

GÉSSYCA FERNANDA DE SENA OLIVEIRA

**USO DE TÉCNICAS DE SENSORIAMENTO REMOTO PARA ESTIMAR
VARIÁVEIS BIOFÍSICAS EM FLORESTA TROPICAL SECA, NO MUNICÍPIO DE
FLORESTA - PE**

**RECIFE - PE
2020**

GÉSSYCA FERNANDA DE SENA OLIVEIRA

**USO DE TÉCNICAS DE SENSORIAMENTO REMOTO PARA ESTIMAR
VARIÁVEIS BIOFÍSICAS EM FLORESTA TROPICAL SECA, NO MUNICÍPIO DE
FLORESTA – PE**

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Florestais da Universidade Federal Rural de Pernambuco, como parte das exigências para obtenção do título de Mestre em Ciências Florestais, Área de Concentração: Biometria e Manejo Florestal.

Orientador: Prof. Dr. Emanuel Araújo Silva

Coorientadores: Prof. Dr. Rinaldo Luiz Caraciolo Ferreira

Profa. Dra. Werônica Meira de Souza

**RECIFE - PE
2020**

“Permitida a cópia total ou parcial deste documento, desde que seja para fins acadêmicos ou científicos, e citada a fonte – O autor”

Dados Internacionais de Catalogação na Publicação (CIP)

Sistema Integrado de Bibliotecas da UFRPE
Biblioteca Central, Recife-PE, Brasil

O48u Oliveira, Géssyca Fernanda de Sena
Uso de técnicas de sensoriamento remoto para estimar variáveis biofísicas em floresta tropical seca, município de Floresta – PE / Géssyca Fernanda de Sena Oliveira. – 2020.
84 f. : il.

Orientador: Emanuel Araújo Silva.
Dissertação (Mestrado) – Universidade Federal Rural de Pernambuco, Programa de Pós-Graduação em Ciências Florestais, Recife, BR-PE, 2020.
Inclui referências.

1. Florestas tropicais – Floresta (PE) 2. Sensoriamento remoto
3. Caatinga 4. Florestas tropicais - Manejo 5. Regiões áridas.
6. LANDSAT (satélites) I. Silva, Emanuel Araújo, orient. II. Título

CDD 634.9

GÉSSYCA FERNANDA DE SENA OLIVEIRA

**USO DE TÉCNICAS DE SENSORIAMENTO REMOTO PARA ESTIMAR
VARIÁVEIS BIOFÍSICAS EM FLORESTA TROPICAL SECA, NO MUNICÍPIO DE
FLORESTA – PE**

APROVADA em 21 de Fevereiro de 2020.

Banca Examinadora

Prof. Dr. César Augusto Guimarães Finger
(Universidade Tecnológica Federal do Paraná – UTFPR)

Profa. Dra. Elisiane Alba
(Universidade Federal Rural do Pernambuco – UFRPE/UAST)

Orientador

Prof. Dr. Emanuel Araújo Silva
(Universidade Federal Rural do Pernambuco – UFRPE/PPGCF)

DEDICATÓRIA

*À minha super Mãe,
aos meus avós, Das Dores e Floriano Sena (in
memoriam) e aos meus padrinhos, Vitória
Sena e Emilson Costa (in memoriam),
Dedico.*

“Nada é tão nosso quanto os nossos sonhos.”

Friedrich Nietzsche

AGRADECIMENTOS

Considerando que este trabalho é o resultado de uma caminhada árdua e cansativa, cheia de altos e baixos, aprendizados, desesperos, sorrisos, angústias e muita amizade envolvida, em que o fator limitante sempre foi o tempo, agradecer pode não ser tarefa fácil, nem justa. Então, para não correr o risco da injustiça, agradeço a todos que passaram por minha vida neste período e contribuíram de alguma forma para a construção desse trabalho, deixando um pedacinho de si e levando um pouco de mim, me permitindo evoluir para o ser humano e profissional que sou hoje.

Agradeço em particular:

A Deus, por me conceder proteção, coragem e sabedoria, abençoando cada passo, cada decisão;

À UFRPE e ao Programa de Pós-Graduação em Ciências Florestais (PPGCF), pelo ensino e condições de trabalho;

À Fundação de Amparo à Ciência e Tecnologia do Estado de Pernambuco (FACEPE), pela bolsa concedida durante esses 2 anos;

Ao meu orientador Dr. Emanuel Araújo Silva, pelo apoio científico, incentivo e amizade ao longo deste percurso;

Aos meus coorientadores Dr. Rinaldo Luiz Caraciolo Ferreira e Dra. Werônica Meira de Souza, pela contribuição e apoio na condução deste trabalho, aos professores do PPGCF pelos conhecimentos compartilhados e convívio ao longo desse tempo e à secretária Juliana Ferreira, por sua amizade, empatia e paciência;

Aos fortes laços de irmandade criados com o melhor estatístico, Wesley Lima, com o parceiro incrível de artigos, Jorge Monteiro, com o aperreio diário Anderson Silva (Mago), com o BFF, Adriano Castelo, que me auxiliou em todas as etapas do Mestrado e foi uma das pessoas que mais contribuíram para a minha aprovação no Doutorado, sem esquecer das cientistas mais “topzeiras” do mundo, Giselle Lemos e Gabriela Salami, que também foram essenciais nesta etapa, além de Tamires Leal, Lorena Moura e Mayara Pessoa. Que sorte a minha encontrá-las nesta caminhada e poder chamá-las de irmãs.

Aos mateiros Demir e Galego, pois, apesar da coleta de dados na Caatinga acontecer sob um sol escaldante, foi muito gratificante porque vocês estavam lá e fizeram de uma obrigação algo prazeroso e divertido;

Aos amigos dos Laboratórios: LASER, LABIOM e LMFN por todos os momentos de alegrias e de desesperos compartilhados;

A Joselane Priscila, pelo apoio e amizade;

Aos amigos Sidney Campelo, pelos conhecimentos compartilhados, e Ouorou Guera, por toda ajuda e paciência aos 45 minutos do segundo tempo com as estatísticas finais;

À minha mãezinha, Graça Sena, por seu imensurável amor, incentivo aos estudos e por compreender os estresses e ausências ao longo dessa trajetória. Foi a sua mão que segurou a minha quando eu tentei dar os primeiros passinhos, a mesma mão que ergueu a minha cabeça após algumas experiências saírem diferente do planejado e quem mostrou o caminho mais sábio a trilhar. A senhora me segurou no colo, me carregou nos ombros, mas também me ensinou a caminhar sozinha. Ensinou-me a ser forte, independentemente da situação, e, se hoje estou na estrada, trilhando caminhos bonitos, você bem sabe que isso é obra sua! Sinto muito orgulho do ser humano que me tornei e mais ainda da senhora, a principal responsável por tudo que sou e por tudo que ainda pretendo ser. Serei eternamente grata por cumprires com tanta excelência o papel de mãe e pai. Quem me dera, se por um descuido, Deus te fizesse eterna;

Ao meu noivo, cúmplice nos sonhos e metas de vida Kleibson Mergulhão, pela paciência, amor e incentivo nos momentos mais difíceis dessa caminhada;

À minha família querida e aos amigos preciosos que sempre torceram e acreditaram no meu potencial.

MUITO OBRIGADA!!!

Sem vocês, nada disso seria possível.

Desejo muita luz no coração e fé na vida, porque no fim SEMPRE dá certo!

OLIVEIRA, GÉSSYCA FERNANDA DE SENA, Uso de técnicas de sensoriamento remoto para estimar variáveis biofísicas em Floresta Tropical Seca, no município de Floresta – PE. 2020. Orientador: Emanuel Araújo Silva. Coorientadores: Rinaldo Luiz Caraciolo Ferreira e Werônica Meira de Souza.

RESUMO

O uso de técnicas de Sensoriamento Remoto para auxiliar o inventário florestal convencional vem sendo impulsionados com o intuito de moderar a necessidade de trabalhos de campo, reduzir tempo e custos. Desse modo, o presente trabalho tem por principal objetivo avaliar o potencial do uso de ferramentas de sensoriamento remoto para estimar as variáveis biofísicas volume, biomassa e carbono em Floresta Seca no Nordeste do Brasil. A área de estudo está localizada na Fazenda Itapemirim, município de Floresta – PE, onde dois fragmentos com diferentes históricos de uso foram analisados em diferentes épocas do ano, sendo denominados de Área I (Transposição), aquele considerado preservado, e de Área II (Correntão), aquele considerado degradado, pois sua vegetação foi retirada com o auxílio de correntões há, aproximadamente, 34 anos para fins de manejo florestal. Avaliou-se 40 parcelas em cada área com dimensões 20 m x 20 m (400 m²), totalizando 3,2 ha de área amostrada. Utilizou-se cenas dos meses de abril/2018 e agosto/2018 do satélite Landsat 8/OLI, na órbita/ponto: 216-66, referentes ao período úmido e seco, respectivamente. Essas cenas foram convertidas para reflectância de superfície a partir da calibração radiométrica e, posteriormente, gerados os índices de vegetação GNDVI, NDVI, SR, SAVI_{L=0,5}, DVI, MVI, ARVI, LAI, GVI, GARI, EVI e GEMI. As bandas multiespectrais, bem como os índices de vegetação (IV), foram relacionados ao volume, biomassa e carbono florestal estimados a partir de dados dendrométricos mensurados em igual período de passagem do Landsat 8/OLI. Os dados foram ajustados ao modelo de regressão linear múltipla, conduzindo a seleção de variáveis por meio do método Stepwise. Considerou-se os critérios estatísticos Coeficiente de Determinação Ajustado (R^2_{aj}), Erro Padrão da Estimativa (S_{xy} %) e o gráfico de Distribuição dos Resíduos ($Res_{(%)}$) para selecionar as melhores equações. A análise estatística foi realizada no *software* R® versão 3.6.1. O período seco foi o mais indicado para estimar variáveis biofísicas, utilizando imagens orbitais e técnicas de sensoriamento remoto em Floresta Tropical Seca (FTS). As melhores equações para estimar volume, biomassa e carbono obtiveram um R^2_{aj} de 0,634, 0,650 e 0,649 e um S_{xy} de 44,894%, 6,030% e 6,842%, respectivamente. Biomassa e carbono apresentaram melhores ajustes após logaritmizar os IVs com valores positivos, enquanto volume demonstrou um comportamento contrário. Os índices de vegetação EVI e SAVI_{L=0,5} não demonstraram ser apropriados para estimar as variáveis biofísicas, independentemente da sazonalidade, enquanto que NDVI mostrou-se eficiente apenas em estação úmida. Logo, observando as devidas restrições e as equações com o melhor ajuste estatístico, bem como os gráficos de resíduos, infere-se que é possível utilizar imagens do Landsat 8/OLI para fazer estimativas sobre parâmetros florestais, demonstrando a importância e aplicabilidade desse método para a estimativa de variáveis biofísicas em FTS, bem como ações de manejo e conservação do Domínio Caatinga.

Palavras-chave: Caatinga, manejo florestal, semiárido, Landsat 8, geoprocessamento.

OLIVEIRA, GÉSSYCA FERNANDA DE SENA. Using remote sensing techniques to estimate biophysical variables in the dry tropical forest, in the municipality of Floresta – PE. 2020. Advisor: Emanuel Araújo Silva. Co-advisors: Rinaldo Luiz Caraciolo Ferreira and Werônica Meira de Souza.

ABSTRACT

The use of Remote Sensing techniques to assist the conventional forest inventory has been promoted to moderate the need for fieldwork, reducing time and costs. Therefore, the present work has as main objective to evaluate the potential of using remote sensing tools to estimate the biophysical variables volume, biomass, and carbon in Dry Forest in the Northeast of Brazil. The study area is located at the Itapemirim Farm, municipality of Floresta – PE. In this area we have two fragments, with different usage background, were analyzed at different times of the year, being called Area I (Transposition) the one considered preserved and Area II (Chaining) the one considered degraded since its vegetation was removed with the help of chains for approximately 34 years for forest management purposes. 40 plots in each area with dimensions 20 m x 20 m (400 m²) were evaluated, totaling 3.2 ha of the sampled area. Scenes from the months of April/2018 and August/2018 of the satellite Landsat 8 / OLI were used, in orbit/point 216-66, referring to the wet and dry period, respectively. These scenes were converted to surface reflectance from the radiometric calibration and, subsequently, the GNDVI, NDVI, SR, SAVI_{L=0,5}, DVI, MVI, ARVI, LAI, GVI, GARI, EVI and GEMI vegetation indices were generated. The multispectral bands, as well as the vegetation indices (IV), were related to the volume, biomass, and forest carbon estimated from dendrometric data measured in the same passage period of Landsat 8 / OLI. The data were fitted to the multiple linear regression model, leading to the selection of variables using the Stepwise method. The adjusted Criteria of Determination Coefficient (R^2_{aj}), Standard Error of the Estimate (S_{xy}), and the Graph of Waste Distribution (Res (%)) were used to select the best equations. Statistical analysis was performed using software R® version 3.6.1. The dry period was the most suitable to estimate biophysical variables using orbital images and remote sensing techniques in Tropical Dry Forest (TDF). The best equations for estimating volume, biomass, and carbon obtained a R^2_{aj} of 0.634, 0.650 and 0.649, and a S_{xy} of 44.894%, 6.030%, and 6.842%, respectively. Biomass and carbon showed better adjustments after logarithmizing the IVs with positive values, while volume showed an opposite behavior. The vegetation indices EVI and SAVI_{L = 0.5} did not prove to be appropriate to estimate the biophysical variables, regardless of seasonality, while NDVI was efficient only in the wet season. Therefore, observing the due restrictions and the equations with the best statistical adjustment, as well as the residual graphs, it appears that it is possible to use Landsat 8/OLI images to make estimates of forest parameters, demonstrating the importance and applicability of this method for the estimation of biophysical variables in TDF, as well as management and conservation actions in the Caatinga Domain.

Keywords: Caatinga, forest management, semiarid, Landsat 8, geoprocessing.

LISTA DE FIGURAS

Figura 1: Reflectância espectral e as características da folha vegetal verde sadia para o intervalo de comprimento de onda entre 0,4 e 2,6 μm	28
Figura 2: Fluxograma da metodologia aplicada no estudo.....	40
Figura 3: Localização e distribuição das unidades amostrais na Fazenda Itapemirim, município de Floresta, PE.	41
Figura 4: Acumulações anuais (mm) dos últimos 16 anos em Floresta, PE, Brasil.....	42
Figura 5: Assinatura espectral da vegetação dos fragmentos avaliados, com dados do satélite Landsat 8, no Período Seco e Úmido, município de Floresta – PE (2018).	52
Figura 6: Distribuição dos resíduos percentuais em relação às variáveis volume, biomassa e carbono para Área I, nos períodos seco e úmido, Floresta – PE.....	56
Figura 7: Distribuição dos resíduos percentuais em relação às variáveis volume, biomassa e carbono para Área II, nos períodos seco e úmido, Floresta – PE.	61
Figura 8: Espacialização da variável Volume (m^3/ua), para as Áreas I e II, nos períodos seco e úmido, Floresta – PE.	65
Figura 9: Espacialização da variável Biomassa (kg/ua), para as Áreas I e II, nos períodos seco e úmido, Floresta – PE.	66
Figura 10: Espacialização da variável Carbono (kg/ua), para as Áreas I e II, nos períodos seco e úmido, Floresta – PE.	66

LISTA DE TABELAS

Tabela 1: Características espectrais, espaciais e temporais das bandas do satélite Landsat 8/OLI.	30
Tabela 2: Equações para estimativa do estoque de biomassa seca para oito espécies características de Floresta Tropical Seca, município de Floresta, Pernambuco, Brasil.	44
Tabela 3: Fatores de conversão para a estimativa do estoque de carbono a partir da biomassa seca para oito espécies características de Floresta Tropical Seca, município de Floresta, Pernambuco, Brasil.	45
Tabela 4: Índices de Vegetação utilizados neste estudo.	47
Tabela 5: Equações e medidas de precisão, para a Área I, utilizando as imagens do satélite Landsat 8/OLI para os períodos seco e úmido, Floresta, PE.	54
Tabela 6: Equações e medidas de precisão, para a Área II, utilizando as imagens do satélite Landsat 8/OLI, para os períodos seco e úmido, Floresta-PE.	58

LISTA DE SIGLAS, ABREVIATURAS E SÍMBOLOS

APAC	Agência Pernambucana de Águas e Clima
APG	<i>Angiosperm Phylogeny Group</i>
ARVI	<i>Atmospherically Resistant Vegetation Index</i>
BOA	<i>Bottom-Of-Atmosphere</i>
CAP	Circunferência à Altura do Peito
DAP	Diâmetro à Altura do Peito
DVI	<i>Difference Vegetation Index</i>
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
ESA	<i>European Space Agency</i>
EVI	<i>Enhanced Vegetation Index</i>
FTS	Floresta Tropical Seca
GARI	<i>Green Atmospherically Resistant Vegetation Index</i>
GEMI	<i>Global Environmental Monitoring Index</i>
GNDVI	<i>Green Normalized Difference Vegetation Index</i>
GPS	<i>Global Positioning System</i>
GVI	<i>Green Vegetation Index</i>
LAI	<i>Leaf Area Index</i>
IBGE	Instituto Brasileiro de Geografia e Estatística
LANDSAT	<i>Land Remote Sensing Satellite</i>
LIDAR	<i>Light Detection and Ranging</i>
MVI	<i>Moisture Vegetation Index</i>
NASA	<i>National Aeronautics and Space Administration</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
NIR	<i>Near Infrared</i>
OLI	<i>Operational Land Imager</i>
SAVI	<i>Soil Adjusted Vegetation</i>
SR	<i>Simple Ratio</i>
SWIR	<i>Short Wave Infrared</i>
TIRS	<i>Thermal Infrared Sensor</i>
TM	<i>Thematic Mapper</i>
TOA	<i>Top-Of-Atmosphere</i>
USGS	<i>United State Geological Survey</i>
UTM	<i>Universal Transversa de Mercator</i>

SUMÁRIO

1. INTRODUÇÃO	14
2. OBJETIVO	17
2.1 GERAL.....	17
2.2 ESPECÍFICOS	17
3. REVISÃO DE LITERATURA	18
3.1 FLORESTAS TROPICAIS SECAS	18
3.2 INVENTÁRIO FLORESTAL E AMOSTRAGEM SISTEMÁTICA.....	20
3.3 VOLUME EM FTS	22
3.4 ESTOQUES DE BIOMASSA E CARBONO ACIMA DO SOLO EM FTS	24
3.5 SENSORIAMENTO REMOTO APLICADO A ESTUDOS FLORESTAIS	26
3.5.1 Satélite LANDSAT 8/OLI	29
3.5.2 Índices de Vegetação.....	30
4. MATERIAL E MÉTODOS	40
4.1 CARACTERIZAÇÃO DA ÁREA DE ESTUDO	40
4.2 ESTIMATIVAS OBTIDAS A PARTIR DO INVENTÁRIO CONVENCIONAL	43
4.2.1 Amostragem e coleta de dados.....	43
4.2.2 Estimativa de Volume	43
4.2.3 Estimativa de Biomassa e Carbono.....	43
4.3 ESTIMATIVAS OBTIDAS A PARTIR DE DADOS ORBITAIS	45
4.3.1 Aquisição e processamento das imagens orbitais	45
4.3.2 Ajuste dos modelos para estimar volume, biomassa e carbono com dados orbitais	48
4.4 ESPACIALIZAÇÃO DAS VARIÁVEIS	49
5. RESULTADOS E DISCUSSÃO	50
5.1 ASSINATURA ESPECTRAL DA VEGETAÇÃO	50
5.2 ESTIMATIVAS DE VOLUME, BIOMASSA E CARBONO EM FTS.....	53
5.3 ESPACIALIZAÇÃO DAS VARIÁVEIS BIOFÍSICAS	65
6. CONCLUSÕES.....	67
7. RECOMENDAÇÕES	69
REFERÊNCIAS	70

1. INTRODUÇÃO

As florestas desempenham funções de suma importância para a manutenção dos ciclos biogeoquímicos e, conseqüentemente, para a vida no planeta. Elas produzem bens de ordem econômica, social e ambiental e protegê-las é uma questão de estratégia para a perpetuação da espécie humana. No entanto, apesar de muitos de seus recursos já se encontrarem no limiar de seus estoques, eles permanecem sendo explorados de tal maneira que a natureza não consegue repor. Esse fato vem gerando uma preocupação entre os profissionais da área e, por isso, estudos relacionados aos impactos ambientais alcançaram extensa notoriedade na última década (LIU *et al.*, 2013).

As Florestas Tropicais Secas (FTS) estão entre as fitofisionomias mais ameaçadas e menos estudadas do mundo (GILLESPIE *et al.*, 2012). Em virtude desse status de conservação eminentemente ameaçado, bem como a escassez de estudos sobre a sua flora e ecologia, requerem maior atenção no intuito de obter mais informações acerca do seu potencial produtivo (RODRIGUES *et al.*, 2015).

A Caatinga representa uma das FTS do mundo e está inserida na Região Nordeste. Possui cerca de 28,6 milhões de pessoas, a maioria de baixa renda e totalmente dependente dos seus recursos naturais (IBGE, 2010), o que justifica a exploração ilegal e não sustentável dos recursos lenhosos que são utilizados para as mais diversas finalidades, sobretudo domésticas, industriais, energéticas, pastoreio e conversão das áreas de floresta em agricultura.

É evidente que o uso inadequado de terras acarreta perda de biodiversidade e reduz os recursos ecossistêmicos que sustentam a população carente (EMBRAPA, 2001). No entanto, a falta de fiscalização por parte das autoridades competentes acaba por favorecer a exploração predatória e excessiva, desencadeando um processo conhecido como desertificação, geralmente irreversível, onde áreas anteriormente produtivas se tornam zonas áridas e inférteis.

Os benefícios relacionados ao monitoramento periódico sobre o comportamento de uma floresta são notórios, especialmente no que se refere ao ganho de produtividade, uma vez que conhecer suas propriedades biofísicas, os danos causados por múltiplos fatores, sejam eles naturais ou antrópicos, permite desenvolver estratégias de manejo e intervenções

adequadas que poderão subsidiar o planejamento da exploração (TILLACK *et al.*, 2014). Apesar de o Inventário Florestal convencional avaliar as potencialidades e capacidades produtivas dos recursos florestais de um povoamento, sua execução implica elevados investimentos, tempo e mão-de-obra. Além disso, deve-se levar em consideração a dimensão territorial da área a ser inventariada, bem como a sua localização, visto que, quando muito extensa, dificulta a periodicidade das avaliações, prejudicando o monitoramento regular.

Estimativas do volume de madeira, da biomassa remanescente e explorável e do carbono estocado de uma floresta servem para auxiliar a tomada de decisões. Porém, essas estimativas são realizadas de forma destrutiva, com uma grande demanda de tempo e capital. Segundo Alba *et al.* (2017), com o avanço das técnicas de processamento digital de imagens e a crescente disponibilidade de dados de sensoriamento remoto, foram desenvolvidos métodos indiretos para estimar variáveis e monitorar áreas verdes, evidenciando avanços extraordinários na modelagem, no mapeamento e, também, na compreensão dos ecossistemas florestais.

Nas últimas décadas, o aperfeiçoamento das geotecnologias, assim como a expansão de estudos intrínsecos à aplicação de técnicas de sensoriamento remoto para auxiliar o Inventário Florestal convencional, estão sendo impulsionados e ganhando destaque (ZANDONÁ; LINGNAU; NAKAJIMA, 2008). O objetivo é, sobretudo, moderar e, até mesmo descartar, a necessidade de trabalhos *in loco*, reduzir o tempo de obtenção e análise dos dados, incrementar a precisão das estimativas, e, ainda, auxiliar no planejamento e alocação das unidades amostrais.

O *Operational Land Imager* (OLI) é um dos sistemas sensores a bordo do satélite Landsat 8 e dispõe das faixas do visível, infravermelho próximo e infravermelho de ondas curtas, além de uma banda pancromática. Melhorias nas imagens do Landsat 8 são notórias quando comparadas aos produtos de seus antecessores. Isso se deve ao aumento do número de bandas espectrais, mas, principalmente, ao aumento da resolução radiométrica, que proporciona uma detecção mais detalhada dos alvos em função de uma maior distribuição dos níveis de cinza.

Mediante o exposto, nota-se que a pesquisa apresenta elevado potencial na obtenção de informações pertinentes a variáveis florestais. Logo, irá contribuir acerca de informações

relevantes sobre o manejo florestal neste tipo de fitofisionomia, subsidiar projetos de conservação, recuperação e monitoramento, e, ainda, servir de suporte para a implantação de políticas públicas e privadas no semiárido pernambucano.

