



UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Campus de Botucatu



FELIPE GÓES DE MORAES

**ESTIMATIVA DE BIOMASSA E CARBONO EM FLORESTA ESTACIONAL
SEMIDECIDUAL UTILIZANDO ÍNDICES DE VEGETAÇÃO VIA SATÉLITES**

Botucatu

2021

FELIPE GÓES DE MORAES

**ESTIMATIVA DE BIOMASSA E CARBONO EM FLORESTA ESTACIONAL
SEMIDECIDUAL UTILIZANDO ÍNDICES DE VEGETAÇÃO VIA SATÉLITES**

Dissertação apresentada à
Faculdade de Ciências Agrônômicas
da Unesp Campus de Botucatu, para
obtenção do título de Mestre em
Ciência Florestal.

Orientador: Prof. Dr. Iraê Amaral
Guerrini

Coorientadora: Prof.^a Dr.^a Deicy
Carolina Lozano Sivisaca

Botucatu

2021

M827e	Moraes, Felipe Góes de Estimativas de biomassa e carbono em floresta estacional semidecidual utilizando índices de vegetação via satélites / Felipe Góes de Moraes. – Botucatu, 2021 82 p. : il., tabs., mapas Dissertação (mestrado) - Universidade Estadual Paulista (Unesp), Faculdade de Ciências Agrônômicas, Botucatu Orientador: Iraê Amaral Guerrini Coorientadora: Deicy Carolina Lozano Sivilsaca 1. Sensoriamento remoto. 2. Biomassa vegetal. 3. Levantamentos florestais. I. Título.
-------	---

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Faculdade de Ciências Agrônômicas, Botucatu. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: ESTIMATIVA DE BIOMASSA E CARBONO EM FLORESTA ESTACIONAL SEMIDECIDUAL UTILIZANDO ÍNDICES DE VEGETAÇÃO VIA SATÉLITES

AUTOR: FELIPE GÓES DE MORAES

ORIENTADOR: IRAÊ AMARAL GUERRINI

COORIENTADORA: DEICY CAROLINA LOZANO SIVISACA

Aprovado como parte das exigências para obtenção do Título de Mestre em CIÊNCIA FLORESTAL, pela Comissão Examinadora:

Prof. Dr. IRAÊ AMARAL GUERRINI (Participação Virtual)

Ciência Florestal, Solos e Ambiente / Faculdade de Ciências Agrônômicas de Botucatu – UNESP



Prof. Dr. RAMON JULIANO RODRIGUES (Participação Virtual)

Biotecnologia / Faculdade de Ciências e Letras de Assis



Prof.^a Dr.^a LIDIA RAQUEL DE CARVALHO (Participação Virtual)

Bioestatística, Biologia Vegetal, Parasitologia e Zoologia / Instituto de Biociências de Botucatu - UNESP



Botucatu, 01 de setembro de 2021

Aos meus ancestrais e progenitores,
que aqui estão e aos que já se foram,
você^s vivem em mim.

AGRADECIMENTOS

Aos meus pais, Dorival e Sandra, pela vida e criação livre; aos meus avós, Chico, Elza, Adelino e Irene, pela história e continuidade genética; e aos meus irmãos, Gustavo e Júlia, por todas as brigas e abraços; à Isadora, portadora da semente da esperança de uma nova primavera (Aiyra). A todos, pelo apoio incondicional: vocês são a base de tudo.

À Laís, por todos os mais de 2.500 dias juntos. Muitos dias de luta e vários dias de glória, mas sem dúvida minha mais linda caminhada até agora. Que sorte ter prendido minha bicicleta na sua em 2010.

À Alessandra, pelo apoio e incentivo para começar. Nossos caminhos se separaram, mas acredito que trabalharemos juntos por um mundo melhor.

À Mônica, pela força e insistência para terminar da melhor maneira possível, mesmo que para isso teve que conhecer meu lado impaciente junto com Guilherme. *Eres la mujer más fuerte y resiliente que he conocido. Aunque un poquito testaruda.*

À Deicy, minha coorientadora que me deu rumo, propósito e causa. Sem ela, não haveria este trabalho. E ao Celso, grande parceiro e professor de campo de quem herdei a missão de manejar o facão. *Muchas gracias a los dos.*

Aos meus companheiros de geoprocessamento por toda a ajuda sempre extremamente solícita e precisa, os renegados da XXIII Felipe Cerignoni (Porra) e Rodrigo Pereira (Jesus Negão); e ao Prof. Dr. Donizeti Nicolete, que também fez parte da banca de qualificação e fez apontamentos fundamentais para a conclusão dessa dissertação.

À Beatriz Papin (Daguia), engenheira florestal bicampeã da América, pelo suporte incomensurável em forma de amizade e companheirismo em 2021. E a todo o GEPPLA, que como grupo me mostrou diferentes formas de atuação nas linhas de frente da Emergência Climática, onde posso aplicar da maneira mais eficiente minhas habilidades.

À minha família/grupo de apoio/hospício em Botucatu, que me ajudou e suportou durante toda duração desse mestrado. Entre todos os elencos de todas as temporadas, créditos para o fixo, composto pela minha irmã mais velha Aline, que sabe me irritar como ninguém, e a mais nova, Vanessa, que eu sei irritar como ninguém. Destaques para participações especiais dos colombianos Alejita e Gerardo (batalha épica do soletrando que nunca aconteceu), Marina (a sulista mais

emocionada), Rafa (lobo solitário da cabeça de adamantium) e Brunas (Patela, o pai que foi comprar cigarro e não voltou; e Diferentona, *Khaleesi* da PG [*dracarys*]).

Aos meus companheiros de teto: Rafael, o cientista maluco e curioso que quer (e vai) entender de tudo; Ton, a fadinha do álcool, satanás em forma de corote que consegue contagiar a todos com uma empolgação fora do normal; e Hector, *el colombito borracho* que me ensinou a fazer caipirinhas.

Ao Prof. Dr. José Raimundo Passos por toda a inestimável ajuda na escolha e execução da metodologia estatística do projeto, além do auxílio na sua interpretação. Assim como a Deicy, sem o Rai esse trabalho não teria sido possível.

Ao Prof. Dr. Iraê Amaral Guerrini pela orientação e independência para realizar o projeto ao meu jeito.

À Faculdade de Ciências Agronômicas da UNESP de Botucatu, por todo apoio material e logístico na realização desse trabalho, especialmente às FEPE.

À IMEI Consultoria, através do Programa Brasil Mata Viva (BMV), pela disponibilização dos dados de campo da pesquisa da Deicy, financiada por eles.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

“All we have to decide is what to do with the time that is given us.”

TOLKIEN, J. R. R. **The Lord of the Rings:** The Fellowship of the Ring. New York: Harper Collins, p. 49, 1991.

RESUMO

O maior desafio da humanidade no século XXI, sem dúvida, são as mudanças climáticas. Emissões de gases causadores do efeito estufa na atmosfera, em especial o dióxido de carbono (CO_2), são sua principal causa e motor de aceleração. Portanto, evitar que mais carbono atinja a atmosfera é a melhor opção no momento. As florestas nativas são estoques e sumidouros de carbono, então preservá-las é uma ferramenta poderosa de mitigação das mudanças climáticas. Biomas devastados por séculos de exploração e ocupação humana, como a Mata Atlântica, se encontram em situação crítica de conservação. O caminho mais efetivo para a manutenção da floresta em pé é oferecendo subsídio financeiro, seja por pagamentos de serviços ecossistêmicos ou pela negociação de créditos de carbono. Uma etapa obrigatória nesse processo é quantificar o estoque de carbono contido nesses fragmentos florestais, que pode ser mais rápido mediante uso do sensoriamento remoto. Essa técnica nos permite acessar essas informações com maior eficácia, até nos lugares remotos onde se localizam as florestas tropicais, sendo uma vantagem para monitoramentos periódicos dos estoques de carbono nestas florestas. Índices de vegetação podem ser correlacionados com características morfológicas e fenológicas das árvores, como a biomassa. Assim, estabelecer correlações, modelos preditivos e categorias entre estoques de carbono florestal acima do solo com índices de vegetação obtidos por meio de imagens de satélite é importante para ganhar escala e eficiência no processo de valoração das florestas nativas. Nessa pesquisa foram avaliados quatro índices de vegetação (NDVI, EVI, RVI e OSAVI) gerados por dois satélites (Landsat 8 sensor OLI e Sentinel-2 sensor MSI), e como se relacionam com a biomassa dos remanescentes de Floresta Estacional Semidecidual nas Fazendas Experimentais Edgárdia e Lageado da UNESP, no município de Botucatu-SP. As medições vieram de inventário florestal dos sete fragmentos, realizado entre setembro e novembro de 2017, com a alocação de 18 parcelas permanentes de 0,2 ha (20 m x 100 m) onde foram medidos o diâmetro e altura de todas as árvores com mais de 5 cm de DAP. Por meio do *Google Earth Engine* foram selecionadas seis cenas com pouca cobertura de nuvens (<10%) de ambos satélites, de setembro a outubro de 2017. Na plataforma foram calculados os valores médios dos índices de vegetação para cada parcela com um *buffer* de 60 m ao redor (um hectare de área). Análises estatísticas descritivas dos efeitos dos satélites na biomassa e área basal e regressões lineares indicam não-correlação entre os valores dos IVs com os medidos em campo. Alargando a abordagem, foi tentada a categorização das variáveis biomassa e área basal e sua posterior classificação com a técnica *bootstrap*, com resultados mostrando percentuais de acerto pouco superiores a 55% para categorias dos extremos. Concluiu-se que a utilização desses índices de vegetação para estimativas de biomassa acima do solo em áreas de Floresta Estacional Semidecidual não é eficiente, assim como modelos preditivos que incorporem esses IVs. A abordagem por categorias é promissora para sondagens prévias, mas necessita de refinamento. IVs podem ser mais indicados para monitoramento do sequestro de carbono do que do seu estoque.

Palavras-chave: sensoriamento remoto; Landsat 8; Sentinel-2; Google earth engine; mata atlântica.

ABSTRACT

Humanity's greatest challenge in the 21st century is undoubtedly climate change. Greenhouse gas emissions into the atmosphere, especially carbon dioxide (CO₂), are its main cause and acceleration engine. Therefore, preventing more carbon from reaching the atmosphere is our best option at the moment. Native forests are carbon stocks and sinks, so preserving them is a powerful tool for mitigating climate change. Biomes devastated by centuries of human exploitation and occupation, such as the Atlantic Rainforest, are in a critical conservation state. The most effective way to maintain the forest standing is offering financial subsidy, either by ecosystem services payments or by negotiating carbon credits. A mandatory step for this financial compensation is to quantify the carbon stock contained in these forest fragments, which can be faster using remote sensing. This technique allows us to access this information more effectively, even in the remote places where tropical forests are located, being an advantage for periodic monitoring of these forests carbon stocks. Vegetation indices can be correlated with morphological and phenological characteristics of trees, such as biomass. Thus, establishing correlations, predictive models and categories between aboveground forest carbon stocks and vegetation indices obtained through satellite images is important to gain scale and efficiency in the remaining native forests valuing process. In this research, four vegetation indices (NDVI, EVI, RVI and OSAVI) generated by two satellites (Landsat 8 OLI and Sentinel-2 MSI) were evaluated on how they relate to the Semideciduous Seasonal Forest remnants' biomass in Edgárdia and Lageado, UNESPs' Experimental Farms, in Botucatu-SP. The measurement data came from a forest inventory of all seven fragments, carried out between September and November 2017, with 18 permanent plots of 0.2 ha (20 m x 100 m) allocation, of which the diameter and height of all trees larger than 5 cm DBH was measured. Through Google Earth Engine, six scenes with little cloud cover (<10%) from both satellites were selected, from September and October 2017. On the platform, the average values of vegetation indices for each plot were calculated with a 60 m buffer (a hectare of area). Descriptive statistical analyzes of the effects of satellites on biomass and basal area and linear regressions indicate non-correlation between VIs values and those measured in the field. Broadening the approach, an attempt was made to categorize and subsequently test the classification of variables biomass and basal area, with bootstrap technique, with results showing hit percentages just above 55% for extreme categories. It was concluded that the use of these vegetation indices for aboveground biomass estimates in Semideciduous Seasonal Forest areas is not efficient, as well as predictive models that incorporate these VIs. The category approach is promising for previous surveys, but needs refinement. VIs may be better suited for monitoring carbon sink than its' stocks.

Keywords: remote sensing; Landsat 8; Sentinel-2; Google earth engine; atlantic rainforest.

LISTA DE ILUSTRAÇÕES

Figura 1 - Ilustração do espectro eletromagnético destacando a faixa do visível	34
Figura 2 - Esquema mostrando as diferenças de reflectâncias nas folhas em diferentes estados fisiológicos.....	34
Figura 3 - Esquema mostrando as diferenças de reflectâncias entre folhas em diferentes estados fisiológicos e o solo (STEFFEN, 2016).....	35
Figura 4 - Mapa localizando Botucatu dentro do Estado de São Paulo.	38
Figura 5 - Mapa mostrando categorização por estágio sucessional das parcelas permanentes nas fazendas da FCA/UNESP – Botucatu	40
Figura 6 - Mapa mostrando a localização das parcelas permanentes nas fazendas da FCA/UNESP – Botucatu.....	41
Figura 7 - Captura de tela demonstrando o funcionamento da plataforma Google Earth Engine	43
Figura 8 - Comparação entre as bandas do Landsat 8 e Sentinel-2 (NASA, 2013) ..	45
Figura 9 - Fluxograma demonstrando funcionamento dos scripts programados para obter os dados de sensoriamento remoto	46
Figura 10 - Imagem demonstrando a área circular do buffer na parcela permanente 1	48
Figura 11 - Gráfico exemplificando como funcionará a categorização seguida da reamostragem e classificação das variáveis biométricas pelos índices de vegetação.....	52
Figura 12 - Contextualização dos dados do inventário de campo para biomassa (SIVISACA, 2020)	53
Figura 13 - Contextualização dos dados do inventário de campo para área basal (SIVISACA, 2020)	53
Figura 14 - Perfil descritivo dos dados de NDVI gerados por imagens Landsat 8, Box-Plot, Histograma e Q-Q Plot.....	54
Figura 15 - Perfil descritivo dos dados de NDVI gerados por imagens Sentinel-2, Box-Plot, Histograma e Q-Q Plot.....	54
Figura 16 - Perfil descritivo dos dados de EVI gerados por imagens Landsat 8, Box-Plot, Histograma e Q-Q Plot.....	55
Figura 17 - Perfil descritivo dos dados de EVI gerados por imagens Sentinel-2, Box-Plot, Histograma e Q-Q Plot.....	55

Figura 18 - Perfil descritivo dos dados de RVI gerados por imagens Landsat 8, Box-Plot, Histograma e Q-Q Plot.....	56
Figura 19 - Perfil descritivo dos dados de RVI gerados por imagens Sentinel-2, Box-Plot, Histograma e Q-Q Plot.....	56
Figura 20 - Perfil descritivo dos dados de OSAVI gerados por imagens Landsat 8, Box-Plot, Histograma e Q-Q Plot.....	57
Figura 21 - Perfil descritivo dos dados de OSAVI gerados por imagens Sentinel-2, Box-Plot, Histograma e Q-Q Plot.....	57
Figura 22 - Ilustração dos fatores que influenciam a fenologia e, por consequência, os índices de vegetação	73

LISTA DE TABELAS

Tabela 1 - Dados técnicos do satélite Landsat 8, sensor OLI (NASA, 2013)	44
Tabela 2 - Dados técnicos do satélite Sentinel-2, sensor MSI (ESA, 2015)	44
Tabela 3 - Fórmulas dos índices de vegetação utilizados	45
Tabela 4 - Fórmulas dos índices de vegetação utilizados	49
Tabela 5 - Comparação de média da biomassa da vegetação, erro padrão da média (em parêntesis), entre as áreas de sucessão ecológica da Floresta Estacional Semidecidual na cuesta de Botucatu, SP.....	58
Tabela 6 - Área basal média (m ² /ha), com erro padrão entre parêntesis, segundo tipo de floresta	58
Tabela 7 - Comparação de médias dos índices de vegetação e os satélites, erro padrão da média entre parênteses. Ajuste (valor-p e resíduos de Pearson) dos modelos lineares generalizados com a distribuição gama e função de ligação logarítmica com estrutura de medi de medidas repetidas, considerando as variáveis resposta os índices espectrais (NDVI, EVI, RVI e OSAVI) e como fatores os satélites (Landsat 8 e Sentinel-2)	59
Tabela 8 - Matriz de correlação entre variáveis biométricas e índices de vegetação obtidos a partir do satélite Landsat 8, para a área de Floresta Tardia	60
Tabela 9 - Matriz de correlação entre variáveis biométricas e índices de vegetação obtidos a partir do satélite Landsat 8, para a área de Floresta Perturbada	60
Tabela 10 - Matriz de correlação entre variáveis biométricas e índices de vegetação obtidos a partir do satélite Landsat 8, para a área de Floresta Secundária	61
Tabela 11 - Matriz de correlação entre variáveis biométricas e índices de vegetação obtidos a partir do satélite Sentinel-2, para a área de Floresta Tardia ...	61
Tabela 12 - Matriz de correlação entre variáveis biométricas e índices de vegetação obtidos a partir do satélite Sentinel-2, para a área de Floresta Perturbada	62
Tabela 13 - Matriz de correlação entre variáveis biométricas e índices de vegetação obtidos a partir do satélite Sentinel-2, para a área de Floresta Secundária	63

