



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÕES
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21d/2022/08.19.01.29-TDI

ESTIMATIVA DE BIOMASSA NO CERRADO TOCANTINENSE UTILIZANDO A COMBINAÇÃO DE DADOS ÓPTICOS E DE MICRO-ONDAS

Philippe Souza Simões

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelos Drs. Sidnei João Siqueira
Sant'Anna, e Leila Maria Garcia
Fonseca, aprovada em 17 de agosto
de 2022.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/47F999P>>

INPE
São José dos Campos
2022

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE
Coordenação de Ensino, Pesquisa e Extensão (COEPE)
Divisão de Biblioteca (DIBIB)
CEP 12.227-010
São José dos Campos - SP - Brasil
Tel.:(012) 3208-6923/7348
E-mail: pubtc@inpe.br

CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELECTUAL DO INPE - CEPPII (PORTARIA Nº 176/2018/SEI-INPE):

Presidente:

Dra. Marley Cavalcante de Lima Moscati - Coordenação-Geral de Ciências da Terra (CGCT)

Membros:

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação (CPG)
Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia, Tecnologia e Ciência Espaciais (CGCE)
Dr. Rafael Duarte Coelho dos Santos - Coordenação-Geral de Infraestrutura e Pesquisas Aplicadas (CGIP)
Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon
Clayton Martins Pereira - Divisão de Biblioteca (DIBIB)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)

EDITORAÇÃO ELETRÔNICA:

Ivone Martins - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÕES
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21d/2022/08.19.01.29-TDI

ESTIMATIVA DE BIOMASSA NO CERRADO TOCANTINENSE UTILIZANDO A COMBINAÇÃO DE DADOS ÓPTICOS E DE MICRO-ONDAS

Philippe Souza Simões

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelos Drs. Sidnei João Siqueira
Sant'Anna, e Leila Maria Garcia
Fonseca, aprovada em 17 de agosto
de 2022.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/47F999P>>

INPE
São José dos Campos
2022

Dados Internacionais de Catalogação na Publicação (CIP)

Simões, Philipe Souza.

Si51e Estimativa de biomassa no Cerrado tocantinense utilizando a combinação de dados ópticos e de micro-ondas / Philipe Souza Simões. – São José dos Campos : INPE, 2022.

xxii + 72 p. ; (sid.inpe.br/mtc-m21d/2022/08.19.01.29-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2022.

Orientadores : Drs. Sidnei João Siqueira Sant'Anna, e Leila Maria Garcia Fonseca.

1. Cerrado. 2. Biomassa. 3. Sentinel-1. 4. Sentinel-2. I.Título.

CDU 528.8(213.54)



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÕES

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS
Secretaria de Pós-Graduação - SEPGR

DEFESA FINAL DE DISSERTAÇÃO DE PHILIFE SOUZA SIMÕES
BANCA Nº 222/2022, REG 942227/2020

No dia 17 de agosto de 2022, por teleconferência, o(a) aluno(a) mencionado(a) acima defendeu seu trabalho final (apresentação oral seguida de arguição) perante uma Banca Examinadora, cujos membros estão listados abaixo. O(A) aluno(a) foi APROVADO(A) pela Banca Examinadora, por unanimidade, em cumprimento ao requisito exigido para obtenção do Título de Mestre em Sensoriamento Remoto. O trabalho precisa da incorporação das correções sugeridas pela Banca Examinadora e revisão final pelo(s) orientador(es).

Título: “ESTIMATIVA DE BIOMASSA NO CERRADO TOCANTINENSE UTILIZANDO A COMBINAÇÃO DE DADOS ÓPTICOS E DE MICRO-ONDAS”

Membros da banca:

Dr. Yosio Edemir Shimabukuro – Presidente – INPE
Dr. Sidnei João Siqueira Sant'Anna – Orientador – INPE
Dra. Leila Maria Garcia Fonseca – Orientadora – INPE
Dr. Luiz Eduardo Oliveira e Cruz de Aragão – Membro Interno – INPE
Dr. Hugo do Nascimento Bendini – Membro Interno – INPE
Dr. Ricardo Flores Haidar – Membro Externo – UFT



Documento assinado eletronicamente por **Yosio Edemir Shimabukuro, Pesquisador**, em 23/08/2022, às 17:26 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Hugo do nascimento bendini (E), Usuário Externo**, em 15/09/2022, às 20:38 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Luiz Eduardo Oliveira E Cruz de Aragão, Chefe da Divisão de Observação da Terra e Geoinformática**, em 23/09/2022, às 09:12 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Leila Maria Garcia Fonseca, Tecnologista**, em 23/09/2022, às 13:41 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Sidnei João Siqueira SantAnna, Tecnologista**, em 30/09/2022, às 15:24 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site <https://sei.mcti.gov.br/verifica.html>, informando o código verificador **10311720** e o código CRC **829B71A8**.

Referência: Processo nº 01340.006613/2022-86

SEI nº 10311720

*"I get eaten by the worms
And weird fishes
Picked over by the worms
And weird fishes
Weird fishes
Weird fishes".*

Radiohead – Weird Fishes / Arpeggi

*À minha amada avó, Marilu Miranda de Souza (in memorian) e aos meus pais,
Antônio Vandimar Simões e Carlu Miranda de Souza.*

AGRADECIMENTOS

À Deus, pela sua infinita misericórdia e pela força dada até aqui.

Aos meus pais Antônio Vandimar Simões e Carlu Miranda de Souza, por tudo.

Aos meus orientadores Dr. Sidnei Sant'Anna e Dra. Leila Fonseca pela oportunidade, paciência e orientação.

Aos meus mentores e incentivadores Dr. Ulisses Guimarães, Dr. Pedro Walfir e Dr. João Almiro, pelas aulas, conversas, incentivo e amizade.

Ao Dr. Ricardo Haidar, pela cessão dos dados de Biomassa do Estado do Tocantins e pelas conversas e conselhos.

Aos amigos da PG-SER 2020, em especial ao Bruno, Gabriel, Isadora, Karolina, Maíra, Marionei e Tânia, pelas noites de estudo, conversas produtivas e momentos de descontração.

Aos amigos Dr. Ricardo Dal'Agnol, Dr. Henrique Cassol e Dr. Hugo Bendini, por toda a ajuda a respeito da estimativa de biomassa acima do solo.

Ao Google, pela ferramenta Earth Engine e pelo aumento da cota de armazenamento.

À CAPES pela concessão da bolsa de estudos e ao Instituto Nacional de Pesquisas Espaciais, pela oportunidade desta formação acadêmica.

RESUMO

O Bioma Cerrado, é o segundo maior bioma brasileiro em termos de extensão territorial, que se estende por cerca de 2 milhões de km². Esta área equivale a aproximadamente 23% do território brasileiro, abrangendo 11 estados, e o Distrito Federal. O bioma é considerado um dos hotspots globais para a conservação da biodiversidade, entretanto, a região se encontra sob severas ameaças antrópicas, induzidas e determinadas pelo homem. A quantidade de biomassa e estoques de carbono neste bioma é pouco conhecida, principalmente devido às suas diferenças fitofisionômicas. A estimativa da biomassa é importante para estudar os impactos das mudanças do uso e cobertura da terra e, assim analisar seus efeitos devido às emissões de carbono para subsidiar as políticas de conservação ambiental. Portanto, a presente pesquisa tem como objetivo estimar a biomassa acima do solo em uma região do Cerrado, no estado do Tocantins, utilizando diferentes fontes de dados de sensores ópticos e de micro-ondas. No trabalho, foram utilizados produtos derivados das missões Sentinel-1, Sentinel-2, além do *Canopy Height Model* (CHM, obtido a partir de dados Landsat-8 e *Global Ecosystem Dynamics Investigation* (GEDI), e do mapa de uso e cobertura da terra produzido pelo projeto MapBiomass Brasil. Para avaliar o melhor resultado de estimativa de biomassa em termos da combinação de diferentes dados ópticos e de radar, 6 modelos foram analisados. O modelo que combinou dados Sentinel-1, Sentinel-2 e CHM obteve-se $R^2 = 0,727$, ao passo que os modelos que utilizaram somente dados Sentinel-1 e Sentinel-2, obtiveram respectivamente $R^2 = 0,663$ e $R^2 = 0,717$. O mapa derivado do modelo que combinou dados Sentinel-1, Sentinel-2 e CHM apresentou os menores erros, com RMSE = 73,881 t.ha⁻¹, enquanto o modelo baseado apenas em dados Sentinel-1 teve RMSE = 83,176 t.ha⁻¹ e o baseado unicamente em dados Sentinel-2, igual a 75,273 t.ha⁻¹. Os resultados da pesquisa foram avaliados em relação aos mapas de Baccini et al. (2012), ESA (2020) e Zimbres et al. (2021). Esta pesquisa resultou no primeiro mapa de biomassa acima do solo para o Cerrado Tocantinense com resolução de 10 metros e provou que a combinação entre dados SAR e ópticos pode ser convertida em estimativas de biomassa mais acuradas.

Palavras-chave: Cerrado. Biomassa. Sentinel-1. Sentinel-2.

BIOMASS ESTIMATION IN CERRADO OF TOCANTINS USING OPTICAL AND MICROWAVE DATA COMBINATION

ABSTRACT

The Cerrado Biome is the second largest Brazilian biome in terms of land area, extending over approximately 2 million km². This area is equivalent to approximately 23% of the Brazilian territory, covering 11 states and the Federal District. The biome is considered one of the global hotspots for biodiversity conservation, however, the region is under severe anthropogenic, man-induced, and man-made threats. The amount of biomass and carbon stocks in this biome is poorly known, mainly due to its physiognomic differences. Biomass estimation is important to study the impacts of land use and land cover changes and, thus, to analyze their effects due to carbon emissions to support environmental conservation policies. Therefore, the present research aims to estimate the aboveground biomass in a Cerrado region, in the state of Tocantins, using different sources of data from optical and microwave sensors. In the work, products derived from the Sentinel-1, and Sentinel-2 missions were used, in addition to the Canopy Height Model (CHM, obtained from Landsat-8 and Global Ecosystem Dynamics Investigation (GEDI) data, and the land use and land cover map produced by the MapBiomass Brasil project. To evaluate the best biomass estimation result in terms of the combination of different optical and radar data, 6 models were analyzed. The model that combined Sentinel-1, Sentinel-2, and CHM data obtained $R^2 = 0.727$, while the models that used only Sentinel-1 and Sentinel-2 data, obtained respectively $R^2 = 0.663$ and $R^2 = 0,717$. The map derived from the model combining Sentinel-1, Sentinel-2, and CHM data showed the lowest errors, with RMSE = 73.881 t.ha⁻¹, while the model based on Sentinel-1 data alone had RMSE = 83.176 t.ha⁻¹ and the one based solely on Sentinel-2 data equaled 75.273 t.ha⁻¹. The results of the research were evaluated against the maps of Baccini et al. (2012), ESA (2020) and Zimbres et al. (2021). This research resulted in the first above-ground biomass map for the Cerrado Tocantinense with 10-meter resolution and proved that the combination between SAR and optical data can be converted into more accurate biomass estimation.

