisionomia de Savana-Estépica Arborizada no município de Mucugê, Bahia, entre os anos de 2022 a 2024. Fonte: Elaboração dos autores (2024).



Ao verificar o comportamento dos índices para a fitofisionomia Savana-Estépica Florestada, nota-se um padrão de perfil bem próximo ao da Savana-Estépica Arborizada, sem variações acentuadas entre os valores dos índices (Figura 4.7). A Florestada apresenta valores de NDVI variando entre 0,60 e 0,69, de EVI entre 0,28 e 0,36 e de NGRDI 0,56 a 0,61. Destaca-se, que a precipitação foi mais alta nos meses de dezembro de 2022 e dezembro de 2023, ambos registrando 148 mm. Em contraste, setembro de 2022 e setembro de 2023 registraram os menores valores de precipitação, com 43 mm.




Figura 4.7 - Assinatura espectro-temporal de NDVI, EVI e NGRDI para fitofisionomia de Savana Estépica-Florestada no município de Mucugê, Bahia, entre os anos de 2022 a 2024. Fonte: Elaboração dos autores (2024).

Somando a isto, foram selecionados pontos representativos nos mosaicos mensais do PlanetScope para compor a análise de perfis temporais de IVs para identificar uma padronização dos principais usos e coberturas identificados no município, de forma a estabelecer uma biblioteca de valores temporais de EVI, NDVI e NGRDI (Figura 4.4).

No entanto, mesmo com a redução da pluviosidade, os valores dos índices de vegetação não diminuíram significativamente. Isso se deve ao fato de que a Savana-Estépica Florestada não apresenta deciduidade elevada, comum da vegetação típica da Savana-Estépica, ou seja, essa fitofisionomia é caracterizada por um dossel semi-contínuo, com vegetação predominante nas proximidades das matas ciliares do município (IBGE, 2012). Essa característica garante uma maior estabilidade nos índices de vegetação ao longo do ano, refletindo a capacidade dessa vegetação de manter a sua biomassa e atividade fotossintética mesmo em períodos de menor disponibilidade hídrica. Em acordo com o que afirmaram Pacheco *et al.* (2023), os índices de vegetação estudados mostraram sensibilidade às áreas com vegetação nativa, mesmo estando no período seco.

A Figura 4.8 apresenta o comportamento dos índices de vegetação para o Campo Rupestre, tipologia de vegetação associada ao Cerrado e que também é encontrada no município de Mucugê, principalmente em áreas rochosas e mais elevadas (Roque *et al.*, 2016), com predomínio de vegetação herbáceo-arbustiva e com a presença eventual de árvores pouco desenvolvidas (Sano *et al.*, 2008).




Figura 4.8 - Assinatura espectro-temporal de NDVI, EVI e NGRDI para a fitofisionomia de Campo Rupestre no município de Mucugê, Bahia, entre os anos de 2022 a 2024. Fonte: Elaboração dos autores (2024).

Os perfis de NDVI, EVI e NGRDI para o Campo Rupestre revelaram características distintas em comparação com as fitofisionomias de Savana-Estépica Arborizada e Florestada. O NDVI apresenta uma variação de valores menores (0,10 a 0,64), refletindo pouca densidade de vegetação típica dessa tipologia (Harley; Simmons, 1986; Sano *et al.*, 2008; Roque *et al.*, 2016). A presença de áreas rochosas e a vegetação menos densa influenciam diretamente nos valores de NDVI, o que pode justificar a ocorrência de valores próximos a 0,10, com uma alta amplitude, mesmo com a manutenção da pluviosidade. Em consonância, o NGRDI (0,10 a 0,66) segue similar ao do NDVI, mas com variações mais graduais, isto porque, por utilizar a banda do verde, é menos sensível à saturação do NDVI (Jannoura *et al.*, 2014).

Em contraste, o EVI (0,13 a 0,36) tende a capturar de forma mais precisa as variações na vegetação do Campo Rupestre, mesmo em áreas com menor biomassa. Isso ocorre porque o EVI é mais sensível às variações na estrutura da vegetação e é menos afetado pelo solo exposto (Huete *et al.*, 2002), o que é comum em áreas rochosas e elevadas. Assim, os valores de EVI fornecem uma representação mais fiel das condições vegetativas do Campo Rupestre. Além disso, os índices apresentam uma resposta espectral menos estável ao longo da série, quando comparado às fisionomias anteriores.

Na Figura 4.9, tem-se o comportamento de uma lavoura temporária, em específico, o arroz irrigado por gotejamento. O cultivo dessa cultura varia de três a seis meses, a

dependem das condições ambientais (Guimarães, Fageria; Barbosa Filho, 2002). Tal condição pode ser percebida nos perfis temporais de NDVI, EVI e NGRDI, que variaram de 0,35 a 0,78; 0,24 a 0,69 e 0,62 a 0,73, respectivamente. No ano de 2022, evidencia-se a ocorrência de cultivos entre os meses de abril a junho e de agosto a outubro, demarcando os períodos entre plantio e colheita. Já para o ano de 2023, a partir do mês de abril de 2023 esta relação não fica evidente para os três índices, apesar de haver redução nos valores de índices.



Figura 4.9 - Assinatura espectro-temporal de NDVI, EVI e NGRDI para Lavoura Temporária – cultura de arroz irrigado por gotejamento no município de Mucugê, Bahia, entre os anos de 2022 a 2024. Fonte: Elaboração dos autores (2024).

Os perfis demonstram claramente a relação entre o comprimento e a amplitude dos ciclos do cultivo. Durante o período de crescimento, os valores dos índices de vegetação aumentam progressivamente, atingindo picos correspondentes à fase de maior vigor vegetativo, destacando-se os meses de setembro de 2022 (NDVI = 0,78; EVI = 0,69; NGRDI = 0,63); dezembro de 2022 (NDVI = 0,73; EVI = 0,57; NGRDI = 0,72) e maio de 2023 (NDVI = 0,72; EVI = 0,66; NGRDI = 0,62).

A amplitude dos valores entre os ciclos de cultivo é notável, com ambos os índices mostrando redução após o tempo estimado de colheita, com destaque para o mês de julho de 2022 (NDVI = 0,33; EVI = 0,23; NGRDI = 0,64) e janeiro de 2023 (NDVI = 0,41; EVI = 0,30; NGRDI = 0,70). Tais meses são correspondentes à temporalidade média indicada para o cultivo. Essa variação entre os valores máximos e mínimos é indicativa da dinâmica das lavouras temporárias que são altamente influenciadas por práticas de manejo e condições ambientais específicas (Magalhães Júnior; Gomes; Santos, 2004), o que proporcionam a amplitude citada, correspondente à exposição do solo após a colheita

agrícola e ao elevado vigor vegetativo alcançados pelas coberturas vegetais com padrão homogêneo. No entanto, nota-se que não há redução abrupta para os valores de NGRDI, o que indica sugerindo ainda uma diferenciação entre a cobertura vegetal e o solo.

Ainda no contexto de lavoura temporária, na Figura 4.10, têm-se os perfis temporais para o cultivo de batata-inglesa em área de pivô irrigado, com duração média de três a quatro meses de plantio. Entre os meses de 2022, é perceptível um padrão homogêneo nas assinaturas espectrais, o que permite inferir que não havia plantio de batata, haja vista que não há variação de valores (amplitude), sem aumento e redução do vigor vegetativo que possa ser associado ao comportamento de um cultivo.




Figura 4.10 - Assinatura espectral-temporal de NDVI, EVI e NGRDI para Lavoura Temporária – cultura de batata-inglesa em pivô irrigado no município de Mucugê, Bahia, entre os anos de 2022 a 2024. Fonte: Elaboração dos autores (2024).

No entanto, ao observar o período de abril a agosto de 2023, nota-se o início da ocorrência de perfis temporais condizentes com que se espera de ciclos de crescimento de culturas, com variação de valores entre 0,83 a 0,29 (NDVI); 0,79 a 0,16 (EVI); 0,64 a 0,52 (NGRDI). Para o mês de agosto de 2023, destaca-se o declínio do vigor vegetativo associado ao cultivo, evidenciado pelo NDVI e EVI. No entanto, o comportamento do NGRDI sugere que, apesar da redução nos índices de vegetação, ainda há presença de cobertura vegetal no terreno, infere-se a presença de vegetação remanescente. Assim como observado por Leivas *et al.* (2022), para o cultivo de soja, os perfis temporais de NDVI e EVI da batata-inglesa apresentaram baixos valores no início do ciclo (abril), seguido de aumento nos valores dos índices, de forma a atingir o máximo valor próximo ao florescimento da cultura, no mês de maio, e decrescendo a seguir, por consequência da senescência das plantas.

Após a senescência, o comportamento inicial dos perfis temporais tende a retornar a um padrão homogêneo próximo ao inicial, isto porque há a necessidade de rotatividade da cultura de batata-inglesa no pivô irrigado, realizando um replantio para este cultivo a cada três anos, conforme constatado durante a visita de campo. Tal prática é comum na região, tornando-se necessária para manter a saúde do solo e a produtividade das lavouras.

Para a Lavoura Permanente, nota-se um comportamento diferente da lavoura temporária, o que já era esperado, considerando-se a duração dos ciclos de cultivos. A duração do cultivo do café é indicada de dois a três anos. Na Figura 4.11, tem-se a relação entre NDVI, EVI e NGRDI e a precipitação para cultivo de café irrigado por gotejamento em área de fazenda e para o mesmo cultivo em uma área de agricultura familiar (Figura 4.12).




Figura 4.11 - Assinatura espectral-temporal de NDVI, EVI e NGRDI para Lavoura Permanente – café irrigado por gotejamento em área de fazenda no município de Mucugê, Bahia, entre os anos de 2022 a 2024. Fonte: Elaboração dos autores (2024).

Na área de cultivo de café na fazenda, observa-se uma uniformidade marcante nos perfis de NDVI e EVI. Este fenômeno pode ser atribuído a diversos fatores, incluindo o tamanho semelhante das folhas, o espaçamento regular entre as plantas e as práticas consistentes de manejo agrícola adotadas na área. A interação desses elementos provavelmente contribui para a estabilidade dos índices. Os valores não apresentam elevada amplitude com variação no NDVI de 0,87 a 0,69, no EVI de 0,69 a 0,24 e NGRDI de 0,77 a 0,66.

No entanto, destaca-se a faixa temporal entre novembro de 2022 a maio de 2023 em que houve uma variação significativa nos perfis de NDVI, EVI, NGRDI com variações de para 0,76 a 0,83; 0,54 a 0,63; 0,71 a 0,76, respectivamente. Essa flutuação

pode ser indicativa de eventos sazonais, práticas agrícolas ou mesmo condições ambientais específicas que afetaram o cultivo durante esse intervalo de tempo. Ademais, destaca-se que, mesmo com a redução da pluviosidade no período de estiagem (junho a outubro), o padrão dos perfis se manteve homogêneo. Destaca-se, o comportamento do perfil de NGRDI, que mesmo com a redução de valores de NDVI e EVI, o padrão deste índice se mantém, o que reforça a continuidade da cobertura vegetal.

A Figura 4.12 revela um comportamento distinto dos perfis comparado ao observado anteriormente na área de cultivo de café na fazenda, conforme apresentado na Figura 4.11. Os índices NDVI, EVI e NGRDI apresentaram variações mais acentuadas, refletindo uma maior heterogeneidade na área estudada. Os valores de NDVI variaram de 0,71 a 0,41, de EVI variaram de 0,69 a 0,24, enquanto que o NGRDI varia de 0,74 a 0,74. Essa variação mais ampla sugere que há diferenças significativas na cobertura vegetal e na condição da vegetação dentro da área analisada. No entanto, ainda há manutenção da vegetação, indicado principalmente pelo comportamento espectro-temporal do NGRDI, que é mais sensível a presença de clorofila e pode fornecer uma melhor distinção entre a vegetação e o solo (Hunt *et al.*, 2005; Haddad *et al.*, 2022).




Figura 4.12 - Assinatura espectro-temporal de NDVI, EVI e NGRDI para Lavoura Permanente – café irrigado por gotejamento em área de agricultura familiar no município de Mucugê, Bahia, entre os anos de 2022 a 2024. Fonte: Elaboração dos autores (2024).