Tabela 14 - Modelos de regressão de biomassa acima do solo para todos os índices de vegetação e satélites para todos os fragmentos forestais de Floresta Estacional Semidecidual (FES) e segundo o tipo de sucessão ecológica da floresta: tardia (FEST) e perturbada (FESP). Nos modelos se mostram o coeficiente de determinação de ajuste (R^2 Adj) e o valor significativo estatístico do modelo (p-value)	64
Tabela 15 - Modelos de regressão de área basal para todos os índices de vegetação e satélites para todos os fragmentos forestais de Floresta Estacional Semidecidual (FES) e segundo o tipo de sucessão ecológica da floresta: tardia (FEST), perturbada (FESP) e secundária (FESS). Nos modelos se mostram o coeficiente de determinação de ajuste (R^2 Adj) e o valor significativo estatístico do modelo (p-value).....	64
Tabela 16 - Categorização das variáveis biométricas (biomassa e área basal) de acordo com a divisão dos dados pelos tercis.....	65
Tabela 17 - Validação cruzada da classificação de categorias de biomassa para os satélites Landsat 8 e Sentinel-2, usando função discriminante com critério de classificação considerando a distribuição não paramétrica dos dados pelo método dos quatro vizinhos mais próximos.....	66
Tabela 18 - Validação cruzada da classificação de categorias de área basal para os satélites Landsat 8 e Sentinel-2, usando função discriminante com critério de classificação considerando a distribuição não paramétrica dos dados pelo método dos quatro vizinhos mais próximos.....	67

LISTA DE ABREVIATURAS E SIGLAS

APA	Área de Preservação Ambiental
BES	Biodiversity Ecosystem Services
BRICS	Brazil, Russia, India, China and South Africa
COP	Conference of the Parties
DAP	Diâmetro da Altura do Peito
ESA	European Space Agency
EVI	Enhanced Vegetation Index
FAO	Food and Agriculture Organization
FP	Floresta Perturbada
FS	Floresta Secundária
FT	Floresta Tardia
IBGE	Instituto Brasileiro de Geografia e Estatística
IPCC	Intergovernmental Panel on Climate Change
IV	Índice de Vegetação
NASA	National Aeronautics and Space Administration
NDVI	Normalized Difference Vegetation Index
NEE	Net Ecosystem Exchange
NPP	Net Primary Productivity
OSAVI	Optimized Soil Adjusted Vegetation index
REDD	Reducing Emissions from Deforestation and Forest Degradation
REDD+	REDD + sustainable management of forests and the conservation and enhancement of forest carbon stocks in developing countries
RVI	Ratio Vegetation Index
SAVI	Soil Adjusted Vegetation index
SIAC	Sensor Invariant Atmospheric Correction
SIG	Sistema de Informação Geográfica
UNESCO	United Nations Educational, Scientific and Cultural Organization
UNFCCC	United Nations Framework Convention on Climate Change

SUMÁRIO

1	INTRODUÇÃO	23
2	REVISÃO DE LITERATURA	26
2.1	Mudanças climáticas.....	26
2.2	Florestas tropicais e Mata Atlântica	28
2.3	Métodos de quantificação e modelos preditivos de biomassa e carbono .	30
2.4	Sensoriamento remoto por satélites	33
2.5	Índices de vegetação	35
3	MATERIAL E MÉTODOS	38
3.1	Área de estudo.....	38
3.2	Amostragem	40
3.3	Quantificação de biomassa viva acima do solo	41
3.4	Geoprocessamento	42
3.4.1	<i>Google Earth Engine</i>	42
3.4.2	Satélites.....	43
3.4.3	Algoritmo	46
3.4.4	Índices de vegetação	48
3.5	Análise estatística	50
3.5.1	Análise descritiva das variáveis biométricas	50
3.5.2	Análise do efeito dos tipos de floresta na biomassa e área basal.....	50
3.5.3	Efeito dos satélites nos índices de vegetação.....	50
3.5.4	Correlação entre biomassa, IVs e modelos de regressão lineares.....	51
3.5.5	Categorização das variáveis de biomassa e área basal	51
4	RESULTADOS.....	53
4.1	Análise descritiva da biomassa e área basal	53
4.2	Análise descritiva dos índices de vegetação.....	54
4.3	Biomassa e área basal entre os estágios sucessionais das florestas	57
4.4	Efeito dos satélites nos índices de vegetação.....	58
4.5	Relação entre a biomassa, área basal e os índices de vegetação	59
4.6	Categorização da biomassa e área basal segundo os IVs	65
4.6.1	Classificação das categorias pelos dados espectrais	65
5	DISCUSSÃO	68
5.1	Relação entre biomassa e os índices de vegetação	68

5.2 Modelos	69
5.3 Categorizações	70
5.4 Problemas e possíveis soluções.....	71
6 CONCLUSÃO.....	74
REFERÊNCIAS	75

1 INTRODUÇÃO

As mudanças climáticas presenciadas nas últimas décadas são decorrência incontestável do aumento da concentração de gases de efeito estufa na atmosfera, notadamente o dióxido de carbono (CO_2), o óxido nitroso (N_2O) e o metano (CH_4). Esses gases absorvem a radiação infravermelha irradiada pela superfície do planeta após ser aquecida pelo Sol, evitando que saia para o espaço e refletindo esse calor de volta, assim ajudando a manter a temperatura da Terra.

Nas suas concentrações naturais, o efeito desses gases é benéfica e extremamente importante para toda a biosfera. Mas as ações antrópicas estão desequilibrando esse balanço atmosférico, e ao aumentar a concentração dos gases de efeito estufa intensificamos essa reflexão da radiação infravermelha, provocando o aquecimento da atmosfera. Emissões desses gases na atmosfera se dão principalmente por meio da queima de combustíveis fósseis, processos industriais e mudanças no uso do solo, como o desmatamento e a degradação florestal. Embora a quantidade de carbono estocado na biomassa das plantas seja pequena comparada aos enormes estoques subterrâneos e oceânicos, ela é importante pois pode ser rapidamente reduzida e convertida para carbono atmosférico.

Com a crescente preocupação em limitar a elevação da temperatura média do planeta a apenas 2 °C e em reduzir as emissões de gases do efeito estufa, muito se tem discutido sobre o carbono estocado nas florestas tropicais. A Convenção-Quadro das Nações Unidas sobre a Mudança do Clima (*UNFCCC* na sigla em inglês) propôs o mecanismo de Redução de Emissões provenientes de Desmatamento e Degradação florestal + conservação dos estoques de carbono florestal, manejo sustentável de florestas e aumento dos estoques de carbono florestal (REDD+) como instrumento para recompensar em termos monetários os países em desenvolvimento que adotarem esforços para reduzir o desmatamento e a degradação florestal. As Conferências das Partes (COPs) já reconhecem o papel e a necessidade desses incentivos financeiros na redução das emissões advindas da conversão de florestas em pastagens e terras agrícolas.

Nesse contexto, a quantificação dos estoques de carbono em florestas e sua comercialização se tornam importantes não só por garantir a preservação das florestas e dos seus ecossistemas, mas também por auxiliar o desenvolvimento das populações que vivem nessas áreas e que as mantêm preservadas até os tempos atuais, mesmo frente grandes pressões dos mais variados atores, como empresas,

governos e o agronegócio. Essa importância é proporcionalmente maior quanto mais ameaçado é o bioma, como a Mata Atlântica, que é uma florestal tropical que abriga grande parte da população brasileira, mas que se encontra extremamente fragmentada e ameaçada pelo contínuo crescimento populacional do país. A aferição e valoração monetária do carbono contido em todas as fitofisionomias da Mata Atlântica é uma das estratégias centrais nos esforços para preservar o bioma.

Há alguns métodos para aferir esse estoque de carbono, e todos passam por quantificar a biomassa vegetal, uma vez que em florestas tropicais pouco menos da metade dela é carbono. Os estudos de quantificação de biomassa em florestas têm sido realizados por meio de métodos diretos e indiretos. Os métodos diretos invariavelmente envolvem alguma forma de destruição de árvores, seja por meio do corte de uma árvore média ou cortes estratificados. Já os métodos indiretos são baseados na correlação da biomassa com alguma variável obtida por medição no campo, sem necessidade de abate da árvore.

A aplicação desses métodos de quantificação historicamente sempre foi realizada em campo, demandando grandes esforços logísticos, estudos trabalhosos e que tomam tempo, resultando em custos operacionais elevados. Mas com atuais avanços tecnológicos com relação às imagens provenientes de sensores remotos, que vão desde satélites com melhores resoluções espaciais e cobertura até varreduras por RADAR e LiDAR feitas por drones e aviões, têm-se obtido uma melhor caracterização da estrutura das florestas e, conseqüentemente, sua biomassa e carbono estocado.

Entre os produtos gerados pelas imagens de satélites, alguns dos mais longamente estudados e aplicados são os índices de vegetação, que são o resultado de transformações matemáticas de diferentes bandas espectrais. A partir desses valores, relacionando-os com características da vegetação, é possível aferir informações relevantes de maneira remota e contínua.

Como inventários florestais tradicionais em áreas de matas nativas demandam grande esforço logístico e financeiro, a utilização de meios remotos para essas estimativas, como drones, aviões ou satélites, tende a direcionar melhor os esforços em campo e assim reduzir os custos, possibilitando ampliar o raio da estimativa. Outra possibilidade que essa tecnologia abre é a prospecção prévia dos estoques de carbono de uma área. Técnicas de sensoriamento remoto estão tornando-se cada vez mais acessíveis com o passar dos anos, sendo um dos últimos empecilhos que restam a validação em campo da acurácia e precisão.

Portanto, com todas essas questões expostas, esta pesquisa tem como objetivo geral avaliar a eficiência das estimativas de carbono acima do solo em fragmentos de Floresta Estacional Semidecidual na Mata Atlântica por meio de índices de vegetação gerados por imagens de satélites. Para isso será verificado se: i) há correlação entre estimativas de estoques de carbono florestal acima do solo que utilizem índices de vegetação gerados por meio de imagens de satélites e estimativas de carbono a partir de inventário florestal tradicional, e ii) modelos preditivos regionais de carbono florestal acima do solo que se baseiem em índices de vegetação apresentam alto grau de confiabilidade e precisão. Sendo assim, os objetivos específicos desta pesquisa serão:

- Avaliar a eficiência das estimativas dos estoques de carbono florestal acima do solo baseadas nos índices de vegetação: NDVI, EVI, RVI e OSAVI em relação à medição realizada em campo por meio de inventário florestal tradicional.
- Desenvolver e ajustar um modelo preditivo regional para medição de carbono florestal acima do solo, com os índices de vegetação obtidos por meio de imagens de satélites ajustados com dados medidos em campo.
- Categorizar as classes de biomassa e área basal por meio dos índices de vegetação gerados por imagens de satélites.

2 REVISÃO DE LITERATURA

2.1 Mudanças climáticas

O surgimento e a manutenção da vida no planeta é consequência direta do fenômeno natural chamado de efeito estufa. Devido a ele, a superfície da Terra mantém temperaturas amenas o suficiente para que a água permaneça no seu estado líquido. Alguns dos gases que compõem a atmosfera absorvem a radiação infravermelha irradiada pela superfície do planeta após ser aquecida pelo Sol, evitando que ela escape para o espaço e refletindo esse calor de volta, assim ajudando a manter a temperatura da Terra. Nas suas concentrações naturais, o efeito desses gases é benéfica e extremamente importante para toda a biosfera. Mas se aumentarmos a concentração dos gases de efeito estufa, intensificamos essa reflexão da radiação infravermelha, provocando o aquecimento da atmosfera (SOUZA, 2012).

O clima é um sistema complexo e dinâmico que já sofreu grandes mudanças ao longo da história natural do nosso planeta. Antes do século XVIII, as mudanças climáticas observadas eram devidas a causas naturais como mudanças na órbita da Terra, na quantidade de radiação que chegava ao planeta, atividades vulcânicas e padrões naturais de trocas de calor entre oceano, continentes e atmosfera. Desde então, um outro fator se somou a essa lista: os seres humanos e suas emissões de dióxido de carbono (RAMANATHAN et al., 2019). O aquecimento registrado nos últimos 150 anos coincide com o período no qual começamos a emitir esses gases em quantidades significativas e cada vez maiores (MARQUES FILHO, 2016), com a concentração de dióxido de carbono na atmosfera indo de 285 ppm antes da Revolução Industrial para mais de 415 ppm em 2020 (NOAA, 2021). Segundo Hansen et al. (2021), desde 1880 a temperatura média global subiu em 1,3 °C. Marques Filho (2016) explica que uma temperatura média mais elevada é um dos fatores que indicam mais energia na atmosfera, alterando o balanço das forças radiativas de todo o sistema climático. Logo, as principais causas de mudanças climáticas estão associadas à queima de combustíveis fósseis e às mudanças dos usos do solo, como desmatamento e atividade agropecuária, que liberam CO₂ que estava antes contido na superfície (SEIFFERT, 2009).

Diminuir a quantidade de CO₂ que emitimos se torna, então, a nossa principal arma para evitar as piores consequências das mudanças climáticas. Mas estudos mostram que, mesmo se todas as atuais metas fossem alcançadas até 2030, o

aumento da temperatura global ainda seria de 2,2 a 3,4 °C até o final do século. Para atingir a meta de 2 °C, será necessário reduzir em mais 30% as atuais metas propostas, até 2030 (CHAO; FENG, 2018). Chao e Feng (2018) afirmam que a quantidade de carbono que podemos emitir ainda, se quisermos limitar o aquecimento global a 1,5 °C, está entre 570 Gt CO₂ e 770 Gt (1 Gt = 1 bilhão de toneladas). Considerando que as emissões globais totalizaram pouco mais de 33 Gt CO₂ em 2019 (IEA, 2020), teríamos apenas duas décadas para neutralizar nossas emissões. Isso implicará reduções rápidas nas emissões globais de CO₂ antropogênico para atingir zero líquido por volta de meados do século, juntamente com a rápida redução de outras emissões antropogênicas. Limitar o aquecimento global a 1,5 °C exigirá transições rápidas e de longo alcance dos sistemas durante as próximas uma a duas décadas, nos sistemas de energia, uso da terra, urbano e industrial (IPCC, 2018).

Assim como as taxas de emissão de gases do efeito estufa, a mudança climática global está se acelerando, pressionando todos os ecossistemas da Terra (HE; SILLIMAN, 2019). A adaptação passará por reconhecermos a conexão direta entre BES (*biodiversity ecosystem services* no termo em inglês) e o bem-estar humano (SCARANO, 2017). Um desses serviços ecossistêmicos é o armazenamento e “sequestro” do carbono (CAVALLET; PAULA, 2007), considerado dentre as mais importantes soluções para diminuir os efeitos do CO₂ atmosférico (IPCC, 2007; KEITH et al., 2019).

Em 1997 no Japão foi assinado o Protocolo de Quioto, documento histórico e que trouxe, entre outros conceitos e avanços, o Mecanismo de Desenvolvimento Limpo (MDL) (LOPES, 2009; LOVINS; COHEN, 2011). O mercado global de carbono passou a existir com o Protocolo e a introdução dos MDL, porém poucos projetos dessa modalidade referentes ao uso da terra e florestas foram implementados no Brasil (RUGGIERO, 2013).

Surgiu então em 2007, durante a 13^a Conferência das Partes (COP 13) da Convenção-Quadro sobre Mudanças Climáticas (UNFCCC), o mecanismo REDD (Redução de Emissões por Desmatamento e Degradação Florestal), que reconheceu o papel das florestas no combate às mudanças climáticas (IPAM, 2011). Seu conceito ampliado é o REDD+, pois inclui conservação florestal, manejo florestal e aumento de estoque de carbono nas florestas (CENAMO et al., 2010). Em dezembro de 2015, como uma substituição ao Protocolo de Quioto, a UNFCCC aprovou na 21^a Conferência das Partes (COP 21) o Acordo de Paris. Esse acordo prevê que novos procedimentos sejam tomados pelos países integrantes para limitar a variação de

temperatura global de até 1,5 °C até 2030, apostando em uma economia verde que prioriza a natureza tanto na vertente energética como na florestal (REI; GONÇALVES; SOUZA, 2017).

2.2 Florestas tropicais e Mata Atlântica

As florestas tropicais são particularmente importantes por terem uma grande influência nos padrões globais de biodiversidade, complexidade ecológica dos ecossistemas, produtividade e ciclos biogeoquímicos (MALHI et al., 2010). Os ecossistemas florestais desempenham um papel importante no sequestro e armazenamento de carbono, exercendo forte controle sobre a evolução do CO₂ atmosférico e servindo como grandes sumidouros de carbono terrestre ao acumular carbono na matéria orgânica viva ou não viva e nos solos (JAMES et al., 2018). Por exemplo: enquanto as florestas maduras retêm maior volume de carbono em sua biomassa do que as mais jovens, as últimas sequestram mais CO₂ da atmosfera (SEDJO, 2001), tornando imperiosa a conservação das florestas tropicais em diferentes estágios de desenvolvimento para mitigar as emissões antropogênicas dos gases do efeito estufa (KAUFFMAN; HUGHES; HEIDER, 2009).

