



**UNIVERSIDADE
ESTADUAL DO
MARANHÃO**



**UNIVERSIDADE ESTADUAL DO MARANHÃO
CENTRO DE ESTUDOS SUPERIORES DE BALSAS
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRICULTURA E AMBIENTE**

PAULO HENRIQUE ALVES LEÃO

**DETECÇÃO DE POPULAÇÕES DA PALMEIRA DE BABAÇU EM
DIFERENTES AMBIENTES DA AMAZÔNIA MARANHENSE USANDO
TÉCNICAS DO SENSORIAMENTO REMOTO**

**BALSAS
2021**

PAULO HENRIQUE ALVES LEÃO

**DETECÇÃO DE POPULAÇÕES DA PALMEIRA DE BABAÇU EM
DIFERENTES AMBIENTES DA AMAZÔNIA MARANHENSE USANDO
TÉCNICAS DO SENSORIAMENTO REMOTO**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Agricultura e Ambiente – PPGAA/CESBA/UEMA, como parte dos requisitos para obtenção do título de Mestre em Agricultura e Ambiente.

Orientador: Dr. Fábio Afonso Mazzei Moura de Assis Figueiredo

Co-orientadora: Dra. Swanni T. Alvarado

L437d

Leão, Paulo Henrique Alves.

Detecção de populações da palmeira de babaçu em diferentes ambientes da amazônia maranhense usando técnicas do sensoriamento remoto. / Paulo Henrique Alves Leão. – Balsas, 2021.

86f.

Monografia (Pós Graduação em Agricultura e Ambiente)
PPGAA/CESBA/UEMA, 2021.

1. *Attlea speciosa* mart. 2. Geoprocessamento. 3 Sensoriamento Remoto. I. Título.

CDU 528.8

PAULO HENRIQUE ALVES LEÃO

**DETECÇÃO DE POPULAÇÕES DA PALMEIRA DE BABAÇU EM
DIFERENTES AMBIENTES DA AMAZÔNIA MARANHENSE USANDO
TÉCNICAS DO SENSORIAMENTO REMOTO**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Agricultura e Ambiente – PPGAA/CESBA/UEMA, como parte dos requisitos para obtenção do título de Mestre em Agricultura e Ambiente.

Orientador: Dr. Fábio Afonso Mazzei Moura de Assis Figueiredo

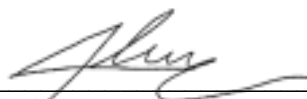
Co-orientadora: Dra. Swanni T. Alvarado

Aprovada em 29/10/2021

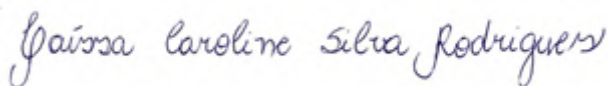
BANCA EXAMINADORA



Prof. Dr. Fábio Afonso Mazzei Moura de Assis Figueiredo (Orientador)
Universidade Estadual do Maranhão



Prof. Dr. Thiago Sanna Freire Silva
University of Stirling



Prof. Dra. Taissa Caroline Silva Rodrigues
Universidade Estadual da Região Tocantina do Maranhão

*Dedico este trabalho à minha família
que sempre me apoiou em todas as etapas da minha vida.*

AGRADECIMENTOS

Aos meus pais pela minha criação, educação e todo o investimento, tempo e cuidado comigo. À minha irmã Priscila, minha companheira, confiante, que está comigo a todo momento e em qualquer decisão da minha vida. À minha tia Tereza e ao Adam, por todo o amor, atenção e por me acolherem no período de disciplinas em Balsas e Riachão. Vocês todos são a minha base, o meu porto seguro.

À orientação do prof. Dr. Fábio Afonso Figueiredo, pela ajuda, persistência, incentivo e por me ensinar que existe muito tempo entre as 22h e 6 da manhã, fazendo com que me revirasse ao avesso para me reencontrar. Você foi uma das pessoas que acreditou em mim, mesmo quando eu não acreditava, e por mais que nossos planos não saíram como queríamos nos projetos de intercâmbio ou na pesquisa, ainda sim você foi como um pai em me ajudar a buscar um caminho para alcançar meus sonhos. Fico muito feliz por ter você, não só como orientador, mas como amigo.

À Dra. Swanni, pelos ensinamentos que vão muito além do conhecimentos sobre geoprocessamento, sensoriamento remoto ou ecologia, você me mostrou como é ser apaixonado pela pesquisa e pra mim você é um exemplo. Agradeço pela excelente orientação, por muitas vezes fora de horário - me desculpe por isso - por toda a dedicação, paciência e pulso firme, sempre pontual e necessário. Além de tudo isso agradeço pelas diversas vezes em que me acolheu em São Luís, me incentivou a buscar meus sonhos, me ensinou a cozinhar comidas “quase” vegetarianas. Se o professor Fábio foi como meu pai na pesquisa, você foi como a mãe e eu serei eternamente grato por ter vocês comigo.

À Universidade Estadual do Maranhão – UEMA, campus de Balsas/MA e de São Luís/MA por todo suporte técnico e científico e pela concessão da bolsa que me possibilitou me dedicar para a realização desta dissertação. Ao Programa de Pós-graduação em Agricultura e Ambiente – PPGAA, e à terceira turma do PPGAA, dos quais me orgulho em fazer parte.

Aos colegas, Patrick, Eduarda e Diego pela ajuda nas coletas em campo e suporte médico nos momentos de morte iminente frente as minhas alergias, o apoio de vocês nas coletas literalmente me salvou e salvou esta pesquisa. A Izadora por toda a

ajuda e ensinamentos, teu apoio foi fundamental para a conclusão desse trabalho em diversos momentos. E reitero o agradecimento ao Patrick, Izadora e Diego que me acolheram e hospedaram durante minhas várias estadias em São Luís e me acompanham nesta jornada de conhecimento desde a graduação, no caso de Diego, desde o IFMA.

Aos colegas do Laboratório de Ciências Ambientais e Biodiversidade - LCAB por todo o incentivo, apoio moral e companheirismo principalmente na fase final de redação desta dissertação.

As meninas do grupo Poc's por todo o apoio desde quando recebi a notícia que fui aprovado no mestrado e que tem me ajudado em diversos momentos da minha vida como um grupo de apoio coletivo. Agradeço em especial a Hyana, minha *soulmate* canceriana, que por várias vezes me ajudou durante o mestrado principalmente revisando essa dissertação.

Ao Chafi Braide e toda a equipe Canal Grupo pela confiança, parceria e suporte principalmente em um dos momentos mais difíceis e traumáticos da minha vida.

E, finalmente, a todas as pessoas que, muitas vezes sem saber, tornaram possível a realização de mais um dos meus objetivos.

RESUMO

O extrativismo do babaçu já se destacou como uma das três principais atividades produtivas do cenário agrário maranhense, que apresentava relevância concentrada no caráter ecológico, preservacionista, político e social. Mas, a partir da década de 70, este cenário começa a mudar, dando início a um conflito histórico entre os produtores rurais e as comunidades extrativistas do coco babaçu. Ainda que o Movimento Interestadual das Quebradeiras de Coco Babaçu tenha unido as quebradeiras e adquirido força nos últimos anos, ele ainda não consegue combater a pressão que as áreas de babaçuais vêm sofrendo pelos grandes empreendimentos agrícolas. O conhecimento sobre os babaçuais é um fator crucial para a proteção dessa palmeira. Portanto, o objetivo desta pesquisa foi detectar a presença de babaçuais em diferentes ecorregiões da Amazônia Maranhense por meio da análise de imagens derivadas de sensoriamento remoto e estimar a quantidade de palmeiras babaçu nas áreas identificadas. O uso das bandas 4, 8 e 11 do sensor Sentinel-2 associada aos dados de NDVI aplicados para a classificação da vegetação do babaçu obteve os melhores resultados para a detecção de babaçuais para as áreas de Matinha e Imperatriz e esses dados somados com as imagens do Sentinel-1 foram o melhor resultado para a área de Santa Inês, com valores de precisão global e índice Kappa, respectivamente, de 71,12% e 66,57% para a área de Imperatriz; 69,66% e 61,93% em Santa Inês; e 57,58% e 48,26% em Matinha. Com base nos dados coletados em campo e com a análise visual de imagens de alta resolução do Google Earth Pro, foi possível validar o método de contagem que demonstrou uma correlação muito alta. Isso permitiu estimar o total de 34.027 mil palmeiras na área piloto de Matinha, 24.060 mil palmeiras na área piloto de Santa Inês e 16.918 mil palmeiras na área piloto de Imperatriz, totalizando aproximadamente 75 mil palmeiras babaçu nas três áreas.

Palavras-chave: *Attalea speciosa mart*, Geoprocessamento, Sensoriamento remoto, Sentinel, OBIA, Maranhão.

ABSTRACT

Babassu extractivism has already stood out as one of the three main productive activities in the agriculture context in Maranhão state which had relevance concentrated in the ecological, conservationist, political and social areas. But from the '70s onwards, this scenario began to change, giving rise to a historical conflict between farmers and agro-collectors of Babassu coconut. Although the “Movimento Interestadual das Quebradeiras de Coco Babaçu” has united the coconut breakers and gained strength in recent years, it is still not able to combat the pressure that the babassu areas have been suffering from large agricultural enterprises. Knowledge about babassu is a crucial factor for the protection of this palm tree. Therefore, the objective of this research was to detect the presence of babassu trees in different ecoregions of the Amazon region of Maranhão through the analysis of images derived from remote sensing and to estimate the number of babassu palms in the identified areas. The use of bands 4, 8 and 11 of the Sentinel-2 sensor associated with the NDVI data applied for the classification of babassu vegetation obtained the best results for the detection of babassu in the Matinha and Imperatriz areas, and these data added to the images of Sentinel-1 were the best result for Santa Inês area, with global precision and Kappa index values, respectively, of 71.12% and 66.57% for the Imperatriz area; 69.66% and 61.93% in Santa Inês; and 57.58% and 48.26% in Matinha. Based on the data collected in the field and with the visual analysis of high-resolution images from Google Earth Pro, it was possible to validate the counting method, which showed a very high correlation. This made it possible to estimate a total of 34027 thousand palm trees in the Matinha pilot area, 24060 thousand palm trees in the Santa Inês pilot area and 16918 thousand palm trees in the Imperatriz pilot area, totalling approximately 75 thousand babassu palms in the three areas.

Keywords: *Attalea speciosa mart*, Geoprocessing, Sentinel, Remote Sensing, OBIA, Maranhão.

LISTA DE SIGLAS

API - Interface de programação de aplicativo
ESA - Agência Espacial Europeia
ETM - Enhanced Thematic Mapper
ETM+ - Enhanced Thematic Mapper Plus
EVI - Enhanced Vegetation Index
GEE - Google Earth Engine
GPS - Global Positioning System
GRD - Ground Range Detected
IDE - Ambiente de desenvolvimento interativo
IMESC - Instituto Maranhense de Estudos Socioeconômicos e Cartográficos
INMET - Instituto Nacional de Meteorologia
INPE - Instituto Nacional de Pesquisas Espaciais
LiDAR - Light Detection And Ranging
MDE – Modelo Digital de Elevação
MIQCB - Movimento Interestadual das Quebradeiras de Coco Babaçu
MODIS - Moderate Resolution Imaging Spectroradiometer
NASA - National Aeronautics and Space Administration
NIR - Near Infrared
NDVI - Normalized Difference Vegetation Index
NDWI - Normalized difference Water Index
OBIA – Object-Based Image Analysis
OLI - Operational Land Imager
RGB - Red, Blue and Green
SAR - Radar de Abertura Sintética
SAVI - Soil Adjusted Vegetation Index
SWIR - Short-wave Infrared
TIR - Infravermelho térmico
TM - Thematic Mapper
UEMA - Universidade Estadual do Maranhão
USGS - United States Geological Survey
VNIR - Infravermelho próximo e visível

LISTA DE FIGURAS

REVISÃO BIBLIOGRÁFICA

FIGURA 1: Ecorregiões do Maranhão.....	22
FIGURA 2: Esquema de tomada de decisão do <i>Random Forest</i>	31
FIGURA 3: Esquema de falso-positivo e falso-negativo da matriz de confusão.....	33
CAPITULO 1	
FIGURA 1: A) Mapa do estado do Brasil com divisões estaduais. B) Visualização da Amazônia legal. C) Estado do Maranhão com identificação das 3 áreas piloto.....	38
FIGURA 2: Gráficos de temperatura e precipitação nas estações de Imperatriz e Zé Doca (Próximo a Matinha e Santa Inês) para o ano de 2020.....	39
FIGURA 3: Tabela de fisionomias e descrições das classes de cobertura.....	41
FIGURA 4: Respostas médias espectrais das respectivas bandas (2 - Blue; 3 - Green; 4 - Red; 5 - Red Edge 1; 6 - Red Edge 2; 7 - Red Edge 3; 8 - NIR; 8A - Red Edge 4; 11 - SWIR; 12 - SWIR) com os polígonos de validação de cada classe.....	42
FIGURA 5. Imagens do Google Earth, composição de bandas RGB (bandas 11, 8 e 4) e resultado da segmentação da área 1 - Matinha.....	45
FIGURA 6. Imagens do Google Earth, composição de bandas RGB (bandas 11, 8 e 4) e resultado da segmentação da área 2 - Santa Inês.....	46
FIGURA 7. Imagens do Google Earth, composição de bandas RGB (bandas 11, 8 e 4) e resultado da segmentação da área de Imperatriz (área 3).....	47
FIGURA 8. Matrizes de confusão resultantes dos processos de validação da classificação das áreas.....	49
FIGURA 9. Classificação da área 1 (unindo as classes de estrada, construção e solo) no município de Matinha em visualização sobreposta com imagem do Google Earth.....	50
FIGURA 10. Classificação da área 2 (unido as classes de estrada, construção e solo) no município de Santa Inês em visualização sobreposta com imagem do Google Earth.....	51
FIGURA 11. Classificação da área 3 (unindo as classes de estrada, construção) no município de Imperatriz em visualização sobreposta com imagem do Google Earth.....	52
FIGURA 12. Matriz de confusão resultante da composição 2.3 para a área de Imperatriz.....	54

CAPÍTULO 2

FIGURA 1. A) Mapa da Amazônia legal (IBGE, 2020). B) Mapa da Amazônia maranhense com identificação das 3 áreas piloto. C) Área 1 com marcações de parcelas. D) Área 2 com marcações de parcelas. E) Área 3 com marcações de parcelas.....	60
FIGURA 2. A) Visualização por imagem de satélite da classe de Floresta Nativa na área de Imperatriz. B) Visão interna da parcela (Autoria própria).....	61
FIGURA 3. A) Imagens do satélite sentinel 2 com resolução de 10m/pixel. B) Imagens do satélite Planet com resolução de 3m/pixel. C) Imagens do Google Earth com resolução de 0,5m/pixel.	62
FIGURA 4. Coleta de dados em campo com a utilização do GPS	63
FIGURA 5. Prancha com imagens do Google Earth relacionando número de indivíduos contados na imagem e número de indivíduos contados na parcela na área piloto de Imperatriz	64
FIGURA 6. Relação linear entre as contagens de babaçu em variáveis de campo e na imagem do Google Earth. A) Babaçu em baixa densidade em mata nativa; B) Babaçu em alta densidade em mata nativa; C) Babaçu em pastagem; e D) Distribuição total das classes na área de Imperatriz.....	65
FIGURA 7. Prancha com imagens do Google Earth com número de indivíduos contados na parcela na área de Matinha (área 1).....	67
FIGURA 8. Prancha com imagens do Google Earth com número de indivíduos contados na parcela na área de Santa Inês (área 2).....	68
FIGURA 9. Prancha com imagens do Google Earth com número de indivíduos contados na parcela na área de Imperatriz (área 3).....	69
FIGURA 10. Boxplot de comparativo de distribuição entre áreas para as classes de: A) Babaçu em Pastagem; B) Babaçu em baixa densidade em mata nativa; e C) Babaçu em alta densidade em mata nativa.....	70

LISTA DE TABELAS

REVISÃO BIBLIOGRÁFICA

TABELA 1: Atributos das bandas do produto Sentinel-2 MSI: MultiSpectral Instrument, Level-2A	29
TABELA 2: Matriz de confusão com p_{ij} representando a proporção da categoria i da cobertura da terra da área mapeada e da categoria j da cobertura da terra de referência.....	32

CAPÍTULO 1

TABELA 1. Resultado das composições e variações de classificação para a área de Matinha	45
TABELA 2. Resultado das composições e variações de classificação para a área de Santa Inês.....	46
TABELA 3. Resultado das composições e variações de classificação para a área de Imperatriz.....	47

CAPÍTULO 2

TABELA 1: Análise de variância entre as áreas de Matinha, Santa Inês e Imperatriz pela classe de: a) Babaçu em Pastagem; b) Babaçu em baixa densidade em mata nativa; e c) Babaçu em alta densidade em mata nativa (nível de significância estabelecido de 0,05).....	71
TABELA 2: Estimção de babaçu e densidade populacional.....	72

SUMÁRIO

INTRODUÇÃO	15
OBJETIVO	16
OBJETIVO GERAL	16
OBJETIVOS ESPECÍFICOS	16
REVISÃO BIBLIOGRÁFICA	17
Babaçu no Maranhão	17
A indústria do babaçu – ascensão e queda	18
As quebradeiras de coco	20
Descrição das Ecorregiões maranhenses com presença de Babaçu:	22
Ecorregião Floresta Amazônica	23
Ecorregião Mata de cocais	23
Ecorregião Campos de Baixada	24
Uso do Sensoriamento remoto aplicado para a proteção da palmeira do babaçu	24
Bases de dados derivados de sensores remotos:	26
Métodos de classificação de imagens	29
CAPÍTULO 1	34
IDENTIFICAÇÃO E MAPEAMENTO DE BABAÇUAIS POR MEIO DE SENSORIAMENTO REMOTO	34
INTRODUÇÃO	36
METODOLOGIA	37
ÁREA DE ESTUDO	37
DETECÇÃO E IDENTIFICAÇÃO DE BABAÇU	39
Obtenção de produtos derivados do satélite	39
Determinação de polígonos de treino e de validação de cada classe de cobertura	40
Segmentação e classificação de imagens	43
Validação e matriz de confusão	43
RESULTADOS	44
Análise espectral das bandas do sensor Sentinel-2	44
Segmentação e classificação	44
Validação da classificação	48
Identificação das classes de babaçu	50
DISCUSSÃO	53
CONSIDERAÇÕES FINAIS	56

CAPÍTULO 2	57
ESTIMAÇÃO DA DENSIDADE DA PALMEIRA BABAÇU EM DIFERENTES ECORREGIÕES DA AMAZÔNIA MARANHENSE	57
INTRODUÇÃO	59
METODOLOGIA	60
Área de estudo	60
Base de dados de imagens	61
Dados de Campo	62
Densidade da população e análise estatística	63
RESULTADOS	64
Validação do modelo de contagem por imagem de alta resolução	64
Estimação da densidade de indivíduos por análise visual da imagem de satélite	66
População de palmeiras babaçu e densidade de indivíduos por classe.	72
DISCUSSÃO	73
CONSIDERAÇÕES FINAIS	77
REFERÊNCIAS	78
APÊNDICES	86

1. INTRODUÇÃO

Babaçu é o nome dado a várias espécies do gênero *Attalea*, pertencente à família *Arecaceae*, típica das matas de transição dos ecossistemas Amazônia, Cerrado e Caatinga (ALBIERO *et al.* 2011; LEITMAN *et al.* 2015). A espécie mais estudada no Brasil é a *Attalea speciosa* Mart. Ex Spreng, uma palmeira robusta e imponente de estirpe isolada de 6-30 metros de altura e 30 a 60 centímetros de diâmetro a altura do peito (FLORA DO BRASIL 2020, 2021; LORENZI *et al.*, 2010). Esta espécie possui uma área de abrangência estimada em 196 mil km² no território brasileiro, englobando 279 municípios e 11 Estados no Brasil, como: Maranhão, Goiás, Tocantins, Piauí, Amazonas, Pará, Rondônia, Mato Grosso, Ceará, Minas Gerais e Bahia (CARRAZA, *et al.* 2012; CARVALHO, 2007; GOUVEIA, 2015).

No Maranhão, o extrativismo do babaçu já se destacou como uma das três principais atividades produtivas no cenário agrário, que apresentava relevância concentrada no caráter ecológico, preservacionista, político e social que assumem seus atores, as mulheres agroextrativistas ou quebradeiras de coco (MESQUITA, 2008). Entretanto, atualmente, o extrativismo tem perdido espaço na economia maranhense para atividades como: lavouras permanentes e temporárias; silvicultura; extração vegetal; e pecuária (SODRÉ, *et al.* 2019).

Mas a importância do babaçu ainda é tamanha nas regiões extrativistas, que muitas famílias têm na retirada e venda dos derivados sua principal fonte de renda. Como produtos da coleta e processamento, estas famílias tradicionalmente retiram a amêndoa e produzem o óleo para a alimentação, sem processar muitos outros subprodutos com grande potencial de venda, como o óleo orgânico, sabonetes, mesocarpo, velas e outros produtos variados de cosméticos (CARVALHO, 2007; GOUVEIA, 2015).

O babaçu é visto pelos pecuaristas como uma planta invasora com potencial para inviabilizar ou restringir o uso da pastagem. No entanto, a presença da palmeira nas áreas de pastagens, quando manejada de forma correta, pode trazer conforto térmico aos animais, resultando em maior ganho de peso, além de benefícios ao ambiente através de aporte de matéria orgânica (OLIVEIRA *et al.*, 2003).

O conhecimento sobre os babaçuais é um fator crucial para a proteção dessa palmeira. Portanto, o objetivo desta pesquisa foi mapear fisionomias com babaçuais e estimar a densidade das populações desta palmeira em áreas com ambientes diferentes. A partir do uso de técnicas de geoprocessamento e sensoriamento remoto foram identificadas áreas com ocorrência de babaçu, tanto em vegetação natural como em pastagens dentro de áreas piloto escolhidas para cada tipo de ambiente.

2. OBJETIVO

2.1. OBJETIVO GERAL

Este estudo tem por objetivo: 1) Detectar a presença de babaçuais em diferentes ecorregiões da Amazônia Maranhense por meio de análise de imagens derivadas de sensoriamento remoto; e 2) Estimar a quantidade de palmeiras babaçu nas áreas identificadas.

2.2. OBJETIVOS ESPECÍFICOS

- Classificar e mapear as vegetações com presença de palmeira babaçu nas diferentes áreas piloto a partir de imagens do satélite Sentinel 2 para o ano 2020;
- Determinar a densidade de palmeiras em diferentes ambientes a partir de uma detecção e delimitação visual em imagem de satélite de alta resolução no Google Earth Pro e validação com dados de campo.
- Estimar a população de babaçuais nas áreas identificadas no mapeamento segundo os diferentes ambientes.

3. REVISÃO BIBLIOGRÁFICA

Babaçu no Maranhão

O Maranhão é um dos 27 estados do Brasil, localizado na fronteira da região norte e situado na região nordeste, contemplando três diferentes biomas: 64,1 % do território no bioma Cerrado, 34,8 % no bioma Amazônia, e 1,1 % na Caatinga (SPINELLI-ARAÚJO, 2016). Ele aparece no cenário nacional como uma área de grande diversidade animal e vegetal, devido à sua extensão territorial e posição estratégica de confluência dos já mencionados biomas Cerrado, Amazônia e Caatinga e também, por apresentar formações típicas como a Mata dos Cocais (MANTOVANI, 2003). Reconhecida como uma área de transição, a Mata dos Cocais é um importante ecossistema não só pelas suas peculiaridades naturais, como também, pela sua importância cultural e por possuir comunidades indígenas e tradicionais, como as autodenominadas quebradeiras de coco babaçu (ALMEIDA E CUNHA, 2009).

O grande sucesso do coco babaçu no Maranhão se deve a três fatores chaves: (1) o extrativismo que leva consigo a roça seletiva que poupa palmeiras adultas produtivas, (2) a excelente adaptação do babaçu à roça e queima (quebra de dormência do coco pela queima, meristema subterrâneo protegido e forte rebrotamento das palmeiras juvenis), e (3) a aparente grande força competitiva do babaçu nos solos inférteis da região (MUNIZ, 2004). Sua ocorrência depende da tolerância a climas com temperaturas elevadas e precipitação pluviométrica superior a 1.000 mm anuais. Suas características morfológicas e fisiológicas permitem sua permanência no banco de sementes, mesmo após a derrubada da floresta e limpeza da área, geralmente realizada por meio de fogo (LATORRE *et al.*, 2017; KERBAUY, 2004).

Essa permanência do babaçu nas pastagens, por um lado, é importante para garantir matéria prima para a extração de óleo e seus demais produtos. Por outro lado, conforme o envelhecimento da pastagem, pode haver um aumento populacional da palmeira que pode eliminar as espécies cultivadas, o que leva aos agricultores a classificá-la como uma espécie invasora (SANTOS *et al.*, 2017; REIS, 2019).

No início da década de 70 se inicia o declínio da extração do babaçu, pois muitas áreas de ocorrência e acesso às palmeiras passam a ser privatizadas e ocupadas por fazendeiros e outras culturas são implantadas, como a cultura da soja,

cana-de-açúcar, arroz, algodão e uso da terra para implantação de pasto. Tal caso não pode deixar de ser abordado, pois afeta famílias rurais que dependem do produto extrativista, sendo que o mesmo desenvolve um forte papel socioeconômico. Até a década de 1980, antes das grandes derrubadas para implantação de projetos agrícolas, os babaçuais do Maranhão e Piauí cobriam uma área de 100.000km², com cerca de um bilhão de palmeiras, concentrando-se principalmente em Matões, Coelho Neto e Caxias no estado do Maranhão (VIANA E ZANIRATO, 2019).