A heterogeneidade na resposta sazonal dos cultivos pode ser atribuída a diversos fatores. Áreas com densidades diferentes podem exibir padrões sazonais distintos devido à variação na quantidade de biomassa vegetal e na atividade fotossintética ao longo do ano. A mesma cultura agrícola (café) pode estar susceptível a características sazonais únicas, influenciadas por fatores como ciclo de crescimento, requerimentos hídricos e sensibilidade a variações climáticas sazonais.

As práticas de manejo adotadas pelos agricultores, como irrigação, aplicação de fertilizantes, controle de pragas e uso de técnicas de cultivo conservacionistas também podem impactar a resposta sazonal da vegetação. Nas áreas de agricultura familiar, a diversidade de cultivos, a rotação de culturas e as técnicas de cultivo tradicionais podem contribuir na resposta sazonal da vegetação. A presença de remanescentes de vegetação nativa ou áreas de vegetação natural adjacente a áreas cultivadas também podem influenciar devido a diferenças nos tipos de vegetação.

4.3.2. Regressão linear múltipla – avaliação dos modelos preditores

A Tabela 4.2 apresenta os resultados das regressões múltiplas e do modelo final (denotados por B, G, R, NIR, NDVI, EVI e NGRDI) correlacionando com as diferentes classes qualitativas. Pode-se notar que, dentre os resultados das regressões, o menor erro padrão residual é observado no Modelo G (0,037), com as classes de Arroz Irrigado, Batata-inglesa, Café em área de agricultura familiar e Campo Rupestre. Ainda neste contexto, ao observar o desempenho do modelo NDVI, destaca-se com o maior erro padrão residual (0,11), medida de variabilidade entre os erros residuais, relacionado à precisão das estimativas dos parâmetros do modelo (Kohn; Kalscheur; Hanigan, 1998; Ahrens, 1982). Tal correspondência pode indicar que o modelo não está ajustado ou que não está capturando as variáveis e padrões relevantes da forma mais eficaz quando comparado aos outros modelos. Em contraponto, este modelo apresenta significância de seis classes preditoras.

Quando observamos o p-value das regressões, evidencia-se que todos os modelos têm um valor inferior a $2.2e-16$, indicando que são altamente significativos, uma vez que, o valor de corte para rejeitar a hipótese é 0,05 (Ferreira; Patino, 2015). No entanto, o modelo NIR apresenta o maior F-Estatístico (632,1) e maior R^2 (0,52), explicando 52% da variação na variável dependente, sugerindo que é um forte preditor com alta significância estatística, haja vista que, quanto maior o R^2 , maior a capacidade que o modelo tem de explicar a variável de interesse (Chiode, 2020), neste caso, as classes de uso e cobertura.

Reforça a afirmação anterior, pela alta significância das classes preditoras no modelo NIR, em que seis das sete classes apresentam significância elevada (Tabela 4.2). Apesar disto, o Modelo B apresenta-se com menor F-Estatístico (51,23) e menor R^2

(0,082), indicando que, apesar de ser significativo, ele é o menos forte como preditor de agrupamento e separabilidade das variáveis, com alta significância de apenas três classes - Arroz Irrigado, Batata Inglesa e Campo Rupestre.

Quando avaliado o modelo final de regressão (Tabela 4.2), afirma-se há um bom ajuste geral com um valor elevado de R^2 (0,75), com relação de 75% entre as variáveis e F-estatístico (1508), indicando que as médias dos grupos são significativamente diferentes umas das outras. Destaca-se ainda, que dentre as correspondências dos modelos utilizados para o final, o G apresenta maior erro residual (8,486) e o NDVI o menor (1,684), em contraste com a regressão linear individual. Ao avaliarmos o p-value, evidencia-se que os modelos do NIR ($1.94e-05$) e EVI (0,088) apresentam-se abaixo dos outros modelos, de forma que o EVI indica uma significância menor que 0,05.

Tabela 4.2 - Resultados das regressões lineares múltiplas considerando as bandas espectrais, os índices de vegetação e as classes preditoras.

		Modelo B	Modelo G	Modelo R	Modelo NIR	Modelo NDVI	Modelo EVI	Modelo NGRDI
Modelo Múltiplas Regressão	Erro padrão médio	0,038	0,037	0,045	0,059	0,11	0,098	0,076
	R ²	0,082	0,19	0,25	0,52	0,43	0,47	0,5
	p-value	< 2.2e-16	< 2.2e-16	< 2.2e-16	< 2.2e-16	< 2.2e-16	< 2.2e-16	< 2.2e-16
	F - Estatístico	51,23	136,6	188,7	632,1	436,6	503,6	568,8
	Classe com maior significância (p < 0.001)	Arroz Irrigado; Batata Inglesa e Campo Rupestre	Arroz Irrigado; Batata Inglesa, Café Agro Familiar e Campo Rupestre	Arroz Irrigado; Batata Inglesa, Café Agro Familiar, Campo Rupestre e Savana-Estépica Florestada	Arroz Irrigado; Batata Inglesa, Café Agro Familiar, Café Fazenda; Campo Rupestre e Savana-Estépica Florestada	Arroz Irrigado; Batata Inglesa, Café Agro Familiar, Café Fazenda; Campo Rupestre e Savana-Estépica Florestada	Batata Inglesa, Café Fazenda; Campo Rupestre e Savana-Estépica Florestada	Arroz Irrigado; Batata Inglesa, Café Fazenda; Campo Rupestre e Savana-Estépica Florestada
Modelo final de Regressão	Erro padrão médio	3,836	8,486	5,149	3,262	1,684	2,295	1,963
	p-value	< 2.2e-16	< 2.2e-16	< 2.2e-16	1.94E-05	< 2.2e-16	0,088	< 2.2e-16
	F - Estatístico				1508			
	R ²				0,758			
	Classe com maior significância (p < 0.001)	Bandas: B; G; R; NIR; NDVI e NGRDI						

Em que = As bandas B, G, R e NIR representam as bandas espectrais do satélite PlanetScope nas faixas azul, verde, vermelho e infravermelho próximo, respectivamente

4.3.3. Agrupamento e separabilidade das classes predictoras

Na Figura 4.13 tem-se o resultado da árvore de decisão, de forma geral, pode-se notar o agrupamento e separabilidade de dois diferentes grupos, as fitofisionomias *versus* as culturas agrícolas. O primeiro critério de agrupamento e divisão no dendograma corresponde a banda do verde ($G < 0,06995$), que representa uma variável inicial de classificação. A seguir, a divisão é realizada com base nos valores do infravermelho próximo ($NIR < 0,3051$), usado para segmentar os dados e distinguir fitofisionomias de cultura permanente, em específico, o café. Em consonância, a banda do vermelho do vermelho ($R < 0,04945$) fornece uma nova camada de diferenciação. Destacam-se, em sequência, os índices de vegetação NDVI e EVI como principais predictoras no agrupamento e diferenciação entre as classes.




Figura 4.13 - Dendograma derivado do algoritmo de classificação e regressão CART. Em que: Arborizada = Savana-Estépica Arborizada; Florestada = Savana-Estépica Florestada; Café_AFamiliar = Café Agricultura Familiar; Café_Fazenda = Café em área de fazenda. Fonte: Elaboração dos autores (2024).

De imediato, com a indicação de $EVI < 0,2401$, torna-se possível agrupar as lavouras temporárias de Batata-inglesa e Arroz irrigado, isto porque, em período de senescência estas classes vão alcançar valores mais baixos quando comparado as outras

áreas de lavouras e as fitofisionomias. Além disso, destaca-se o fator temporalidade, a relação entre aumento e redução de vigor vegetativo se dá em curtos períodos, o que auxilia o EVI a separá-las das demais.

Ao analisarmos o agrupamento indicado por $NIR < 0,3051$, é possível destacar a ocorrência de classes que possuem comportamentos de manutenção de atividade vegetativa por um período mais prolongado. Estas classes incluem as fitofisionomias e a lavoura permanente de café, que são caracterizadas por uma vegetação que permanece ativa por mais tempo. Analogamente, o café é diferenciado entre a área de cultivo em fazenda e área de agricultura familiar, considerando o $EVI < 0,50715$, que permite distinguir entre esses dois tipos de cultivo devido às diferenças em suas características de cultivos, previamente indicadas nas séries temporais de IVs.

Em sequência, o agrupamento indicado por $R < 0,0495$ permite agregar as fitofisionomias naturais, de mesmo modo que distingue da lavoura, isto porque, vegetação mais saudáveis ou plena atividade fotossintética apresentam baixa reflectância no canal vermelho devido à densidade da vegetação e à alta concentração de clorofila (Ponzoni; Shimabukuro; Kuplich, 2015), resultando em valores mais baixos de R. No entanto, é apenas através do NDVI e EVI que se torna possível agrupar de forma categórica as fitofisionomias.

A distinção entre o Campo Rupestre e a Savana-Estépica Arborizada é eficazmente realizada utilizando valores de EVI inferiores a 0,34815. O Campo Rupestre é caracterizado por uma vegetação menos densa, resultando em valores mais baixos de EVI que refletem uma vegetação mais esparsa e menos vigorosa. Em contraste, a Savana-Estépica Arborizada possui uma vegetação mais densa, o que se traduz em valores de EVI relativamente mais altos e constantes. Além disso, destaca-se o EVI como índice preciso as variações associadas ao CP.

Para diferenciar as classes Florestada e Arborizada, destaca-se o uso do NDVI com um valor de corte de $< 0,6241$ como preditor principal. O NDVI, que mede a densidade da vegetação (Rouse *et al.*, 1973), é particularmente eficaz em identificar áreas com cobertura florestal densa, caracterizando a classe Florestada. Em comparação, a classe Arborizada possui uma vegetação menos densa, resultando em valores de NDVI mais baixos. Adicionalmente, observa-se que as fitofisionomias, exigem um maior número de nós para serem distinguidas entre si, em contraste com as áreas de lavouras, que apresentam uma separação mais clara com menos nós.

4. CONCLUSÃO

A análise das séries temporais dos índices de vegetação, incluindo NDVI, EVI e NGRDI, para as fitofisionomias Savana-Estépica Arborizada, Savana-Estépica Florestada, Campo Rupestre e para as culturas agrícolas de batata-inglesa, arroz e café revelou variações sazonais e mudanças nos perfis espectrais. Esses dados proporcionaram uma compreensão detalhada da dinâmica da vegetação no município de Mucugê e demonstraram o potencial dos índices de vegetação para discriminar diferentes tipos de fitofisionomias e culturas agrícolas.

O modelo linear de regressão permitiu uma avaliação aprofundada da influência das diferentes bandas espectrais e índices na separabilidade das classes vegetacionais. A análise mostrou que os índices de vegetação são fundamentais para a distinção entre as fitofisionomias e culturas. O dendrograma construído a partir dessas análises evidenciou como diferentes classes vegetacionais são agrupadas com base nos valores das bandas e dos índices. A separação entre as fitofisionomias e as lavouras foi evidente a partir destes dados, no entanto, destaca-se a necessidade de diferentes dados para distinguir as fitofisionomias entre si.

O uso de dados de alta resolução espacial e temporal do PlanetScope, combinado com métodos avançados de análise de índices de vegetação, demonstrou um potencial significativo para o monitoramento ambiental e para a compreensão do comportamento fenológico. Destaca-se a importância dos dados de precipitação na análise, pois garantem uma avaliação mais precisa da dinâmica das classes, considerando tanto a regularidade quanto a distribuição do padrão de chuvas.

Além disso, os dados provenientes do trabalho de campo foram cruciais para a construção e validação desta pesquisa, integrando e respaldando a análise das séries temporais. A análise da dinâmica espaço-temporal através dos índices de vegetação revelou-se eficiente e recomendada para aplicação em outras tipologias de vegetação na área de estudo ou em ambientes diversos, oferecendo uma abordagem robusta para o monitoramento e a gestão ambiental.