Keywords: Cerrado. Biomass. Sentinel-1. Sentinel-2.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 1.1 – Limites do Bioma Cerrado Brasileiro.	2
Figura 3.1 – Localização da Área de Estudo.	17
Figura 3.2 – Precipitação acumulada mensal (mm) para a área de estudo discriminada pelos anos de coleta dos dados de campo e ano de referência para a produção do mapa de BAS.	18
Figura 3.3 – Fluxograma.	20
Figura 3.4 – Esquema de amostragem e dimensões das parcelas. (a) Cerradão / Cerrado Denso e Cerrado <i>Stricto Sensu</i> com parcelas de 20x50 m, (b) Mata Ciliar e Mata de Galeria com parcelas de 10x10 m e (c) Floresta Estacional com parcelas de 20x20 m.	22
Figura 3.5 – Criação de <i>buffers</i> circulares com base nos centroides das parcelas. (a) Cerradão / Cerrado Denso e Cerrado <i>Stricto Sensu</i> com parcelas de 20x50 m, (b) Floresta Estacional com parcelas de 20x20 m e (c) Mata Ciliar com parcelas de 10x10 m.	23
Figura 3.6 – Sobreposição de uma parcela correspondente à fitofisionomia Cerradão / Cerrado Denso para cálculo da mediana a partir das bandas das imagens. A diferença entre as imagens dos períodos seco e chuvoso pode ser melhor observada nas composições coloridas.	35
Figura 4.1 – Gráficos da importância das variáveis em cada modelo.	43
Figura 4.2 – Avaliação da acurácia absoluta dos modelos. na coluna principal, à esquerda, os valores referentes ao erro padrão, RMSE e MAE. Na coluna à direita, valores referentes aos coeficientes de determinação.	45
Figura 4.3 – Gráficos de dispersão dos modelos de predição de biomassa em t.ha ⁻¹	47
Figura 4.4 – Avaliação da acurácia dos modelos por fitofisionomia.	49
Figura 4.5 – Média dos estimadores RMSE e MAE calculados para cada modelo especificados por fitofisionomia.	51
Figura 4.6 – Mapa de BAS do Cerrado Tocantinense para o Ano de 2019.	52

Figura 4.7 – Recortes dos mapas BAS produzidos para a região de Palmas – TO.	54
Figura 4.8 – Magnitude dos estimadores RMSE e MAE.	56
Figura 4.9 – Comparação dos erros dos mapas por fitofisionomia.	57

LISTA DE TABELAS

	<u>Pág.</u>
Tabela 3.1 – Estatísticas descritivas das parcelas.....	25
Tabela 4.1 – Avaliação da acurácia absoluta dos modelos.....	45
Tabela 4.2 – Avaliação da Acurácia dos Modelos Por Fitofisionomia.	48
Tabela 4.3 – Comparação do mapa M6 com os mapas de referência B12, C20 e Z21.	55
Tabela 4.4 – Biomassa acima do solo média dos Mapas M6, B12, C20 e Z21 de estudo em t.ha ⁻¹ , de acordo com os tipos de vegetação do MapBiomass Brasil (Coleção 5) 2019.....	58

LISTA DE QUADROS

	<u>Pág.</u>
Quadro 3.1 – Raio do <i>buffer</i> para espacialização das parcelas.	23
Quadro 3.2 – Características das imagens Sentinel-1 utilizadas.	27
Quadro 3.3 – Índices calculados a partir das imagens Sentinel-1, onde γ_{VV}^0 e γ_{VH}^0 representam o coeficiente de retroespalhamento nas bandas VV e VH, respectivamente.	29
Quadro 3.4 – Atributos de textura calculados a partir das imagens mediana Sentinel-1 para cada período. Para todas as equações, $p(i,j)$ é a enésima entrada normalizada da matriz GLCM; N_g é o número total de níveis de cinza na imagem; e μ_x , μ_y e σ_x , σ_y correspondem, respectivamente, à média e ao desvio padrão das linhas e colunas da matriz GLCM.	30
Quadro 3.5 – Bandas espectrais e resolução espacial dos satélites Sentinel-2.	31
Quadro 3.6 – Características das imagens Sentinel-2A e 2B utilizadas.	32
Quadro 3.7 – Índices de vegetação calculados. Onde, ρ_{NIR} , ρ_{RED} , $\rho_{RED\ EDGE}$ e ρ_{SWIR} correspondem à reflectância nas bandas do infravermelho próximo (NIR), Vermelho (<i>RED</i>), borda do vermelho (<i>RED EDGE 2</i>) e infravermelho de ondas curtas (SWIR), respectivamente. C representa a constante que minimiza o efeito do solo.	33
Quadro 3.8 – Modelos para estimativa de biomassa e seus atributos.	37
Quadro 4.1 – Variáveis selecionadas para serem excluídas dos modelos de predição de BAS. Onde, o prefixo (ex.: VH, B2, RVI) denota a banda ou índice espectral e o sufixo, o período da imagem (seco ou chuvoso).	40
Quadro 4.2 – Variáveis preditoras de cada modelo.	41

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO.....	1
1.1 Objetivo.....	5
1.2 Objetivos específicos.....	5
2 REVISÃO TEÓRICA.....	6
2.1 Estimativa de biomassa.....	6
2.2 Estimativa de BAS Baseada em Sensoriamento Remoto.....	8
2.2.1 Sensoriamento remoto óptico.....	8
2.2.2 Sensoriamento remoto por micro-ondas.....	10
2.2.3 Abordagens que combinam dados radar e ópticos.....	12
2.3 Random forests.....	15
3 METODOLOGIA.....	17
3.1 Caracterização da área de estudo.....	17
3.2 Fluxograma metodológico.....	19
3.3 Conjunto de dados e processamento.....	20
3.3.1 Dados de campo.....	20
3.3.2 MapBiomas Brasil.....	25
3.3.3 Sentinel-1.....	26
3.3.3.1 Processamento das imagens Sentinel-1.....	27
3.3.4 Sentinel-2.....	31
3.3.4.1 Processamento das imagens Sentinel-2.....	32
3.3.5 Canopy Height Model (CHM).....	33
3.3.6 Extração dos valores das Imagens.....	34
3.3.7 Correlação e seleção de variáveis.....	36
3.3.8 Definição dos modelos e Regressão Random Forests.....	36
3.3.9 Análise dos erros.....	38
4 RESULTADOS E DISCUSSÕES.....	40
4.1 Seleção de variáveis.....	40
4.2 Importância relativa das variáveis.....	42
4.3 Avaliação da acurácia dos modelos.....	44

4.3.1	Avaliação da acurácia absoluta.....	44
4.3.2	Avaliação da acurácia por fitofisionomia	48
4.4	Mapa de BAS para o Cerrado tocantinense	51
4.5	Comparação com mapas de referência.....	55
5	CONCLUSÕES E RECOMENDAÇÕES	59
	REFERÊNCIAS BIBLIOGRÁFICAS	61

1 INTRODUÇÃO

O bioma Cerrado é o segundo maior bioma brasileiro em área, ocupando aproximadamente dois milhões de quilômetros quadrados, o que representa cerca de 23% do território nacional. Sua área abrange áreas dos estados de Goiás, Tocantins, Bahia, Maranhão, Mato Grosso, Mato Grosso do Sul, Minas Gerais, Piauí, Paraná, Rondônia, São Paulo e o Distrito Federal. Os limites do bioma Cerrado são apresentados na Figura 1.1 (OLIVEIRA-FILHO; RATTER, 1995; RIBEIRO; WALTER, 1998; OLIVEIRA; MARQUIS, 2002).

A vegetação do Cerrado é formada por diferentes fitofisionomias, composta por formações florestais, savânicas e campestres (RIBEIRO; WALTER, 1998). Em termos fisionômicos, a floresta é representada principalmente por áreas com espécies arbóreas onde existe formação de dossel, contínuo ou não. As savanas caracterizam-se por áreas de gramíneas com árvores e arbustos sem formação de dossel, enquanto o termo campo caracteriza áreas com predomínio de espécies herbáceas e um número reduzido de espécies arbustivas. A flora do bioma Cerrado é bem característica e distinta dos biomas adjacentes, embora tenha espécies compartilhadas com outros biomas (OLIVEIRA-FILHO; RATTER, 1995; RIBEIRO; WALTER, 1998).

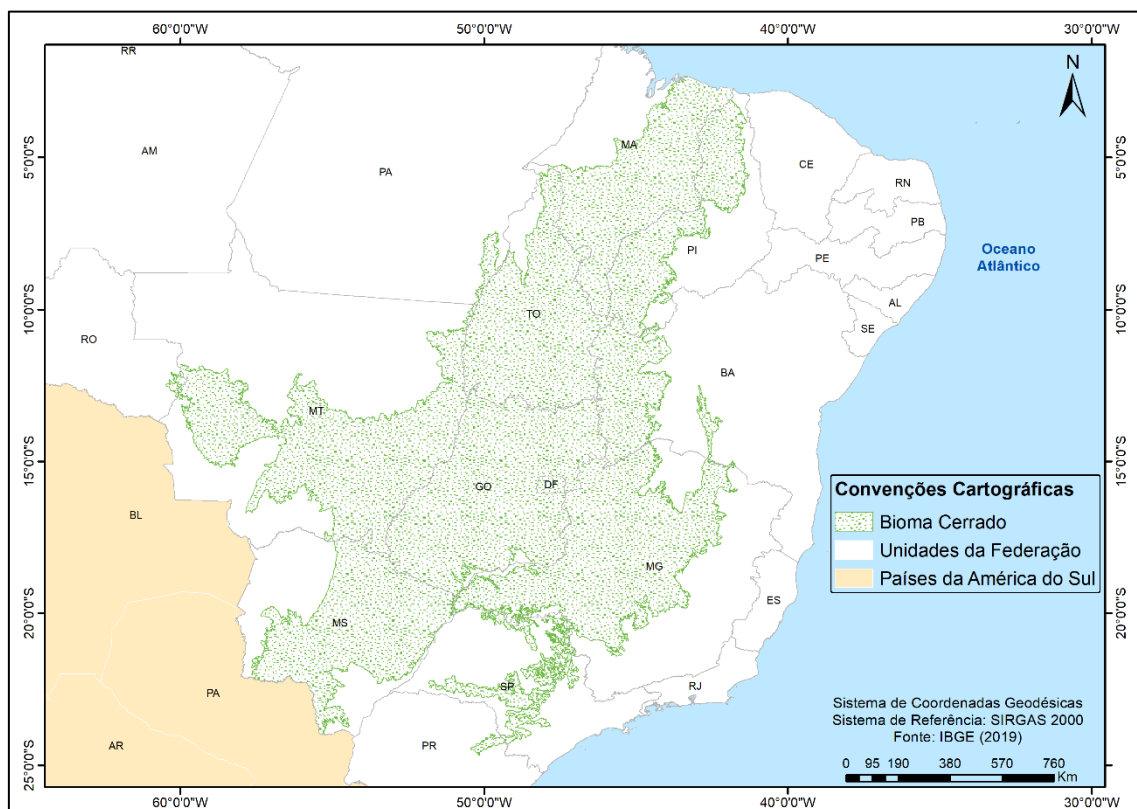
De acordo com Huang et al. (2018), o mapeamento da biomassa florestal acima do solo utilizando dados de observações da Terra tornou-se parte integral de programas de avaliação e monitoramento ambiental devido a sua importância para o entendimento dos impactos do desmatamento e degradação das florestas nas mudanças climáticas (GIBBS et al., 2007; KUMAR; MUTANGA, 2017; MACKAY et al., 2020).

As florestas desempenham um papel dual no ciclo do carbono. Estas atuam como absorvedores de carbono pois, no processo de fotossíntese, as árvores subtraem o carbono presente na atmosfera na forma de dióxido de carbono (CO₂), o convertem em carboidratos e liberam oxigênio de volta à atmosfera. Contudo, as florestas também atuam como fontes de emissão de carbono na atmosfera, resultante dos processos autotróficos e, também, antrópicos de desmatamento, extração seletiva de madeira, e degradação florestal como as

queimadas(VASHUM; JAYAKUMAR, 2012; KUMAR; MUTANGA, 2017; MITCHARD, 2018).

Nesse contexto, a estratégia do REDD+ da Convenção-Quadro das Nações Unidas sobre Mudança do Clima para redução do desmatamento e degradação das florestas, conservação e desenvolvimento sustentável dos países em desenvolvimento (KACHAMBA et al., 2016), tem possibilitado ao Brasil receber pagamentos por resultados de redução de emissões por desmatamento e degradação, assim como fomentado a captação de recursos financeiros para monitoramento ambiental dos biomas brasileiros.

Figura 1.1 – Limites do Bioma Cerrado Brasileiro.



Fonte: Elaborado pelo autor.

Diferentemente do bioma Amazônia, o bioma Cerrado não tem sido foco de atenção no contexto das políticas ambientais brasileiras, mesmo ele já tendo perdido quase 50% de sua vegetação (INPE, 2021). De acordo com o Instituto Chico Mendes de Biodiversidade (ICMBio), somente 8% da área total do bioma é protegida legalmente pela política de unidades de conservação (ICMBIO, 2021). Cunha et al. (2008) apontam que no bioma Cerrado, a degradação

ambiental decorrente da exploração agropecuária, tem modificado consideravelmente as características do ambiente, com excesso de desmatamento, compactação do solo, assoreamento de rios, erosão, perda de biodiversidade, impactando todo o ecossistema.

O mapeamento detalhado da vegetação e a estimativa de emissões de carbono levando em conta os tipos de vegetação do Cerrado é uma atividade complexa devido a sua diversidade de fitofisionomias e ao gradiente de variação na transição entre elas (MIRANDA et al., 2014).

Segundo Kumar e Mutanga (2017) as técnicas de sensoriamento remoto desempenham um papel importante na estimativa de biomassa acima do solo (BAS), uma vez que permite abordagens em larga escala, com custo relativamente baixo em relação a extensivas campanhas de campo, além de permitir o acesso a áreas que presencialmente são inacessíveis.