Para entender o conflito existente e a importância do babaçu para o estado é necessário entender como foi o reconhecimento do seu potencial com o desenvolvimento da indústria do óleo de babaçu até a queda dessa indústria e troca por pastagens, agroindústrias, mineradoras, madeireiras e mais recentemente por extensas plantações de eucalipto (MARTINS E OLIVEIRA, 2011; VIANA E ZANIRATO, 2019).

A indústria do babaçu – ascensão e queda

Desde as primeiras décadas do século 20 até o final da década de 1970 houve um grande aumento de mão de obra rural no Maranhão. E um dos principais fatores para esse aumento foi a rápida expansão e relevância do babaçu, juntamente com a produção de alimentos como arroz e mandioca. Isto porque a base sobre a qual se organizava a produção do babaçu era na agricultura familiar (VIANA E ZANIRATO, 2019). Enquanto a agricultura familiar se expandia, associada a ela, também crescia a oferta do babaçu, principalmente a partir da década de 1920, quando o óleo de babaçu se transformou num produto comercial importante na pauta de exportações do Maranhão (MESQUITA. 1996).

Mas assim que a exploração do babaçu começou a ter visibilidade, ela foi acompanhada por uma série de impactos, dentre os quais se destacaram os conflitos sociais quanto ao acesso à terra e aos recursos naturais. (ALMEIDA, 1995; ANDRADE, 2004; VIANA E ZANIRATO, 2019). Os impactos foram sentidos no que diz respeito à questão da apropriação da renda gerada pelos diferentes segmentos envolvidos, da produção até a venda, que se fez de forma diferenciada e desigual. Em seguida, relacionou-se aos latifundiários que passaram a ver no babaçu, uma nova e importante fonte de recursos, possibilitando-lhes barganhar a cobrança de renda e a prestação de

serviço com o pequeno produtor sem terra. Por último, atingiram o pequeno produtor familiar, como uma alternativa extra e de fácil renda monetária para complementar o seu processo de produção, embora sujeito a pagar uma renda não-capitalista pelo uso da terra, no caso de vincular-se ao dono do babaçual (MESQUITA. 1996).

Neste contexto, muitas empresas que foram incentivadas pelo Estado, enxergavam a possibilidade de crescimento e lucro, instalaram-se nas áreas produtoras de matéria-prima e assumiram um papel preponderante no processamento do babaçu (FEARNSIDE, 2005). De fato, o setor industrial passou a dominar o mercado e, portanto, uma parcela maior do excedente gerado pelo pequeno produtor do babaçu começou a ser apropriada pela indústria. A partir de 1951, notou-se um crescimento significativo do número de indústrias no Maranhão: de 11 para um total de 17 usinas em 1961 e chega ao ápice de 34 no ano 1981, onde se concentrou principalmente nas cidades de São Luís (nove), Caxias (seis), Bacabal (quatro), entre outras 15 distribuídas pelo estado (MESQUITA. 1996).

No decorrer da década de 1970 se iniciou o processo de expansão da soja na região Sul do estado introduzido pelos "gaúchos", que na época eram grandes fazendeiros que migraram dos estados do sul do país. Os investimentos públicos em infra-estrutura e pesquisa agrônômica e, claro, os subsídios oferecidos pelo estado, tiveram um papel importante para essa expansão. Em decorrência do mercado externo favorável naquela década, a produção de soja cresceu rapidamente nos cerrados maranhenses, deslocando outras atividades tradicionais como a pecuária e o arroz e quase extinguindo as relacionadas ao extrativismo, como a palmeira babaçu (MELLO-THÉRY, 2011). Ainda nesse período, o governo passou a implantar políticas públicas de incentivo à criação de frentes de povoamento rumo à Amazônia Legal, como o Plano de Integração Nacional, adotado durante o regime militar, que aportaram um número significativo de grandes grupos empresariais para aproveitarem as benesses do estado, gerando conflito com a agricultura familiar (FEARNSIDE, 2005; MELLO, 2006).

O principal conflito criado foi a desarticulação da pequena produção de alimentos, que afetou diretamente a oferta do babaçu. De fato, houve o direcionamento dos investimentos em projetos que chegavam a quase 95 % para a pecuária de corte e apenas 5% destinados a agricultura temporária, que eram os cultivos de curta ou média

duração baseado, sobretudo, na cultura do arroz, feijão, milho, cana-de-açúcar e mandioca (IBGE, 1984). Além de que, as áreas utilizadas para a pecuária se aproximavam dos 200 km², áreas essas que antes eram utilizadas para a coleta do coco babaçu (MESQUITA, 1996).

A década de 1980 foi o período em que os problemas relativos ao extrativismo emergiram com mais força, sem contudo, haver um encaminhamento para sua solução. Ao final dos anos 1970, era notório o direcionamento para este quadro, visto que os segmentos com base no babaçu estavam com baixo desempenho. A conversão de áreas para a atividade pecuária contribuiu, de fato, para deslocar/expulsar uma parcela importante de agroextrativistas e impediu-lhes o acesso à terra e, portanto, ao babaçu (ALMEIDA, 1995; ANDRADE, 2004; VIANA E ZANIRATO, 2019).

Assiste-se, assim, a um declínio constante do parque industrial tradicional, em particular as empresas ligadas ao babaçu, indústrias de alimentos, perfumaria, sabão, velas, entre outras. Inúmeras empresas, de todos os tamanhos, na capital e no interior, desaparecem. As poucas que sobreviveram adaptaram seu processo produtivo a outras oleaginosas ou, simplesmente, passaram a comprar óleo bruto importado da Ásia, sendo este mais barato do que o processado no próprio estado (MESQUITA, 1996).

Este acontecimento ocorreu tanto em áreas tradicionais voltadas à exploração, como a região dos Cocais, quanto em outras: Amazônia, Litoral e Baixada. Embora em várias dessas áreas surjam movimentos de pequenos produtores contestando, o impedimento ao livre acesso aos babaçuais e a sua devastação indiscriminada, poucos conseguiram sucesso (PEIXOTO, 2004; MESQUITA, 1996). De fato, apesar de existir uma legislação específica de proteção a tais práticas abusivas, o que se constata, é uma ação insuficiente, ineficaz e, muitas vezes, omissa das instituições públicas responsáveis pela fiscalização (FEARNSIDE, 2005; MELLO-THÉRY, 2011; VIANA E ZANIRATO, 2019).

As quebradeiras de coco

O cenário no final da década de 1980 era o seguinte: para que essas mulheres agroextrativistas pudessem exercer suas atividades, elas deveriam firmar contratos com os proprietários das terras que estipulavam as cláusulas com mais interesse para si mesmos. Aquelas que se recusassem a se submeterem a esses contratos eram proibidas

de entrar na área, sendo acusadas de furto, invasão de propriedade, dano, entre outros crimes (SHIRAIISHI, 2017). Elas sofriam por baixa remuneração, falsas acusações de sacrifício de animais, por roubos diversos e sofriam a apropriação da produção extrativista. E foi a partir desse contexto de subordinação que as quebradeiras começaram a realizar reivindicações com mais força (ALMEIDA, 1995; ARAUJO-JUNIOR, 2014)

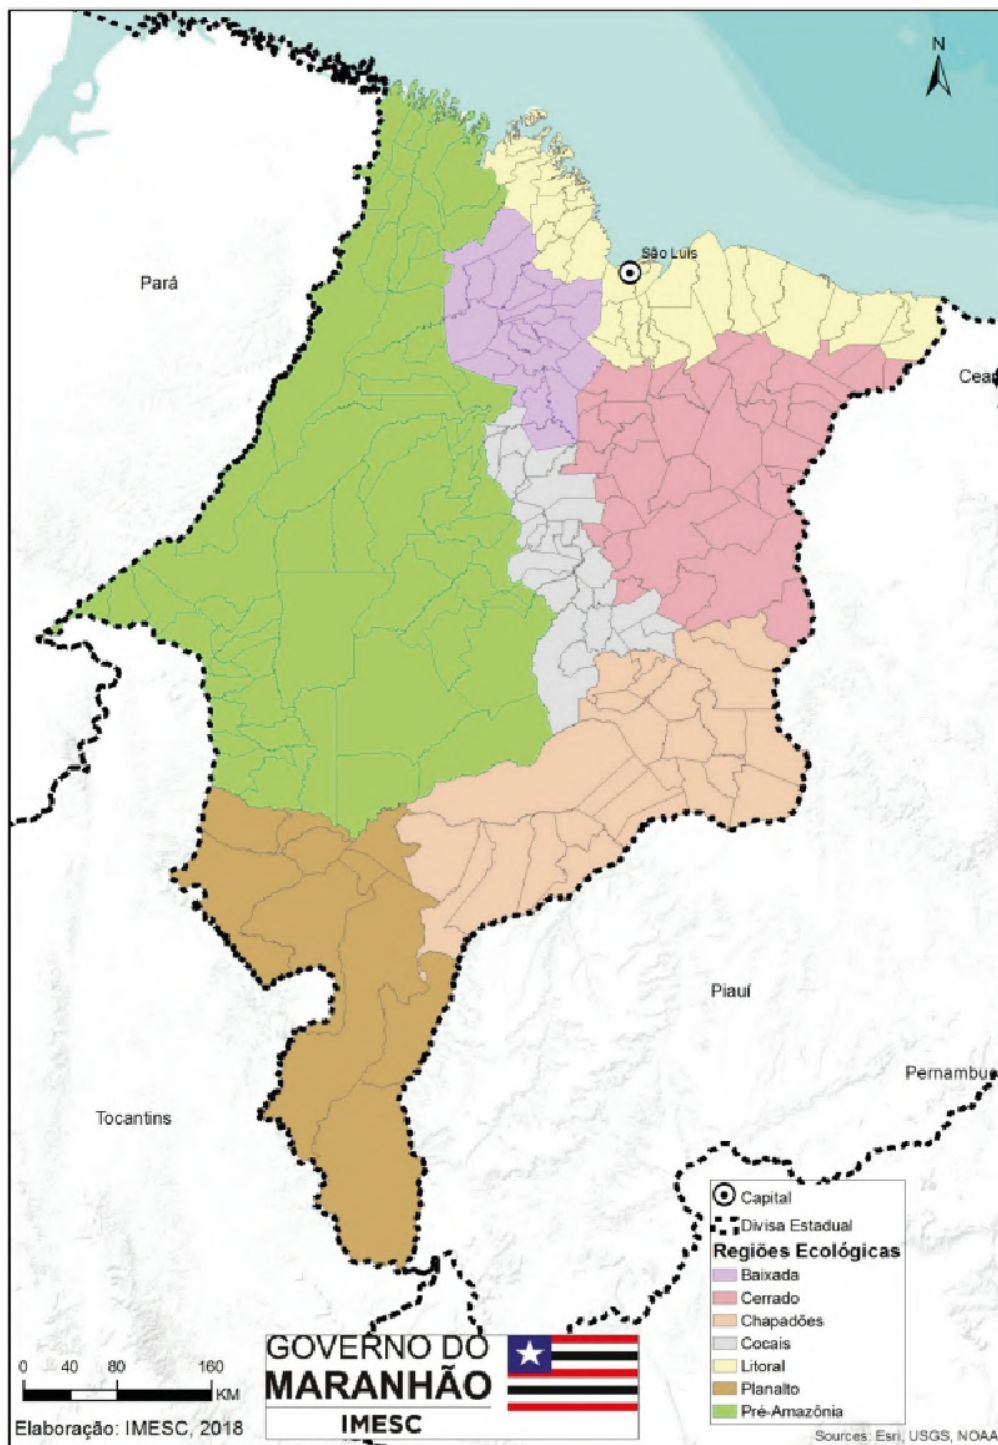
Em 1991 foi quando se iniciou o processo de organização, que resultou no Movimento Interestadual das Quebradeiras de Coco Babaçu – MIQCB. Esse movimento contribuiu com a agenda de luta das quebradeiras de coco, que priorizava as questões ligadas à preservação do meio ambiente e às garantias do livre acesso e uso comum das palmeiras de babaçu. Assim, as quebradeiras conseguiram mais força nas leis do “babaçu livre”¹ (NETO, 2017; MIQCB, 2020).

O extrativismo do babaçu, feito de forma manual pelas quebradeiras, é uma prática sustentável que tem potencial até para auxiliar na dispersão do fruto do coco e no ingresso de novas palmeiras, contribuindo indiretamente na manutenção da planta (MIQCB, 2020). Essas práticas condizem com os princípios da sustentabilidade, já que cada mulher coleta somente o suficiente para sua produção particular, deixando outros cocos para as demais mulheres. Por causa disso, não são comuns disputas entre as quebradeiras pelo recurso, já que sempre tem disponível para todas as famílias (NETO 2017).

Mas mesmo que o MIQCB tenha unido as quebradeiras e adquirido força nos últimos anos, eles ainda não conseguem combater a pressão que as áreas de babaçuais vêm sofrendo pelos grandes empreendimentos agrícolas (BARTABURU *et al.* 2018; ARAUJO E NOVAE, 2018). A falta de conhecimento sobre a distribuição e dinâmica da palmeira é um dos fatores que impossibilitam a proteção do babaçu, e conseqüentemente, da atividade extrativista que afeta as quebradeiras de coco.

¹ Lei Estadual nº 4734 de 18 de junho de 1986 - Proíbe a derrubada de palmeira do babaçu.
Lei n 4.154/1980 - Disciplina a Política de Controle e Preservação do Meio Ambiente e dos Recursos Naturais / Art.11 – São consideradas áreas sob Proteção Especial as de incidências de Babaçuais, de propriedade pública ou privada.
Lei 4.349/1981 – Institui o babaçu como árvore símbolo do Maranhão.

Descrição das Ecorregiões maranhenses com presença de Babaçu:



Fonte: IMESC, 2018

FIGURA 1: Ecorregiões do Maranhão (IMESC, 2018).

Ecorregião Floresta Amazônica

A Amazônia é o maior bioma do Brasil em um território de 4.196.943 milhões de km² que corresponde a mais de 40% do território nacional (MMA, 2020). A vegetação predominante desta ecorregião é a floresta ombrófila densa, que subdivide-se em floresta ombrófila aluvial, de platôs e submontana. A floresta ombrófila aluvial ocupa as áreas mais úmidas dos vales onde se destacam as palmáceas, como o açaí (*Euterpe oleracea*), o buriti (*Mauritia flexuosa*) e a buritirana (*Mauritia aculeata*). A fertilidade do solo amazônico está restrita a camada superior que possui húmus. (FEITOSA E TROVÃO, 2006; MERCEDES E CUNHA, 2008).

A ecorregião amazônica apresenta altas temperaturas médias anuais (entre 25°C e 27°C), baixa amplitude térmica e moderada deficiência hídrica nos meses de julho a setembro, com totais pluviométricos entre 1500 mm a 2000 mm e umidade relativa do ar superior a 70 %. No extremo noroeste nesta zona, ocorre moderada ou nenhuma deficiência hídrica anual e totais pluviométricos anuais superiores a 2000 mm e umidade relativa do ar em torno de 80 % (FEITOSA E TROVÃO, 2006).

Ecorregião Mata de cocais

Localizada entre o cerrado e o bioma amazônico, a ecorregião Mata de cocais apresenta vegetação resultante da mistura de espécies de diferentes formações vegetais. As espécies predominantes são palmeiras, como o babaçu (*Attalea speciosa*), a carnaúba (*Copernicia prunifera*), o tucum (*Bactris setosa*), a juçara (*Euterpe edulis*) e o buriti (*Mauritia flexuosa*). As matas dessa zona fitogeográfica são de difícil caracterização, sendo a zona que apresenta a maior concentração da palmeira babaçu no estado do Maranhão. Na Mata de cocais apresenta altas temperaturas médias anuais (entre 25°C e 27°C), moderada amplitude térmica, pouco ou nenhum excedente hídrico anual, totais pluviométricos entre 800 mm e 1600 mm anuais e umidade relativa do ar superior a 70 % (FEITOSA E TROVÃO, 2006).

Ecorregião Campos de Baixada

A “Baixada Maranhense” é considerada um pantanal amazônico, uma imensa região formada por cadeias de lagoas com extensos pântanos e campos naturais inundáveis periodicamente que, no período de estiagem, ficam descobertos durante aproximadamente seis meses por ano. Predominância de formações vegetais abertas localizadas nas planícies de inundação, onde também, se vêem árvores mais altas e palmeiras, como a canarana (*Mauritia carana*) e o buriti (*Mauritia flexuosa*) e também, mata de igapó, vegetação marginal de lagos, rios e igarapés, inundadas sazonalmente. Essa ecorregião também apresenta altas temperaturas médias anuais (superior a 27°C), moderada amplitude térmica e pequena deficiência hídrica anual, totais pluviométricos entre 800 mm e 1200 mm anuais e umidade relativa do ar superior a 70 % (FEITOSA E TROVÃO, 2006).

Uso do Sensoriamento remoto aplicado para a proteção da palmeira do babaçu

O sensoriamento remoto tem se mostrado como uma das mais bem-sucedidas ferramentas para a coleta de dados, assim como para o levantamento e monitoramento de recursos terrestres (MENESES E ALMEIDA, 2012). Por meio de imagens e produtos de satélite é possível identificar os diferentes tipos de usos e cobertura da terra de acordo com o valor de reflectância de cada pixel, tendo em vista que cada componente da superfície terrestre como vegetação, água e solo, possuem características espectrais únicas de cada elemento químico, físico ou biológico que o compõe (LIU, 2006; TRINDADE E IARMUL, 2018).

Por exemplo, sabe-se que as imagens orbitais auxiliam práticas de monitoramento da produtividade como exemplo, o trabalho de Oliveira (2015), no qual estimou a produtividade da biomassa da cana-de-açúcar em função de índices de vegetação a partir de dados do sensor OLI/Landsat 8. Em trabalhos como o de Schultz *et al.* (2016) as imagens Landsat foram avaliadas para a classificação de culturas de cana-de-açúcar e soja via análise de imagens orientadas a objetos (OBIA/Random Forest). Isso se deve ao refinamento significativo nas resoluções espacial, espectral e radiométrica de imagens, como a inserção de bandas espectrais específicas sensíveis à vegetação (XAVIER *et al.*, 2019).

A detecção e identificação de espécies a partir de imagens de satélite representa um grande desafio, tendo em vista que ainda não se estabeleceram metodologias robustas para se mapear as espécies de maneira mais rápida e menos onerosa que o inventário (HAMAMURA, 2020). Hamamura (2020) comparando dois métodos de identificação de árvores: utilizando imagens RGB de alta resolução e com sensor LiDAR multiespectral. Nesta pesquisa o autor indicou que é possível se aplicar ambas as metodologias, mas que com os sensores de banda multiespectral foi possível obter resultados mais satisfatórios com até 90% de acurácia. Xavier *et al.* (2019) avaliaram o potencial do uso de imagens multiespectrais do Sentinel-2 para identificar a infecção por nematoides em uma lavoura cafeeira. No trabalho foi identificado que plantas saudáveis respondem diferentemente de sadias apresentando uma variação na refletância de bandas (Red, NIR e NDVI) que poderia auxiliar no processo de classificação de imagens. Essa combinação permitiu detectar áreas de infecção por nematoides e realizar a classificação da imagem com 97,91% de acurácia. Ambos os trabalhos evidenciam a utilização de faixas multiespectrais e hiperespectrais para a identificação de espécies e fatores ambientais importantes, demonstrando o potencial dessas ferramentas.

No presente, existem poucos estudos sobre a detecção de palmeiras usando ferramentas e técnicas do sensoriamento remoto, principalmente da palmeira do babaçu no estado do Maranhão. Esse tipo de detecção apresenta um certo desafio, já que o babaçu encontra-se misturado a outras espécies de palmeiras e formações florestais que apresentam padrão espectral muito semelhante (VIEIRA *et al* 2017). Todavia, as áreas com presença de babaçu apresentam feições de sombreamento bem características, fator este de bastante relevância para a identificação dessas áreas, especialmente na utilização do processo de classificação supervisionada (VIEIRA *et al* 2017; THALES, 1999).

Os primeiros esforços para a identificação da palmeira no Brasil por meio de sensoriamento remoto começaram a ser desenvolvidas na década de 1990. Thales (1999) foi um dos pioneiros, identificando as áreas dominadas por babaçu usando imagens orbitais do sensor TM do satélite Landsat 5. Essas manchas foram reconhecidas nas imagens como manchas escuras (devido a sombra projetada pela palmeira) em ambientes com baixa densidade de babaçu. Em seguida, outros autores como Espírito Santo e Shimabukuro (2005) encontraram resultados semelhantes,

identificando áreas de florestas dominadas por babaçu pelo aspecto escuro em imagens dos sensores TM e ETM+ também do satélite Landsat 5 e 7. Já Castro e Silva (2020) utilizando dados de sensores do ETM+/Landsat 7 avaliaram diferentes índices de vegetação com o intuito de verificar o mais adequado na identificação de babaçuais, por meio dos seus respectivos valores de biomassa no município de Babaçulândia no Tocantins - TO.

Outros estudos conseguiram caracterizar as áreas potenciais de ocorrência do babaçu na bacia do rio Cocal no estado do Tocantins a partir do processamento digital da imagem ASTER constatando assim que 31,36% da área total da bacia são áreas de potencial ocorrência (SILVA *et al*, 2009). Na pesquisa de Vieira *et al* (2017), os autores utilizaram imagens do satélite de alta resolução RapidEye (resolução espacial de 6.5 m, reamostrado a 5 m se for ortorretificado) para a detecção de babaçuais com o intuito de melhorar a detecção usando uma imagem com um sensor de melhor resolução comparado com os trabalhos preliminares realizados com o satélites da série Landsat, o que permitiu a individualização das classes: água, solo, babaçu, área de cultivo, área urbana e vegetação nativa, possibilitando a localização das áreas de babaçu.

Até agora não existe um consenso ou uma metodologia que permita realizar a detecção de babaçuais a grande escala, considerando que esta espécie pode se encontrar em vários ambientes diferentes, tanto abertos (pastagem, cerrado, mata dos cocais) como fechados (floresta amazônica, etc). Esses trabalhos evidenciaram a necessidade de novas metodologias ou outros sensores para que haja maior segurança na identificação dos babaçuais. A adoção de ferramentas como classificadores de aprendizado de máquina em conjunto com uma base de dados diversificada que engloba imagens multiespectrais, sensor de radar e índices de vegetação podem nos trazer um mapeamento com bons resultados de acurácia, gerando a segurança necessária para a identificação dessa palmeira.

Bases de dados derivados de sensores remotos:

Atualmente, existe uma diversidade de sensores e satélites que captam a superfície terrestre em vários níveis de resolução espectral, faixas temporais e com uma resolução espacial que pode chegar até menos de um metro. Isso possibilita o uso do sensoriamento remoto para realizar levantamentos de recursos naturais, desmatamentos

florestais, monitoramento ambiental e dinâmica de ecossistemas , inclusive na identificação de áreas com espécies específicas (MENESES E ALMEIDA, 2015).

Nesse contexto, a empresa Google desenvolveu uma plataforma para análises de dados em escala planetária, o Google Earth Engine (GEE). Ele combina um catálogo de imagens de satélite e conjuntos de dados geoespaciais e disponibiliza para pesquisadores e desenvolvedores a detecção de alterações, mapeamento de tendências e quantificação de diferenças na superfície da Terra (GORELICK *et. al.*, 2017).

Ele é acessado e controlado por meio de uma interface de programação de aplicativo (API) acessível pela Internet e um ambiente de desenvolvimento interativo (IDE) baseado na web associado que permite a prototipagem rápida e a visualização dos resultados. Os usuários podem acessar e analisar dados do catálogo público, bem como seus próprios dados privados, usando uma biblioteca de operadores fornecida pela API do Earth Engine. Esses operadores são implementados em um grande sistema de processamento paralelo que subdivide e distribui automaticamente os cálculos, fornecendo recursos de análise de alto rendimento(GORELICK *et. al.*, 2017).

A maior parte do catálogo é composta por imagens de sensoriamento remoto que observam a Terra, incluindo toda a série Landsat, bem como arquivos completos de dados dos satélites Sentinel-1 e Sentinel-2 e os sensores MODIS (*Moderate Resolution Imaging Spectroradiometer*) a bordo das plataformas Terra e Acqua. O GEE também inclui previsões climáticas, dados de cobertura do solo e muitos outros conjuntos de dados ambientais, geofísicos e socioeconômicos (GORELICK *et. al.*, 2017).

O Landsat é um programa conjunto do *United States Geological Survey* - USGS e da *National Aeronautics and Space Administration* - NASA, que tem observado a Terra continuamente desde 1972 até os dias atuais, sendo uma das séries temporais de imagens mais completas e extensas disponíveis. O satélite Landsat 1-4 esteve em órbita no período de 1972 a 1993 com uma resolução de 60m. Já o sensor TM do Landsat 5 foi lançado em 1984 e ficou em órbita até novembro de 2011.

Hoje, os sensores ETM+ e OLI dos satélites Landsat 7 e 8 respectivamente cobrem toda a superfície terrestre com uma resolução de 30 metros, uma vez a cada duas semanas, incluindo dados multiespectrais com 4 bandas (LS7) e 5 bandas (LS8) de infravermelho próximo e visível (VNIR) e 2 bandas de infravermelho de onda curta (SWIR) processadas para reflectância de superfície ortorretificada e uma banda de

infravermelho térmico (TIR) processada para temperatura de superfície ortorretificada. Os dados do Landsat estão disponíveis no Google Earth Engine em sua forma bruta, como reflectância de superfície, reflectância aparente, e em vários produtos computados prontos para uso, como índices de vegetação NDVI - *Normalized Difference Vegetation Index* e EVI - *Enhanced Vegetation Index* (GEE, 2020).