Perdas de cobertura vegetal refletem em diversos níveis, desde o local, com queda na produção de água, quanto no global, com mais emissões (COUTINHO, 2010). De acordo com Ruggiero (2013), devido à crescente preocupação relacionada ao desmatamento, queimadas e demais causadores do aquecimento global, foi identificada a necessidade não somente de que se evite emissões de carbono, mas de que os países que preservam suas áreas florestais atuem como sumidouros de carbono. Dixon et al. (1994) estimaram que até 80% de todo o carbono estocado acima do solo e 40% de todo o carbono estocado abaixo do solo esteja contido nas florestas do mundo. É necessário ressaltar a diferença entre florestas maduras e jovens no estoque de carbono (BROWN, 1997; SEDJO, 2001).

O Brasil tem uma economia que não faz uso intensivo de energia e carbono quanto outros países dos BRICS (grupo de países emergentes formado por Brasil, Rússia, Índia, China e África do Sul), e desde 1990 até 2014 vinha obtendo sucesso na redução de suas emissões de gases do efeito estufa referentes ao desmatamento e mudanças do uso do solo (ZHENG et al., 2019). Apesar disso, a expansão da agricultura devido à derrubada de florestas durante os últimos 140 anos levou a uma liberação líquida de 121 Gt de carbono para a atmosfera e o Brasil é o maior

responsável pela emissão de gases de efeito estufa por mudanças no uso do solo (WATSON, 2000; HOUGHTON et al., 2001; FEARNSIDE, 2010).

O gerenciamento de áreas de florestas para aprimorar o sequestro de carbono foi proposto como um método para reduzir as concentrações atmosféricas de CO₂ e mitigar as ameaças das mudanças climáticas. Segundo Halofsky et al. (2018), as mudanças climáticas são dinâmicas e contínuas, e por isso seus efeitos nos sistemas e processos florestais são complexos e há um nível crescente de incerteza sobre como serão as florestas futuras, exigindo abordagens de manejo adaptativas. A priorização por zonas como forma de identificar áreas florestais que permanecerão climaticamente sustentáveis (MAXWELL et al., 2019) é uma dessas novas abordagens, que permitirá um manejo inteligente e eficiente para conter as consequências das mudanças climáticas.

A Mata Atlântica é, entre as florestas tropicais do planeta, a mais biodiversa (MYERS et al., 2000; MMA, 2003). Porém, segundo Lacerda et al. (2009), é um dos biomas brasileiros mais devastados por ciclos econômicos, que a reduziram do seu tamanho pré-colombiano de 1,3 milhão de km² para apenas 12,4% da cobertura original, de acordo com o relatório da SOS Mata Atlântica em parceria com o Instituto Nacional de Pesquisas Espaciais (INPE, 2019). A sua área de ocorrência também é, ou como consequência desses ciclos de desenvolvimento, densamente povoada, concentrando mais de 70% da população do Brasil e seus principais polos industriais (SANTOS; CÂMARA, 2002; GALINDO-LEAL; CÂMARA, 2005).

Considerada um *hotspot* mundial por sua biodiversidade (REZENDE et al., 2018), a Mata Atlântica é parte da Reserva da Biosfera da UNESCO desde 1991, uma categoria internacional de unidade de conservação que compreende áreas representativas de vários biomas e assim visa conservar uma amostra da diversidade mundial (RIBEIRO et al., 2009). Devido a essa grande abrangência territorial, o bioma está inserido em diferentes regiões geográficas e climáticas, apresentando muitas fitofisionomias distintas (SILVA; SANTOS; MORAES, 2014).

Segundo o Instituto Brasileiro de Geografia e Estatística (IBGE, 2012), compõe a Mata Atlântica as seguintes formações florestais: Floresta Ombrófila Densa, caracterizada por virtualmente não apresentar período seco e contar com temperaturas elevadas o ano inteiro; Floresta Ombrófila Mista, popularmente chamada de “mata de araucárias” em referência à sua espécie mais característica; Floresta Ombrófila Aberta, que apresenta período de seca maior que as anteriores, ocorrendo na faixa litorânea; Floresta Estacional Semidecidual, com uma demarcação

bem clara das estações do ano que ocasionam a queda das folhas de parte das suas espécies arbóreas, inverno com seca prolongada e verões chuvosos; Floresta Estacional Decidua, apresenta características climáticas mais definidas que a Semidecidual, com regiões enfrentando invernos consistentemente frios, ocasionando a perda de folhagem de mais da metade das espécies.

Por ser um *hotspot* de biodiversidade, abrigar grande parte da população do país e se encontrar extremamente fragmentada, a Mata Atlântica é uma área de máxima prioridade para conservação e restauração florestal como medidas de mitigação dos efeitos deletérios das mudanças climáticas. Para implantar essas medidas, Crouzeilles et al. (2019) listaram os desafios que o governo enfrentará: (i) eliminar o desmatamento ilegal por meio de ações de monitoramento e fiscalização; (ii) melhorar o monitoramento local para quantificar a qualidade da restauração e o monitoramento em grande escala para aumentar a precisão e robustez das estimativas; e (iii) incentivos econômicos (pagamentos por serviços ambientais, etc.) e financiamento para restauração.

2.3 Métodos de quantificação e modelos preditivos de biomassa e carbono

Por todo esse contexto mundial da urgência de agirmos contra as mudanças climáticas, de como isso pode ser feito evitando-se desmatar áreas de florestas intactas e também permitir que populações marginalizadas sejam recompensadas, e não penalizadas por preservarem, a quantificação da biomassa e aferição indireta do carbono nela estocado ganha uma relevância inédita. Segundo Asner e Mascaro (2014), há alguns métodos para aferir esse estoque de carbono, e todos passam por quantificar a biomassa vegetal, uma vez que aproximadamente 48% dela é carbono em florestas tropicais.

Brown (1997), Qureshi, Pariva e Hussain (2012) e o IPCC (2019) afirmam que o carbono se encontra “aprisionado” e pode ser medido em cinco depósitos naturais: biomassa viva acima do solo, biomassa subterrânea, madeira morta, serrapilheira e a matéria orgânica do solo. A divisão desse estoque de carbono está em 45-55% na biomassa viva acima do solo; 20-26% na biomassa abaixo do solo; 20% no próprio solo; e 6-8% na serrapilheira, dependendo do estágio de desenvolvimento da floresta (HOUGHTON; UNRUH; LEFEBVRE, 1993; QURESHI; PARIVA; HUSSAIN, 2012).

Os estudos de quantificação de biomassa em florestas têm sido realizados por meio de métodos diretos e indiretos (FERRAZ et al., 2014). Os métodos diretos

invariavelmente envolvem alguma forma de destruição de árvores para obtenção de dados. A escolha pode ser feita baseada no tamanho médio das árvores ou em uma determinada classe de tamanho; ou pode-se selecionar todos os materiais de uma área; ou ainda elegendo indivíduos para compreender uma grande variação de tamanho (ROY; RAVAN, 1996). Apesar de muito preciso, o método é considerado oneroso, demorado e inviável de aplicação em grandes áreas, fora os danos que causa à floresta. Também pode gerar uma seleção tendenciosa, por incluir poucas árvores grandes (BROWN; LUGO, 1992). Utilizar o método destrutivo para a estimação de biomassa é crescentemente mais difícil quanto maior a amostragem, consideram Chave et al. (2005), devido ao pesado trabalho de campo que tal método exige.

Já os métodos indiretos fazem uso de outras técnicas, como inventários florestais ou estudos fitossociológicos, fatores de expansão ou conversão, equações alométricas e, mais recentemente como apontou Nakai (2016), sensoriamento remoto com dados aplicados em modelos baseados em um Sistema de Informação Geográfica (SIG). Apesar da precisão ser inferior à do método destrutivo, os custos da coleta de dados são menores, o método é mais fácil de trabalhar e os resultados são obtidos mais rapidamente, além de não haver a destruição do objeto quantificado (BROWN, 1997; QURESHI; PARIVA; HUSSAIN, 2012).

Dados obtidos de inventário são uma maneira prática para estimar a biomassa acima do solo, pois normalmente consideram escala e população de interesse, mas há lacunas nesses dados, especialmente em florestas tropicais, onde podem faltar dados pela dificuldade de incluir a altura das árvores (CHAVE et al., 2005), ou dados incompletos, uma vez que os inventários raramente apresentam os diâmetros individuais de cada árvore, mas sim áreas basais, classes de diâmetro ou volume da madeira (NAKAI, 2016).

Quanto maior a precisão da estimativa de biomassa, melhor será a quantificação de carbono estocado pelos ecossistemas florestais (SOTOMAYOR, 2013). Modelos alométricos, dessa forma, passaram a ser a técnica mais utilizada para estimar e prever biomassa, e segundo Ferraz et al. (2014), as equações utilizadas por esses modelos são baseadas na relação entre biomassa e alguma variável obtida por medição no campo. Podem ser relacionadas e ajustadas com variáveis de fácil medição, como diâmetro à altura do peito (DAP), área basal, altura total ou comercial da árvore, densidade da madeira entre outros (CHAVE et al., 2005). O emprego de duas ou mais variáveis em uma mesma equação alométrica, como

DAP e altura, apresenta melhores resultados, mas a aferição das alturas das árvores em campo tende a ser problemática e imprecisa (BROWN, 2002).

As características do local precisam ser consideradas para definir um adequado modelo volumétrico regional (LEITE; ANDRADE, 2003). Dada a inerente alta variabilidade das florestas nativas, a definição de uma equação volumétrica regional é muito necessária, como frisaram Rolim et al. (2006). Dessa maneira, o ajuste e uso de equações de regressão que estejam em sintonia com as condições locais se faz imprescindível em florestas nativas, levando em consideração informações precisas sobre os estoques de produtos madeireiros e não madeireiros (AMARO, 2010).

Modelos de regressão os quais fazem uso de dados de inventários são utilizados para converter os dados de campo na estimativa da biomassa acima do solo (CHAVE et al., 2005). Mas modelar a biomassa de florestas tropicais esbarra na óbvia dificuldade representada por sua grande diversidade, uma vez que em um hectare pode se encontrar até 300 espécies diferentes (OLIVEIRA; MORI, 1999). Como demonstram Brown e Schroeder (1999), não é fácil utilizar modelos de regressão específicos para uma espécie, como é praxe em florestas temperadas.

Dentre os modelos preditivos de biomassa acima do solo mais utilizados para a Mata Atlântica, a equação de Chave et al. (2005) ganha destaque especial. Nela, os preditores mais importantes são diâmetro à altura do peito (DAP), densidade específica da madeira (ρ) e altura total (H). Como os diferentes volumes de pluviosidade em cada fitofisionomia foram as variáveis mais significativas, os parâmetros foram estimados a partir deles. Essa equação consegue resultados melhores do que a de Brown et al. (1997), que foi intermediada pela FAO e é uma das metodologias propostas pelo IPCC, por levar em consideração a densidade de cada espécie.

Realizar inventários contínuos é uma forma eficiente de analisar a magnitude dos fluxos de carbono entre os ecossistemas e a atmosfera (GRACE, 2004). O emprego de técnicas de sensoriamento remoto, que trabalhem em conjunto com os dados coletados em campo, se encaixa perfeitamente nos requerimentos de se manter uma vigília constante nos estoques de carbono nas florestas, uma vez que a medição dessa biomassa acima do solo, baseada em exaustivos inventários de campo, pode ser acompanhada quase que em tempo real via satélite.

2.4 Sensoriamento remoto por satélites

Sensoriamento remoto é uma técnica que, como o nome indica, adquire informações sobre objetos na superfície terrestre sem contato físico, por meio de sensores que registram ativa ou passivamente a interação de ondas eletromagnéticas com o meio, podendo ser por via terrestre, aérea ou orbital (JENSEN, 2009). Alguns desses sensores são ópticos, que operam dentro da fração óptica do espectro eletromagnético, nas faixas do visível, infravermelho próximo e médio. São sensores passivos, uma vez que necessitam da radiação solar refletida pelos alvos. Assim, uma interpretação desses dados da fração ótica do eletromagnético exige o conhecimento prévio do comportamento espectral dos alvos (KUNTSCHIK, 2004).

Segundo Moreira (2011), existem três fenômenos através dos quais a radiação solar interage com a vegetação: absorção, transmissão e reflexão. A magnitude de cada um desses fenômenos depende da interação da fração do espectro eletromagnético com as estruturas físicas e químicas da folha. Mas de um modo geral, os pigmentos da folha absorvem cerca de 50% da radiação solar, e essa quantidade absorvida supri o processo de fotossíntese.

De acordo com o mesmo autor, uma parte dessa radiação é transmitida através dos componentes estruturais da folha, e outra parte é refletida pelas folhas. E é essa energia refletida pela vegetação que é a mais utilizada pelos sensores orbitais e suborbitais, devido à facilidade de ser quantificada.

Ainda segundo Moreira (2011), a fração do visível do espectro eletromagnético situa-se entre 400 nm e 720 nm, (Figura 1), atuando como a radiação fotossinteticamente ativa que é absorvida para acúmulo de biomassa. Com a absorção da radiação incidente pelos pigmentos das plantas ocorrendo nos comprimentos de onda 480 nm e 620 nm, a percepção da cor verde na vegetação se dá devido a um aumento no coeficiente de reflectância em 560 nm. Já na fração do infravermelho próximo (700 a 1.300 nm) a absorção é consideravelmente menor, resultando em uma elevada refletância da vegetação, como podemos observar na Figura 2 (PONZONI; DISPERATI, 1995).

Figura 1 - Ilustração do espectro eletromagnético destacando a faixa do visível






Figura 2 - Esquema mostrando as diferenças de reflectâncias nas folhas em diferentes estados fisiológicos



A outra região de interesse do sensoriamento remoto no espectro eletromagnético é a do infravermelho médio, situada entre 1.100 nm e 3.200 nm (MOREIRA, 2011). De acordo com Ponzoni, Shimabukuro e Kuplich (2012), entre 1.300 nm e 2.000 nm ocorre novamente absorção da radiação incidente como consequência da presença de água líquida. Quanto maior a quantidade de água presente nas folhas, maior será a absorção e menor a reflectância. O comportamento espectral está intimamente ligado à reflexão da radiação eletromagnética (PONZONI; DISPERATI, 1995), e entre as partes da planta, a folha apresenta maior papel na reflexão captada pelos sensores ópticos, principalmente as saudáveis (Figura 3).

Figura 3 - Esquema mostrando as diferenças de reflectâncias entre folhas em diferentes estados fisiológicos e o solo (STEFFEN, 2016)



Segundo Picard, Saint-André e Hanry (2012), utilizar o sensoriamento remoto para mapear e monitorar as mudanças de estoques de carbono é tanto prático quanto viável. Há quase 40 anos temos satélites imageadores fornecendo dados de vegetação com uma cobertura global e altas resoluções espaciais e temporais.

Mesmo que a biomassa florestal não possa ser diretamente medida a partir do espaço, o sensoriamento remoto se vale das características da vegetação para obter informações de regiões distantes e por longos períodos. As relações entre a biomassa medida em inventário e as estimativas baseadas em imagens de satélite nos permitem acessar detalhes do estoque de carbono e apontar onde ocorrem as mudanças (ROY; RAVAN, 1996).

Independente de qual satélite vem os dados, esses métodos assumem que é possível se basear medições de campo para ajustar os modelos de predição de biomassa às observações de sensoriamento remoto (PICARD; SAINT-ANDRÉ; HANRY, 2012). O uso de índices de vegetação gerados de imagens de satélite, juntamente com equações de regressão permitem estimar a biomassa florestal dentro de margens de erro aceitáveis (ZHENG et al., 2004; HENTZ et al., 2014).

2.5 Índices de vegetação

Os índices de vegetação são a transformação matemática da reflectância espectral original (PATEL; SAXENA; SHIWALKAR, 2007), gerados por algoritmos através das imagens de sensores ópticos, para serem usados na interpretação da

cobertura vegetal e sua biomassa. De acordo com Kuntschik (2004) os valores de reflectância de imagens devem ser transformados em valores do índice de interesse para cada pixel, que então podem ser relacionados a características da vegetação. Apesar da praticidade e viabilidade, os sensores ópticos apresentam algumas limitações e dificuldades em sua utilização, como variações nas propriedades da atmosfera e do solo, geometria da visada do sensor, iluminação, fração de nuvens, dentre outros fatores, que novos índices se propuseram a corrigir parcialmente (SINHA et al., 2015).

A fundamentação dos índices de vegetação se baseia na alta reflectância no infravermelho próximo apresentado pelas plantas, causada pelo espalhamento da radiação incidente pelas células do mesófilo da folha, e uma baixa reflectância no vermelho, devido à absorção pela clorofila (BARET; GUYOT, 1991). Utilizando esses comprimentos de onda para enfatizar a diferença entre a forte absorção da radiação eletromagnética vermelha e a forte dispersão da radiação infravermelha próxima, é possível descobrir as características da vegetação. Assim, aumentando as características absorptivas e reflexivas da vegetação em combinações matemáticas de diferentes bandas espectrais, os índices de vegetação fornecem indicadores para medir a verdura e o vigor do dossel (CHEN et al., 2019). As variações das medições da reflectância espectral, provocadas pelo ângulo de visão do sol, condições atmosféricas e solo, são corrigidas pelos índices de vegetação (LU, 2006).