Dentro do contexto, o presente trabalho fundamenta-se nas seguintes hipóteses: (i) É possível obter estimativas confiáveis de volume, biomassa e carbono utilizando imagens espectrais do sensor OLI/Landsat 8; e (ii) Os dados espectrais oriundos do sensor OLI são sensíveis às variações estruturais da vegetação seca, em função do histórico de uso, como também da sazonalidade.

2. OBJETIVO

2.1 GERAL

Avaliar o potencial do uso de ferramentas de sensoriamento remoto para estimar as variáveis biofísicas volume, biomassa e carbono em Floresta Tropical Seca no Nordeste do Brasil.

2.2 ESPECÍFICOS

- Caracterizar o comportamento espectral da vegetação a partir da relação oriunda da resposta espectral das bandas B2, B3, B4, B5, B6 e B7 com os diferentes históricos de uso e sazonalidade;
- Ajustar o modelo de regressão linear múltipla tendo como variáveis dependentes o volume (m³), a biomassa (kg) e o carbono (kg) estocados em Floresta Tropical Seca, e, os dados espectrais como variáveis independentes;
- Analisar o nível de detalhamento com que as variáveis biofísicas são estimadas a partir de dados das imagens Landsat 8/OLI; e
- Espacializar o volume, a biomassa e o carbono a partir das equações ajustadas, em função de variáveis espectrais.

3. REVISÃO DE LITERATURA

3.1 FLORESTAS TROPICAIS SECAS

As Florestas Tropicais Secas (FTS) recobrem cerca de 41,5% da superfície terrestre (BLACKIE *et al.*, 2014; BASTIN *et al.*, 2017). Essas florestas são classificadas como perturbadas, pois apresentam aspectos morfológicos, geológicos, climáticos e fitossociológicos bem distintos de ambientes ecológicos considerados prístinos (MURPHY; LUGO, 1986).

A principal característica da vegetação desse tipo de floresta é a sua adaptabilidade ao estresse hídrico, tal como a elevadas temperaturas (PULLA *et al.*, 2015). Localizadas próximas à linha do Equador, a precipitação costuma oscilar entre 500 e 1000 mm ao ano, com estação seca compreendida entre 5 a 8 meses e temperatura média superior a 20°C no mês mais frio (BLACKIE *et al.*, 2014).

O domínio Caatinga, FTS brasileira, é a formação florestal mais evidente na Região Nordeste, possuindo uma extensão territorial de 844.453 km², equivalente a 55% da região e 11% do território nacional (BRASIL, 2014). Caracterizada por altos níveis de radiação solar, em virtude da sua posição geográfica em relação ao Equador, a Caatinga apresenta, por conseguinte, elevadas taxas de evapotranspiração e baixas taxas de precipitação, que oscilam entre 1500-2000 mm ano⁻¹ e 300-1000 mm ano⁻¹, respectivamente (LOPES *et al.*, 2015).

A vegetação é classificada, segundo o IBGE (2012), como savana estépica, marcada fortemente pela sazonalidade climática, bastante singular e resistente, uma vez que apresenta morfologia e mecanismo fisiológico em concordância com o ambiente seco e a umidade disponível é proveniente de um período pouco expressivo da estação chuvosa.

A fauna e flora são bastante afetadas devido à inexistência de um plano de manejo e de fontes alternativas que visem suprir a demanda de matéria prima na região. Apresenta grande potencial para as mais diversas finalidades, mas, para Silva *et al.* (2004), esse domínio não é priorizado quando se trata de políticas públicas que visam o estudo de suas potencialidades e a conservação da biodiversidade.

As características do solo, assim como as condições climáticas, não permitem acumular água por um longo período (SOUTO *et al.*, 2009). Sampaio (2006) considerou a

indisponibilidade hídrica como o principal fator responsável pela variabilidade ambiental no semiárido nordestino. Embora seja comumente apontada como um Domínio Morfoclimático exclusivamente brasileiro por diversos autores da atualidade, fitofisionomias semelhantes são encontradas no sul do México, sudeste da África, Índia Central, Austrália, leste da Bolívia e ao longo das costas do Equador e Peru (LEBRIJA-TREJOS *et al.*, 2010; WWF, 2018).

Um dos fenômenos mais surpreendentes da Caatinga é a perda da folhagem no período de estiagem de grande parte das espécies e sua recuperação exuberantemente rápida no período das chuvas (GUIMARÃES, 2009).

A agropecuária intensiva, a exploração predatória dos recursos madeireiros para serem utilizados como fonte energética, assim como as queimadas descontroladas, têm acarretado muitos impactos ambientais, que associados à baixa capacidade de regeneração dos solos do semiárido, bem como da agressividade climática (SOUZA *et al.*, 2009), poderão culminar no aumento da susceptibilidade à desertificação e à consequente formação de áreas degradadas (MELO *et al.*, 2008; RIBEIRO *et al.*, 2009; SOUSA *et al.*, 2012).

Cerca de um terço da demanda de lenha por indústrias da região Nordeste, para serem utilizadas como fonte de energia, é proveniente do desmatamento ilegal (INSA, 2015; AMÉRICO, 2018). Azevedo *et al.* (2012) ressaltam que a recuperação de áreas na região semiárida é uma preocupação constante de pesquisadores da região Nordeste.

Geralmente, as FTS apresentam uma menor variabilidade quando comparadas às úmidas (GENTRY, 1988), fato este fortemente influenciado pelo estresse hídrico, em virtude das chuvas irregulares e elevadas temperaturas, resultando numa vegetação dominada por espécies espinhosas e suculentas (JOLY *et al.*, 1999). No entanto, definições relacionadas às formações vegetais classificadas como FTS ainda são contraditórias (KORTZ, 2012). A Caatinga, da mesma forma que as Florestas Estacionais Deciduais e Semideciduais do Domínio Cerrado, se encontra inclusa nessa classificação (GONÇALVES, 2015).

Ainda que provida de solo raso, pedregoso e com fertilidade relativamente baixa, a fauna e flora da Caatinga são bastante diversificadas, corroborando com sublime riqueza biológica e múltiplas espécies endêmicas (ALVES *et al.*, 2017). Blackie *et al.* (2014) ressaltaram a importância desse tipo de floresta e a classifica como uma das fitofisionomias mais ameaçadas do mundo, enfatizando a urgência por estudos interdisciplinares sobre as

FTS. Segundo Trovão *et al.* (2007), o estudo desses ambientes áridos representa um dos grandes e complexos desafios do conhecimento científico brasileiro.

3.2 INVENTÁRIO FLORESTAL E AMOSTRAGEM SISTEMÁTICA

A avaliação do potencial florestal de um ecossistema é constituída a partir do conhecimento de seus produtos em prol da sociedade, seja de valor econômico, ambiental ou social (GAMA *et al.*, 2007). O autor enfatiza ainda que a madeira é considerada um recurso florestal de suma importância para o homem, uma vez que produz uma grande amplitude de bens diretos e indiretos, intensificando a necessidade de procedimentos que sejam eficientes para quantificar e avaliar os maciços florestais.

O processo de coleta de dados no intuito de obter conhecimento sobre um maciço florestal se baseia em roteiros pré-estabelecidos denominados de inventários florestais. Binoti (2012) define o inventário florestal como o conjunto de informações que apresentam metodologias de coleta e processamento de dados específicos, a depender do tipo de floresta e dos objetivos pretendidos, como nos processos de cubagem e estimativa de volume. Há alguns anos, ele era executado no Brasil por meio de um simples levantamento dos indivíduos de grande porte, susceptíveis à exploração, porém resultava numa visão incompleta e distorcida das reais condições de desenvolvimento da floresta (REIS *et al.*, 1994).

Segundo Husch *et al.* (1993), o inventário florestal é um procedimento que permite obter informações sobre os parâmetros quantitativos e qualitativos de uma floresta, além de possibilitar inferências sobre as áreas do entorno. Dentre os quantitativos, os principais são volume, biomassa e carbono estocado. Quanto aos tipos de inventário, estes diferem conforme o objetivo proposto para efetuar a realização do levantamento, podendo abranger interesses específicos de uma empresa florestal ou de uma instituição de pesquisa. De acordo com Hosokawa e Souza (1987), o principal objetivo de um levantamento é fornecer as melhores estimativas sobre uma população, e não apenas uma estimativa exata do erro amostral.

De acordo com Péllico Netto e Brena (1993), o inventário florestal fornece dados sobre o potencial produtivo de uma floresta, que permitem planejá-la adequadamente. As amostras da área a ser inventariada devem ser selecionadas de modo que seja possível obter, posteriormente, inferências fidedignas sobre a população, as quais são evidenciadas, se a parte

selecionada for uma verdadeira representação da população analisada. No entanto, o sistema de amostragem escolhido é de suma importância para garantir o sucesso do empreendimento, visto que deverá permitir, através de cálculos estatísticos, estimativas biofísicas precisas sobre a população em estudo (VEIGA, 1984).

Grande parte dos trabalhos de mensuração florestal é realizada por amostragem, considerando um conjunto de amostras que teve suas características dendrométricas mensuradas *in loco* (FICK, 2011). A partir dessas medidas, são obtidos os estimadores, que podem ser correlacionados com dados espectrais.

Os processos de amostragem são distinguidos quanto à maneira que abordam ou fazem inferências sobre uma população em função de um conjunto de unidades amostrais. Na amostragem sistemática, as amostras são selecionadas a partir de um rígido esquema, recobrando toda a extensão da população, uma vez que apenas a primeira é selecionada de forma aleatória (SOARES *et al.*, 2011). É a partir dela que as demais são selecionadas e distribuídas ao longo da área de estudo.

A amostragem pode ser resumida, portanto, como um instrumento básico utilizado para avaliar estatisticamente as potencialidades e capacidades produtivas dos recursos florestais de determinado local, tais como o crescimento dos indivíduos, mudanças ocorridas após a exploração florestal, o planejamento da produção e os tratamentos silviculturais.

Os custos do inventário aumentam quando se almeja obter menores erros nas estimativas das variáveis dendrométricas. Essa redução irá depender da fase de planejamento, em que será necessário determinar a intensidade de amostragem, tamanho e forma das unidades amostrais. No entanto, Binoti (2014) afirma que as técnicas e ferramentas de sensoriamento remoto podem ser uma excelente alternativa auxiliar para alcançar o objetivo pretendido e ressalta a importância do uso de variáveis de fácil obtenção para ajustar modelos preditivos. Sá *et al.* (2008) observaram que os dados referentes ao levantamento da estrutura florestal *in loco*, quando correlacionados àqueles oriundos de sensores remotos, proporcionam maior precisão nas estimativas, aumento na qualidade das inferências sobre o maciço florestal, além da redução do erro.

Decisões importantes sobre a viabilidade de empreendimentos florestais, principalmente àqueles que demandam altos investimentos, tomam como referência os

resultados obtidos por meio de inventários florestais. As equações propostas neste trabalho prometem reduzir os custos inerentes ao processo de inventário e amostragem, já que podem estimar valores precisos e confiáveis a partir de dados derivados de imagens espectrais e vir a auxiliar nas estimativas de volume, biomassa e carbono de uma floresta.

3.3 VOLUME EM FTS

O volume de madeira representa uma das variáveis biofísicas mais importantes da floresta e monitorá-lo é uma das principais tarefas dos planos regionais de manejo florestal. Thomas *et al.* (2006) e Cunha (2004) concordam que é uma das informações mais pertinentes ao entendimento do potencial produtivo de um maciço florestal e, de acordo com Barros *et al.* (2015), a sua correta avaliação permite planejar novos investimentos, modernizar tratos culturais e, por conseguinte, otimizar resultados simultaneamente à redução de custos. No entanto, estudos específicos sobre volumetria e modelagem de FTS, tal qual suas espécies, são escassos, sobretudo quando se trata de FTS brasileiras (SAMPAIO *et al.*, 2010).

Segundo Campos e Leite (2006), o estudo volumétrico intrínseco às espécies de folhosas nativas geralmente estimam apenas o volume comercial do fuste. No entanto, eles tendem a ser menos expressivos quando se trata de formações savânicas do Cerrado (RUFINI *et al.*, 2010) e de Caatinga (SILVA, 2006). Silva e Santana (2014) afirmaram que o volume de madeira oriundo de florestas nativas vem sofrendo uma redução, acarretando a elevação dos preços dessa matéria prima. Quando se trata de Caatinga, essa redução é ainda mais acentuada, devido à inexistência de um Plano de Manejo Sustentável (PMS) e à pouca fiscalização por parte das autoridades ambientais competentes (GARIGLIO, 2015).

Objetivando ajustar modelos volumétricos para estimar o volume total com casca da vegetação de Caatinga, Silva (2006) cubou 100 árvores de dez espécies e ajustou o modelo de Schumacher e Hall (1933), utilizando o diâmetro à altura do solo e o diâmetro equivalente para as árvores que apresentaram dois ou mais fustes, na forma logaritimizada. Segundo Miranda *et al.* (2011), experiências com modelagem matemática, no que se refere às espécies florestais nativas, se restringe aos modelos de volume.

A determinação do volume de uma floresta pode ser feita por métodos diretos (destrutivos), constituindo um processo oneroso e que necessita de mão-de-obra intensiva

(TESFAMICHAEL *et al.*, 2010), ou indiretos (não destrutivos), ao empregar equações alométricas e técnicas de sensoriamento remoto para calcular as estimativas desejadas (SANQUETTA; BALBINOT, 2004). O modelo de Schumacher e Hall (1933), para estimar volume, é apontado como um dos clássicos da literatura florestal (SILVA; PAULA NETO, 1979; FINGER, 1992; SOARES *et al.*, 2011) e utiliza, como variáveis independentes, o diâmetro e a altura das árvores.

Estimar o volume de um povoamento florestal por meio de técnicas de sensoriamento remoto é considerado um estudo recente. No que se refere à modelagem, as bandas espectrais dos sensores constituem as variáveis preditoras, enquanto o volume florestal, a variável resposta a ser estimada pixel a pixel (SOUSA *et al.*, 2015).

De acordo com Pertille *et al.* (2019), os dados oriundos de sensores vêm mostrando grande contribuição na avaliação e monitoramento florestal, por meio da adição de algum componente espacial relacionado à floresta. Chrysafis *et al.* (2017) afirmaram que os dados espectrais fornecem estimativas precisas referentes às características da vegetação, como volume de madeira, biomassa acima do solo, área basal etc., constituindo, dessa forma, uma ferramenta eficiente e acessível para auxiliar na tomada de decisão (BARROS *et al.*, 2015).

Srivastava *et al.* (1999) desenvolveram uma tabela de volume, ao estudarem imagens do satélite IRS-1B, para obter estimativas de variáveis dendrométricas em povoamentos de *Shoera robusta*. Da mesma forma, outros autores realizaram estudos semelhantes utilizando imagens do sensor Landsat para geração de modelos preditivos de volume em povoamentos florestais (BERRA, 2013; GOERGEN, 2014).

Diversos autores já comprovaram o potencial dos instrumentos sensores para estimar características da vegetação, como o volume, de florestas tropicais úmidas (BANNARI *et al.*, 1995; ROSENQVIST *et al.*, 2003; PALACIOS-ORUETA *et al.*, 2005; LU, 2006; POWELL *et al.*, 2010; DU *et al.*, 2010). Bons resultados foram obtidos em FTS localizadas na América Central (FEELEY *et al.*, 2005; GILLESPIE, 2005; KALACSKA *et al.*, 2005). Entretanto, estudos que envolvam técnicas de sensoriamento remoto e estimativas de variáveis biofísicas ainda são escassos em área de Caatinga, havendo a necessidade de investigar possíveis correlações com outras características da vegetação utilizando dados espectrais.

3.4 ESTOQUES DE BIOMASSA E CARBONO ACIMA DO SOLO EM FTS

Trabalhos que relatam os estoques diretos de biomassa arbórea seca na vegetação da Caatinga são bastante reduzidos, inviabilizando a extrapolação de valores de um local para outro, mesmo quando próximos. Segundo Dalla Lana (2018), as equações de estimativa de biomassa aérea, direta ou indireta, e carbono para áreas de FTS, grupos de espécies, espécies ou diferentes partes da vegetação, são limitadas.

As estimativas de biomassa, a partir de modelos alométricos, propiciam a avaliação das possibilidades energéticas e industriais, principalmente quando o intuito é utilizar toda a árvore (VIRGENS *et al.*, 2017).

Paralelamente à falha relacionada à quantificação da produção biomassa em FTS, o quantitativo do material lenhoso retirado nos processos exploratórios de recursos madeireiros é desconhecido (SAMPAIO *et al.*, 2006).

O ciclo do carbono terrestre tem grande dependência dos ecossistemas florestais (LORENZ; LAL, 2010), que são considerados grandes sumidouros de carbono atmosférico, sendo as florestas tropicais maduras as principais responsáveis por armazenar 471 ± 93 toneladas, valor resultante da soma entre biomassa viva acima e abaixo do solo, madeira morta, serrapilheira e solo, representando cerca de 50% do estoque de carbono estimado para todos os ecossistemas florestais (PAN *et al.*, 2011).

O tipo de manejo que será direcionado para uma área influenciará diretamente nos estoques de carbono na vegetação (DON *et al.*, 2011). Ao multiplicar a biomassa por um fator de carbono predito para determinada área, é possível obter as estimativas da quantidade de carbono incorporado a essa biomassa (DALLAGNOL *et al.*, 2011). Esses valores estimados estão sendo amplamente utilizados e correspondem a um percentual de aproximadamente 50% do peso da biomassa, determinada independentemente do tipo de fitofisionomia, uma vez que consiste numa média resultante dos valores encontrados em diversos trabalhos (XU *et al.*, 2016; BEHERA *et al.*, 2017). Entretanto, os valores médios sugeridos pela literatura nem sempre são ideais e podem, eventualmente, superestimar ou subestimar o estoque de carbono.

As áreas de FTS do mundo apresentam, de uma maneira geral, estoques de biomassa variando de 39 a 334 Mg.ha⁻¹ (BECKNELL *et al.*, 2012). Um estudo de grande contribuição sobre teores de carbono em FTS foi realizado por Chaturvedi *et al.* (2011), que descobriram

que florestas possuintes de um maior diâmetro e mais antigas concentram as maiores quantidades de carbono, enquanto árvores de diâmetros menores a 10 cm podem conter de 2,6% a 8,6% do carbono total acima do solo; quando negligenciado, poderá subestimar o estoque. Ngo *et al.* (2013) confirmaram a influência do diâmetro em Singapura, quando avaliaram os estoques de carbono da biomassa aérea de uma floresta primária com uma secundária de 60 anos, e encontraram percentuais de 49,8% e 38,1%, respectivamente.

Inúmeros fatores estão correlacionados com a dinâmica dos estoques de biomassa e carbono, mas, de acordo com Oliveira (2016), áreas com baixa densidade que tenham predominância de espécies com diâmetros elevados possuam maior contribuição na biomassa aérea e, conseqüentemente, para o carbono.

Chao *et al.* (2017) encontraram um percentual médio de 44% ao investigar a relação da concentração de carbono de árvores vivas com o carbono encontrado em duas florestas tropicais distintas em Taiwan. Teores médios de carbono de 46,7% foram encontrados por Yeboah *et al.* (2014) em espécies tropicais plantadas em Gana na África. Analisando os estoques de carbono da biomassa aérea de formações florestais distintas, Silva *et al.* (2014) encontraram, para a Amazônia mato-grossense, valores médios próximos a 50%.

Vieira *et al.* (2009) encontraram, para uma área de Caatinga no estado da Bahia, um teor médio de carbono de 44,96%. Ou seja, bem próximo do observado por Dalla Lana *et al.* (2019) que, ao avaliar os teores de carbono no interior do estado de Pernambuco, encontraram um percentual na parte aérea de 45,85%, enquanto Pereira-Júnior *et al.* (2016) observaram um teor médio de 44,53% ao estudar um fragmento de Caatinga no Ceará, com 30 anos de regeneração. Valores semelhantes foram registrados em outras áreas de FTS no mundo.

Distúrbios relacionados ao período úmido em FTS provocam alterações na dinâmica na vegetação, sobretudo, contribuindo com o aumento da mortalidade (DICKINSON *et al.*, 2001), prejudicando as estimativas quando realizadas utilizando sistemas sensores, uma vez que haverá uma maior extensão de solo exposto.

Dalla Lana *et al.* (2019) afirmaram que trabalhos relacionados ao quantitativo de teores de carbono em regiões semiáridas no Brasil ainda são escassos. Este fato é justificado pela grande dificuldade em determiná-los (OLIVEIRA, 2016), visto que o método de determinação direto de biomassa exige a derrubada da árvore e separação dos seus

compartimentos vegetais (folhas, galhos, tronco, raiz, etc.). Porém, os valores encontrados seguem os padrões observados para as demais formações florestais do País e o número de trabalhos no mundo que vêm buscando determinar com maior exatidão os teores de carbono disponíveis na biomassa florestal são cada vez maiores.

É notória a importância de estimativas precisas referentes à quantidade de biomassa florestal, utilizando técnicas de sensoriamento remoto no semiárido, tendo em vista que proporcionam o monitoramento periódico de áreas, sejam elas manejadas ou de preservação permanente, a quantificação do estoque de carbono, além de simular cenários de manejo.

3.5 SENSORIAMENTO REMOTO APLICADO A ESTUDOS FLORESTAIS

Atribui-se ao sensoriamento remoto (SR) a capacidade de obter informações sobre um objeto, área ou fenômeno por meio de dados espectrais, adquiridos por um sensor, que não está em contato direto com os alvos estudados (LILLESAN *et al.*, 2015). O avanço das técnicas remotas tem proporcionado um nível maior de detalhes sobre as áreas florestais, permitindo delimitar zonas específicas de manejo e obter estimativas mais precisas sobre os parâmetros biofísicos da vegetação.

A energia eletromagnética (REM) emitida pelo sol é vital para o desenvolvimento e sobrevivência da vegetação e consiste em uma das principais fontes de energia para o SR, a qual interage com os alvos na superfície. Segundo Alba *et al.* (2017) essa interação é fundamentada em técnicas e processos que permitem obter remotamente informações detalhadas sobre a vegetação, assim como correlações com variáveis mensuráveis em campo. A autora ainda afirma que estimar essas variáveis por meio de valores de reflectância apresenta um elevado potencial produtivo, uma vez que permite a concentração de recursos técnicos e financeiros em áreas de maior interesse, contribuindo para uma tomada de decisão eficiente e reduzindo possíveis perdas na produtividade da floresta. Densidade, quantificação e espacialização da vegetação são alguns dos parâmetros possíveis e constatados utilizando sistemas sensores, remotamente (PONZONI *et al.*, 2012).

De acordo com Sousa e Ponzoni (1998), embora a utilização das técnicas de sensoriamento remoto seja aplicada especialmente para determinar e quantificar a biomassa florestal, o volume da floresta é a variável de maior interesse nos estudos realizados com

instrumentos sensores. Esses instrumentos são capazes de coletar e registrar as variações da REM refletida e emitida pelos alvos, situados na superfície terrestre e têm como resultado o seu comportamento espectral a partir de valores de radiância (SOUSA, 1997). Ou seja, a aquisição e a análise dos mesmos compreendem a fonte de REM, a atmosfera, o alvo e o sensor, e a resposta dessa interação depende diretamente das características físico-químicas do alvo, assim como do seu comprimento de onda.

Os valores orbitais de uma imagem podem sofrer interferências ambientais (gases, poluição, vapor d'água etc.) em função das características específicas do próprio alvo (JENSEN, 2009; LILLESAND *et al.*, 2015). Por isso, é necessário fazer correções atmosféricas no intuito de minimizar esses efeitos, uma vez que a variável resultante desse processo é a reflectância de superfície, que poderá ser subsídio para identificar alterações nas propriedades biofísicas da vegetação (BERRA, 2013).

Ponzoni *et al.* (2012) definem a reflectância como a fração da energia eletromagnética incidente sobre um alvo, que é refletida pelo mesmo e armazenada pelo sensor. Logo, verifica-se que as regiões do Visível, Infravermelho Próximo e Infravermelho Médio sofrem interferência de diversos fatores como: estrutura celular (mesófilo), senescência, concentração de pigmentos, presença de água, entre outros, conforme mostra a Figura 1.




Figura 1: Reflectância espectral e as características da folha vegetal verde sadia para o intervalo de comprimento de onda entre 0,4 e 2,6 μm .

Fonte: Jensen (2009).

A detecção qualitativa e quantitativa da vegetação sadia é uma das grandes contribuições do sensoriamento remoto para os estudos ambientais (OLIVEIRA *et al.*, 2009). A quantidade de fluxo radiante refletido (reflectância), do fluxo radiante absorvido (absortância) e do fluxo radiante transmitido (transmitância) pela vegetação pode ser mensurada em função do balanço de energia.