Além disso, a estimativa de BAS por técnicas de sensoriamento remoto permite a utilização de diferentes tipos de plataformas, sejam elas orbitais ou aerotransportadas, bem como o emprego de variados sensores, tais como ópticos, Radar de Abertura Sintética (*Synthetic Aperture Radar – SAR*) e LiDAR (*Light Detection and Ranging*) (KUMAR et al., 2015; KUMAR; MUTANGA, 2017; LAURIN et al., 2018).

Bao et al. (2019), Bispo et al. (2020), Laurin et al. (2018), Liu et al. (2019) e Wang et al. (2019) analisaram o potencial da combinação dos dados obtidos por diferentes sensores na estimativa da biomassa de diferentes coberturas vegetais. Esta combinação implica em processamentos e análises mais complexos devido ao grande volume de dados e o fato dos sensores ópticos, SAR e LiDAR possuírem características técnicas diferentes, mas com potencial de melhor estimar os diferentes tipos de cobertura vegetal do Cerrado.

Sensores eletro-ópticos, a bordo das plataformas Landsat e Sentinel-2, por exemplo, interagem com as características físico-químicas da vegetação, ao passo que sensores que operam na faixa do espectro das micro-ondas (SAR) interagem com as propriedades geométricas e dielétricas destes alvos. Cada tipo de dado permite a extração de uma série de atributos distintos, como o

cálculo de índices espectrais para dados ópticos, e propriedades polarimétricas e interferométricas para dados SAR polarizados.

As particularidades do bioma Cerrado em termos fisionômicos, como já mencionado, impõem dificuldades para o mapeamento da vegetação nesta região. Desse modo, a combinação entre dados de diferentes fontes para a estimativa de BAS no Cerrado brasileiro pode ser mais bem explorada. Entretanto, a utilização de dados e técnicas em sensoriamento remoto não exclui a necessidade de se ter dados de campo para validar os modelos de estimativa de BAS.

O programa Copernicus da Agência Espacial Europeia (*European Space Agency – ESA*) tornou viável a integração de dados de diferentes sensores em aplicações de observação da Terra com as missões Sentinel 1 e 2, que fornecem dados de observação da Terra com alta qualidade espectral, espacial, radiométrica e temporal sem custos para os usuários. A utilização de dados Sentinel para estimação da BAS vai de encontro aos dois eixos temáticos de serviços do programa Copernicus, sendo eles o monitoramento do uso e cobertura do solo e o fornecimento de informações sobre as mudanças climáticas (COPERNICUS, 2021).

Dado o exposto, pode-se observar que o uso de tecnologias de sensoriamento remoto com a integração de dados de diferentes fontes para a estimativa de BAS no Cerrado pode superar as limitações impostas pela variação da estrutura da vegetação, escassez de trabalhos de campo e o grande gradiente de variação nas transições das fitofisionomias, bem como o grande gradiente latitudinal do bioma (MIRANDA et al., 2014; ROITMAN et al., 2018; BISPO et al., 2020).

Este documento está organizado da seguinte forma: apresentação dos objetivos na Seção 1.1, a revisão teórica (Capítulo 2) introduz alguns conceitos e estudos científicos relacionados com o tema de estimativa de biomassa, seguindo com a metodologia no Capítulo 3. O Capítulo 4 apresenta os resultados e discussões, e finalmente as conclusões são apresentadas no Capítulo 5.

1.1 Objetivo

Dentro deste contexto, este estudo tem como objetivo principal estimar a Biomassa Acima do Solo da região correspondente ao bioma Cerrado no estado do Tocantins, a partir da combinação de dados de sensoriamento remoto obtidos nos espectros óptico e de micro-ondas.

1.2 Objetivos específicos

- i. Selecionar entre os dados utilizados, os melhores preditores para a estimativa da BAS;
- ii. Definir diferentes modelos para estimar a BAS e avaliar a utilização diferentes combinações dos dados ópticos e de radar;
- iii. Produzir um mapa de biomassa acima do solo para o Cerrado tocantinense;
- iv. Avaliar a acurácia das estimativas.

2 REVISÃO TEÓRICA

Este capítulo apresenta alguns conceitos, fundamentos e revisão da literatura relacionadas ao tema do presente estudo.

2.1 Estimativa de biomassa

Para Silveira et al. (2008), biomassa pode ser definida como a massa de matéria de origem biológica, enquanto o termo biomassa florestal está relacionado à biomassa existente na floresta ou apenas na sua fração arbórea. A biomassa florestal é comumente dividida entre a biomassa abaixo do solo e a biomassa acima do solo (do inglês, *Below-Ground Biomass* – BGB e *Above-Ground Biomass* – AGB, respectivamente). Este trabalho é centrado na biomassa acima do solo (BAS), que será referida como BAS.

Basicamente, existem dois métodos para obter a biomassa florestal: método direto e método indireto. O método direto é um método destrutivo, no qual as árvores são cortadas e têm suas partes separadas e pesadas, enquanto o método indireto é um método não destrutivo, no qual podem ser utilizadas equações alométricas e técnicas de sensoriamento remoto para a realização das estimativas (KUMAR et al., 2015; WATZLAWICK et al., 2009).

Silveira (2010) explica que a partir do método direto, a biomassa pode ser determinada porque, a medição real é feita diretamente na biomassa, enquanto o método indireto produz uma estimativa da biomassa. Na estimativa de biomassa, esta é correlacionada com diâmetro, altura e densidade da madeira, utilizando de relações quantitativas ou matemáticas, como razões ou regressões, sem a destruição do material vegetal.

Os métodos diretos para determinação da biomassa florestal são onerosos, uma vez que é necessária a derrubada, separação, secagem e pesagem do material para o desenvolvimento de equações alométricas e, portanto, estes métodos são viáveis apenas em pequenas escalas (QURESHI et al., 2012). Os modelos de regressão para estimativa de biomassa florestal podem utilizar equações alométricas que incluem diferentes variáveis, tais como o diâmetro do tronco, altura e densidade, podendo ser usadas em conjunto ou isoladamente (CHAVE et al., 2005).

Segundo Somogyi et al. (2007), a biomassa pode ser estimada indiretamente de duas formas. Uma forma de estimativa indireta consiste na multiplicação entre um fator de biomassa (em inglês, *Biomass Factor* – BF) e dados de volume de árvores ou talhões, que resulta em um valor convertido (expandido ou reduzido) do volume para estimativa de biomassa. A outra forma é dada pelo ajuste de equações com variáveis dendrométricas utilizando técnicas de regressão.

Para Chave et al. (2005), o uso dos modelos de regressão com equações alométricas são cruciais na estimativa de BAS. O uso de equações de regressão é mais vantajoso em relação aos outros métodos porque não há necessidade de se calcular medidas de volume. Entretanto, a sua desvantagem reside no fato que os inventários florestais, não possuem todas as classes de diâmetro. Assim, apenas os diâmetros de 10 cm ou maiores são medidos, desprezando-se as árvores menores, que podem representar até 30% da biomassa de uma determinada floresta (BROWN, 1997; SILVEIRA et al., 2008).

O procedimento mais comum para estimativa de biomassa florestal é por meio da análise de regressão (PARRESOL, 1999). Desse modo, as equações alométricas de biomassa podem atender os critérios de equações lineares ou não lineares (CASSOL, 2013). Os modelos lineares possuem aplicações simples e podem ser ajustados pelo método dos mínimos quadrados (MMQ), enquanto os modelos não lineares utilizam métodos iterativos para estimar seus parâmetros. Desse modo, a seleção do modelo para aplicação deve ser baseada na experiência do analista, no comportamento das variáveis e recomendações da literatura. (CASSOL, 2013; SILVEIRA et al., 2008).

Os estudos de Fassnach et al. (2021); Forkour et al. (2020); Jacon et al. (2021); Liu et al. (2019); Wang et al. (2019) e Zimbres et al. (2021) mostram uma tendência do uso de métodos baseados em aprendizado de máquina (*Machine Learning*) para estimar a biomassa a partir de dados de sensores remotos.

Métodos como *Random Forests* (RF), *Classification and Regression Trees* (CART) e *Support Vector Machine* (SVM) têm sido usados devido a sua

robustez, praticidade e capacidade para tratar a diversidade e quantidade de dados que podem ser derivados de sensores remotos, sobretudo, quando se combina dados de sensores ópticos e radar (acrônimo para *Radio Detection and Ranging*) (JOSHI et al., 2016).

2.2 Estimativa de BAS Baseada em Sensoriamento Remoto

As tecnologias de sensoriamento remoto, sistemas de informações geográficas (SIG) e fotogrametria constituem, ferramentas importantes para a avaliação de recursos florestais, tais como estimativa de biomassa, volume de madeira e emissões de carbono (DRAKE et al., 2003; PARRESOL, 1999; QURESHI et al., 2012; SILVEIRA et al., 2008). O sensoriamento remoto é uma ciência ampla, de tal modo que para aproveitar seu pleno potencial, é imperativo que o usuário ou analista entenda como a radiação eletromagnética (REM) interage com a atmosfera e os alvos terrestres nas diferentes faixas do espectro eletromagnético (JENSEN, 2009; NOVO, 2008).

2.2.1 Sensoriamento remoto óptico

O sensoriamento remoto óptico passivo é o mais difundido em observação da Terra e têm sido frequentemente utilizado em estudos para estimação da BAS (LU, 2007). Isso é devido, principalmente, à maior oferta de dados de sensores nesta categoria. Em relação aos dados de fonte aberta, destacam-se dados adquiridos por diferentes sensores multiespectrais das missões Landsat (e.g. POWELL et al., 2010), *China-Brazil Earth-Resources Satellites* (CBERS) (e.g. CHEN et al., 2005) e mais recentemente pela missão Sentinel-2 (e.g. CHEN et al., 2019; FASSNACH et al., 2021; GUERINI FILHO et al., 2020).

As características espectrais da vegetação estão relacionadas com os atributos da folha, tais como seus pigmentos, estrutura interna e umidade, afetando diretamente a reflectância e transmitância da REM (JENSEN, 2009). Os sensores ópticos, que dependem das condições de iluminação e atmosféricas, operam no intervalo entre 0,35 μ m e 3,0 μ m.

De acordo com Ponzoni et al. (2012), ao utilizar técnicas de sensoriamento remoto no estudo da vegetação, é necessário compreender a interação da radiação eletromagnética, não somente com as folhas isoladas, mas também

com os diferentes tipos fisionômicos de dosséis. A interação da REM com os dosséis, a exemplo de florestas, formações vegetais arbustivas, herbáceas e culturas agrícolas, apresenta diferenças em relação a interação da REM com folhas isoladas.

Para o estudo da vegetação por sensoriamento remoto óptico, as bandas espectrais mais relevantes são as bandas na faixa do espectro visível, infravermelho próximo e infravermelho médio (JENSEN, 2009; NOVO 2008; PONZONI et al., 2012). A partir delas, é possível caracterizar o comportamento espectral da vegetação e calcular índices espectrais, tais como o Índice de Vegetação da Diferença Normalizada (*Normalized Difference Vegetation Index* – NDVI), o Índice de Vegetação Melhorado (*Enhanced Vegetation Index* – EVI) e o Índice de Vegetação Ajustado para o Solo (*Soil Adjusted Vegetation Index* – SAVI). Por sua vez, os índices espectrais de vegetação podem ser relacionados aos parâmetros biofísicos da vegetação como, por exemplo, a biomassa e o índice de área foliar (LAI) (PONZONI et al., 2012).

Sensores LiDAR também operam na faixa do espectro óptico. Porém, estes sensores são considerados sensores ativos, pois possuem fonte de energia própria e controlada. Diferentemente dos sensores ópticos multiespectrais, sistemas LiDAR são sensores não imageadores e baseiam-se na medição de distâncias. Estes sensores emitem pulsos amplificados da REM em forma de *laser* que interagem com os aspectos físicos dos alvos, através dos fenômenos de espalhamento, absorção, reflexão e fluorescência (DIAZ et al., 2017; JENSEN, 2009).

No estudo da biomassa florestal, a vantagem dos sensores LiDAR consiste na possibilidade do uso de modelos de superfície (Modelo Digital de Superfície – MDS) e do terreno (Modelo Digital do Terreno – MDT) como informações adicionais de altura e volume dos dosséis, uma vez que REM emitida por estes sensores é sensível à altura das árvores (DIAZ et al., 2017; JENSEN, 2009). De posse da altura dos dosséis florestais, pode-se ter mais uma medida que auxilia na estimativa da biomassa florestal.