REFERÊNCIAS

- AB'SABER, A. N. **Domínios da Natureza**. São Paulo: Ateliê Editorial, 2003.
- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; GONÇALVES, J. L. M.; SPAVOREK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2014.
- AHRENS, S. **Importância da distribuição de resíduos de regressão na seleção de equações de volume**. In: EMBRAPA. Unidade Regional de Pesquisa Florestal Centro-Sul (Curitiba). Contribuição da URPFCs ao 4. Congresso Florestal Brasileiro. Curitiba: EMBRAPA-URPFCS, 1982.
- BARROS, A. S.; FARIAS, L. D.; MARINHO, J. L. A. Aplicação do índice de vegetação por diferença normalizada (NDVI) na caracterização da cobertura vegetal de Juazeiro do Norte–CE. **Revista Brasileira de Geografia Física**, v. 13, n. 6, p. 2885-2895, 2020.
- BORGES, E. F. **Aplicação das geotecnologias para a definição do zoneamento geoambiental do município de Mucugê – BA** (Mestrado em Modelagem de Ciências da Terra e do Ambiente). Feira de Santana: Universidade Estadual de Feira de Santana, 2008, 147 p.
- BORGES, E. F.; SANO, E. E. Séries temporais de EVI do MODIS para o mapeamento de uso e cobertura vegetal do Oeste da Bahia. **Boletim de Ciências Geodésicas**, v. 20, n. 3, p. 526-547, 2014.
- CARON, M. L.; MINUZZI, R. B. Estimativa de produtividade de soja com uso de perfis temporais de índices de vegetação do sensor MODIS no município de Sapezal, Mato Grosso. **Revista Brasileira de Geografia Física**, v. 15, n. 3, p. 1660-1675, 2022.
- CHIODE, A. S. **Avaliação de propostas de coeficientes de determinação do tipo R^2 em modelos de regressão logística com resposta nominal**. 2020. 124f. Dissertação (Mestrado) – Instituto de Matemática e Estatística, Universidade de São Paulo, 2020.
- CLIMA TEMPO. Climatologia em Mucugê: Climatologia e histórico de previsão do tempo em Mucugê, BR. Disponível em: <https://www.climatempo.com.br/climatologia/3402/mucuge-ba>. Acesso em: 10 ago. 2023.
- COSTA, G. J. A.; RIBEIRO, K. V.; ALBUQUERQUE, E. L. S. Aplicação do índice de vegetação por diferença normalizada (NDVI) na avaliação da cobertura vegetal do município de regeneração, estado do Piauí, Brasil. **Revista Geonordeste**, v. 2, p. 230-246, 2020.
- FERREIRA, J. C.; PATINO, C. M. What does the p-value really mean? **Jornal Brasileiro de Pneumologia**, v. 41, n. 5, 485, 2015.
- FILGUEIRAS, R.; NICOLETE, D. A. P.; CUNHA, A. R.; ZIMBACK, C. R. L. Variação espaço-temporal da condição da vegetação no interior paulista. **Nativa**, v. 7, n. 5, p. 582-588, 2019.

FLORENZANO, T.G. **Imagens de satélite para estudos ambientais**. São Paulo: Oficina de Textos, 2002.

GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18–27, 2017.

HADDAD, I.; GALVÃO, L. S.; BREUNIG, F. M.; DALAGNOL, R.; BOURSCHEIDT, V.; JACON, A. D. On the combined use of phenological metrics derived from different PlanetScope vegetation indices for classifying savannas in Brazil. **Remote Sensing**, v. 26, 100764, 2022.

HARLEY, R. M.; SIMMONS, N. A. Flórlula de Mucugê, Chapada Diamantina, Bahia, Brazil. **Royal Botanic Gardens**, p. 34-49, 1986.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The Elements of Statistical Learning: Data Mining, Inference, and Prediction**. Springer, 2009.

HOSMER Jr., D. W.; LEMESHOW, S.; STURDIVANT, R. X. **Applied logistic regression**. John Wiley & Sons, 2013.

HUETE, A.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E. P.; GAO, X.; FERREIRA, L. G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, p. 195–213, 2002.

HUNT Jr., E. R.; CAVIGELLI, M.; DAUGHTRY, C. S. T.; MCMURTREY III, J.; WALTHALL, C. L. Evaluation of digital photography from model aircraft for remote sensing of crop biomass and nitrogen status. **Precision Agriculture**, v. 6, p. 359–378, 2005.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Manual técnico da vegetação brasileira**. Série manuais técnicos em Geociências 1. 2a ed. Instituto Brasileiro de Geografia e Estatística, Rio de Janeiro. 275 p., 2012.

IDE, A. K.; BAPTISTA, G. M. M. MODIS time series for irrigated-area mapping in hydrographic basins of the Brazilian Northeastern region. **Pesquisa Agropecuária Brasileira**, v. 53, n. 1, p. 80-89, 2018.

GOUVEIA, J. R. F.; NASCIMENTO, C. R. Uso e cobertura do solo após eventos de queimadas no município de Floresta em Pernambuco. **Revista Brasileira de Geografia Física**, v. 15, n. 6, p. 3121-3135, 2022.

GUIMARÃES, C. M.; FAGERIA, N. K.; BARBOSA FILHO, M. P. Como a planta de arroz se desenvolve. **Encarte do Informações Agronômicas**, n. 99, Arquivo do Agrônomo, 13 setembro 2002.

JANNOURA, R.; BRINKMANN, K.; UTEAU, D.; BRUNS, C.; JOERGENSEN, R. G. Monitoring of crop biomass using true colour aerial photographs taken from a remote controlled hexacopter. **Biosystems Engineering**, v. 129, p. 341-351, 2015.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: Uma Perspectiva em Recursos Terrestres**. Tradução de José Carlos Epiphânio (coord.) et al. São José dos Campos: Parêntese, 2009.

JUSTICE, C. O.; VERMOTE, E.; TOWNSHEND, J. R. G.; DeFRIES, R.; ROY, D. P.; et al. The moderate resolution imaging spectroradiometer (MODIS): Land remote sensing for global change research. **IEEE Transactions on Geoscience and Remote Sensing**, v. 36, p. 1228-1249, 1998.

KOHN, R.A.; KALSCHEUR, K.F.; HANIGAN, M. Evaluation of models for balancing the protein requirements of dairy cows. **Journal of Dairy Science**, v. 81, n. 12, p. 3401-3414, 1998.

LI C, CAI R, TIAN W, YUAN J, MI X. Land cover classification by Gaofen satellite images based on CART algorithm in Yuli County, Xinjiang, China. **Sustainability**, v. 15, n. 3, p. 2535, 2023.

LEIVAS, J.F.; TEIXEIRA, A.H DE C.; TAKEMURA, C.M.; GARCON, E.A.M. Análise da dinâmica temporal de índices de vegetação NDVI, EVI, SAVI e IRECI através de imagens Sentinel-2a e MODIS. In: MELO, J. O. F. (Org.). **Ciências agrárias: o avanço da ciência no Brasil**. São Paulo, SP: Editora Científica Digital, 2022. cap. 21.

MAGALHÃES JÚNIOR, A. M.; GOMES, A. S.; SANTOS, A. B. **Sistema de cultivo de arroz Irrigado no Brasil**. Pelotas: Embrapa Clima Temperado, 2004, 270 p.

MENESES, P. R; ALEIDA, T. **Introdução ao Processamento Imagens de Sensoriamento Remoto**. Brasília: UNB, 2012.

NING, T.; LIU, W.; LIN, W. NDVI variation and its responses to climate change on the northern loess plateau of China from 1998 to 2012. **Advanced Meteorology**, p. 1–10, 2015.

OLIVEIRA, M. T.; 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, 2020.

PANDEY, P.; KINGTON, J.; KANWAR, A.; CURDOGLO, M. Addendum to Planet basemaps product specifications: NICFI basemaps. Revision: v02. NICFI. 2023. Disponível em: https://assets.planet.com/docs/NICFI_Basemap_Spec_Addendum.pdf. (acesso em: 07 jan. 2024).

PLANET TEAM. **Planet Application Program Interface: In Space for Life on Earth**. San Francisco, CA, 2017.

PLANET. **Planet Imagery Product Specifications**, 2002a, 101 p. Disponível em: https://assets.planet.com/docs/Planet_Combined_Imagery_Product_Specs_letter_screen.pdf. Acesso em: 31 jun. 2022.

PICOLI, M. CAMARA, G.; SANCHES, I.; SIMÕES, R.; CARVALHO, A.; MACIEL, A.; COUTINHO, A.; ESQUERDO, J.; ANTUNES, J.; BEGOTTI, R.; ARVOR, D.;

ALMEIDA, C. Big earth observation time series analysis for monitoring Brazilian agriculture. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 145, p. 328-339, 2018.

RISSO, J.; RIZZI, R.; RUDORFF, B. F. T.; ADAMI, M.; SHIMABUKURO, Y. E.; FORMAGGIO, A. R.; EPIPHANIO, R. D. V. Índices de vegetação MODIS aplicados na discriminação de áreas de soja. **Pesquisa Agropecuária Brasileira**, v. 47, p. 1317-1326, 2012.

RIPLEY, B. Package 'tree'. **Classification and Regression Trees, Version 1.0-43**. Disponível em: <https://cran.r-project.org/web/packages/tree/tree.pdf>. Acesso em: 18 jul. 2024.

ROQUE, N.; OLIVEIRA, E. C. D.; MOURA, L.; QUARESMA, A. S.; OGASAWARA, H. A.; ALVES, M.; BAUTISTA, H. P. Asteraceae no município de Mucugê, Chapada Diamantina, Bahia, Brasil. **Rodriguésia**, v. 67, p. 125-202, 2016.

ROY, D. P.; HUANG, H.; HOUBORG, R.; MARTINS, V. S. A global analysis of the temporal availability of PlanetScope high spatial resolution multi-spectral imagery. **Remote Sensing of Environment**, v. 264, 112586, 2021.

SANO, E. E.; BOLFE, É. L.; PARREIRAS, T. C.; BETTIOL, G. M.; VICENTE, L. E.; SANCHES, I. D. A.; VICTORIA, D. D. C. Estimating double cropping plantations in the Brazilian Cerrado through PlanetScope monthly mosaics. **Land**, v. 12, n. 3, 581, 2023.

SANTOS, F. S. D.; GOMES, H. B.; BARROS, G. V. P. D.; ALVES, L. E. R.; SILVA, D. F. D.; COSTA, R. L.; OLIVEIRA, J. F. D. Análise sazonal dos parâmetros biofísicos utilizando o sensor MODIS para o estado de Alagoas. **Revista Brasileira de Meteorologia**, v. 35, p. 955-968, 2020.

SANTOS, H. C. A.; CALDEIRA, C. R. T.; COSTA, Y. K. S.; SILVA, T. M.; LEITE, T. V. S.; LIMA, V. M.; GONÇALVES, M. A. S. **Análise multitemporal de uso e ocupação do solo com enfoque na agricultura, pecuária e extração do seixo no município de Ourém/PA, nos anos de 2016 a 2020**. Seven Editora, 2024.

SARTORIO, L. F., VARNIER, M., FELIPPE, L. D. S., ZANOTTA, D. C., FREITAS, M., GRONDONA, A. Análise comparativa entre o uso de bandas espectrais e o uso da análise de componentes principais (ACP) na Classificação de uso e cobertura da terra. **Revista Brasileira de Cartografia**, v. 75, 2023.

SILVA, M. R.; CARTAXO, P. H. A.; ARAÚJO, H. M.; LACERDA, L. B.; GONZAGA, K. S.; SANTOS, A. S.; SANTOS, J. P. O. Análise e mapeamento da vegetação remanescente de um município do agreste de Alagoas (Brasil). **Meio Ambiente**, v. 1, n. 1, 2020.

SILVEIRA, N. T., SANTOS, T. O.; TIBÚRCIO, I. M.; GALVÍNCIO, J. D. Aplicação do Índice de Vegetação por Diferença Normalizada (NDVI) para a análise espaço-temporal da bacia hidrográfica do rio Terra Nova, Pernambuco, Brasil. **Revista Brasileira de Sensoriamento Remoto**, v. 3, 2022.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da vegetação**. Oficina de Textos, 2015.