Já os sensores MODIS (*Moderate Resolution Imaging Spectroradiometer*) nos satélites Terra e Aqua da NASA adquirem imagens da superfície terrestre diariamente desde 1999, com resoluções de 250 m, 500 m e 1 km. As imagens desses sensores incluem a temperatura, reflexão de superfície e produtos derivados, como índices de vegetação, albedo, índice de área foliar e cobertura de neve (PETRI, 2019; GEE, 2020).

O projeto Sentinel implementado pela Agência Espacial Europeia (ESA) desenvolveu um grupo de satélites para operacionalizar o programa Copernicus, que inclui imagens de radar para qualquer clima, imagens ópticas de alta resolução, dados oceânicos e terrestres adequados para estudos ambientais e monitoramento climático (GEE, 2020).

A missão Sentinel-1 fornece dados de um instrumento Radar de Abertura Sintética (SAR) de banda C de dupla polarização a 5,405 GHz. A coleção é atualizada diariamente e os novos ativos são inseridos dentro de dois dias após serem disponibilizados pelo satélite. Nela, contém todas as cenas Ground Range Detected (GRD), sendo que cada cena contém três resoluções (10, 25 ou 40 metros), quatro combinações de banda (correspondendo à polarização da cena) e três modos de instrumento. Além disso, a cena também contém 1 ou 2 das 4 bandas de polarização possíveis, dependendo das configurações de polarização do instrumento (GEE, 2020b). As combinações possíveis são VV ou HH de banda única e VV + VH e HH + HV de banda dupla:

- VV: co-polarização única, transmissão vertical / recepção vertical
- HH: co-polarização única, transmissão horizontal / recepção horizontal
- VV + VH: polarização cruzada de banda dupla, transmissão vertical / recepção horizontal
- HH + HV: polarização cruzada de banda dupla, transmissão horizontal / recepção vertical

O Sentinel-2 é uma missão de geração de imagens multiespectrais de alta resolução e alta largura que apoia os estudos de monitoramento de vegetação, solo e cobertura de água (GEE, 2020b). Com resoluções de bandas que variam entre 10 metros a 60 metros por pixel (**Tabela 1**), coletados a cada 5 dias, as imagens obtidas nesse satélite podem ajudar na identificação de palmeiras, tendo em vista que em algumas configurações de distribuição, estas ficam dispersas e as manchas podem ser mais difíceis de detectar em resoluções maiores.

Nome	Escala	Resolução	Comprimento de onda	Descrição
B1	0.0001	60 metros	443.9nm (S2A) / 442.3nm (S2B)	Aerosols
B2	0.0001	10 metros	496.6nm (S2A) / 492.1nm (S2B)	Blue
B3	0.0001	10 metros	560nm (S2A) / 559nm (S2B)	Green
B4	0.0001	10 metros	664.5nm (S2A) / 665nm (S2B)	Red
B5	0.0001	20 metros	703.9nm (S2A) / 703.8nm (S2B)	Red Edge 1
B6	0.0001	20 metros	740.2nm (S2A) / 739.1nm (S2B)	Red Edge 2
B7	0.0001	20 metros	782.5nm (S2A) / 779.7nm (S2B)	Red Edge 3
B8	0.0001	10 metros	835.1nm (S2A) / 833nm (S2B)	NIR
B8A	0.0001	20 metros	864.8nm (S2A) / 864nm (S2B)	Red Edge 4
B9	0.0001	60 metros	945nm (S2A) / 943.2nm (S2B)	Water vapor
B11	0.0001	20 metros	1613.7nm (S2A) / 1610.4nm (S2B)	SWIR 1
B12	0.0001	20 metros	2202.4nm (S2A) / 2185.7nm (S2B)	SWIR 2

Tabela 1: Atributos das bandas do produto Sentinel-2 MSI: MultiSpectral Instrument, Level-2A (Adaptado de GEE, 2020b).

Métodos de classificação de imagens

A classificação é o processo de extração de informação em imagens para reconhecer padrões e objetos homogêneos e são utilizados em Sensoriamento Remoto para detectar e mapear áreas da superfície terrestre que correspondem aos temas de interesse. A etapa de classificação é executada por algoritmos que reconhecem padrões espectrais, tanto para classificação por regiões ou pixel a pixel, e podem ser executados de maneira supervisionada ou não-supervisionada (INPE, 2006).

Nas classificações supervisionadas, são feitas seleções de áreas cuja classe é anteriormente conhecida para a criação de amostras de treinamento. Nestas áreas amostradas são calculados valores estatísticos que permitem a caracterização de cada classe pelo algoritmo escolhido. Já a classificação não-supervisionada, é indicada quando não há conhecimento específico sobre a área de estudo, ela é executada por agrupamento de pixels. Ambas dão origem ao produto final: o mapa temático (SILVA, 2014).

Na classificação pixel a pixel, os algoritmos procuram usar de forma individual a informação espectral de cada pixel na busca por regiões homogêneas. Ou seja, se um pixel satisfaz a um determinado conjunto de critérios, este pixel é atribuído à classe que melhor satisfaz os critérios estabelecidos (INPE, 2006; SILVA, 2014). Já os classificadores por regiões, utilizam a informação espectral de cada pixel e a relação espacial de vizinhança entre pixels (áreas homogêneas espectrais e espaciais da imagem), como a Classificação Orientada ao Objeto (OBIA). A classificação OBIA (*Object-based Image Analysis*) consiste em analisar parâmetros que vão além da resposta espectral do pixel, como textura e forma dos objetos que compõem uma determinada cena em uma imagem (PINHO, 2005).

Nos métodos OBIA a análise da imagem é baseada em objetos geográficos e consiste basicamente na aplicação de dois procedimentos metodológicos: (1) segmentação/regionalização, técnica primária usada para conversão de uma cena ou imagem em múltiplos objetos; (2) classificação baseada em regras de decisão que explicitam as propriedades dos objetos expressas pelos atributos (SILVA, 2014).

Recentemente, as áreas de Inteligência Artificial e Aprendizado de Máquina têm revolucionado a classificação de imagens. O crescimento explosivo dessa área do conhecimento nas últimas décadas levou ao desenvolvimento de vários algoritmos classificadores, como por exemplo o *Random Forest* e as redes neurais convolucionais (CHAMMA *et al*, 2021).

O algoritmo de classificação *Random Forest* é formado por várias árvores de decisão. Cada árvore é um classificador individual que emite um voto para o rótulo correspondente para uma entrada. Os votos das árvores individuais são computados e a classe que tem a maioria dos votos é eleita como rótulo definitivo do valor de entrada (**Figura 2**). As árvores de decisão são construídas de forma randômica, utilizando

exemplos de treinamento e características aleatórias do conjunto de dados de treinamento. Isso faz com que cada classificador individual seja relativamente robusto, mas tenha pouca correlação com qualquer outra árvore de decisão da floresta randômica (BREIMAN, 2001; CHAMMA *et al*, 2021).

A comunidade de sensoriamento remoto têm dado bastante atenção a esse classificador, já que as florestas randômicas são intuitivas, não sofrem sobreajuste, têm estimativas de erro não-enviesados (BREIMAN, 2001), são rápidas no processamento (BELGIU E DRAGUT, 2016), e são capazes de fazer diferentes análises em grandes conjuntos de dados, de forma eficaz (RODRIGUEZ-GALIANO *et al.*, 2012).

Ressalta-se que as técnicas e algoritmos de classificação digital de imagens, automatizam o processo de extração de informações das imagens eliminando a subjetividade da interpretação humana e reduzindo o esforço de trabalho do analista. Desta forma, o resultado final da classificação constitui em um mapa temático de pixels classificados, representado em polígonos os padrões homogêneos de classes de alvos (MENESES E ALMEIDA, 2015).

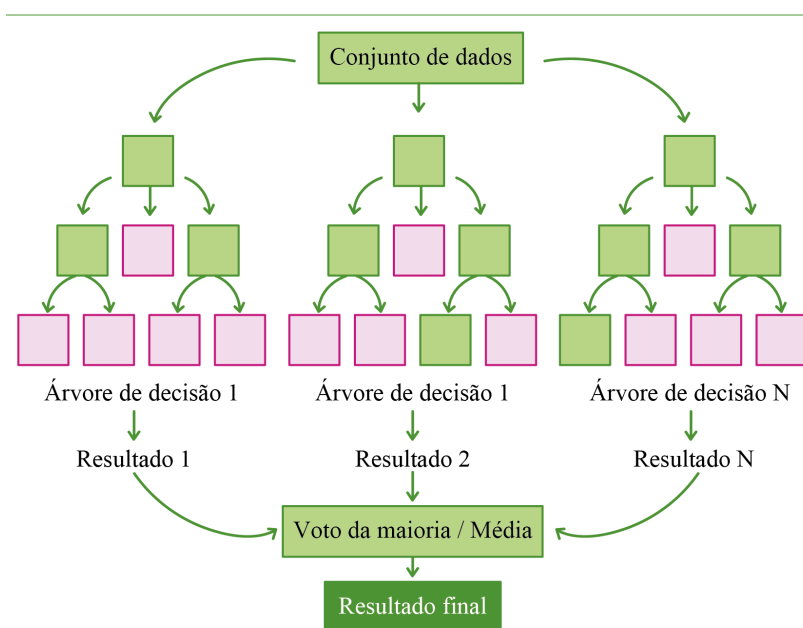


FIGURA 2: Esquema de tomada de decisão do *Random Forest* (Adaptado de CHAMMA *et al*, 2021).

Validação da classificação: A prática de classificação de imagens em sensoriamento remoto sempre nos leva a questionamentos sobre a acurácia dos dados,

quanto deste mapeamento realizado condiz com a realidade de campo. Para aferir essa informação se faz necessário ir ao campo, para coleta de pontos de validação e a realização de análises estatísticas que nos apresentem o grau de similaridade entre dados de referência e a classificação (LEVER, 2016).

A matriz de confusão (**figura 3**) ou matriz de erro é uma das formas estatísticas mais usadas para a análise de confiabilidade da classificação, permitindo verificar o nível de acerto entre a classificação e o mapeamento de referência (CONGALTON, 1991). Basicamente o processo se dá em uma tabela, onde linhas representam a classificação, as colunas representam a referência (verdade) e a diagonal principal representa os acertos da classificação. A matriz de confusão, apresentada na Tabela 1, apresenta uma visão tabulada da acurácia do mapa de classificação além de permitir o cálculo de medidas específicas tais como a acurácia global, acurácia do usuário e acurácia do produtor (CONGALTON, 1991). A acurácia global é uma das medidas calculada pela soma do total dos pixels corretamente classificados dividida pelo número total de pixels da matriz de confusão (CONGALTON, 1991; PANTALEÃO E SCOFIELD, 2009).

Classificada	Referência				total
	1	2	...	m	
<i>1</i>	<i>p11</i>	<i>p12</i>	...	<i>p1m</i>	<i>p1+</i>
<i>2</i>	<i>p21</i>	<i>p22</i>	...	<i>p2m</i>	<i>p2+</i>
...
<i>m</i>	<i>pm1</i>	<i>pm2</i>	...	<i>pmm</i>	<i>pm+</i>
<i>Total</i>	<i>p+1</i>	<i>p+2</i>	...	<i>p+m</i>	

TABELA 2: Matriz de confusão com “*p_{ij}*” representando a proporção da categoria “*i*” da cobertura da terra da área mapeada e da categoria “*j*” da cobertura da terra de referência (Adaptado de PANTALEÃO E SCOFIELD, 2009)

A estatística Kappa é uma medida largamente utilizada da acurácia de classificação. O Kappa é uma proporção de acerto depois da eliminação do acerto por acaso, ele sempre apresenta valor menor que a acurácia total porque, diferentemente do Índice de Acurácia Total, este considera todos os valores fora da diagonal da matriz de confusão (SOUZA *et al*, 2019).

Matriz de confusão

		+	-		
+	Verdadeiro Positivo (TPs)	Falso Negativo (FNs)	Verdadeiro Positivo (TPs)	Erro tipo 2 Erro de omissão	
-	Falso Positivo (FPs)	Verdadeiro Negativo (FPs)	Erro tipo 1 Erro de comissão	Verdadeiro Negativo (FPs)	

FIGURA 3: Esquema de falso-positivo e falso-negativo da matriz de confusão (Adaptado de LEVER, 2016).

As métricas de classificação são calculadas a partir de verdadeiros positivos (TPs), falsos positivos (FPs), falsos negativos (FNs) e verdadeiros negativos (TNs), onde: Falso-Positivo é um Erro tipo I ou Erro de comissão: erro em que o modelo previu a classe Positivo quando o valor real era classe Negativo; e o Falso-Negativo é um Erro tipo II ou Erro de omissão: erro em que o modelo previu a classe Negativo quando o valor real era classe Positivo (**Figura 4**) (LEVER, 2016).

CAPÍTULO 1

IDENTIFICAÇÃO E MAPEAMENTO DE BABAÇUAIS POR MEIO DE SENSORIAMENTO REMOTO

RESUMO

A relação entre o homem e a natureza se caracteriza pela alteração do uso do ambiente, que se torna ainda mais intensa em locais onde há conversão de ecossistemas naturais para ambientes antrópicos, como os agrícolas, industriais e urbanos. No Maranhão, áreas com babaçuais têm sido substituídas principalmente pela implantação de monoculturas como a soja, eucalipto e pastagens. Assim, este estudo tem por objetivo classificar e mapear as vegetações com presença de palmeira babaçu em diferentes áreas piloto a partir de imagens do satélite Sentinel 2 para o ano de 2020. Para a classificação foi utilizada a metodologia OBIA (*Object-based Image Analysis*) por meio das ferramentas de código aberto da biblioteca RSGISLib, em linguagem de programação Python, e da linguagem de programação R para a validação. O uso das bandas 4, 8 e 11 do sensor Sentinel-2, associada aos dados de NDVI aplicados para a classificação da vegetação do babaçu, obteve os melhores resultados para as áreas de Matinha e Imperatriz, esses dados somados com as imagens do sentinel 1 foram o melhor resultado para a área de Santa Inês, com valores de precisão global e índice Kappa, respectivamente, de 71,12% e 66,57% para a área de Imperatriz; 69,66% e 61,93% em Santa Inês; e 57,58% e 48,26% em Matinha. O maior desafio no processo de classificação de babaçuais a uma escala regional aparece no contexto maranhense pelo fato de ter áreas com presença de outras palmeiras. De fato, a classificação de palmeiras de babaçu utilizando os sensores sentinel 1 e sentinel 2 atrelado aos dados de NDVI e ferramentas aqui apresentadas demonstram potencial na identificação de plantas e áreas com ocorrência desta espécie.

Palavras-chave: *Attalea speciosa mart*, Sentinel, OBIA, Palmeiras, Maranhão.

ABSTRACT

The relationship between man and nature is characterized by the change in the use of the environment, which becomes more intense even in places where there is a conversion of natural ecosystems to anthropic environments, such as agricultural, industrial and urban environments. In Maranhão, areas with babassu trees were mainly replaced by the implantation of monocultures such as soy, eucalyptus and pastures to support cattle raising. This study aims to classify and map the vegetation with the presence of babassu palm in the different pilot areas based on images from the Sentinel-2 satellite for the year of 2020. To classification, the OBIA (Object-based Image Analysis) methodology was used through the open-source tools of the RSGISLib library, in Python programming language, and the R programming language for validation. The use of bands 4, 8 and 11 of the Sentinel-2 sensor, associated with the NDVI data applied to classify the babassu vegetation, obtained the best results for the areas of Matinha and Imperatriz, these data added to the images of sentinel 1 were the best result for the Santa Inês area, with global precision and Kappa index values, respectively, of 71.12% and 66.57% for the Imperatriz area; 69.66% and 61.93% in Santa Inês; and 57.58% and 48.26% in Matinha. The biggest challenge in the process of classifying babassu on a regional scale appears in the context of Maranhão, because there are areas with the presence of other palm trees. In fact, the classification of babassu palms using sentinel 1 and sentinel 2 sensors linked to NDVI data and tools presented here demonstrate potential in identifying plants and areas with occurrence of this species.

Keywords: Babassu, *Attalea speciosa mart*, Sentinel, OBIA, Palm tree Maranhão.

1. INTRODUÇÃO

Desde o surgimento dos seres humanos, a paisagem é alterada conforme as necessidades da expansão antrópica sobre o espaço. Por isso, a conservação da biodiversidade tem sido um dos maiores desafios atuais, devido ao elevado nível de perturbações antrópicas nos ecossistemas (AMARAL, 2019). A relação entre o homem e a natureza se caracteriza pela alteração do uso do ambiente, que se torna ainda mais intensa em locais onde há conversão de ecossistemas naturais para ambientes antrópicos, como os agrícolas, industriais e urbanos. O monitoramento dessas mudanças se faz essencial, visto que possibilita evitar alterações futuras no espaço que podem ser prejudiciais para os ecossistemas, assim como auxilia na proteção e conservação ambiental (AMARAL, 2019).

No estado do Maranhão encontra-se uma vasta biodiversidade decorrente da presença de um conjunto de biomas (amazônico, cerrado e caatinga) e ecorregiões (Campos de baixada, Mata dos cocais, Chapadão, Planalto), destacando-se as vegetações com presença de babaçu. Segundo relatório do IMESC - Zoneamento Ecológico Econômico do Estado do Maranhão – para o ano de 2020, o Estado do Maranhão antes da década de 80 possuía uma cobertura de babaçu que estava distribuído em uma área estimada de 120.000 km², ou seja, 36% do território maranhense. No início da década de 1980 essa área foi reduzida para 100.000 km², 30% do território, e mais recentemente para 90.000 km², 27% do território.

Nos últimos 50 anos, as áreas com babaçuais foram sendo substituídas principalmente pela implantação de monoculturas como a soja, eucalipto e pastagens. Essa substituição no uso da terra e conseqüentemente na paisagem traz importantes impactos ao meio ambiente e principalmente às comunidades tradicionais que tiram seus sustentos do extrativismo do fruto dessa palmeira (ARAÚJO E NOVAE, 2018; BARTABURU *et al.* 2018; MELLO-THÉRY, 2011).

Com base nisso e visando proteger a palmeira babaçu, se faz necessário a adoção de metodologias que permitam a sua identificação, avaliação da sua distribuição e monitoramento. Nesse caso, podemos destacar o Sensoriamento Remoto como uma importante ferramenta para análise das questões ambientais. Ele permite a obtenção de informações sobre a superfície terrestre através de medições de radiação

eletromagnética, e se mostra um instrumento de grande utilidade para o monitoramento de áreas em larga escala espacial e temporal (MASCARENHAS *et al*, 2009).

Sendo assim, o objetivo deste trabalho foi detectar a presença de palmeira babaçu em diferentes regiões no estado do Maranhão, considerando paisagens dentro de um mosaico de usos e cobertura da terra com vegetações naturais e áreas antrópicas na Amazônia Maranhense.

2. METODOLOGIA

2.1. ÁREA DE ESTUDO

O trabalho foi conduzido em três áreas-piloto com área de 10 km² (recorte de 3 km x 3,34 km) com mosaicos de vegetação (naturais e antrópicas) localizados em três grandes ecorregiões no bioma amazônico do estado do Maranhão (Floresta Amazônica, Campos de baixada e Mata de Cocais) (**figura 1**):

- Área 1: Município de Matinha (Campos de Baixada), 03°05'50"S, 45°02'56"O. A região dos Campos de Baixada, próximo à cidade de Matinha, possui pequeno declive e drenagem natural deficiente, o que provoca grandes inundações nos campos naturais no período de chuva (MARANHÃO, 1991).
- Área 2: Município Santa Inês (Mata dos Cocais), 03°40'01"S, 45°22'48"O. Esta área da Mata dos Cocais, em proximidade da cidade de Santa Inês, é caracterizado por vastas superfícies aplainadas, com topografia plana a levemente ondulada, e subordinadamente, por colinas baixas e suaves, modeladas em vales amplos com baixa a moderada densidade de drenagem (FILHO, 2018).
- Área 3: Município de Imperatriz (Floresta Amazônica), 05°31'32"S, 47°28'37" O. O povoado de , no município de Imperatriz, localiza-se próximo ao Rio Tocantins, num território razoavelmente plano e fértil, de drenagem natural, ao Sudoeste do estado, que se encontra dentro da Amazônia maranhense (FILHO, 2018). A área amostrada se encontra no limite dos biomas Amazônia e Cerrado, sendo influenciada pelos dois biomas em termos de características ambientais e tipos de vegetação.

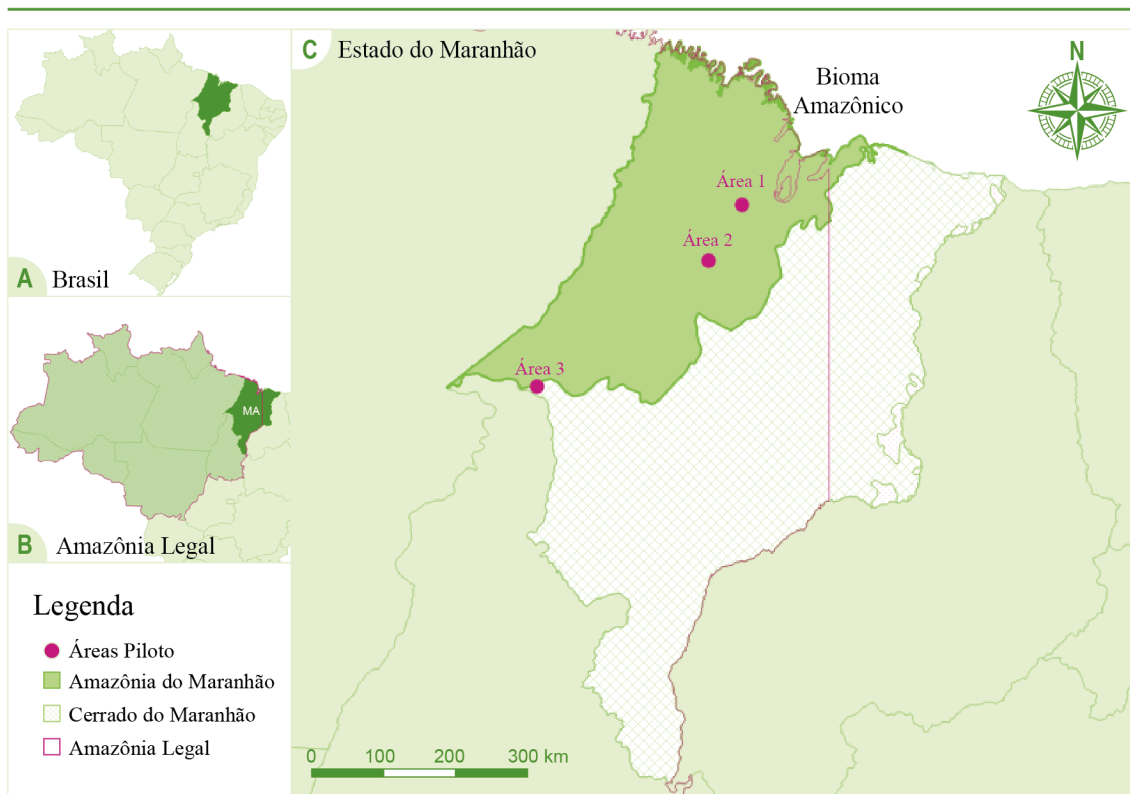


FIGURA 1: A) Mapa do estado do Brasil com divisões estaduais (IBGE, 2020). B) Visualização da Amazônia legal (IBGE, 2020) C) Estado do Maranhão com identificação das 3 áreas piloto.

O estado do Maranhão é caracterizado por um clima tropical úmido, com duas estações bem definidas - Seca e Chuvosa.

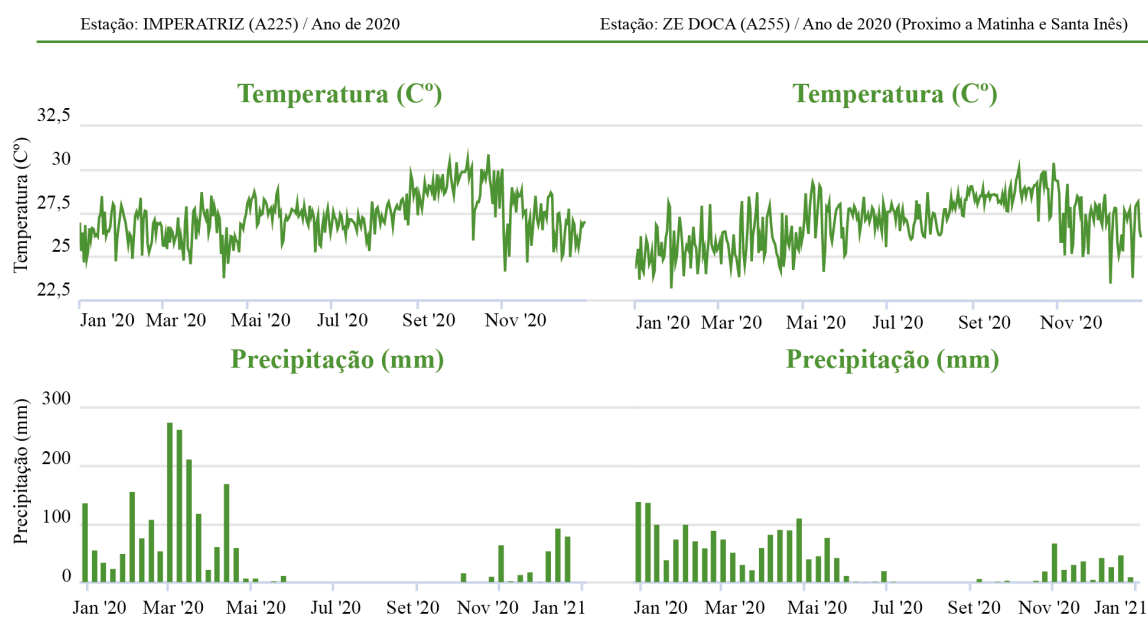


FIGURA 2: Gráficos de temperatura e precipitação mensal nas estações de Imperatriz e Zé Doca (Próximo a Matinha e Santa Inês) para o ano de 2020 (Adaptado de INMET, 2021)

2.2. DETECÇÃO E IDENTIFICAÇÃO DE BABAÇU

Obtenção de produtos derivados do satélite

Para a segmentação e classificação dos babaçuais nas áreas-piloto, foram utilizadas imagens obtidas pelo sensor Sentinel-1 (S1) e Sentinel-2 (S2) do programa Copernicus disponíveis a partir da plataforma Google Earth Engine (GEE). Nas imagens do Sentinel-1 foram utilizadas as bandas com polarização VV + VH, sendo a melhor combinação sobre a terra (COPERNICUS, 2021). Já as imagens do Sentinel-2 que contém 12 bandas espectrais, foram filtradas com uma máscara de nuvens que remove pixels brancos e baixadas em duas combinações de banda:

- Combinação de 10 bandas: todas as disponíveis no catálogo, menos as de aerossóis e vapor d'água (B1 e B9);
- Combinação de 3 bandas: B4 (vermelho), B8 (NIR) e B11 (SWIR1).