Segundo Chen et al. (2019), por serem ferramentas simples e eficazes, os índices de vegetação têm sido amplamente aplicados em vários estudos de pesquisa de vegetação, incluindo recuperação de parâmetros de vegetação, monitoramento de fenologia, modelagem do ciclo de carbono e estimativa de erosão do solo. De acordo com Rondeaux, Steven e Baret (1996), os índices podem ser divididos em três categorias: 1) índices intrínsecos, como a razão simples (RVI) e o NDVI, que só usam as reflectâncias espectrais medidas; 2) índices relacionados ao solo, que incluem parâmetros da linha do solo, como o índice de vegetação ajustado pelo solo (SAVI) e sua versão otimizada (OSAVI); e 3) índices com correção atmosférica, como o *Enhanced Vegetation Index* (EVI na sigla em inglês).

2.5.1 NDVI

O *Normalized Difference Vegetation Index* (NDVI na sigla em inglês), desenvolvido por Rouse et al. (1974), é um dos mais amplamente empregados índices

de vegetação, sendo utilizado em várias aplicações florestais (DAS; SINGH, 2012). Segundo Hunt Jr. et al. (2004), a motivação para o desenvolvimento do NDVI originalmente foi reduzir os efeitos da transmitância atmosférica, topografia, elevação solar e o azimute, possibilitando assim uma melhor distinção entre a vegetação e o solo. O índice permite também observar as variações sazonais e interanuais da vegetação, auxiliando no seu monitoramento (FERREIRA et al., 2013). Apesar de corrigir vários ruídos multiplicativos (HUETE et al., 2002), o NDVI apresenta saturação em dosséis densos e estratificados (BARET; GUYOT, 1991).

2.5.2 EVI

Por essa razão, muitos trabalhos se propuseram a apresentar melhorias e a desenvolver outros índices de vegetação, como o *Enhanced Vegetation Index* (EVI na sigla em inglês), elaborado por Liu e Huete (1995), que é uma variante aprimorada do NDVI quanto a correções das influências atmosféricas e do solo, e se propõe a ter mais sensibilidade à grandes densidades de biomassa.

2.5.3 RVI

O índice da razão simples, ou *Ratio Vegetation Index* (RVI na sigla em inglês), proposto por Richardson e Wiegand (1977), é um índice de vegetação bem direto que é calculado dividindo o valor de refletância do comprimento de onda do infravermelho próximo pelo comprimento de onda do vermelho, exigindo assim menos capacidade de processamento (CRIPPEN, 1990)

2.5.4 OSAVI

Desenvolvido por Rondeaux, Steven e Baret (1996), o *Optimized Soil Adjusted Vegetation Index* (OSAVI na sigla em inglês) visa reduzir o ruído do solo tanto em baixas quanto em altas coberturas vegetais, e é uma versão mais simplificada de outros índices voltados para solo e que não requer conhecimento prévio do tipo de solo da região alvo.

3 MATERIAL E MÉTODOS

3.1 Área de estudo

As áreas de estudo foram instaladas na região centro-sul do Estado de São Paulo, município de Botucatu (Figura 4), nas Fazendas Experimentais Edgárdia e Lageado, nos fragmentos de Floresta Estacional Semidecidual pertencentes à Faculdade de Ciências Agrônômicas da Universidade Estadual Paulista (UNESP).

Figura 4 - Mapa localizando Botucatu dentro do Estado de São Paulo.



O clima é classificado como subtropical úmido e quente (Cfa), segundo os critérios adotados por Köppen (CUNHA; MARTINS, 2009; ALVARES et al., 2013). Baseado em dados meteorológicos do período de 1997 a 2018 da estação meteorológica da Faculdade de Ciências Agrônômicas/UNESP, campus Botucatu, foi determinada a precipitação média anual de 1.494,4 mm, distribuída principalmente entre os meses de outubro a março. A temperatura média anual determinada para o mesmo período foi de 20,5 °C, com médias mensais de 17,5 °C (julho) a 23 °C (fevereiro) (SIVISACA, 2020).

A vegetação natural das áreas é classificada como Floresta Tropical Estacional Semidecidual, domínio da Mata Atlântica (IBGE, 2012) e na região encontram-se fragmentos de vegetação natural de Floresta Estacional Semidecidual e de transição para Cerradão (JORGE; SARTORI, 2002). Segundo Nogueira Júnior (2010), alguns remanescentes possuem bom estado de conservação, assim como há outros que estão em recuperação natural. Esses remanescentes estão recebendo uma atenção


especial nos últimos anos por situarem-se na Área de Preservação Ambiental (APA) de Botucatu, considerada um importante ponto de recarga do aquífero Guarani (NOGUEIRA JÚNIOR, 2010). Os fragmentos foram agrupados em três categorias de estágios sucessionais de sua vegetação (Figura 5):

Área 1 – Floresta Tardia (FT): localizada inteiramente na Fazenda Experimental Edgárdia, presente nos fragmentos Bixiguento (parcelas 1 e 4), Mata do IB (parcelas 14 e 15) e Mata da Bica (parcelas 12 e 13). Apresenta vegetação nativa antiga, com grande riqueza de espécies e estrutura. Seu relevo de grande declive, devido à ruptura da encosta da *cuesta*, dificulta o acesso e impediu exploração mais intensa da área.

Área 2 – Floresta Perturbada (FP): localizada tanto na Fazenda Experimental Lageado quanto na Edgárdia, abrangendo desde a Mata Ciliar do Lavapés (parcelas 16, 17 e 18), passando pelo Bixiguento (parcelas 2 e 3) e Pomar Velho (parcelas 7 e 8), até chegar ao Carmelucho (parcela 10). Segundo Jorge e Sartori (2002), as áreas sofreram intensa perturbação devido a ações antrópicas como exploração seletiva de madeira e pastagem extensiva, apresentando hoje estágio intermediário de sucessão.

Área 3 – Floresta Secundária (FS): também localizada inteiramente na Fazenda Edgárdia, essa categoria é representativa do fragmento das Três Barras (parcelas 5 e 6), sendo também encontrada no Pomar Velho (parcela 9) e no Carmelucho (parcela 11). Capoeiras jovens ou degradadas e matas secundárias que regeneraram após o abandono das pastagens nos anos 80 (JORGE; SARTORI, 2002).

Figura 5 - Mapa mostrando categorização por estágio sucessional das parcelas permanentes nas fazendas da FCA/UNESP – Botucatu




3.2 Amostragem

Sivisaca (2020) instalou 18 unidades amostrais (parcelas) de 20 m x 100 m (2.000 m²) escolhidas por meio de amostragem aleatória, das quais três foram instaladas na Mata Ciliar do Rio Lavapés, duas foram instaladas no remanescente que apresenta transição para Cerradão e 13 foram instaladas nos remanescentes de Floresta Estacional Semidecidual (Figuras 5 e 6). Foi observada a distância mínima de 500 m entre as parcelas, buscando-se alocá-las em áreas livres de fatores que pudessem influenciar a amostragem, como o efeito de borda (200 m dos limites dos fragmentos).

Os fragmentos florestais estão inseridos nas coordenadas 22°47'32" a 22°50'08" de latitude Sul e 48°22'54" a 48°26'13" de longitude Oeste. Além da categorização por estágio sucessional, a área está dividida em sete fragmentos denominados: Bixiguento (329 ha), Mata Ciliar do Rio Lavapés (155 ha), Três Barras (133 ha), Mata do IB (102 ha), Pomar Velho (80,8 ha), Carmelucho (80,4 ha) e Mata da Bica (58 ha), totalizando 938 ha e 57 km de perímetro (Figura 6).

Figura 6 - Mapa mostrando a localização das parcelas permanentes nas fazendas da FCA/UNESP – Botucatu



Para facilitar a medição e a posterior análise, as parcelas permanentes foram divididas em 10 subparcelas de 10 m x 20 m (200 m²). Todas as árvores com mais de 5 cm de diâmetro à altura do peito (DAP) foram então medidas em seu diâmetro e altura, além de identificadas ao nível de espécie. O período das medições foi de setembro a novembro de 2017.

3.3 Quantificação de biomassa viva acima do solo

A partir desse inventário, Sivilisaca (2020) aplicou a “Metodologia Científica de Inventário Florestal e Geração de UCS^{VT} BMV” (Metodologia Base - MCIF 3.0/2020), Padrão Brasil Mata Viva para a quantificação da biomassa total acima do solo e estoque de carbono. Também, a autora utilizou a equação alométrica de Chave et al. (2005), conhecida como pantropical e indicada para as características climáticas e fenológicas da área de estudo para obter a biomassa; (EQUAÇÃO 1):

$$B_{vas} = \exp(-2,977 + \ln(\rho \times (DAP)^2 \times H)) \quad (1)$$

em que, B_{vas} é a biomassa viva acima do solo (kg); ρ é a densidade da madeira da árvore (g/cm³); DAP é o diâmetro a altura do peito da árvore (cm); H é altura total da árvore (m); $\ln$ é o logaritmo na base neperiana.

Para converter a biomassa viva acima do solo medida em quantidade do carbono, Sivilis (2020) empregou a (EQUAÇÃO 2) de Brown, Lugo e Chapman (1986).

$$C = t_c \times B \quad (2)$$


em que, C é o estoque do carbono (Mg ha^{-1}); t_c é o fator de conversão da biomassa para carbono; B é biomassa de cada reservatório avaliado (Mg ha^{-1}). O fator de conversão utilizado foi 0,47 (IPCC, 2019).

3.4 Geoprocessamento

3.4.1 Google Earth Engine

Para a aquisição das imagens de satélites, foi utilizado o *Google Earth Engine*, que é uma plataforma de processamento geoespacial baseada em nuvem para monitoramento e análises ambientais em grande escala (GORELICK et al., 2017). Há uma enorme quantidade de dados de sensoriamento remoto disponibilizada por várias agências do governo norte-americano, entre elas a NASA e o NOAA, além da agência espacial europeia. Tudo isso aliado à capacidade de processamento da *Google*, acessível por linguagens de programação populares como *JavaScript*, torna a plataforma extremamente prática e poderosa (Figura 7). O que vem popularizando o seu emprego em um número cada vez maior de estudos segundo Tamiminia et al. (2020), inclusive em países e instituições que não teriam condições técnicas de realizar tais análises. Tarefas que, de outra forma, demandariam meses de processamento e *terabytes* de espaço em memória para armazenamento, além de outros custos ocultos como o tempo para escolha, aquisição, *download*, composição e controle de qualidade dos dados dos satélites, são executadas em poucos minutos pela plataforma (XIE et al., 2019).

Figura 7 - Captura de tela demonstrando o funcionamento da plataforma *Google Earth Engine*



3.4.2 Satélites

Para essa pesquisa foram empregadas imagens da área de estudo dos satélites norte-americano Landsat 8 sensor OLI, lançado em 2013 e orbitando a 705 km de altura; e o europeu Sentinel-2 sensor MSI, lançado em 2015 e orbitando a 786 km de altura. Os aparelhos têm resolução espacial de 30 m e 10 m, e resolução temporal de 16 e 5 dias, respectivamente, conforme podemos observar nas Tabelas 1 e 2 e na Figura 8.


Tabela 1 - Dados técnicos do satélite Landsat 8, sensor OLI (NASA, 2013)

Landsat 8	Bandas Espectrais	Resolução Espectral	Resolução Espacial	Resolução Temporal	Área Imageada	Resolução Radiométrica
Sensor OLI (Operational Land Imager)	(B1) Azul Costeiro	430 – 450 nm	30 m	16 dias	170 x 183 km	16 bits
	(B2) Azul	450 – 510 nm				
	(B3) Verde	530 – 590 nm				
	(B4) Vermelho	640 – 670 nm				
	(B5) Infravermelho Próximo	850 – 880 nm				
	(B6) Infravermelho Médio 1	1570 – 1650 nm	15 m			
	(B7) Infravermelho Médio 2	2110 – 2290 nm				
	(B8) Pancromática	500 – 680 nm				
	(B9) Cirrus	1360 – 1380 nm	30 m			

Tabela 2 - Dados técnicos do satélite Sentinel-2, sensor MSI (ESA, 2015)

Sentinel-2	Bandas Espectrais	Resolução Espectral	Resolução Espacial	Resolução Temporal	Área Imageada	Resolução Radiométrica
Sensor MSI (MultiSpectral Instrument)	(B1) Aerosols	443 nm	60 m	5 dias	100 x 290 km	12 bits
	(B2) Blue	490 nm	10 m			
	(B3) Green	560 nm				
	(B4) Red	665 nm				
	(B5) Red Edge 1	705 nm	20 m			
	(B6) Red Edge 2	740 nm				
	(B7) Red Edge 3	783 nm				
	(B8) NIR	842 nm	10 m			
	(B8A) Red Edge 4	865 nm	20 m			
	(B9) Water Vapor	940 nm	60 m			
	(B10) Cirrus	1375 nm				
	(B11) SWIR 1	1610 nm	20 m			
(B12) SWIR 2	2190 nm					

Figura 8 - Comparação entre as bandas do Landsat 8 e Sentinel-2 (NASA, 2013)



As imagens utilizadas foram as que compreenderam o mesmo período em que Sivisaca (2020) realizou as medições em campo, de setembro a novembro de 2017. As imagens foram filtradas pela porcentagem de cobertura de nuvens, sendo selecionadas as que apresentaram quantidade inferior a 10%. Como resultado dessa seleção, seis cenas foram escolhidas com datas de aquisição de 03, 07, 19, 27 de setembro, 05 e 17 de outubro de 2017. As identificações das imagens são apresentadas na Tabela 3 abaixo, discriminando de quais dos satélites e em quais dias elas foram adquiridas. As cenas, da forma que vêm dos servidores da *Google*, exigem algumas correções, que são detalhadas no próximo item.

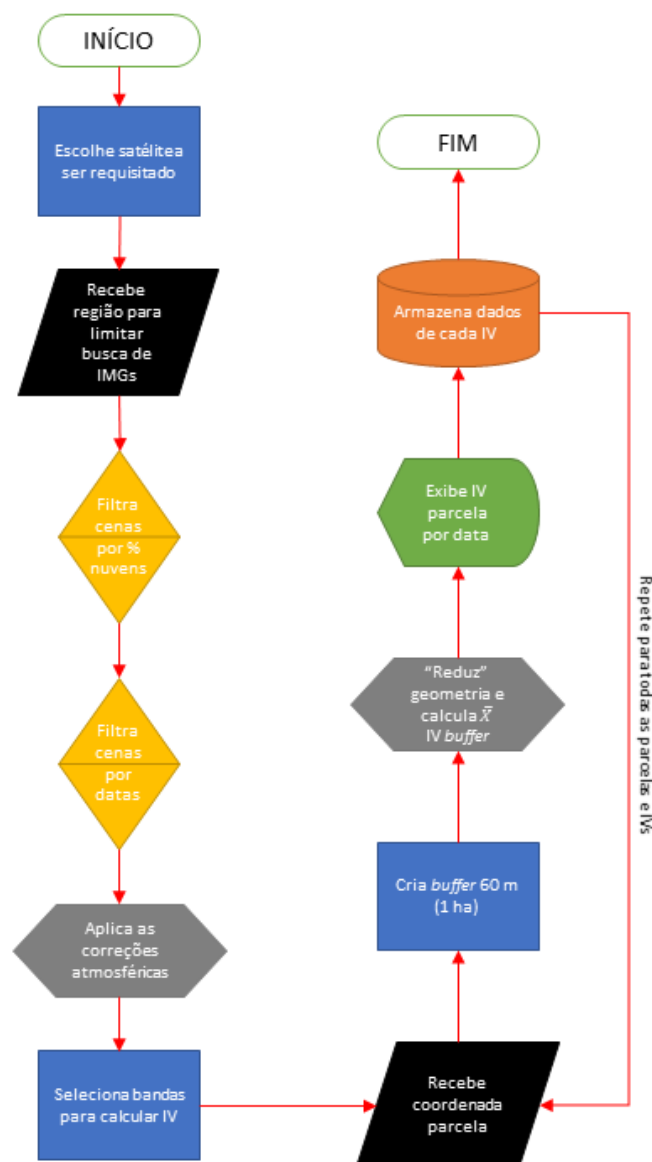
Tabela 3 - Fórmulas dos índices de vegetação utilizados

Satélite	ID Imagem	Data de Aquisição
Landsat 8	LANDSAT/LC08/C01/T1_TOA/LC08_220076_20170903	03/09/2017
	LANDSAT/LC08/C01/T1_TOA/LC08_220076_20170919	19/09/2017
	LANDSAT/LC08/C01/T1_TOA/LC08_220076_20171005	05/10/2017
Sentinel-2	COPERNICUS/S2/20170907T132229_20170907T132225_T22KGV	07/09/2017
	COPERNICUS/S2/20170927T132219_20170927T132218_T22KGV	27/09/2017
	COPERNICUS/S2/20171017T132219_20171017T132219_T22KGV	17/10/2017

3.4.3 Algoritmo

Para acessar todo o acervo de imagens e poder computacional do *Google Earth Engine* foram empregados vários *scripts*, programados na linguagem *JavaScript*. Sua lógica de funcionamento é demonstrada por meio de fluxograma exposto na Figura 9.

Figura 9 - Fluxograma demonstrando funcionamento dos scripts programados para obter os dados de sensoriamento remoto



De maneira geral, primeiro se escolhe a coleção do satélite que será solicitada; a região de interesse é então indicada para limitar a quantidade de imagens apresentadas; o próximo passo é a filtragem das imagens disponíveis baseadas no

percentual de cobertura de nuvens ($< 10\%$) e no período determinado (do inventário de campo).