Atualmente, os dados do LiDAR *Global Ecosystem Dynamics Investigation* (GEDI) a bordo da Estação Espacial Internacional (*International Space Station* – ISS) têm mostrado potencial em estudos dos recursos florestais. Tais dados, bem como dados simulados, têm sido estudados e combinados com outros dados ópticos e SAR, com o objetivo de superar suas limitações em termos de resolução e cobertura espacial (SAARELA et al., 2018; PARDINI et al., 2019; POTAPOV et al., 2021; QI et al., 2019).

Fassnach et al. (2021) correlacionaram valores de referência de biomassa de pastagens, vegetações arbustivas e floresta nativa obtidos em campo e imagens obtidas pelo sensor *Multispectral Instrument* (MSI) a bordo das plataformas Sentinel-2. Além das bandas multiespectrais, os autores também obtiveram altos valores de correlação de *Spearman* na correlação entre os dados de biomassa com métricas texturais derivadas da matriz GLCM (*Grey Level Co-Occurrence Matrix* – GLCM) (HARALICK et al., 1973). Desse modo, os autores puderam definir as variáveis preditoras mais adequadas para realizar a regressão e atingir os objetivos propostos na pesquisa.

Guerini Filho et al. (2020) utilizaram uma imagem Sentinel-2 (MSI) e calcularam os índices NDVI, EVI, Índice de Vegetação da Diferença Normalizada na Borda Vermelha (*Normalized Difference Red Edge Index* – NDREI) e Índice de Reflectância de Senescência das Plantas (*Plant Senescence Reflectance Index* – PSRI) para uma região de pastagem para estimar a biomassa verde e senescente na área de estudo. Os autores utilizaram técnicas de correlação e regressão e dados de campo e os resultados atingiram coeficientes de determinação (R^2) maiores que 0,50, demonstrando o potencial dos índices de vegetação para esta aplicação.

2.2.2 Sensoriamento remoto por micro-ondas

O sensoriamento por micro-ondas permite abordagens muito diferentes em relação ao sensoriamento remoto óptico. Uma das principais vantagens de sensores radar é a possibilidade de imageamento com independência das condições atmosféricas porque, sua faixa de comprimentos de onda tem capacidade de penetração nas nuvens e assim sofre pouco ou nenhum efeito

da atmosfera pois, quanto maior o comprimento de onda, maior é a penetração (WOODHOUSE, 2006; JENSEN, 2009).

No estado da arte do sensoriamento remoto ativo por micro-ondas, tem-se os Radares de Abertura Sintética, com diferentes possibilidades de aquisição de dados em termos de polarização, geometria, órbita (ascendente ou descendente), comprimento de onda e, principalmente, controle de iluminação. Em relação aos sensores ópticos, os sensores SAR possuem menos faixas de frequência, mas com maiores comprimentos de onda, que permitem que a REM interaja com os atributos geométricos e dielétricos, e, assim, seja aplicável em áreas com cobertura de nuvens.

De acordo com Woodhouse et al. (2012) e Woodhouse (2006), o retroespalhamento (*backscattering*) em banda L ou maiores, possuem sensibilidade à biomassa florestal de forma indireta, até um ponto de saturação. O retroespalhamento nas bandas L e P fornecem dados mais adequados para a classificação de florestas tropicais. Contudo, pode-se obter dados igualmente adequados ao se calcular atributos texturais calculados sobre dados nas bandas X e C, o que não invalida os dados de menores comprimentos de onda para o estudo de florestas (VAN DER SANDEN, 1997).

Diversos estudos foram desenvolvidos para estimar BAS de diferentes tipos de vegetação utilizando imagens de radar (BISPO et al., 2014; BOUVET et al., 2018; CASSOL, 2017; COUGO et al., 2015; HUANG et al., 2018 MITCHARD et al., 2009, 2011; NARVAES, 2010;). Nestes estudos, observa-se a ampla utilização de dados do sensor de banda L *Phased Array-type Synthetic Aperture Radar* (PALSAR) a bordo da plataforma *Advanced Land Observing Satellite* (ALOS). Isto é devido à melhor adequação dos dados de banda L para o estudo da biomassa, relacionada a sua maior capacidade de penetração nos dosséis florestais (VAN DER SANDEN, 1997; WOODHOUSE, 2006).

Huang et al. (2018) utilizaram dados ALOS-2/PALSAR-2 e C-SAR (sensor de banda C da missão Sentinel-1) para estimar a mudança da biomassa no tempo em uma região de floresta temperada nos Estados Unidos. Estes autores utilizaram uma adaptação de Cartus et al. (2012) do modelo *Water Cloud*

Model (WCM), proposto por Attema e Ulaby (1978), que é um modelo semi-empírico que pode ser relacionado com a BAS, admitindo que a vegetação é composta por um conjunto de gotas d'água esféricas que são mantidas no lugar pela matéria seca.

Os resultados mostraram que a polarização VH do Sentinel-1 e PALSAR-2 foram mais sensíveis à BAS. Além disso, como já esperado, o dado de banda C atingiu o ponto de saturação em 50 t.ha⁻¹, frente ao valor de 150 t.ha⁻¹ do dado de banda L. Utilizando somente imagens PALSAR-2, os autores usaram modelos de regressão linear múltipla para relacionar diferentes polarizações e atributos polarimétricos como Entropia, Anisotropia, Ângulo Alfa, entre outros. Nesta análise, os autores obtiveram baixos valores de R^2 e altos valores do estimador de erro *Root Mean Square Error* (RMSE), reforçando que os atributos polarimétricos podem obter melhores estimativas de BAS na análise de baixas e altas quantidades de BAS conjuntamente.

Vreugdenhil et al. (2018) reportaram a viabilidade da estimativa de biomassa de diferentes culturas agrícolas, usando índices extraídos a partir de dados Sentinel-1. Além disso, para regiões de florestas, a utilização de índices e outros atributos derivados de imagens Sentinel-1 deve ser estudada, uma vez que os resultados de Kumar et al. (2019) mostram que o retroespalhamento nas polarizações VV e VH possuem baixíssima correlação com a biomassa em florestas subtropicais e temperadas.

2.2.3 Abordagens que combinam dados radar e ópticos

Joshi et al. (2016) apresentam uma revisão sobre as possibilidades e benefícios da combinação de dados SAR e ópticos em estudos relacionados com uso e cobertura do solo. Eles mostram que a fusão de informações de sensores ópticos multiespectrais sobre a atividade fotossintética e informações adquiridas por dados SAR, como estrutura e volume, pode melhorar as estimativas de biomassa.

Embora os sensores ópticos e SAR serem úteis na estimativa de BAS, eles apresentam limitações devido aos problemas de saturação em vegetações densas. Atualmente, os dados Sentinel-1 têm sido uma boa opção em estudos

de recursos florestais, mas apresentam um desafio na estimativa da BAS, devido a indisponibilidade de dados em banda L de forma gratuita e sistemática (NUTHAMMACHOT et al., 2020).

Os métodos que combinam dados SAR e ópticos para mapeamento do uso e cobertura do solo vão desde o simples empilhamento (*stacking*) entre as bandas dos diferentes sensores, até a fusão por métodos baseados em Análise de Principais Componentes (*Principal Components Analysis – PCA*), transformada de Brovey, transformada Wavelet, Fusão de Gram-Schmidt e transformação IHS (*Intensity-Hue-Saturation*). Não há consenso na definição do melhor método de fusão, uma vez que cada método possui suas particulares e é dependente do grau de compatibilidade dos dados de entrada (JOSHI et al., 2016).

Para o estudo dos recursos florestais, a combinação entre dados SAR e dados LiDAR tem potencial de melhorar as estimativas, sobretudo em extensas áreas (LAURIN et al., 2018). Estudos comprovaram que a combinação de dados multisensores permite aprimorar as estimativas da biomassa florestal, sobretudo utilizando dados das missões Sentinel, que possuem facilidade de integração e permitem a utilização de séries temporais (BAO et al., 2019; BISPO et al., 2020; FORKUOR et al., 2020; KHUDINYAN, 2019; LAURIN et al., 2018; LIU et al., 2019; PHAM et al., 2020; WANG et al., 2019).

Forkuor et al. (2020) obtiveram o coeficiente de determinação (R^2) de 0,90 na estimativa de biomassa em uma região de savana no continente africano utilizando a combinação dos dados Sentinel-1 e Sentinel-2. A estimativa da biomassa utilizando os dados separadamente resultou em R^2 de 0,76 utilizando somente o retroespalhamento nas polarizações VV e VH e R^2 de 0,83 utilizando as bandas espectrais, índices e variáveis biofísicas derivados de imagens Sentinel-2.

Laurin et al. (2018) exploraram o uso de séries temporais de imagens Sentinel-1 para a estimar de BAS em florestas de pinheiros, florestas caducifólias e florestas de faia. As análises mostraram que a combinação entre as séries temporais Sentinel-1 e imagens Sentinel-2 causaram um aumento significativo

no R^2 , partindo de 0,52 somente com os dados SAR, para 0,70 com a combinação de dados SAR e ópticos, considerando parcelas com BAS de até 400 t.ha⁻¹.

Para uma região do bioma Cerrado, Bispo et al. (2020) combinaram dados SAR do mosaico global de imagens dos sensores PALSAR e PALSAR-2, transportados pelas plataformas *Advanced Land Observing Satellite* (ALOS) e ALOS-2, imagens ópticas do sensor *Operational Land Imager* (OLI) a bordo da plataforma Landsat-8 e dados LiDAR aerotransportado obtido pelos sensores Optech Orion M300 e Optech ALTM 09SEN243. Os autores relacionaram primeiramente a estimativa da BAS obtida a partir de dados de campo com atributos extraídos dos dados LiDAR, como Modelo de Altura do Dossel (*Canopy Height Model* – CHM), Densidade do Dossel (*Canopy Density* – CD) e Cobertura do Dossel (*Canopy Cover* – CC).

De posse da BAS estimada a partir dos dados LiDAR, os autores utilizaram dados SAR e ópticos empilhados e modelos de regressão baseadas no algoritmo *Random Forests* para criar um mapa de BAS em larga escala, com resolução de 30 metros. Eles obtiveram resultados com R^2 de 0,89 e RMSE de 7,58 t.ha⁻¹ para uma região da Bacia Hidrográfica do Rio Vermelho no Cerrado, na qual as formações de vegetação predominantes são o Cerradão e Floresta Estacional.

O estudo de Zimbres et al. (2021) é uma referência para a presente pesquisa, uma vez que os autores produziram o primeiro mapa de densidade de biomassa acima do solo para o cerrado brasileiro. Eles produziram dois mapas de densidade de biomassa acima do solo com tamanho de *pixel* de 30 metros referente ao ano de 2019 a partir de dados PALSAR e Sentinel-2, um deles baseado no algoritmo RF e outro baseado no algoritmo CART.

Os resultados mostraram que o mapa gerado a partir do RF apresentou R^2 de 0,53, enquanto o modelo derivado do algoritmo CART apresentou R^2 de 0,45. Em relação a estimativa dos erros, estes autores dividiram a análise dos erros de acordo com grandes formações do bioma cerrado, florestais, savânicas e campestres.

Na análise do RMSE ($t \cdot ha^{-1}$), o modelo RF apresentou os valores de 46,36, 18,56 e 27,80 para as formações florestais, savânicas e campestres, respectivamente. Seguindo a mesma sequência, os RMSEs ($t \cdot ha^{-1}$) calculados para o modelo derivado do CART foram de 50,92, 21,41 e 21,77. Os resultados da estimativa de BAS no Cerrado foram consistentes, usando o algoritmo de regressão do RF.

Com base no exposto, as abordagens baseadas na combinação de dados radar e ópticos apresentaram potencial para estimativa de BAS, sobretudo no bioma Cerrado, que possui diversidade fitofisionômica relevante. Desta forma, a combinação das características peculiares a cada uma das fontes de dados aliada à utilização de algoritmos de regressão baseado em aprendizado de máquina, permite identificar e selecionar os atributos mais adequados para contornar as limitações de cada fonte de dados e assim obter o melhor modelo para a estimativa de BAS no bioma Cerrado.

2.3 Random forests

Os tópicos anteriores mostraram que algoritmos de aprendizado de máquina têm se mostrado eficazes e estão sendo vastamente utilizados em análises de mapeamento do uso e cobertura da terra, bem como para a estimativa de Biomassa (BISPO et al., 2020; FORKUOR et al., 2020; ZIMBRES et al., 2021). Dentre as vantagens da utilização dos algoritmos de aprendizagem de máquina, está o fato destes serem não-paramétricos e não considerarem a distribuição original dos dados.