A partir das bandas B4 (vermelho) e B8 (NIR) do sentinel-2 foram calculados os índices de vegetação NDVI (equação 1) e SAVI (equação 2).

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (\text{equação 1})$$

$$SAVI = \frac{NIR - RED}{NIR + RED + L} \times (1 + L) \quad (\text{equação 2})$$

No qual: onde NIR é o infravermelho próximo (banda 8) e RED é a banda vermelha (banda 4) (ROUSE *et al.* 1973), e L é uma constante denominada de fator de ajuste do índice SAVI (HUETE, 1988), que foi adotado o valor de 0,5 para vegetação com densidade intermediária (GAMEIRO *et al.*, 2017).

Para seleção das datas de coleta das imagens foram vistos os dados de precipitação das estações meteorológicas do INMET mais próximas das áreas piloto, sendo estas: estação IMPERATRIZ (A225) e ZÉ DOCA (A225). Como pode ser visto na figura (2) a estação seca inicia nos meses de maio ou junho e segue até outubro, dando início a estação chuvosa que segue até maio do ano seguinte. Foram escolhidas uma imagem ao final da estação chuvosa (2/05/2020 para a área 1; 16 a 28/06/2020 para a área 2; e 07/05/2020 para a área 3) e uma ao final da estação seca (05/08/2020 para as 3 áreas). As datas do período chuvoso são diferentes entre as 3 áreas pois não foi possível encontrar imagens sem nuvens para a mesma data em todas as áreas. Além

disso, na área 2 - Santa Inês, foi necessário uma combinação de duas imagens de datas consecutivas para obter uma imagem sem nuvem.

Todas as bandas (dois sensores e dois índices) foram re-amostradas para uma resolução de 10 m pelo método de vizinho mais próximo no Software R (R-PROJECT, 2021) utilizando a biblioteca Raster (HIJMANS *et al*, 2021). Também foi realizado a combinação total das bandas (stack) já mencionadas para dois períodos representativos em cada área, um em período seco (05/08/2020) e uma do período úmido (07/05/2020; 12/05/2020; e 16 e 28/06/2020), a fim de incluir a variação no comportamento espectral de acordo com a variação fenológica da vegetação.

Determinação de polígonos de treino e de validação de cada classe de cobertura

Inicialmente, foram delimitados 270 polígonos, sendo distribuídos 90 para cada área piloto (Matinha, Santa Inês e Imperatriz). Em cada área os 90 polígonos foram distribuídos para as 9 classes (Corpos d'Água; Floresta nativa; Babaçu em alta densidade em mata nativa; Babaçu em baixa densidade em mata nativa; Babaçu em pastagem; Pastagem; Estrada; Solo exposto e Construções) (**figura 3**), resultando em 10 polígonos por classe.

As classes foram definidas por análise visual das 3 áreas pilotos. Os polígonos foram alocados nas áreas representativas de sua classe também por análise visual em imagens do Google Earth e conhecimento de campo. Do total de polígonos demarcados, 70% destes polígonos foram utilizados para o treinamento do algoritmo (classificação), o 30% restante foram usados no processo de validação,

Seleção da melhor combinação de bandas

Para a seleção das bandas foram realizados recortes nas imagens, utilizando como base os polígonos de treino, com separação por classe de cobertura, período (chuvoso e seco) e área (área 1, 2 e 3) na composição com todas as bandas do Sentinel-2, para um melhor entendimento da resposta espectral de cada classe de cobertura em cada banda espectral. Compreender o comportamento espectral das bandas nas distintas classes de cobertura (**figura 3**) nos ajuda a identificar quais delas podem ser utilizadas para distinguir melhor áreas similares, como as de vegetação densa e floresta nativa ou de solo exposto, construção e estrada (**Figura 4**).

Fisionomias

	Vista pelo Google Earth	Vista pelo Sentinel 2 (bandas 11, 8 e 4)	Foto de campo
<p>Corpos d'água: qualquer acumulação significativa de água, usualmente cobrindo a superfície da área.</p>			
<p>Floresta nativa: Alta densidade e diversidade de árvores em dossel fechado</p>			
<p>Babaçu em alta densidade em mata nativa: Alta densidade de árvores, principalmente palmeiras de babaçu, em dossel fechado ou em capoeiras com presença de vegetação arbustiva.</p>			
<p>Babaçu em baixa densidade em mata nativa: Densidade baixa de árvores, principalmente palmeiras de babaçu por área em dossel aberto ou capoeiras com presença de vegetação rasteira e arbustiva.</p>			
<p>Babaçu em pastagem: Área de pastagem dominadas predominantemente com gramíneas mas também com presença de palmeira babaçu espalhadas no espaço .</p>			
<p>Pastagem: Área de pastagem dominadas predominantemente com gramíneas.</p>			
<p>Estrada: via de trânsito por pessoas, animais e/ou veículos podendo ser asfaltada ou não.</p>			
<p>Construções: Ocupação antrópica decorrente de exploração (Casas, estruturas industriais, entre outras construções).</p>			
<p>Solo exposto: áreas sem nenhum tipo de cobertura (vegetal ou de alvenaria) que podem ser resultados de ações antrópicas ou degradação natural.</p>			

FIGURA 3: Fisionomias e descrição das classes de cobertura

Foram calculados os valores médios de reflectância para das principais bandas com distinção entre classes e realizados testes de composição de bandas para análise de interpretação visual (**figura 4**), com o intuito de determinar qual combinação de imagens de falsa cor permitia distinguir melhor cada classe de cobertura. Após a interpretação da resposta espectral, foram propostas três composições: uma composição com todas as bandas (Composição 1), e duas usando as bandas 4 (Red); 8 (NIR); e 11 (SWIR) (composição 2 e 3). O resultado final da combinação de bandas resultou nas seguintes composições :

- **Composição 1:** Sentinel-1 (bandas HH e HV), Sentinel-2 (bandas 2, 3, 4, 5, 6, 7, 8, 8A, 11, 12), NDVI e SAVI para as épocas úmida e seca;
- **Composição 2:** Sentinel-1 (bandas HH e HV), Sentinel-2 (bandas 4, 8, 11) e NDVI para as épocas úmida e seca;
- **Composição 3:** Sentinel-2 (bandas 4, 8, 11), NDVI para as épocas úmida e seca;




FIGURA 4: Respostas médias espectrais das respectivas bandas (2 - Blue; 3 - Green; 4 - Red; 5 - Red Edge 1; 6 - Red Edge 2; 7 - Red Edge 3; 8 - NIR; 8A - Red Edge 4; 11 - SWIR; 12 - SWIR) com os polígonos de validação de cada classe (1 - Água; 2 - Babaçu em alta densidade em mata nativa; 3 - Babaçu em baixa densidade em mata nativa de baixa densidade; 4 - Babaçu em pastagem; 5 - Construções; 6 - Estrada; 7 - Floresta nativa; 8 - Pastagem; 9 - Solo) das 3 áreas analisadas nos períodos úmidos e secos.

Segmentação e classificação de imagens

Na classificação orientada a objeto (OBIA), se define as regras de classificação baseadas em características espectrais e relações espaciais. Características intrínsecas dos objetos e suas inter-relações são levadas em consideração e segmentos gerados agrupando pixel, dentro de sua definição, atributos (tamanho, cor, tipo etc.) e a relação existente entre eles (DARWISH et al., 2003; YOURDON, 1994; BENZ et al., 2004).

O algoritmo utilizado para a segmentação das imagens foi o de Shepherd, implementado na biblioteca RSGISLib (CARVALHO, 2019; CLEWLEY et al., 2014). Para cada área foram testados diferentes combinações dos parâmetros de número de *clusters* (k) em KMeans, número mínimo de tamanho de objetos em pixels (variáveis: *numClusters* e *minObjectSize*). Levando em consideração o tamanho das áreas, o limite de distância para evitar a fusão foi desabilitado (Variável: *distThres*).

Os parâmetros para a segmentação escolhidos de acordo aos melhores resultados foram:

Área de Matinha (área 1): *numClusters* = 12; *minObjectSize* = 10; *distThres* = 100;

Área de Santa Inês (área 2): *numClusters* = 16; *minObjectSize* = 5; *distThres* = 100;

Área de Imperatriz (área 3): *numClusters* = 12; *minObjectSize* = 50; *distThres* = 100.

A classificação, foi realizada usando o algoritmo de *machine learning Random Forest*, da biblioteca *Scikit-learn*, em conjunto com a biblioteca RSGISLib (CARVALHO, 2019; PEDREGOSA et al., 2011). Todos os algoritmos foram executados na linguagem de programação Python.

Validação e matriz de confusão

Para a avaliação da qualidade e acurácia da classificação, foram utilizados os 30% restantes dos polígonos demarcados, usando o pacote *rsacc - Accuracy Assessment for Remote Sensing Classification* na linguagem R (SILVA, 2020; CARVALHO, 2019). Assim calculados a precisão global e o coeficiente Kappa a partir da matriz de confusão, que analisa a acurácia da classificação a partir do cruzamento de amostras de cada classe mapeada com a classe real encontrada em campo, conforme descrito por Ponzoni e Rezende (2002) e Congalton e Green (2009).

3. RESULTADOS

Análise espectral das bandas do sensor Sentinel-2

Ao analisar os gráficos de resposta espectral (**Figura 4**), foi percebido que as classes de Floresta nativa, de Babaçu em vegetação densa, de Construção, de Estrada e Solo tem muita similaridade espectral. Por isso, buscando formas de classificar as áreas com altos níveis de acurácia, agrupamos as classes que tinham alta semelhança espectral gerando 4 variações na classificação:

- Construção + Estrada (CE);
- Construção + Estrada + Solo Exposto (CES);
- Construção + Estrada e Floresta Nativa + Babaçu em floresta nativa densa (CE+FV);
- Construção + Estrada + Solo Exposto e Floresta Nativa + Babaçu em floresta nativa densa (CES+FV).

O foco principal desse processo foi de agrupar as classes que podem causar mais confusão espectral e que poderiam prejudicar os resultados de acurácia e erro do mapeamento.

Segmentação e classificação

Foram segmentadas as três composições com as quatro variações de classificação previamente descritas para cada área e realizado a matriz de confusão (**tabela 1, 2 e 3**) para avaliar os melhores resultados com base nos valores de acurácia, erro e índice de Kappa. Durante o processo de classificação, foi percebido que ao utilizar um conjunto de bandas para a segmentação, mas não utilizar as estatísticas do NDVI poderiam causar menos ruído e gerar resultados de acurácia diferentes, por isso foram adicionadas mais duas colunas de resultados variantes das composições 2 e 3, segmentando com o NDVI mas não utilizando os valores desta banda para a classificação.

Área 1 - Matinha

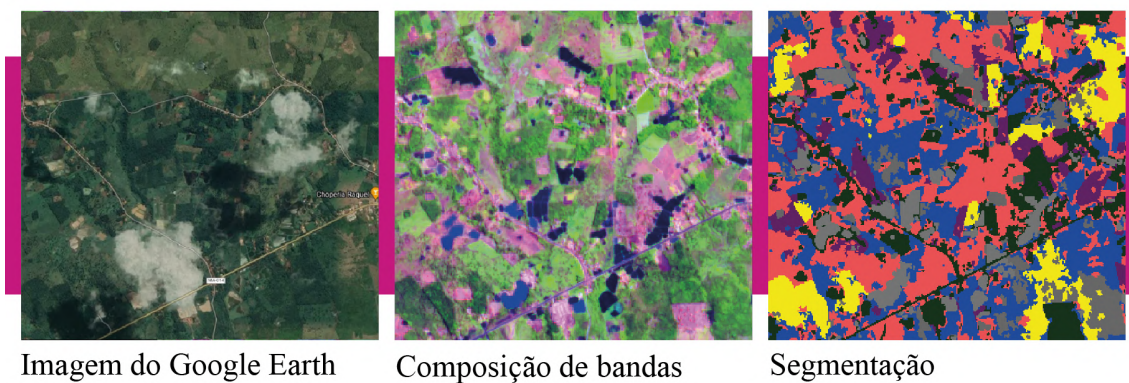


FIGURA 5. Imagens do Google Earth, composição de bandas RGB (bandas 11, 8 e 4) e resultado da segmentação da área 1 - Matinha

Resultados de Acurácia, Erro e Kappa						
Classes		Com. 1	Comp 2	Comp 3	Comp 2.2	Comp 3.2
Junção: Construção e Estrada	<i>Overall Accuracy</i>	56%	50%	55%	53%	53%
	<i>Overall Error</i>	44%	50%	45%	47%	47%
	<i>Kappa</i>	49%	42%	48%	45%	46%
Junção: Construção, Estrada e Solo	<i>Overall Accuracy</i>	57%	54%	57%	55%	57%
	<i>Overall Error</i>	43%	46%	43%	45%	43%
	<i>Kappa</i>	48%	43%	48%	45%	48%
Junção: Construção e Estrada Floresta Nativa e Babaçual Denso	<i>Overall Accuracy</i>	60%	54%	57%	55%	57%
	<i>Overall Error</i>	40%	46%	43%	45%	43%
	<i>Kappa</i>	52%	44%	49%	45%	49%
Junção: Construção, Estrada e Solo Floresta Nativa e Babaçual Denso	<i>Overall Accuracy</i>	61%	58%	61%	58%	61%
	<i>Overall Error</i>	39%	42%	39%	42%	39%
	<i>Kappa</i>	51%	46%	51%	47%	51%

TABELA 1. Resultado das composições e variações de classificação para a área de Matinha - **Composição 1:** Sentinel-1 (HH e HV), Sentinel-2 (todas as bandas), NDVI e SAVI para os períodos úmido e seco; **Composição 2:** Sentinel-1 (HH e HV), Sentinel-2 (B4, B8, B11) e NDVI para os períodos úmido e seco; **Composição 3:** Sentinel-2 (B4, B8, B11), NDVI para os períodos úmido e seco; **Composição 2.2:** Sentinel-1 (HH e HV), Sentinel-2 (B4, B8, B11) e NDVI (sem estatísticas) para os períodos úmido e seco; **Composição 3.2:** Sentinel-2 (B4, B8, B11), NDVI (sem estatísticas) para os períodos úmido e seco;

O melhor resultado na localidade de Matinha (área 1) foram as composições 1, 3 e 3.2 com os mesmos níveis de acurácia, erro e Kappa (61%, 39% e 51% respectivamente), unificando as classes de: Construção, Solo exposto e Estrada; Floresta nativa e de Babaçu em alta densidade em mata nativa. Sem unificar as classes de Floresta nativa e Babaçu em alta densidade em mata nativa obtivemos os resultados de 57% de acurácia, 43% de erro e 48% de índice de Kappa com as composições 1, 3 e 3.2.

Porém foi selecionada a composição 3 - Bandas dos períodos úmido e seco dos sensores Sentinel-2 (B4, B8 e B11) + NDVI. Totalizando 8 bandas - como principal, tendo em vista uma uniformização de metodologias e resultados para a amazônia maranhense.

Área 2 - Santa Inês




FIGURA 6. Imagens do Google Earth, composição de bandas RGB (bandas 11, 8 e 4) e resultado da segmentação da área 2 - Santa Inês.

Resultados de Acurácia, Erro e Kappa						
Classes		Com. 1	Comp 2	Comp 3	Comp 2.2	Comp 3.2
Junção: Construção e Estrada	<i>Overall Accuracy</i>	57%	62%	58%	65%	55%
	<i>Overall Error</i>	43%	38%	42%	35%	45%
	<i>Kappa</i>	50%	55%	50%	59%	47%
Junção: Construção, Estrada e Solo	<i>Overall Accuracy</i>	65%	67%	63%	70%	67%
	<i>Overall Error</i>	35%	33%	37%	30%	33%
	<i>Kappa</i>	56%	59%	54%	62%	59%
Junção: Construção e Estrada Floresta Nativa e Babaçual Denso	<i>Overall Accuracy</i>	59%	68%	62%	62%	57%
	<i>Overall Error</i>	41%	32%	38%	38%	43%
	<i>Kappa</i>	50%	61%	54%	54%	47%
Junção: Construção, Estrada e Solo Floresta Nativa e Babaçual Denso	<i>Overall Accuracy</i>	69%	68%	66%	72%	69%
	<i>Overall Error</i>	31%	32%	34%	28%	31%
	<i>Kappa</i>	60%	59%	56%	63%	61%

TABELA 2. Resultado das composições e variações de classificação para a área de Santa Inês. **Composição 1:** Sentinel-1 (HH e HV), Sentinel-2 (todas as bandas), NDVI e SAVI para os períodos úmido e seco; **Composição 2:** Sentinel-1 (HH e HV), Sentinel-2 (B4, B8, B11) e NDVI para os períodos úmido e seco; **Composição 3:** Sentinel-2 (B4, B8, B11), NDVI para os períodos úmido e seco; **Composição 2.2:** Sentinel-1 (HH e HV), Sentinel-2 (B4, B8, B11) e NDVI (sem estatísticas) para os períodos úmido e seco; **Composição 3.2:** Sentinel-2 (B4, B8, B11), NDVI (sem estatísticas) para os períodos úmido e seco.

O melhor resultado para a localidade de Santa Inês (área 2) foi a composição 2.2 - Bandas dos períodos úmido e seco dos sensores Sentinel-1 (HH +HV), Sentinel-2 (B4,

B8 e B11) e NDVI, Totalizando 12 bandas - sem utilizar as estatísticas do NDVI para a classificação, com os resultados de 72% de acurácia, 28% de erro e 63% de índice de Kappa, quando foram unificadas as classes de: Construção, Solo exposto e Estrada; Floresta nativa e de Babaçu em alta densidade em mata nativa. Sem unificar as classes de Floresta nativa e Babaçu em alta densidade em mata nativa obtivemos os resultados de 70% de acurácia, 30% de erro e 62% de índice de Kappa com a mesma composição.

Área 3 - Imperatriz

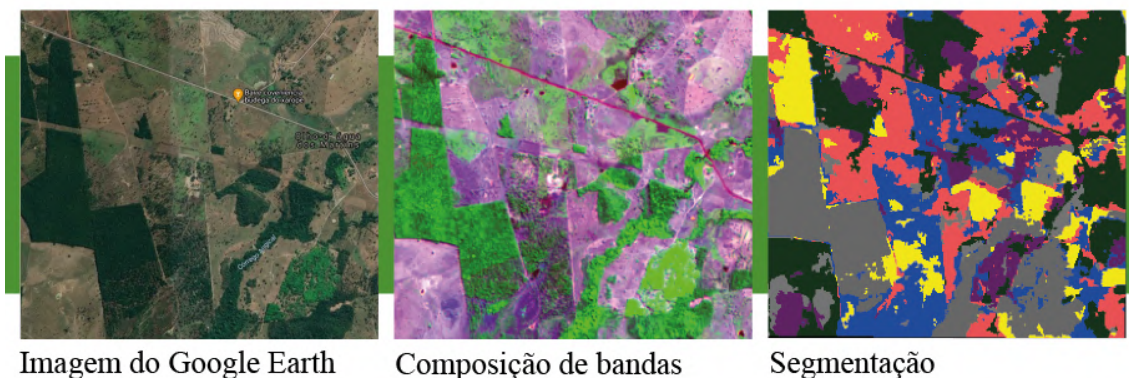


FIGURA 7. Imagens do Google Earth, composição de bandas RGB (bandas 11, 8 e 4) e resultado da segmentação da área de Imperatriz (área 3).

Resultados de Acurácia, Erro e Kappa						
Classes		Com. 1	Comp 2	Comp 3	Comp 2.2	Comp 3.2
Junção: Construção e Estrada	<i>Overall Accuracy</i>	64%	59%	71%	60%	69%
	<i>Overall Error</i>	36%	41%	29%	40%	31%
	<i>Kappa</i>	58%	53%	67%	54%	64%
Junção: Construção, Estrada e Solo	<i>Overall Accuracy</i>	64%	59%	67%	60%	71%
	<i>Overall Error</i>	36%	41%	33%	40%	29%
	<i>Kappa</i>	56%	51%	60%	51%	65%
Junção: Construção e Estrada Floresta Nativa e Babaçual Denso	<i>Overall Accuracy</i>	68%	64%	73%	67%	71%
	<i>Overall Error</i>	32%	36%	27%	33%	29%
	<i>Kappa</i>	61%	57%	68%	61%	65%
Junção: Construção, Estrada e Solo Floresta Nativa e Babaçual Denso	<i>Overall Accuracy</i>	66%	63%	71%	64%	75%
	<i>Overall Error</i>	34%	37%	29%	36%	25%
	<i>Kappa</i>	58%	54%	64%	54%	68%

TABELA 3. Resultado das composições e variações de classificação para a área de Imperatriz. **Composição 1:** Sentinel-1 (HH e HV), Sentinel-2 (todas as bandas), NDVI e SAVI para os períodos úmido e seco; **Composição 2:** Sentinel-1 (HH e HV), Sentinel-2 (B4, B8, B11) e NDVI para os períodos úmido e seco; **Composição 3:** Sentinel-2 (B4, B8, B11), NDVI para os períodos úmido e seco; **Composição 2.2:** Sentinel-1 (HH e HV), Sentinel-2 (B4, B8, B11) e NDVI (sem estatísticas) para os períodos úmido e seco; **Composição 3.2:** Sentinel-2 (B4, B8, B11), NDVI (sem estatísticas) para os períodos úmido e seco.

O melhor resultado para a localidade de Imperatriz (área 3) foi a composição 3.2 - Bandas dos períodos úmido e seco dos sensores Sentinel-2 Bandas: B4, B8 e B11) + NDVI. Totalizando 8 bandas - sem utilizar as estatísticas do NDVI para a classificação e unificando as classes de: Construção, Solo exposto e Estrada; Floresta nativa e de Babaçu em alta densidade em mata nativa, com os resultados de 75% de acurácia, 25% de erro e 68% de índice de Kappa,

Porém, sem unificar as classes de Floresta nativa e Babaçu em alta densidade em mata nativa e apenas unificando as classes de Construção e Estrada, obtivemos os resultados de 70% de acurácia, 30% de erro e 62% de índice de Kappa com a composição 3 - Bandas dos períodos úmido e seco dos sensores Sentinel-2 Bandas: B4, B8 e B11) + NDVI. Totalizando 8 bandas - utilizando as estatísticas do NDVI para a classificação.

Validação da classificação

Por meio da matriz de confusão podemos perceber mais claramente os erros de comissão e omissão (Tipo 1 e 2) em cada área. Em Matinha (área 1) pode ser percebido que as principais classes que se confundem são as de vegetações de Babaçu em baixa densidade em mata nativa com 16 pixels omitidos sendo comissionados na classe de babaçu em pastagem (erros de comissão e omissão em 66% e 74%), além dos 14 pixels da classe de pastagem que também são comissionados a classe de babaçu em pastagem (**Figura 8**). Já em Santa Inês (área 2) esse erro se mantém entre as mesmas classes acima de 50% e 60% em comissão (**Figura 8**). Porém, em Imperatriz (área 3) esses erros diminuem para a maioria das classes, permanecendo elevado apenas entre as classes de Babaçu em alta densidade em mata nativa e floresta nativa (**Figura 8**).

Matriz de confusão

		Área 1 - Matinha								
		AG	BD	BM	BP	CES	FN	PS		
Área 1 - Matinha	AG	18	0	0	9	0	0	0	Resultados de acurácia: Overall Accuracy 0.5758 Overall Error 0.4242 Kappa Index of Agreement 0.4826 Acurácia por classe: Sigla Omissão Comissão AG 0.0000 0.3333 BD 0.6667 0.6786 BM 0.5926 0.3889 BP 0.5185 0.7400 CES 0.2278 0.1286 FN 0.3462 0.3462 PS 0.8519 0.6667	
	BD	0	9	0	0	9	1	9		
	BM	0	4	11	0	3	0	0		
	BP	0	0	16	13	6	1	14		
	CES	0	0	0	2	61	7	0		
	FN	0	9	0	0	0	17	0		
	PS	0	5	0	3	0	0	4		
		Área 2 - Santa Inês								
		AG	BD	BM	BP	CES	FN	PS		
Área 2 - Santa Inês	AG	17	0	0	9	0	0	0	Resultados de acurácia: Overall Accuracy 0.6966 Overall Error 0.3034 Kappa Index of Agreement 0.6193 Acurácia por classe: Sigla Omissão Comissão AG 0.0556 0.3462 BD 0.2593 0.3103 BM 0.5185 0.1875 BP 0.6667 0.5000 CES 0.1807 0.2527 FN 0.2800 0.4857 PS 0.3333 0.0526	
	BD	0	20	0	0	9	0	0		
	BM	0	3	13	0	0	0	0		
	BP	0	0	4	9	5	0	0		
	CES	1	0	6	9	68	7	0		
	FN	0	4	3	0	1	18	9		
	PS	0	0	1	0	0	0	18		
		Área 3 - Imperatriz								
		AG	BD	BM	BP	CE	FN	PS	SL	
Área 3 - Imperatriz	AG	18	0	9	0	0	0	0	0	Resultados de acurácia: Overall Accuracy 0.7112 Overall Error 0.2888 Kappa Index of Agreement 0.6657 Acurácia por classe: Sigla Omissão Comissão AG 0.0000 0.3333 BD 0.3704 0.6383 BM 0.1111 0.2258 BP 0.3333 0.4000 CE 0.1731 0.1731 FN 0.6667 0.0000 PS 0.3333 0.0000 SL 0.3333 0.0000
	BD	0	18	3	0	9	9	9	0	
	BM	0	7	24	0	0	0	0	0	
	BP	0	3	0	18	0	0	0	9	
	CE	0	0	0	0	43	9	0	0	
	FN	0	0	0	0	0	9	0	0	
	PS	0	0	0	0	0	0	18	0	
	SL	0	0	0	0	0	0	0	18	

FIGURA 8. Matrizes de confusão resultantes dos processos de validação da classificação das áreas. (Classes: AG - Agua; BD - Babaçu em alta densidade em mata nativa; BM - Babaçu em baixa densidade em mata nativa; BP - Babaçu em pastagem; CES - Construções + Estradas + Solo; CE - Construções + Estradas; FN - Floresta nativa; PS - Pastagem; SL - Solo).