TRINDADE, F. S.; ALVES, M. C.; NOETZOLD, R.; ANDRADE, I. C.; POZZA, A. A. A. Relação espectro-temporal de índices de vegetação com atributos do solo e produtividade da soja. **Revista de Ciências Agrárias Amazonian Journal of Agricultural and Environmental Sciences**, v. 62, 2019.

VEIGA, A. J. P.; DA MATTA, J. M. B.; VEIGA, D. A. M.; BOMFIM, C. S. S. Análise do uso e cobertura da terra em Itapetinga no estado da Bahia, Brasil, com uso de Sensoriamento Remoto e SIG. **Brazilian Journal of Development**, v. 6, n. 9, p. 73928-73947, 2020.

WELSINK, A. J.; REICHE, J.; DE SY, V.; CARTER, S.; SLAGTER, B.; SUAREZ, D. R.; HEROLD, M. Towards the use of satellite-based tropical forest disturbance alerts to assess selective logging intensities. **Environmental Research Letters**, v. 18, n. 5, 054023, 2023.

5. CAPÍTULO 5

ARTIGO 2: CLASSIFICAÇÃO DE CULTURAS AGRÍCOLAS NO MUNICÍPIO DE MUCUGÊ, CHAPADA DIAMANTINA, BAHIA A PARTIR DE MOSAICOS MENSAIS DO SATÉLITE PLANETSCOPE

RESUMO: O mapeamento e classificação do uso e cobertura da terra na Caatinga por meio de dados de sensoriamento remoto é uma iniciativa ainda desafiadora. Tendo em vista os recentes lançamentos de nanossatélites de sensoriamento remoto, esta pesquisa objetivou analisar o potencial de mosaicos mensais do satélite PlanetScope na classificação de culturas agrícolas temporárias e permanentes do município de Mucugê, Chapada Diamantina, Bahia. Foram utilizados mosaicos mensais do satélite PlanetScope correspondentes aos meses de setembro de 2023 e março de 2024 convertidos para índices de vegetação por diferença normalizada (NDVI), índice de vegetação realçado (EVI) e atributos texturais derivados da matriz de co-ocorrência de níveis de cinza (GLCM), junto aos dados amostrais de campo, em que foram coletados 200 pontos representativos entre fitofisionomias e culturas agrícolas temporárias e permanentes. No processo de classificação utilizou-se o classificador não-paramétrico Random Forest, de forma que os atributos espectrais e texturais mais importantes, definidos na fase de treinamento, foram utilizadas para mapear as culturas agrícolas. Os resultados obtidos mostraram alta acurácia global, especialmente durante o período seco, atingindo até 92,03%, com erro estimado de 5,08% bem como a importância de atributos texturais derivados das quatro bandas espectrais disponíveis (R, G, B, NIR) particularmente a média e a variância na classificação. Para o período chuvoso, a acurácia global foi de 87,45%, com erro estimado de 7,91%. Tal abordagem pode ser replicada para outras áreas de caatinga e também aprimorada para identificar culturas específicas.

ABSTRACT: Mapping and classifying land use and cover in the Caatinga using remote sensing data is still a challenging initiative. In view of the recent launches of remote sensing nanosatellites, this research aimed to analyze the potential of monthly mosaics from the PlanetScope satellite in classifying temporary and permanent agricultural crops in the municipality of Mucugê, Chapada Diamantina, Bahia. Monthly mosaics from the PlanetScope satellite corresponding to the months of September 2023 and March 2024

were used, converted to normalized difference vegetation indices (NDVI), enhanced vegetation index (EVI) and textural attributes derived from the co-occurrence matrix of levels of gray (GLCM), together with field sampling data, in which 200 representative points were collected between phytophysionomies and temporary and permanent agricultural crops. In the classification process, the non-parametric Random Forest classifier was used, so that the most important spectral and textural attributes, defined in the training phase, were used to map agricultural crops. The results obtained showed high overall accuracy, especially during the dry period, reaching up to 92.03%, with an estimated error of 5.08%, as well as the importance of textural attributes derived from the four available spectral bands (R, G, B, NIR) particularly the mean and variance in classification. For the rainy season, the overall accuracy was 87.45%, with an estimated error of 7.91%. This approach can be replicated to other caatinga areas and also improved to identify specific crops.

5.1. INTRODUÇÃO

O mapeamento e classificação de áreas agrícolas destaca-se por apresentar análise qualitativa e quantitativa dos diferentes aspectos do ambiente (Silva *et al.*, 2023). Embora incipiente comparados a outros biomas (Ganem, 2020; Santana *et al.*, 2021), os mapeamentos e monitoramentos na Caatinga apresentam potencial crescente, visto que o bioma se tornou local de interesse do agronegócio, ocupando principalmente as áreas campestres (IBGE, 2020), com produção e desenvolvimento de cultivos de lavouras temporárias, notadamente as forrageiras para corte, horticultura e outras culturas como cana-de-açúcar, mandioca, café, abacaxi e mamona (EMBRAPA, 2022).

O bioma apresenta um panorama histórico da ocupação de áreas naturais e respectiva conversão em áreas agrícolas (IBGE, 2020). Nesse sentido, o uso de geotecnologias insere-se tanto como ferramenta auxiliar para manejo de culturas agrícolas distintas, quanto como recurso para o monitoramento socioeconômico e conservação ambiental (Cardoso e Costa, 2019; Mendes, 2019), uma vez que a obtenção de tais dados possibilita a implementação de políticas de desenvolvimento, incluindo as ações voltadas ao setor agropecuário (EMBRAPA, 2022). Dentre algumas iniciativas, destaca-se o projeto MapBiomas, que visa mapear e monitorar as transformações no uso e cobertura da terra no Brasil, por meio de imagens da série de satélites Landsat que opera com resolução espacial de 30 m desde 1985.

O mapeamento e classificação do uso e cobertura da terra na Caatinga por meio de dados de sensoriamento remoto é ainda desafiadora, haja visto o seu início tardio quando comparado a outros ecossistemas (Ganem *et al.*, 2020) e a variabilidade espacial, temporal e espectral das culturas agrícolas. Ainda assim, diferentes estudos têm sido desenvolvidos para contornar tais problemáticas. Estudos como o de Lopes *et al.* (2023) utilizaram índices de vegetação derivados do sensor *Operational Land Imager* (OLI), acoplado ao satélite Landsat 8, para identificar e caracterizar o uso e cobertura da terra em ambiente de Caatinga, constatando que, quanto mais densa a cobertura vegetal, maiores os acertos dos índices. No entanto, para identificação de áreas com cobertura vegetal esparsa, predominante em algumas áreas de Caatinga e solo exposto, os índices não apresentaram desempenho satisfatório na separabilidade dessas áreas.

Em termos metodológicos, Souza *et al.* (2023) utilizaram imagens provenientes do satélite Landsat 5 *Thematic Mapper* (TM) para classificação de uso e cobertura da terra no município de Iguatu, Ceará. Testou-se a separabilidade e acurácia dos métodos de classificação *Support Vector Machine* (SVM), *Multilayer Perceptron* (MLP) e Máxima Verossimilhança (MaxVer), de forma a identificar a superioridade dos algoritmos de aprendizado de máquina, em relação aos métodos de classificação tradicionais. Apesar disso, salienta-se que os classificadores baseados em aprendizado de máquina demandam maior tempo computacional, além de constante indicação dos parâmetros. Júnior e Pacheco (2023) realizaram o mapeamento de uso e ocupação da terra no entorno da barragem Barra do Juá, Pernambuco, baseados nos dados obtidos pelos sensores Câmera Multiespectral Regular (MUX) a bordo do satélite CBERS-4, além do Landsat-8 OLI. Ambos os sensores apresentaram resultados satisfatórios. No entanto, destaca-se a mudança da acurácia ao inserir diferentes métodos de classificação e estatística.

Souza e Reis (2020) estudaram o avanço de áreas agrícolas em Senhor do Bonfim, Bahia, utilizando imagens dos satélites Landsat 5, 7 e 8 para os anos de 1986, 1996, 2009 e 2017. Esses autores destacaram que, embora os dados analisados sejam confiáveis, faz-se necessário estudos mais detalhados com imagens orbitais de alta resolução espacial para se obter uma delimitação de uso mais precisa (Souza e Reis, 2020). Apesar disso, os estudos citados forneceram informações acerca das mudanças no uso da terra, sem serem categóricos quanto à separabilidade das culturas agrícolas.

Apesar do aprimoramento dos sensores, a resolução espacial e temporal das imagens de satélite apresentam-se ainda como um desafio para mapeamentos mais

precisos e maior separabilidade das diferentes culturas temporárias e permanentes e áreas naturais (Souza-Júnior *et al.*, 2020; Machichi *et al.*, 2023). Nesse sentido, com o lançamento da constelação de nanossatélites do satélite PlanetScope (PS), tem-se a oportunidade de utilizar dados de satélite com maior resolução espacial e temporal para monitorar a dinâmica de uso e cobertura da terra da Caatinga, em prol da separabilidade das culturas agrícolas temporárias e permanentes.

A constelação de satélites do PS abre a possibilidade para obtenção de imagens de alta resolução temporal. Os dados provenientes desses satélites possuem passagem quase que diária. Destaca-se ainda a resolução espacial dos dados, com pixel de aproximadamente 5 m. Além disso, são produzidos mosaicos mensais compostos por imagens coletadas ao longo do mês, selecionando-se aquelas de melhor qualidade, especialmente em relação à quantidade de nuvens (Planet, 2022). Essas características tornam o PS uma fonte de dados recomendada para o estudo de áreas de vegetação natural, mas principalmente de culturas agrícolas temporárias ou permanentes (Sano *et al.*, 2023).

Alguns estudos demonstraram o potencial do uso dos mosaicos mensais. Watrin *et al.* (2021) propuseram mapear pequenas áreas de cultivo de cacau na Amazônia. Manssugi Filho (2023) utilizaram-se dos mosaicos mensais do PS para diagnosticar as mudanças no uso e cobertura da terra após o rompimento de barragem Brumadinho, Minas Gerais. Sano *et al.* (2023) extraíram diferentes índices espectrais e atributos texturais utilizando os mosaicos mensais do PS para monitorar culturas agrícolas no Cerrado. Dal'Asta *et al.* (2023) caracterizaram a distribuição espacial de comunidades quilombolas no estado do Pará, a partir de dados obtidos por meio de mosaicos mensais do PS.

Nesse contexto, este estudo objetivou analisar o potencial dos mosaicos mensais PS para discriminar áreas agrícolas no município de Mucugê, Chapada Diamantina, Bahia. Essa área foi selecionada por ser um ambiente de exceção da Caatinga e por apresentar crescente avanço na produção agrícola. Na medida do que se sabe, não há nenhum estudo avaliando a alta resolução espacial e temporal disponibilizada pelos mosaicos mensais do NICFI para discriminar tais áreas em ambiente de Caatinga. Assim, esta pesquisa pretende contribuir significativamente como referência para mapeamentos consistentes e precisos das áreas agrícolas da Caatinga, a partir da seleção dos melhores atributos espectrais e texturais para identificar tais áreas, com base no classificador Random Forest.

5.2. MATERIAS E MÉTODO

5.2.1. Área de estudo

A área de estudo compreende o município de Mucugê (Figura 5.1), localiza-se na porção central do estado da Bahia e encontra-se inserido no domínio morfoclimático da caatinga (Ab'Saber, 2003), caracterizado por apresentar padrões ambientais (topografia, umidade e temperatura) que condicionam a ocorrência de clima ameno, configurando-se como um enclave subúmido da Caatinga, um verdadeiro ambiente de exceção (Borges, 2008). O clima de Mucugê é Tropical, com verões quentes e úmidos e invernos secos – Aw no sistema de classificação climática de Köppen (Alvares *et al.*, 2014). Quanto à vegetação, a predominância é de campo rupestre, que ocorre nas áreas mais elevadas e em superfícies rochosas. A leste, ocorrem os campos gerais, florestas semidecíduas e ombrófilas, caatinga e vegetação de brejos (Harley; Simmons, 1986; Roque *et al.*, 2016).