Segundo Brandelero *et al.* (2007), a incorporação de variáveis espaciais e temporais, do mesmo modo que a inserção de tecnologias como o sensoriamento remoto, os sistemas de informações geográficas (SIG) e os sistemas de posicionamento global (GPS), proporcionam inferências mais precisas sobre o povoamento florestal. A função primordial do processamento digital de imagens orbitais é subsidiar e facilitar a identificação, assim como a

interpretação de informações específicas a uma determinada área (SILVA, 2001), fazendo-se necessário o uso de sistemas computacionais para fins de análise e manipulação dos dados brutos.

A associação do Inventário Florestal convencional com as técnicas e métodos de sensoriamento remoto permite reduzir custos e obter estimativas mais precisas sobre os parâmetros biofísicos relacionados à vegetação, dispensando, dessa forma, constantes e onerosas avaliações *in loco*, além de servir de alicerce na organização e alocação de unidades amostrais (UAs).

3.5.1 Satélite LANDSAT 8/OLI

O programa Landsat (*Land Remote Sensing Satellite*), desenvolvido pela *National Aeronautics and Space Administration* (NASA), teve início com o lançamento do *Earth Resources Technology Satellite – 1* (ERTS-1) em 1972, passando a ser chamado de Landsat em 1973 (USGS, 2016). Desde então, fornece dados com cobertura global, consolidando-se como uma das ferramentas fundamentais para analisar e avaliar impactos ambientais, uso e cobertura da terra, georreferenciar áreas, estimar parâmetros biofísicos, bem como auxiliar no planejamento de atividades florestais, entre outros.

Os produtos do programa LANDSAT registram, continuamente, dados multiespectrais, proporcionando imageamento da superfície terrestre e auxiliando pesquisas nos mais diversos segmentos, uma vez que possui boa resolução espacial (NOVO, 2010). Eles foram programados para ter cerca de dois anos de vida útil, no entanto, muitos permaneceram ativos por um período superior. Em virtude da facilidade de acesso às imagens, tornou-se um produto bastante utilizado no mapeamento e monitoramento da superfície. Nesse sentido, a resposta espectral obtida por meio de produtos da série LANDSAT tem representado uma importante fonte de dados, os quais podem ser adquiridos de forma gratuita.

Existe um grande número de sensores orbitais disponíveis para monitoramento global da superfície terrestre, cada um com suas peculiaridades espectrais, espaciais e radiométricas. O Landsat 8 iniciou suas atividades em abril de 2013, com dois sensores imageadores a bordo: o OLI (*Operational Land Imager*) e o TIRS (*Thermal Infrared Sensor*). Segundo Roy *et al.* (2014), o principal sensor do Landsat 8 é o OLI, tendo como maior diferencial, em

relação aos satélites anteriores da sua série, a adição de bandas espectrais (B1 e B9) associadas à maior capacidade de gravação de dados, como também na detecção de alterações na superfície terrestre. Sua resolução radiométrica é de 16 bits, com um intervalo de 1 a 65.535 níveis de cinza. Ele contempla onze faixas espectrais e, de acordo com a USGS (2016), coleta cerca de 400 cenas por dia.

O sensor OLI é composto por oito bandas espectrais (B1 a B7 e B9) e uma banda pancromática (B8), com resolução espacial de 30 metros e 15 metros, respectivamente. Além dessas, o Landsat 8/TIRS contempla duas faixas térmicas (B10 e B11), com resolução espacial de 100 metros, que melhora bastante as estimativas da temperatura da superfície, sobretudo em regiões áridas.

Tabela 1: Características espectrais, espaciais e temporais das bandas do satélite Landsat 8/OLI.

Banda	Sensor	Faixa Espectral (μm)	Resposta Espectral	Resolução Espacial (m)	Resolução Temporal
B1		0,43 – 0,45	Ultra-Azul		
B2		0,45 – 0,51	Azul		
B3		0,53 – 0,59	Verde		
B4		0,64 – 0,67	Vermelho	30	
B5	OLI	0,85 – 0,88	Infravermelho Próximo		16 dias
B6		1,57 – 1,65	Infravermelho Médio 1		
B7		2,11 – 2,29	Infravermelho Médio 2		
B8		0,50 – 0,68	Pan	15	
B9		1,36 – 1,38	Cirrus	30	
B10	TIRS	10,60 – 11,19	Termal 1	100	16 dias
B11		11,50 – 12,51	Termal 2		

Fonte: Adaptado de USGS (2016).

3.5.2 Índices de Vegetação

Pesquisas sobre a vegetação e uso e cobertura da terra vêm sendo desenvolvidas em regiões semiáridas, no intuito de obter informações cada vez mais precisas a partir de imagens de espectrais, além de outros produtos do sensoriamento remoto, e, assim, possibilitar a

análise e a interpretação dos dados de superfície (CHAVES *et al.*, 2013).

Existem correlações aceitáveis entre transformações de refletância espectral, chamados índices de vegetação, e parâmetros descritivos da biomassa, área foliar da vegetação e desempenho fisiológico. A avaliação quantitativa de um povoamento florestal, utilizando técnicas de sensoriamento remoto, pode ser realizada com os chamados índices de vegetação. Eles se fundamentam em razões, somas e diferenças elaboradas a partir de valores de refletância apresentados pela cobertura vegetal (TUCKER, 1979), consistindo em combinações de bandas espectrais, que tem por finalidade evidenciar características da vegetação, reduzindo os efeitos do solo e da atmosfera (RAMOS, 2016), utilizando, normalmente, as bandas do visível e infravermelho (SANTOS *et al.*, 2015). Porém, em regiões áridas, a faixa do infravermelho médio vem ganhando maior notoriedade.

Segundo Holben *et al.* (1980) e Baret e Guyot, (1991), os índices de vegetação foram desenvolvidos a fim de reduzir o número de parâmetros presentes nos dados multiespectrais. No sensoriamento remoto, o seu uso está intrínseco ao monitoramento das condições e distribuições espaciais dos diferentes alvos (vegetação, corpos hídricos, solo exposto) a partir de refletâncias espectrais da REM.

Barbosa *et al.* (2008) consideram que o comportamento espectral e os modelos matemáticos desenvolvidos relacionam-se com as variáveis dendrométricas mensuradas em campo. Esses índices têm apresentado resultados bastante satisfatórios no que se refere ao monitoramento de mudanças na vegetação em grande escala.

Há diversos índices de vegetação que, associados a um sistema de informação geográfica (SIG), contribuem e aceleram pesquisas, principalmente no que se refere ao monitoramento das alterações naturais ou antrópicas, constituindo numa das ferramentas importantes (FEITOSA *et al.*, 2004), visto que ressaltam o comportamento espectral da vegetação, permitindo distinguir diferentes tipologias e classificação do solo (MOREIRA, 2011). Nesse contexto, Ponzoni (2001) afirma que as medidas resultantes podem ser utilizadas também como indicadoras do incremento e do vigor da vegetação.

Os índices de vegetação permitem relacionar os parâmetros biofísicos do povoamento florestal por meio de imagens, além de contribuir para a redução dos efeitos de iluminação e declividade da superfície, já que estes influenciam negativamente nos valores de refletância

da vegetação (PONZONI *et al.*, 2012).

3.5.2.1 *Normalized Difference Vegetation Index – NDVI*

O Índice de Vegetação por Diferença Normalizada foi proposto por Rouse *et al.* (1974) e tem por característica principal separar a vegetação verde do brilho do solo. De acordo com Robinson *et al.* (2017), esse índice é, evidentemente, o mais utilizado para fins de monitoramento da superfície terrestre.

O índice NDVI é obtido por meio da razão entre a diferença da banda do infravermelho próximo e da banda do vermelho. Seus valores variam entre -1 a 1. Quando positivos, significa presença de vegetação, e, outros objetos, quando são menores que zero.

3.5.2.2 *Simple Ratio Vegetation Index – SR*

O Índice de Vegetação Razão Simples proposto por Jordan (1969) consiste no valor de reflectância oriunda da relação que existe entre a faixa do infravermelho próximo e do vermelho. Amplamente utilizado para monitorar vegetação, uma vez que se relaciona ao vigor vegetativo da mesma.

O resultado fornecido por este índice será maior que zero e assumirá um valor positivo em áreas de densa cobertura vegetal (MENESES; ALMEIDA, 2012).

3.5.2.3 *Leaf Area Index – LAI*

O Índice de Área Foliar é um índice biofísico que evidencia o elo existente entre a área foliar de um povoamento florestal e a unidade de superfície projetada no terreno. Segundo Beneditti *et al.* (2015), quanto maior o LAI, menor os valores de reflectância na região do Visível e do Infravermelho Médio e maior na região do Infravermelho Próximo. O LAI está diretamente relacionado com a transpiração e a produtividade florestal à área de solo ocupada por ela (COUTINHO *et al.*, 2016).

3.5.2.4 *Soil Adjusted Vegetation - SAVI*

O Índice de Vegetação Ajustado ao Solo foi proposto por Huete (1988), após constatar que características do solo apresentam uma influência considerável no espectro de radiação e

que a sua resposta espectral numa área de baixa densidade vegetacional poderia ser dominante sobre a resposta desta. Esse índice inclui uma constante (L), que varia de acordo com a característica do solo (calor, brilho, declividade etc.) e da densidade da vegetação a ser analisada. Quando mais densa a vegetação, maior será o valor de sua constante. Para vegetação muito baixa, é sugerido utilizar um fator $L = 1,0$, para vegetação intermediária, $L = 0,5$ e, para altas densidades, $L = 0,25$.

3.5.2.5 Atmospherically Resistant Vegetation Index - ARVI

O Índice de Vegetação Resistente à Atmosfera foi desenvolvido por Kaufman e Tanré (1992), propondo uma adaptação na formulação do NDVI, a fim de minimizar a sua dependência em relação aos efeitos atmosféricos sobre a faixa do Vermelho. O objetivo foi criar um índice mais resistente às variações de reflectância das vegetações que comumente ocorrem devido à presença de aerossóis, fumaças e poeiras. A reflectância na região do vermelho é menor do que na faixa do infravermelho, logo, busca-se reduzir os efeitos da atmosfera na faixa do vermelho, fazendo o uso da reflectância da região do vermelho-azul, que demonstrou ser menos sensível e resistente aos efeitos atmosféricos (PONZONI; SHIMABUKURO, 2010).

3.5.2.6 *Enhanced Vegetation Index* – EVI

O Índice de Vegetação Realçado foi proposto por Huete *et al.* (1997), a partir da combinação entre os IVs SAVI e o ARVI, com o objetivo de minimizar os efeitos do solo e da atmosfera sobre o monitoramento da vegetação. Ele utiliza fatores de ajustes e a reflectância no azul para retificar a influência indesejada da atmosfera e do solo, este último mais acentuado em FTS.

3.5.2.7 *Moisture Vegetation Index* – MVI

O índice de vegetação de umidade (MVI) foi proposto por Sousa e Ponzoni (1998), no intuito de analisar a reflectância nas faixas do Infravermelho Próximo e Médio, pois as consideram inversamente proporcionais. Ocorre redução da resposta espectral na região do infravermelho médio à medida que aumenta a densidade vegetal, esse fato é atribuído à maior

presença de água nas células, desse modo, a REM é mais facilmente absorvida do que refletida nessa faixa espectral (ALBA, 2016).

3.5.2.8 *Green Vegetation Index – GVI*

O Índice de Vegetação Verde, proposto por Kauth e Thomas (1976), reduz os efeitos do solo enquanto evidencia a vegetação verde. Foi criado para ser utilizado com o Landsat TM, porém apresenta bom desempenho com as bandas correspondentes dos satélites Landsat ETM+ e Landsat 8.

3.5.2.9 *Difference Vegetation Index – DVI*

O Índice de Vegetação da Diferença, proposto por Clevers (1988), é sensível à quantidade de vegetação verde. Estudos desenvolvidos em florestas nativas por Mohammadi *et al.* (2010) comprovaram a eficiência desse índice na obtenção de volume estocado a campo.

3.5.2.10 *Green Normalized Difference Vegetation Index – GNDVI*

O Índice de Vegetação por Diferença Normalizada Verde se mostrou eficiente na pesquisa realizada por Sousa e Ponzoni (1998), que teve por objetivo evidenciar mudanças no volume de madeira. Segundo Alba (2016), outros trabalhos vêm sendo desenvolvidos com este índice de vegetação, uma vez que ele demonstra correlações significativas com os parâmetros biofísicos, admitindo a mensuração com o auxílio do sensoriamento remoto.

3.5.2.11 *Green Atmospherically Resistant Vegetation Index – GARI*

O Índice de Vegetação Verde Resistente à Atmosfera é utilizado para detectar a concentração de clorofila, mensurar a taxa fotossintética e monitorar o estresse das plantas. Proposto por Gitelson *et al.* (1996), o GARI é menos sensível aos efeitos atmosféricos quando comparado ao NDVI.

3.5.2.12 *Global Environmental Monitoring Index – GEMI*

O Índice de Monitoramento Ambiental Global não linear foi criado para corrigir os efeitos atmosféricos em índices de vegetação como SR e o NDVI. Seus valores variam entre 0

e +1 para áreas continentais (PINTY; VERSTRAETE, 1992; PONZONI; SHIMABUKURO, 2010). É influenciado pelo solo exposto e, portanto, não é recomendado para uso em áreas com vegetação esparsa ou moderadamente densa.

3.6 MODELAGEM PREDITIVA POR REGRESSÃO

A análise de regressão soluciona a maioria dos problemas da área florestal, sobretudo, quando se pretende estimar variáveis biofísicas de difícil obtenção com equações de regressão, a partir de relações biométricas (SCHNEIDER *et al.*, 2009). Harris (2001) a define como uma técnica desenvolvida para estimar a variável resposta (Y) em função dos valores das variáveis explicativas (X). O principal objetivo desta técnica é obter uma equação que explique, de forma satisfatória, a relação (forte ou fraca) entre as variáveis envolvidas e tornando possível a predição de valores da variável de interesse.

Segundo Alba *et al.* (2016), a regressão linear explica a relação existente entre as variáveis dendrométricas de maciços florestais. Schneider *et al.* (2009) ressaltam que há três características importantes que devem ser levadas em consideração, são elas: o ponto médio situado sobre a linha de regressão, a soma dos desvios é nula e a soma dos quadrados dos desvios é mínima.

A regressão linear é baseada em ajuste de modelos matemáticos que envolvem variáveis distintas que se relacionam (SCHNEIDER *et al.*, 2009). Alba (2016) afirma que diversos são os modelos utilizados para prever o desenvolvimento futuro de povoamentos florestais em condições peculiares e os estudos que almejam o progresso da análise quantitativa, visando avaliar a viabilidade econômica de alternativas de manejo específicas para determinada situação (CAMPOS, 1980). A relação entre as variáveis pode ser explicada por modelos de regressão linear simples, envolvendo apenas duas variáveis (Equação 1) ou modelos de regressão linear múltipla (Equação 2).

$$Y_i = \beta_0 + \beta_1 X_{i1} + \varepsilon_i \quad (1)$$

Em que:

Y_i : valor da ocorrência i da variável dependente;

β_0 : intercepto múltiplo;
 X_{ij} : valor da ocorrência i da variável independente;
 β_j : parâmetro de regressão;
 ε_i : erro aleatório.

A análise de regressão múltipla (Equação 2) permite avaliar a interação entre uma variável dependente com diversas variáveis independentes, resultando em uma equação de reta, que melhor representa a estimativa de uma variável resposta, na qual pode ser explicada por diversas variáveis preditoras.

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_j X_{ij} + \varepsilon_i \quad (2)$$

Em que:

Y_i : valor da ocorrência i da variável dependente;
 β_0 : intercepto múltiplo;
 X_{ij} : valor da ocorrência i da variável independente;
 β_j : parâmetro de regressão;
 ε_i : erro aleatório.

O emprego da modelagem é uma ferramenta essencial para fazer inferências quanto às características do povoamento florestal, no intuito de fornecer precisão e confiabilidade nas respostas, subsidiar as tomadas de decisão e propiciar rendimentos científicos, financeiros e sustentáveis para a sociedade e para a floresta.

De acordo com Costa *et al.* (2015), estudos utilizando dados oriundos de instrumentos sensores, que tem por objetivo prever variáveis biofísicas, vêm ganhando notoriedade. Alba *et al.* (2016) afirma que isso só é possível devido ao comportamento espectral dos alvos que pode ser observado nas imagens de satélites.

Existem técnicas que avaliam a contribuição das variáveis independentes em relação à variável resposta, quando se pretende desenvolver modelos de predição. O método de seleção *Stepwise* é eficiente e funcional, uma vez que não requisita avaliar todas as possíveis

regressões. Schneider *et al.* (2009) menciona que este método desenvolve procedimentos passo a passo (*Stepwise regression*), para frente (*Forward selection*) e para trás (*Backward elimination*), permitindo inferir sobre a precisão estatística quando adiciona uma nova variável ao modelo e quando esta é removida do modelo.

A modelagem de parâmetros florestais por meio de métodos indiretos, considerando a relação entre os valores de reflectância de superfície e as variáveis mensuradas a campo, inclui o uso de análises estatísticas. Alguns critérios são recomendados para selecionar as melhores equações, como: Coeficiente de Determinação Ajustado (R^2_{aj}), Erro Padrão da Estimativa (S_{xy}) e Distribuição dos Resíduos ($Res(\%)$) (SCHNEIDER *et al.*, 2009).

O Coeficiente de Determinação (R^2) (Equação 3) é uma medida de precisão da variabilidade da variável dependente, na qual é explicada pela variável independente (TSUCHIYA, 2002), apresenta valores entre 0 e 1, e considera-se a equação que obtiver maior valor, sendo, portanto, uma medida descritiva da qualidade do ajuste obtido e pouco apropriada para ser critério estatístico quando se deseja comparar equações com diferentes números de coeficientes. Desse modo, é prudente optar pelo uso do Coeficiente de Determinação Ajustado (Equação 4). Finger (1992) salienta que utilizá-lo isoladamente como critério de seleção, sobretudo quando o modelo apresenta muitos coeficientes é arriscado, visto que o acréscimo de uma nova variável ao modelo aumenta o seu valor.

$$R^2 = \sum_{i=1}^n \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3)$$

Em que:

R^2 = coeficiente de determinação;

\hat{y}_i = valor estimado da variável dependente; \bar{y} = valor médio da variável dependente;

y_i = valor observado da variável dependente.

$$R^2_{aj} = R^2 - (1 - R^2) \cdot \frac{n-1}{n-p} \quad (4)$$

Em que:

R^2_{aj} : coeficiente de determinação ajustado;

p: número de variáveis independentes no modelo;

n: número de observações;

R^2 : coeficiente de determinação.

O Erro Padrão das Estimativas (S_{xy}) consiste em uma medida de dispersão entre os valores observados em campo e os estimados pela regressão (SCHNEIDER *et al.*, 2009), sendo expresso pela Equação 5, a seguir:

$$S_{xy} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n-p}} \quad (5)$$

Em que:

S_{xy} : erro padrão da estimativa;

y_i : valor observado (real);

\hat{y}_i : valor estimado pela equação de regressão;

n: número de observações;

p: número de parâmetros do modelo.

O Erro Padrão das Estimativas em porcentagem ($S_{xy}\%$) da equação gerada pode ser obtido pela Equação 6, a seguir:

$$S_{xy}(\%) = \frac{S_{xy}}{\hat{y}} \cdot 100 \quad (6)$$

Recomenda-se o uso do erro padrão da estimativa relativo quando se deseja comparar equações que apresentam variáveis dependentes com diferentes unidades (ALBA, 2016). Quanto mais próximo de zero, mais preciso será o S_{xy} , uma vez que o valor indica o quão próximo os valores estimados estão dos valores observados.

Quando as variáveis positivas de uma equação forem logaritmizadas, faz-se necessário corrigir o valor do R^2 , R^2_{aj} , S_{xy} (%), em virtude da discrepância logarítmica, pois, do contrário, poderá haver a indução de uma avaliação equivocada. Logo, utiliza-se o Fator de

correção de Meyer (FM), obtido pela Equação 7, para posteriormente multiplicá-lo aos valores estimados.

$$FM = e^{\frac{QMR}{2}} \quad (7)$$

Em que:

FM: fator de correção da discrepância logarítmica;

e : exponencial;

QMR: quadrado médio do resíduo.

A distribuição dos resíduos ($Res_{(\%)}$), por sua vez, é utilizada para verificar a dispersão percentual dos valores estimados pela equação com os valores observados, obtida pela Equação 8, a seguir:

$$Res_{(\%)} = \left(\frac{y_i - \hat{y}_i}{y_i} \right) \cdot 100 \quad (8)$$

Em que:

$Res_{(\%)}$: resíduo percentual;

y_i : valor observado (real);

\hat{y}_i : valor estimado pela equação de regressão.

4. MATERIAL E MÉTODOS

A metodologia utilizada nesse estudo pode ser visualizada no fluxograma exposto na Figura 2. As atividades realizadas compreenderam procedimentos metodológicos aplicados nos dados de campo, bem como nos dados orbitais.

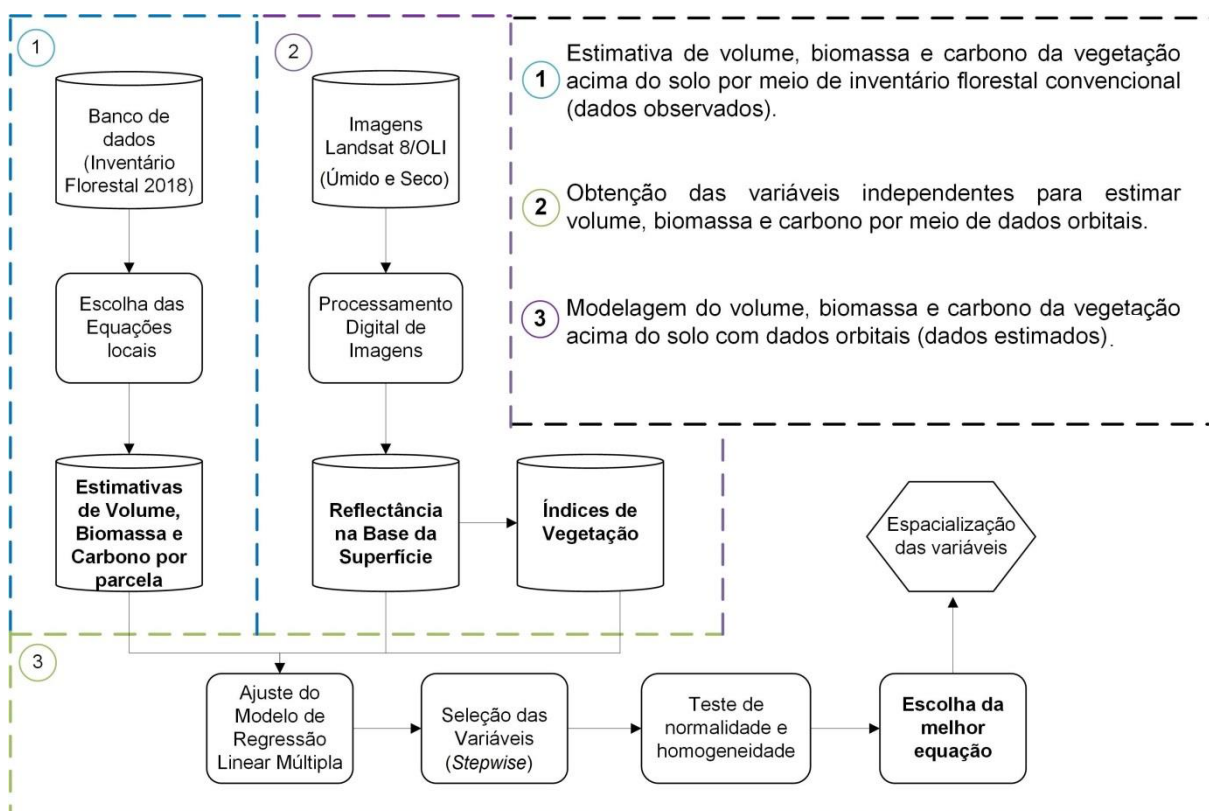


Figura 2: Fluxograma da metodologia aplicada no estudo.

Fonte: A autora.