Identificação das classes de babaçu

Área 1 - Matinha

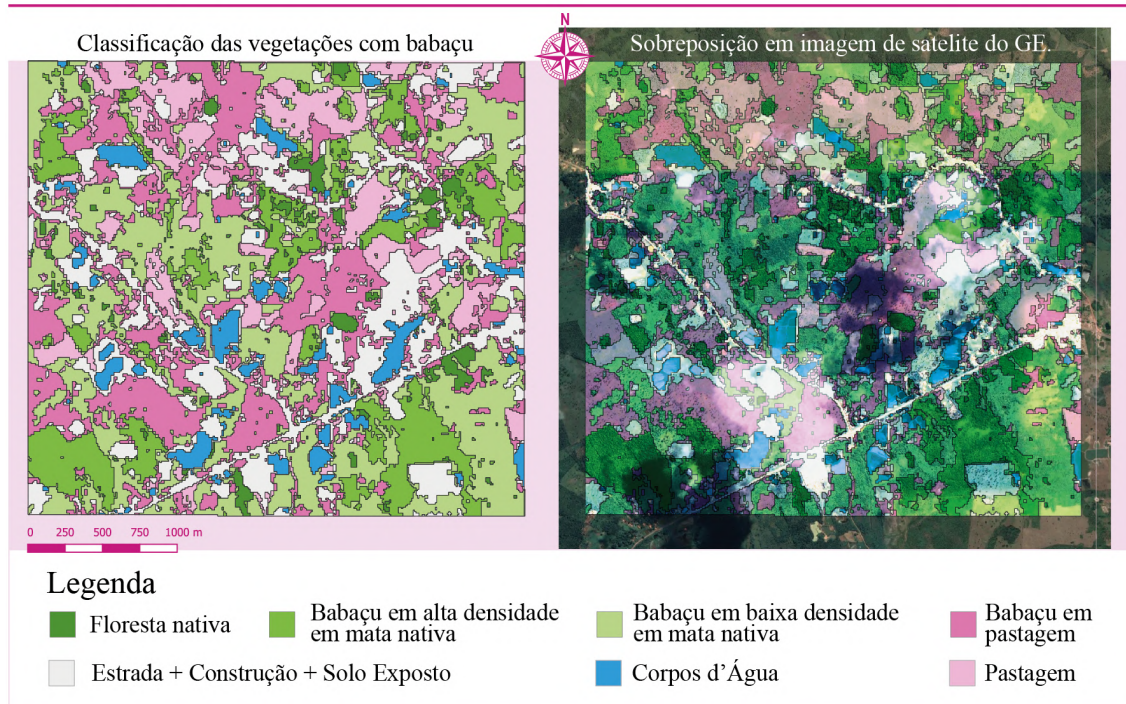


FIGURA 9. Classificação da área 1 (unindo as classes de estrada, construção e solo) no município de Matinha em visualização sobreposta com imagem do Google Earth.

O primeiro produto (**figura 9**) é o da classificação das fisionomias vegetais que contêm babaçu, recortado a partir dos limites da área de Matinha que demonstra o mosaico de vegetação que ocorre na ecorregião da baixada maranhense. Na parte sul da área, observamos a maior concentração da fisionomia Babaçu em baixa densidade em mata nativa. Enquanto na área central encontramos principalmente a fisionomia Babaçu em pastagem, coincidindo com as alocações de construções, no caso as casas centrais das fazendas.

Com destaque temos as principais classes com babaçu: Babaçu em baixa densidade em mata nativa (27,88%, 2,841 km²); e Babaçu em pastagem (20,85%, 2,125 km²); Babaçu em alta densidade em mata nativa (12,15%, 1,238 km²); Floresta nativa (3,21%, 0,327 km²) (**Figura 9**). Em seguida temos as classes: Corpos d'Água (4,94%, 0,504 km²); Pastagem (12,17%, 1,241 km²); e Estrada + Solo exposto + Construções (18,49%, 1,885 km²).

Área 2 - Santa Inês

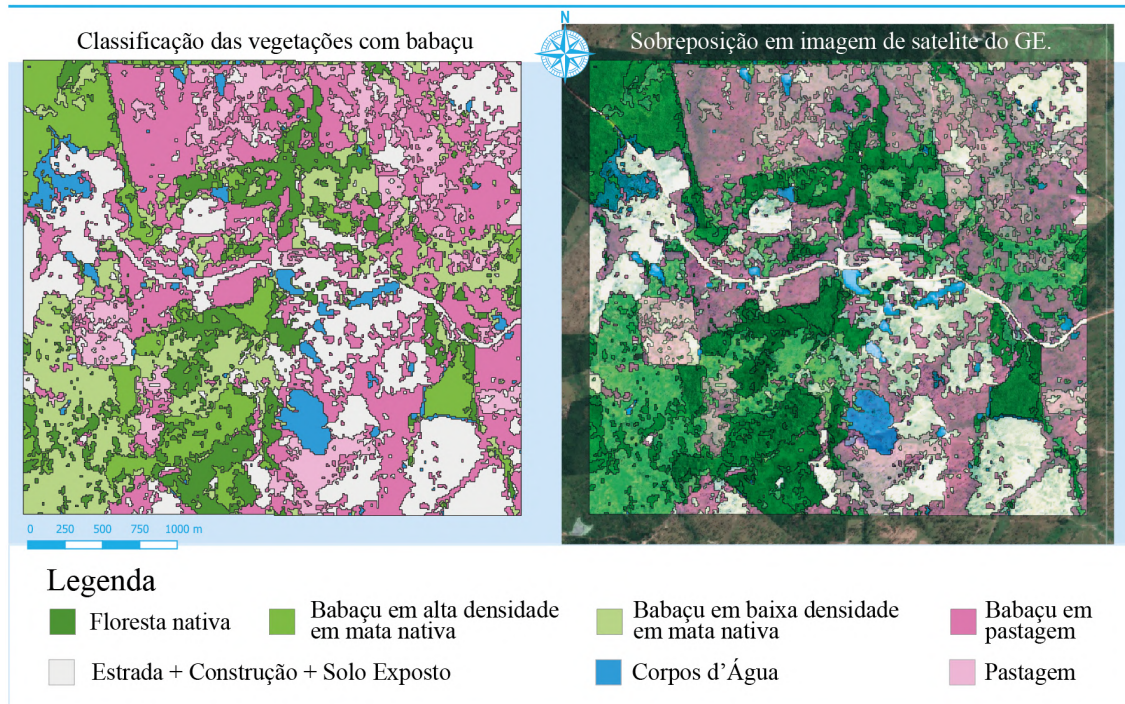


FIGURA 10. Classificação da área 2 (unido as classes de estrada, construção e solo) no município de Santa Inês em visualização sobreposta com imagem do Google Earth.

O segundo produto (**figura 10**) é o da classificação das fisionomias vegetais que contêm babaçu, recortado a partir dos limites da área de Santa Inês que demonstra o mosaico de vegetação que ocorre na ecorregião próxima a Mata dos Cocais. Na parte leste e inferior da área, observamos a maior concentração das fisionomias de Babaçu em baixa densidade em mata nativa e Babaçu em alta densidade em mata nativa. Enquanto na área central e oeste encontramos principalmente a fisionomia Babaçu em pastagem.

Com destaque temos as principais classes com babaçu: Babaçu em pastagem (29,04%, 2,958 km²); Babaçu em baixa densidade em mata nativa (15,67%, 1,597 km²); Floresta nativa (11,20%, 1,141 km²); e Babaçu em alta densidade em mata nativa (9,71%, 0,989 km²) (**Figura 10**). Em seguida temos as classes: Corpos d'Água (3,49%, 0,355 km²); Pastagem (9,59%, 0,977 km²); Estrada + Construções e Solo exposto (20,96%, 2,136 km²).

Área 3 - Imperatriz

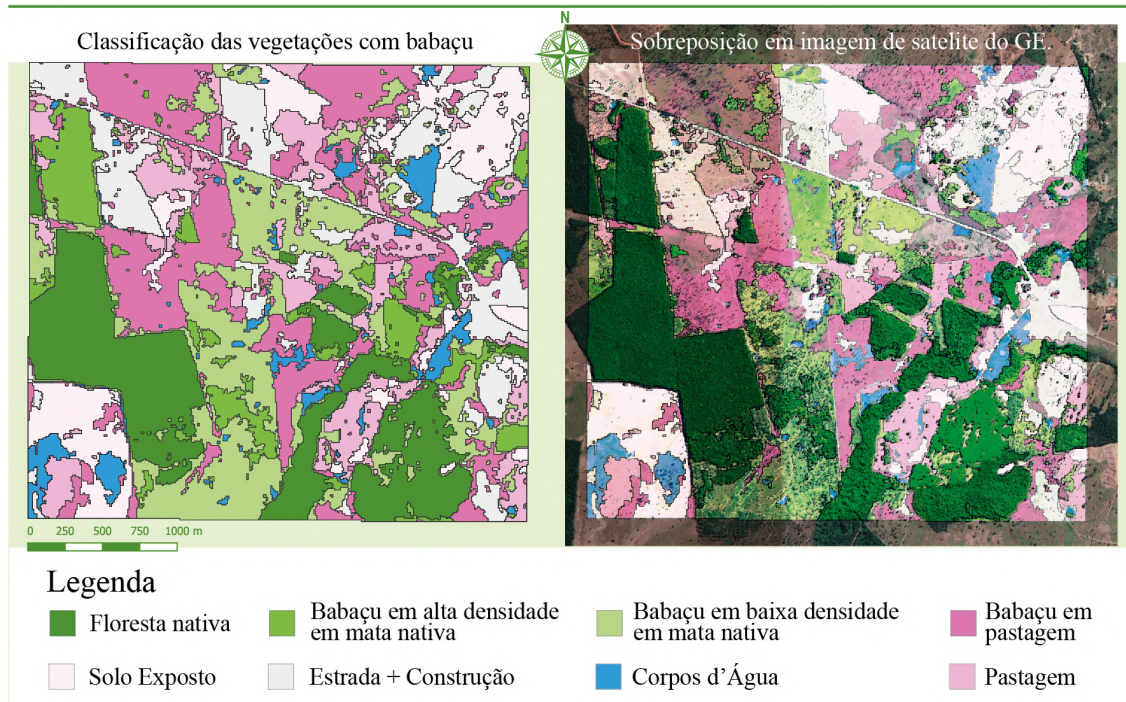


FIGURA 11. Classificação da área 3 (unindo as classes de estrada, construção) no município de Imperatriz em visualização sobreposta com imagem do Google Earth.

O terceiro produto (**figura 11**) é o da classificação das fisionomias vegetais que contêm babaçu, recortado a partir dos limites da área de Imperatriz que demonstra o mosaico de vegetação que ocorre na ecorregião pré-amazônica. Na parte sul da área, observamos a maior concentração da fisionomia Babaçu em alta densidade em mata nativa e Babaçu em baixa densidade em mata nativa. Enquanto na área central e norte encontramos em sua maioria a fisionomia de Babaçu em pastagem.

Com destaque temos as principais classes com babaçu: Babaçu em pastagem (19,69%, 2,024 km²); Floresta nativa (17,51%, 1,800 km²); Babaçu em baixa densidade em mata nativa (17,48%, 1,797km²); e Babaçu em alta densidade em mata nativa (7,23%, 0,744 km²) (**Figura 11**). Em seguida temos as classes: Corpos d'Água 3,94%, 0,405 km²); Pastagem (19,69%, 2,024 km²); Estrada + Construções (12,79%, 1,315 km²); e Solo exposto (9,28%, 0,954 km²).

4. DISCUSSÃO

Alguns estudos de classificação do babaçu indicam dificuldades em mensurar classes de florestas densas, abertas e áreas antropizadas, muitas vezes devido à resolução espacial das imagens trabalhadas e métodos de classificação utilizados. Outros trabalhos já apresentam formas alternativas para identificar áreas de possível presença do babaçu, como o trabalho de Silva *et al.*, (2009), que buscaram identificar a distribuição da palmeira babaçu por meio de modelos de distribuição potencial das espécies (MDE), em regiões com características de solo específicas que a palmeira poderia se estabelecer.

A principal dificuldade para quem busca identificar palmeiras de babaçu é apresentar metodologias com um processo de validação claro e bons níveis de acurácia e erro. Nossos resultados encontraram moderada precisão para a área de Matinha (área 1), e um alto nível de precisão para as áreas de Santa Inês (área 2) e Imperatriz (área 3), sendo estas: área 1 com 57,58% de acurácia para 7 classes (unindo as classes de estrada, construção e solo exposto); área 2 com 69,66% de acurácia para 7 classes (unido as classes de estrada, construção e solo exposto); e área 3 com 71,12% de acurácia para 8 classes (unindo somente as classes de estrada e construção), utilizando imagens com 10 metros de resolução espacial. Na pesquisa de Vieira *et al.*, (2017) foi possível realizar o mapeamento usando imagens do satélite RapidEye e com uma composição de bandas 5, 4 e 3 (RGB) melhorada através da correção de contraste para realçar a vegetação, mas não deixa claro o método de validação, sem apresentar os resultados de acurácia para o modelo utilizado. Os autores explicam que em visita às áreas mapeadas, fica evidente a veracidade do mapeamento, mas a informação pode não ser suficiente para ser replicada em outras áreas.

Embora os resultados de classificações que juntam as classes de Babaçu em alta densidade em mata nativa e Floresta nativa tiveram maiores valores de acurácias, esses resultados foram desconsiderados como o nosso melhor resultado porque, primeiramente, mesmo sendo superiores que os resultados citados acima, a diferença dos valores Kappa comparado com o segundo melhor resultado (só juntando as classes de estrada e construção ou as classes de estradas, construção e solo exposto) que não juntar essas classes não resulta numa melhora muito elevada com base na classificação

de Landis e Koch (1977). Além disso, no presente estudo, consideramos que a distinção entre essas classes é mais importante devido às diferenças estruturais das duas fisionomias e da importância do babaçu em ambientes diferentes, mesmo que incluir as duas classes separadamente resulta num aumento em nível de erro, do que juntá-las para aumentar o nível de acurácia. Porém, vale citar o potencial para o mapeamento do babaçu em áreas de pastagem e babaçu em baixa densidade em mata nativa, que na área de Imperatriz apresentaram resultados de 75% de acurácia com um índice de Kappa de 65,45% para a composição 2.2.

		AG	BM	BP	CES	FND	PS
Área 3 - Imperatriz	AG	18	0	9	0	0	0
	BM	0	24	0	9	7	0
	BP	0	0	18	0	3	0
	CES	0	0	0	61	9	0
	FND	0	3	0	9	35	9
	PS	0	0	0	0	0	18

Resultados de acurácia:		
Overall Accuracy		0.7500
Overall Error		0.2500
Kappa Index of Agreement		0.6845
Acurácia por classe:		
Sigla	Omissão	Comissão
AG	0.0000	0.3333
BM	0.1111	0.4000
BP	0.3333	0.1429
CES	0.2278	0.1286
FND	0.3519	0.3750
PS	0.3333	0.0000

FIGURA 12. Matriz de confusão resultante da composição 2.3 para a área de Imperatriz. (Classes: AG - Agua; BM - Babaçu em baixa densidade em mata nativa; BP - Babaçu em pastagem; CES - Construções + Estradas + Solo; FND - Floresta nativa + Babaçu em alta densidade em mata nativa; PS - Pastagem).

Essas fisionomias são as principais a serem trabalhadas na problemática das quebradeiras de coco, já que são as mais afetadas pela antropização sendo transformadas em pastagem limpa ou área para monocultivos. O acompanhamento dessas áreas é de extrema importância tendo em vista que são os ambientes principais para a exploração deste recurso por parte dessas comunidades tradicionais. A identificação dessas áreas com um nível de precisão maior pode ser utilizada para mapear as áreas de conflito entre quebradeiras de coco e os donos das propriedades, assim como evidências de mudanças nos usos e coberturas do solo por transformações e aumentos de áreas usadas exclusivamente para pastagem ou monocultivos.

A partir das análises das matrizes de confusão (**figura 8**), observou-se a boa identificação da classe Babaçu em baixa densidade em mata nativa na área de

Imperatriz (com o erro de omissão em 0,1111 e comissão em 0,2258), destacando assim o uso da composição três com dados de NDVI. Nesta pesquisa foi percebido que ao utilizar os dados de NDVI para segmentação mas não utilizar suas estatísticas para a classificação, poderiam aumentar o índice de Kappa e o nível de acurácia como foi nos melhores resultados das áreas de Santa Inês e Matinha e neste mapeamento para a área de Imperatriz que resultou em 75% de acurácia e 65,45% de índice de Kappa (**figura 8**), o que demonstra novas possibilidades para adaptação deste método para outras áreas.

Os valores de precisão global e índice Kappa foram considerados muito bons de acordo com tabela proposta por Landis e Koch (1977), levando em consideração o número de classes e a resolução espacial das imagens utilizadas. Devido a heterogeneidade das copas das árvores em ambiente de florestas, a classificação a partir de imagens apresentou dificuldades, o que é comum em classificações deste tipo (VIEIRA *et al.* 2017). Fica claro que com o uso do método de classificação OBIA e das ferramentas e softwares acessíveis utilizados no presente estudo, os resultados para o desenvolvimento desse tipo de trabalho mostraram-se promissores.

As implicações desta pesquisa direcionam a um mapeamento do babaçu em áreas maiores como o bioma Amazônico maranhense e possivelmente em todo o estado. Além da metodologia aplicada utilizando os índices de NDVIs e SAVIs, outros dados auxiliares para a classificação como: NDWI e outros índices foram utilizados em estudos em regiões babaçuais realizados por Castro e Silva (2020), demonstrando outras possibilidades futuras para agregar informações adicionais para melhorar os resultados das classificações aqui presentes. Outras camadas que também podem ser utilizadas para uma escala de mapeamento maior, seriam informações de geologia, método utilizado na pesquisa de Silva *et al.*, (2009) e imagens de elevação como SRTM (Shuttle Radar Topography Mission), além da possibilidade de uma máscara de recorte que retire áreas urbanas como estradas e construções, que com base nos nossos resultados a um nível regional, demonstraram o potencial de melhora nos índices de Kappa e acurácia para o mapeamento de babaçuais.

5. CONSIDERAÇÕES FINAIS

O uso da imagem multiespectral do sensor Sentinel 1 e Sentinel 2 associada a dados de NDVI aplicados para a classificação da vegetação do babaçu obteve bons resultados, sendo possível o mapeamento das classes propostas com acurácias entre 71 e 57% de acurácia. Assim como o uso das ferramentas de código aberto, RSGISLib, Python, R e QGIS que permitiu o desenvolvimento da metodologia OBIA com elevado desempenho com valores muito bons de precisão global e índice Kappa para as áreas de estudo.

Os resultados da classificação podem ser melhorados agregando mais dados no processo de classificação, diminuindo a ocorrência de conflitos entre classes que possuem respostas espectrais parecidas e avaliando se esses dados não trazem mais ruído à segmentação. A maior dificuldade do processo de classificação, a uma escala regional, aparece no contexto maranhense pelo fato de ter área com presença de outras palmeiras (Açaí, Buriti, Tucum e outras), o que pode representar um desafio. A falta de conhecimento sobre a palmeira e as comunidades que os circundam são os principais fatores que impossibilitam sua proteção. Esse estudo colabora para o acervo de conhecimento que possa gerar um mapeamento preciso a respeito da população do babaçu, viabilizando meios para criação de políticas públicas que venham a proteger essa palmeira, servindo como base também para a identificação de outras áreas e espécies de interesse.

CAPÍTULO 2

ESTIMAÇÃO DA DENSIDADE DA PALMEIRA BABAÇU EM DIFERENTES ECORREGIÕES DA AMAZÔNIA MARANHENSE

RESUMO

A contagem de árvores é tradicionalmente feita por pesquisas de campo que normalmente demandam bastante tempo, são onerosas e altamente suscetíveis a erros. Contudo, os avanços dos últimos anos na qualidade de imagens de satélite de custo acessível tem aberto caminho para várias pesquisas de sensoriamento remoto com propósitos de identificar e mapear espécies específicas. Dada a disponibilidade de imagens de sensoriamento remoto e as possibilidades de estudos, pesquisadores têm se concentrado no desenvolvimento de técnicas que possam vir a substituir o inventário manual in loco. Nesta pesquisa, utilizamos uma metodologia para a contagem visual de palmeiras de babaçu a partir de imagens de satélite de alta resolução do Google Earth Pro, e fizemos o comparativo com dados coletados em campo em parcelas de 50 x 50m, aplicando regressões lineares para comparar o método de contagem visual de palmeiras para novas áreas com a detecção realizada a partir das imagens. Assim pôde-se estimar a quantidade populacional de palmeiras babaçu em três fisionomias diferentes (Babaçu em pastagem, Babaçu em alta densidade em mata nativa e Babaçu em baixa densidade em mata nativa) e em três diferentes ecorregiões do Maranhão. Com base nos dados coletados em campo e com a análise visual de imagens de alta resolução do Google Earth, foi possível validar o método de contagem que demonstrou uma correlação muito alta. Isso permitiu identificar as seguintes densidades médias: 3.403 palmeiras por km² na área de Matinha, 2.406 palmeiras por km² na área de Santa Inês e 1.692 palmeiras por km² na área de Imperatriz; e estimar o total de 34.027 mil palmeiras na área piloto de Matinha, 24.060 mil palmeiras na área piloto de Santa Inês e 16.918 mil palmeiras na área piloto de imperatriz, totalizando aproximadamente 75 mil palmeiras babaçu nas 3 áreas. O uso do software Google Earth Pro mostrou ser uma ferramenta prática e com boa precisão para validação e como medida alternativa para contagem de indivíduos.

Palavras-chave: *Attalea speciosa mart*, Google Earth Pro, contagem, palmeiras, Maranhão.

ABSTRACT

Tree counting is traditionally done by field research that are usually time-consuming, costly and highly susceptible to errors. However, advances in the quality of affordable satellite imagery in recent years have paved the way to various remote sensing surveys to identify and mapping specific species. Given the availability of remote sensing images and the possibilities for studies, researchers have focused on the development of techniques that could replace the manual inventory in loco. In this research, we used a methodology for visually counting babassu palm trees from high-resolution satellite images from Google Earth Pro, and we compared it with data collected in the field in 50 x 50m plots, applying linear regressions to compare the method of visual counting of palm trees for new areas with the detection performed from the images. Thus, it was possible to estimate the population amount of babaçu palms in three different physiognomies (Babassu in pasture, Babassu in high density in native forest and Babassu in low density in native forest) and in three different ecoregions of Maranhão. Based on the data collected in the field and with the visual analysis of high-resolution images from Google Earth, it was possible to validate the counting method, which showed a very high correlation. This allowed the identification of the following average densities: 3,403 palm trees per km² in the Matinha area, 2,406 palm trees per km² in the Santa Inês area and 1,692 palm trees per km² in the Imperatriz area; and estimate a total of 34,027 thousand palm trees in the Matinha pilot area, 24,060 thousand palm trees in the Santa Inês pilot area and 16,918 thousand palm trees in the Empress pilot area, totalling approximately 75 thousand babassu palms in the 3 areas. The use of Google Earth Pro software proved to be a practical tool with good accuracy for validation and as an alternative measure for counting individuals.

Palavras-chave: *Attalea speciosa mart*, Google Earth Pro, Counting, Palm trees, Maranhão.

1. INTRODUÇÃO

A contagem de plantas é importante para o gerenciamento de florestas principalmente por fornecer informações precisas para o planejamento de produtividade, de inventários, para mensurar a quantidade de biomassa e de estoque de carbono (DALIAKOPOULOS *et al.* 2009). O inventário de árvores é tradicionalmente feito através de pesquisas de campo, que são demoradas e têm alto custo. Contudo os avanços dos últimos anos na qualidade de imagens de satélite de alta resolução espacial de acesso gratuito ou de custo acessível tem aberto caminho para várias pesquisas de sensoriamento remoto com o propósito de identificar e mapear espécies específicas (SILVA *et al.* 2019).

As palmeiras são plantas pertencentes da família *Arecaceae* e apresentam sua distribuição quase exclusiva nas regiões tropicais e subtropicais. Devido à importância socioeconômica da palmeira babaçu, em especial para os estados do Maranhão, Piauí e Tocantins, tem-se uma necessidade de proteção dessa palmeira, tendo em vista que muitas famílias de comunidades tradicionais dependem da exploração extrativista dos seus produtos (CARRAZZA *et al.*, 2012).