Os campos gerais, característicos da região da Chapada Diamantina, propiciaram o desenvolvimento de cultivos de pequenos agricultores nas áreas mais próximas aos corpos d'água. Analogamente, o avanço do agronegócio e a existência da barragem do Apertado no rio Paraguaçu possibilitaram o aumento das áreas irrigadas por meio de pivôs centrais e a formação do Agropolo Mucugê-Ibiocara, que se destaca como grande produtor de lavouras permanentes e temporárias, entre elas, cebola, tomate, batata-inglesa, maracujá e café (IBGE, 2022). De acordo com MapBiomas (2022), 26,4% do município de Mucugê foi convertido para agropecuária em 2021, sendo 51% desse percentual composta de lavoura temporária, 18,9% de lavoura perene e 19,3% de pastagem.




Figura 5.1 - Localização do município de Mucugê/BA no bioma Caatinga. Fonte: Elaboração dos autores (2024).

5.2.2. Métodos

Na Figura 5.2, são mostradas as principais etapas metodológicas desenvolvidas. Foram utilizados mosaicos mensais dos anos de 2023 e 2024 do PlanetScope para a área de estudo, que foram convertidos em índices de vegetação e atributos texturais baseados no algoritmo Gray-Level Co-occurrence Matrix (GLCM) (Haralick; Dieststein, 1973). A combinação de bandas multiespectrais, índices espectrais e atributos texturais foram usados como parâmetros de entrada para classificação Random Forest.

Os mosaicos mensais (*Normalized Analytic Mosaics*) são desenvolvidos pela NCIFI (Planet Team, 2017) e disponibilizados para *download* por meio da plataforma Google Earth Engine. Os mosaicos fazem parte de uma iniciativa de reduzir e reverter a perda de florestas e contribuir para o combate às mudanças climáticas e manutenção da biodiversidade, por isso as imagens cobrem uma área que corresponde a região das florestas tropicais a nível mundial. Elas são compostas pelas bandas do azul (455-515 nm), verde (500-590 nm), vermelho (590-670 nm) e infravermelho próximo (780-860 nm).




Figura 5.2 - Fluxograma das principais etapas metodológicas utilizadas nesse estudo. Fonte: Elaboração dos autores (2004). NCIFI = Norway's International Climate and Forests Initiative; NDVI = Índice de vegetação por diferença normalizada; EVI = Índice de vegetação.

Esses mosaicos são baseados nos dados de refletância da superfície e incluem correções geométrica, atmosférica e radiométrica (Planet Team, 2020). Um processamento adicional é aplicado para melhorar a consistência espacial e temporal por meio de dois métodos independentes: normalização para reduzir a variabilidade cena a cena; e remoção da linha de borda entre duas cenas adjacentes (Pandey *et al.*, 2021). De acordo com Pandey *et al.* (2021), os produtos normalizados de refletância de superfície são apropriados para algoritmos de classificação de uso e cobertura da terra. Para esta pesquisa, selecionaram-se dois mosaicos mensais de setembro de 2023 e março de 2024, que correspondem ao intervalo de sazonalidade entre período chuvoso e seco.

Além da combinação das bandas espectrais derivadas dos mosaicos mensais, utilizaram-se os dados multitemporais dos índices espectrais. Calcularam-se dois índices de vegetação: índice de vegetação por diferença normalizada (NDVI) (Rouse *et al.*, 1973) (Equação 5.1) e o índice de vegetação realçado (EVI) (Huete *et al.*, 2002) (Equação 5.2).

$$NDVI = \frac{(\rho_{NIRb4} - \rho_{Redb3})}{(\rho_{NIRb4} + \rho_{Redb3})} \quad (5.1)$$

$$EVI = 2,5 \times \left(\frac{\rho_{NIRb4} - \rho_{Redb3}}{\rho_{NIRb4} + C1 [\rho_{Redb3}] - C2 [\rho_{Blueb1}] + L} \right) \quad (5.2)$$

Onde ρ é a reflectância dos canais espectrais da constelação PS, NIR (banda 4), Red (banda 3) e Blue (banda 2). Os fatores e seus valores empíricos são: $L = 0,5$; $C1 = 6$; $C2 = 7,5$.

Tais índices levam em consideração as combinações entre as bandas do vermelho e infravermelho próximo. O NDVI é mais usual na literatura e regularmente utilizado para detectar atividades sazonais e fenológicas, duração, crescimento, pico verde, mudanças fisiológicas das folhas e períodos de senescência e é determinado pela razão entre a subtração das bandas no infravermelho próximo e do vermelho, normalizado pela soma dessas mesmas bandas, como apresentado na Equação 1. No entanto, apesar de levar consideração o vermelho e infravermelho como o NDVI, o EVI utiliza a banda do azul para minimizar influências atmosféricas (Huete *et al.*, 2002).

As métricas texturais foram geradas a partir das quatro bandas do PS baseadas no GLCM (Haralick; Dieststein, 1973). Esses atributos têm sido utilizados em classificações de uso e cobertura da terra em diferentes cenários e conjuntos de dados (Tassi *et al.*, 2021; Sano *et al.*, 2023; Maciel Júnior, 2024). Destaca-se que o GLCM requer a configuração de quatro parâmetros, sendo eles, bandas espectrais, tamanho da janela do kernel, direção e nível de quantização (Sano *et al.*, 2023). O tamanho da janela é um fator crucial que afeta o desempenho das métricas texturais do GLCM na classificação de uso e cobertura da terra (Sothe *et al.*, 2017; Sano *et al.*, 2023). Janelas pequenas tendem a amplificar diferenças e aumentar o conteúdo de ruído na imagem de textura, enquanto janelas maiores podem não ser capazes de extrair efetivamente informações de textura devido à suavização exagerada (Sothe *et al.*, 2017).

Baseados em indicações da literatura (Sothe *et al.*, 2017; Sano *et al.*, 2023) e testes preliminares realizados na área do município de Mucugê, selecionaram-se os seguintes parâmetros: todas as quatro bandas disponíveis (R, G, B e NIR), tamanho da janela de 7 x 7, direção azimutal de 45° e nível de quantização de 64 bits. Dessa matriz, extraíram-se seis métricas texturais, usando o programa de código aberto, o *Software Application Platform* (SNAP), desenvolvido pela Agência Espacial Europeia (ESA), sendo estas: contraste (CON), homogeneidade (HOM), segundo momento angular (SMA), entropia (ENT), média (MEAN) e correlação (COR) (Tabela 5.1).

Tabela 5.1 - Métricas de textura GLCM e características respectivas.

Métrica de textura	Característica	Equação
Contraste	Medida do contraste entre as intensidades de um pixel analisado e do pixel vizinho. A comparação é realizada em todos os pixels da imagem	$\sum_i \sum_j (i - j)^2 p(i, j)$
Homogeneidade	Medida da autocorrelação espacial	$\sum_i \sum_j \frac{p(i, j)}{(1 + i - j)}$
Segundo momento angular	Mede a uniformidade textural, ou seja, repetições em pares de pixels	$\sum_{i,j=0}^{N-1} P(i, j) \cdot (i - j)^2$
Entropia	Mede a informação contida em p, muitos valores nulos representam pouca informação	$-\sum_i \sum_j p(i, j) \log_2 p(i, j)$
Média	Média das intensidades de contraste presentes na matriz de coocorrência	$\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} P(i, j) \times i$
Variância	Mede a dispersão dos níveis de cinza no entorno do pixel central	$\sum_{i,j} p(i, j) (i - \mu_i)^2$

Fonte: adaptado de Iqbal *et al.* (2021).

Os atributos indicados na Tabela 5.2 foram usados como parâmetros de entrada para classificação RF (Breiman, 2001). O RF é utilizado regularmente no desenvolvimento de pesquisa e mapeamentos de uso e cobertura da terra, pois apresenta alto desempenho em diferentes escalas cartográficas e níveis hierárquicos de classificação (Penha *et al.*, 2023).

Com base em 266 amostras coletadas em campo, realizou-se um subconjunto de treinamento e teste de 70% e 30%, respectivamente. Foram avaliados os cenários entre o

período seco e chuvoso para o município. Ademais, usando o algoritmo de regressão *stepwise* disponível no pacote “*steprf*” do programa estatístico R (<https://cran.r-project.org/web/packages/steprf/steprf>) (Li, 2019; 2022), foram selecionadas e indicadas as variáveis consideradas mais importantes para a construção da classificação.

Tabela 5.2 - Parâmetros de entrada para classificação RF

Métrica de textura	Característica
Resolução espacial PS	4,77 m
Nível de processamento PS	Mosaicos analíticos normalizados com correções atmosféricas
Mosaicos mensais	Setembro de 2023 e março de 2024
Bandas espectrais	Azul (0,455–0,515 μm), verde (0,500–0,590 μm), vermelho (0,590–0,670 μm) e infravermelho próximo (0,780–0,860 μm)
Índices de vegetação	NDVI e EVI
Atributos GLCM	Contraste, Homogeneidade, Segundo momento angular, Entropia, Média e Variância
Amostras	266

Fonte: Elaboração dos autores (2004).

O método *stepwise*, ou o método de seleção de variáveis por passos, é uma técnica amplamente utilizada em análises estatísticas para selecionar as variáveis mais significativas em um modelo de regressão. Segundo Alves et al. (2013), esse método ajuda a reduzir o número de variáveis incluídas na equação de regressão, tornando o modelo mais simples e interpretável sem sacrificar a qualidade do ajuste.

Para fins ilustrativos, a Figura 5.3 mostra duas composições coloridas RGB das bandas 4, 3 e 2 dos mosaicos mensais do PS da área de estudo para o mês de setembro de 2023 e março de 2024. Na composição de setembro (período seco), as áreas verdes e/ou esverdeadas são ocupadas majoritariamente pela vegetação nativa e alguns dos pivôs irrigados associados a lavoura permanente. No mês de março, há predominância da cor esverdeada, que corresponde ao pico da estação chuvosa, quando a maior parte das áreas de lavoura temporária também se encontram em pleno vigor vegetativo.




Figura 5.3 - Mosaicos mensais do PlanetScope em composição colorida RGB das bandas 3 (vermelho), 4 (NIR), 2 (verde), para o município de Mucugê, Bahia, dos meses de (A) setembro e (B) março. Fonte: Elaboração dos autores (2024).


Adicionalmente, foi realizado um comparativo entre a classificação supervisionada do período seco e chuvoso e a classificação disponibilizada pelo MapBiomas (2022). Utilizou-se como base o mapa de uso e cobertura (coleção 8), com acurácia geral de 75,4% para o bioma Caatinga, em nível 3 de detalhamento de legenda. Tais dados são derivados dos mosaicos de imagens com resolução de 30 metros, formado pela composição dos pixels representativos do satélite *Landsat*, que contém sete bandas espectrais, azul (0,45 – 0,52 μm); verde (0,53 a 0,61 μm); vermelho (0,63 a 0,69 μm); NIR (0,76 a 0,90 μm); SWIR (1,55 – 1,75 μm); Termal (10,40 a 12,50 μm); SWIR 2 (2,08 a 2,35 μm).




Além disso, também se utilizou os dados derivados da Coleção Beta, a partir de imagens do satélite Sentinel-2, que contém 13 bandas espectrais, aerossol (0,433 a 0,453 μm); azul (0,458 a 0,523 μm); verde (0,543 a 0,578 μm); vermelho (0,655 a 0,680 μm); NIR (0,694 a 0,713 μm); SWIR 1 (0,740 a 0,783 μm); SWIR 2 (0,773 a 0,796 μm); SWIR 3 (0,848 a 0,874 μm); SWIR 4 (0,855 a 0,875 μm); Vapor de água (0,935 a 0,965 μm); Cirrus (1,360 a 1,390 μm); SWIR 5 (1,440 a 1,480 μm); SWIR 6 (2,020 a 2,250 μm), com resolução espacial de 10m, ainda em processo de teste para iniciativa.