Algoritmos de classificação mais comuns, a exemplo do Máxima Verossimilhança, consideram a distribuição a priori dos dados como Gaussiana, o que não é recomendado para os dados SAR, devido ao efeito *speckle* (BARRETT et al., 2014). O algoritmo *Random Forests* possui a capacidade incomum de performar a partir de milhares de variáveis sem que haja deterioração da acurácia (BREIMAN, 2004). Por este motivo, foi o algoritmo escolhido para ser utilizado nesta pesquisa.

O algoritmo *Random Forests* é um dos principais algoritmos de aprendizagem de máquina, pois é capaz de realizar classificações e regressões com base em

uma coleção de árvores estruturadas $\{h(\mathbf{x}, \Theta_k), k = 1, \dots\}$, onde $h(\mathbf{x}, \Theta_k)$ é o classificador em função de \mathbf{x} e Θ_k . Desse modo, k representa as árvores, Θ_k são vetores aleatórios independentes e igualmente distribuídos e, \mathbf{x} , o vetor dos atributos de entrada (BREIMAN, 2001).

Random Forests para regressão são formados por árvores crescentes que dependem do vetor aleatório Θ , de modo que, o preditor de árvores $h(\mathbf{x}, \Theta_k)$ assume valores numéricos, ao contrário de legendas de classe (no caso de classificações). O preditor *Random Forests* é formado a partir da média sobre as k árvores $\{h(\mathbf{x}, \Theta_k)\}$ (BREIMAN, 2001).

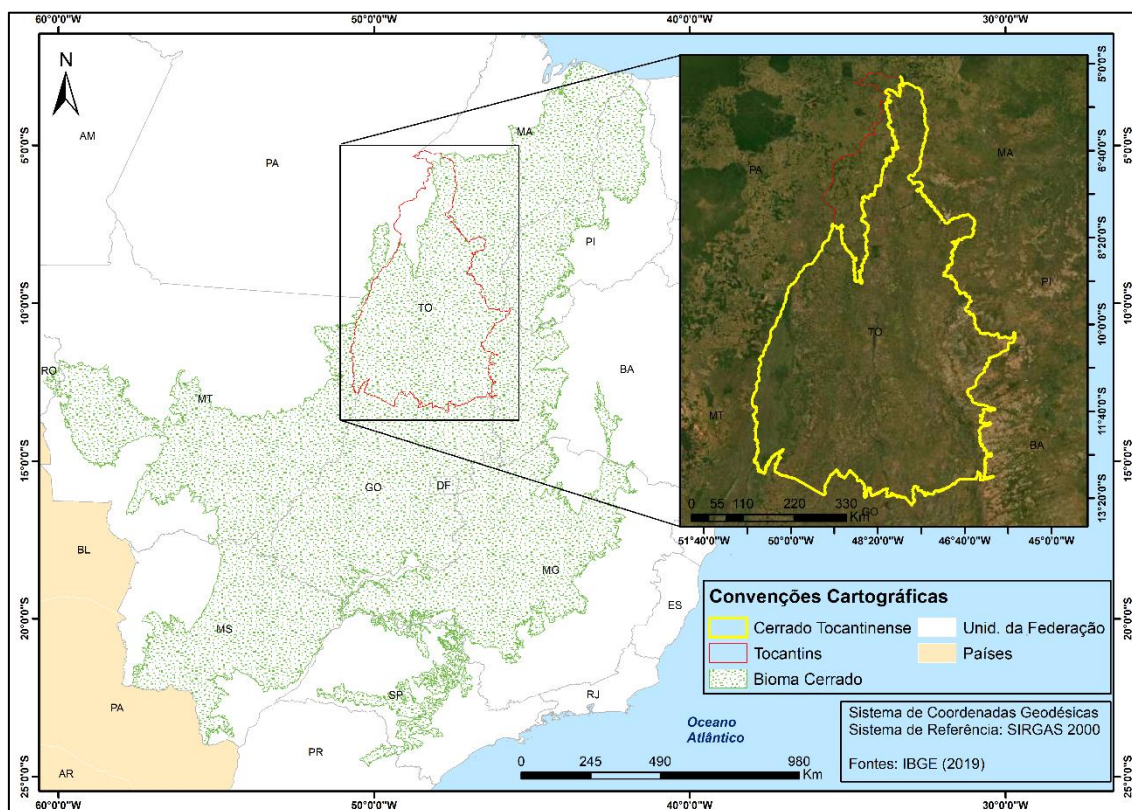
3 METODOLOGIA

Nesta sessão, serão descritos a área de estudo, o fluxograma metodológico, os conjuntos de dados a serem utilizados e os processamentos realizados para obter a estimativa de biomassa.

3.1 Caracterização da área de estudo

A área de estudo é uma região do estado do Tocantins, mais especificamente na extensão de área do estado que corresponde ao bioma Cerrado, que está delimitada pela linha na cor amarela na Figura 3.1. Localizado na região norte do Brasil, o estado do Tocantins possui uma área territorial total de 277.423,630 km² de acordo com Instituto Brasileiro de Geografia e Estatística (IBGE, 2021). No último censo demográfico (2010), o estado do Tocantins contava com uma população de 1.383.445 de habitantes e densidade demográfica de 4,98 hab/km². Em 2020, a população estimada foi de 1.590.248 pessoas (IBGE, 2021).

Figura 3.1 – Localização da Área de Estudo.

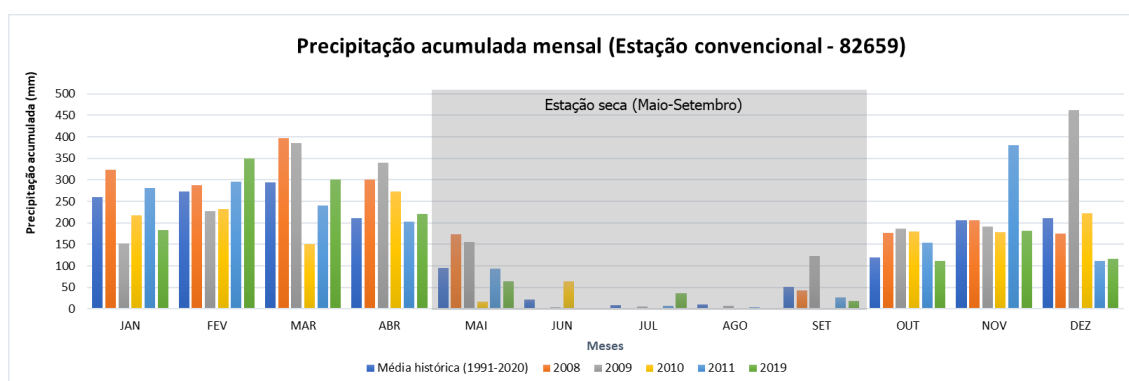


Fonte: Elaborado pelo autor.

A área do Cerrado Tocantinense corresponde a um total de 253.049,144 km². Em termos climáticos, o estado do Tocantins apresenta três tipos climáticos de acordo com a classificação de Thornthwaite: úmido, úmido subúmido e subúmido seco (SOUSA et al., 2012). A precipitação média anual do estado do Tocantins varia de 1.200 a 2.100 mm, e temperatura média anual é de 25,8°C (HAIDAR et al., 2013).

No estado do Tocantins, predomina o clima estacional, com pelo menos cinco meses de seca, que ocorre de maio a setembro (SOUSA et al., 2012). Por este motivo, neste estudo, os dados de sensoriamento remoto serão agrupados em dois períodos, sendo eles: Período Seco e Período Chuvoso. A Figura 3.2 denota a precipitação acumulada entre 1991 e 2020, bem como a precipitação acumulada mensal para o estado do Tocantins nos anos de coleta dos dados de campo e no ano de referência para a produção do mapa de BAS.

Figura 3.2 – Precipitação acumulada mensal (mm) para a área de estudo discriminada pelos anos de coleta dos dados de campo e ano de referência para a produção do mapa de BAS.



Fonte: Elaborado pelo autor.

A Figura 3.2 foi elaborada tendo como base os dados de precipitação fornecidos pela estação convencional 82659 do Instituto Nacional De Meteorologia (INMET), localizada no município de Araguaína, no estado do Tocantins. A análise destes dados confirma o exposto por Sousa et al. (2012) e respalda a definição dos intervalos correspondentes aos períodos seco e chuvoso. Como período seco, definiu-se o intervalo entre 01 e 31 de agosto de

2019, dado que este mês apresentou precipitação média abaixo de 50 milímetros em todos os anos analisados.

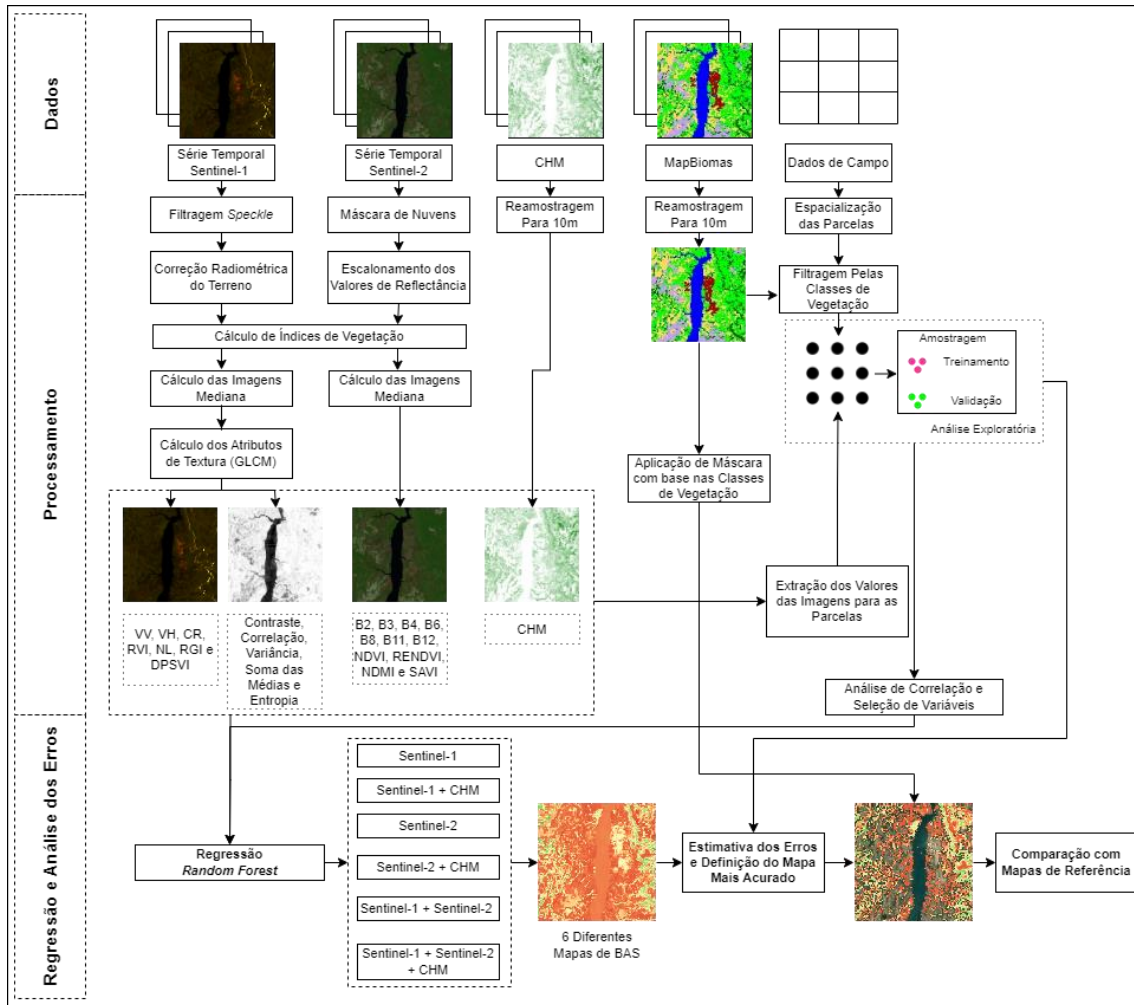
Além disso, sabendo que a vegetação do Cerrado possui variações fenológicas ao longo do ano e pode ter suas atividades fotossintéticas rapidamente ativadas a mínima incidência de chuvas (JACON et al., 2021; PONZONI; SHIMABUKURO; KUPLICH, 2012). No que diz respeito ao período chuvoso, definiu-se o intervalo entre 01 de outubro de 2018 e 30 de abril de 2019.