4.1 CARACTERIZAÇÃO DA ÁREA DE ESTUDO

A área de estudo é de propriedade da empresa Agrimex - Agroindustrial Excelsior S.A. e está localizada na Fazenda Itapemirim, município de Floresta – PE, situada nas coordenadas geográficas 8°30'49'' Latitude Sul e 37°57'44'' Longitude Oeste. Possui uma dimensão de 5.695,65 ha, com acesso pelas rodovias PE-360, BR-232 e BR-110, a 360 km da cidade do Recife (FERRAZ, 2014).

Nesse estudo foram utilizados dados de Inventário Florestal provenientes de duas áreas (Figura 3) com distintos históricos de perturbação da vegetação.

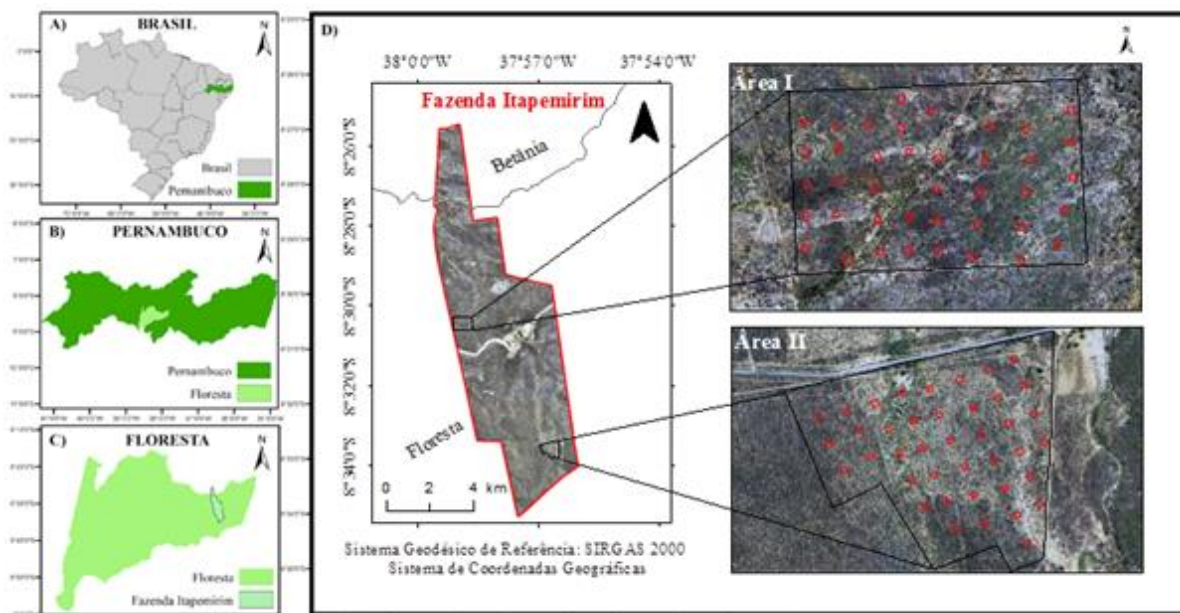


Figura 3: Localização e distribuição das unidades amostrais na Fazenda Itapemirim, município de Floresta, PE.

Fonte: A autora.

A Área I ou de Transposição possui cerca de 50 hectares e está situada no interior da fazenda, onde a vegetação encontra-se em bom estado de conservação, em função do reduzido histórico de corte, supostamente, ocorrendo apenas a retirada de produtos florestais para eventuais manutenções das cercas que limitam o local, além de ser pastejada por animais de forma extensiva e não controlada, sobretudo por caprinos (SANTOS, 2013).

A Área II ou Correntão, também com cerca de 50 hectares, está localizada ao sul da fazenda e se encontra próxima a PE – 360. Há aproximadamente 34 anos, houve retirada da vegetação com o auxílio de correntões, para fins de manejo florestal com o posterior abandono, ocorrendo pastejo de caprinos e a exploração esporádica de madeira até os dias atuais (FERRAZ, 2011; BARRETO, 2017).

Köppen classificou a região da área de amostragem como BS'h, o que reporta a um clima semiárido quente, com verão seco. De acordo com os dados meteorológicos do Instituto Nacional de Meteorologia – INMET, dos últimos 16 anos do município de Floresta, a

precipitação média acumulada foi de 452,1 mm/ano. Porém, esteve abaixo dessa média pelos sete anos consecutivos que antecederam 2018, conforme mostra a Figura 4.

O período úmido se concentra entre Janeiro e Maio, sendo os meses Março e Abril, geralmente, os mais chuvosos. A temperatura média anual é de 26°C (EMBRAPA, 2000).

De acordo com o IBGE (2012), a vegetação da área de estudo pode ser classificada como Savana-Estépica Arborizada e o solo como Luvissoilo Crômico, caracterizado por sua baixa profundidade e, comumente, apresenta mudança abrupta em sua textura (EMBRAPA, 2018).




Figura 4: Acumulações anuais (mm) dos últimos 16 anos em Floresta, PE, Brasil.

Fonte: APAC (2018).

A área de estudo está inserida na Ecorregião Depressão Sertaneja Meridional e encontra-se entre as mais impactadas pelas ações antrópicas, com poucas áreas protegidas em termos de número, área total ou categoria de proteção. No entanto, ainda possuem fragmentos extensos com grande possibilidade de recuperação (VELLOSO *et al.*, 2002).

4.2 ESTIMATIVAS OBTIDAS A PARTIR DO INVENTÁRIO CONVENCIONAL

4.2.1 Amostragem e coleta de dados

No ano de 2008, Alves Junior (2010) realizou uma amostragem sistemática com 80 parcelas permanentes dentro dos limites da Fazenda Itapemirim, sendo 40 na Área I (Trasnposição ou Preservada) e, as outras 40, na Área II (Correntão ou Degradada), todas georreferenciadas nos quatro vértices, com o auxílio de uma antena GPS Catalyst e precisão de 0,5 cm. Cada parcela possui 400 m² e estão distanciadas 50 m da bordadura do talhão e 80 m entre cada unidade, totalizando 3,2 ha de área amostrada.

Todos os vegetais com altura superior a 1,30 m em relação ao solo que apresentaram circunferência maior ou igual a 6 cm, (Circunferência à Altura do Peito - CAP), foram medidos e identificados conforme o modelo de classificação proposto por APG IV (2016), etiquetados na posição da CAP, visando padronizar o local da medição.

O banco de dados utilizado foi do ano de 2018, sendo inseridos os recrutados, ao atingirem a CAP mínima, bem como registrados os mortos. As espécies de FTS normalmente apresentam a característica de emitir múltiplos fustes, por isso, as bifurcações acima de 0,30 m de altura foram consideradas como um único indivíduo.

4.2.2 Estimativa de Volume

O modelo de Schumacher e Hall, ajustado por Alves Junior (2010) para o mesmo fragmento de caatinga na Fazenda Itapemirim, Floresta-PE, foi utilizado para determinar o volume (m³) individual das árvores amostradas, utilizando os dados dendrométricos coletados no ano de 2018.

$$\text{Volume} = 0,020829 \cdot \text{CAP}_i^{1,799468} \cdot \text{H}^{1,360720} \quad (9)$$

Onde:

CAP_i: circunferência à altura do peito (1,30 m)

H: altura

4.2.3 Estimativa de Biomassa e Carbono

Para a determinação do estoque de biomassa seca da área de estudo foram utilizadas equações alométricas (Tabela 2), descritas por Dalla Lana *et al.* (2018), para as oito espécies

da caatinga de maior Índice de Valor de Importância (IVI) e que juntas somaram mais de 90% da densidade total, baseando-se no inventário fitossociológico realizado em 2013.

Dalla Lana *et al.* (2018) escolheu os exemplares na Área I de forma aleatória em 2014, porém, evitando plantas parcialmente cortadas, queimadas ou tombadas. As árvores foram derrubadas e os seus compartimentos separados em fuste, folhas, galhos finos ($CAP < 6$ cm) e grossos ($CAP \geq 6$ cm) para posterior pesagem (peso úmido em kg) em balança digital portátil.

Retirou-se uma amostra aleatória e representativa de cada compartimento para uma nova pesagem em campo (peso úmido da amostra em kg). Todas as amostras úmidas foram secadas em estufa de circulação forçada de ar, à temperatura de 70°C até a estabilização do peso seco (peso seco da amostra em kg).

Para o ajuste dos modelos matemáticos, foram utilizadas as informações de biomassa total seca acima do solo como variável dependente e as variáveis independentes foram o diâmetro à altura do peito e a altura total de cada indivíduo por espécie analisada.

Para calcular o Diâmetro à Altura do Peito (DAP) utilizado nas equações da Tabela 2, foi necessário dividir a medida da CAP mensurada em campo pelo valor de π ($\pi = 3,1416$).

Tabela 2: Equações para estimativa do estoque de biomassa seca para oito espécies características de Floresta Tropical Seca, município de Floresta, Pernambuco, Brasil.

Espécies	Equações
<i>Anadenanthera colubrina</i> var. <i>cebil</i> (Griseb.) Altschul	$Bio = 48,7255 * [1 - \exp(-0,1435 * DAP)]^{2,4096}$ (10)
<i>Aspidosperma pyrifolium</i> Mart.	$Bio = 0,7858 * (DAP^2 * H)^{0,4550}$ (11)
<i>Bauhinia cheilantha</i> (Bong.) Steud.	$Bio = 0,0669 * (DAP^{2,2115}) * (H^{0,8155})$ (12)
<i>Cnidoscolus quercifolius</i> Pohl	$Bio = 0,6064 * (DAP^{1,4216})$ (13)
<i>Croton heliotropiifolius</i> Kunth	$Bio = 0,1868 * (DAP^{1,2764}) * (H^{0,9401})$ (14)
<i>Mimosa ophthalmocentra</i> Mart. ex Benth.	$\ln Bio = 1,1118 + 1,7371 * \ln DAP - 0,9536 * \ln H$ (15)
<i>Mimosa tenuiflora</i> (Willd.) Poir.	$Bio = 0,5084 * (DAP^{1,7121})$ (16)
<i>Cenostigma bracteosum</i> (Tul.) Gagnon e G.P. Lewis	$Bio = 6,6205 + 0,0341 * (DAP^2 * H)$ (17)
Equação Geral	$\ln Bio = -1,2884 + 1,6102 * \ln(DAP) + 0,4343 * \ln(H)$ (18)

Bio = estimativa de biomassa seca total acima do solo (kg); DAP = diâmetro a 1,30 m acima do solo (cm) e H = altura total (m).

Fonte: Dalla Lana *et al.* (2018)

Dalla Lana *et al.* (2019) utilizou as amostras de biomassa secas coletadas e preparadas para a determinação dos teores de carbono em cada compartimento. Elas foram fracionadas e

trituras em moinho com peneiras metálicas até atingir a consistência de pó, e, posteriormente, pesadas. Em seguida, foram armazenadas de acordo com a espécie e com compartimento analisado.

A determinação dos teores de carbono foi realizada com auxílio do analisador elementar CHNS/O, constituído por analisador, impressora e ultramicrobalança *Perkin-Elmer AD-6*. Nesse equipamento, a amostra de um grama é levada à combustão total (1000 °C) e, ao final da combustão, o resultado ou fator de conversão é fornecido pelo *software* em percentual (%).

O estoque de carbono para as espécies foi estimado pelo produto do peso da massa seca (biomassa seca) de cada exemplar arbustivo-arbóreo pelo respectivo fator de conversão de biomassa (Tabela 3) obtido por Dalla Lana *et al.* (2019).

Tabela 3: Fatores de conversão para a estimativa do estoque de carbono a partir da biomassa seca para oito espécies características de Floresta Tropical Seca, município de Floresta, Pernambuco, Brasil.

Espécies	Fator de Conversão
<i>Anadenanthera colubrina</i> var. <i>cebil</i> (Griseb.) Altschul	0,464
<i>Aspidosperma pyrifolium</i> Mart.	0,464
<i>Bauhinia cheilantha</i> (Bong.) Steud.	0,464
<i>Cnidoscolus quercifolius</i> Pohl	0,464
<i>Croton heliotropiifolius</i> Kunth	0,459
<i>Mimosa ophthalmocentra</i> Mart. ex Benth.	0,464
<i>Mimosa tenuiflora</i> (Willd.) Poir.	0,464
<i>Cenostigma bracteosum</i> (Tul.) Gagnon e G.P. Lewis	0,449
Equação Geral	0,461

Fonte: Dalla Lana *et al.* (2019)

4.3 ESTIMATIVAS OBTIDAS A PARTIR DE DADOS ORBITAIS

4.3.1 Aquisição e processamento das imagens orbitais

Utilizou-se cenas do satélite Landsat 8/OLI (6 bandas espectrais), excluindo-se as bandas 1, 8, 9, 10 e 11, uma vez que estas não apresentam informações relevantes para o alvo em estudo (vegetação). As imagens, tanto para o período úmido quanto para o período seco, datadas de 19 de abril e 25 de agosto de 2018, respectivamente, na órbita/ponto 216-66, em Collection 1 Level-1C, com correção radiométrica, geométrica e atmosférica no sistema de

projeção cartográfica UTM/WGS84, foram obtidas gratuitamente por meio da base de dados do Serviço Geológico dos Estados Unidos (*United States Geological Survey*).

O processamento digital de imagens foi realizado no *software* QGIS versão 3.6. Com o auxílio do *Semi-Automatic Classification Plugin* (SCP) do QGIS, desenvolvido por Congedo (2014), foi feita a conversão dos valores em níveis digitais (ND) para a medida física da reflectância no topo da atmosfera – TOA, conforme Equação 19, descrita por USGS (2016), juntamente com a correção atmosférica pelo método DOS1 (Dark Object Subtraction 1), visando eliminar a interferência da atmosfera e gerar a reflectância na base da superfície - BOA.

$$\rho_{\lambda} = \frac{(M_p * Q_{cal} + A_{\rho})}{\cos(\theta_{sz})} \quad (19)$$

Em que:

ρ_{λ} : reflectância no topo da atmosfera medida ao nível do sensor (adimensional);

M_p : fator de escala multiplicativo para reflectância (REFLECTANCE_MULT_BAND_n, onde n é o número da banda);

A_{ρ} : fator de escala aditivo para reflectância (REFLECTANCE_ADD_BAND_n);

Q_{cal} : valor do pixel da imagem de nível 1 (a banda em DN);

$\cos\theta_{sz}$: cosseno do ângulo zenital solar local (graus).

Após a obtenção dos dados de reflectância, foram calculados Índices de Vegetação (IV) (Tabela 4), sensíveis à detecção das características da vegetação florestal, tais como: Green Normalized Difference Vegetation Index – GNDVI, Normalized Difference Vegetation Index – NDVI, Simple Ratio Vegetation Index – SR, Soil Adjusted Vegetation Index - SAVI_{L=0,5}, Difference Vegetation Index – DVI, Moisture Vegetation Index – MVI, Atmospherically Resistant Vegetation Index – ARVI, Leaf Area Index – LAI, Green Vegetation Index – GVI, Green Atmospherically Resistant Vegetation Index – GARI, Enhanced Vegetation Index – EVI e Global Environmental Monitoring Index - GEMI.

Tabela 4: Índices de Vegetação utilizados neste estudo.

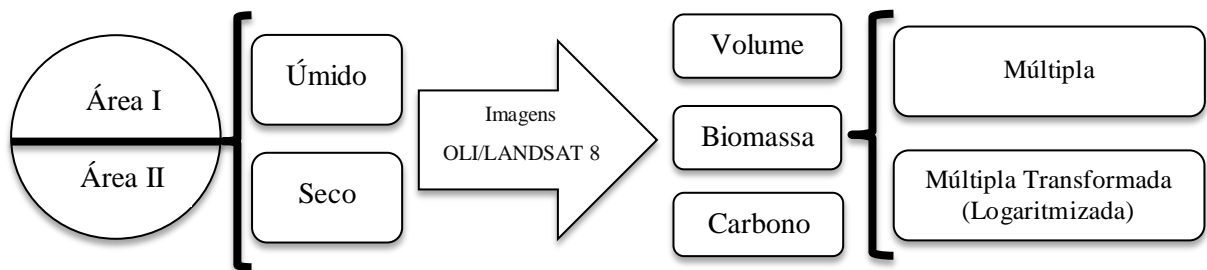
Índice de Vegetação	Fórmula	Autor
GNDVI	$\frac{\text{Nir} - \text{Green}}{\text{Nir} + \text{Green}}$	Gitelson <i>et al.</i> (1996)
NDVI	$\frac{\text{Nir} - \text{Red}}{\text{Nir} + \text{Red}}$	Rouse <i>et al.</i> (1974)
SR	$\frac{\text{Nir}}{\text{Red}}$	Jordan (1969)
SAVI _{L=0,5}	$\frac{\text{Nir} - \text{Red}}{\text{Nir} + \text{Red} + L} \cdot (1 - L)$	Huete <i>et al.</i> (1985)
DVI	$(\text{Nir} - \text{Red})$	Clevers (1988)
MVI	$\frac{\text{Nir} - \text{Swir}_1}{\text{Nir} + \text{Swir}_1}$	Sousa; Ponzoni (1998)
ARVI	$\frac{\text{Nir} - (2 \cdot \text{Red} + \text{Blue})}{\text{Nir} + (2 \cdot \text{Red} + \text{Blue})}$	Kaufman; Tanré (1992)
LAI	$\frac{\ln\left(\frac{0,69 - \text{SAVI}}{0,59}\right)}{0,91}$	Allen <i>et al.</i> (2002)
GVI	$(-0,2848 \cdot \text{Blue}) + (-0,2435 \cdot \text{Green}) + (-0,5436 \cdot \text{Red}) + (0,7243 \cdot \text{Nir}) + (0,0840 \cdot \text{Swir}_1) + (0,1800 \cdot \text{Swir}_2)$	Kauth; Thomas (1976)
GARI	$\frac{\text{Nir} - (\text{Green} - (\text{Blue} - \text{Red}))}{\text{Nir} + (\text{Green} - (\text{Blue} - \text{Red}))}$	Gitelson <i>et al.</i> (1996)
EVI	$\frac{2,5 \cdot (\text{Nir} - \text{Red})}{(\text{Nir} + (6,0 \cdot \text{Red})) - ((7,5 \cdot \text{Blue}) + 1,0)}$	Justice <i>et al.</i> (1998)
GEMI	$\eta \cdot (1 - 0,25\eta) - \frac{(\text{Red} - 0,125)}{(1 - \text{Red})}$ $\eta = \frac{2 \cdot ((\text{Nir} \cdot \text{Nir}) - (\text{Red} \cdot \text{Red})) + (1,5 \cdot \text{Nir}) + (0,5 \cdot \text{Red})}{(\text{Nir} + \text{Red} + 0,5)}$	Pinty; Verstraete (1992)

Em que: Nir = Reflectância da banda do infravermelho próximo; Green = Reflectância da banda do verde; Red = Reflectância da banda do vermelho; Swir = Reflectância da banda do infravermelho de ondas curtas; Blue = Reflectância da banda do azul; L = Constante que minimiza os efeitos do solo, em que foi utilizado o valor de 0,50 em virtude do porte intermediário da vegetação da área de estudo.

Ao final desta etapa, extraiu-se os valores médios (centróides) de reflectância das bandas e dos IVs das 80 unidades amostrais (UAs), dos dois períodos (úmido e seco).

4.3.2 Ajuste dos modelos para estimar volume, biomassa e carbono com dados orbitais

Nesta etapa, foram realizados os ajustes do modelo de regressão linear múltipla para as áreas estudadas (Área I e Área II), com os respectivos dados orbitais do Landsat 8, de forma que cada área obteve 12 equações ajustadas, conforme apresentado no esquema a seguir:



Fonte: A autora.

Considerou-se os dados de reflectância da superfície obtidos das bandas individuais do Landsat 8 sensor OLI (B2, B3, B4, B5, B6 e B7), bem como os 12 IVs como variáveis independentes no modelo de regressão linear múltipla, enquanto o volume total de madeira (m³), biomassa (kg) e o carbono (kg) por UA como as variáveis dependentes.

Os procedimentos para os ajustes do modelo de regressão linear múltipla, assim como as análises estatísticas, foram realizadas com o auxílio do *software* R[®] versão 3.6.1 (R DEVELOPMENT CORE TEAM, 2019), ao nível de 95% de probabilidade, utilizando o algoritmo dos mínimos quadrados ordinários.

A seleção das variáveis mais significativas para compor os modelos preditivos de volume, biomassa e carbono, foi realizada por meio da metodologia de *stepwise*, visto que esta permite examinar a contribuição de cada variável independente, descartando àquelas que menos adicionaram informação ao modelo de regressão. O método de seleção das variáveis do *stepwise* levou em consideração o critério de Akaike (AIC) e selecionou como o melhor modelo aquele que obteve o menor número de variáveis.

Após a seleção, os índices de vegetação que apresentaram apenas valores positivos foram logaritimizados para testar, tal como conferir, maior estabilidade aos dados, a fim de

reduzir a variância no modelo. Novas análises estatísticas foram realizadas em função das equações transformadas.

As melhores equações foram selecionadas com base nos critérios estatísticos recomendados por Schneider *et al.* (2009) e Alba *et al.* (2017), que são: Coeficiente de Determinação Ajustado (R^2_{aj}), Erro Padrão da Estimativa (S_{xy}) e Distribuição dos Resíduos ($Res_{(%)}$).

Para as equações logaritmizadas ou transformadas, utilizou-se o Fator de correção de Meyer, em virtude da discrepância logarítmica.

A verificação dos pressupostos de normalidade dos resíduos e homocedasticidade da variância foram realizadas pelo teste de Shapiro Wilk e Levene, respectivamente.

4.4 ESPACIALIZAÇÃO DAS VARIÁVEIS

A espacialização das variáveis biofísicas baseou-se nas equações que obtiveram os melhores ajustes, segundo os critérios estabelecidos previamente. Desse modo, cada pixel da imagem passou a representar o volume de madeira (m^3), biomassa (kg) e carbono (kg), em suas respectivas imagens, geradas após o cálculo de cada equação, tornando possível a elaboração dos mapas temáticos.

A espacialização das variáveis biofísicas, juntamente com a elaboração dos mapas temáticos, foi realizada no *software* Qgis versão 3.6.

5. RESULTADOS E DISCUSSÃO

5.1 ASSINATURA ESPECTRAL DA VEGETAÇÃO

Inicialmente, foi analisada a curva ou assinatura espectral dos valores reflectância, na base da superfície das amostras de vegetação, nas parcelas selecionadas para o estudo (Figura 5). Os valores de comprimentos de onda dos gráficos representam o comprimento de onda central de cada banda.

No gráfico de assinatura espectral da vegetação, para a Área I no período seco, observou-se uma curva espectral com menores valores (oscilando entre 0,10 a 0,23 μm) na região do infravermelho próximo (B5/OLI), quando comparada com uma vegetação verde e sadia. Para Ponzoni *et al.* (2012), a reflectância típica de uma folha verde sadia apresenta, nesse intervalo espectral, valores de reflectâncias superiores a 0,3 μm , conforme observado nos demais gráficos, com destaque aos do período úmido, nos dois locais estudados.

Na Área II, área com histórico de uso mais intenso do solo, os valores de reflectância foram maiores que na Área I, área mais conservada, tanto no período seco quanto no período úmido. Esse comportamento está associado ao grau de maturidade das áreas, uma vez que a vegetação da Área II é mais jovem, em virtude do seu histórico de uso. Swain e Davis (1978) explicam que há uma relação inversamente proporcional entre a reflectância da vegetação e o grau de maturidade, pois, com a senescência, perde-se a clorofila, restando apenas carotenóides e xantofilas.

A vegetação verde é caracterizada por picos de reflectância, especialmente na região do Infravermelho Próximo (PONZONI *et al.* 2012). Essa condição é observada no período úmido, em ambas as áreas, ocasionada pela maior presença de vegetação, visto que as chuvas proporcionam o desenvolvimento da folhagem e uma copa mais densa. Logo, a assinatura espectral da FTS no período úmido está de acordo com o comportamento esperado para uma vegetação sadia. Por outro lado, a FTS no período seco apresentou um padrão de resposta espectral diferenciado. O comportamento do solo arenoso exposto corresponde a um aumento gradual e constante, similar ao observado para o período seco nas áreas I e II. A resposta do solo arenoso na região do visível é maior que na vegetação verde, conforme observado nesse período. Desse modo, verificou-se uma maior influência do solo na resposta espectral quando

comparado ao período úmido, modificando sensivelmente o comportamento da vegetação em áreas de FTS.

A vegetação, no período seco, apresentou comportamento anômalo em relação ao déficit hídrico, posto que ele desencadeia a senescência, resultando no aumento de massa seca e perda de boa parte da folhagem, além de uma maior exposição do solo, afetando, dessa forma, os valores de refletâncias nesse tipo de fitofisionomia.