5.3 RESULTADOS

5.3.1. Assinaturas temporais e índices de vegetação

A Figura 5.4 apresenta as assinaturas espectrais das classes de lavoura temporária, lavoura permanente e vegetação natural encontradas no município de Mucugê entre 2023 e 2024. As assinaturas são derivadas com base nos pontos amostrais visitados na campanha de campo em junho de 2023. Pode-se notar a diferença espectral entre os meses de período chuvoso e seco para as duas classes antrópicas. Para a lavoura temporária, no período seco (5.4a), destaca-se a dissimilaridade entre os meses, de forma que não há manutenção do padrão de absorção e reflectância. No entanto, no período chuvoso (5.4b), destaca-se uma proximidade de valores entre as bandas do azul e verde e uma diferenciação entre as bandas do vermelho e do infravermelho próximo, quando a relação entre absorção e reflectância é analisada. Ainda considerando o período chuvoso da lavoura temporária, evidencia-se que o mês de março é o que apresenta alta absorção na banda do vermelho e reflectância na banda do NIR, o que é associada à recuperação de vigor vegetativo.








Figura 5.4 - Reflectância de superfície terrestre da classe lavoura temporária (a e b), lavoura permanente (c e d) e vegetação natural (e e f) nos períodos chuvoso e seco. As bandas B, G, R e NIR representam as bandas espectrais do satélite PlanetScope nas faixas azul, verde, vermelho e infravermelho próximo, respectivamente.

Quando observada a reflectância da classe lavoura permanente entre os períodos seco (5.4c) e chuvoso (5.4d), pode-se inferir que não há variação acentuada entre esses parâmetros. No entanto, no período seco, nota-se a diferenciação de valores nas bandas espectrais, principalmente nas bandas do vermelho e NIR, indicado pela constância das atividades fotossintéticas. Já a vegetação natural garante assinaturas espectrais típicas de áreas verdes, com alta absorção de energia eletromagnética na banda do vermelho, associada às atividades fotossintéticas e alta reflectância na banda do NIR durante os dois períodos (5.4e e 5.4f). Ressalta-se o comportamento das três classes para as bandas do azul e do verde, em que há pouca separabilidade entre os períodos analisados.

Os valores mais estáveis de EVI para os ciclos seco (Figura 5.5e) e chuvoso (5.5f) foram encontrados na classe de vegetação natural (faixa de 0,4 a 0,6). Embora apresente áreas com fitofisionomias com dossel semi-contínuo, a maioria da área de estudo é composta por Caatinga florestada e arborizada, o que justifica tal comportamento do EVI. Como esperado, a lavoura temporária apresenta um padrão durante o período chuvoso (5.5a), indicando atividade fotossintética e uma diminuição no EVI no período seco (5.5b), com destaque para os meses de maio a julho e, novamente o aumento de valores no fim do período de estiagem, haja vista a recuperação do vigor vegetativo e retomada de produção da lavoura.




Figura 5.5 - Índice de vegetação realçado (EVI) da classe lavoura temporária (a e b), permanente (c e d) e vegetação natural (e e f) nos períodos chuvoso e seco. Fonte: Elaboração da autora (2024).

A lavoura permanente, para o período chuvoso (5.5c), apresentou uma variação entre os valores máximos e mínimos de EVI e manutenção do padrão mesmo com o período de estiagem (5.5d), isto porque a cultura predominante é o café, que leva um maior período para atingir a senescência, o que garante valores de reflectância sem grandes alterações.

5.3.2. Atributos texturais

A Tabela 5.3 apresenta os resultados estatísticos da classificação RF para os períodos seco e chuvoso envolvendo as bandas espectrais e os índices de vegetação junto a cinco combinações mais importantes envolvendo os atributos texturais. Como opção, escolheu-se a combinação que apresentou melhor acurácia para os dois períodos.

Tabela 5.3 - Resultados estatísticos da classificação Random Forest envolvendo quatro bandas espectrais, dois índices de vegetação e 10 combinações possíveis envolvendo os atributos texturais derivados da Matriz de Co-ocorrência de Nível de Cinza (GLCM).

Modelo	Atributos	Acurácia Global
1 Chuvoso	4 bandas + 2 IVs + 2 atributos texturais	0,81
2 Chuvoso	4 bandas + 2 IVs + 4 atributos texturais	0,83
3 Chuvoso	4 bandas + 2 IVs + 6 atributos texturais	0,86
4 Chuvoso	4 bandas + 2 IVs + 8 atributos texturais	0,84
5 Chuvoso	4 bandas + 2 IVs + 10 atributos texturais	0,87
1 Seco	4 bandas + 2 IVs + 2 atributos texturais	0,88
2 Seco	4 bandas + 2 IVs + 4 atributos texturais	0,90
.3 Seco	4 bandas + 2 IVs + 6 atributos texturais	0,92

4 Seco	4 bandas + 2 IVs + 8 atributos texturais	0,91
5 Seco	4 bandas + 2 IVs + 10 atributos texturais	0,92

Fonte: Elaboração dos autores (2024).

A Figura 5.6 mostram os 10 parâmetros de entrada mais relevantes para classificação Random Forest para estação chuvosa e seca, baseada no critério *Mean Decrease Gini* (MDG) (Hong *et al.*, 2016). Destaca-se, para o período chuvoso, a importância da banda do verde (B2) e a participação regular dos atributos texturais derivados da banda 4 (NIR). O período seco também evidencia a importância da banda 2, em destaque, os atributos de média e variância.




Figura 5.6 - Ranking dos 10 atributos mais importantes para classificação Random Forest dos períodos chuvoso (a) e seco (b). NDVI = índice de vegetação por diferença normalizada; EVI = índice de vegetação realçado. Fonte: Elaboração dos autores (2024).

5.3.3. Classificação Random Forest

A Figura 5.7 mostra a classificação final para os períodos chuvoso e seco. Notam-se diferenças de valores associadas às classes entre os períodos. Para vegetação nativa, classe majoritária, a classificação chuvosa indicou que a mesma ocupa 57,4% da área de estudo, enquanto a seca ocupou 61,6%. Para a Lavoura Temporária, a chuvosa apresentou 32,04%, enquanto a seca 30,5% e para a Lavoura Permanente, a classificação chuvosa indicou 9,06% de área, enquanto a seca indicou 5,3%. Somadas, as lavouras configuraram-se em cerca de 40% da área do município.

5.3.4. Avaliação da Acurácia

A Tabela 5.4 apresenta o desempenho da classificação do período chuvoso, destacando-se a acurácia global de 87,45%, com erro estimado de 7,91%. Os erros de omissão para as classes variam de 0 para Água, 10,5% para Vegetação, 5,9% para Lavoura Temporária e 15,1% para Lavoura Permanente. Em termos de erro de comissão, destacam-se a Vegetação (12,8%) e a Lavoura Permanente (15,1%), enquanto a Lavoura Temporária apresentou um erro de 4,8% e F-score de 0,94. De forma geral, para classificação no período chuvoso, destaca-se que, dentre os 84 pontos de Lavoura Temporária, três foram classificados como vegetação e dois como Lavoura Permanente (erro de omissão), ao passo que, para o erro de comissão, um ponto foi classificado erroneamente como vegetação e três como Lavoura Permanente.

Já a Lavoura Permanente, de 33 pontos, três foram indicados como vegetação e dois como Lavoura Temporária, enquanto dois pontos foram atribuídos para vegetação e cinco para a Lavoura Temporária. Destaca-se também que não houve erro de separabilidade da classe de água. Para a classe de Vegetação, o erro de omissão é destacado com a classe de Lavoura Temporária, enquanto o erro de comissão é com a Lavoura Permanente.




Figura 5.7 - Resultado da classificação Random Forest para o município de Mucugê, Bahia, para os períodos chuvoso (5.7a) e seco (5.7b). Fonte: Elaboração dos autores (2024).

Tabela 5.4 - Matriz de confusão da classificação RF do período chuvoso baseado no mosaico mensal de março de 2024 do PlanetScope, para o município de Mucugê, Bahia. Veg = Vegetação; Temp = Lavoura Temporária; Perm = Lavoura Permanente; O.E = erro de omissão; C.E = erro de comissão.

	Água	Veg	Temp	Perm	Total	O.E. (%)	C.E. (%)	Precision	Recall	F-Score
Água	22	0	0	0	22	0	0	1	1	1
Veg	0	34	1	3	39	10,5	12,8	0,87	0,89	0,88
Temp	0	3	79	2	84	5,9	4,8	0,95	0,94	0,94
Perm	0	2	3	28	33	15,1	15,1	0,84	0,84	0,84
Total	22	39	83	33	177					
AO (%)	87,45									
OOB (%)	7,91									

Fonte: Elaboração dos autores (2024).

Em consonância, a Tabela 5.5 apresenta o desempenho para classificação do período seco, em que há o aumento da acurácia global de 92,03% e diminuição do OOB para 5,08%, em comparação com a estação chuvosa. Destaca-se a não ocorrência de erro de omissão e comissão para a classe Água. Quanto às culturas agrícolas, a classificação seca infere que, para a Lavoura Temporária, apenas 2,38% dos pontos foram omitidos, enquanto cinco pontos foram classificados como Lavoura Permanente e dois como Vegetação (erros de comissão), com F-score de 0,95.

Tabela 5.5 - Matriz de confusão da classificação RF do período seco baseado no mosaico mensal de setembro de 2023 do PlanetScope, para o município de Mucugê, Bahia. Veg = Vegetação; Temp = Lavoura Temporária; Perm = Lavoura Permanente; O.E = erro de omissão; C.E = erro de comissão

	Água	Veg	Temp	Perm	Total	O.E. (%)	C.E. (%)	Precision	Recall	F-Score
Água	22	0	0	0	22	0	0	1	1	1
Veg	0	38	0	0	38	0	7,32	0,92	1	0,96
Temp	0	1	82	1	84	2,38	5,75	0,94	0,97	0,95
Perm	0	2	5	26	33	21,21	3,7	0,96	0,78	0,86
Total	22	41	87	27	177					
AO (%)	92,03									

Fonte: Elaboração dos autores (2024).

Adicionalmente, o erro de omissão para a Lavoura Permanente indica que 21,21% dos pontos foram omitidos da classificação, enquanto o erro de comissão indica uma porcentagem significativa de instâncias incorretamente classificadas como Lavoura Temporária (cinco pontos) e Vegetação (2 pontos).

5.3.5. COMPARAÇÃO COM CLASSIFICAÇÃO MAPBIOMAS

As classificações para o município de Mucugê não apresentaram discrepâncias acentuadas quando comparados aos resultados da classificação MapBiomas com dados Landsat 30m (MapBiomas, 2022) (Figura 5.8). Essa concordância indica que a metodologia aplicada nas classificações foi eficaz em capturar a dinâmica de uso e cobertura da terra na região, refletindo de forma precisa as características do território.




Figura 5.8 - Comparação entre a classificação RF dos dados PlanetScope para o período chuvoso e seco e a classificação do Projeto MapBiomas para o município de Mucugê, Bahia. Fonte: A autora (2024).

Apesar disso, ao avaliar a Coleção Beta com imagens do satélite Sentinel-2, com resolução espacial de 10 metros, a classificação não indicou valores correspondentes a Lavoura Permanente. Dessa forma, a classificação das áreas agrícolas restringe-se entre Pastagem e Agricultura, com a correspondência de Lavouras Temporárias de 25,5% em relação à área total de Agropecuária. Essa diferença era um tanto esperada devido aos modos de aquisição de imagem, resolução espacial e correspondência de mapeamento (Sano *et al.*, 2023). Tal comportamento era um tanto esperado devido aos modos de aquisição de imagem, resolução espacial e correspondência de mapeamento (Sano *et al.*, 2023).

5.4. DISCUSSÃO

A análise das classificações obtidas para o município de Mucugê revela a disposição das áreas agrícolas no campo dos gerais, que se destacando-se como a principal área do polo de produção na Chapada Diamantina, o que reafirma o crescimento do agronegócio na região (OCA, 2022). A expansão do agronegócio em Mucugê, particularmente no campo dos gerais, é um indicativo de mudanças no uso da terra e da intensificação das atividades agrícolas, o que gera impactos significativos tanto econômicos quanto ambientais. Dados da ANA (2017) indicam que essa parte dos gerais da Chapada Diamantina tem uma das maiores concentrações de pivôs centrais do país, com 471 pivôs, totalizando 32.107 ha.