No que concerne a vegetação, o Cerrado tocantinense compreende formações vegetais de estrutura campestre, savânica e florestal (SOUSA et al., 2012). Em determinadas situações, torna-se difícil a diferenciação entre as fitofisionomias, mesmo *in loco*, a exemplo de Cerrado Denso e Cerradão, comprovando a complexidade de interpretação das fitofisionomias deste Bioma.

3.2 Fluxograma metodológico

O fluxograma metodológico que indica as principais etapas do método é apresentado na Figura 3.3. A seguir, cada uma das etapas do método é descrita em detalhes, de forma lógica e de dependência entre elas. O fluxograma está sequenciado nos grupos Dados, Processamento e Regressão e Análises dos Erros.

Figura 3.3 – Fluxograma.



Fonte: Elaborado pelo autor.

3.3 Conjunto de dados e processamento

Nesta seção, serão apresentados os diferentes tipos de dados e processamentos executados na preparação dos dados para atingir o objetivo desta pesquisa.

3.3.1 Dados de campo

Serão utilizados como referência os dados das parcelas permanentes do Mapeamento das Regiões Fitoecológicas e Inventário Florestal do Estado do Tocantins, elaborado por (HAIDAR et al., 2013). Este documento descreve a metodologia e procedimentos dos trabalhos de campo realizados para calcular a BAS de cada parcela. Para este estudo, foram cedidas um total de 937

parcelas com sua correspondente BAS. As parcelas contemplam as amostras de biomassa fitofisionomias Cerradão / Cerrado Denso (CD), Cerrado *Strictu Sensu* (CE, representando as subdivisões Cerrado Típico, Cerrado Ralo e Cerrado Rupestre), Floresta Estacional (FE), Mata Ciliar (MC) e Mata de Galeria (MG), segundo o sistema de classificação de Ribeiro e Walter (1998). No trabalho de Haidar et al. (2013) pode-se obter mais detalhes sobre os métodos e procedimentos aplicados para o cálculo da BAS do Inventário Florestal do Estado do Tocantins.

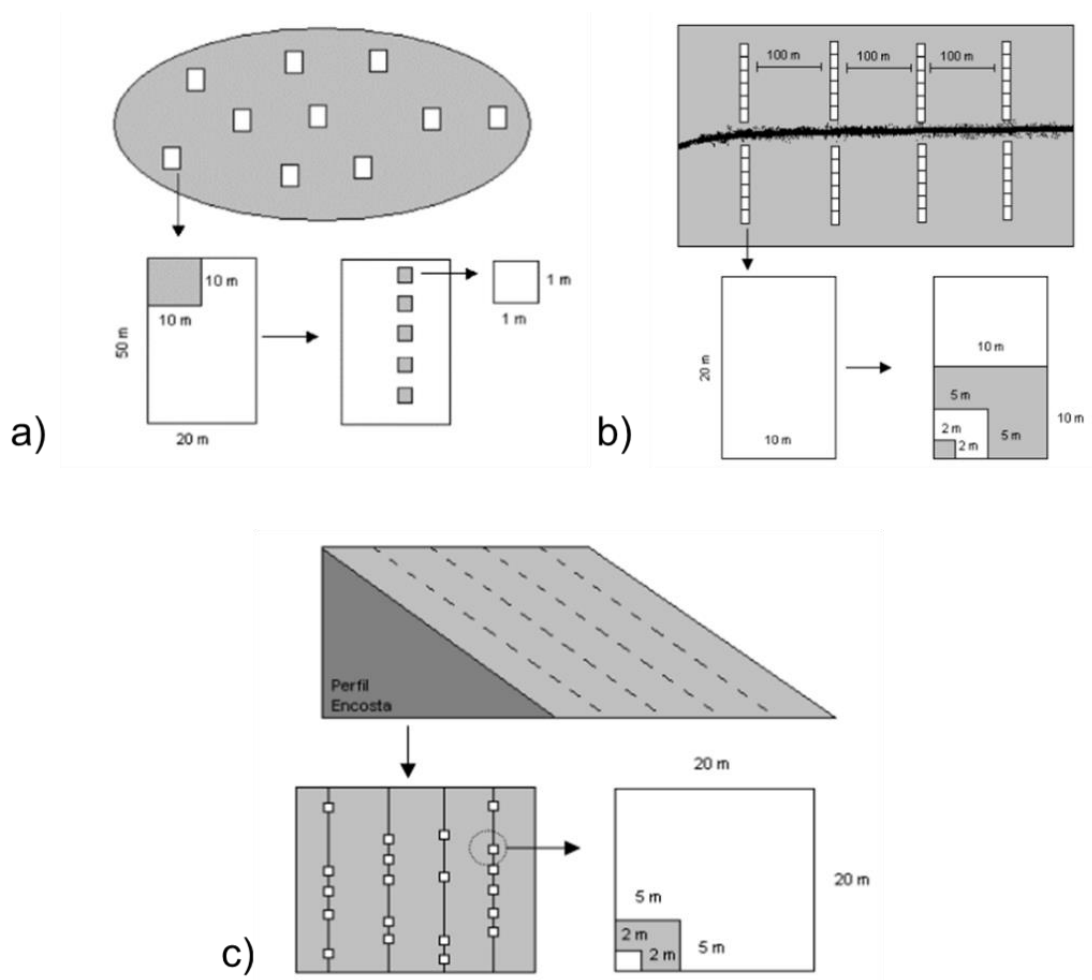
As medições do Inventário Florestal do Estado do Tocantins ocorreram entre os anos de 2008 e 2011. Aquino et al. (2007) mostram que a dinâmica das populações vegetais do Cerrado é lenta, podendo os distúrbios sob plantas de ciclos longos serem detectados somente décadas após os eventos. Este fato, justifica a utilização dos referidos dados de campo, mesmo que estes apresentem defasagem temporal em relação as datas das imagens utilizadas, bem como o ano de análise.

Os dados cedidos correspondem às coordenadas do centroide das parcelas. As parcelas possuem informações sobre a sua BAS e outros atributos como fitofisionomia, clima, relevo e pedologia. Alguns ajustes nos dados foram necessários para que pudessem ser utilizados da forma adequada, tais como:

- Espacialização das parcelas em polígonos de área compatível com a área que foi delimitada em campo; e
- Normalização do valor de BAS da área da parcela para BAS em um (1) hectare.

A determinação das parcelas, foi pautada nos estudos de Felfili et al. (2005), que construíram um manual para parcelas permanentes nos biomas Cerrado e Pantanal. A dimensão das parcelas varia de acordo com a fitofisionomia, conforme é mostrado na Figura 3.4. *Buffers* circulares foram criados para fazer a adequação da espacialização das parcelas em polígonos de área equivalente às das parcelas delimitadas em campo, com base nos centroides das parcelas.

Figura 3.4 – Esquema de amostragem e dimensões das parcelas. (a) Cerradão / Cerrado Denso e Cerrado *Stricto Sensu* com parcelas de 20x50 m, (b) Mata Ciliar e Mata de Galeria com parcelas de 10x10 m e (c) Floresta Estacional com parcelas de 20x20 m.



Fonte: Adaptado de Felfili et al. (2005).

Considerando a área original das parcelas, os raios necessários para criar *buffers* são apresentados no Quadro 3.1.


Quadro 3.1 – Raio do *buffer* para espacialização das parcelas.

Fitofisionomia da Parcela	Raio para criação do <i>Buffer</i> (m)	Área do <i>Buffer</i> (m ²)
Cerradão / Cerrado Denso e Cerrado <i>Strictu Sensu</i>	17,841	1000
Floresta Estacional	11,284	400
Mata Ciliar e Mata de Galeria	5,642	100

Fonte: Elaborado pelo autor.

O procedimento de espacialização das parcelas foi baseado nos trabalhos de Bispo et al., (2020), Forkuor et al. (2020) e Zimbres et al. (2021), que utilizaram o método de *buffers* circulares para mitigar os erros derivados da geolocalização das parcelas e das diferenças entre o tamanho das parcelas e o tamanho dos *pixels* das imagens. A Figura 3.5 ilustra a adequação.

Figura 3.5 – Criação de *buffers* circulares com base nos centroides das parcelas. (a) Cerradão / Cerrado Denso e Cerrado *Strictu Sensu* com parcelas de 20x50 m, (b) Floresta Estacional com parcelas de 20x20 m e (c) Mata Ciliar com parcelas de 10x10 m.



Fonte: Elaborado pelo autor.

Após a espacialização das parcelas, foi realizada uma etapa filtragem de parcelas duplicadas assim, como a análise de intersecção entre as parcelas e os vetores de uso e cobertura da terra, disponibilizados na Coleção 5 do MapBiomas Brasil. A análise teve como objetivo a identificação das parcelas que, no ano de 2019, não mais compreendiam áreas de vegetação nativa.

Portanto, parcelas que em 2019 se interseccionavam com qualquer classe que não correspondesse à vegetação nativa, foram removidas da análise. Assim, o número inicial de parcelas de 937, foi reduzido a 564. Para converter a densidade de biomassa das parcelas para $t.ha^{-1}$, o valor da biomassa foi dividido pela área da parcela em hectare, conforme a Equação 3.1:

$$AGB = \frac{AGB_{parcela} t. ha^{-1}}{\text{Área}_{parcela} ha} \quad (3.1)$$

Esta abordagem se faz necessária porque as parcelas possuem tamanhos diferentes e a área de estudo é extensa. Também, para adequar a metodologia deste trabalho às metodologias difundidas internacionalmente, que tratam a densidade de biomassa em $t.ha^{-1}$. Contudo, este processo resultou em valores insuficientes para que se pudesse ter noção da densidade de biomassa no hectare.

Isto ocorreu devido à presença de árvores muito grandes em parcelas pequenas, sobretudo, nas parcelas correspondentes às fitofisionomias Mata Ciliar e Mata de Galeria. Baseado em Zimbres et al. (2021), um limiar de 300 $t.ha^{-1}$ foi definido como valor máximo de BAS para treinamento e validação dos modelos. Assim, parcelas com BAS acima deste valor foram excluídas.

Como a maior parte das parcelas são de fitofisionomias de Mata Ciliar e Mata de Galeria, o número de parcelas foi reduzido de 564 para 279. Todas as parcelas de Mata de Galeria foram excluídas. A Tabela 3.1 apresenta as estatísticas descritivas das parcelas utilizadas neste estudo.

Tabela 3.1 – Estatísticas descritivas das parcelas.

	Mínimo (t.ha ⁻¹)	Máximo (t.ha ⁻¹)	Média (t.ha ⁻¹)	Mediana (t.ha ⁻¹)	Desvio Padrão (t.ha ⁻¹)	Nº de Parcelas
Cerradão / Cerrado Denso	75,983	296,449	191,605	192,578	65,042	26
Cerrado Strictu Sensu	5,800	85,388	28,232	25,737	14,536	127
Floresta Estacional	64,066	297,842	196,130	204,086	61,002	74
Mata Ciliar	12,417	290,612	155,355	137,815	76,160	49
Total						279

Fonte: Elaborado pelo autor.

3.3.2 MapBiomas Brasil

O projeto Mapbiomas consiste em uma rede colaborativa entre ONGs, *startups* de tecnologia e universidades que tem por objetivo mapear anualmente a cobertura da terra em território brasileiro, para que seja possível, a partir dos dados gerados, promover a conservação ambiental e combate às mudanças climáticas (MAPBIOMAS BRASIL, 2022). O projeto é robusto e atualmente disponibiliza dados de uso e cobertura da terra de 1985 a 2020 na sua Coleção 6.

O mapa de uso e cobertura da terra de 2019 referente a Coleção 5 foi utilizado como referência. A escolha foi baseada no fato dele consistir em uma produção nacional, de larga escala de mapeamento com foco nos biomas brasileiros. Os mapas do projeto Mapbiomas têm sido amplamente utilizados em pesquisas científicas pois são produzidos para todos os biomas brasileiros, utilizando imagens dos satélites Landsat, na resolução espacial de 30 m, adquiridas desde 1985 e reconhecido cientificamente em periódicos internacionais.

Os mapas de uso e cobertura do solo do Mapbiomas são disponibilizados com tamanho de *pixel* de 30 metros. Para compatibilizar o mapa do MapBiomas do estado do Tocantins com as imagens utilizadas neste trabalho, o mapa foi reamostrado para *pixels* com tamanho de 10 x 10 metros.