Francisco *et al.* (2015), avaliando diferentes índices espectrais no mapeamento da caatinga com Landsat 5 sensor TM, também encontraram valor baixo (valor médio de 0,24 μm) de refletância para a banda B4 do infravermelho próximo para o período seco.

A banda B6 (Infravermelho médio – SWIR₁/1.560-1.660 μm) foi a banda que apresentou os valores mais altos de refletância, nos períodos úmidos da Área I e II e no período seco da Área I, sendo a região do espectro eletromagnético que representou bem a caatinga em ambos os períodos. Southworth (2004), em estudos de dinâmica de uso e cobertura da vegetação em floresta seca, no México, verificou que as bandas do infravermelho, de um modo geral, corresponderam bem na discriminação de classes de uso e cobertura, em especial, à vegetação de FTS no período de estiagem, conforme verificado neste estudo.

Para Fitz (2008), a região do espectro que compõe o infravermelho apresenta boa resposta, sobretudo, ao teor de umidade da vegetação, ou seja, quimicamente, espera-se que a diminuição da quantidade de água acarrete degradação de proteínas e de pigmentos fotossintetizantes, o que tornará a folha menos eficiente em absorver radiação eletromagnética nessa região espectral e isso, por sua vez, resultará no aumento dos valores do valor de refletância. Jensen (2009) afirma que a água é um bom absorvedor de energia no infravermelho médio, uma vez que quanto maior a turgidez das folhas, menores as refletâncias nessa faixa. Em contraste, à medida que o conteúdo de umidade das folhas diminui, a refletância no infravermelho médio aumenta substancialmente, corroborando com os resultados encontrados. Segundo Zakaria (2010), as folhas das árvores e dosséis tendem a refletir mais nos comprimentos de onda mais curtos e troncos de árvores e galhos, nos comprimentos de onda mais longos. Ou seja, a densidade da vegetação afetará a dispersão dos comprimentos de onda.

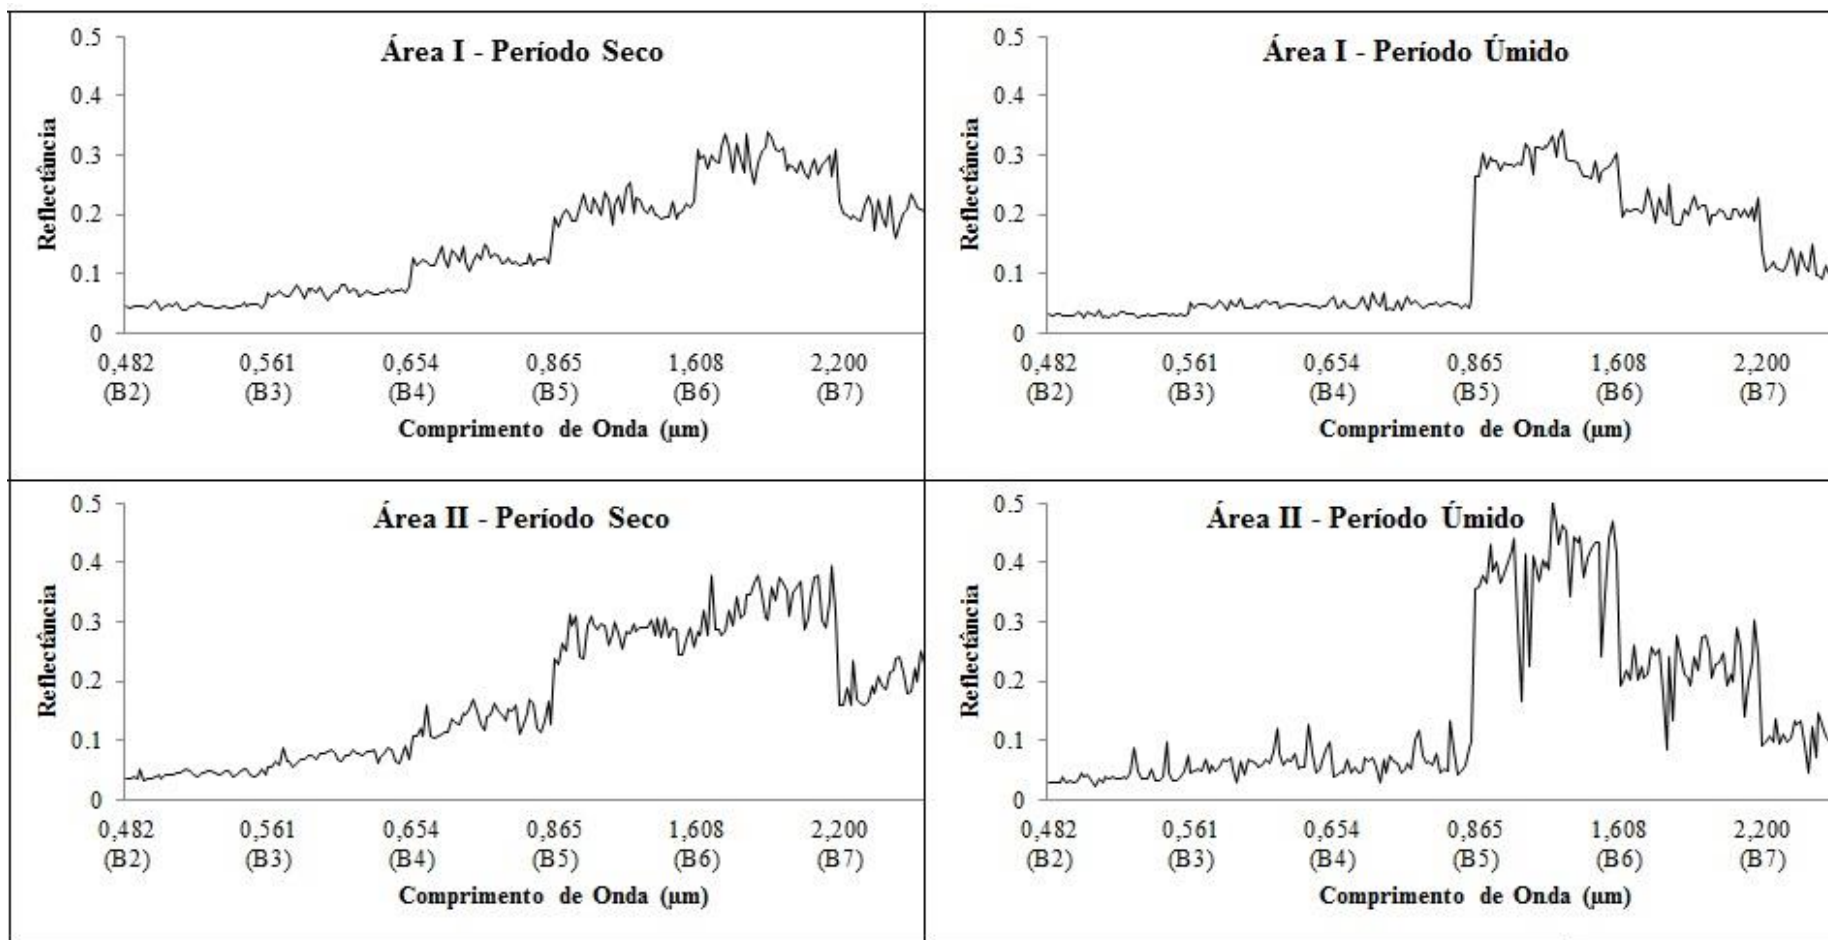


Figura 5: Assinatura espectral da vegetação dos fragmentos avaliados, com dados do satélite Landsat 8, no Período Seco e Úmido, município de Floresta – PE (2018).

Fonte: A autora.

5.2 ESTIMATIVAS DE VOLUME, BIOMASSA E CARBONO EM FTS

Na Área I, para o período seco, apenas as variáveis B2, B6, DVI, ARVI, GARI, GEMI, LAI, GNDVI, MVI e GVI apresentaram significância no ajuste das três equações de regressão linear múltipla. Já nas equações transformadas, além de manter as variáveis independentes citadas, com exceção da B2, houve a inclusão do índice de vegetação SR.

As equações obtidas para as variáveis biofísicas, assim como as estatísticas de qualidade de ajuste, são apresentadas na Tabela 5 para período seco. As melhores equações para estimar volume, biomassa e carbono, na Área I e no período seco, são: 20, 23 e 25, respectivamente. As três selecionadas apresentaram um $S_{xy}(\%)$ menor em relação às demais, sobretudo as transformadas de biomassa (Equação 23) e carbono (Equação 25). A equação de volume na forma logaritmizada não demonstrou melhora na qualidade dos ajustes, visto que houve um aumento do $S_{xy}(\%)$, embora os R^2_{aj} tenham sido próximos em todas elas.

Já no período úmido, as variáveis B2, B3, B5, B6, B7, ARVI, GARI, GEMI, IAF, GNDVI, SR, NDVI e MVI apresentaram significância no ajuste da equação de regressão linear múltipla para a variável volume, enquanto biomassa e carbono obtiveram a inclusão do índice de vegetação DVI e a exclusão do GEMI de suas equações. As transformadas também apresentaram as mesmas variáveis independentes como significativas para as três variáveis biofísicas. As equações obtidas para as variáveis biofísicas, tal como as estatísticas de qualidade de ajuste, são apresentadas na Tabela 5 para período úmido. O mesmo comportamento do período seco, em relação ao $S_{xy}(\%)$ e ao R^2_{aj} , foi observado para o período úmido.

No período úmido, destacaram-se as equações 26, 29 e 31 para estimar volume, biomassa e carbono, respectivamente, as quais apresentaram um $S_{xy}(\%)$ menor em relação às demais, sobretudo as transformadas de biomassa (Equação 29) e carbono (Equação 31). A equação de volume na forma logaritmizada, assim como no período seco, não demonstrou melhora na qualidade dos ajustes, uma vez que houve um aumento do $S_{xy}(\%)$, embora os R^2_{aj} tenham sido próximos em ambas.

Tabela 5: Equações e medidas de precisão para a Área I, utilizando as imagens do satélite Landsat 8/OLI para os períodos seco e úmido, Floresta, PE.

EQUAÇÕES	S_{xy} (%)	R^2_{aj}	SW (Valor p)	Levene Test (Valor p)	
Período Seco					
Volume = -57,163 + (129,933 * DVI) + (220,344 * ARVI) - (305,727 * GARI) + (20,407 * GEMI) - (36,403 * LAI) + (175,636 * GNDVI) - (52,515 * MVI) - (54,620 * GVI) - (86,856 * B6) + (462,733 * B2)	44,894	0,634	0,179	0,079	(20)
Ln (Volume) = -64,471 - (28,625 * LnDVI) + (85,976 * ARVI) - (21,038 * LnGARI) + (32,644 * LnGEMI) + (1,538 * LnLAI) + (16,931 * LnGNDVI) + (13,468 * LnSR) - (4,208 * MVI) + (6,665 * LnGVI) + (192,452 * B2)	59,097	0,595	0,134	0,648	(21)
Biomassa = -18452,540 - (112289,496 * DVI) + (198504,580 * ARVI) - (325333,536 * GARI) - (59216,003 * GEMI) + (66046,750 * LAI) + (176039,709 * GNDVI) - (54597,651 * MVI) + (86532,930 * GVI) - (84661,182 * B6) + (548256,176 * B2)	35,677	0,620	0,404	0,553	(22)
Ln (Biomassa) = -121,006 - (43,786 * LnDVI) - (52,185 * ARVI) - (14,950 * LnGARI) + (37,968 * LnGEMI) + (1,045 * LnLAI) + (7,323 * LnGNDVI) + (90,225 * LnSR) - (6,411 * MVI) + (10,770 * LnGVI) + (376,270 * B2)	6,030	0,650	0,930	0,064	(23)
Carbono = -8883,725 - (48356,081 * DVI) + (91216,846 * ARVI) - (149007,262 * GARI) - (26357,442 * GEMI) + (28998,810 * LAI) + (80742,943 * GNDVI) - (25068,352 * MVI) + (38691,114 * GVI) - (38950,964 * B6) + (250478,102 * B2)	35,413	0,622	0,428	0,479	(24)
Ln (Carbono) = -121,785 - (43,418 * LnDVI) - (55,014 * ARVI) - (14,554 * LnGARI) + (37,598 * LnGEMI) + (0,987 * LnLAI) + (6,707 * LnGNDVI) + (91,178 * LnSR) - (6,270 * MVI) + (10,660 * LnGVI) + (375,603 * B2)	6,842	0,649	0,918	0,061	(25)
Período Úmido					
Volume = 17,328 + (26,333 * ARVI) - (7,439 * GARI) + (30,399 * GEMI) - (10,508 * LAI) - (37,651 * GNDVI) + (0,180 * SR) - (12,767 * NDVI) - (1,709 * MVI) - (11,497 * B7) + (12,002 * B6) + (19,576 * B5) - (224,911 * B3) + (182,059 * B2)	47,207	0,639	0,561	0,053	(26)
Ln (Volume) = 88,042 + (117,521 * LnDVI) + (28,492 * LnARVI) - (19,909 * LnGARI) - (97,829 * LnLAI) - (74,287 * LnGNDVI) + (26,217 * LnSR) - (32,817 * LnNDVI) - (1,593 * LnMVI) - (67,292 * B7) + (24,764 * B6) + (51,245 * B5) - (547,364 * B3) + (483,253 * B2)	58,575	0,656	0,062	0,974	(27)
Biomassa = 30760,661 + (23761,599 * DVI) + (45892,250 * ARVI) - (32136,625 * GARI) - (8342,942 * LAI) - (19221,678 * GNDVI) - (60,360 * SR) - (17985,884 * NDVI) - (8766,480 * MVI) - (57844,164 * B7) + (16194,632 * B6) + (18254,813 * B5) - (162742,298 * B3) + (276846,388 * B2)	37,348	0,629	0,311	0,187	(28)

Continua...

...Continuação

$$\begin{aligned} \text{Ln (Biomassa)} = & 29,953 + (49,137 * \text{LnDVI}) + (25,793 * \\ & \text{LnARVI}) - (41,895 * \text{LnGARI}) - (46,718 * \text{LnLAI}) - (17,773 \\ & * \text{LnGNDVI}) + (14,801 * \text{LnSR}) - (17,075 * \text{LnNDVI}) - & 6,304 & 0,661 & 0,075 & 0,574 & (29) \\ & (1,738 * \text{LnMVI}) - (83,190 * \text{B7}) + (25,717 * \text{B6}) + (27,060 * \\ & \text{B5}) - (279,496 * \text{B3}) + (504,836 * \text{B2}) \end{aligned}$$

$$\begin{aligned} \text{Carbono} = & 13998,532 + (11080,419 * \text{DVI}) + (20732,410 * \\ & \text{ARVI}) - (14476,208 * \text{GARI}) - (3815,026 * \text{LAI}) - (8883,090 \\ & * \text{GNDVI}) - (26,408 * \text{SR}) - (8127,746 * \text{NDVI}) - (3925,128 * & 37,115 & 0,629 & 0,319 & 0,196 & (30) \\ & \text{MVI}) - (25936,908 * \text{B7}) + (7271,174 * \text{B6}) + (8216,529 * \\ & \text{B5}) - (74495,470 * \text{B3}) + (125305,736 * \text{B2}) \end{aligned}$$

$$\begin{aligned} \text{Ln (Carbono)} = & 29,572 + (49,339 * \text{LnDVI}) + (25,702 * \\ & \text{LnARVI}) - (41,598 * \text{LnGARI}) - (46,762 * \text{LnLAI}) - (18,179 \\ & * \text{LnGNDVI}) + (14,777 * \text{LnSR}) - (17,089 * \text{LnNDVI}) - & 7,137 & 0,660 & 0,066 & 0,638 & (31) \\ & (1,722 * \text{LnMVI}) - (82,375 * \text{B7}) + (25,390 * \text{B6}) + (26,925 * \\ & \text{B5}) - (281,217 * \text{B3}) + (503,219 * \text{B2}) \end{aligned}$$

Fonte: A autora.

Os índices de vegetação EVI e SAVI_{L=0,5} não foram considerados significativos na seleção de variáveis, não sendo variável preditora em nenhuma equação. No caso do EVI, de acordo com HUETE *et al.* (2002), esse fato pode ser explicado por sua sensibilidade às variações da vegetação, levando em consideração, inclusive, a arquitetura vegetacional, bem como a sua fitofisionomia. O fator L= 0,5 do SAVI, utilizado para vegetação intermediária e considerado nesse estudo, demonstrou não ser sensível às variações da estrutura florestal para esse tipo de fitofisionomia.

O NDVI mostrou-se significativo apenas nos períodos úmidos de ambas as áreas, e isso pode ser explicado por sua sensibilidade à clorofila (HUETE *et al.*, 2002), visto que, no período seco, poucas espécies permanecem com suas folhas (caducas).

Com exceção da B4 (banda do vermelho), que foi significativa apenas para a Área II (Correntão), todas as demais bandas demonstraram ser significantes para o período úmido, nos dois fragmentos considerados nesse estudo.

Verificou-se que, para a variável volume, não houve normalidade na distribuição dos resíduos, mesmo após logaritmizar os índices que tinham valores acima de zero (Figura 6), apresentando-se disperso. Em contrapartida, a biomassa e o carbono obtiveram seus resíduos mais próximos da linha média de distribuição, demonstrando que os valores estimados pelas equações geradas para esses parâmetros explicaram melhor a relação entre valor real com valor estimado.

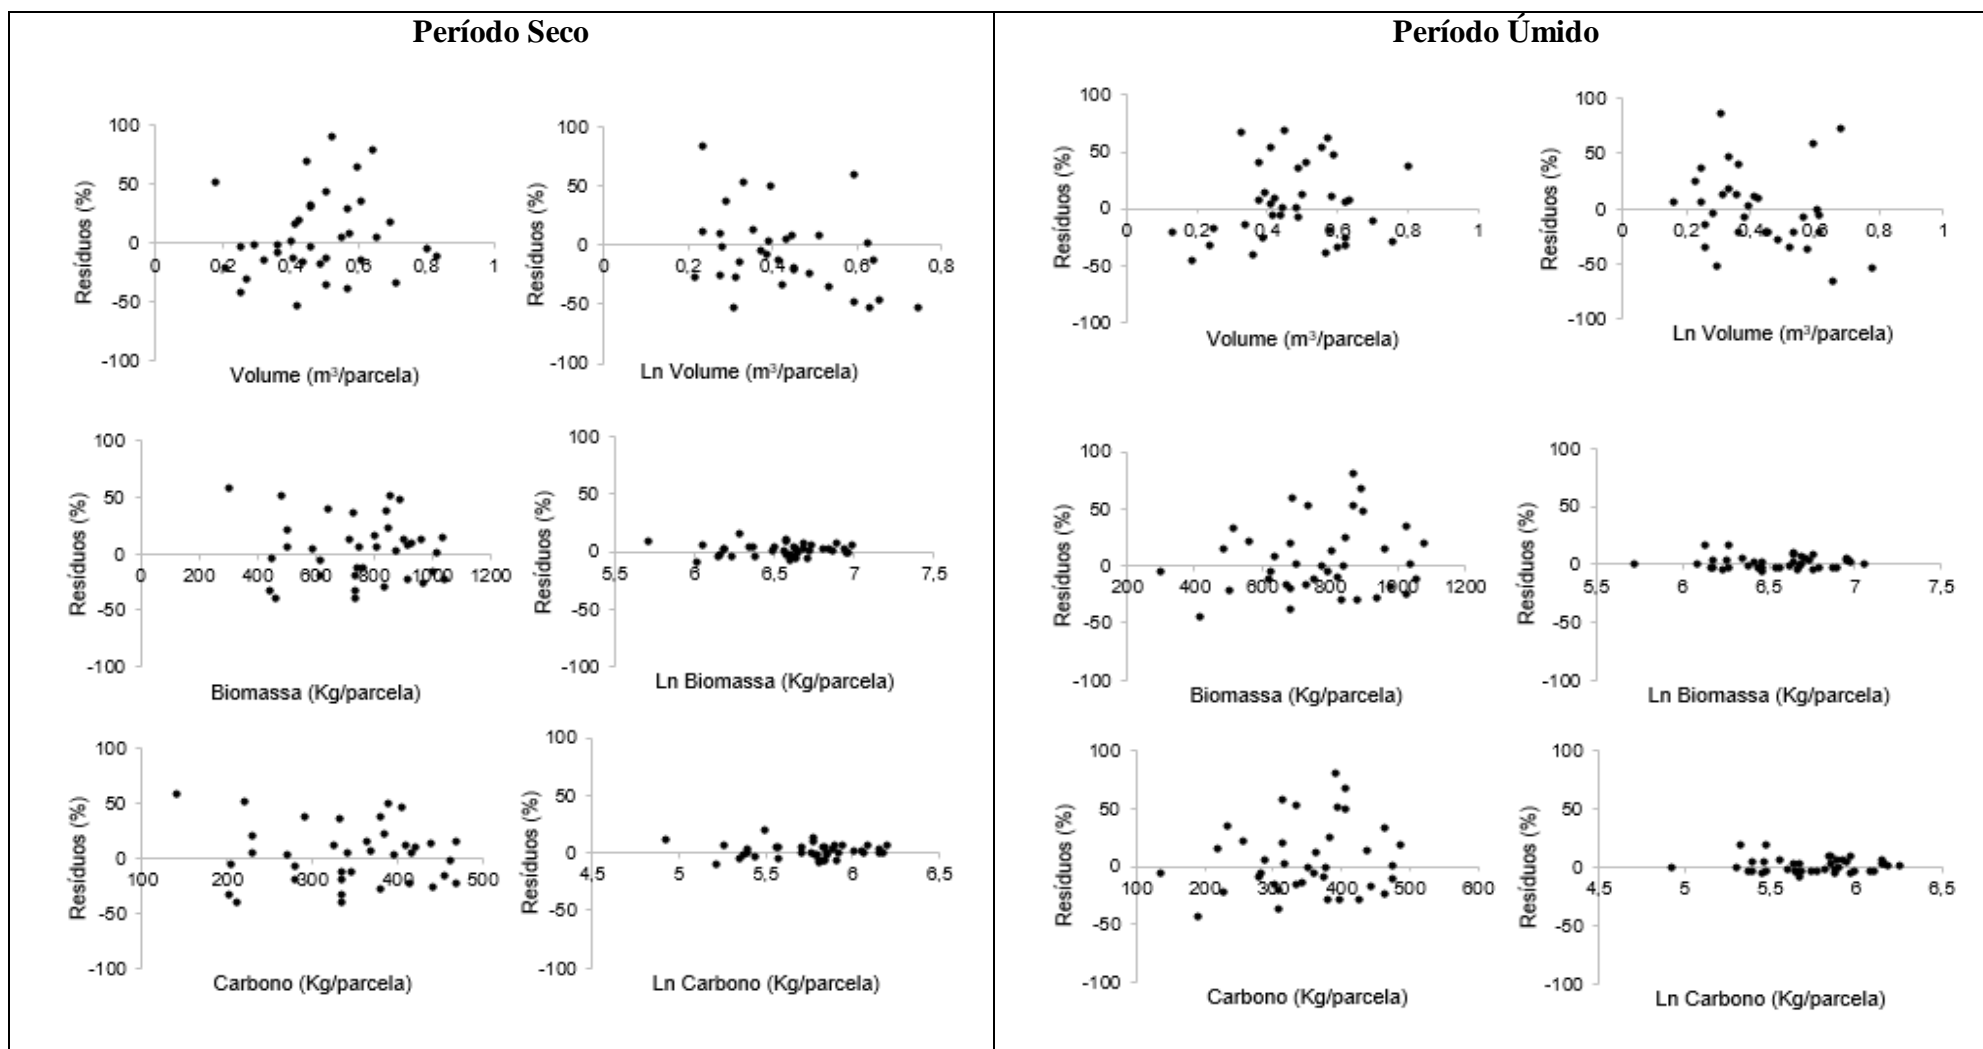


Figura 6: Distribuição dos resíduos percentuais em relação às variáveis volume, biomassa e carbono para Área I, nos períodos seco e úmido, Floresta – PE.

Fonte: A autora.

Na Área II, para o período seco, apenas as variáveis B2, B6, DVI, ARVI, GARI, GEMI, LAI, GNDVI, MVI e GVI apresentaram significância no ajuste das três equações de regressão linear múltipla. Já nas equações transformadas, além de manter as variáveis independentes citadas, com exceção da B6, houve a inclusão do índice de vegetação SR e da B7.