Os dados derivados do Projeto MapBiomass para os anos de 1985 e 2022 revelam mudanças significativas na extensão das áreas de lavoura temporária e lavoura permanente para Mucugê. Em 1985, a área de lavoura temporária era de apenas 199 ha. Ao longo dos anos, houve um aumento substancial nessa categoria, chegando a 34.222 ha em 2022. Esse crescimento expressivo indica uma expansão considerável das atividades agrícolas de curto prazo, como batata-inglesa, milho e cebola. Quanto à lavoura permanente, em 1985, a área era de apenas 1.222 ha e, em 2022, essa categoria também apresentou um aumento considerável, atingindo 9.196 ha. Esse crescimento também sugere uma expansão significativa das culturas agrícolas de longo prazo na região, como plantações de café (MapBiomass, 2022).

Em geral, a maior parte dos estudos desenvolvidos no bioma Caatinga para mapear e classificar culturas agrícolas têm utilizado, como base, imagens ópticas de

satélites com ampla faixa de resolução espacial (30-250 m), convertidas em índices espectrais e de vegetação (Oliveira; Costa, 2020; Cardoso *et al.*, 2021). No entanto, nota-se que há limitação de estudos que enfocam esse tipo de abordagem, evidenciando as culturas agrícolas, o que comporta cenário limitado quando comparado ao mapeamento dessas áreas em ambientes de Cerrado (Trentin *et al.*, 2021; Penha *et al.*, 2023). Tal discrepância pode ser atribuída a uma série de fatores, desde a complexidade da vegetação da Caatinga, que apresenta ampla diversidade e adaptações às condições semiáridas, a extensão territorial e tipologia desses cultivos, o que gera dificuldade de identificação das culturas agrícolas. Além disso, as características edafoclimáticas específicas da Caatinga também podem influenciar na diferenciação das culturas agrícolas e, consequentemente, na sua detecção por métodos remotos.

Em termos metodológicos, os atributos texturais estão mais relacionados ao sensoriamento remoto de radar (Guyot *et al.*, 2023), objetivando caracterizar a textura da superfície terrestre. Isto inclui características como a rugosidade, padrões de distribuição e variações na intensidade do sinal de retorno do radar (Rodrigues *et al.*, 2023). No cenário dos dados ópticos, as pesquisas que incluem os atributos GLCM abrangem temáticas associadas a mapeamento de vegetação (Mohammadpour *et al.*, 2022), identificação de inundações em áreas montanhosas (Tavus; Kocaman, 2023); comparação entre diferentes métodos de classificação (Tassi; Vizzari, 2020) e mapeamento de cultivos específicos (Fei *et al.*, 2022).

Na lista dos parâmetros de entrada considerados mais importantes para classificação RF, para o período chuvoso, os atributos texturais de variância, contraste, média e segundo momento angular foram indicados como os mais significativos. Esta indicação é fundamentada na dissemelhança textural, haja vista que, a variância e o contraste, a partir da dispersão dos níveis de cinza e variações na tonalidade da imagem (Haralick *et al.*, 1973), podem capturar a heterogeneidade das lavouras, que tende a aumentar durante o período chuvoso devido ao crescimento vegetativo intenso e ao desenvolvimento desigual das plantas, considerando a diferença entre os cultivos temporários e permanentes. Em consonância, a média e o segundo momento angular contribuem significativamente para a captura da uniformidade e regularidade de texturas nas imagens (Haralick *et al.*, 1973), o que permite identificar áreas homogêneas com crescimento vegetativo uniforme, em detrimento de outras.

Analogamente, no período seco, a média e a variância continuam sendo atributos relevantes, pois, o primeiro atributo reflete o brilho geral de uma imagem ou região (Haralick *et al.*, 1973), o que pode indicar a densidade e a saúde da vegetação, que são influenciadas pelas condições climáticas. Durante o período seco, este atributo pode indicar a presença de áreas irrigadas versus áreas não irrigadas, o que diferencia boa parte das lavouras permanentes e temporárias. Já a variância, evidencia a heterogeneidade da resposta dos cultivos à redução da precipitação, uma vez que é sensível a pequenas variações na textura (Haralick *et al.*, 1973), que podem ser indicativas de condições locais de estresse hídrico ou variações na cobertura do solo, o que garante a manutenção deste atributo como variável de importância na classificação.

Tal como indicado por Sano *et al.* (2023), a seleção dos atributos mais relevantes é associada ao local e ao sensor utilizado, de forma a relatarmos a correlação, média e variância como atributos mais importantes associados às bandas espectrais dos mosaicos PS e índices de vegetação para classificação de culturas agrícolas em uma área do Cerrado. Pode-se adicionar também, a variabilidade temporal, uma vez que modificando a data de entrada, os dados de importância variaram. De forma geral, pode-se inferir que o período chuvoso necessitou de diferentes atributos texturais para garantir a separabilidade das classes.

A diferença na classificação das culturas temporárias e permanentes em Mucugê entre os períodos chuvoso e seco reflete a dinâmica sazonal das atividades agrícolas e os desafios associados à interpretação destes alvos pelo sensoriamento remoto (Kuchler *et al.*, 2022). Durante o período chuvoso, as culturas temporárias estão em um estágio de vigor vegetativo intenso, caracterizado por um aumento na densidade de biomassa e na cobertura vegetal. Isso cria uma dificuldade na separação espectral das diferentes culturas temporárias, já que elas podem apresentar assinaturas espectrais semelhantes. Como resultado, a classificação por sensoriamento remoto tende a sobrestimar a área de lavouras temporárias, aumentando a taxa de erros de omissão. Esses erros ocorrem quando áreas de uma determinada cultura são erroneamente classificadas como pertencentes a outra, devido à similaridade espectral.

No caso específico de Mucugê, durante o período chuvoso, a classificação chuvosa identificou que 34% da área do município estava ocupada por lavouras temporárias. Essa proporção diminuiu para 30,5% durante o período seco, quando as culturas temporárias têm menor vigor vegetativo e, portanto, um comportamento espectral diferente que pode

ser mais facilmente distinguida. Quanto às lavouras permanentes, como são compostas em sua maioria pelo cultivo do café, que mantêm certa cobertura durante um maior período, a variação na classificação é menos acentuada entre os períodos chuvoso e seco. No entanto, também se observa uma redução na área classificada como lavoura permanente durante o período seco, de 9,06% para 5,30%, indicando possíveis mudanças na vegetação devido à sazonalidade ou a práticas agrícolas específicas.

Tal como indicado por Mohammadpour *et al.* (2022), o uso de atributos texturais e índices de vegetação na classificação aumentou a precisão em até 2%, alcançando a acurácia global de 90,5%, o que faz correspondência aos dados indicados, uma vez que apresentam altos valores de precisão e acurácia global variando entre 0,87 e 0,92. Fei *et al.* (2022) afirmaram a eficácia dos dados GLCM para melhorar a classificação de áreas de cultivos de algodão, com acurácia global alcançando 93,36%. (Figura 5.8).

Neste estudo, destaca-se que a classificação das culturas agrícolas pode ser desafiadora devido à sazonalidade das plantações. Algumas culturas podem ter ciclos de crescimento e colheita que se sobrepõem ou são semelhantes em termos de respostas espectrais, o que dificulta sua distinção, como visto na comparação entre os períodos chuvoso e seco. Assim como indicado por Sano *et al.* (2023), as principais diferenças nas datas de plantio das culturas podem causar grandes variações radiométricas nos mosaicos mensais do PS, levando a erros de classificação.

5.5. CONCLUSÃO

O uso de atributos texturais combinados com índices de vegetação e bandas espectrais do PS mostrou-se uma abordagem eficaz para a classificação de áreas agrícolas em Mucugê. A metodologia aplicada apresenta desempenho satisfatório, distinguindo as lavouras permanentes e temporárias. De tal modo que, pode ser aprimorada e ajustada para outras regiões da Caatinga, contribuindo para um mapeamento agrícola mais detalhado e preciso. Desse modo, recomendam-se mais testes integrando outros dados geográficos e ópticos para que possam estabelecer e identificar as áreas no nível de cultivo.

Os mosaicos mensais do PlanetScope apresentam-se como alternativa eficaz para surgem como uma alternativa eficaz para a análise e monitoramento contínuo das áreas

agrícolas. Esses mosaicos permitem uma cobertura regular e consistente de diferentes áreas. A capacidade de obter imagens integradas ao longo do tempo permite uma visão abrangente das mudanças no uso da terra e na cobertura vegetal.

Evidencia-se que nem sempre o aumento ou diminuição dos dados de entrada indica uma elevada acurácia, bem como quantidade de dados amostrais. É importante garantir uma distribuição espacial equivalente à realidade de campo. Ademais, a continuidade dos estudos nessa linha pode ajudar a compreender melhor as mudanças no uso do solo e a expansão do agronegócio, bem como a desenvolver estratégias de gestão e conservação mais eficientes.

REFERÊNCIAS

AB'SABER, A. N. **Domínios da Natureza**. São Paulo. Ateliê Editorial. 2003.

ALVARES, C. A. et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, vol. 22, no. 6, p. 711–728, 2014.

ALVES, M. F.; LOTUFO, A. D. P.; LOPES, M. L. M. Seleção de variáveis stepwise aplicadas em redes neurais artificiais para previsão de demanda de cargas elétricas. **Proceeding Series of the Brazilian Society of Applied and Computational Mathematics**, vol. 1, n. 1, 2013.

ANA. **Atlas Irrigação: Uso da Água na Agricultura Irrigada**, 2017. Disponível em: <https://11nk.dev/tnKN6>. Acesso em: 15 mai. 2024.

BORGES, E. F. **Aplicação das Geotecnologias para a definição do zoneamento geoambiental do município de Mucugê – BA**. 2008.147 p. Dissertação (Mestrado em Modelagem de Ciências da Terra e do Ambiente). Universidade Estadual de Feira de Santana, Feira de Santana, 2008.

Breiman, L. Classification and Regression Trees. **Wadsworth Press**, 1984.

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

CARDOSO, P. V. et al. Mapeamento de áreas de Caatinga através do Random Forrest: Estudo de caso na Bacia do Rio Taperoá. **Revista Geoaraguaia**, v. 11, p. 55-68, 2021.

CHAVES, I. B. et al. Uma classificação morfo-estrutural para descrição e avaliação da biomassa da vegetação da caatinga. **Revista Caatinga**, vol. 21, n. 2, p. 204-213, 2008.

DAL'ASTA, A. P. et al. Caracterização de comunidades quilombolas em Oriximiná (Pará) com imagens CBERS-4A e PlanetScope. In: SIMPÓSIO BRASILEIRO DE

SENSORIAMENTO REMOTO, 20. Florianópolis, Santa Catarina. Anais... São José dos Campos, SP: INPE, p. 2506-2509, 2023.

EMBRAPA TERRITORIAL. **Sistema de inteligência territorial estratégica do bioma Caatinga**. Campinas, SP, 2022. Disponível em: <https://www.embrapa.br/bioma-caatinga>. Acesso em: 22 abr. 2024.

FEI, H. et al. Cotton classification method at the county scale based on multi-features and Random Forest feature selection algorithm and classifier. **Remote Sensing of Environment**, v. 14, n. 4, 829, 2020.

GANEM, K. A. et al. Mapeamento da vegetação da Caatinga a partir de dados ópticos de observação da terra – Oportunidades e desafios. **Revista Brasileira de Cartografia**, v. 72, p. 829–854, 2020.

GUYOT, A. et al. Segmentation of polarimetric radar imagery using statistical texture. **Atmospheric Measurement Techniques**, v. 16, n. 19, p. 4571-4588, 2023.

IBGE. **IBGE retrata cobertura natural dos biomas do país de 2000 a 2018**. Editora Geociências, 2020. Disponível em: <<https://acesse.one/l5ucm>>. Acesso em: 22 abr. 2024.

HARALICK, S.; DINSTEIN, I. H. Textural features for image classification. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 3, n. 6, p. 610–621, 1973.

HARLEY, R. M.; SIMMONS, N. A. Flórlula de Mucugê, Chapada Diamantina, Bahia, Brazil. **Royal Botanic Gardens**, p. 34-49, 1986.

hong, h.; guo, x.; hua y. variable selection using mean decrease accuracy and mean decrease Gini based on Random Forest. **IEEE International Conference on Software Engineering and Service Science (ICSESS)**, Beijing, 2016, p. 219-224.