No processo de reamostragem, foi utilizado o algoritmo do vizinho mais próximo, para que não houvesse alteração nas estatísticas originais do dado, bem como produzir a menor alteração possível nestes. Como era esperado, após a reamostragem, foram observadas sutis alterações nas bordas, contudo, não foram observadas discrepâncias em relação ao dado original que desabonassem esta abordagem.

3.3.3 Sentinel-1

A missão Sentinel-1, no escopo do programa Copernicus da União Europeia, é responsável por adquirir dados observação da Terra a partir de sensores SAR. Atualmente, é utilizada a plataforma Sentinel-1A, após o encerramento da missão Sentinel-1B, até então, satélites gêmeos que transportaram um instrumento que opera em banda C, com comprimento de onda de 5,6 cm (frequência equivalente a 5,405 GHz). O Sentinel-1A foi lançado em abril de 2014 e o Sentinel-1B em abril de 2016. Operando juntos, os sensores podiam prover dados com uma resolução temporal de até 6 dias em certas regiões do planeta (ESA, 2021a, 2021b).

O sensor possui até quatro modos de aquisição de imagens, dentre eles o *Interferometric Wide Swath* (IW), que é o modo de aquisição padrão dos sensores, possuindo uma largura de faixa (*swath*) de 250 km e resolução espacial de 5 x 20 metros em alcance (*range*) e azimute (*azimuth*), respectivamente. Este modo de aquisição permite imageamento nas polarizações VV e VH ou HH e HV (ESA, 2021a, 2021c).

Atualmente, a missão Sentinel-1 é a maior fornecedora de dados SAR com uso gratuito e por este motivo, seus dados têm sido utilizados nas mais diversas aplicações em sensoriamento remoto, tais como mapeamento do uso e cobertura da terra, desastres, mineração, identificação de alvos marítimos e mapeamento de estoques de carbono.

Para compor o conjunto de dados de imagens Sentinel-1, foram selecionadas imagens *Level-1* no formato *Ground Range Detected* (GRD) nas polarizações VV e VH, adquiridas no modo IW. As imagens *Level-1* são imagens no formato intensidade e convertidas para alcance no terreno, sem sua parte complexa

(fase da onda). Desse modo, as imagens GRD disponíveis na plataforma *Google Earth Engine* (GEE) podem ser utilizadas (GORELICK et al., 2017). Esta plataforma fornece acesso rápido e eficiente aos dados Sentinel-1, o que fomenta estudos em regiões extensas e análises multitemporais.

O Quadro 3.2 apresenta o conjunto de imagens utilizadas na pesquisa. Esta coleção de imagens foi obtida através da plataforma GEE e consideram imagens separadas no tempo e espaço, uma vez que para incorporar toda a área de estudo, são necessários 19 *tiles* de imagens Sentinel-1.

Quadro 3.2 – Características das imagens Sentinel-1 utilizadas.

	Período Seco	Período Chuvoso
Sensor	C-band SAR	
Tipo do Produto	GRD	
Tamanho do Pixel (m)	10	
Nº de Imagens	52	328
Data Inicial	01/08/2019	01/10/2018
Data Final	31/08/2019	30/04/2019
Polarizações	VV e VH	
Órbita	Descendente	

Fonte: Elaborado pelo autor.

Como já mencionado anteriormente, os conjuntos de dados de sensores remotos foram divididos em período seco e chuvoso. Esta abordagem permite explorar a sensibilidade da vegetação do Cerrado nestes períodos, enriquecendo as análises e melhorando a predição da BAS (ARANTES et al., 2016; ZIMBRES et al., 2021).

3.3.3.1 Processamento das imagens Sentinel-1

Uma vez selecionadas as imagens Sentinel-1, estas foram pré-processadas para gerar os dados no formato ARD (*Analysis Ready Data*) como proposto por Mullissa et al. (2021), que implementa na plataforma GEE algoritmos de pré-processamento de imagens Sentinel-1. É sabido que dados SAR suportam diferentes cadeias de processamento, a depender do objetivo da aplicação.

Desse modo, o Comitê da Sociedade de Observação da Terra (*Committee on Earth Observation Society*, CEOS) para Dados Prontos para Análise para terra

(*Analysis-Ready-Data for Land*, CARD4L), faz recomendações de etapas de pré-processamento para uma série de aplicações, que incluem filtragem *speckle* e correção radiométrica do terreno (LEWIS et al., 2018; MULLISSA et al., 2021).

Os processamentos consistiram na correção do ruído da borda, filtragem *speckle* multitemporal utilizando o filtro de Lee de janela 9 x 9 (DI MARTINO et al., 2014; MULLISSA et al., 2020). Na sequência, foi realizada a correção radiométrica do terreno, tendo em vista a mitigação de distorções radiométricas derivadas gradiente topográfico do estado do Tocantins (SMALL, 2011).

Para isto, foi utilizado o Modelo Digital de Elevação *Shuttle Radar Topography Mission* (SRTM) GL1 de 3 arcos de segundo. Obrigatoriamente, ao performar a correção radiométrica do terreno na estrutura de Mullissa et al. (2021), os dados de saída possuem coeficiente de retroespalhamento Gamma 0 (γ^0). Por fim, as imagens foram exportadas com tamanho de *pixels* de 10 metros e coeficiente de retroespalhamento em formato linear.

Posteriormente, os índices indicados no Quadro 3.3, foram calculados para realçar as informações contidas nas diferentes polarizações das imagens SAR. O Quadro 3.3 apresenta todos os atributos calculados para cada imagem nos diferentes períodos.

Calculados os índices do Quadro 3.3, a série temporal dos períodos seco e chuvoso foram reduzidas a um mosaico temporal a partir da mediana dos *pixels* das imagens de cada período. Desse modo, agora não mais tendo 52 e 328 imagens para cada período, mas apenas uma. Cada imagem é composta por 7 bandas de atributos, sendo elas, VV, VH, CR, RVI, NL, RGI e DPSVI.

Quadro 3.3 – Índices calculados a partir das imagens Sentinel-1, onde γ_{VV}^0 e γ_{VH}^0 representam o coeficiente de retroespalhamento nas bandas VV e VH, respectivamente.

Índice	Equação	Referência	Nº da Equação
Cross Ratio (CR)	$CR = \frac{\gamma_{VH}^0}{\gamma_{VV}^0}$	(PALOSCIA et al., 1999)	(3.2)
Radar Vegetation Index (RVI)	$RVI = \frac{4 * \gamma_{VH}^0}{\gamma_{VV}^0 + \gamma_{VH}^0}$	(NASIRZADEHDIZAJI et al., 2019)	(3.3)
Normalization Ratio (NL)	$NL = \frac{\gamma_{VV}^0 * \gamma_{VH}^0}{\gamma_{VV}^0 + \gamma_{VH}^0}$	(LU et al., 2011)	(3.4)
Radar Gap Index (RGI)	$RGI = \frac{\gamma_{VV}^0 - \gamma_{VH}^0}{\gamma_{VV}^0 + \gamma_{VH}^0}$	(CASSOL et al., 2019)	(3.5)
Dual Polarization SAR Vegetation Index (DPSVI)	$DPSVI = \frac{\gamma_{VH}^0 * [(\gamma_{VVmax}^0 * \gamma_{VH}^0) - (\gamma_{VV}^0 * \gamma_{VH}^0) + (\gamma_{VV}^0)^2] + ((\gamma_{VVmax}^0 * \gamma_{VV}^0) - (\gamma_{VV}^0)^2) + (\gamma_{VH}^0 * \gamma_{VV}^0)}{\sqrt{2} * \gamma_{VV}^0}$	(PERIASAMY, 2018)	(3.6)

Fonte: Elaborado pelo autor.

Além destes índices, foram calculados os atributos de textura (GLCM) descritos em Haralick et al. (1973), que, segundo Khudinyan (2019) e Kuplich et al. (2005), apresentaram bons resultados para estimativa de BAS. Os atributos de textura foram calculados a partir do mosaico temporal de cada período, cujas equações são apresentadas no Quadro 3.4.

Quadro 3.4 – Atributos de textura calculados a partir do mosaico temporal Sentinel-1 para cada período. Para todas as equações, $p(i, j)$ é a n ésima entrada normalizada da matriz GLCM; N_g é o número total de níveis de cinza na imagem; e $\mu_x\mu_y$ e $\sigma_x\sigma_y$ correspondem, respectivamente, à média e ao desvio padrão das linhas e colunas da matriz GLCM.

Atributo	Equação	Descrição	Nº da Equação
Contraste (contrast)	$\sum_{n=0}^{N_g-1} n^2 \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j)$	Mede o contraste.	(3.7)
Correlação (corr)	$\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{ijp(i, j) - \mu_x\mu_y}{\sigma_x\sigma_y}$	Mede a dependência linear dos níveis de cinza em relação aos <i>pixels</i> vizinhos.	(3.8)
Variância (var)	$\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i - u)^2 p(i, j)$	Mede a dispersão (em relação à média) da distribuição do nível de cinza.	(3.9)
Soma das Médias (savg)	$\sum_{i=2}^{2N_g} ip_{x+y} - (i)$	Mede a média da soma dos níveis de cinza da imagem.	(3.10)
Entropia (ent)	$- \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) \log p[(i, j)]$	Mede o grau de desordem entre os <i>pixels</i> da imagem. Ou seja, quando maior o número de níveis de cinza, maior a entropia.	(3.11)

Fonte: Adaptado de Haralick et al. (1973) e Khudinyan (2019).

Tais atributos foram calculados a partir das bandas VV e VH dos mosaicos temporais de cada período. No total, 5 atributos foram calculados: contraste, correlação, variância, somas das médias e entropia. Desta forma, o conjunto de dados gerado a partir das imagens Sentinel-1 consiste em uma imagem, para cada período, com as bandas VV, VH, CR, RVI, NL, RGI e DPSVI e quatro bandas de atributos de textura derivados das imagens VV e VH, para cada período.

3.3.4 Sentinel-2

Os satélites Sentinel-2A e Sentinel-2B foram lançados em junho de 2015 e março de 2017, respectivamente. A missão Sentinel-2 inclui o sensor eletro-óptico MSI, com 13 bandas espectrais variando entre 400 e 2200 nm. A resolução espacial é de 10 metros para quatro bandas, 20 metros para 6 bandas e 60 metros para três bandas (ESA, 2021d). A constelação Sentinel-2 permite um período de revisita de 5 dias (ESA, 2021e).

A disponibilidade de bandas na faixa do visível, *red edge* (borda do vermelho) e infravermelho, permite explorar diferentes índices de vegetação. Os produtos *Level-2A* são imagens corrigidas para reflectância de superfície e ortorretificadas, que estão disponíveis na plataforma GEE. O Quadro 3.5 apresenta as informações sobre as bandas e resolução espacial do sensor MSI a bordo dos satélites Sentinel-2A e 2B.

Quadro 3.5 – Bandas espectrais e resolução espacial dos satélites Sentinel-2.

Nome	Resolução Espacial (m)	Comprimento de Onda (nm)	
		S2A	S2B
B1 (Aerossóis)	60	442,7	442,2
B2 (Azul)	10	492,7	492,3
B3 (Verde)	10	559,8	558,9
B4 (Vermelho)	10	664,6	664,9
B5 (Borda do vermelho 1)	20	704,1	703,8
B6 (Borda do vermelho 2)	20	740,5	739,1
B7 (Borda do vermelho 3)	20	782,8	779,7
B8 (Infravermelho Próximo)	10	832,8	832,9
B8A (Borda do vermelho 4)	20	864,7	864
B9 (Vapor d'água)	60	945,1	943,2
B10 (Cirrus)	60	1373,5	1376,9
B11 (Infravermelho de ondas curtas 1)	20	1613,7	1610,4
B12 (Infravermelho de ondas curtas 2)	20	2202,4	2185,7

Fonte: ESA (2022).

As características das imagens Sentinel-2A e 2B, utilizadas no trabalho, são resumidas no Quadro 3.6. No total, foram utilizadas 2282 imagens Sentinel-2.

Quadro 3.6 – Características das imagens Sentinel-2A e 2B utilizadas.

	Período Seco	Período Chuvoso
Sensor	MSI	
Tipo do Produto	<i>Level-2A</i>	
Tamanho do <i>Pixel</i> (m)	10 / 20 / 60	
N° de Imagens	403	1879
Data Inicial	01/08/2019	01/10/2018
Data Final	31/08/2019	30/04/2019

Fonte: Elaborado pelo autor.