Antes de iniciar as manipulações matemáticas para obter os índices de vegetação (IV), se faz necessário aplicar correções atmosféricas nas imagens dos satélites, uma vez que as mesmas são entregues pela plataforma *Engine* na reflectância de topo-de-atmosfera. Para essa etapa, foi empregado o método SIAC (*sensor invariant atmospheric correction*, na sigla em inglês), desenvolvido por Yin et al. (2019), que corrige distorções causadas por aerossóis e vapor d'água presentes na atmosfera e transforma para reflectância de superfície as imagens. O diferencial desse método é que ele foi projetado para ser aproveitado em todos os sensores ótimos espaciais, e foi validado com os satélites que foram utilizados neste trabalho.

Para calcular os IVs foram utilizadas três bandas: infravermelho próximo (B5 no Landsat, B8 no Sentinel), vermelho (B4 em ambos satélites) e pontualmente a azul (B2 em ambos satélites). O item abaixo entra em mais detalhes sobre os índices de vegetação. O algoritmo então aplica as fórmulas dos respectivos IVs (Tabela 4) nas imagens corrigidas, que geram outra imagem que atribui um valor do IV para cada pixel. A extração desses valores das imagens de forma aproveitável se dá criando um *buffer* de 60 m em volta de cada parcela (Figura 10), compreendendo uma área de aproximadamente 1 hectare cada. Em seguida, aplica-se uma função de redução na área do *buffer*, obtendo-se a média dos valores dos pixels de cada parcela permanente, de modo para poder permitir a comparação com os valores medidos por Sivilisaca (2020). Esse processo é repetido para cada parcela permanente, para todos os quatros índices.

Figura 10 - Imagem demonstrando a área circular do buffer na parcela permanente 1



3.4.4 Índices de vegetação

Uma vez que a fundamentação dos índices de vegetação se apoia na alta reflectância no infravermelho próximo e baixa reflectância no vermelho apresentada pelas plantas, invariavelmente essas bandas estão no centro das fórmulas. Como os índices de vegetação são transformações matemáticas da reflectância espectral original das imagens de sensores ópticos, diferentes fórmulas apresentam vantagens e desvantagens entre si. Os índices de vegetação escolhidos para este trabalho foram o NDVI, EVI, RVI e o OSAVI, demonstrados na Tabela 4.

Tabela 4 - Fórmulas dos índices de vegetação utilizados

Índice de Vegetação	Equação	Referência
<i>Normalized Difference Vegetation Index</i> (NDVI)	$NDVI = \frac{(NIR - R)}{(NIR + R)}$	Rouse et al. (1974)
<i>Enhanced Vegetation Index</i> (EVI)	$EVI = 2,5 \times \frac{(NIR - R)}{(NIR + 6 \times R - 7,5 \times B + 1)}$	Liu e Huete, (1995)
<i>Ratio Vegetation Index</i> (RVI)	$RVI = \frac{NIR}{R}$	Richardson e Wiegand (1977)
<i>Optimized Soil Adjusted Vegetation Index</i> (OSAVI)	$OSAVI = \frac{(1 + 0,16) \times (NIR - R)}{(NIR + R + 0,16)}$	Rondeaux, Steven e Baret (1996)

NIR = infravermelho próximo, R = vermelho e B = azul

O NDVI foi selecionado por ser um dos mais amplamente empregados índices de vegetação, dada sua simplicidade e responsividade a vegetação em contraste com o solo. Apesar disso, apresenta saturação em dosséis densos e estratificados.

Por isso nosso segundo índice escolhido foi o EVI, que se propõe a ser uma variante aprimorada do NDVI, mostrando mais sensibilidade à grandes densidades de biomassa. É o único dos IVs do trabalho que se utiliza da banda azul das imagens de satélites.

O RVI foi eleito por ser um IV de cálculo muito simples e direto, que além de exigir menos capacidade de processamento dos computadores pode ser um índice com menor chance de erros e interferências por fatores externos. Também é o único dos quatro que não se limita à faixa de valores do -1 ao 1.

Para representar a família de IVs desenvolvidos com foco no solo, o OSAVI foi incluído. É um índice que visa reduzir o ruído do solo tanto em baixas quanto em altas coberturas vegetais, tendo uma formulação muito próxima à do NDVI.

3.5 Análise estatística

3.5.1 Análise descritiva das variáveis biométricas

Para a melhor visualização e descrição do comportamento de todos os dados, foram feitas estatísticas descritivas, histogramas e box-plots das variáveis biométricas de cada estágio sucessional das florestas, e dos índices de vegetação (as variáveis resposta), ambas para cada um dos dois satélites (Landsat 8 e Sentinel-2).

3.5.2 Análise do efeito dos tipos de floresta na biomassa e área basal

Na análise da biomassa e da área basal diâmetro, foram ajustados modelos lineares generalizados com a distribuição gama e função de ligação logarítmica (NELDER; WEDDERBURN, 1972), considerando como fatores os tipos de floresta (tardia, secundária e perturbada). Foram tomados os logaritmos neperianos das variáveis respostas (biomassa e área basal) para estabilidade dos resíduos padronizados. Foi utilizado o procedimento *genmod* (do Programa estatístico SAS – *Free Statistical Statistical Software, SAS University Edition* e para comparações entre tratamentos foi utilizado foi o teste de Tukey-Kramer (WESTFALL et al., 1999). A qualidade de ajuste dos modelos foi feita através da análise de desvios (*deviance*), gráficos dos resíduos de Pearson padronizados.

3.5.3 Efeito dos satélites nos índices de vegetação

Nesta etapa, foram ajustados modelos lineares generalizados com a distribuição gama e função de ligação logarítmica (NELDER; WEDDERBURN, 1972), considerando as variáveis resposta os índices de vegetação (NDVI, EVI, RVI e OSAVI) e como fatores os satélites (Landsat 8 e Sentinel-2). Devido à estrutura de dados longitudinais - medições no tempo na mesma unidade amostral (subparcela), foi utilizada a técnica das equações de estimação generalizadas (NELDER; WEDDERBURN, 1972; DIGGLE et al., 2002). Foi utilizado o procedimento *genmod* (do Programa estatístico SAS – *Free Statistical Statistical Software, SAS University Edition* e para comparações entre tratamentos foi utilizado foi o teste de Tukey-Kramer (Westfall, et al., 1999). A qualidade de ajuste dos modelos foi feita através da análise de desvios (*deviance*), gráficos dos resíduos de Pearson padronizados.

3.5.4 Correlação entre biomassa, IVs e modelos de regressão lineares

Para determinar se existem correlações significativas entre a biomassa com os índices de vegetação (NDVI, EVI, RVI e OSAVI) foram realizadas correlações de Spearman (r de Spearman), seguidos dos valores- p ($p < 0,05$) referentes ao teste de significância da correlação (H_0 : correlação = 0; H_1 : correlação $\neq$ 0). As análises de correlação foram realizadas no programa R Core Team (R, 2018).

Também, nesta etapa foram ajustados modelos lineares múltiplos considerando como variáveis resposta a biomassa e a área basal, e covariáveis os índices de vegetação (NDVI, EVI, RVI e OSAVI) segundo os satélites (Landsat 8 e Sentinel-2). Os modelos são apresentados ao teste de significância de 90% ($p < 0,10$) e 95% ($p < 0,05$).

3.5.5 Categorização das variáveis de biomassa e área basal

Nesta etapa, outra abordagem é sugerida para explicar as estimativas de biomassa por meio dos índices de vegetação, sendo a categorização das covariáveis contínuas biomassa e área basal, usando os tercís das respectivas distribuições. Assim, esta nova variável ficará subdividida nos intervalos: do mínimo (0% dos dados) até o 1º tercíl (33,33% dos dados); do 1º tercíl até o 2º tercíl (66,66% dos dados) e do 2º tercíl até o máximo (100% dos dados).


3.5.5.1 Técnica *bootstrap* para reamostragem de biomassa e área basal

Com o objetivo de classificar os dados de biomassa e de área basal a partir dos dados dos índices espectrais, foram feitas amostragens casuais simples considerando 1.000 (mil) repetições, com 60% do conjunto de dados destinados para a modelagem os 40% restantes para fazer a classificação e validação. Esta é considerada uma técnica de simulação *bootstrap* (EFRON, 1979). Foi utilizado o comando *proc surveyselect* do programa SAS - Free Statistical Software, SAS University Edition.

3.5.5.2 Classificação das categorias pelos dados espectrais

A partir das amostras para modelagem e validação obtidas no item anterior, foram utilizadas Funções Lineares Discriminantes (JOHNSON; WICHERN, 2014) com o objetivo de classificar amostras de dados espectrais. Foi considerada a distribuição não paramétrica dos índices de vegetação - devido à não normalidade dos dados espectrais, utilizando a técnica dos quatro vizinhos mais próximos. Foi também obtida a validação cruzada (*cross-validation*), sendo possível verificar a acurácia do método de classificação usado. Foi utilizado o comando *proc discrim* do programa SAS - Free Statistical Software, SAS University Edition.

Figura 11 - Gráfico exemplificando como funcionará a categorização seguida da reamostragem e classificação das variáveis biométricas pelos índices de vegetação



4 RESULTADOS

4.1 Análise descritiva da biomassa e área basal

Nas três áreas florestais avaliadas foram registradas 4.231 árvores vivas com $DAP_{1,30m} \geq 5$ cm, as árvores se distribuíram em 175 espécies e 43 famílias nas áreas florestais estudadas. Na floresta tardia foram medidas 1.335 árvores, enquanto na floresta perturbada se chegou ao número de 1.759 indivíduos e para a floresta secundária foram 1.137 árvores.

A média da biomassa total das áreas foi $191,93 \text{ Mg ha}^{-1}$ (Figura 12). E a média da área basal total foi $24,65 \text{ m}^2 \text{ ha}^{-1}$ (Figura 13).

Figura 12 - Contextualização dos dados do inventário de campo para biomassa (SIVISACA, 2020)





Figura 13 - Contextualização dos dados do inventário de campo para área basal (SIVISACA, 2020)



4.2 Análise descritiva dos índices de vegetação

As Figuras 14 a 21 apresentam os resultados das estatísticas descritivas dos índices de vegetação (NDVI, EVI, RVI e OSAVI), gerados por imagens dos satélites (Landsat 8 e Sentinel-2).

NDVI apresentou valores que variaram de 0,54 até 0,90. Notou-se uma diferença entre os valores gerados pelo Landsat 8 (maiores) e os obtidos por meio do Sentinel-2 (menores). Para o satélite americano, os valores mínimo e máximo foram de 0,67 e 0,90, com média de 0,83. No Sentinel-2, os valores mínimo e máximo foram de 0,54 e 0,80, com média de 0,73.

Figura 14 - Perfil descritivo dos dados de NDVI gerados por imagens Landsat 8, Box-Plot, Histograma e Q-Q Plot





Figura 15 - Perfil descritivo dos dados de NDVI gerados por imagens Sentinel-2, Box-Plot, Histograma e Q-Q Plot



Para o EVI, os valores foram consideravelmente mais baixos com relação aos do NDVI, variando de 0,30 até 0,66. A diferença entre os valores gerados pelo Landsat

8 (maiores) e os obtidos por meio do Sentinel-2 (menores) persiste, mas também foi menor. No Landsat, os valores mínimo e máximo foram de 0,35 e 0,66, com média de 0,52. Enquanto no Sentinel-2, os valores mínimo e máximo foram de 0,30 e 0,60, com média de 0,48.

Figura 16 - Perfil descritivo dos dados de EVI gerados por imagens Landsat 8, Box-Plot, Histograma e Q-Q Plot





Figura 17 - Perfil descritivo dos dados de EVI gerados por imagens Sentinel-2, Box-Plot, Histograma e Q-Q Plot



O RVI apresentou valores muito diferentes dado a natureza de sua formulação, não se limitando a ficar abaixo de 1. Seus resultados variaram de 3,48 até 19,76. Para esse índice a diferença entre os satélites foi sensivelmente maior. No Landsat 8, os valores mínimo e máximo foram de 5,32 e 19,76, com média de 11,91. Já no Sentinel-2, os valores mínimo e máximo foram de 3,48 e 9,01, com média de 6,72.

Figura 18 - Perfil descritivo dos dados de RVI gerados por imagens Landsat 8, Box-Plot, Histograma e Q-Q Plot





Figura 19 - Perfil descritivo dos dados de RVI gerados por imagens Sentinel-2, Box-Plot, Histograma e Q-Q Plot



O OSAVI apresentou valores mais próximos dos do EVI, variando de 0,40 até 0,76. A diferença entre os satélites começou negligenciável nos valores mínimos, mas foi se alargando quanto mais próximo dos máximos. Para o Landsat 8, os valores mínimo e máximo foram de 0,40 e 0,76, com média de 0,65. E para o Sentinel-2, os valores mínimo e máximo foram de 0,40 e 0,67, com média de 0,57.

Figura 20 - Perfil descritivo dos dados de OSAVI gerados por imagens Landsat 8, Box-Plot, Histograma e Q-Q Plot





Figura 21 - Perfil descritivo dos dados de OSAVI gerados por imagens Sentinel-2, Box-Plot, Histograma e Q-Q Plot



4.3 Biomassa e área basal entre os estágios sucessionais das florestas

Ao comparar as médias da biomassa da vegetação e estágios sucessionais da Floresta Estacional Semidecidual, foram encontradas diferenças significativas ($p < 0,0001$) entre as áreas de floresta tardia com as áreas de florestas perturbadas e secundárias. Entre as áreas perturbadas e as secundárias, não foi encontrada diferença estatística na biomassa (Tabela 5).

Tabela 5 - Comparação de média da biomassa da vegetação, erro padrão da média (em parêntesis), entre as áreas de sucessão ecológica da Floresta Estacional Semidecidual na cuesta de Botucatu, SP

Floresta	Biomassa média (Mg/ha)	
Tardia	261,54 (16,54)	a*
Secundária	161,42 (9,92)	b
Perturbada	154,97 (11,70)	b

*Médias seguidas de mesma letra na coluna, não diferem estatisticamente pelo teste de Tukey-Kramer ($p < 0,05$).

Fazendo a mesma comparação de médias da área basal e estágios sucessionais, novamente foram encontradas diferenças significativas ($p < 0,0001$) entre as áreas de floresta tardia com as áreas de florestas perturbadas e secundárias. Entre as áreas perturbadas e secundárias, não foi encontrada diferença estatística na área basal (Tabela 6).

Tabela 6 - Área basal média (m²/ha), com erro padrão entre parêntesis, segundo tipo de floresta





Floresta	Área basal média (m²/ha)	
Tardia	30,16 (1,4511)	a*
Secundária	21,97 (0,9894)	b
Perturbada	21,85 (1,0478)	b

*Médias seguidas de mesma letra, não diferem estatisticamente pelo teste de Tukey-Kramer ($p < 0,05$).

4.4 Efeito dos satélites nos índices de vegetação

De acordo com os resultados obtidos a partir dos modelos lineares generalizados e teste de comparação de médias dos índices de vegetação, em função dos satélites (Landsat 8 e Sentinel-2), observou-se diferença significativa entre cada um dos índices e os satélites (Tabela 7).

Tabela 7 - Comparação de médias dos índices de vegetação e os satélites, erro padrão da média entre parênteses. Ajuste (valor-p e resíduos de Pearson) dos modelos lineares generalizados com a distribuição gama e função de ligação logarítmica com estrutura de medi de medidas repetidas, considerando as variáveis resposta os índices espectrais (NDVI, EVI, RVI e OSAVI) e como fatores os satélites (Landsat 8 e Sentinel-2)

Índice de vegetação	Satélite		valor-p	Resíduos de Pearson
	Landsat 8	Sentinel-2		
NDVI	0,83 (0,002)	a 0,73 (0,002)	b <0,0001	
EVI	0,52 (0,003)	a 0,48 (0,003)	b <0,0001	
RVI	11,92 (0,12)	a 6,72 (0,12)	b <0,0001	
OSAVI	0,65 (0,002)	a 0,57 (0,003)	b <0,0001	

4.5 Relação entre a biomassa, área basal e os índices de vegetação

As análises de correlação de Spearman entre a biomassa, assim como área basal, e os índices de vegetação gerados pelas imagens do Landsat 8 na área de floresta tardia na *cuesta* de Botucatu, não foram significativas, ou seja, não existe correlação entre biomassa e os índices de vegetação, assim como entre área basal e os índices de vegetação nesta área (Tabela 8).

Tabela 8 - Matriz de correlação entre variáveis biométricas e índices de vegetação obtidos a partir do satélite Landsat 8, para a área de Floresta Tardia

	Área Basal	Biomassa	NDVI	EVI	RVI	OSAVI
Área Basal	1	0,93 **	-0,02 ^{ns}	-0,04 ^{ns}	-0,02 ^{ns}	-0,03 ^{ns}
Biomassa	0,93 **	1	0,01 ^{ns}	-0,07 ^{ns}	0,01 ^{ns}	-0,04 ^{ns}
NDVI	-0,02 ^{ns}	0,01 ^{ns}	1	0,38 **	1,00 **	0,68 **
EVI	-0,04 ^{ns}	-0,07 ^{ns}	0,38 **	1	0,38 **	0,91 **
RVI	-0,02 ^{ns}	0,01 ^{ns}	1,00 **	0,38 **	1	0,68 **
OSAVI	-0,03 ^{ns}	-0,04 ^{ns}	0,68 **	0,91 **	0,68 **	1

Valores seguidos de “ * ” indicam significância a nível de 5% de probabilidade; “ ** ” indica significância a 1% de probabilidade; ns: não significativo

Na área de floresta perturbada, as análises de correlação entre a biomassa, área basal, e os índices de vegetação também não foram significativas para todos os IVs do Landsat, mostrando novamente que não há correlação entre biomassa e área basal com os índices de vegetação (Tabela 9).