Mas, para poder proteger, é necessário ter um conhecimento sobre sua população, com ênfase na sua distribuição e densidades de indivíduos. Como a palmeira do babaçu apresenta uma arquitetura de copa e forma bastantes características, facilita sua identificação em campo e contribui para sua utilização a partir de dados de sensoriamento remoto (ARASATO *et al.*, 2011). Dada a disponibilidade de imagens de sensoriamento remoto e as possibilidades de estudos, diferentes pesquisadores têm se concentrado no desenvolvimento de técnicas que possam vir a substituir o inventário à campo. (SILVA *et al.* 2019).

O presente trabalho teve por objetivo determinar a densidade de palmeiras em diferentes fisionomias a partir de uma detecção e delimitação visual em imagem de satélite de alta resolução no Google Earth Pro e validação com dados de campo, para assim então estimar a população de babaçuais em áreas identificadas por mapeamento segundo os diferentes ambientes.

2. METODOLOGIA

Área de estudo

Foram escolhidas três áreas piloto localizadas em três ecorregiões da amazônia maranhense: Campos de Baixada (área de Matinha; 03°05'50"S, 45°02'56"O), Bioma Amazônico (área de Imperatriz) 05°31'32"S, 47°28'37" O e Mata dos Cocais (área de Santa Inês) 03°40'01"S, 45°22'48"O (**Figura 1**). Em cada região foi delimitada uma área piloto de 3,33 km x 3,00 km (10 km²). Um mapeamento preliminar de cobertura e uso do solo feito nessas áreas piloto (LEÃO *et al.* in prep.) apontou a presença de Babaçu em pastagem; Babaçu em alta densidade em mata nativa; Babaçu em baixa densidade em mata nativa. No presente trabalho, foram delimitadas 90 parcelas de tamanho de 50m por 50m (2500 m²) dentro das três áreas piloto, sendo 30 parcelas por área. Estas 30 parcelas por área foram distribuídas entre as três classes que contém babaçu, resultando em 10 parcelas por classe (Figura 1).

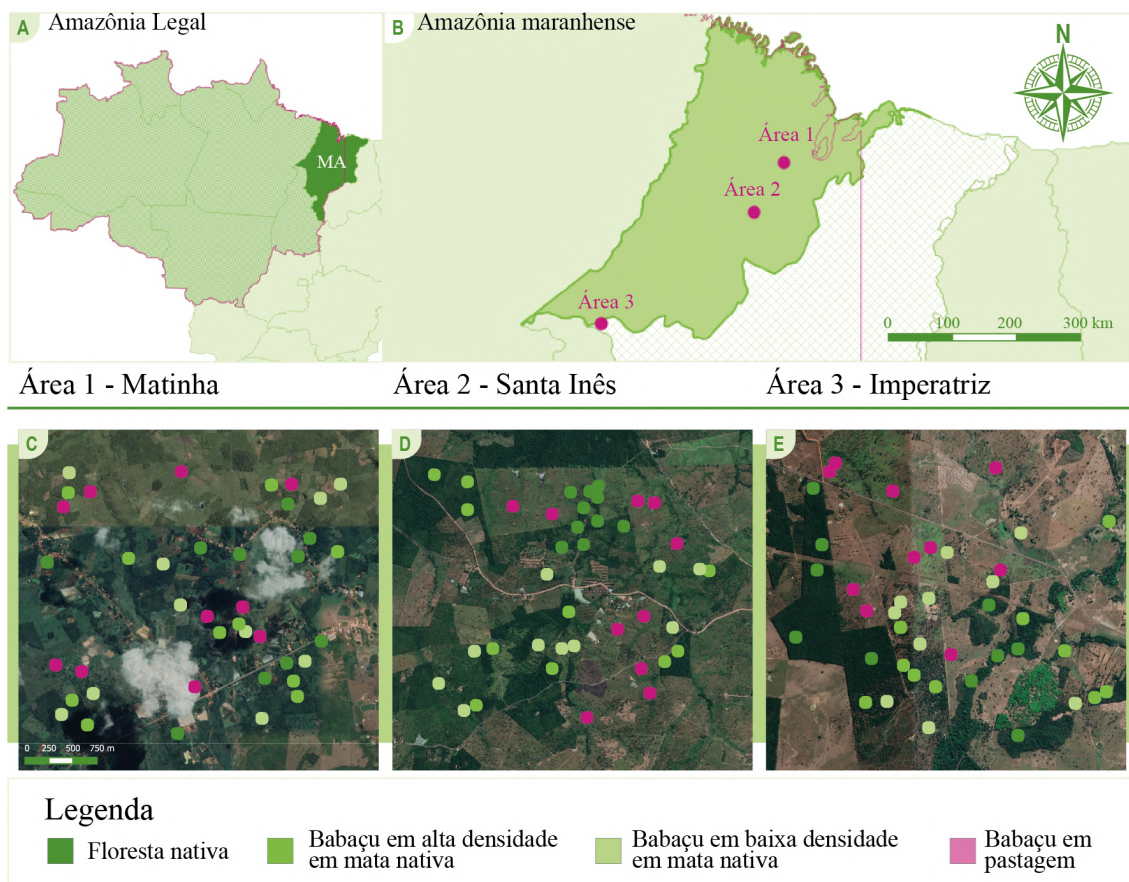


FIGURA 01: A) Mapa da Amazônia legal (IBGE, 2020). B) Mapa da Amazônia maranhense com identificação das 3 áreas piloto. C) Área 1 com marcações de parcelas. D) Área 2 com marcações de parcelas. E) Área 3 com marcações de parcelas.

Também foram identificados indivíduos de babaçu em campo nas áreas de Floresta Nativa, porém, devido a densidade de árvores de diferentes espécies não foi possível utilizar essas parcelas para a contagem visual a partir das imagens de satélite (**Figura 2**).



FIGURA 02: A) Visualização por imagem de satélite da classe de Floresta Nativa na área de Imperatriz. B) Visão interna da parcela (Autoria própria).

Base de dados de imagens

Foram escolhidos três produtos derivados de sensores remotos para a detecção visual e contagem manual das palmeiras: Imagens do satélite Sentinel 2, Planet e Google Earth Pro. As imagens do Sentinel 2 tem uma frequência de revisita global de cinco dias, onde faz a amostragem de 13 bandas espectrais: visível e NIR a 10 metros, borda vermelha e SWIR a 20 metros e bandas atmosféricas a 60 metros de resolução espacial (GEE, 2020b). As imagens Planet são obtidas pela constelação de satélites Dove que possuem o mesmo tipo de sensor, e são adquiridas por mais de 180 satélites diariamente, com quatro bandas espectrais (Red, Blue, Green e NIR) e resolução radiométrica de 12 bits, são ortorretificadas e possuem três metros de resolução espacial (PLANET, 2021). O Google Earth Pro é um software livre de geotecnologia que permite obter imagens do satélite Pléiades da Airbus, que fornecem dados com resolução de cerca de 0,5 m, informando como entrada as coordenadas de latitude, de longitude e um parâmetro de zoom em datas definidas.




FIGURA 03 : A) Imagens do satélite sentinel 2 com resolução de 10m/pixel. B) Imagens do satélite Planet com resolução de 3m/pixel. C) Imagens do Google Earth com resolução de 0,5m/pixel.

Embora o estudo preliminar tenha possibilitado o mapeamento das diferentes fisionomias e coberturas nas áreas estudadas (LEÃO *et al.* in prep), não foi possível realizar a contagem de palmeiras utilizando as imagens do satélite do Sentinel-2, devido a resolução do pixel de 10 m que não permitiu distinguir as copas das palmeiras de maneira individual. A análise de imagens do segundo produto testado, o produto Planet Monitoring, embora apresentasse uma melhor resolução espacial (de 3 a 5 m), também não foi possível distinguir as palmeiras. Finalmente a detecção visual e contagem manual dos indivíduos de babaçus nas parcelas delimitadas foi conduzido utilizando as imagens do Google Earth Pro. Como critério de seleção para se ter o melhor comparativo entre as imagens e os pontos das palmeiras coletadas (missão de campo em maio de 2021), utilizamos as imagens mais recentes do Google Earth Pro, obtidas em outubro de 2020. A partir dessas imagens foram detectadas, visualmente, e marcadas manualmente no próprio Google Earth Pro cada uma das palmeiras de babaçu, por parcela. Os dados das contagens foram tabulados no software Excel para posterior análise.

Dados de Campo

As coletas em campos foram realizadas com ajuda de um GPS (Trimble Juno SA) (**figura 4**). Das 30 parcelas (50m x 50m) selecionadas para a área piloto de Imperatriz, foram inventariadas, à campo, as palmeiras presentes em 12 parcelas nas três fisionomias com babaçu (4 parcelas por fisionomia). Devido a problemas logísticos relacionados a pandemia de covid-19 nos anos de 2020 e 2021 não foi possível realizar

as coletas para as outras duas áreas piloto (Matinha e Santa Inês). A contagem de indivíduos considerou apenas plantas de babaçu com a copa desenvolvida, tendo em vista que pela imagem de satélite não é possível identificar as palmeiras mais jovens principalmente em áreas mais adensadas e com o dossel fechado. Foi considerada a razão entre o número de árvores constatadas na parcela pelo tamanho da parcela.



FIGURA 04: Coleta de dados em campo com a utilização do GPS (Autoria própria).

Densidade da população e análise estatística

Primeiramente, utilizou-se a análise de regressão para verificar a relação entre indivíduos observados em campo e indivíduos detectados por análise visual das imagens de satélite. Também foi determinada a equação da linha de tendência para assim estimar a densidade de palmeiras em campo e também na área total para cada classe. Foi feito um gráfico de dispersão para cada uma das classes, e calculado o coeficiente de Pearson para compreender qual o grau de relação entre as variáveis. Outras medidas de estatísticas descritivas foram calculadas, como a média do número de indivíduos por tipo de vegetação e por área, também calculou-se desvio padrão.

Finalmente, após validação do método de contagem a partir de imagens de alta resolução do Google Earth Pro, foram consideradas as 90 parcelas para a estimação da população sendo estas: 10 parcelas dentro de três classes (Babaçu em pastagem, Babaçu em baixa densidade em mata nativa e Babaçu em alta densidade em mata nativa) em 3 áreas piloto (Matinha, Santa Inês e Imperatriz) (**figura 5**). A análise de variância ANOVA foi utilizada para comparar se as médias por classe em cada área piloto são

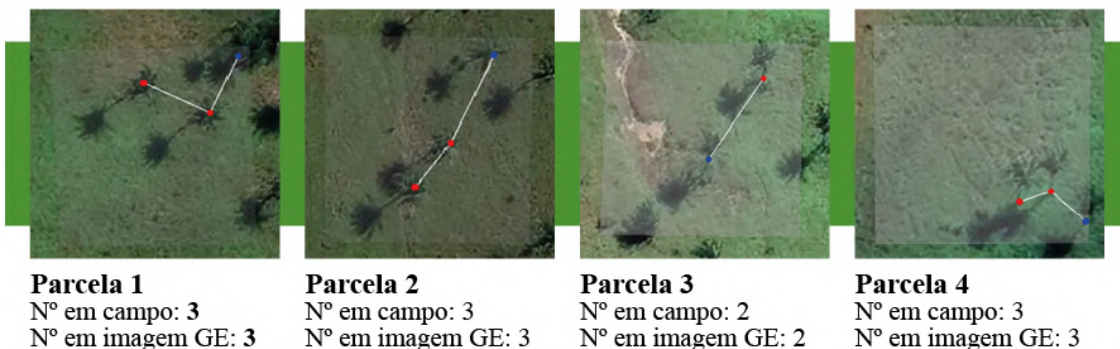
iguais ou diferentes a um nível de significância 0,05 (**Tabelas 1 A, B e C**). Para estimar a população total para cada classe foi calculado a contagem de indivíduos por parcela (2500m²) ou densidade amostral (d), e a partir desse número foi estimado o total de indivíduos por classe a partir do mapeamento.

$$d = \frac{\text{média de indivíduos por classe}}{\text{área da parcela(m}^2\text{)}}$$

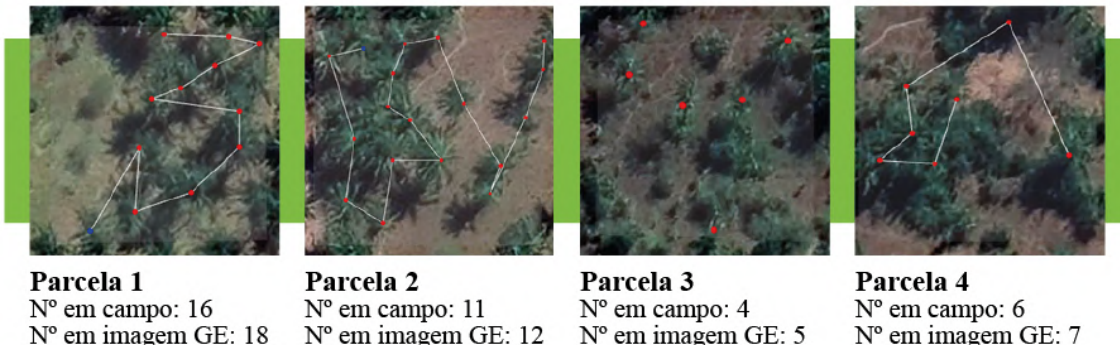
3. RESULTADOS

Validação do modelo de contagem por imagem de alta resolução

Babaçu em pastagem:



Babaçu em baixa densidade em mata nativa:



Babaçu em alta densidade em mata nativa.

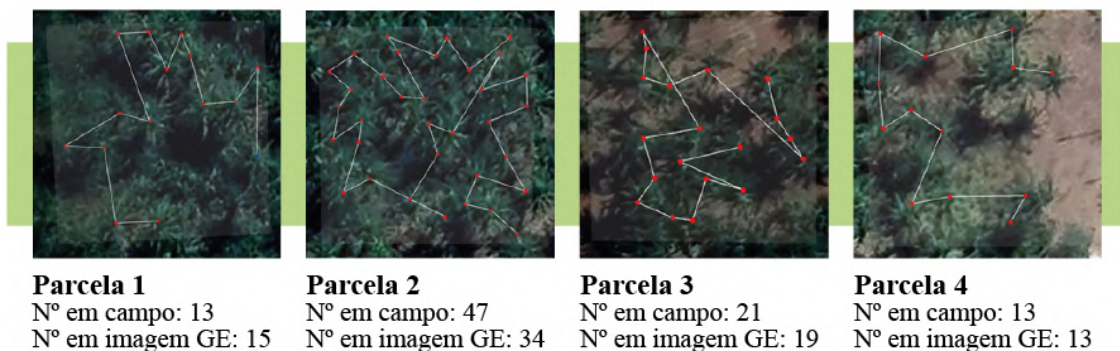
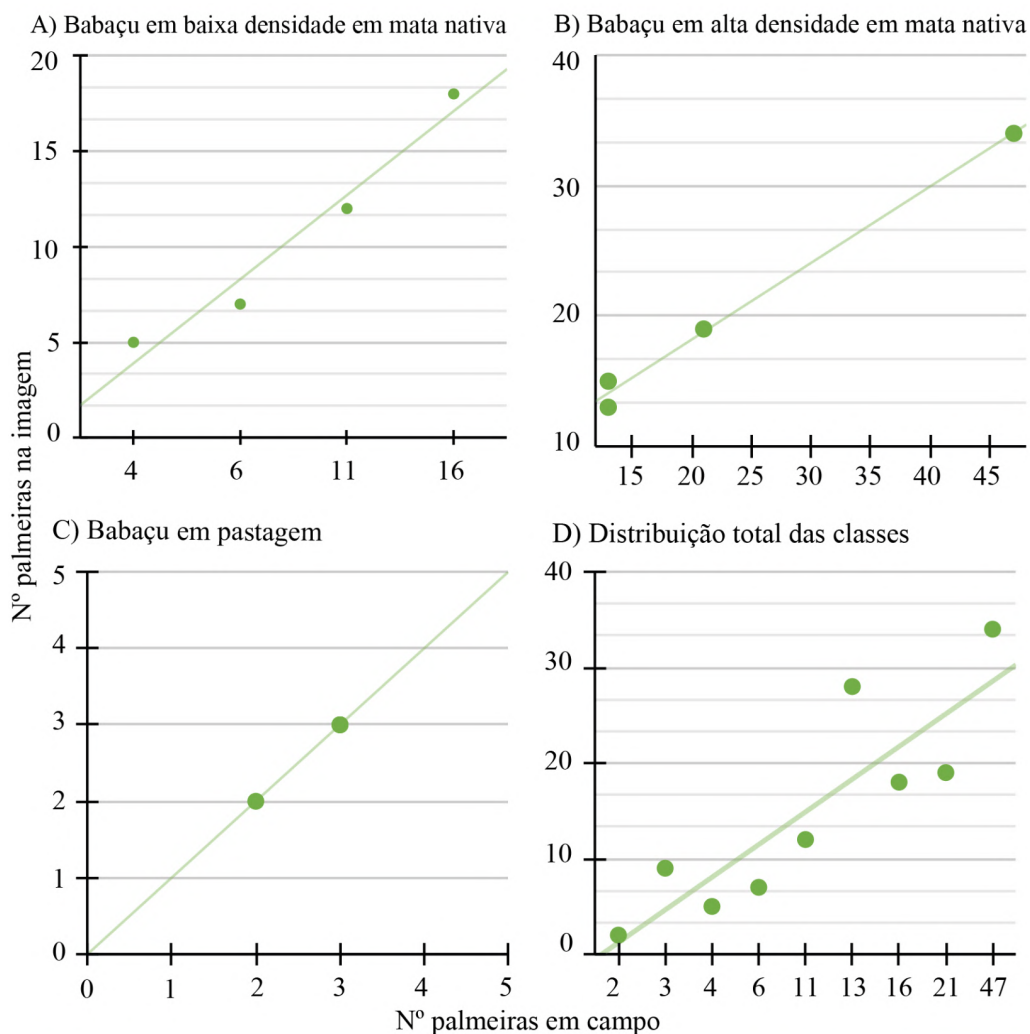


FIGURA 5: Prancha com imagens do Google Earth relacionando número de indivíduos contados na imagem e número de indivíduos contados na parcela na área piloto de Imperatriz .

Na estratificação das coletas de campo por classe de cobertura (**figura 5**) foi possível encontrar valores próximos entre as médias de Babaçu em pastagem (média de três indivíduos em campo e média de três indivíduos na análise visual). Para o Babaçu em baixa densidade em mata nativa foram encontradas uma média de nove indivíduos em campo e média de três indivíduos na análise visual). Para o Babaçu em alta densidade em mata nativa foi encontrado uma média de 24 indivíduos em campo e média de 20 indivíduos na análise visual da imagem .



	Equação	R ²	R
A) Babaçu em baixa densidade	$y = 1,0778x + 0,5303$	0,9978	0,9989
B) Babaçu em alta densidade	$y = 0,5873x + 6,4487$	0,9924	0,9962
C) Babaçu em pastagem	$y = x$	1	1
D) Classes reunidas	$y = 0,7288x + 2,5421$	0,9507	0,9750

FIGURA 6: Relação linear entre as contagens de babaçu em variáveis de campo e na imagem do Google Earth. A) Babaçu em baixa densidade em mata nativa; B) Babaçu em alta densidade em mata nativa; C) Babaçu em pastagem; e D) Distribuição total das classes na área de Imperatriz.

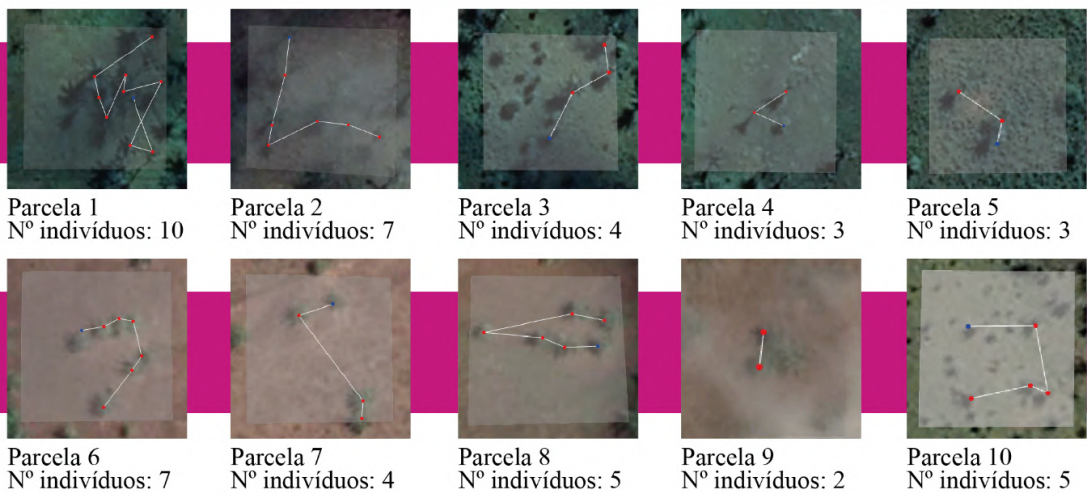
A partir da regressão linear realizada por classe obtivemos as três equações, onde y representa o número de indivíduos reais e x o valor na contagem visual por imagem (**Figura 6 a b e c**). Também foi calculada a equação para todas as classes reunidas (**Figura 6 d**). Foram encontradas correlações positivas e próximos ou iguais a 1 ($R = 0,9989$ para a classe de Babaçu em baixa densidade em mata nativa; $R = 0,9962$ para a classe de Babaçu em alta densidade em mata nativa; 1 para a classe de Babaçu em pastagem; e $R = 0,9750$ para a área total), demonstrando que as variáveis estão fortemente correlacionadas e que os dados das imagens correspondem com os dados de campo (**Figura 6**).

Estimação da densidade de indivíduos por análise visual da imagem de satélite

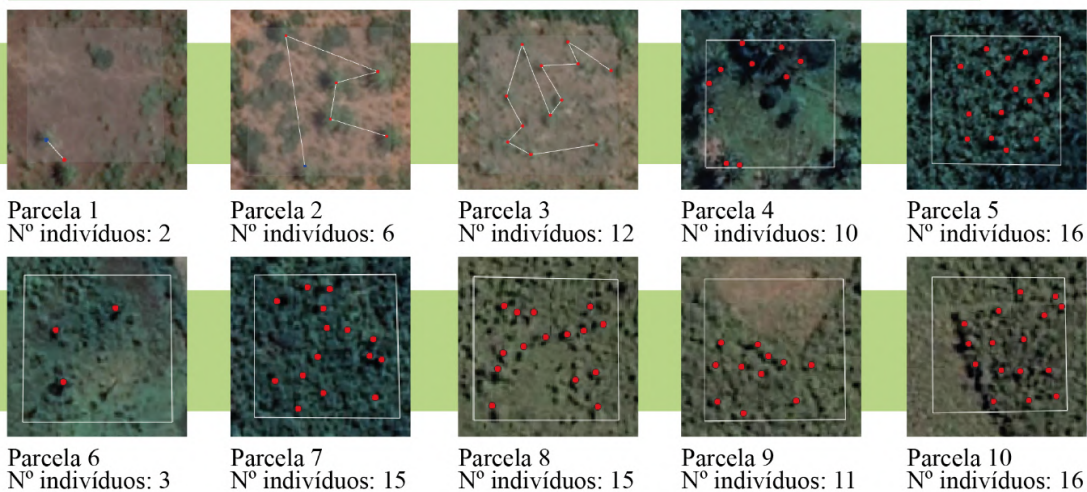
Nas 90 parcelas analisadas visualmente a partir de imagens de satélite de Google Earth Pro (**figuras 6, 7 e 8**), foram identificados os valores médios de indivíduos de babaçu para cada parcela (50x50m) nas três classes de cobertura para cada uma das três áreas piloto estudadas:

- **Área de Matinha:** 11 ± 5 indivíduos/2500m² para a classe de Babaçu em baixa densidade em mata nativa; 36 ± 8 indivíduos/2500m² para a classe de Babaçu em alta densidade em mata nativa; 5 ± 2 indivíduos/2500m² para a classe de Babaçu em pastagem.
- **Área de Santa Inês:** 9 ± 3 indivíduos/2500m² para a classe de Babaçu em baixa densidade em mata nativa; 31 ± 7 indivíduos/2500m² para a classe de Babaçu em alta densidade em mata nativa; 5 ± 3 indivíduos/2500m² para a classe de Babaçu em pastagem
- **Área de Imperatriz:** 12 ± 4 indivíduos/2500m² para a classe de Babaçu em baixa densidade em mata nativa; 22 ± 7 indivíduos/2500m² para a classe de Babaçu em alta densidade em mata nativa; 3 ± 1 indivíduos/2500m² para a classe de Babaçu em pastagem.