Já no período úmido, as variáveis B2, B3, B4, B5, B6, B7, ARVI, GARI, GEMI, LAI, GNDVI, SR, NDVI e MVI apresentaram significância no ajuste das equações para estimar as três variáveis respostas. Essas equações, como também as estatísticas de qualidade de ajuste, são encontradas na Tabela 6 para período úmido. O comportamento observado no período seco em relação ao $S_{xy}(\%)$ e ao R^2_{aj} , corrobora com o apresentado no período úmido desse fragmento de floresta seca.

As equações obtidas para as variáveis biofísicas, tal qual as estatísticas de qualidade de ajuste, são apresentadas na Tabela 6 para período seco. Observou-se, de forma semelhante à Área I, que as equações obtidas a partir dos dados derivados das imagens orbitais apresentaram, de um modo geral, resultados melhores em função do $S_{xy}(\%)$, para área de caatinga, tendo em vista que os R^2_{aj} foram próximos dentro do mesmo período.

As equações transformadas apresentaram, em ambos os períodos avaliados para este fragmento, uma redução significativa no $S_{xy}(\%)$ para as variáveis biomassa e carbono. O volume, por sua vez, demonstrou redução pouco expressiva. Quatro das equações preditivas (32, 39, 40 e 42), três delas múltiplas transformadas (úmido) e uma múltipla (seco), não atenderam aos pressupostos de normalidade e homocedasticidade, nesta ordem, sendo descartadas.

Considerou-se como mais apropriadas para estimar volume, biomassa e carbono, na Área II no período seco, as equações 33, 35 e 37, respectivamente. Já para o período úmido, as selecionadas foram: 38, 41 e 43.

Tabela 6: Equações e medidas de precisão para a Área II, utilizando as imagens do satélite Landsat 8/OLI, para os períodos seco e úmido, Floresta-PE.

EQUAÇÕES	S_{xy} (%)	R^2_{aj}	SW (Valor p)	Levene Test (Valor p)	
Período Seco					
Volume = -0,763 - (67,265 * DVI) + (6,256 * ARVI) + (0,923 * GARI) + (13,641 * GEMI) + (1,732 * LAI) - (5,883 * GNDVI) + (9,553 * MVI) + (21,197 * GVI) + (16,263 * B6) - (24,334 * B2)	67,807	0,299	0,069	0,033	(32)
Ln (Volume) = 143,476 + (84,399 * LnDVI) - (2,298 * LnARVI) + (30,250 * LnGARI) - (15,947 * LnGEMI) - (32,250 * LnLAI) - (43,519 * LnGNDVI) - (24,359 * LnSR) - (30,391 * MVI) - (12,419 * LnGVI) - (59,142 * B7) - (501,166 * B2)	60,351	0,463	0,051	0,180	(33)
Biomassa = 29918,307 - (148753,109 * DVI) - (65326,996 * ARVI) + (141629,167 * GARI) + (10325,966 * GEMI) - (1892,516 * LAI) - (100539,126 * GNDVI) + (50343,930 * MVI) + (64288,715 * GVI) + (76733,056 * B6) - (250850,191 * B2)	72,403	0,362	0,110	0,523	(34)
Ln (Biomassa) = 156,850 + (107,222 * LnDVI) - (1,887 * LnARVI) + (24,406 * LnGARI) - (28,322 * LnGEMI) - (31,124 * LnLAI) - (27,287 * LnGNDVI) - (25,595 * LnSR) - (31,571 * MVI) - (28,538 * LnGVI) - (87,071 * B7) - (468,868 * B2)	14,174	0,469	0,556	0,160	(35)
Carbono = 13840,919 - (65561,178 * DVI) - (29728,697 * ARVI) + (64224,027 * GARI) + (3960,154 * GEMI) - (860,176 * LAI) - (45627,517 * GNDVI) + (22542,022 * MVI) + (28974,559 * GVI) + (34399,497 * B6) - (113783,809 * B2)	72,304	0,361	0,110	0,525	(36)
Ln (Carbono) = 160,059 + (111,752 * LnDVI) - (1,854 * LnARVI) + (24,981 * LnGARI) - (31,403 * LnGEMI) - (32,362 * LnLAI) - (27,901 * LnGNDVI) - (25,791 * LnSR) - (32,446 * MVI) - (29,739 * LnGVI) - (89,557 * B7) - (479,326 * B2)	16,324	0,469	0,573	0,140	(37)
Período Úmido					
Volume = -4,060 + (0,991 * DVI) - (3,251 * ARVI) - (7,312 * GARI) + (1,037 * GEMI) - (0,510 * LAI) + (11,896 * GNDVI) + (0,111 * SR) - (0,523 * NDVI) + (4,586 * MVI) + (6,742 * B7) + (4,982 * B6) - (5,010 * B5) - (50,028 * B4) + (40,395 * B3) + (10,029 * B2)	62,556	0,587	0,641	0,093	(38)
Ln (Volume) = 31,013 - (15,918 * LnDVI) - (7,596 * LnARVI) + (5,697 * LnGARI) + (25,679 * LnGEMI) + (2,909 * LnLAI) + (58,148 * LnGNDVI) - (11,592 * LnSR) + (11,251 * LnNDVI) + (3,151 * LnMVI) + (63,954 * B7) - (2,954 * B6) - (32,928 * B5) - (177,709 * B4) + (248,174 * B3) + (9,715 * B2)	63,488	0,503	<0,001	0,845	(39)
Biomassa = -18539,835 - (14152,463 * DVI) - (8121,233 * ARVI) - (6126,185 * GARI) + (12050,549 * GEMI) + (3,409 * LAI) + (15096,021 * GNDVI) - (6,969 * SR) + (13795,589 * NDVI) + (7692,318 * MVI) + (25871,781 * B7) - (463,051 * B6) - (16907,650 * B5) - (47020,826 * B4) + (88716,759 * B3) - (11425,832 * B2)	71,181	0,552	0,014	0,597	(40)

Continua...

...Continuação

$$\text{Ln (Biomassa)} = 30,271 - (18,724 * \text{LnDVI}) - (5,653 * \text{LnARVI}) + (0,752 * \text{LnGARI}) + (28,143 * \text{LnGEMI}) + (4,446 * \text{LnLAI}) + (46,479 * \text{LnGNDVI}) - (10,522 * \text{LnSR}) + (12,133 * \text{LnNDVI}) + (2,978 * \text{LnMVI}) + (81,639 * \text{B7}) - (11,781 * \text{B6}) - (29,621 * \text{B5}) - (164,151 * \text{B4}) + (172,701 * \text{B3}) + (49,041 * \text{B2})$$

$$\text{Carbono} = -8411,409 - (6321,441 * \text{DVI}) - (3681,801 * \text{ARVI}) - (2705,634 * \text{GARI}) + (5404,718 * \text{GEMI}) - (3,545 * \text{LAI}) + (6791,840 * \text{GNDVI}) - (2,140 * \text{SR}) + (6283,587 * \text{NDVI}) + (3442,257 * \text{MVI}) + (11482,083 * \text{B7}) - (158,390 * \text{B6}) - (7665,353 * \text{B5}) - (20770,844 * \text{B4}) + (40167,127 * \text{B3}) - (5429,277 * \text{B2})$$

$$\text{Ln (Carbono)} = 29,599 - (18,498 * \text{LnDVI}) - (5,646 * \text{LnARVI}) + (0,729 * \text{LnGARI}) + (27,893 * \text{LnGEMI}) + (4,358 * \text{LnLAI}) + (46,449 * \text{LnGNDVI}) - (10,461 * \text{LnSR}) + (12,248 * \text{LnNDVI}) + (2,976 * \text{LnMVI}) + (80,892 * \text{B7}) - (11,421 * \text{B6}) - (29,743 * \text{B5}) - (162,921 * \text{B4}) + (172,571 * \text{B3}) + (48,822 * \text{B2})$$

Fonte: A autora.

As mesmas observações da Área I se aplicam à Área II, já que ambas se encontram inseridas na mesma fitofisionomia e apresentam a mesma composição florística, porém com intensidade de uso diferentes. O uso de índices de vegetação que consideram apenas a reflectância de folhas não apresentaram, de maneira geral, bons ajustes. A vegetação correspondente aos fragmentos estudados é caducifólia e as espécies que pertencem a essa categoria perdem suas folhas em períodos específicos, sobretudo naqueles onde há deficiência hídrica, influenciando diretamente nos resultados, corroborando com Lu *et al.* (2004), ao afirmarem que os elementos do ecossistema influenciam a resposta espectral e, portanto, afetam os modelos ajustados para a obtenção de dados biofísicos estimados por meio dados orbitais.

A banda B5 esteve presente nas equações 26, 27, 28, 29, 30, 31, 38, 39, 40, 41, 42 e 43, que podem ser verificadas nas Tabelas 5 (Área I) e 6 (Área II), referentes ao período úmido, o que pode ser justificado pelos altos valores de reflectância nesse período, verificado na Figura 5. A banda B4, por sua vez, esteve presente apenas na Equação 37, para a Área II e no período úmido, pois também apresentou comportamento diferente nessa estação do ano.

As bandas B2 (azul), B6 (Swir₁) e B7 (Swir₂) foram as únicas bandas que, dentre as seis consideradas na análise, apresentaram significância para o período seco nas Área I e II, indicando uma afinidade com ambientes áridos, sobretudo em estação seca. Em conformidade

com o observado na Área I, a Área II não apresentou um bom ajuste para a variável volume, ainda que transformado. Para biomassa e o carbono, os resultados também apresentaram menor dispersão dos dados em torno da linha média de distribuição (Figura 7).

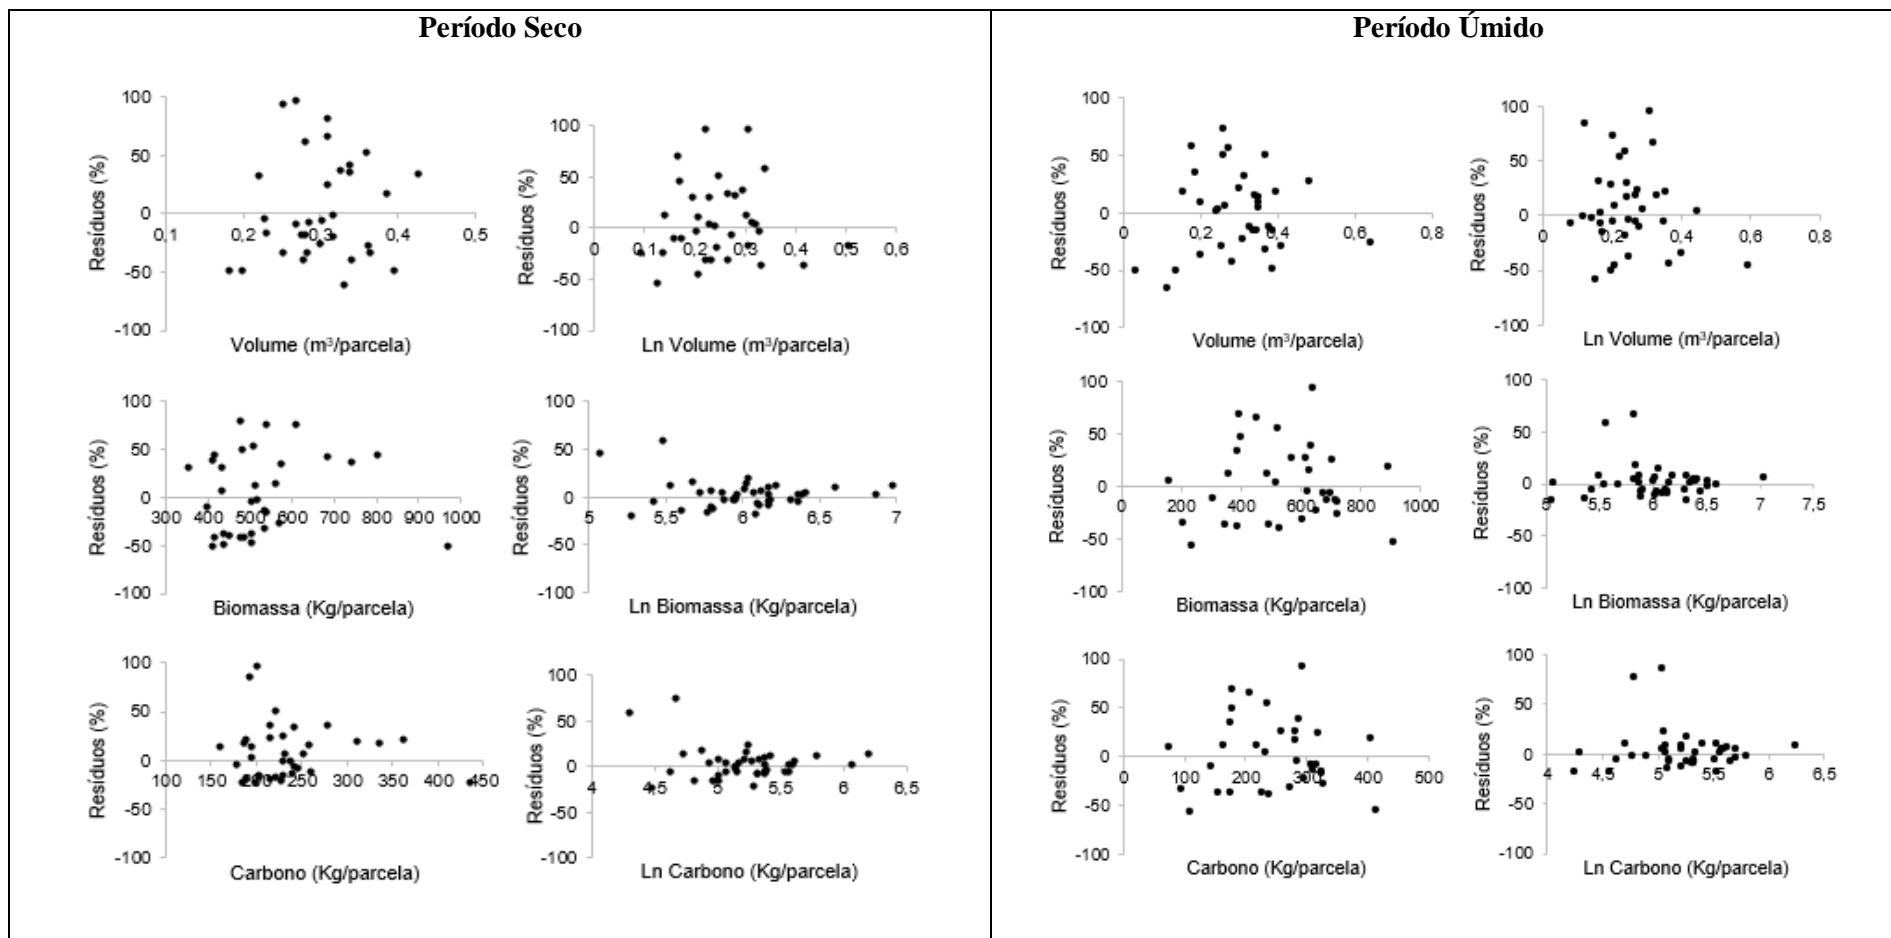


Figura 7: Distribuição dos resíduos percentuais em relação às variáveis volume, biomassa e carbono para Área II, nos períodos seco e úmido, Floresta – PE.

Fonte: A autora.

Outros autores empregaram modelos para estimar parâmetros biofísicos de coberturas florestais e encontraram valores similares aos encontrados nesse estudo. Trabalhos como os de Lu *et al.* (2004), Berra *et al.* (2012) e Hentz *et al.* (2014) são alguns dos exemplos de utilização de imagens provenientes do satélite Landsat para a estimativa de variáveis de interesse florestal.

Santos *et al.* (2017) avaliaram a viabilidade da utilização de imagens multiespectrais do sensor OLI/Landsat 8 através de análise de regressão com dados de campo, para a estimativa de parâmetros florestais em área de cerrado, obtendo valores de R^2_{aj} para o volume de 0,47 e 0,49, bem como um S_{xy} (%) de 44,01 e 43,48, semelhantes aos observados nas equações selecionadas da Área I, para os dois períodos. Ainda observou que as bandas espectrais B3 (verde), B4 (vermelho) e B7 (infravermelho médio – Swir₂) apresentaram melhores correlações com os parâmetros florestais do sensor OLI/Landsat 8 em seu estudo. Essas bandas foram significativas nesta pesquisa, visto que entraram em todas as equações da Área I, no período úmido, com exceção da B4 (vermelho), que só entrou nas equações da Área II, período seco.

Ao estimar o volume de madeira por hectare em área de Caatinga brasileira, a partir de dados do sensor TM do Landsat 5, após realizar validação cruzada, Almeida *et al.* (2014) obtiveram equações com R^2 e RMSE de 0,61 e 34,5. Gasparri *et al.* (2010) realizaram um estudo de análise multitemporal entre dados Landsat e características da vegetação subtropical seca da Argentina e observaram que apenas a banda espectral do infravermelho próximo (B4) não apresentou correlação significativa com as variáveis dendrométricas. O resultado é justificado pela sensibilidade dessa banda do Landsat 5/TM à vegetação densa, o que não ocorre em regiões secas, cuja vegetação é mais esparsa e o solo, por sua vez, mais exposto, influenciando nos valores de reflectância.

Berra *et al.* (2012) encontraram valores de R^2_{aj} e S_{xy} (%) oscilando entre 0,61 e 0,68 e 106,35% e 118,31%, respectivamente, ao modelar equações para estimar volume de madeira de *Eucalyptus sp.*, a partir de imagens Landsat 5/TM, utilizando os índices SR e NDVI.

Barros *et al.* (2015) utilizaram imagens do Landsat 5 para a determinação do volume de uma floresta de eucalipto, na região de Botucatu/SP, obtendo equações com valores de R^2_{aj} de 0,70 e 0,56, próximos aos encontrados nesse trabalho com o sensor OLI. Valores

semelhantes de R^2 foram obtidos por Canavesi *et al.* (2010), na estimativa do volume de madeira em plantios de *Eucalyptus spp.*, com a aplicação de dados hiperespectrais.

Hentz *et al.* (2014) testaram a relação entre NDVI, SAVI e EVI com dados de biomassa arbórea em fragmento de floresta ombrófila mista e ajustaram equações para estimar os valores de biomassa a partir do índice de maior correlação, que, nesse caso, foi com o $SAVI_{L=0,5}$, utilizando cena do satélite Landsat 8/OLI, observando que o melhor ajuste foi dado pela equação com índice na forma logaritimizada, assim como o obtido neste estudo, e obteve R^2_{aj} de 0,86 e $S_{xy}(\%)$ de 27,98%.

Os resultados apresentados Hentz *et al.* (2014) são semelhantes aos encontrados por Watzlawick *et al.* (2009), que avaliaram biomassa arbórea utilizando imagens do satélite Ikonos II e observaram para diversos índices valores de erro variando de 22% a 61% e de R^2_{aj} máximo de 0,73. No presente estudo, as melhores equações (transformadas) para estimar tanto a biomassa quanto o carbono obtiveram valores semelhantes de R^2_{aj} e $S_{xy}(\%)$, que oscilaram entre 0,46 a 0,66 e 6,03% a 17,2%, nesta ordem. Watzlawick *et al.* (2009) modelaram equação com o uso exclusivo do SAVI e obtiveram erro de 40% e R^2_{aj} de 0,57, diferentemente do observado por Hentz *et al.* (2014), assim como, nesse estudo, o $SAVI_{L=0,5}$ também não teve significância com a biomassa, não compondo nenhuma equação.

Com o objetivo de estimar o estoque de biomassa aérea e o carbono de uma área de caatinga, foi realizada a correlação entre os valores de biomassa da caatinga arbórea, medidos em campo, e os índices de vegetação pela diferença normalizada (NDVI) e pelo ajuste do solo (SAVI), calculados com uso de cenas do sensor Landsat 5/TM.

Lima Júnior *et al.* (2014), ao investigar a relação entre o NDVI e a biomassa estimada ($t.ha^{-1}$) com uso de equações alométricas em uma área de caatinga hiperxerófila, com o intuito de ajustar um modelo de regressão linear que permitisse estimar a biomassa lenhosa em áreas em FTS, encontraram, em seus estudos, um coeficiente de determinação $R^2 = 0,70$ e desvio padrão de $8,43 t.h^{-1}$. O erro de predição na estimativa da biomassa, calculado por validação cruzada, foi igual a 31%, sendo considerado satisfatório para um método não destrutivo.

Rezende *et al.* (2006) selecionaram modelos para estimativa de volume, biomassa e estoque de carbono para área de cerrado, em Brasília, com cubagem rigorosa, feita pelo método de Smalian. Testaram vários modelos matemáticos e utilizaram os mesmos critérios

estatísticos utilizados neste trabalho, para selecionar as melhores equações. Apresentaram coeficientes de determinação acima de 93% e erros padrões percentuais entre 25,03% e 28,09%.

Miguel *et al.* (2015) avaliaram a eficácia da aplicação de modelos de análise de regressão e redes neurais artificiais (RNA) para prever volume de madeira e da biomassa acima do solo, de vegetação arbórea em área de cerradão, utilizando dados orbitais do sensor LISS-III. A equação de regressão para o volume de madeira total apresentou 0,96 para R^2 e 11,92% para S_{xy} , respectivamente, enquanto a biomassa, 0,91 para R^2 e 22,73% para S_{xy} , nesta ordem. Apresentaram bons ajustes, porém, um pouco inferior em relação ao ajuste obtido pelas RNA. Schoeninger *et al.* (2008) e Ferraz *et al.* (2014) afirmaram que essa tecnologia associada às imagens orbitais e suas derivadas, é uma ferramenta promissora na estimativa de parâmetros florestais de difícil obtenção.

As estimativas usando o método convencional, em geral, apresentam melhores ajustes quando comparado às técnicas do Sensoriamento Remoto. Porém, estudos com LIDAR têm alcançado resultados tão bons quanto, como os encontrados por Figueiredo *et al.* (2014), que estimou volume em área de floresta tropical na Amazônia, e por Lefsky *et al.* (2002), em estudo para estimativa de biomassa em três formações florestais distintas.

As equações e os ajustes encontrados neste trabalho estão em concordância com a literatura, com resultados melhores que alguns resultados encontrados utilizando imagens espectrais. Dessa forma, é notório o elevado potencial das técnicas de sensoriamento remoto em estimar variáveis florestais, sua viabilidade em trabalhar com áreas de diferentes extensões, a facilidade em adquirir os dados, bem como a praticidade em obtê-los sem contato físico.

5.3 ESPACIALIZAÇÃO DAS VARIÁVEIS BIOFÍSICAS

Com a espacialização das variáveis biofísicas em função das melhores equações para as Áreas I e II, em ambos períodos estudados, cada pixel passou a representar o valor de volume de madeira (m^3/ua), biomassa (kg/ua) e carbono (kg/ua), viabilizando suas quantificações nos fragmentos de FTS. Essas informações, gerenciadas por um SIG, compõem uma das principais ferramentas de interesse no processo de gestão florestal, visando à otimização da produtividade.

Foram gerados 12 mapas temáticos, quatro para cada variável dependente, representados nas Figuras 8, 9 e 10. Eles ilustram a variação das variáveis biofísicas pela alteração das cores associadas, permitindo detectar áreas homogêneas e heterogêneas e comprovando a eficiência da metodologia utilizada ao fornecer imagens precisas da disponibilidade volumétrica, quantificação de biomassa e de carbono nas áreas estudadas.

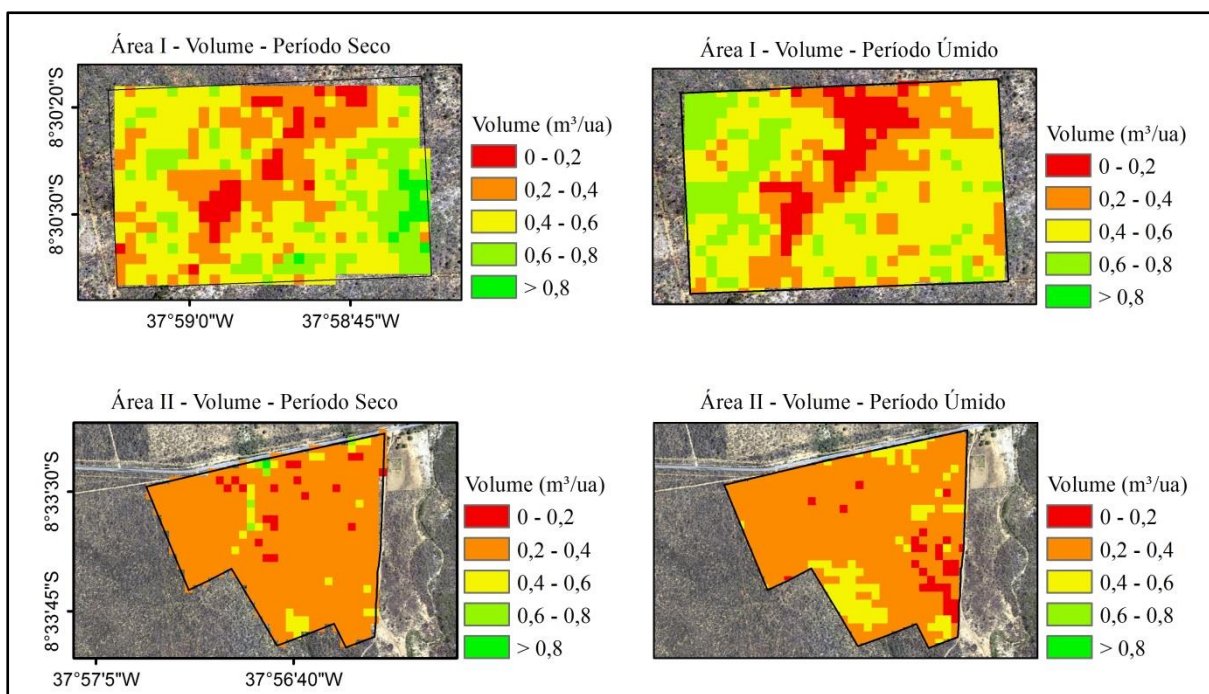


Figura 8: Espacialização da variável Volume (m^3/ua), para as Áreas I e II, nos períodos seco e úmido, Floresta – PE.