HUETE, A. R. et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, n. 1-2, p. 195-213, 2002.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: Uma Perspectiva em Recursos Terrestres**. Tradução de José Carlos Ephifanio (coord.) *et al.* São José dos Campos: Parêntese, 2009.

JÚNIOR, A. S.; PACHECO, A, P. Classificador Support Vector Machine para o mapeamento da cobertura do solo usando imagens CBERS-4/MUX e Landsat-8/OLI. **Revista Brasileira de Geografia Física** v. 16, n. 3, p. 1304-1319. 2023.

KUCHLER, M. P.; SIMÕES, R.; FERRAZ, D.; ARVOR, P. A.; MACHADO, M.; ROSA, R.; GAETANO, R.; BÉGUÉ, A. Monitoring complex integrated crop–livestock systems at regional scale in Brazil. **Remote Sensing**, v. 14, 1648, 2022.

LI, J. A critical review of spatial predictive modeling process in environmental sciences with reproducible examples in R. **Applied Sciences**, v. 9, 2048, 2019.

LOPES, R. J. C.; SANTOS, A. M.; LIMA JÚNIOR, C. Análise dos índices de vegetação para monitoramento remoto das Caatingas. **GeoUERJ**, n. 42, e55653, 2023.

MACIEL JÚNIOR, I. C.; DALLACORT, R.; BOECHAT, C. L.; TEODORO, P. E.; TEODORO, L. P. R.; ROSSI, F. S.; OLIVEIRA-JÚNIOR, J. F. D.; DELLA-SILVA, J. L.; BAIO, F. H. R.; LIMA, M.; et al. Maize crop detection through geo-object-oriented analysis using orbital multi-sensors on the Google Earth Engine Platform. **AgriEngineering**, v. 6, n. 1, p. 491-508, 2024.

MENDES, I. A. S. O uso de geotecnologias na organização do espaço. **Cadernos do Leste**, v. 19, n. 19, 2019.

MOHAMMADPOUR, P.; VIEGAS, D. X.; VIEGAS, C. Vegetation mapping with Random Forest using Sentinel 2 and GLCM texture feature—A case study for Lousã region, Portugal. **Remote Sensing**, v. 14, n. 18, 4585, 2022.

OCA. Observatório dos Conflitos Socioambientais na Chapada Diamantina. **A depredação da natureza nos gerais de Mucugê e Ibicoara**. Bahia, 2022. Disponível: <https://acesse.dev/gGHsk>. Acesso em: 10 mar. 2024

PANDEY, P.; KINGTON, J.; KANWAR, A.; CURDOGLO, M. Addendum to Planet basemaps product specifications: NICFI basemaps. Revision: v02. NICFI. 2023. Disponível em: https://assets.planet.com/docs/NICFI_Basemap_Spec_Addendum.pdf. Acesso em: 10 nov. 2023.

PLANET TEAM. **Planet Application Program** Interface: In Space for Life on Earth. San Francisco, CA, 2017. Disponível em: <https://api.planet.com>. Acesso em 7 mai. 2023.

MACHICHI, M. A. et al. Crop mapping using supervised machine learning and deep learning: a systematic literature review. **International Journal of Remote Sensing**, v. 44, n. 8, 2023.

MANGUSSI FILHO, C. R. **Avaliação da resolução espacial e espectral de imagens de satélite na identificação das mudanças de uso e ocupação em áreas de rompimento da barragem de rejeitos B1, na sub-bacia do Ribeirão Ferro-Carvão, em Brumadinho, MG**. 31 jan. 2023, 85 p. (Dissertação em Ciência e Tecnologia Ambiental). Universidade Federal do Triângulo Mineiro, Uberaba, MG, 2023.

MAPBIOMAS. MapBiomass v. 7.0. Disponível em: <https://mapbiomas.org/download>. Acesso em: 29 set. 2022.

PENHA, A. R. et al. Análise de dados Harmonized Landsat Sentinel para mapeamento de uso e cobertura da terra em área de expansão agrícola no Cerrado. **Boletim de Geografia**, v. 41, p. 38-56, e64865, 2023.

RODRIGUES, T. et al. Detecção de mudanças na cobertura vegetal natural do Cerrado por meio de dados de radar (Sentinel-1A). **Sociedade & Natureza**, v. 31, e46315, 2023.

ROQUE, N. et al. Asteraceae no município de Mucugê, Chapada Diamantina, Bahia, Brasil. **Rodriguésia**, v. 67, p. 125-202, 2016.

ROUSE, J. W. et al. Monitoring vegetation systems in the Great Plains with ERTS. **Proceedings of the Third ERTS Symposium**, NASA SP-351, NASA, Washington, DC, v. 1, p. 309-317, 1973. Disponível em: <https://encr.pw/8ZJmx>. Acesso em: 05 mai. 2022.

RUIZ, I. H. **Uso de métricas fenológicas calculadas de diferentes índices de vegetação da constelação de satélites PlanetScope para classificação de fitofisionomias do Cerrado**. 93 p. (Mestrado em Sensoriamento Remoto). Instituto Nacional de Pesquisas Espaciais, São José dos Campos, SP, 2022.

SANO, E. E. et al. Estimating double cropping plantations in the Brazilian Cerrado through PlanetScope monthly mosaics. **Land**, v. 12, 581, 2023.

SILVA, R. B. et al. Mapeamento da expansão agrícola no município de Alta Floresta-MT nos anos de 2019 e 2022. **Enciclopédia Biosfera**, Centro Científico Conhecer – Jandaia-GO, v. 20, n. 45, p. 261. 2023. Disponível em: <https://acesse.dev/6C8m3>. Acesso em: 23 abr. 2024.

SOTHE, C. et al. Evaluating Sentinel-2 and Landsat-8 data to map successional forest stages in a subtropical forest in southern Brazil. **Remote Sensing**, v. 9, 838, 2017.

SOUZA-JÚNIOR C. M. et al. Reconstructing three decades of land use and land cover changes in Brazilian biomes with Landsat archive and Earth Engine. **Remote Sensing**, 2020. v. 12, 2735, 2020.

SOUZA, S. O.; REIS, F. S. Análise multitemporal do uso e cobertura da terra no município de Senhor do Bonfim (BA), Brasil. **Geoambiente On-line**, n. 38, p. 106-128, 2020.

TASSI, A. et al. Pixel- vs. object-based Landsat 8 data classification in Google Earth Engine using Random Forest: The case study of Maiella National Park. **Remote Sensing**, v. 13, n. 12, 2299, 2021.

TAVUS, B.; KOCAMAN, S. Flood mapping in mountainous areas using Sentinel-1 & 2 data and GLCM features. **International Archives on Photogrammetry and Remote Sensing**. Spatial Inf. Sci., XLVIII-1/W2-2023, p. 1575–1580. doi.org/10.5194/isprs-archives-XLVIII-1-W2-2023-1575-2023, 2023.

TRENTIN, C. B. et al. Características da vegetação dos biomas Pampa e Cerrado monitorados por NDVI. **Revista Geoaraguaia**, v. 11, p. 69-84, 2021.

VIZZARI, M. PlanetScope, Sentinel-2, and Sentinel-1 data integration for object-based land cover classification in Google Earth Engine. **Remote Sensing**, v. 14, n. 11, 2628, 2022.

WATRIN, O. S. et al. Padrões espaciais de sistemas agroflorestais com cultivo de cacau em Tomé-Açu, nordeste paraense. **Agroecossistemas**, v. 13, n. 2, p. 155–170.

6. CONSIDERAÇÕES FINAIS

O conjunto de dados gerados pelo PlanetScope tem contribuído para a formação de uma série significativa de imagens de satélites e mosaicos mensais, voltados para o estudo de fenômenos geográficos e a estimativa de parâmetros biofísicos da paisagem, tornando-o uma ferramenta poderosa para o monitoramento da vegetação e a análise da dinâmica do uso da terra. No contexto da Caatinga, essa capacidade é relevante, uma vez que a região enfrenta desafios relacionados a expansão do agronegócio, sobretudo na Chapada Diamantina.

Ainda nesse sentido, a sequência de imagens obtidas com alta frequência temporal e espacial possibilita a identificação de diferentes fitofisionomias e culturas, bem como a análise detalhada do ciclo vegetativo. Todavia, a interpretação desses dados requer um entendimento aprofundado das variáveis envolvidas e das particularidades de cada fitofisionomia, a fim de garantir a precisão e a relevância dos resultados obtidos.

A avaliação de bandas espectrais e índices de vegetação derivados das imagens do PlanetScope, para as fitofisionomias e culturas agrícolas para o município de Mucugê, evidenciou as variações sazonais e alterações nos perfis espectrais. Os resultados demonstraram a sensibilidade dessas variáveis em relação às áreas com vegetação nativa, mesmo durante o período seco. Nas áreas de lavoura temporária, os perfis dos índices de vegetação (IVs) apresentaram uma ampla variação, refletindo a dinâmica de curto prazo do ciclo de cultivo. Em contrapartida, nas lavouras permanentes, foram observadas diferenças significativas entre os perfis de culturas do mesmo tipo, como o café, dependendo das práticas agrícolas empregadas.

Ao avaliarmos a diferença entre fitofisionomias e culturas agrícolas, a análise de regressão múltipla revelou um modelo final com um coeficiente de determinação (R^2) de 0,75, indicando uma relação de 75% entre as variáveis preditoras e categóricas, evidenciando a relevância das bandas espectrais e dos índices de vegetação, com as classes de uso e cobertura analisadas. Além disso, ao agrupar as classes, foi possível diferenciar as fitofisionomias das lavouras usando a variável $G < 0,06995$. No entanto, evidencia-se a necessidade de incluir mais variáveis para uma distinção mais clara entre as fitofisionomias.

Quando avaliado a classificação das culturas agrícolas para a área de estudo, os resultados usando as bandas espectrais, os índices de vegetação e os atributos texturais, mostraram uma alta taxa de acerto global, especialmente durante o período seco, que

atingiu 92,03% com um erro estimado de 5,08%. Para o período chuvoso, a acurácia global foi de 87,45%, com um erro estimado de 7,91%. Nesse sentido, destaca-se a importância dos atributos texturais derivados das bandas espectrais (vermelho, verde, azul e infravermelho próximo), particularmente a média e a variância, na classificação das culturas agrícolas.

A análise comparativa com os dados do Projeto MapBiomas indica que apesar e utilizar outros dados, a metodologia aplicada, com imagens de alta resolução do PlanetScope, combinada com índices de vegetação e atributos texturais, foi eficaz na identificação e classificação das culturas agrícolas, diferenciando-as entre lavouras temporárias e permanentes. Isso corrobora a acurácia e a relevância dos resultados obtidos, demonstrando a capacidade da abordagem em captar as dinâmicas de uso e cobertura da terra de forma precisa.

No entanto, o estudo também reconhece limitações relacionadas à qualidade espectral das imagens do PlanetScope, que podem apresentar desafios em ambientes complexos como de Caatinga. Isso pode influenciar a precisão dos índices de vegetação e, consequentemente, a acurácia na classificação. Para futuros estudos, recomenda-se a consideração de outras variáveis geográficas e ambientais, como informações de solos e características topográficas, que poderiam fornecer um contexto adicional e melhorar a acurácia das análises. Além disso, a exploração de imagens de satélites com maior capacidade espectral e temporal, como os da constelação Sentinel, pode ampliar as possibilidades de monitoramento e classificação em áreas de Caatinga e outros biomas semiáridos.

Todos os objetivos específicos propostos nesta pesquisa foram alcançados. A identificação da resposta sazonal das fitofisionomias da área de estudo a partir das bandas espectrais e dos índices de vegetação, e a avaliação do desempenho de IVs na análise da dinâmica espaço-temporal foram considerados no Capítulo 4. A análise do desempenho de índices de vegetação e atributos de textura para a classificação das diferentes classes de culturas agrícolas, resultou nas classificações do período seco e chuvoso apresentados no Capítulo 5.