Tabela 9 - Matriz de correlação entre variáveis biométricas e índices de vegetação obtidos a partir do satélite Landsat 8, para a área de Floresta Perturbada

	Área Basal	Biomassa	NDVI	EVI	RVI	OSAVI
Área Basal	1	0,92 **	-0,04 ^{ns}	-0,10 ^{ns}	-0,02 ^{ns}	-0,07 ^{ns}
Biomassa	0,92 **	1	-0,02 ^{ns}	-0,06 ^{ns}	-0,01 ^{ns}	-0,04 ^{ns}
NDVI	-0,04 ^{ns}	-0,02 ^{ns}	1	0,67 **	1,00 **	0,83 **
EVI	-0,10 ^{ns}	-0,06 ^{ns}	0,67 **	1	0,67 **	0,95 **
RVI	-0,02 ^{ns}	-0,01 ^{ns}	1,00 **	0,67 **	1	0,83 **
OSAVI	-0,07 ^{ns}	-0,04 ^{ns}	0,83 **	0,95 **	0,83 **	1

Valores seguidos de “ * ” indicam significância a nível de 5% de probabilidade; “ ** ” indica significância a 1% de probabilidade; ns: não significativo

E as análises de correlação para a área de floresta secundária também não foram significativas, como para as florestas tardia e perturbada (Tabela 10). Observa-se também um padrão de afinidades entre esses IVs – gerados pelas imagens Landsat 8 – que se mantém, em maior ou menor grau, para todas as áreas de florestas, com

o NDVI se mostrando sempre altamente correlacionado com o RVI, assim como EVI com o OSAVI.

Tabela 10 - Matriz de correlação entre variáveis biométricas e índices de vegetação obtidos a partir do satélite Landsat 8, para a área de Floresta Secundária

	Área Basal	Biomassa	NDVI	EVI	RVI	OSAVI
Área Basal	1	0,94 **	0,01 ^{ns}	0,03 ^{ns}	0,01 ^{ns}	0,01 ^{ns}
Biomassa	0,94 **	1	-0,03 ^{ns}	-0,01 ^{ns}	-0,03 ^{ns}	-0,04 ^{ns}
NDVI	0,01 ^{ns}	-0,03 ^{ns}	1	0,75 **	1,00 **	0,81 **
EVI	0,03 ^{ns}	-0,01 ^{ns}	0,75 **	1	0,75 **	0,97 **
RVI	0,01 ^{ns}	-0,03 ^{ns}	1,00 **	0,75 **	1	0,81 **
OSAVI	0,01 ^{ns}	-0,04 ^{ns}	0,81 **	0,97 **	0,81 **	1

Valores seguidos de “ * ” indicam significância a nível de 5% de probabilidade; “ ** ” indica significância a 1% de probabilidade; ns: não significativo

Para os índices de vegetação gerados pelo Sentinel-2 a tendência continua, com a correlação de Spearman entre a biomassa, área basal e os índices de vegetação na área de floresta tardia na *cuesta* de Botucatu não se mostrando significativas, ou seja, não existe correlação entre biomassa e os índices de vegetação, assim como entre área basal e os índices de vegetação nesta área (Tabela 11).

Tabela 11 - Matriz de correlação entre variáveis biométricas e índices de vegetação obtidos a partir do satélite Sentinel-2, para a área de Floresta Tardia

	Área Basal	Biomassa	NDVI	EVI	RVI	OSAVI
Área Basal	1	0,92 **	0,01 ^{ns}	-0,05 ^{ns}	0,01 ^{ns}	-0,03 ^{ns}
Biomassa	0,92 **	1	-0,02 ^{ns}	-0,11 ^{ns}	-0,03 ^{ns}	-0,09 ^{ns}
NDVI	0,01 ^{ns}	-0,02 ^{ns}	1	0,72 **	1,00 **	0,86 **
EVI	-0,05 ^{ns}	-0,11 ^{ns}	0,72 **	1	0,75 **	0,97 **
RVI	0,01 ^{ns}	-0,03 ^{ns}	1,00 **	0,75 **	1	0,88 **
OSAVI	-0,03 ^{ns}	-0,09 ^{ns}	0,86 **	0,97 **	0,88 **	1

Valores seguidos de “ * ” indicam significância a nível de 5% de probabilidade; “ ** ” indica significância a 1% de probabilidade; ns: não significativo

Já as análises de correlação entre a biomassa, área basal e os índices de vegetação na área de floresta perturbada mostraram um resultado consideravelmente diferente das demais áreas, pois todos os IVs apresentaram correlações significativas. Apesar de negativas e fracas, sugerem uma leve relação inversa dos índices de vegetação e biomassa, assim como para área basal, nesta área (Tabela 12).

Tabela 12 - Matriz de correlação entre variáveis biométricas e índices de vegetação obtidos a partir do satélite Sentinel-2, para a área de Floresta Perturbada

	Área Basal	Biomassa	NDVI	EVI	RVI	OSAVI
Área Basal	1	0,90 **	-0,13 *	-0,18 *	-0,16 *	-0,16 *
Biomassa	0,90 **	1	-0,14 *	-0,16 *	-0,15 *	-0,16 *
NDVI	-0,13 *	-0,14 *	1	0,86 **	0,96 **	0,94 **
EVI	-0,18 *	-0,16 *	0,86 **	1	0,90 **	0,98 **
RVI	-0,16 *	-0,15 *	0,96 **	0,90 **	1	0,95 **
OSAVI	-0,16 *	-0,16 *	0,94 **	0,98 **	0,95 **	1

Valores seguidos de “ * ” indicam significância a nível de 5% de probabilidade; “ ** ” indica significância a 1% de probabilidade; ns: não significativo

E as análises de correlação para a área de floresta secundária também não foram significativas, como para a floresta tardia (Tabela 13). Novamente observa-se um padrão de afinidades entre os IVs – gerados pelas imagens Sentinel-2 – que se mantém, em maior grau do que os IVs Landsat, para todas as áreas de florestas, com o NDVI se mostrando sempre altamente correlacionado com o RVI, assim como EVI com o OSAVI.

Tabela 13 - Matriz de correlação entre variáveis biométricas e índices de vegetação obtidos a partir do satélite Sentinel-2, para a área de Floresta Secundária

	Área Basal	Biomassa	NDVI	EVI	RVI	OSAVI
Área Basal	1	0,92 **	0,005 ns	0,01 ns	0,01 ns	0,01 ns
Biomassa	0,92 **	1	0,01 ns	0,01 ns	0,02 ns	0,01 ns
NDVI	0,005 ns	0,01 ns	1	0,90 **	0,98 **	0,96 **
EVI	0,01 ns	0,01 ns	0,90 **	1	0,93 **	0,98 **
RVI	0,01 ns	0,02 ns	0,98 **	0,93 **	1	0,97 **
OSAVI	0,01 ns	0,01 ns	0,96 **	0,98 **	0,97 **	1

Valores seguidos de “ * ” indicam significância a nível de 5% de probabilidade; “ ** ” indica significância a 1% de probabilidade; ns: não significativo

Os modelos de regressão ajustados para explicar a biomassa e área basal em função dos índices de vegetação mostraram coeficientes de determinação baixos, apesar de significativos. Para biomassa, não houve modelos significativos para floresta secundária, enquanto para área basal apenas floresta perturbada gerou modelos significativos (Tabelas 14 e 15).

Tabela 14 - Modelos de regressão de biomassa acima do solo para todos os índices de vegetação e satélites para todos os fragmentos forestais de Floresta Estacional Semidecidual (FES) e segundo o tipo de sucessão ecológica da floresta: tardia (FEST) e perturbada (FESP). Nos modelos se mostram o coeficiente de determinação de ajuste (R^2 Adj) e o valor significativo estatístico do modelo (p-value)

Nº	Tipo de floresta	Satélite	Modelo	R^2 Adj	p-value
1	FES	Sentinel-2	Biomassa = 401,6 - 440,4 EVI	0,015	0,052**
2	FES	Sentinel-2	Biomassa = 795,1 - 725,3 (EVI/OSAVI)	0,019	0,037*
3	FES	Sentinel-2	Biomassa = -146,91 + 218,84 (NDVI/EVI)	0,023	0,023*
4	FES	Sentinel-2	Biomassa = -598,6 + 616,8 (NDVI/OSAVI)	0,024	0,020*
5	FEST	Sentinel-2	Biomassa = -477,6 + 474,3 (NDVI/EVI)	0,030	0,098**
6	FEST	Sentinel-2	Biomassa = -1549,0 + 1409,0 (NDVI/OSAVI)	0,038	0,072**
7	FESP	Landsat 8	Biomassa = 333,5 - 356,1 EVI	0,023	0,094**
8	FESP	Sentinel-2	Biomassa = 354,5 - 431,5 EVI	0,027	0,079**
9	FESP	Sentinel-2	Biomassa = 340,0 - 28,44 RVI	0,027	0,076**
10	FESP	Sentinel-2	Biomassa = 455,5 - 537,9 OSAVI	0,026	0,079**
11	FESP	Sentinel-2	Biomassa = 725,2 - 694,4 (EVI/OSAVI)	0,026	0,083**
12	FESP	Sentinel-2	Biomassa = -137,9 + 185,4 (NDVI/EVI)	0,025	0,085**
13	FESP	Sentinel-2	Biomassa = -499,9 + 506,7 (NDVI/OSAVI)	0,025	0,087**

Nível de significância $p = 0,05^*$, $p=0,10^{**}$. (Modelo de melhor desempenho em negrito.)

Tabela 15 - Modelos de regressão de área basal para todos os índices de vegetação e satélites para todos os fragmentos forestais de Floresta Estacional Semidecidual (FES) e segundo o tipo de sucessão ecológica da floresta: tardia (FEST), perturbada (FESP) e secundária (FESS). Nos modelos se mostram o coeficiente de determinação de ajuste (R^2 Adj) e o valor significativo estatístico do modelo (p-value)

Nº	Tipo de floresta	Satélite	Modelo	R Adj ²	p-value
1	FES	Sentinel-2	Área basal = 77,40 - 63,43 (EVI/OSAVI)	0,018	0,039*
2	FES	Sentinel-2	Área basal = -5,48 + 19,46 (EVI/OSAVI)	0,023	0,022*
3	FES	Sentinel-2	Área basal = -46,01 + 55,13 (NDVI/OSAVI)	0,025	0,019*
4	FESP	Sentinel-2	Área basal = 83,28 - 74,80 (EVI/OSAVI)	0,043	0,036*
5	FESP	Sentinel-2	Área basal = -10,690 + 20,596 (NDVI/EVI)	0,045	0,032*
6	FESP	Sentinel-2	Área basal = -49,78 + 55,42 (NDVI/OSAVI)	0,043	0,036*

Nível de significância $p = 0,05^*$, $p=0,10^{**}$. (Modelo de melhor desempenho em negrito.)

4.6 Categorização da biomassa e área basal segundo os IVs

Para a categorização das covariáveis contínuas biomassa e área basal, foram criadas duas categorias: área de floresta tardia (com 60 observações) e as áreas de floresta secundárias + perturbadas (com 120 observações). É importante notar que a segunda categoria é formada a partir da união das áreas perturbadas e secundária devido a ambas não terem apresentado diferenças significativas nas estimativas de biomassa e área basal. Portanto, todas as modelagens seguintes foram feitas com a segunda categoria devido ao número de observações. A seguir, na Tabela 16, são apresentadas as categorias para biomassa e área basal seguindo três percentis: do mínimo (0% dos dados) até o 1º tercil (33,33% dos dados); do 1º tercil até o 2º tercil (66,66% dos dados) e do 2º tercil até o máximo (100% dos dados).

Tabela 16 - Categorização das variáveis biométricas (biomassa e área basal) de acordo com a divisão dos dados pelos tercís

Percentil	Biomassa (Mg/ha)	Área basal (m²/ha)
1º	20,75 – 89,52	6,14 – 15,65
2º	89,52 – 147,94	15,65 – 24,15
3º	147,94 – 795,50	24,15 – 71,88

4.6.1 Classificação das categorias pelos dados espectrais

Após a categorização e aplicação da técnica de reamostragem *bootstrap*, foi feita a validação cruzada da classificação das categorias usando a função discriminante. Foram usadas como critério a distribuição não paramétrica dos dados pelo método de quatro vizinhos mais próximos e a distribuição normal dos índices e variâncias comuns usando a função quadrática discriminante.

Na Tabela 17 observa-se que o índice de acerto na classificação para a primeira categoria de biomassa fica pouco acima de 50%, enquanto na segunda categoria não chega a 40%. O destaque fica para a terceira categoria, com mais de dois terços das iterações classificando corretamente. O índice médio de classificações certas ficou em 53,31%.

Tabela 17 - Validação cruzada da classificação de categorias de biomassa para os satélites Landsat 8 e Sentinel-2, usando função discriminante com critério de classificação considerando a distribuição não paramétrica dos dados pelo método dos quatro vizinhos mais próximos

Categoria de biomassa	Classificação			Total
	20,75 ┆ 89,52	89,52 ┆ 147,94	147,94 ┆ 795,50	
20,75 ┆ 89,52	5.552 54,83%	1.940 20,20%	2.508 24,97%	10.000 100%
89,52 ┆ 147,94	3.033 30,33%	3.701 37,01%	3.266 32,66%	10.000 100%
147,94 ┆ 795,50	1.536 15,36%	1.723 17,23%	6.741 67,41%	10.000 100%
Total	10.121 37,74%	7.364 24,55%	12.515 41,72%	30.000 100%

A Tabela 18 mostra melhora no índice de acerto na classificação para a primeira categoria de área basal, pouco acima de 61%, melhora essa também observada na segunda categoria, que alcança acertos pouco acima de 50% das vezes. A terceira categoria apresenta pouco mais de 55% das iterações classificadas corretamente. O índice médio de classificações certas ficou em 55,49%.

Tabela 18 - Validação cruzada da classificação de categorias de área basal para os satélites Landsat 8 e Sentinel-2, usando função discriminante com critério de classificação considerando a distribuição não paramétrica dos dados pelo método dos quatro vizinhos mais próximos

Categoria de área basal	Classificação			Total
	6,14 ┘ 15,65	15,65 ┘ 24,15	24,15 ┘ 71,88	
6,14 ┘ 15,65	5.514 61,27%	2.328 25,87%	1.158 12,87%	9.000 100%
15,65 ┘ 24,15	1.927 17,52%	5.616 51,05%	3.457 31,43%	11.000 100%
24,15 ┘ 71,88	2.228 22,28%	2.256 22,56%	5.516 55,16%	10.000 100%
Total	9.669 32,23%	10.200 34,00%	10.131 33,77%	30.000 100%

5 DISCUSSÃO

5.1 Relação entre biomassa e os índices de vegetação

Dividindo as parcelas estudadas por Sivisaca (2020) em áreas florestais com diferentes estágios de sucessão ecológica, observou-se uma clara diferença, tanto em biomassa quanto em área basal, entre a floresta tardia e as áreas de floresta perturbada e secundária. Como era esperado (BROWN, 1997; SEDJO, 2001), a área florestal mais madura retém maior volume de biomassa, e por conter mais indivíduos maiores, apresenta maior área basal. E dessa forma armazena grandes quantidades do carbono terrestre (JAMES et al., 2018).

Os satélites que forneceram as imagens utilizadas nesse estudo, o norte-americano Landsat 8 (NASA, 2013) e o europeu Sentinel-2 (ESA, 2015), possuem diferenças técnicas entre seus sensores ópticos, notadamente a resolução espacial (30m e 10m, respectivamente). Supunha-se que essa diferença fosse se refletir nos valores dos índices de vegetação gerados das imagens capturadas por esses satélites, o que se provou verdadeiro, com os mesmos IVs resultando em valores estatisticamente diferentes entre si.

Mas ao contrário do que outros autores encontraram (PANDEY; ANAND; SRIVASTAVA, 2019; THAKUR et al., 2019), os índices de vegetação estudados neste trabalho não mostraram correlação com a biomassa acima do solo, e conseqüentemente, com o carbono estocado. O mesmo se repetiu para área basal, métrica que é altamente correlata à biomassa florestal. Mesmo as diferentes resoluções entre os satélites empregados não geraram efeitos perceptíveis na relação dos índices de vegetação com biomassa ou área basal. Uma exceção digna de nota encontrada pelo Sentinel-2 são as correlações fracas e negativas, mas significativas, de todos os índices de vegetação tanto com a biomassa quanto com a área basal, somente para a área de floresta perturbada, o que corrobora os resultados encontrados por Chrysafis et al. (2017), em estudo que também utilizou imagens do satélite europeu.