Fonte: A autora.

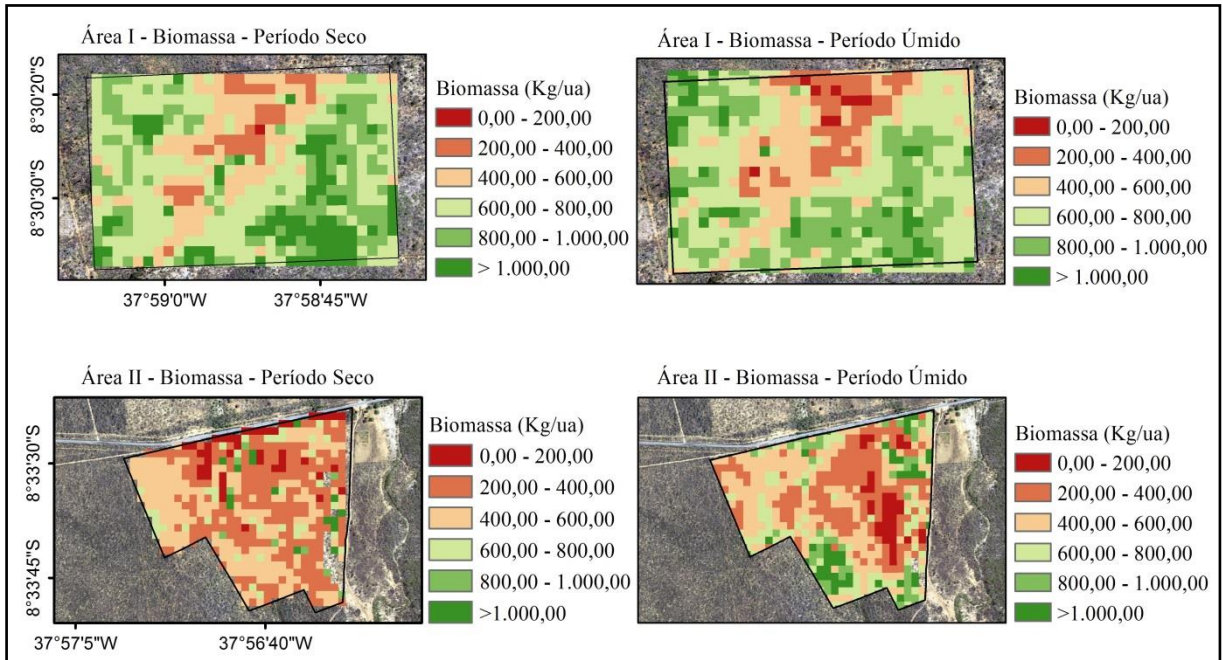


Figura 9: Espacialização da variável Biomassa (kg/ua), para as Áreas I e II, nos períodos seco e úmido, Floresta – PE.

Fonte: A autora.

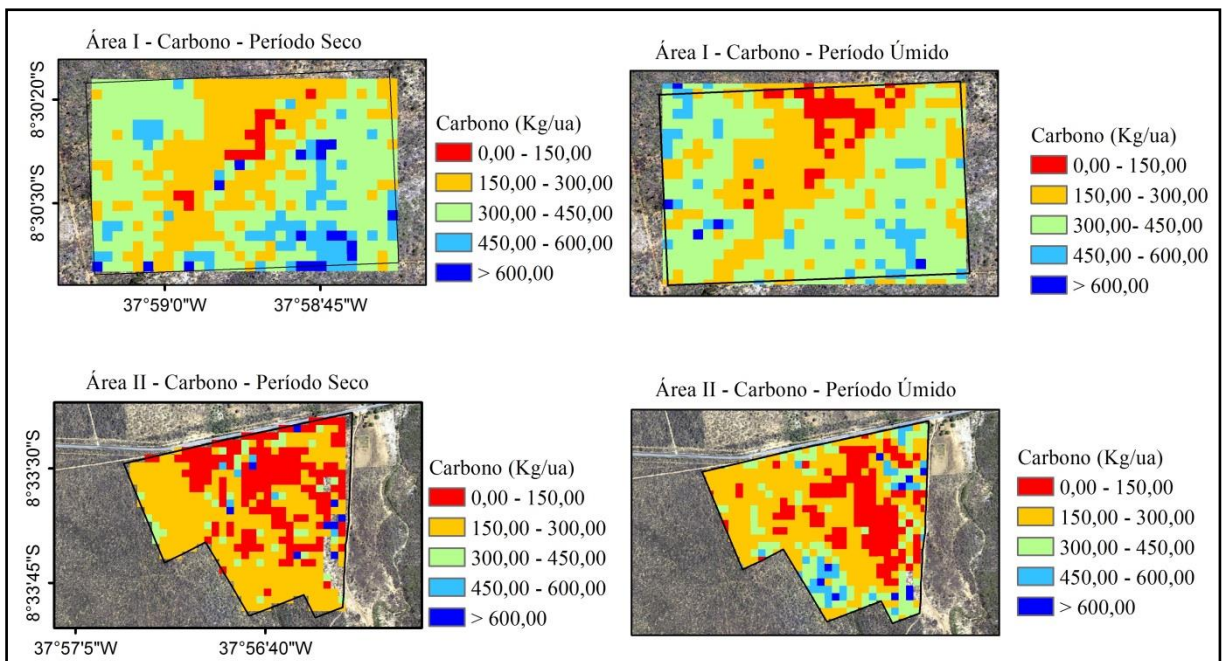


Figura 10: Espacialização da variável Carbono (kg/ua), para as Áreas I e II, nos períodos seco e úmido, Floresta – PE.

Fonte: A autora.

6. CONCLUSÕES

Os dados Landsat 8/OLI demonstraram ser úteis para estimativas precisas do volume, biomassa e carbono, assim como aptidão para serem utilizados no planejamento florestal. A relação significativa ao nível de probabilidade entre as variáveis preditoras, o S_{xy} (%), o R^2_{aj} e os gráficos de resíduos mostraram a aplicabilidade do método para a estimativa de variáveis biofísicas em FTS.

A sazonalidade e o histórico do uso do solo influenciaram na resposta espectral da vegetação e, conseqüentemente, na precisão do ajuste das equações para estimar variáveis biofísicas, concluindo que é preferível realizar estimativas de variáveis biofísicas utilizando imagens orbitais e técnicas de sensoriamento remoto em Floresta Tropical Seca nos períodos secos. Para que haja um aumento da precisão, faz-se necessário reduzir a variabilidade nos dados coletados em campo, pois a Caatinga é uma fitofisionomia bastante heterogênea e tal característica influencia diretamente nos ajustes.

De forma geral, para todas as análises realizadas, a Área I (Transposição) obteve melhores resultados em relação à Área II (Correntão), nos dois períodos estudados, ao comparar os critérios estatísticos.

Na Área II (Correntão), os impactos resultantes da atividade continuam influenciando de forma negativa nas estimativas de volume, biomassa e carbono.

A banda B6 é a região do espectro eletromagnético que melhor representa a vegetação de caatinga, independentemente da estação.

O uso da banda B4 mostrou-se apropriado para ambientes secos e impactado por atividades antrópicas, desde que seja na estação úmida.

As bandas B2, B6 e B7 são adequadas para o período seco em ambientes áridos, independentemente do histórico do uso do solo.

Os índices de vegetação EVI e $SAVI_{L=0,5}$ não são adequados para realizar estimativas em Floresta Tropical Seca, independentemente da sazonalidade.

O uso do índice NDVI, para ajustes de equações, para estimar volume, biomassa e carbono, mostrou-se inapropriado em estação seca, mas eficiente no período úmido.

As regressões múltiplas, sobretudo as de biomassa e carbono, apresentaram destaque nos ajustes após transformação dos índices de vegetação de valores positivos, constituindo as mais indicadas para estimar variáveis biofísicas.

A espacialização, gerenciada por SIG, resultou em imagens capazes de representar a distribuição do volume, biomassa e carbono nas áreas e épocas estudadas e compõe uma das principais ferramentas no processo de gestão florestal, visando nortear ações, auxiliar na tomada de decisão e subsidiar projetos futuros.

7. RECOMENDAÇÕES

Sugere-se teste sobre o fator L do índice SAVI em área de Caatinga, independente da sazonalidade, uma vez que esse índice não apresentou relação significativa com as variáveis florestais englobadas no estudo em ambos os períodos de análise.

Em virtude da disponibilidade de cenas da área de estudo no período da coleta dos dados em campo, foi possível selecionar apenas duas, para fins de análises, uma em cada período. Porém, recomenda-se repetir o estudo com outras cenas ao longo do ano, a fim de contemplar a variabilidade nas condições ambientais neste tipo de fitofisionomia, propiciando maior representatividade da qualidade dos dados.

Utilizar UAs com dimensões superiores à área mínima detectada pelo sensor (pixel), posto que facilitaria a identificação da área contendo a informação espectral registrada em campo, reduzindo a influência de outros alvos na resposta espectral delimitada pelo pixel.

Na perspectiva moderna de gestão, planejamento, ordenação ou monitoramento do espaço é necessário incluir a análise dos distintos componentes ambientais, tendo em vista que influenciam diretamente nas análises. Logo, são necessárias pesquisas complementares com o objetivo de aumentar a precisão das estimativas e reduzir, cada vez mais, o erro. Isso poderá ser alcançado com o aumento do número de pontos amostrais, o uso de imagens de satélites com melhor resolução espacial que o Landsat 8/OLI, além de índices de vegetação mais específicos para este tipo de fitofisionomia.

É válido ressaltar a importância do uso do geoprocessamento em projetos do segmento florestal como uma realidade atual, que requer técnicas de correlação de dados em conjunto com ferramentas que permitem a análise espacial, o processamento de imagens e modelagem numérica de terreno. Por sua praticidade e rapidez, pode subsidiar a gestão florestal e ser uma excelente alternativa para obtenção de informações importantes com elevado grau de exatidão e confiabilidade, remotamente, dispensando, assim, as dificuldades e os custos onerosos intrínsecos aos inventários florestais e a outras atividades vinculadas à área ambiental.

REFERÊNCIAS

ALBA, E. et al. Uso de Imagens de Média Resolução Espacial para o Monitoramento de Dosséis DE *Eucalyptus grandis*. **Scientia Agraria**, [s.l.], v. 18, n. 4, p. 1-8, dez. 2017.

ALBA, E. **Caracterização espectral dos dosséis e estimativa de variável biofísica em plantios de *Eucalyptus grandis* e *Pinus elliottii* a partir de imagens Landsat 8/OLI**. 2016. 131 f. Dissertação (Mestrado em Recursos Florestais e Engenharia Florestal) - Universidade Federal de Santa Maria, Santa Maria, 2016.

ALMEIDA, A. Q. et al. Relações empíricas entre características dendrométricas da Caatinga brasileira e dados TM Landsat 5. **Pesquisa Agropecuária Brasileira**, [s.l.], v. 49, n. 4, p.306-315, abr. 2014. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0100-204x2014000400009>.

ALVES JUNIOR, F. T. **Estrutura, biomassa e volumetria de uma área de caatinga, Floresta, PE**. 2010. 123 f. Tese (Doutorado em Ciências Florestais) – Universidade Federal Rural de Pernambuco, Departamento de Ciência Florestal, Recife, 2010.

ALVES, A. R. et al. Nutrientes na biomassa aérea e na serapilheira em áreas de caatinga em Floresta, PE. **Pesquisa Florestal Brasileira**, [s.l.], v. 37, n. 92, p.413-420, 29 dez. 2017. Embrapa Florestas. <http://dx.doi.org/10.4336/2017.pfb.37.92.1060>.

AMÉRICO, C. Sustentabilidade para o desenvolvimento da Caatinga: Desmatamento causado pelo uso da madeira para produção de energia é um dos problemas do bioma. **Ações combinadas que protejam a fauna, flora e o bem-estar social garantem benefício para a região**. Ministério do Meio Ambiente - MMA, 2018. Disponível em: <<http://www.mma.gov.br/informma/item/7003-sustentabilidade-para-o-desenvolvimento-da-caatinga>>. Acesso em: 30 abr. 2020.

APG IV. An update of the Angiosperm Phylogeny Group classification for the orders and families of flowering plants: APG IV. **Botanical Journal of the Linnean Society**, v.181, n.1, p. 1-20, 2016.

AZEVEDO, S. M. A.; AZEVÊDO, M. A. A. Crescimento de plântulas de jurema preta (*Mimosa tenuiflora* (Wild) Poiret) em solos de áreas degradadas da caatinga. **Engenharia Ambiental: Pesquisa e Tecnologia**, v. 9, n. 3, p.150-160, 2012.

BANNARI, A. et al. A review of vegetation indices. **Remote Sensing Reviews**, v.13, p.95-120, 1995. DOI: 10.1080/02757259509532298.

BARBOSA, K. M. N. et al. Estudo temporal da vegetação herbácea da várzea da Amazônia central. **Revista Floresta**, v. 38, n. 1, Jan./Mar., 2008.

BARET, F.; GUYOT, G. Potentials and limits of vegetation indices for LAI and APAR assessment. **Remote Sensing of Environment**, v. 35, p. 161-173, 1991.

BARRETO, T. N. A. **Avaliação de modelos e métodos geoestatísticos para estimativa de biomassa em área de caatinga**. 2017. 100 f. Tese (Doutorado em Ciências Florestais) – Universidade Federal Rural de Pernambuco, Departamento de Ciência Florestal, Recife, 2017.

BARROS, B. S. X. de et al. Uso de imagens de satélite para cálculo de volume em floresta de eucalipto no município de Botucatu/SP. **Energia na Agricultura**, [s.l.], v. 30, n. 1, p.60-67, 1 abr. 2015. EIA Energy in Agriculture. <http://dx.doi.org/10.17224/energagric.2015v30n1p60-67>.

BASTIN, J.-F. et al. The extent of forest in dryland biomes. **Science**, New York, v.356, n.6338, p.635–638, 2017. <https://doi.org/10.1126/science.aam6527>.

BECKNELL, M. J. et al. Aboveground biomass in mature and secondary seasonally dry tropical forests: A literature review and global synthesis. **Forest Ecology and Management**, v.276, p.88-95, 2012. <https://doi.org/10.1016/j.foreco.2012.03.033>.

BEHERA, S. K. et al. Aboveground biomass and carbon stock assessment in Indian tropical deciduous forest and relationship with stand structural attributes. **Ecological Engineering**, v.99, p.513-524, 2017. <https://doi.org/10.1016/j.ecoleng.2016.11.046>.

BENEDITTI, C. A. et al. Comparação do índice de área foliar (IAF) estimado por sensoriamento remoto entre os anos de 1984 e 2011 na região central de Rondônia. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17. (SBSR), 2015, João Pessoa. **Anais...** São José dos Campos: INPE, 2015. p. 2937-2943. Internet. ISBN 978-85-17-0076-8. IBI: <8JMKD3MGP6W34M/3JM4AH8>. Disponível em:<<http://urlib.net/rep/8JMKD3MGP6W34M/3JM4AH8>>.

BERRA, E. F. **Avaliação e comparação de imagens LISS-III/ResourceSAT-1 e TM/LANDSAT 5 para estimar volume de madeira de um plantio de *Pinus elliottii***. 2013. 127 p. Dissertação (Mestrado em Sensoriamento Remoto) – Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, 2013.

BERRA, E. F. et al. Estimativa do volume total de madeira em espécies de eucalipto a partir de imagens de satélite Landsat. **Ciência Florestal**, [s.l.], v. 22, n. 4, p.853-864, 26 dez. 2012. Universidad Federal de Santa Maria. <http://dx.doi.org/10.5902/198050987566>.

BINOTI, M. L. M. S. **Emprego de redes neurais artificiais em mensuração e manejo florestal**. 2012. 130f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2012.

BINOTI, M. L. M. S. et al. Redes neurais artificiais para estimação do volume de árvores. **Revista Árvore**, v. 38, p. 283-288, 2014.

BLACKIE, R. et al. **Tropical dry forests: The state of global knowledge and recommendations for future research**. Discussion Paper. Bogor, Indonesia: CIFOR. 2014.

BRANDELERO, C. et al. Silvicultura de precisão: mapeamento, inventário e geoestatística. **Revista Geomática**, v.2, n.1, p.12-25, 2007.

BRASIL. Ministério do Meio Ambiente. **Biomass**: Caatinga. Brasília, DF, [2014]. Disponível em: <<http://www.mma.gov.br/biomass/caatinga>>. Acesso em: 20 ago. 2019.

CAMPOS, J. C. C.; LEITE, H. G. **Mensuração Florestal**: perguntas e respostas. 2 ed. Viçosa-MG: UFV, 2006. 407 p.

CANAVESI, V. et al. Estimativa de volume de madeira em plantios de *Eucalyptus* spp. utilizando dados hiperespectrais e dados topográficos. Viçosa, **Revista Árvore**. Viçosa, MG, v.34, n.3, p. 539-549, 2010.

CHATURVEDI, R. K. et al. Carbon density and accumulation in woody species of tropical dry forest in India. **Forest Ecology and Management**, v.262, n.8, p.1576-1588, 2011. <https://doi.org/10.1016/j.foreco.2011.07.006>.

CHAVES, I. DE B. et al. Índices espectrais, diagnóstico da vegetação e da degradação da caatinga da bacia do Rio Taperoá-PB. In: SILVA, B. B. da. (Org.). **Aplicações ambientais brasileiras de geoprocessamento e sensoriamento remoto**. Campina Grande: EDUFPG, 2013. 1-31.

CHRYSAFIS, I. et al. Estimating Mediterranean forest parameters using multi seasonal Landsat 8 OLI imagery and an ensemble learning method. **Remote Sensing of Environment**, New York, v. 199, p.154-166, 2017.

CLEVERS, J. G. P. W. The derivation of a simplified reflectance model for the estimation of leaf area index. **Remote Sensing of Environment**, v. 25, n. 1, p. 53–70, 1988. Disponível em: <http://www.sciencedirect.com/science/article/pii/0034425788900417>>. Acesso em: 25 ago. 2019. DOI: 10.1016/0034-4257(88)90041-7.

CONGEDO, L. Tutorial: Land Cover Classification Using the Semi-automatic Classification Plugin v. 3.0 “Rome” for QGIS. Disponível em: <<https://fromgistors.blogspot.com/2014/06/land-cover-classification-using-SCP-3.html>>. Acesso em: 30 nov. 2019.

COSTA, L. F. et al. Estimativa do volume e densidade de árvores em povoamentos de *Eucalyptus grandis* a partir de dados espectrais. In: SIMPÓSIO LATINO AMERICANO DE MANEJO FLORESTAL, 6., 2015, Santa Maria/RS. **Anais...** Santa Maria/RS: Universidade Federal de Santa Maria, 2015, p. 210-217.

COUTINHO, M. A. N.; Fernandes, A.C.G.; Santos, V. G; Nascimento, C.R. Análise comparativa dos índices de vegetação NDVI, SAVI, RATIO E IAF para identificação de queimadas. **Caderno de Ciências Agrárias**, Montes Claros, MG, v. 8, n. 1, p.70-81, 20 abr. 2016.

CUNHA, U. S. da. Dendrometria e inventário florestal. Manaus, 2004, 61p. **Apostila** - Escola Agrotécnica Federal de Manaus.

DALLA LANA, M. et al. Biomass equations for Caatinga species. **Nativa**, v.6, n.5, p.517-525. 2018. <http://dx.doi.org/10.31413/nativa.v6i5.5361>.

DALLA LANA, M. et al. Carbon Content in Shrub-tree Species of the Caatinga. **Floresta e Ambiente**, v.26, n.2, p.e20170617. 2019. <http://dx.doi.org/10.1590/2179-8087.061717>.

DALLAGNOL, F. S. et al. Teores de carbono de cinco espécies florestais e seus compartimentos. **Floresta e Ambiente**, v.18, n.4, p.410-416, 2011. <http://dx.doi.org/10.4322/floram.2011.060>.

DICKINSON, M. B. et al. Low rates of background canopy - gap disturbance in a seasonally dry forest in the Yucatan Peninsula with a history of fires and hurricanes. **Journal of Tropical Ecology**, 17(6): 895-902. 2001.

DU, H. et al. The responses of Moso bamboo (*Phyllostachys heterocycla* var. *pubescens*) forest aboveground biomass to Landsat TM spectral reflectance and NDVI. **Acta Ecologica Sinica**, v.30, p.257-263, 2010. DOI: 10.1016/j.chnaes.2010.08.005.

EMBRAPA - Empresa Brasileira de Pesquisa Agropecuária. **Diagnóstico Ambiental do Município de Floresta, Pernambuco**. Rio de Janeiro-RJ: EMBRAPA, 2001. (Circular Técnica, ISSN 1517-5146). Disponível em: <<https://ainfo.cnptia.embrapa.br/digital/bitstream/CNPS/11849/1/circular tecnica10diagambflor esta.pdf>> Acesso em: 11 de maio de 2018.

EMBRAPA - Empresa Brasileira de Pesquisa Agropecuária. **Levantamento de reconhecimento de baixa e média intensidade dos solos do Estado de Pernambuco**. Rio de Janeiro: Embrapa Solos, 2000.

EMBRAPA - Empresa Brasileira de Pesquisa Agropecuária. **Sistema brasileiro de classificação de solos**. 5.ed. Rio de Janeiro: EMBRAPA, 2018. 353p.

FEELEY, K. J. et al. The utility of spectral indices from Landsat ETM+ for measuring the structure and composition of tropical dry forest. **Biotropica**, v.37, p.508-519, 2005. DOI: 10.1111/j.1744-7429.2005.00069.x.

FEITOSA, J. R. P. et al. Avaliação de índices de vegetação em área irrigada do sub-médio São Francisco, Petrolina-PE, a partir de imagens do satélite LANDSAT 5-TM. In: Congresso Brasileiro de Meteorologia, 18, 2004, Fortaleza. **Anais...** Fortaleza, 2004.

FERRAZ, A. S. et al. Estimativa do estoque de biomassa em um fragmento florestal usando imagens orbitais. **Floresta e Ambiente**, Seropédica, v. 21, n. 3, p. 286-296, 2014. <http://dx.doi.org/10.1590/2179-8087.052213>.

FERRAZ, J. S. F. **Análise da vegetação de caatinga arbustivo – arbórea em Floresta, PE, como subsídio ao manejo florestal.** 2011. 131 f. Tese (Doutorado em Ciências Florestais) – Universidade Federal Rural de Pernambuco, Departamento de Ciência Florestal, Recife, 2011.

FICK, Tiago Antonio. Amostragem para inventário florestal em sistemas silvipastoris. **Revista Árvore**, v. 35, n. 5, p.1033-1038, 2011. <http://dx.doi.org/10.1590/s0100-67622011000600009>.

FIGUEIREDO, E. O. et al. Modelos para estimativa de volume de árvores individuais pela morfometria da copa obtida com lidar. **Cerne**, Lavras, v. 20, n. 4, p. 621-628, 2014. (DOI: <http://dx.doi.org/10.1590/01047760201420041693>).

FINGER, C. A. G. **Fundamentos de biometria florestal.** Santa Maria: UFSM, FATEC, 1992. 269 p.

FITZ, P. R. Cartografia básica. São Paulo: Oficina de Textos, 2008.