Área 1 - Matinha - Babaçu em pastagem:



Área 1 - Matinha - Babaçu em baixa densidade em mata nativa



Área 1 - Matinha - Babaçu em alta densidade em mata nativa

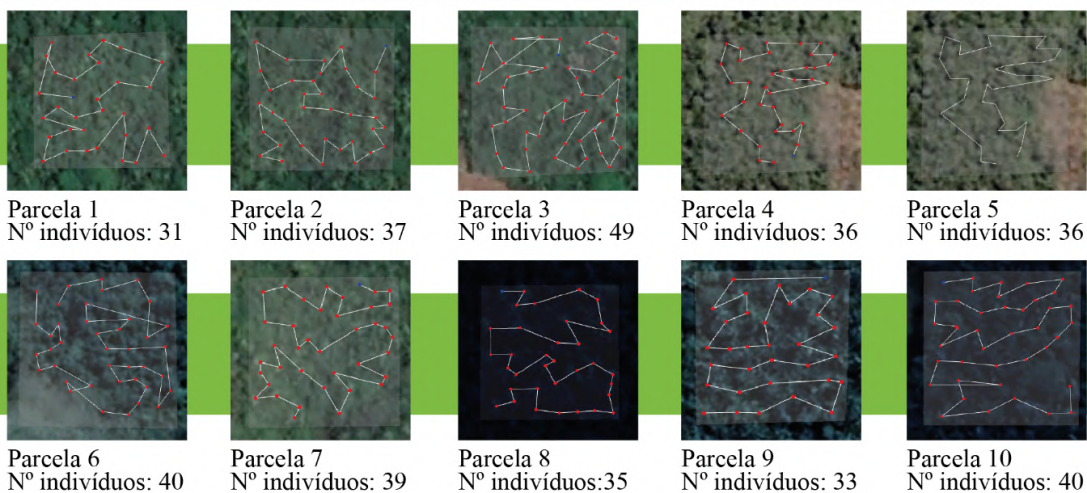
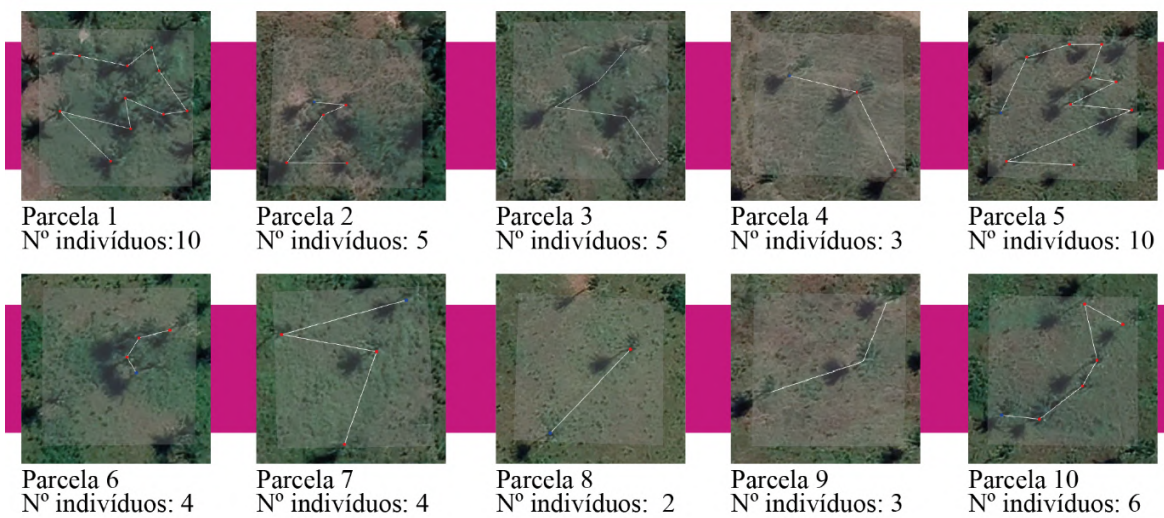
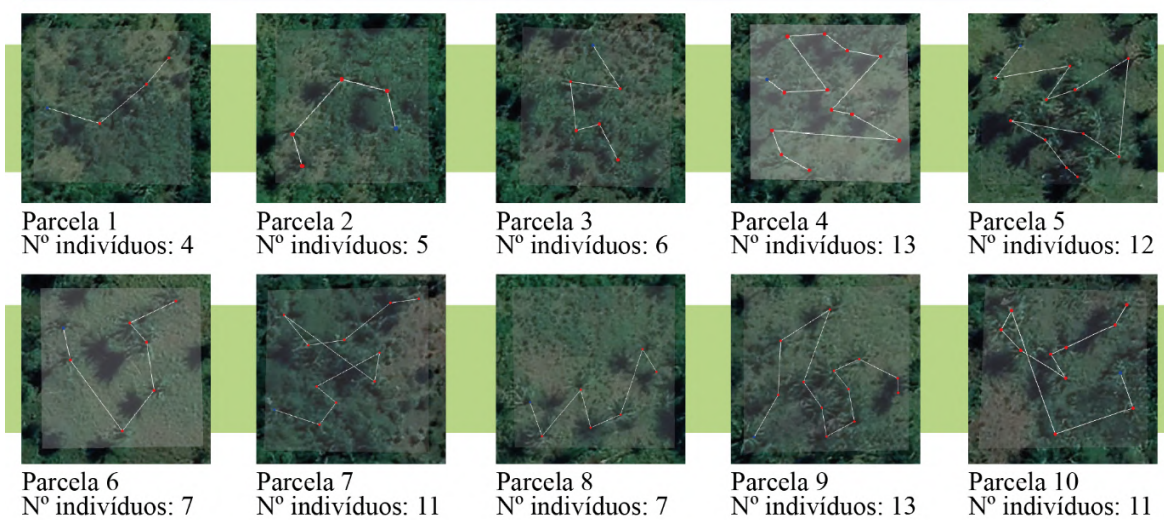


FIGURA 7: Prancha com imagens do Google Earth com número de indivíduos contados na parcela na área de Matinha (área 1).

Área 2 - Santa Inês - Babaçu em pastagem:



Área 2 - Santa Inês - Babaçu em baixa densidade em mata nativa



Área 2 - Santa Inês - Babaçu em alta densidade em mata nativa

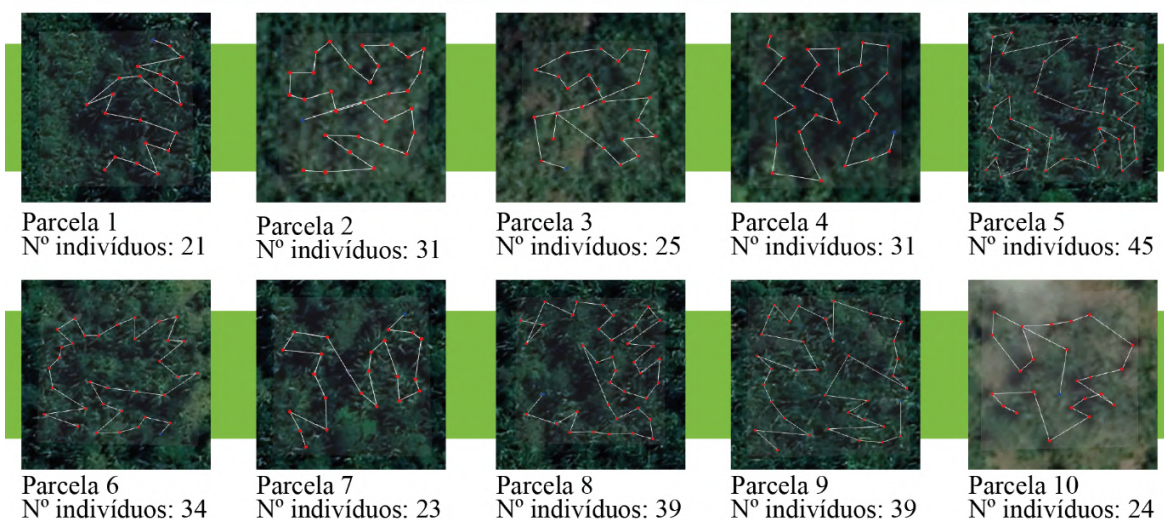
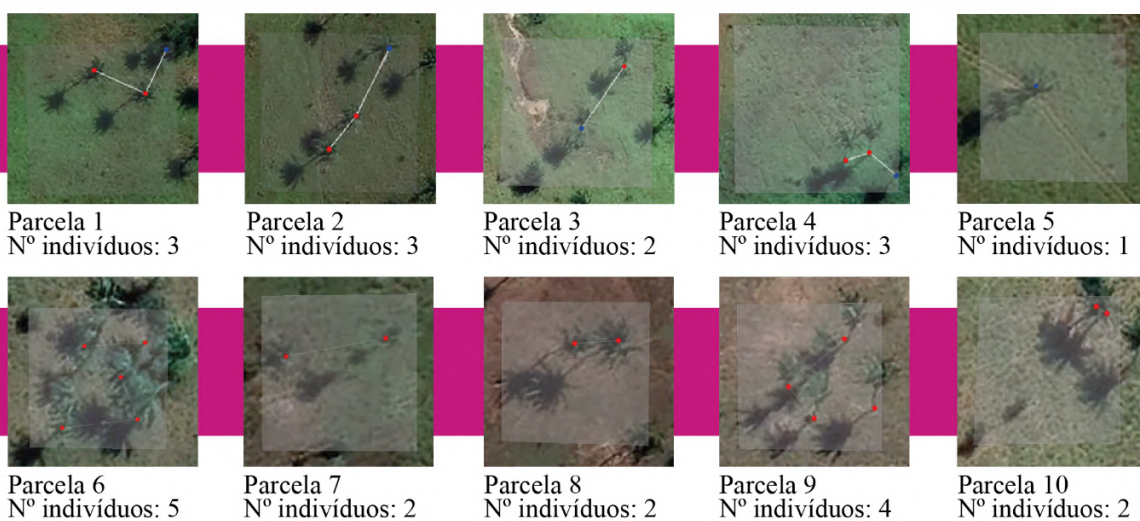
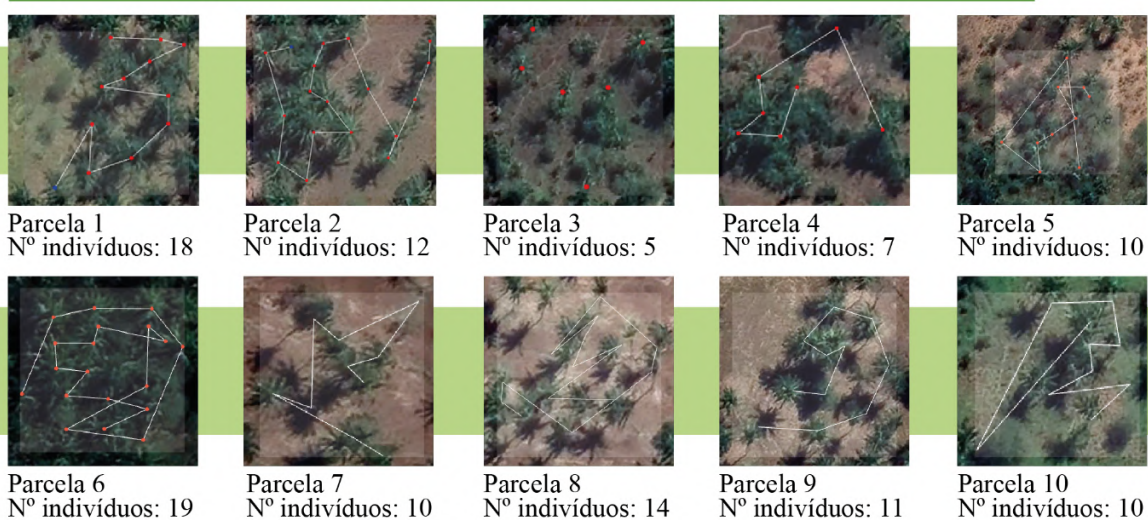


FIGURA 8: Prancha com imagens do Google Earth com número de indivíduos contados na parcela na área de Santa Inês (área 2).

Área 3 - Imperatriz - Babaçu em pastagem:



Área 3 - Imperatriz - Babaçu em baixa densidade em mata nativa



Área 3 - Imperatriz - Babaçu em alta densidade em mata nativa

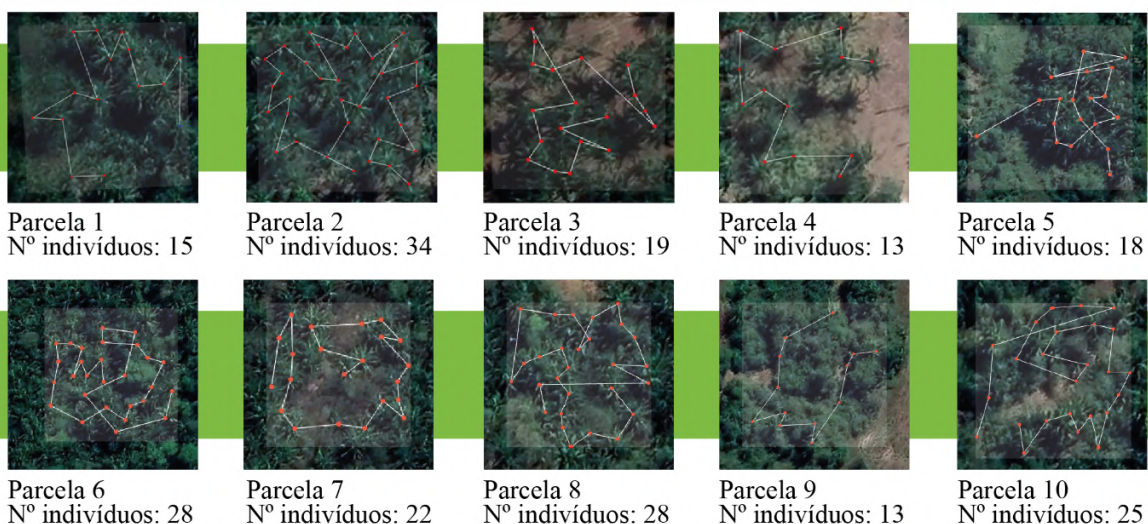




FIGURA 9: Prancha com imagens do Google Earth com número de indivíduos contados na parcela na área de Imperatriz (área 3).

a) Babaçu em pastagem



b) Babaçu em baixa densidade em mata nativa



c) Babaçu alta densidade em mata nativa




FIGURA 10: Boxplot de comparativo de distribuição entre áreas para as classes de: A) Babaçu em Pastagem; B) Babaçu em baixa densidade em mata nativa; e C) Babaçu em alta densidade em mata nativa.

A) ANOVA - Babaçu em pastagem

Fonte da variação	SQ	gl	MQ	F	valor-P	F crítico
Entre grupos	38,6	2	19,30	3,90	0,03	3,35
Dentro dos grupos	133,7	27	4,95			
Total	172,3	29				

B) ANOVA - Babaçu em baixa densidade em mata nativa

Fonte da variação	SQ	gl	MQ	F	valor-P	F crítico
Entre grupos	37,27	2	18,63	0,94	0,40	3,35
Dentro dos grupos	533,70	27	19,77			
Total	570,97	29				

C) ANOVA - Babaçu em alta densidade em mata nativa

Fonte da variação	SQ	gl	MQ	F	valor-P	F crítico
Entre grupos	1056,20	2	528,10	9,08	0,001	3,35
Dentro dos grupos	1571	27	58,19			
Total	2627,2	29				

TABELA 1: Análise de variância entre as áreas de Matinha, Santa Inês e Imperatriz pela classe de: a) Babaçu em Pastagem; b) Babaçu em baixa densidade em mata nativa; e c) Babaçu em alta densidade em mata nativa (nível de significância estabelecido de 0,05).

Para a fisionomia de babaçu em pastagem, foi encontrado diferenças significativas entre as diferentes áreas (valor-p = 0,032) (**tabela 1 A**) sendo que Matinha e Santa Inês apresentaram médias de densidade de indivíduos similares entre 5 e 5,2, e uma distinção com a média de Imperatriz (2,7) que foi significativamente menor (**figura 10**). Já para a fisionomia de babaçu em baixa densidade em mata nativa, não foi encontrado diferenças significativas entre as áreas (valor-p = 0,402) (**tabela 1 B**) sendo que os valores médios de palmeiras de babaçu 10,6, 8,9 e 11,6 para as áreas de Matinha,

Santa Inês e Imperatriz respectivamente (**figura 10**). Para a fisionomia de babaçu em alta densidade em mata nativa, foi encontrado diferenças significativas entre as áreas (valor-p = 0,001) (**tabela 1 A**) sendo que as áreas de Matinha e Santa Inês apresentaram médias de densidade de indivíduos próximas entre 35,8 e 30,9, e uma distinção com a média de Imperatriz (20,5) que foi significativamente menor (**figura 10**).

População de palmeiras babaçu e densidade de indivíduos por classe.

Local	Tipo de vegetação	Contagem média por parcela (ind/2500m ²)	Desvio Padrão	Área da classe (km ²)	Palmeiras estimadas (ind)	Densidade (ind/km ²)
Matinha	Babaçu em baixa densidade em mata nativa	11	5	2,8414	12.047	4240
Matinha	Babaçu em alta densidade em mata nativa	36	8	1,2381	17.729	14320
Matinha	Babaçu em pastagem	5	2	2,1249	4.250	2000
Santa Inês	Babaçu em baixa densidade em mata nativa	9	3	1,5965	5.684	3560
Santa Inês	Babaçu em alta densidade em mata nativa	31	7	0,9889	12.223	12360
Santa Inês	Babaçu em pastagem	5	3	2,9585	6.154	2080
Imperatriz	Babaçu em baixa densidade em mata nativa	12	4	1,7970	8.338	4640
Imperatriz	Babaçu em alta densidade em mata nativa	22	7	0,7436	6.395	8600
Imperatriz	Babaçu em pastagem	3	1	2,0236	2.185	1080

TABELA 2: Estimação de babaçu e densidade populacional

O total de indivíduos para as classes que contém babaçu na área piloto de Matinha foi de 34.027 mil palmeiras (com limites de variação mínimos e máximos entre 22.641 mil a 45.412 mil indivíduos) para uma área de 6,2 km² que representa 60,87 % da área piloto total (**tabela 2**). Desse total, 35,41% foi encontrado na vegetação de babaçu em baixa densidade em mata nativa, 52,10% em babaçu em alta densidade em

mata nativa e 12,49% em babaçu em pastagem. As densidades para esses tipos de cobertura foram de 4.240, 14.320 e 2.000 mil indivíduos/km² respectivamente.

O total de indivíduos para as classes que contém babaçu na área piloto de Santa Inês foi de 24.060 mil palmeiras (com limites de variação mínimos e máximos entre 15.936 mil a 32.185 mil indivíduos) para uma área de 5,54 km² que representa 48,46 % da área piloto total (**tabela 2**). Desse total, 23,62% foi encontrado na vegetação de babaçu em baixa densidade em mata nativa, 50,80% em babaçu em alta densidade em mata nativa e 25,58% em babaçu em pastagem. As densidades para esses tipos de cobertura foram de 3.560, 12.360 e 2.080 mil indivíduos/km² respectivamente.

O total de indivíduos para as classes que contém babaçu na área de Imperatriz foi de 16.918 mil palmeiras (com limites de variação mínimos e máximos entre 11.012 mil a 22.824 mil indivíduos) para uma área de 4,56 km² que representa 54,42 % da área total (**tabela 2**). Desse total, 49,28% foi encontrado na vegetação de babaçu em baixa densidade em mata nativa, 37,80% em babaçu em alta densidade em mata nativa e 12,92% em babaçu em pastagem. As densidades para esses tipos de cobertura foram de 4.640, 8.600 e 1.080 mil indivíduos/km² respectivamente.

4. DISCUSSÃO

Para esta pesquisa não foi possível identificar palmeiras de forma automática, devido as imagens utilizadas para o mapeamento, imagens do sensor Sentinel 2, e as imagens disponíveis obtidas do Planet Monitoring não ter a resolução necessária para contagem de indivíduos nas três fisionomias, por isso foi utilizada a metodologia de contagem manual no software Google Earth Pro. Alguns estudos de identificação e contagem de árvores apresentam variadas metodologias para realizar suas pesquisas, como por exemplo a pesquisa de Shafri *et al* (2011), que detectou e contabilizou palmeiras de dendê em Selangor - Malásia, de forma semi-automática, por meio de algoritmos e imagens de alta resolução, e outros trabalhos que buscaram essas informações por meio da identificação da copa das árvores em imagens de alta resolução juntamente com a sombra. Exemplo do trabalho de Santos *et al* (2017) ao analisar a detecção automática de palmeira babaçu usando uma imagem pancromática GeoEye de alta resolução espacial (0,50 m) e um algoritmo chamado “Compt-palm”

baseado na detecção de sombras de palmeiras, em uma comunidade de pequenas propriedades agrícolas na Amazônia.

No trabalho de Shafri et al (2011), os autores testaram imagens AISA de alta resolução de uma nave aerotransportada, e os dados processados nos softwares ENVI 4.0 e Matlab 7.5.0. Após validação dos dados obtidos com os dados terrestres, a precisão média obtida foi de 95%. No entanto, segundo os autores haviam várias árvores contadas incorretamente devido a algumas copas de palmeira sobrepostas. Os autores relatam que o método funciona bem se as copas de dendzeiros estiverem isoladas ou distanciadas, o que significa que este método não seria viável em áreas adensadas como as de babaçu. Já na pesquisa de Santos *et al* (2017), o algoritmo reconheceu aproximadamente 60% dos indivíduos de babaçu jovens (palmeiras com estipe aérea, independentemente da cobertura da bainha, e sem presença de órgãos reprodutivos masculinos ou femininos) e 96% de indivíduos adultos (palmeiras com estipe aérea com a presença de órgãos reprodutivos masculinos e/ou femininos), porém todos os indivíduos somente em áreas abertas com as palmeiras espaçadas.

Os trabalhos citados trazem formas de identificação automáticas ou semiautomáticas por meio de algoritmos para detecção e contagem de palmeiras. A problemática dos métodos é que só seria possível essa contagem em áreas com palmeiras espaçadas, onde poderiam se identificar indivíduos, copas e sombras. Para uma contagem mais precisa no bioma amazônico, onde são apresentados outras fisionomias de babaçu que concentram uma maior quantidade de palmeiras, esses métodos não serviriam para estimar a população em toda a área.

O método empregado no presente trabalho conseguiu identificar e contar indivíduos adultos em três classes de fisionomias que contém babaçu com densidades variadas. A validação para o método de contagem demonstrou que a correlação dos dados de campo com a contagem visual em imagem de alta resolução do Google Earth se mostraram muito altos ($R = 0,95$ para todas as classes e variando $R = 0,9962$ e 1 dentro das classes), apesar de haver uma diferença temporal entre as imagens do Google Earth (Agosto de 2020) com as coletas em campo (maio de 2021). Importante ressaltar que, com as imagens históricas do Google Earth, é possível realizar um estudo temporal sobre a paisagem com foco nas fisionomias que contém babaçu para averiguar a mudança ao longo do tempo.

Com a validação na metodologia de contagem visual foi possível obter as informações nas 90 parcelas amostradas em que a densidade de babaçu variou de 1 a 49 indivíduos por 2500 m², nas três áreas piloto (Matinha, Santa Inês e Imperatriz). Esses dados permitiram identificar uma densidade média de 3.403 palmeiras por km² na área de Matinha, 2.406 palmeiras por km² na área de Santa Inês e 1.692 palmeiras por km² na área de Imperatriz. As áreas de maior densidade são aquelas que estão em proximidade com as ecorregiões da Mata dos Cocais e da Baixada Maranhense, áreas que são relativamente próximas à região central do estado do Maranhão. Já a área de Imperatriz, que fica mais ao sul do estado, apresentou densidades menores tanto por classe quanto total por área (km²). Essa diferenciação, também, fica evidente na comparação de médias de parcelas entre classes, principalmente nas classes de babaçu em pastagem e babaçu em alta densidade em mata nativa, onde foi constatado a diferença significativa a 5% de probabilidade ($p=0,05$). Uma possível explicação para a maior densidade nas áreas de Matinha e Santa Inês é a proximidade com a ecorregião Mata dos Cocais, onde é predominante na paisagem a presença de babaçuais mais adensados (IMESC, 2020). Esse resultado já era esperado, pois a Mata dos Cocais, por ser uma área de predominância para as palmeiras de diversas espécies, sendo uma área de transição entre os biomas amazônicos e cerrado ela tem as condições ideais para o estabelecimento de palmeiras, como campos abertos, solos profundos, disponibilidade hídrica e exposição solar, que difere de vegetações amazônicas densas que por ter um dossel fechado que não possibilita a germinação de plântulas (REIS, 2019).

Um estudo sobre babaçuais, no estado do Maranhão, mostrou que a densidade média do babaçu com idade acima de 10 anos é de 95 indivíduos por hectare (MAY, 1990) que, transformado extrapolando para quilômetros quadrados apresentaria uma população aproximada de 9500 indivíduos. As áreas do presente estudo possuem médias menores que as apontadas por May (1990), o que pode estar relacionado à diferença temporal e as mudanças na paisagem influenciadas pelas atividades antrópicas, e que pode justificar a diminuição da população palmeiras por área desde seu estudo até os dias atuais. As três áreas piloto se encontram no arco de desmatamento da Amazônia maranhense, que de acordo com Dias *et al* (2017) sofre deste problema desde a década 1960, além de conflitos de terra, do desmatamento para a pecuária extensiva e abertura de frentes de ocupação humana. Essa problemática pode ser

demonstrada pelos dados de remanescentes florestais ainda preservados no bioma amazônico do Maranhão que apresenta apenas 24% de suas áreas de floresta conservadas, de acordo com o INPE (2021), e 85% desse restante estão reduzidas aos territórios indígenas e a reserva biológica do Gurupi (MAPBIOMAS, 2021).

Dias *et al* (2017) também relatam que ao final dos anos 90, somam-se aos problemas anteriores outras advindas como o plantio extensivo de eucalipto, as erosões remontantes, o assoreamento de cursos d'água e a diminuição da vegetação ciliar por estresse, desmatamento ou agricultura itinerante. As áreas piloto de Imperatriz, que apresentou os menores valores de densidade de palmeiras, pode ser justificada, principalmente, por ser um grande centro de agronegócio na região e, também, por estar localizada em uma região de transição para o Cerrado de planaltos (Chapada das Mesas) que não apresenta a ocorrência de babaçuais. A presença de diversos cultivos, como a monocultura da soja e do eucalipto, além de extensas áreas de pastagem podem ter modificado a paisagem da região, por mais que exista uma iniciativa de algumas empresas do meio privado para preservar áreas de babaçuais e projetos sociais que direcionam orçamentos para diminuir o impacto de suas atividades, os números de densidade de população para a área demonstram uma diminuição com base nas médias apresentadas por May (1990). Neste sentido, abre-se uma nova linha de pesquisa para entender se esse comportamento é advindo da região transição para as áreas de planalto no cerrado do maranhense ou se de fato é resultado das atividades antrópicas.