Foi observado também que os índices de vegetação, além da diferença devido à qual satélite os gerou, apresentam tendências de afinidade entre si, independente de satélite. O NDVI é extremamente correlato ao RVI, enquanto o EVI se correlaciona muito com o OSAVI. Para esse último par, considerando que na análise descritiva ambos (EVI e OSAVI) apresentavam valores próximos entre si, essa relação não

chega a ser de todo surpreendente. O que se destaca é que as fórmulas desses IVs são consideravelmente distintas (LIU; HUETE, 1995; RONDEAUX; STEVEN; BARET, 1996), com o EVI destoando muito de todos os outros índices por usar a banda azul e ter fatores de correção elevados no denominador e multiplicando a fórmula toda. Já a relação entre NDVI e RVI provavelmente é tão estreita dado que os *inputs* de ambos são somente duas bandas (vermelho e infravermelho próximo), sem outros fatores de modificação (ROUSE et al., 1974; RICHARDSON; WIEGAND, 1977). Sánchez-Ruiz et al. (2019) sugerem também que a banda de reflectância SWIR (*short-wave infrared* no termo em inglês) pode ser incluída ou mesmo substituir o infravermelho para aumentar a performance dos IVs, o que pode ser um caminho para estudos futuros com os índices de vegetação estudados.

De toda forma, algum erro e subestimava eram esperados, considerando que o alvo atingido com os índices de vegetação, a reflectância das folhas, é apenas parte de um dos cinco depósitos naturais de carbono (biomassa viva acima do solo, com os outros quatro sendo biomassa subterrânea, madeira morta, serrapilheira e matéria orgânica do solo), e contém pouco mais da metade do estoque (BROWN, 1997; QURESHI; PARIVA; HUSSAIN, 2012; IPCC, 2019). Mas fica evidente a ineficiência desses IVs para a estimativa de biomassa e área basal nessa fitofisionomia da Mata Atlântica.

5.2 Modelos

Todos os modelos de regressão desenvolvidos para explicar biomassa viva acima do solo e área basal em função dos índices de vegetação escolhidos tiveram baixos coeficientes de determinação de ajuste (nenhum passou de 5%), apesar de significativos. Ou seja, é quase nula a explicação da biomassa e da área basal pelos IVs.

Ajustar todas as parcelas de maneira única rendeu sete dos 19 modelos das Tabelas 15 e 16. Com relação à divisão por áreas sucessionais, não foi possível obter modelo de regressão significativo de biomassa para floresta secundária. Para área basal, além dos modelos para todas as áreas, apenas floresta perturbada gerou modelos significativos.

Para biomassa, dos 13 modelos apresentados na Tabela 15, apenas um foi derivado do Landsat 8. Para área basal, nenhum. Provavelmente aqui se observa que o refinamento espacial do satélite europeu resulta em modelos de regressão mais

significativos. Apesar disso, de acordo com Ploton et al. (2017), o aumento da resolução espacial em relação aos dados ópticos mais grosseiros e amplamente usados (como o Landsat), pode permitir explorar as propriedades geométricas de copas de árvores (com algoritmos de delineamento de copas) ou de dosséis florestais (análise textural), que se relacionam de forma mais direta à biomassa do que os índices de vegetação, que são transformações matemáticas da reflectância espectral original (PATEL; SAXENA; SHIWALKAR, 2007).

Outra observação que se destaca é que três quartos dos modelos significativos utilizam a combinação de dois índices de vegetação em sua fórmula. E a maioria dos modelos que utilizam apenas um IV, se valem do EVI ou do OSAVI. Isso pode indicar que índices que entregam valores menores saturem menos em vegetações mais densas, como é a Floresta Estacional Semidecidual, superando um antigo problema do NDVI (BARET; GUYOT, 1999; THAKUR et al., 2019). Mas os baixos coeficientes de determinação obtidos com esses modelos não nos permitem perder de vista que índices de vegetação são primariamente indicadores para medir a verdura e o vigor do dossel (CHEN et al., 2019), e talvez não as ferramentas mais adequadas para estimativas de biomassa.

5.3 Categorizações

A categorização das áreas em três classes de biomassa (com um terço dos dados cada), seguida da reamostragem e validação cruzada por meio da classificação baseada nos índices de vegetação mostrou resultados um pouco melhores que as correlações e os modelos. No geral, o índice médio de acerto flutua entre 48% e 55% na maioria das simulações. Uma tendência perceptível dentro dessa análise é a de maiores percentuais de iterações corretas nas categorias extremas (1ª e 3ª). A primeira categoria mostrou índice de acerto médio de 59% em todas as classificações, enquanto a terceira quase chega aos 65% médios. A categoria intermediária mal passa dos 30% de acerto médio.

As causas para esses maiores índices de acerto nas categorias extremas podem ser diferentes, com a classe de maior biomassa e área basal justificando esses valores por representar indivíduos arbóreos de maior volume, ao passo que na primeira classe as árvores menores compensem essa diferença de tamanho com uma maior população total. Há ainda de ser considerado o bioma do estudo, em que mais da metade das espécies arbóreas perdem sua folhagem (IBGE, 2012) em partes do

ano, o que pode interferir nas medições orbitais e resultar em resultados mais confiáveis nas classes extremas. A abordagem por classes e categorias pode ser a mais apropriada para um bioma que apresenta tantas diferenças geográficas e climáticas, que resultam em muitas fitofisionomias distintas (SILVA; SANTOS; MORAES, 2014).

Dividir as áreas de floresta em classes de biomassa e área basal, para aferir o nível de acerto que os índices de vegetação atingem, é uma maneira de obter alguma aplicação prática, em um formato que normalmente são apresentados os resultados dos inventários florestais (NAKAI, 2016). Ao alargar os alvos e admitir resultados mais grosseiros, o foco muda da estimativa para a sondagem de biomassa acima do solo, o que pode ser utilizado para identificar e priorizar por zonas áreas florestais que se manterão climaticamente sustentáveis (MAXWELL et al., 2019), como forma de mitigar os efeitos das mudanças climáticas. Mas Sader et al. (1989) já tentaram técnica semelhante, incluindo testando a viabilidade de detecção de classes de idades sucessionais, também sem resultados promissores. Isso indica que uma calibragem baseada no bioma alvo pode ser necessária para que essa ferramenta chegue a níveis maiores de precisão.

5.4 Problemas e possíveis soluções


A despeito de Brown (2002) afirmar que as medições em campo são problemáticas e imprecisas, devido à dificuldade de se obter a variável altura, o sensoriamento remoto ainda não está no estágio de desenvolvimento em que será possível dispensar os inventários tradicionais *in loco*. Como os resultados do presente estudo mostraram, utilizar esses índices de vegetação para estimar biomassa acima do solo de florestas pode não atingir os mesmos resultados em todos os lugares, ao contrário das conclusões de Roy e Ravan (1996), Zheng et al. (2004) e Hentz et al. (2014).

A maior complexidade em estrutura e diversidade de espécies do bioma Mata Atlântica e de sua fitofisionomia Floresta Estacional Semidecidual, na qual metade das espécies arbóreas perdem suas folhas em alguma parte do ano (IBGE, 2012), muito provavelmente interfere com as medidas orbitais dos satélites. Afinal, um hectare pode conter até 300 espécies diferentes (OLIVEIRA; MORI, 1999) e não é possível utilizar modelos específicos para uma espécie, como nas florestas temperadas (BROWN; SCHROEDER, 1999).

Apesar da escolha do período de captura das imagens satelitais se basear no momento em que Sivilisaca (2020) realizou o inventário, essa talvez não tenha sido a melhor janela de tempo. Zhu e Liu (2015) verificaram que há maior correlação dos IVs com biomassa no outono, embora esses resultados tenham que ser contextualizados, dado que o estudo foi realizado em uma floresta temperada com clima continental. Mas como as estações na Floresta Estacional Semidecidual são claramente demarcadas entre invernos de secas prolongadas e verões chuvosos, as conclusões dos autores podem se aplicar nessa área, uma vez que as condições climáticas levam a flutuações sazonais na folhagem dos dois biomas. Pode haver uma clara assinatura espectral, identificável para cada estação, devido a quais espécies perdem as folhas e enfolham no período e as respectivas classes de biomassa dessas árvores. Uma medida que poderia ser adotada para minimizar o efeito das estações nos IVs é a adoção de uma abordagem multianual, com a utilização de composições de imagens de diferentes estações do ano para elevar a acurácia das estimativas (ZHU; LIU, 2015).

Não é negligenciável, porém, a falta de relação direta entre os índices de vegetação espectrais e a biomassa florestal acima do solo, assim como a área basal. Segundo Kuntschik (2004), é necessário conhecimento do comportamento espectral dos alvos para adquirir informações por meio de sensores remotos que registrem a interação com ondas eletromagnéticas. E a folha é, entre as partes da planta, a que contribui mais na reflexão dessa radiação (PONZONI; DISPERATI, 1995; MOREIRA, 2011). Assim, presume-se que os IVs, dada sua origem nas reflectâncias das folhas das árvores, se relacionem de maneira mais estreita com características fenológicas e fisiológicas. E essas características, que notadamente mudam muito ao longo do ano, respondam mais diretamente a outros fatores igualmente sazonais, como fotoperíodo, precipitação e temperatura (Figura 22).

Figura 22 - Ilustração dos fatores que influenciam a fenologia e, por consequência, os índices de vegetação



Todos esses resultados e indicativos parecem dizer que, ainda que o emprego desses índices de vegetação em estimativas de biomassa acima do solo na Floresta Estacional Semidecidual, seja na melhor das hipóteses, ineficiente, eles não podem ser descartados como ferramentas úteis no monitoramento do carbono florestal. Picard, Saint-André e Hanry (2012) dizem que utilizar o sensoriamento remoto para mapear e monitorar as mudanças de estoques de carbono pode ser tanto prático como viável. E a realização de inventários contínuos é uma forma eficiente de analisar a magnitude dos fluxos de carbono entre os ecossistemas e a atmosfera (GRACE, 2004).

O foco dos IVs então precisa mudar para as métricas que valoram esses fluxos, entre elas NEE e NPP (respectivamente *net ecosystem exchange* e *net primary production*, nos termos em inglês). Veroustraete, Patyn e Myneni (1996) e Ichii et al. (2001) apresentaram há mais de 20 anos os caminhos para a utilização de IVs e satélites nas estimativas dessas variáveis e sua associação com o sequestro de carbono por florestas. Essa abordagem nos permite ainda observar a relação da idade das florestas com o carbono atmosférico (ZHOU et al., 2015) e acompanhar essa mudança ao longo do tempo.

A conservação das florestas tropicais, em diferentes estágios de desenvolvimento, é imprescindível para contribuir com o esforço humano de zerar as emissões dos gases do efeito estufa (KAUFFMAN; HUGHES; HEIDER, 2009). O gerenciamento de áreas de florestas para aprimorar o sequestro de carbono é um método promissor para reduzir as concentrações atmosféricas de CO₂ e mitigar as ameaças das mudanças climáticas (HALOFSKY et al., 2018).

6 CONCLUSÃO

De modo geral, as correlações entre os índices de vegetação estudados (NDVI, EVI, RVI e OSAVI) e biomassa vegetal acima do solo para a Floresta Estacional Semidecidual não são significativas, ou quando muito, fracas e negativas. O mesmo se repete em relação à área basal. As estimativas dessas variáveis biométricas a partir desses índices não se mostram eficientes nessa fitofisionomia da Mata Atlântica.

Os modelos de regressão desenvolvidos para prever biomassa e área basal por meio dos índices de vegetação escolhidos igualmente não se provaram confiáveis, com baixos coeficientes de determinação de ajuste. Mas EVI e OSAVI mostram talvez um caminho para melhorias no problema da saturação dos IVs em dosséis florestais densos e diversos.

A categorização do alvo em classes de biomassa e área basal parece ser o caminho mais promissor, mas os níveis de acerto ainda são insatisfatórios, passando pouco dos 55% nas 1ª e 3ª categorias. O emprego dessa técnica como forma de sondagem prévia de áreas a serem inventariadas pode ser viável.

Em linhas gerais, ainda há muita pesquisa a ser feita com relação à utilização dos índices de vegetação para estimar biomassa e carbono acima do solo, antes que se possa considerar a dispensa dos inventários florestais de campo. Os IVs podem ser ferramentas mais adequadas para análise e monitoramento do incremento de carbono ao longo do tempo, através das estimativas dos fluxos e produtividade dos ecossistemas, mudando o foco de sua utilização dos estoques para o sequestro de C.

REFERÊNCIAS

- ALVARES, C. A et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, p. 711-728, 2013.
- AMARO, M. A. **Quantificação do estoque volumétrico de biomassa e de carbono em uma Floresta Estacional Semidecidual no município de Viçosa-MG**. 168 f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2010.
- ASNER, G. P.; MASCARO, J. **Mapping tropical forest carbon: Calibrating plot estimates to a simple LiDAR metric**. *Remote Sensing of Environment*, v. 140, n. 3, p. 614-624, 2014.
- 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.
- BRASIL MATA VIVIA (BMV). **Metodologia Científica de Inventário Florestal e Geração de UCS^{VT} BMV**, Metodologia Base - MCIF 3.0/2020, Goiânia – GO, 32 p., 2020.
- BROWN, A. S. L.; SCHROEDER, P. E. Spatial Patterns of Aboveground Production and Mortality of Woody Biomass for Eastern U.S. Forests. **Wiley**, v. 9, n. 3, p. 968-980, 1999.
- BROWN, S.; LUGO, A. Aboveground biomass estimates for tropical moist forests of the Brazilian Amazon. **Interciencia**, Caracas, v. 17, n. 1, p. 8-18, 1992.
- BROWN, S., LUGO, A., CHAPMAN, J. Biomass of tropical tree plantations and its implications for the global carbon budget. **Canadian Journal of Forestry Research**, v.16, p. 390-394, 1986.
- BROWN, S. Estimating biomass and biomass changing of tropical forests a primer. **FAO Forestry Paper**, Rome, n. 134, p. 1-55, 1997.
- BROWN, S. Measuring carbon in forests: Current status and future challenges. **Environmental Pollution**, London, v. 116, n. 3, p. 363-372, 2002.
- CAVALLET, L. E; PAULA, E. V. Estimativa de sequestro de carbono da biomassa aérea como indicador de sustentabilidade em decorrência da adequação da área de preservação permanente na sub-bacia do rio pequeno (Antonina - PR). **SciELO**, Paraná, v. 5, n. 8, p. 1-13, 2007.
- CENAMO, M. C. et al. Guia sobre Projetos REDD+ na América Latina. 96p., **Manaus, Brasil**, 2010.
- CHAO, Q.; FENG, A. Scientific basis of climate change and its response. **Global Energy Interconnection**. Development and Cooperation Organization, v. 1, n. 4, p. 420-427, 2018.
- CHAVE, J. et al. Tree allometry and improved estimation of carbon stocks and balance in tropical forests. **Oecologia**, Germany, v. 145, n. 1, p. 87-99, 2005.

CHEN, X. et al. Replacing the red band with the red-SWIR band (0.74 pred+ 0.26 pswir) can reduce the sensitivity of vegetation indices to soil background. **Remote Sensing**, v. 11, n. 7, p. 851, 2019.

CHRYSAFIS, I. et al. Assessing the relationships between growing stock volume and Sentinel-2 imagery in a Mediterranean forest ecosystem. **Remote Sensing Letters**, v. 8, n. 6, p. 508-517, 2017.

COUTINHO, R. P. et al. Estoque de carbono e nitrogênio e emissão de N₂O em diferentes usos do solo na Mata Atlântica. **Pesquisa Agropecuária Brasileira**, Brasília, v. 45, n. 2, p.195-203, 2010.

CRIPPEN, R. E. Calculating the vegetation index faster. **Remote Sensing of Environment**, v. 34, n. 1, p. 71-73, 1990.

CUNHA, A. R.; MARTINS, D. Classificação Climática para os municípios de Botucatu e São Manuel – SP. **Revista Irriga**, Botucatu, v. 14, n. 1, p. 1-11, 2009.

DAS, S.; SINGH, T. P. Correlation analysis between biomass and spectral vegetation indices of forest ecosystem. **International Journal of Engineering Research & Technology**, New York, v. 1, n. 5, p. 1-13, 2012.

DIGGLE, P. J. et al. **Analysis of longitudinal data**, 2^a ed., Oxford University Press, Oxford, 2002.

DIXON, R. K. et al. Carbon pools and flux of global forest ecosystems. **Science**, v. 263, n. 5144, p. 185-189, 1994.

EFRON, B. Bootstrap methods: Another look at the jackknife. **The Annals of Statistics**, v. 7, n. 1, p. 126, 1979.

ESA. Sentinel online. **User Guides Introduction**. 2015 Disponível em: <<https://sentinel.esa.int/web/sentinel/user-guides>>. Acesso em: 28 jan. 2021.

FEARNSIDE, P.M. Consequências do desmatamento da Amazônia. **Scientific American Brasil Especial Biodiversidade**, p. 54-59, 2010.

FERRAZ, A. S. et al. Estimativa do estoque de biomassa em um fragmento florestal usando imagens orbitais. **Rev. Floresta e Ambiente**. Rio de Janeiro, v. 21, n. 3, p. 286-296, 2014.

FERREIRA, A. M. R. et al. Utilização de aeronaves remotamente pilotadas para extração de mosaico georreferenciado multiespectral e modelo digital de elevação de altíssima resolução espacial. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17., 2013. João Pessoa. **Anais...** São José dos Campos: INPE, p. 9308-9315, 2013.