FRANCISCO et al. Análise espectral e avaliação de índices de vegetação para o mapeamento da caatinga. **Revista Verde** (Pombal - PB - Brasil) v. 10, n.3, p 01 - 12, jul-set, 2015.

GAMA, J. R. V. et al. Fitossociologia de duas fitocenoses de Floresta Ombrófila Aberta no Município de Codó, Estado do Maranhão. **Revista Árvore**, 31:465-477,2007.

GARIGLIO, M. A. Manejo florestal sustentável em assentamentos rurais na caatinga. In: PAREYN, F. G. C.; VIEIRA, J. L.; GARIGLIO, M. A (Orgs.). **Estatística Florestal da Caatinga.** Recife: Associação Plantas do Nordeste, v. 2, p. 6-17, 2015.

GASPARRI, N. I. et al. Assessing multi-temporal Landsat 7 ETM+ images for estimating above-ground biomass in subtropical dry forests of Argentina. **Journal of Arid Environments**, v.74, p.1262-1270, 2010. DOI: 10.1016/j.jaridenv.2010.04.007.

GENTRY, A. H. Changes in plant community diversity and floristic composition on environmental and geographical gradients. **Annals of the Missouri Botanical Garden**, v.75, n. 1-34, 1988. <https://doi.org/10.2307/2399464>.

GILLESPIE, T. et al. The rarest and least protected forests in biodiversity hotspots. **Biodiversity and Conservation**, v. 21, n. 14, p. 3597-3611, 2012.

GILLESPIE, T. W. Predicting woody-plant species richness in tropical dry forests: a case study from South Florida, USA. **Ecological Applications**, v.15, p.27-37, 2005. DOI: 10.1890/03-5304.

GITELSON, A. et al. "Use of a Green Channel in Remote Sensing of Global Vegetation from EOS-MODIS." **Remote Sensing of Environment** 58 (1996): 289-298.

GOERGEN, L. C. de G. **Uso da reflectância de imagens Landsat 5 TM na identificação de plantios de *Eucalyptus dunnii* e *Eucalyptus urograndis* e sua correlação com o volume de madeira.** 2014. 100 p. Dissertação (Mestrado em Engenharia Florestal) – Universidade Federal de Santa Maria, Santa Maria, RS, 2014.

GONÇALVES, T. S. A floresta estacional decidual no Brasil: distribuição geográfica e influência dos aspectos pedogeomorfológicos na vegetação. **Monografias Ambientais**, v.14, n.1, p.144-153, 2015. <http://dx.doi.org/10.5902/2236130815213>.

GUIMARÃES, A. P. **Dinâmica da resposta espectral da vegetação de caatinga na bacia hidrográfica do açude Soledade, utilizando técnicas de sensoriamento remoto.** Dissertação (Mestrado). Universidade Federal da Paraíba. Areia, 2009.

HARRIS, R. J. **A primer of multivariate statistics.** 3. ed. Mahwah: Lawrence Erlbaum, 2001.

HENTZ, A. M. K. et al. Técnicas de sensoriamento remoto para estimativa de biomassa em ambientes florestais. **Enciclopédia Biosfera**, Goiânia, v.10, n.18; p.2810-2823, 2014.

HOLBEN, B. N. et al. Spectral assessment of soybean leaf area and leaf biomass. **Photogrammetric Engineering and Remote Sensing**, n. 46, p. 651-656. 1980.

HOSOKAWA, R. T.; SOUZA, A. L. Amostragem para fins de manejo. **Curso de Manejo Florestal**. Brasília - DF, 1987, v. 5, 25p.

HUETE, A. et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, p. 195-213, Mar. 2002. Disponível em: < https://cimss.ssec.wisc.edu/dbs/China2011/Day2/Lectures/MODIS_MOD13_NDVI_referenc.pdf>. Acesso em: 12 mar. 2014.

Huete, A. R. et al. A Comparison of Vegetation Indices over a Global Set of TM Images for EOS-MODIS. **Remote Sensing of Environment**, n.59, p.440-451, 1997.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v.25, p.295-309, 1988. [http://dx.doi.org/10.1016/0034-4257\(88\)90106-X](http://dx.doi.org/10.1016/0034-4257(88)90106-X).

HUETE, A. R. et al. Spectral response of a plant canopy with different soil background. **Remote Sensing of Environment**, v. 17, n. 1, p. 37–53, Feb. 1985. Disponível em: < <http://www.sciencedirect.com/science/article/pii/0034425785901117>>. Acesso em: 10 fev. 2019.

HUSCH, B.; MILLER, C.I.; BEERS, T.W. **Forest mensuration.** 3 ed. Malabar: Krieger Publishing Company, 1993. 402 p.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Manual técnico da vegetação brasileira.** 2.ed. Rio de Janeiro: IBGE, 2012. 271p.

INSTITUTO NACIONAL DO SEMIÁRIDO – INSA. **Cerâmica na caatinga terá manejo florestal**. Ministério do Meio Ambiente - MMA, 2015. Disponível em: <<http://mma.gov.br/index.php/comunicacao/agencia-informma?view=blog&id=724>>. Acesso em: 30 abr. 2020.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos: Parêntese, 2009. 604 p.

JOLY, C. A. et al. Evolution of the Brazilian phytogeography classification systems: implications for biodiversity conservation. **Ciência e Cultura**, v.51, n.5/6, p.331-348, 1999.

JORDAN, C. F. Derivation of Leaf-Area Index from Quality of Light on the Forest Floor. **Ecology**, v. 50, n. 4, p. 663-666, 1969.

KALACSKA, M. E. R. et al. Estimating leaf area index from satellite imagery using Bayesian networks. **IEEE Transactions on Geoscience and Remote Sensing**, v.43, p.1866-1873, 2005. DOI: 10.1109/TGRS.2005.848412.

KAUTH, R.; THOMAS, G. "The Tasselled Cap-A Graphic Description of the Spectral-Temporal Development of Agricultural Crops as Seen By Landsat" In *Proceedings of the LARS 1976 Symposium of Machine Processing of Remotely-Sensed Data*, West Lafayette, IN: Purdue University, pp. 4B41-4B51.

KORTZ, A. R. **Florestas Tropicais Sazonalmente Secas: estudo da ocupação das áreas através de espécies representativas**. 2012. 92f. Dissertação (Mestrado) – Universidade Federal de São Carlos, Programa de Pós-Graduação em Diversidade Biológica e Conservação, Sorocaba. 2012.

LEBRIJA-TREJOS, E. et al. Pathways, mechanisms and predictability of vegetation change during tropical dry forest succession. **Perspectives in Plant EcoLny, Evolution and Systematics**, v.12, n.4, p.267–275, 2010.

LEFSKY, M. A. et al. Lidar Remote Sensing of Above-Ground Biomass in Three Biomes. **Global Ecology and Biogeography**, v. 11, n. 5, p. 393-399, 2002.

LILLESAND, T. M. et al. **Remote Sensing and Image Interpretation**. 7a ed. Hoboken: Wiley, 2015.

LIMA JÚNIOR, C. de. et al. Estimativa de biomassa lenhosa da caatinga com uso de equações alométricas e índice de vegetação. **Scientia Forestalis**, v.42, p.289-298, 2014.

LIU, H. et al. Rapid warming accelerates tree growth decline in semi-arid forests of Inner Asia. **Global Change BioLny**, [s.l.], v. 19, n. 8, p.2500-2510, 9 mai. 2013. Wiley. <http://dx.doi.org/10.1111/gcb.12217>.

LOPES, M. C. A. et al. The effects of rainfall and vegetation on litterfall production in the semiarid region of northeastern Brazil. **Brazilian Journal Of Biology**, [s.l.], v. 75, n. 3, p.703-708, 25 set. 2015. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/1519-6984.21613>.

LORENZ, K.; LAL, R. **Carbon Sequestration in Forest Ecosystems**. Springer Netherlands. 2010.

LU, D. et al. Relationships between forest stand parameters and Landsat TM spectral responses in the Brazilian Amazon Basin. **Forest Ecology and Management**, Amsterdam, v.198, n.1-3, p.149-167. 2004.

MELO, R. O. et al. Susceptibilidade à compactação e correlação entre as propriedades físicas de um Neossolo sob vegetação de caatinga. **Revista Caatinga**, v. 21, n. 5, p.12-17, 2008.

MENESES, P. R.; ALMEIDA, T. de. "**Introdução ao processamento de imagens de sensoriamento remoto.**" Embrapa Cerrados-Livros técnicos (INFOTECA-E). 2012.

MIGUEL, E. P. et al. Redes neurais artificiais para a modelagem do volume de madeira e biomassa do cerradão com dados de satélite. **Pesquisa Agropecuária Brasileira**, [s.l.], v. 50, n. 9, p.829-839, set. 2015. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0100-204x2015000900012>.

MIRANDA, D. L. C. de. et al. Equações alométricas para estimativa de biomassa e carbono em árvores de reflorestamentos de restauração. **Revista Árvore**, [s.l.], v. 35, n. 31, p.679-689, jun. 2011. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0100-67622011000400012>.

MOHAMMADI, J. et al. Modeling forest stand volume and density using Landsat ETM+ data. **International Journal of Remote Sensing**, v. 31, n. 11, p. 2959-2975, 2010.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicações**. 4. ed. Viçosa: Ed. UFV, 2011. 422p.

MURPHY, P.; LUGO, A. EcoLny of tropical dry forest. **Annual Review of Ecology and Systematics**.v.17, p.67-88, 1986. <http://dx.doi.org/10.1146/annurev.es.17.110186.000435>.

NATIONAL AERONAUTICS AND SPACE ADMINISTRATION. 2013. Disponível em:<<http://www.nasa.gov/>>. Acesso em: 15 set. 2019.

NGO, K. M. et al. Carbon stocks in primary and secondary tropical forests in Singapore. **Forest Ecology and Management**, Amsterdam-NL, v.296, p.81-89, 2013.

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

OLIVEIRA, E. V. S. **Dinâmica temporal e aspectos da vegetação em uma comunidade de Caatinga**. 2016. 98 f. Dissertação (Mestrado) – Universidade Federal do Sergipe, Programa de Pós-Graduação em Ecologia e Conservação, São Cristóvão, 2016.

OLIVEIRA, W. M. de. et al. Índices espectrais de vegetação de caatinga em um neossolo litólico do semiárido paraibano. In: Simpósio Brasileiro de Sensoriamento Remoto, 14, 2009, Natal. **Anais...** Natal: INPE, 2009. p. 2103-2110.

PALACIOS-ORUETA, A. et al. Biomass burning emissions: a review of models using remote sensing data. **Environmental Monitoring and Assessment**, v.104, p.189-209, 2005. DOI: 10.1007/s10661-005-1611-y.

PAN, Y. et al. A large and persistent carbon sink in the world's forests. **Science**, v.333, p.988–993, 2011.

PÉLLICO-NETTO. S.; BRENA, D. A. (1993). Apostila: Inventário florestal. Curitiba: Universidade Federal do Paraná, **1993**. 245 p.

PEREIRA JÚNIOR, R. L. et al. Carbon stocks in a tropical dry forest in Brazil. **Revista Ciência Agronômica**, 47(1): 32-40. 2016.

PERTILLE, C. T. et al. Estimativa do volume de Pinus taeda L. a partir de dados de sensoriamento remoto. **Scientia Forestalis**, [s.l.], v. 47, n. 123, p. 526-535, 30 set. 2019. Instituto de Pesquisa e Estudos Florestais (IPEF). <http://dx.doi.org/10.18671/scifor.v47n123.14>.

PINTY, B.; M. VERSTRAETE. GEMI: a Non-Linear Index to Monitor Global Vegetation From Satellites. *Vegetation* 101 (1992): 15-20.

PONZONI, F. J. **Comportamento Espectral da Vegetação**. In: MENESES, P. R., NETTO, J. S. M. (Org) Sensoriamento remoto, reflectância dos alvos naturais. Brasília – DF: Editora Universidade de Brasília - UNB, Embrapa Cerrados, p. 157-199, 2001.

PONZONI, F. J. et al. **Sensoriamento Remoto da vegetação**. 2 Ed. São Paulo: Oficina de Textos, v.11, n.3-4. 164p. 2012.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento Remoto no Estudo da Vegetação**. 2010. ed. São José dos Campos: Parêntese, 2010. 128 p.

POWELL, S. L. et al. Quantification of live aboveground forest biomass dynamics with Landsat time-series and field inventory data: a comparison of empirical modeling approaches. **Remote Sensing of Environment**, v.114, p.1053-1068, 2010. DOI: 10.1016/j.rse.2009.12.018.

PULLA, S. et al. Assessing the resilience of Global dry forests: a proLnew global seasonally dry tropical forests. **International Forestry Review**, v.17, n.2, p.91–113, 2015.

QGIS Development Team, (2018). QGIS Geographic Information System. Open Source Geospatial Foundation Project. <http://www.qgis.org/>

R Development Core Team. R: A Language and Environment for Statistical Computing. Vienna: R Foundation for Statistical Computing, 2019. Disponível em: <<http://www.r-project.org>>. Acesso em: 12 set. 2019.

RAMOS, M. F. **Estudo da variação temporal do Índice de Vegetação por Diferença Normalizada em Juiz de Fora a partir de imagens de satélite.** 2016. 41 f. TCC (Graduação) - Curso de Engenharia Ambiental e Sanitária, Faculdade de Engenharia da Ufjf, Juiz de Fora, 2016.

REIS, A. et al. **Manejo do Palmitreiro (*Euterpe edulis*) em Regime de Rendimento Sustentável.** Florianópolis, UFSC, 1994.

REZENDE, A. V. et al. Comparação de modelos matemáticos para estimativa do volume, biomassa e estoque de carbono da vegetação lenhosa de um cerrado *sensu stricto* em Brasília, DF. **Scientia Forestalis**, n.71, p.65-73, 2006.

RIBEIRO, M. R. et al. Os solos e o processo de desertificação no semiárido brasileiro. In: Tópicos em ciência do solo, v. 6, 497p. **Sociedade Brasileira de Ciência do Solo.** Viçosa, p.413-449. 2009.

ROBINSON, N. P. et al. Dynamic Landsat Derived Normalized Difference Vegetation Index (NDVI) Product for the Conterminous United States. **Remote Sensing.** 9, 863. 2017.

RODRIGUES, P. M. S. et al. Climate change effects on the geographic distribution of specialist tree species of the Brazilian tropical dry forests. **Brazilian Journal Of BioLny**, [s.l.], v. 75, n. 3, p.679-684, 2015. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/1519-6984.20913>.

ROSENQVIST, A. et al. A review of remote sensing technology in support of the Kyoto Protocol. **Environmental Science and Policy**, v.6, p.441-455, 2003. DOI: 10.1016/S1462-9011(03)00070-4.

ROUSE, J. W. et al. **Monitoring the vernal advancement of retrogradation (greenwave effect) of natural vegetation.** NASA/GSFC, Type III, Final Report, Greenbelt, MD, 1974, 371 p.

ROY, D. P. et al. Landsat-8: Science and product vision for terrestrial global change research. **Remote sensing of Environment**, v. 145, p. 154-172, 2014.

RUFINI, A. L. et al. Equações volumétricas para o cerrado *sensu stricto*, em Minas Gerais. **Cerne**, Lavras, v. 16, n. 1, p. 1-11, 2010.

SÁ, I. I. S. et al. Uso do índice de vegetação da diferença normalizada (IVDN) para caracterização da cobertura vegetal da Região do Araripe Pernambucano. **Revista Brasileira de Geografia Física**, v.1 n.1. 28-38. 2008.

SAMPAIO, E. V. S. B. et al. Tree biomass estimation in regenerating areas of tropical dry vegetation in northeast Brazil. **Forest Ecology and Management**. v.259, p 1135–1140, 2010.

SAMPAIO, E. V. S. B. et al. Espacialização do uso da vegetação nativa no semi-árido nordestino. **Revista de Geografia**, Recife, v. 23, p. 117-156, 2006.

SANQUETTA, C. R; BALBINOT, C. R. R. Metodologias para determinação de biomassa florestal. In: Fixação de carbono: atualizações, projetos e pesquisas. Curitiba. 2004. p. 77-94.

SANTOS, G. D. et al. Mineração de dados aplicada à discriminação da cobertura da terra em imagem LANDSAT 8 OLI. **Boletim de Ciências Geodésicas**, v. 21, n. 4, 2015.

SANTOS, M. M. et al. Estimativa de parâmetros florestais em área de Cerrado a partir de imagens do sensor Landsat 8. **Floresta**, [s.l.], v. 47, n. 1, p.75-83, 31 mar. 2017. Universidade Federal do Paraná. <http://dx.doi.org/10.5380/rf.v47i1.47988>.

SANTOS, M. S. **Influência de diferentes níveis de uso sobre a regeneração natural em ambiente de caatinga no município de Floresta, PE**. 2013. 54 f. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal Rural de Pernambuco, Departamento de Ciência Florestal, Recife, 2013.

SCHNEIDER, P. R. et al. **Análise de regressão aplicada à Engenharia Florestal**. 2. ed. Santa Maria: Facos, 2009.

SCHOENINGER, E.R. et al. Uso de redes neurais artificiais para mapeamento de biomassa e carbono orgânico no componente arbóreo de uma Floresta Ombrófila Densa. **Ambiência**, v.4, p.179-195, 2008.

SILVA, A. M. Curso Processamento digital de imagens de satélite. Porto Alegre: Centro de Eventos da PUCRS, 2001. Disponível em: < <http://www.cartografia.org.br> >

SILVA, E. N. da; SANTANA, A. C. de. Modelos de regressão para estimação do volume de árvores comerciais, em florestas de Paragominas. **Revista Ceres**, Viçosa, v. 61, n. 5, p. 631-636, out. 2014. Disponível em <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0034-737X2014000500005&lng=pt&nrm=iso>. acessos em 21 maio 2019. <https://doi.org/10.1590/0034-737X201461050005>.

SILVA, G. C.; SAMPAIO, E. V. S. B. Biomassas de partes aéreas em plantas da Caatinga. **Revista Árvore**, Viçosa-MG, v. 32, n. 3, p. 567-575, 2008.

SILVA, J. A. A.; PAULA NETO, F. **Princípios básicos de dendrometria**. Recife: UFRPE, 1979. 185 p.

SILVA, J. A. **Fitossociologia e relações alométricas em Caatinga nos Estados da Paraíba e Rio Grande do Norte**. 2006. 80 f. Tese (Doutorado em Ciência Florestal) - Universidade Federal de Viçosa, 2006.

SILVA, J. M. C. da. et al. **Biodiversidade da Caatinga: áreas e ações prioritárias para a conservação**. Brasília, DF: Ministério do Meio Ambiente: Universidade Federal de Pernambuco, 2004. 382 p.

SILVA, N. et al. Conhecimento e uso da vegetação nativa da Caatinga em uma comunidade rural da Paraíba, Nordeste do Brasil. **Boletim do Museu de Biologia Mello Leitão**, v.34, p.5-37. 2014.

SOARES, C. P. B. et al. **Dendrometria e inventário florestal**. 2.ed. Viçosa, MG: Universidade Federal de Viçosa, 2011. 272p.

SOUSA, C. L. **Uso de imagens-índice e de imagens-proporção para avaliar a quantidade de madeira em povoamentos de *Pinus spp.*** 1997. 111 p. Dissertação (Mestrado em Sensoriamento Remoto)–Instituto Nacional de Pesquisas Espaciais, São José dos Campos, SP, 1997.

SOUSA, C. L.; PONZONI, F. J. Avaliação de índices de vegetação e de bandas TM/Landsat para estimativa de volume de madeira em floresta implantada de *Pinus spp.* In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 9., 1998, Santos. **Anais...** Santos: INPE, 1998. Disponível em: <http://marte.sid.inpe.br/col/sid.inpe.br/deise/1999/02.11.10.35/doc/2_03p.pdf>. Acesso em: 1 dez. 2019.

SOUSA, F. P. et al. Carbon and nitrogen in degraded brazilian semi-arid soils undergoing desertification. **Agriculture, Ecosystems and Environment**, v. 148, p. 11-21, 2012.

SOUTO, P. C. et al. Características químicas da serapilheira depositada em área de Caatinga. **Revista Caatinga**, Mossoró, v. 22, n. 1, p. 264-272, 2009.

SOUZA, B. I. de. et al. Desertificação e seus efeitos na vegetação e solos do Cariri Paraibano. **Mercator**, v. 8, n. 16, p. 217-232. 2009.

SRIVASTAVA, V. K. et al. Preparation of volume table of SAL (*Shorea robusta*) - an approach using satellite data. **International Applied Earth Observation and Geoinformation**, v. 1, n.3-4, p. 214-221, 1999. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0303243499850156>>. Acesso em: 04 abr. 2020. DOI: 10.1016/S0303-2434(99)85015-6.

SWAIN, P. H.; DAVIS, S. M. **Remote sensing: the quantitative approach**. New York: McGraw-Hill, 1978. 396 p.

TESFAMICHAEL, S. et al. Estimating plot-level tree height and volume of Eucalyptus grandis plantations using small-footprint, discrete return LiDAR data. **Progress in Physical Geography**. v. 34, n. 4, p. 515–540, 2010.

THOMAS, C. et al. Comparação de equações volumétricas ajustadas com dados de cubagem e análise de tronco. **Ciência Florestal**, 16(3), 2006.

TILLACK, A. et al. Estimation of the seasonal leaf area index in an alluvial forest using high-resolution satellite-based vegetation indices. **Remote Sensing of Environment**, v. 141, p. 52-64, Feb., 2014. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0034425713003866>>

TROVÃO, D. M. de B.M. et al. (2007). Variações sazonais de aspectos fisiológicos de espécies da Caatinga. **Revista Brasileira de Engenharia Agrícola e Ambiental** v.11, n.3, p.307–311.

TSUCHIYA, I. **Regressão Lnística aplicada na análise espacial de dados arqueológicos**. 2002. 86 p. Dissertação (Mestrado em Ciências Cartográficas)- Universidade Estadual Paulista, Faculdade de Ciência e Tecnologia, Presidente Prudente, 2002.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, Madison, v.8, p.127-150, 1979. UFPR. 245p;

USGS (2016). **Landsat 8 (L8) Data Users Handbook, 2016**, LSDS-1574, version 2.0. Sioux Falls, USA: USGS EROS. Disponível em<<https://landsat.usgs.gov/sites/default/files/documents/Landsat8DataUsersHandbook.pdf>> Acesso em: 08 out. 2019.

VEIGA, R. A. A. **Dendrometria e Inventário Florestal**. Botucatu, SP: Fundação de Estudos e Pesquisas Agrícolas e Florestais, 1984. Boletim didático n. 1, 108p.

VELLOSO, A. L. et al. **Ecorregiões propostas para o Bioma Caatinga**. Associação Plantas do Nordeste; Instituto de Conservação Ambiental: The Nature Conservancy do Brasil, 2002. 76 p.

VIEIRA, G. et al. Teores de carbono em espécies vegetais da caatinga e do cerrado. **Revista Acadêmica Ciências Agrárias e Ambientais**, Curitiba, v.7, n.2, p.145-155, 2009.

VIRGENS, A. P. das. et al. Biomassa de espécies florestais em área de caatinga arbórea. **Pesquisa Florestal Brasileira**, Colombo-PR, v.37, n.92, p.555-561, 2017. <https://doi.org/10.4336/2017.pfb.37.92.1465>.

WATZLAWICK, L. F. et al. Estimativa de biomassa e carbono em floresta com Araucária utilizando imagens do satélite Ikonos II. **Ciência Florestal**, v. 19, n. 2, p. 169-181, 2009.

WWF - World Wide Fund for Nature. Terrestrial Ecoregions. Tropical and subtropical dry broadleaf forests. Acessado em: <https://www.worldwildlife.org/biomes/tropical-and-subtropical-dry-broadleaf-forests> 2018.

XU, B. et al. Decadal change of forest biomass carbon stocks and tree demography in the Delaware River Basin. **Forest Ecology and Management**, v.374, p.1-10. 2016. <https://doi.org/10.1016/j.foreco.2016.04.045>.

YEBOAH, D. et al. Variation in wood density and carbon content of tropical plantation tree species from Ghana. *New Forests*, v.45, n.1, p.35-52, 2014.

ZAKARIA, H. E. A. **Integration of Remote Sensing and GIS in Studying Vegetation Trends and Conditions in the Gum Arabic Belt in North Kordofan, Sudan**. Thesys (Doctor of Natural Science) - Technical University of Dresden, Institute of Photogrammetry and Remote Sensing, Dresden, 2010.

ZANDONÁ, D. F. et al. Varredura a laser aerotransportado para estimativa de variáveis dendrométricas. **Scientia Forestalis**, Piracicaba, v. 36, n. 80, p. 295-306, 2008.