As palmeiras de babaçu, de fato, apresentam maior ocorrência em áreas antropizadas, porém não restrito a elas. As ações do homem exercem influência direta nas populações, como em áreas de desmatamento e áreas de pastagem (DIAS *et al* 2017). As alterações antrópicas contribuem na criação de um ambiente mais propício ao estabelecimento da palmeira. Em áreas que ocorrem o manejo por fogo, é perceptível a brotação de novas plantas, pois como relata Reis (2019), o babaçu possui geotropismo negativo que favorece o estabelecimento do indivíduo, o que significa que quando a palmeira está nos estágios iniciais sua gema de crescimento está ainda protegida no solo, e quando a mesma se torna aérea, o indivíduo já está estabilizado e praticamente não é mais afetado pelo fogo e capina. O fogo e a capina apenas atrasam o crescimento no momento da queima ou corte das folhas, mas ao mesmo tempo aceleram o crescimento das novas folhas produzidas, pois diminui a competição com outras plantas.

OLIVEIRA *et al.* (2003) relatam que o babaçu é visto pelos pecuaristas como uma planta invasora e que pode inviabilizar ou restringir o uso da pastagem caso não seja controlado. Falta uma compreensão de que a presença da palmeira, quando manejada, pode trazer benefícios e ganhos de peso aos animais da pastagem, além de benefícios ao ambiente através de aporte de matéria orgânica. E junto a isto compreender que as quebradeiras de coco babaçu, de certa forma, contribuem tanto para o controle, já que coletam os cocos de uma área e os transportam, quanto para a preservação da palmeira. De acordo com o MIQCB (2020), o extrativismo feito de forma manual pelas quebradeiras contribui indiretamente para a manutenção da palmeira, pois auxiliam na dispersão do fruto do coco e no ingresso de novas palmeiras, inclusive porque cada mulher coleta somente o suficiente para sua produção particular, deixando outros cocos para as demais mulheres.

5. CONSIDERAÇÕES FINAIS

Com base nos dados coletados em campo e com a análise visual de imagens de alta resolução do Google Earth, foi possível validar o método de contagem que demonstrou uma correlação muito alta. Isso permitiu identificar as densidades médias de 3.403 palmeiras por km² na área de Matinha, 2.406 palmeiras por km² na área de Santa Inês e 1.692 palmeiras por km² na área de Imperatriz.

Extrapolando essas informações para o mapeamento das áreas piloto, obtemos o resultado de aproximadamente 75 mil palmeiras para as três áreas, sendo estas: 34.027 mil palmeiras na área de Matinha, 24.060 mil palmeiras na área de Santa Inês e 16.918 mil palmeiras na área de Imperatriz. As áreas com maior concentração de palmeiras na amazônia maranhense foram as áreas em proximidade ao centro do Estado, ou ecorregiões da Baixada maranhense e da Mata dos Cocais.

O uso do software Google Earth Pro mostrou ser uma ferramenta prática e com boa precisão para validação e como medida alternativa para contagem de indivíduos em parcelas. Os resultados desta pesquisa contribuem para o monitoramento e mapeamento de áreas de babaçu no Maranhão e podem ser a base para pesquisas futuras visando a criação de políticas públicas para a proteção da palmeira.

REFERÊNCIAS

- ALBIERO et al. Desenvolvimento e projeto de colhedora de babaçu (*Orbignya phalerata* Mart.) para agricultura familiar nas regiões de matas de transição da Amazônia. **Acta Amazonica** - n.41, p. 57 – 68, 2011.
- ALMEIDA E CUNHA. Populações tradicionais e conservação ambiental. **Cultura com Aspas**. São Paulo: Cosac Naify. p. 277- 300, 2009.
- ALMEIDA, A. W. B. Quebradeiras de Coco Babaçu: identidade e mobilização - legislação específica e fontes documentais e arquivísticas. **III Encontro Interestadual das Quebradeiras de Coco Babaçu**. São Luís: MIQCB, 1995.
- AMARAL et al. Ecologia da paisagem e o sensoriamento remoto na investigação da dinâmica da paisagem. **XIII ENANPEGE**, São Paulo 2019.
- ANDRADE, M. de P.; FIGUEIREDO, L.D. Na lei e na marra – a luta pelo livre acesso aos babaçuais. **Projeto Olhar Crítico**. São Luís, 2004.
- ARASATO, L.S. et. al. Detecting individual palm trees (*Arecaceae* family) in the Amazon rainforest using high resolution image classification. **Anais XV Simpósio Brasileiro de Sensoriamento Remoto – SBSR 2011, INPE**. Curitiba, PR, Brasil, p.7628, 2011.
- ARAUJO, H. F. A.; NOVAE, J. S. MEGAEMPREENDIMENTOS, AGROESTRATÉGIAS E POVOS E COMUNIDADES TRADICIONAIS: a resistência das quebradeiras de coco babaçu. **Revista de Políticas Públicas**, vol. 22, pp. 1431-1448, 2018. Acesso: <<https://www.redalyc.org/journal/3211/321158844073/html/>> em Setembro 2021.
- ARAUJO JUNIOR, M. E.; DMITRUK, E. J.; MOURA, J. C. C. **A Lei do Babaçu Livre: uma estratégia para a regulamentação e a proteção da atividade das quebradeiras de coco no Estado do Maranhão**. Sequência (Florianópolis), n. 68, p. 129-157, jun. 2014
- BARTABURU, X.; MENDES, A.; MOTOK, C. **Quebradeiras de coco babaçu**. Reporter Brasil. Publicado em 2018. Acesso em: <<https://reporterbrasil.org.br/comunidadestradicionais/quebradeiras-de-coco-babacu/>> Setembro de 2021
- BELGIU, M.; DRAGUȚ, 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, Publicado em abril de 2016.
- BENZ, U. C.; HOFMANN, P.; WILLHAUCK, G.; LINGENFELDER, I.; HEYNEN, M. Multiresolution, object-oriented fuzzy analysis of remote sensing data for GIS-91 ready information. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 58, n.3-4, p. 239-258, 2004.

- BREIMAN, L. Random Forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 1 out. 2001.
- CARRAZZA, L.R.; SILVA, M.L.; ÁVILA, J.C.C. Manual Tecnológico de Aproveitamento Integral do Fruto do Babaçu. **Instituto Sociedade, População e Natureza (ISPAN)**. Brasília – DF, Brasil, 2012.
- CARVALHO, I.S. Análise espaço-temporal do regime de queimadas no parque nacional da chapada das mesas, Maranhão. **Dissertação de Mestrado** - Curso de Pós-Graduação em Agricultura e Ambiente, Universidade Estadual do Maranhão, 2019.
- CARVALHO, M.D.F. de. **Aproveitamento racional do babaçu**. Teresina: UFPI/CNPq, 2007. 48 p.
- CASELLI, F.T.R. *et al.* Extrativismo, sustentabilidade e inclusão social das Quebradeiras de Babaçu no Meio Norte do Piauí. **PAPERS DO NAEA**. Paper 384. Publicado em abril de 2018. Belém.
- CASTRO E SILVA. análise de índices de vegetação para classificação de áreas potenciais de ocorrência de *Attalea Speciosa* Mart. ex Spreng. **Revista Georaguia** ISSN:2236-9716 Barra do Garças – MT v.10, n.2, p. 86-101. Publicado em Dezembro de 2020.
- CHAMMA, W.; BATISTELLA, D. CRISIGIOVANNI, E. *et al.* **Aprendizado de máquina aplicado em imagens de satélite para classificação de telhados**. Brazilian Journal of Development, Curitiba, v.7, n.7, p.72558-72576 jul. 2021
- CLEWLEY et al. A Python-Based Open Source System for Geographic Object-Based Image Analysis (GEOBIA) Utilizing Raster Attribute Tables. **Remote Sens**. n.6, p. 6111-6135. 2014
- CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, 37, 35–46. 1991.
- CONGALTON, R. G.; GREEN, K. Assessing the accuracy of remotely sensed data: principles and practices. **CRC Press**. 2º ed. Boca Raton - FL, 2009.
- COPERNICUS. **Acquisition Modes. User Guides - Sentinel-1 SAR**. Disponível em <<https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-1-sar/acquisition-modes>> acesso em setembro de 2021
- DALIAKOPOULOS, I. N., GRILLAKIS, E. G., KOUTROULIS, A. G., AND TSANIS, I. K. Tree crown detection on multispectral vhr satellite imagery. **Photogrammetric Engineering Remote Sensing**, 75. 2009.
- DARWISH, A.; LEUKERT, K.; REINHARDT, W. Image segmentation for the purpose of object-based classification. **IEEE Geoscience and Remote Sensing Symposium**, n.3, p. 2039-2041, 2003.

ESPIRITO-SANTO, F. D. B.; SHIMABUKURO, Y. E. Validação do mapeamento de uma área de floresta tropical com uso de imagens de videografia aérea e dados de levantamento de campo. **Revista Arvore**, Viçosa/MG, vol.29, n. 2, 2005, p.277-239. Disponível em: <<https://www.scielo.br/j/rarv/a/6RX5nmdjkh3YDYck7x4zhvd/?lang=pt>> Acesso em setembro 2021

FEARNSIDE, P.M. Desmatamento na Amazônia brasileira: História, índices e consequências. **Instituto Nacional de Pesquisas da Amazônia (INPA)**. Megadiversidade: 113-123. Volume 1 - Nº 1. Julho 2005.

FEITOSA, A. C. E TROVÃO, J. R. **Atlas escolar do Maranhão: espaço geo-histórico-cultural**. João Pessoa: Ed. Grafset, p. 207, 2006

FILHO, B. C. et. al. Caracterização de pedoambientes da mesorregião oeste maranhense, microrregião de Pindaré sob diferentes níveis de pastagens. **Embrapa Cocais**, São Luís - MA, 2018.

FLORA DO BRASIL 2020. **Jardim Botânico do Rio de Janeiro**. Disponível em: <<http://floradobrasil.jbrj.gov.br/>>. Acesso em: 30 ago. 2021

GAMEIRO S. *et al.* **Avaliação da cobertura vegetal por meio de índices de vegetação (NDVI, SAVI e IAF) na Sub-Bacia Hidrográfica do Baixo Jaguaribe, CE**. *Terræ*, 13(1-2):15-22. Publicado em 2017. Acesso em <<https://www.ige.unicamp.br/terrae/V13/PDFv13/TE067-2.pdf>> setembro 2021.

GEE. **Conheça o Google Earth Engine**. Site institucional do Google Earth Engine. Acesso: <<https://earthengine.google.com/>> em 19 de fevereiro de 2020

GEE. **MSI Sentinel-2: Instrumento multiespectral, nível 2A**. Catálogo de dados do Earth Engine. Acesso: <https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S2_SR> em 19 de fevereiro de 2020-b

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.

GOUVEIA, V M; MATRICARDI, E A T; ANGELO, H. **Dinâmica espaço-temporal da produção de amêndoas de babaçu e da utilização das terras no Maranhão**. [s. l.], p. 35 p, 2015.

HAMAMURA, C. Sensoriamento remoto para identificação taxonômica e mapeamento de espécies arbóreas em ambiente urbano. **Tese de doutorado** - USP. Escola Superior de Agricultura “Luiz de Queiroz”. 2020.

HIJMANS, R. J. *et al.* **Geographic Data Analysis and Modeling**. Rspatial. Publicado em 2021-06-18. Acesso em <<https://cran.r-project.org/web/packages/raster/raster.pdf>> setembro de 2021.

- HUETE A.R. A soil adjusted vegetation index (SAVI). **Remote Sensing Environ.** Publicado em 1988.
- IBGE. Manual técnico da vegetação brasileira: sistema fitogeográfico, inventário das formações florestais e campestres, técnicas e manejo de coleções botânicas, procedimentos para mapeamentos. **Gráfica do IBGE- Instituto Brasileiro de Geografia e Estatística**, Rio de Janeiro, ed II, p. 275, 2012.
- IBGE. Produção agrícola municipal - culturas temporárias e permanentes. **Instituto Brasileiro de Geografia e Estatística**, Rio de Janeiro, 1984.
- INPE. Classificação de Imagens. **Instituto Nacional de Pesquisas Espaciais**. Publicado em 2006. Disponível em:
<<http://www.dpi.inpe.br/spring/portugues/tutorial/classific.html>> Acesso em 06 de março de 2020.
- INPE. **TerraBrasilis**. Instituto Nacional de Pesquisas Espaciais, 2021. Acesso em:
<<http://www.dpi.inpe.br/prodesdigital/prodesmunicipal.php>> outubro de 2021
- IMESC. **Relatório Técnico de Classificação da Vegetação do Zoneamento Ecológico Econômico do Estado do Maranhão (ZEE-MA)** – Etapa Bioma Amazônico. São Luís: IMESC, 2020. Acesso em:
<<http://www.zee.ma.gov.br/src/upload/relatorios/Vegetacao.pdf>> setembro de 2021.
- KERBAUY, G.B. Fisiologia Vegetal. **Editora Guanabara Koogan S.A.**, Rio de Janeiro, p. 452, 2004.
- LANDIS, J. RICHARD; KOCH, GARY G. The measurement of observer agreement for categorical data. **Biometrics**, p. 159-174, 1977.
- LATORRE, N.S.; CRUZ DE ARAGÃO, L.E.O.; ANDERSON, L.O.; ANDERE, L.; DUARTE, V.; ARAI, E.; LIMA, A. Impactos de queimadas sobre diferentes tipos de cobertura da terra no leste da Amazônia legal brasileira. **Revista Brasileira de Cartografia**, v.1, n.69, 2017.
- LEÃO, P. H. A. Detecção de populações da palmeira de babaçu em diferentes ambientes da Amazônia maranhense usando técnicas do sensoriamento remoto. **Dissertação - Mestrado em Agricultura e Ambiente** - Universidade Estadual do Maranhão - UEMA, Balsas, MA, 2021, em produção.
- LEVER, J., KRZYWINSKI, M. E ALTMAN, N. Classification evaluation. *Methods* 13, 541–542 **Nature**. Publicado em 2016. Acesso:
<<https://www.nature.com/articles/nmeth.3945.pdf>> em setembro de 2021
- LEITMAN, P. SOARES, K. HENDERSON, A. NOBLICK, L. MARTINS, R.C. Arecaceae in Lista de Espécies da Flora do Brasil. **Jardim Botânico do Rio de Janeiro**. 2015. Disponível em:

<<http://floradobrasil.jbrj.gov.br/jabot/floradobrasil/FB53>> acesso em 30 de outubro de 2021

LIU, W.T.H. Aplicações de Sensoriamento Remoto. **Campo Grande: Ed. UNIDERP**, p. 908, 2006.

LORENZI, Harri; NOBLICK, Larry R.; KAHN, Francis. FERREIRA, Evandro. Flora Brasileira: Arecaceae (palmeiras). Nova Odessa, SP: **Instituto Plantarum**, 2010.

MAPBIOMAS. Levantamento inédito do MapBiomias Amazônia. **MapBiomias - Site**. 2021. Acesso em: <<https://mapbiomas.org/>> outubro de 2021.

MANTOVANI, W. **A degradação dos biomas brasileiros**. Patrimônio Ambiental Brasileiro. São Paulo. EDUSP/ Imprensa Oficial do Estado, p. 402, 2003.

MARANHÃO. **Diagnóstico dos principais problemas ambientais do Estado do Maranhão**. Secretaria do Estado do Meio Ambiente e Turismo do Maranhão, São Luís: Lithograf, 1991.

MARTINS, M. B; OLIVEIRA, T. G. Amazonia Maranhense: diversidade e conservação. **Museu paraense Emílio Goeldi**. Belém: MPEG, p. 328, 2011.

MASCARENHAS, L. M. D. A.; FERREIRA, M. E.; FERREIRA, L. G. Sensoriamento remoto como instrumento de controle e proteção ambiental: análise da cobertura vegetal remanescente na Bacia do Rio Araguaia. **Sociedade & Natureza**, v. 21, n. 1, p. 5–18, 2009.

MELLO, N. A. **Políticas territoriais na Amazônia**. São Paulo: Annablume, 2006.

MELLO-THÉRY. Território e Gestão Ambiental na Amazônia. **Terras públicas e os dilemas do Estado**. São Paulo: Annablume, 2011.

MENESES, P.R; ALMEIDA, T. Introdução ao processamento de imagens de sensoriamento remoto. **UNB**, Brasília, p.1-31, 2015.

MERCEDES, R. E CUNHA, S. Maranhão: Geografia. **Editora FTD**, São Paulo, vol. I , p.144, 2008.

MESQUITA. A crise da economia do babaçu no maranhão (1920-80). **Revista de políticas públicas**. São Luís, V.2, n.2, p.61-76, 1996.

MESQUITA, B. A. AS MULHERES AGROEXTRATIVISTAS DO BABAÇU: a pobreza a serviço da preservação do meio ambiente. Universidade Federal do Maranhão - **Rev. Políticas Públicas**. São Luís, v. 12, n. 1, p. 53-61, 2008.

MIQCB. **Floresta babaçu em pé**. Site institucional. Disponível em: <<https://www.miqcb.org/publicacoes>> Acesso em 20/02/2020

MMA. O Bioma Cerrado. **Ministério do Meio Ambiente**. Disponível em: <<https://www.mma.gov.br/biomas/cerrado>> acesso em 03/03/2020.

MUNIZ, F.H. **A vegetação da região de transição entre a Amazônia e o Nordeste, diversidade e estrutura**. São Luís, MA., UEMA, p.53-69. 2004.

NETO. Quebradeiras de coco: “babaçu livre” e reservas extrativistas. **Veredas do Direito**, Belo Horizonte, v.14 n.28 p.147-166. 2017.

OLIVEIRA, T. S. Desenvolvimento do milho sob influência de árvores de pau-branco em sistema agrossilvipastoril. **Pesquisa Agropecuária Brasileira**, v. 48, n. 10, p. 1342-1350, 2003.

OLIVEIRA, G. S. Produtividade de biomassa de cana-de-açúcar em função dos índices de vegetação utilizando técnicas de sensoriamento remoto. 2015. vii, 65 p. **Dissertação (mestrado)** - Universidade Estadual Paulista Júlio de Mesquita Filho, Faculdade de Ciências Agrárias e Veterinárias de Jaboticabal, 2015. Disponível em: <<http://hdl.handle.net/11449/136733>>.

PANTALEÃO E SCOFIELD. Comparação entre medidas de acurácia de classificação para imagens do satélite ALOS. **Anais. XIV Simpósio Brasileiro de Sensoriamento Remoto**, Natal, Brasil, 25-30 abril 2009, INPE, p. 7039-7046.

PEDREGOSA et al. **Scikit-learn: Machine Learning in Python**, JMLR 12, pp. 2825-2830, 2011.

PEIXOTO, P. O desaparecimento do mundo rural. **VIII Congresso Luso-Afro-Brasileiro de Ciências Sociais**. Universidade de Coimbra, Portugal, 2004

PETRI, C. A. avaliação de dados MODIS (MAIAC) corrigidos e não-corrigidos para efeitos bidirecionais na amazônia. **Instituto Nacional de Pesquisas Espaciais - INPE**. São José dos Campos, 2019.

PINHO, C. M. D. Análise orientada a objetos de imagens de satélites de alta resolução espacial aplicada à classificação de cobertura do solo no espaço intra-urbano: o caso de São José dos Campos – SP. 2006. 178 p. (INPE-14183-TDI/1095). **Dissertação - Mestrado em Sensoriamento Remoto** - Instituto Nacional de Pesquisas Espaciais - INPE, São José dos Campos, SP, 2005

PLANET. **Monitoramento de satélite em tempo real com o Planet**. Site institucional. Acesso em <<https://www.planet.com/products/monitoring/>> setembro 2021

PONZONI, F. J.; REZENDE, A. C. P. Influência da resolução espacial de imagens orbitais na identificação de elementos da paisagem em Altamira-PA. **Revista Árvore**, v. 26, n. 4, p. 403-410, 2002.

REIS, J. A. M. Dinâmica populacional de babaçu (*Atalea speciosa* Mart. ex. Spreng.) em pastagens na amazônia oriental. **Dissertação de Mestrado**. UFRA – Belém Pará, 2019.

- ROUSE J.W., HAAS H.R. SCHELL J.A. DEERING D.W. Monitoring vegetation systems in the great plain with ERTS. In: **Earth Resources Technology Satellite - 1 Symposium**. Washington, v. 1, Publicado em 1973.
- RODRIGUEZ-GALIANO, V. F. et al. **An assessment of the effectiveness of a random forest classifier for land-cover classification**. ISPRS Journal of Photogrammetry and Remote Sensing, v. 67, p. 93–104, jan. 2012.
- SANTOS, A.M. *et al.* Estimating babaçu palm density using automatic palm detection with very high spatial resolution satellite images. **Journal of Environmental Management**, v. 193, p.40-51, 2017.
- SILVA, M. R. et. al. Mapeamento de áreas potenciais do babaçu (*Attalea Speciosa Mart. ex Spreng*) na bacia do Rio Cocal, TOCANTINS. **Espaço & Geografia**, Vol.12, Nº1. Publicado em 2009.
- SILVA, V. M. Classificação de imagens por sensoriamento remoto: análise comparativa das metodologias pixel-a-pixel e segmentação por região. **Monografia (especialização)** – Universidade Federal de Minas Gerais, Departamento de Cartografia, 2014.
- SILVA, P. D. *et al.* **Metodologias de visão computacional para contagem de plantas por meio de imagens de satélite**. VII Escola Regional de Informática de Goiás, Goiânia. Publicado em 2019. Acesso em: <<https://sol.sbc.org.br/index.php/erigo/article/view/9092/8994>> setembro de 2021
- SILVA, T. S. F. **Proto-package for assessing the accuracy of remote sensing classifications**. EcoDyn - Github. Disponível em: <<https://github.com/EcoDyn/rsacc/>> acesso em 10/03/2020
- SHAFRI, H. Z. M., HAMDAN, N., SARIPAN, M. I. Semi-automatic detection and counting of oil palm trees from high spatial resolution airborne imagery. **International Journal of Remote Sensing**, 32(8), 2095–2115. Publicado em 2011.
- SHIRAISHI N. J. Quebradeiras de coco: "babaçu livre" e reservas extrativistas. **Veredas do Direito**, v. 14, n.28, p. 147-166, 2017.
- SCHULTZ, B; IMMITZER, M; FORMAGGIO, A. R. **Self-guided segmentation and classification of multi-temporal Landsat 8 images for crop type mapping in Southeastern Brazil**. Multidisciplinary Digital Publishing Institute, Jaguariúna -sp, v. 7, n. 11, p.14482-14508, 30 out. 2015.
- SRESTASATHIERN, P. e RAKWATIN, P. Oil Palm Tree Detection with High Resolution Multi-Spectral Satellite Imagery. **Remote Sens**. n. 6, p. 9749-9774, 2014.
- SODRÉ, et. al. As faces do agronegócio maranhense: uma análise da expansão agrícola e do aumento da violência no campo. **Dossiê Agronegócios no Brasil**, p. 599-622, 2019.

SPINELLI-ARAÚJO, L. *et. al.* Conservação da biodiversidade do estado do Maranhão: cenário atual em dados geoespaciais. Jaguariúna: **Embrapa Meio Ambiente**, 2016.

SOUZA, J. A. *et al.* ANÁLISE DE MEDIDAS DE ACURÁCIA EM PROCESSOS DE CLASSIFICAÇÃO BASEADAS NA MATRIZ DE CONFUSÃO . In: LI SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, 2019, Limeira. **Anais eletrônicos...** Campinas, Galoá, 2019. Disponível em: <<https://proceedings.science/sbpo-2019/papers/analise-de-medidas-de-acuracia-em-processos-de-classificacao-baseadas-na-matriz-de-confusao-?lang=pt-br>> Acesso em: 26 set. 2021.

THALES, M. C. Imagem fração sombra na caracterização e mapeamento de babaçu (*Attalea speciosa* Mart ex Spreng.) em áreas de floresta. **Dissertação** (Mestrado em Sensoriamento Remoto) - INPE, Maio 1999. Disponível em: <<http://mtc-m12.sid.inpe.br/rep/6qtX3pFwXQZ3r59YD6/GNV4p?ibiurl.backgroundlanguage=pt-BR>> Acesso em setembro 2021.

TRINDADE E IARMUL. **O uso de imagens de satélite Sentinel-2 na análise de impactos ambientais: um caso de incêndio no Parque Estadual de Vila Velha**, Ponta Grossa, Paraná. 2018.

VIANA E ZANIRATO. As quebradeiras de coco babaçu e o avanço da fronteira agrícola no oeste do maranhão: dimensões políticas e socioambientais. **IX Jornada de políticas públicas**, Universidade Federal do Maranhão. São Luís – MA, 2019.

VIEIRA, V. C. B.; MOREIRA, M. A.; DANTAS, F. R.; ALENCAR, H. M. Q.; SOUSA, M. F. L. O.; ROCHA, M. E. S. A. Uso de imagens do RapidEye e técnicas de geoprocessamento para mapear o babaçu nas regiões central e norte do Piauí. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 18. (SBSR), 2017, Santos. **Anais...** São José dos Campos: INPE, 2017. p. 4227-4234. Disponível em: <<http://urlib.net/rep/8JMKD3MGP6W34M/3PSM2N5>>. Acesso em Setembro de 2021

XAVIER *et. al.* **Potencial de Imagens Multiespectrais Sentinel 2 na Detecção de Nematoides na Cultura Cafeeira**. R. bras. Geom., Curitiba, v. 7, n. 2, p. 095-114, abr/jun. 2019.

YOURDON, E. **Object-oriented systems design: an integrated approach**. New Jersey: Prentice-Hall. 1994.

APÊNDICES





Apêndice A: Fotos de campo para as coletas de dados em maio de 2021.