GALINDO-LEAL, C.; CÂMARA, I.G. **Mata Atlântica: biodiversidade, ameaças e perspectivas**. Fundação SOS Mata Atlântica. Conservação Internacional. Belo Horizonte, 472 p., 2005.

GRACE, J. Understanding and managing the global carbon cycle. **Journal of Ecology**, British, v. 92, n. 2, p. 189-202, 2004.

GORELICK, N. et al. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, n. 202, p. 18-27, 2017.

HALOFSKY, J. E. et al. Adapting forest management to climate change: The state of science and applications in Canada and the United States. **Forest Ecology and Management**, v. 421, p. 84-97, 2018.

HANSEN, J. et al. Global Temperature in 2020. **Columbia University**: Communications, New York, 2021. Disponível em: <http://www.columbia.edu/~jeh1/mailings/>. Acesso em: 06 fev., 2021.

HE, Q.; SILLIMAN, B. R. Climate Change, Human Impacts, and Coastal Ecosystems in the Anthropocene. **Current Biology**, v. 29, p. 1021-1035, 2019.

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.

HOUGHTON, J. T. et al. Climate Change 2001: The scientific basis. **Intergovernmental Panel on Climate Change**, 2001.

HOUGHTON, R. A.; UNRUH, J. D.; LEFEBVRE, P. A. Current Land cover in the tropics and its potential for sequestering carbon. **Global Biogeochemical Cycles**, Washington, v. 7, n. 2, p. 305-320, 1993.

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

HUNT Jr., E. R. et al. Estimation of carbon sequestration by combining remote sensing and net ecosystem exchange data for Northern Mixed-Grass prairie and sagebrush-steppe ecosystems. **Environmental Management**, New York, v. 33, supplement 1, p. S432-S44, 2004.

ICHII, K. et al. Comparison of global net primary production trends obtained from satellite-based normalized difference vegetation index and carbon cycle model. **Global biogeochemical cycles**, v. 15, n. 2, p. 351-363, 2001.

IEA. **Global CO₂ emissions in 2019**, IEA, Paris <https://www.iea.org/articles/global-co2-emissions-in-2019>, 2020. Acesso em: 04 jan., 2021.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Manual técnico da vegetação brasileira**. Série Manuais Técnicos em Geociências. 2 ed. Rio de Janeiro: IBGE. n. 1, 271 p., 2012.

IPAM. Instituto de Pesquisa Ambiental da Amazônia. **REDD no Brasil: Um enfoque Amazônico**: Fundamentos, critérios e estruturas institucionais para um regime nacional de Redução de Emissões por Desmatamento e Degradação Florestal - REDD. 3. ed. Brasília: Centro de Gestão e Estudos Estratégicos - CGEE, 160 p., 2011.

IPCC. **Climate change 2007: the physical science basis. Summary for policymakers**. Geneva, Switzerland, 2007.

IPCC. **Summary for Policymakers**. In: Global Warming of 1.5°C. An IPCC Special Report on the impacts of global warming of 1.5°C above pre-industrial levels and related global greenhouse gas emission pathways, in the context of strengthening the global response to the threat of climate change, sustainable development, and efforts to eradicate poverty. World Meteorological Organization, Geneva, Switzerland, 32 p, 2018.

IPCC. **Refinement to the 2006 IPCC Guidelines for National Greenhouse Gas Inventories**. Agriculture, Forestry and Other Land Use Report, 2019. Disponível: <https://www.ipcc-nggip.iges.or.jp/public/2019rf/vol4.html>

JAMES, J. N. et al. The effects of forest restoration on ecosystem carbon in western North America: A systematic review. **Forest Ecology and Management**, v. 429, p. 625-641, 2018.

JENSEN, J. R. **Sensoriamento remoto do ambiente**: uma perspectiva em recursos terrestres. Parêntese Editora, 2.ed., 598 p., São José dos Campos, 2009

JOHNSON, R. A.; WICHERN, D. W. **Applied multivariate statistical analysis**. London, UK: Pearson, 2014.

JORGE, L. A. B.; SARTORI, M. S. Uso do solo e análise temporal da ocorrência de vegetação natural na fazenda experimental Edgardia, em Botucatu, SP. **Revista Árvore**, v. 26, p. 585-592, 2002.

KAUFFMAN, J. B.; HUGHES, R. F.; HEIDER, C. Carbon pool and biomass dynamics associated with deforestation, land use, and agricultural abandonment in the neotropics. **Ecological Applications**, v. 19, p. 1211-1222, 2009.

KEITH, H. et al. Contribution of native forests to climate change mitigation – A common approach to carbon accounting that aligns results from environmental-economic accounting with rules for emissions reduction. **Environmental Science and Policy**, v. 93, p. 189-199, 2019.

KUNTSCHIK, G. **Estimativa de biomassa vegetal lenhosa em cerrado por meio de sensoriamento remoto óptico e de radar**. 2004. 155 f. Tese (Doutorado em Ciências), Universidade de São Paulo, São Paulo, 2004.

LACERDA, J. S. et al. **Estimativa de biomassa e carbono em áreas restauradas com plantio de essências nativas**. Publicações da ESALQ, Piracicaba, 23 p., 2009.

LEITE, H. G.; ANDRADE, V. C. L. Importância das variáveis altura dominante e altura total em equações hipsométricas e volumétricas. **Revista Árvore**, v. 27, n. 3, p. 301-310, 2003.

LIRA, S. A.; NETO, A. C. Coeficientes de correlação para variáveis ordinais e dicotômicas derivados do coeficiente linear de Pearson. **Ciência & Engenharia**, v. 15, n. 1/2, p. 45-53, 2006.

LIU, H. Q.; HUETE, A. R. A feedback based modification of the NDVI to minimize canopy background and atmospheric noise. **IEEE Transactions on Geoscience and Remote Sensing**, v. 33, n. 2, p. 457-465, 1995.

LOPES, L. **O Mecanismo de Desenvolvimento Limpo: guia de orientação**. Brasil, 42 f., 2009.

LOVINS, L. H., COHEN, B. **Climate capitalism: Capitalism in the age of climate change**. New York, NY: Hill & Wang, 2011.

LU, D. The potential and challenge of remote sensing-based biomass estimation. **International Journal of Remote Sensing**, v. 27, n. 7, p. 1297-1328, 2006.

MALHI, Y. et al. Introduction: Elevation gradients in the tropics: laboratories for ecosystem ecology and global change research. **Global Change Biology**, v. 16, p. 3171–3175, 2010.

MARQUES FILHO, L. C. **Capitalismo e colapso ambiental**. 2. ed. Campinas: Editora da Unicamp, p. 310, 2016.

MINISTÉRIO DO MEIO AMBIENTE (MMA). **Diretrizes Para A Política de Conservação e Desenvolvimento Sustentável da Mata Atlântica**. São Paulo, 26 p., 2003.

MINISTÉRIO DO MEIO AMBIENTE (MMA). **Estratégia Nacional para Redução das Emissões de Gases de Efeito Estufa Provenientes do Desmatamento e da Degradação Florestal, Conservação dos Estoques de Carbono Florestal, Manejo Sustentável de Florestas e Aumento de Estoques de Carbono Florestal – ENREDD+**. Brasília. 45 p, 2015.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto**. 4.ed. Viçosa: Editora UFV, 422 p., 2011.

NAKAI, E. S. **Quantificação da biomassa e estoque de carbono em diferentes coberturas vegetais por meio de sensoriamento remoto**. 2016. 153 f. Tese (Doutorado) - Curso de Engenharia de Sistemas Agrícolas, Universidade de São Paulo, Piracicaba, 2016.

NASA. **Landsat 8**. 2013. Disponível em: <http://www.nasa.gov/mission_pages/landsat/spacecraft/index.html#.UieDrzY3s0M>. Acesso em: 28 jan 2021.

NELDER, J. A.; WEDDERBURN, R. W. Generalized linear models. **Journal of the Royal Statistical Society Series A**, v.135, n.3, p.370–384, 1972.

NOAA. **Trends in Atmospheric Carbon Dioxide**. Global Monitoring Laboratory, 2021. Disponível em <https://www.esrl.noaa.gov/gmd/ccgg/trends/>, acesso em: 07 de fevereiro de 2021.

NOGUEIRA JUNIOR, L. R. **Estoque de carbono na fitomassa e mudanças os atributos dos solos em diferentes modelos de restauração de Mata Atlântica**. 2010. 96 f. Tese (Doutorado) - Curso de Conservação de Ecossistemas Florestais, Universidade de São Paulo, Piracicaba, 2010.

OLIVEIRA, A. A. D.; MORI, S. A. A central Amazonian terra firme forest. I. High species richness on poor soils. **Biodiversity and Conservation**, v. 8, p. 1219-1244, 1999.

PANDEY, P. C.; ANAND, A.; SRIVASTAVA, P. K. Spatial distribution of mangrove forest species and biomass assessment using field inventory and earth observation hyperspectral data. **Biodiversity and Conservation**, v. 28, n. 8, p. 2143-2162, 2019.

PATEL, N.K.; SAXENA, R.K.; SHIWALKAR, A. Study of fractional vegetation cover using high spectral resolution data. **Journal of the Indian Society of Remote Sensing**, v. 35, p. 73-79, 2007.

PICARD, N.; SAINT-ANDRÉ, L.; HANRY, M. **Manual for building tree volume and biomass allometric equations: from field measurement to prediction**. Rome: FAO, 215p., 2012.

PLOTON, P. et al. Toward a general tropical forest biomass prediction model from very high resolution optical satellite images. **Remote Sensing of Environment**, v. 200, p. 140-153, 2017.

PONZONI, F. J.; DISPERATI, A. A. **Comportamento espectral da vegetação**. INPE: São José dos Campos, 35 p., 1995.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da vegetação**. 2.ed. São José dos Campos: Oficina de Textos, 160p., 2012.

QURESHI, A.; PRAIVA, R. B.; HUSSAIN, S. A. A review of protocols used for assessment of carbon stock in forested landscapes. **Environmental Science & Policy**, Exeter, v. 16, p. 81-89, 2012.

RAMANATHAN, V. et al. **Bending the Curve**: Climate Change Solutions. The Regents of the University of California, Oakland, 2019.

REI, F. C. F.; GONÇALVES, A. F.; SOUZA, L. P. Acordo de Paris: reflexões e desafios para o regime internacional de mudanças climáticas. **Veredas do Direito**, Belo Horizonte, v. 14, n. 29, p. 81-99, 2017.

REZENDE, C. L. et al. From hotspot to hopespot: An opportunity for the Brazilian Atlantic Forest. **Perspectives in Ecology and Conservation**, v. 16, n. 4, p. 208-214, 2018.

RIBEIRO, S. C. et al. Quantificação de biomassa e estimativa de estoque de carbono em uma floresta madura no município de Viçosa, Minas Gerais. **Revista Árvore**. Viçosa – Minas Gerais, v. 33, n. 5, p. 917-926, 2009.

RICHARDSON, A. J.; WIEGAND, C. L. Distinguishing vegetation from soil background information. **Photogrammetric Engineering and Remote Sensing**, v. 43, n. 12, p. 1541-1552, 1977.

ROLIM, S. G. et al. Modelos volumétricos para a Floresta Nacional do Tapirapé-Aquirí, Serra dos Carajás (PA). **Acta Amazonica**, v. 36, n. 1, p. 107-114, 2006.

RONDEAUX, G.; STEVEN, M.; BARET, F. Optimization of soil-adjusted vegetation indices. **Remote Sensing of Environment**, v. 55, n. 2, p. 95-107, 1996.

ROUSE, J.W. et al. Monitoring the vernal advancement of retrogradation of natural vegetation. **NASA/GSFC, type III, final report, greenbelt, MD**, v. 371, 1974.

- ROY, P. S.; RAVAN, S. A. Biomass estimation using satellite remote sensing data - An investigation on possible approaches for natural forest. **Journal of Biosciences**, Bangalore, v. 21, n. 4, p. 535-561, 1996.
- RUGGIERO, J. K. C. **Carbono da biomassa radicular e variabilidade espacial do carbono orgânico em solo sob vegetação de cerrado “stricto sensu”**. 2013. 56 f. Dissertação (Mestrado) - Curso de Ciência Florestal, Universidade Estadual Paulista, Botucatu, 2013.
- SADER, S. A. et al. Tropical forest biomass and successional age class relationships to a vegetation index derived from Landsat TM data. **Remote Sensing of Environment**, v. 28, p. 143-198, 1989.
- SÁNCHEZ-RUIZ, S. et al. Growing stock volume from multi-temporal landsat imagery through google earth engine. **International Journal of Applied Earth Observation and Geoinformation**, v. 83, p. 101913, 2019.
- SCARANO, F. R. Ecosystem-based adaptation to climate change concept, scalability and a role for conservation science. **Perspectives in Ecology and Conservation**, v. 15, p. 65-73, 2017.
- SEDJO, R. A. Forest carbon sequestration: some issues for forest investments. **Discussion Paper**, 01-34. 26p. Washington: Resources for the Future, 2001.
- SEIFFERT, M.E.B. **Mercado de carbono e protocolo de Quioto oportunidades de negócio na busca da sustentabilidade**. Editora Atlas. São Paulo. 2009.
- SILVA, L. G.; SANTOS, S.; MORAES, F. Fragmentação da mata atlântica de interior: análise de paisagem do corredor verde sul-americano e florestas do alto Paraná. **Boletim de Geografia**, Maringá, v. 32, n. 3, p. 61-68, 2014.
- SINHA, S. et al. A review of radar remote sensing for biomass estimation. **International Journal of Environment Science and Technology**. v. 12, n. 5, p. 1779-1792, 2015.
- SIVISACA, D. C. L. **Caracterização estrutural e de biodiversidade de árvores e aves em florestas da cuesta de Botucatu: existe relação entre estoque de carbono e biodiversidade?** 233f. Tese (Doutorado) - Universidade Estadual Paulista (Unesp), Botucatu, 2020.
- SOS MATA ATLÂNTICA/INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS - INPE. **Relatório Anual 2019**. Acesso em: 14 de janeiro de 2021.
- SOTOMAYOR, J. F. M. **Determinação de biomassa aérea em florestas nativas num ambiente agrícola do Estado de São Paulo**. 2013. 129p. Tese (Doutorado) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2013.
- SOUZA, C. R. **Dinâmica de carbono em floresta explorada e em floresta nativa não explorada na Amazônia**. 2012. 129 f. Tese (Doutorado) - Curso de Ciência de Florestas Tropicais, Instituto Nacional de Pesquisas da Amazônia, Manaus, 2012.
- STEFFEN, C. A. Introdução ao sensoriamento remoto. **Divisão de Sensoriamento Remoto. Instituto Nacional de Pesquisas Espaciais–INPE**, São José dos Campos

São– SP, 2016. Disponível em:< <http://www.inpe.br/unidades/cep/atividadescep/educasere/apostila.htm>>. Acesso em: Fevereiro de 2021.

TAMIMINIA, H. et al. Google Earth Engine for geo-big data applications: A meta-analysis and systematic review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 164, p. 152-170, 2020.

THAKUR, T. K. et al. Assessment of biomass and net primary productivity of a dry tropical forest using geospatial technology. **Journal of Forestry Research**, v. 30, n. 1, p. 157-170, 2019.

UNFCCC. **Report of the Conference of the Parties on its fifteenth session**, held in Copenhagen from 7 to 19 December 2009.

VEROUSTRAETE, F.; PATYN, J.; MYNENI, R. B. Estimating net ecosystem exchange of carbon using the normalized difference vegetation index and an ecosystem model. **Remote Sensing of Environment**, v. 58, n. 1, p. 115-130, 1996.

WATSON, R. T. et al. **Land Use, Land-Use Change and Forestry: A Special Report of the IPCC**, Cambridge University Press: Cambridge, 2000.

WATZLAWICK, L. F.; KIRCHNER, F. F.; SANQUETTA, C. R. Estimativa de biomassa e carbono em floresta com Araucária utilizando imagens do satélite IKONOS II. **Ciência Florestal**, Santa Maria, v. 19, n. 2, p. 169-181, 2009.

WESTFALL, P. H. et al. **Multiple Comparisons and Multiple Tests Using the SAS System**, Cary, NC: SAS Institute Inc. 1999.

XIE, Z. et al. Using Landsat observations (1988–2017) and Google Earth Engine to detect vegetation cover changes in rangelands - A first step towards identifying degraded lands for conservation. **Remote Sensing of Environment**, v. 232, p. 111317, 2019.

YING, F. et al. A sensor-invariant atmospheric correction method: Application to Sentinel-2/MSI and Landsat 8/OLI. 2019. Disponível em <https://doi.org/10.31223/osf.io/ps957>, acesso em: 13 de maio de 2021.

ZHENG, D. et al. Estimating aboveground biomass using Landsat 7 ETM+ data across a managed landscape in northern Wisconsin, USA. **Remote Sensing of Environment**, New York, v. 93, n. 3, p. 402-411, 2004.

ZHENG, X. et al. A review of greenhouse gas emission profiles, dynamics, and climate change mitigation efforts across the key climate change players. **Journal of Cleaner Production**, v. 234, p. 1113-1133, 2019.

ZHOU, T. et al. Age-dependent forest carbon sink: Estimation via inverse modeling. **Journal of Geophysical Research: Biogeosciences**, v. 120, n. 12, p. 2473-2492, 2015.

ZHU, X.; LIU, D. Improving forest aboveground biomass estimation using seasonal Landsat NDVI time-series. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 102, p. 222-231, 2015.