3.3.4.1 Processamento das imagens Sentinel-2

A partir das imagens Sentinel-2 *Level-2A*, foi realizada uma máscara de nuvens utilizando suas bandas de qualidade, e, a conversão do intervalo de valores de reflectância de superfície de 0-10000 para 0-1. Foram calculados diferentes índices de vegetação, apresentados no Quadro 3.7 para cada imagem nos dois períodos de análise. A aquisição e pré-processamento das imagens foram realizadas na plataforma GEE.

Para o cálculo do RENDVI, foi utilizada a banda B6, da mesma forma como Laurin et al. (2018). A constante C do índice SAVI pode assumir três valores distintos: 1, 0,5 e 0,2. Nesta pesquisa, foi utilizado $C = 0,5$, uma vez que a área de estudo abrange densidades altas, médias e baixas de vegetação. Por esse motivo, escolheu-se utilizar o fator referente a densidades médias.

A plataforma GEE permite realizar operações de aritmética de bandas com resoluções espaciais distintas. Portanto, para calcular os mosaicos temporais nos períodos seco e chuvoso, foram selecionadas as bandas B2, B3, B4, B6, B8, B11, B12 e as quatro imagens dos índices de vegetação. Ao final, exportou-se as imagens com tamanho de *pixel* de 10 metros. Portanto, como produto de entrada Sentinel-2 para estimativa da BAS, tem-se dois mosaicos temporais com sete bandas espectrais e quatro índices de vegetação, totalizando onze bandas cada.

Quadro 3.7 – Índices de vegetação calculados. Onde, ρ_{NIR} , ρ_{RED} , $\rho_{RED\ EDGE}$ e ρ_{SWIR} correspondem à reflectância nas bandas do infravermelho próximo (NIR), Vermelho (RED), borda do vermelho (RED EDGE 2) e infravermelho de ondas curtas (SWIR), respectivamente. C representa a constante que minimiza o efeito do solo.

Nome	Equação	Referência	Nº da Equação
Normalized Difference Vegetation Index (NDVI)	$NDVI = \frac{(\rho_{NIR} - \rho_{RED})}{(\rho_{NIR} + \rho_{RED})}$	(ROUSE et al., 1973)	(3.12)
Red Edge Normalized Difference Vegetation Index (RENDVI)	$RENDVI = \frac{(\rho_{NIR} - \rho_{RED\ EDGE})}{(\rho_{NIR} + \rho_{RED\ EDGE})}$	(LAURIN et al., 2018)	(3.13)
Normalized Difference Moisture Index (NDMI)	$NDMI = \frac{(\rho_{NIR} - \rho_{SWIR})}{(\rho_{NIR} + \rho_{SWIR})}$	(BISPO et al., 2020)	(3.14)
Soil Adjusted Vegetation Index (SAVI)	$SAVI = 1 + C * \frac{(\rho_{NIR} - \rho_{RED})}{(\rho_{NIR} + \rho_{RED} + C)}$	(HUETE, 1988)	(3.15)

Fonte: Elaborado pelo autor.

3.3.5 Canopy Height Model (CHM)

Sendo a altura dos indivíduos arbóreos de relevante importância para medidas diretas e indiretas de biomassa acima do solo, o produto CHM, derivado de dados GEDI, foi utilizado. O instrumento GEDI é o primeiro sensor LiDAR a prover dados em alta resolução da estrutura florestal e modelo de superfície a nível global.

O sensor entrou em operação no início de 2019 a bordo da ISS, e tem uma missão programada de dois anos, a missão homônima: GEDI. (GEDI, 2021a). O sensor opera com comprimento de onda de 1064 nm, com 242 pulsos por segundo e uma potência de 10 mJ e *footprints* de 25 metros de diâmetro (GEDI, 2021b).

O produto CHM proposto por Potapov et al. (2021), consiste em um modelo de altura do dossel com resolução vertical de um (1) metro. Ele integra dados GEDI e Landsat 8 para extrapolar as faixas de aquisição dos dados GEDI para todo o globo terrestre, podendo ser aplicado em larga escala. Originalmente, este produto é oferecido em *pixels* de 30 metros.


Contudo, neste trabalho, os *pixels* foram reamostrados para o tamanho 10 metros, tendo em vista a compatibilidade espacial com os demais dados utilizados. O produto está armazenado em 8 *bits* e, portanto, com capacidade para armazenar valores entre 0 e 255. O maior valor de altura do dossel observado na área de estudo foi de 24 metros.

3.3.6 Extração dos valores das Imagens

Nesta etapa, os valores das imagens foram extraídos para o vetor das parcelas banda a banda. Como há parcelas com dimensões superiores ao tamanho padrão dos *pixels* (10 m), foi calculada a mediana dos *pixels* que interseccionam cada parcela. Assim, a mediana calculada, representa o valor de cada banda na parcela, como ilustra a Figura 3.6.

Assim, obteve-se a informação das 57 bandas na mesma tabela de atributos dos dados de campo. A execução desta etapa, permite o cálculo da Correlação entre as variáveis preditoras (57 bandas) e o valor de BAS de cada parcela, conforme será demonstrado no tópico seguinte.

Figura 3.6 – Sobreposição de uma parcela correspondente à fitofisionomia Cerradão / Cerrado Denso para cálculo da mediana a partir das bandas das imagens. A diferença entre as imagens dos períodos seco e chuvoso pode ser melhor observada nas composições coloridas.



Fonte: Elaborado pelo autor.

3.3.7 Correlação e seleção de variáveis

A partir das 57 variáveis preditoras de BAS, foi calculado o coeficiente de correlação (r), em relação a elas mesmas e às amostras de BAS. O coeficiente de correlação linear mensura o grau e a direção da relação linear entre duas variáveis quantitativas (MOORE; MCCABE; CRAIG, 2009). Para isto, utilizou-se o método de Correlação de Pearson.

Para selecionar as variáveis, analisou-se a magnitude dos coeficientes. A correlação r é sempre um número entre -1 e 1. Valores de r próximos de 0, possuem correlação fraca, enquanto valores próximos de -1 e 1, indicam correlação forte. É importante ressaltar que a correlação só descreve a relação se ela for linear. A correlação não descreve relações curvas (MOORE; MCCABE; CRAIG, 2009).

Figueiredo Filho e Da Silva Júnior (2009) apresentam intervalos de magnitude dos coeficientes em que o grau de correlação pode ser classificado em fraco, moderado e forte. Sintetizando informações de Figueiredo Filho e Da Silva Júnior (2009) e Moore, McCabe e Craig (2009), adotou-se $r = \pm 0,7$ como valor que indica forte correlação.

A matriz de correlação foi calculada individualmente para os dados Sentinel-1 e Sentinel-2. Uma terceira matriz foi calculada para os dados Sentinel-1 e Sentinel-2 agrupados. As variáveis preditoras tiveram seus coeficientes de correlação analisados por pares. Assim, variáveis preditoras com r maiores ou iguais a $\pm 0,7$ foram ser excluídas da análise, para reduzir o número de variáveis preditoras com informações redundantes. No caso em que as duas variáveis do par apresentem forte correlação, a variável com maior média absoluta de r em relação a todas as outras variáveis, foi excluída.

3.3.8 Definição dos modelos e Regressão Random Forests

Para a fase de análise da Regressão, seis diferentes modelos para a estimativa BAS foram definidos, como mostra o Quadro 3.8. O objetivo é analisar o desempenho dos modelos para a estimativa da BAS, para derivar o mapa de

BAS mas acurado, bem como, avaliar se a combinação de dados SAR e Ópticos foi ou não benéfica.

Quadro 3.8 – Modelos para estimativa de biomassa e seus atributos.

Nome	Dados	Bandas	Períodos
Modelo 1	Sentinel-1	Coef. de Retroespalhamento, Índices e Atributos de Textura	Seco e Chuvoso
Modelo 2	Sentinel-1 + CHM	Coef. de Retroespalhamento, Índices, Atributos de Textura e CHM	
Modelo 3	Sentinel-2	Reflectância e Índices	
Modelo 4	Sentinel-2 + CHM	Reflectância, Índices e CHM	
Modelo 5	Sentinel-1 + Sentinel-2	Equivalente ao Modelo 1 + Modelo 3	
Modelo 6	Sentinel-1 + Sentinel-2 + CHM	Equivalente ao Modelo 2 + Modelo 4	

Fonte: Elaborado pelo autor.

A Regressão *Random Forest* foi executada para os 6 modelos. Do total de parcelas, 279 parcelas, 191 foram utilizadas como amostras de treinamento (70%) e 88 como amostras de validação (30%). O processo de amostragem foi realizado de forma aleatória. Nesta etapa, foi garantido que as regressões fossem realizadas sempre com as mesmas amostras. A estabilização dos modelos ocorreu em cerca 100 árvores de decisão.

Como complemento à análise, foi observada a importância de cada variável no modelo a partir da Importância de Gini. A importância de Gini é resultado da seleção de “fortes” variáveis, realizada de forma implícita pelo algoritmo RF. A importância de Gini pode ser utilizada como um indicador geral de relevância, uma vez que ela ranqueia os atributos espectrais do modelo a partir de uma pontuação (MENZE et al., 2009).

3.3.9 Análise dos erros

A avaliação da acurácia dos mapas produzidos foi baseada na Análise Exploratória dos erros e no cálculo de dos estimadores RMSE e *Mean Absolute Error* (MAE). Estes estimadores são consolidados e aceitos cientificamente para a avaliação da acurácia de produtos derivados de dados de sensores remotos (CONGALTON; GREEN, 2009). O RMSE e MAE são definidos pelas Equações 3.16 e 3.17:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\Delta y_i)^2}{n}} \quad (3.16)$$

$$MAE = \frac{\sum_{i=1}^n |\Delta y|}{n} \quad (3.17)$$

onde, n representa o número de amostras e y a variável de estudo. O RMSE calcula a raiz quadrática média da diferença (erro) entre os valores observados e preditos. A raiz quadrada é utilizada para compensar o fato que os erros podem assumir valores positivos e negativos. Uma vez que os erros são elevados ao quadrado antes de terem sua raiz calculada, o RMSE está sujeito a ser consideravelmente impactado a qualquer presença de *outliers*. Ao passo que, o MAE calcula o erro absoluto médio, a partir de todos dos erros.

Além disto, buscou-se avaliar os erros de estimação por fitofisionomia. Com base na avaliação dos erros dos mapas produzidos, escolheu-se o mapa mais acurado para a análise seguinte: comparar o melhor mapa produzido, com mapas de BAS que são considerados referência no meio científico.

Como mapas de referência, foram utilizados os mapas produzidos por Baccini et al. (2012), ESA, (2020) e Zimbres et al. (2021). O mapa de Baccini et al. (2012) possui resolução espacial de 500 metros e apresenta a BAS para as florestas tropicais globais. Os autores utilizaram diferentes dados de sensores remotos e de campo dos anos de 2007 a 2010. O ano de referência do mapa é 2010.

O projeto ESA *Climate Change Initiative* (CCI) *Biomass* derivou mapa de BAS global, que está disponível com *pixels* de 100x100 metros. Nesta pesquisa, inclui-se a utilização de dados Sentinel-1, PALSAR-1 e 2 e Envisat. O produto ESA CCI utilizado nesta pesquisa refere-se ao mapa global de BAS referente ao ano de 2018, recortado para a área e estudo.

O mapa de BAS mais aderente ao produzido nesta pesquisa é o de Zimbres et al. (2021), que apresenta um mapa de BAS para todo o Cerrado brasileiro no ano de 2019. Foram utilizados dados PALSAR, PALSAR-2 e Landsat 8, além de dados de campo. O mapa possui resolução espacial de 30 metros, com máscara de uso e cobertura para alvos diferentes de vegetação nativa. Zimbres et al. (2021) produziram dois mapas, com o emprego dos algoritmos RF e CART. Na avaliação dos resultados deste trabalho, foi utilizado o mapa obtido a partir do RF.

Para obter compatibilidade na análise dos mapas, o mapa com maior acurácia produzido nesta pesquisa, foi reamostrado para as mesmas dimensões dos mapas de referência. Assim, assumirá *pixels* de 30 x 30, 100 x 100 e 500 x 500 metros. A comparação se dará em termos de acurácia absoluta e relativa, discriminada pelas fitofisionomias dos dados de campo.

4 RESULTADOS E DISCUSSÕES

Nesta seção, são apresentados os resultados obtidos e discussões.

4.1 Seleção de variáveis

De acordo com o método proposto para seleção de variáveis, variáveis altamente recomendadas na literatura, a exemplo do NDVI, SAVI, NDMI e banda VH, não deveriam ser consideradas na análise. A seguir, no Quadro 4.1, são apresentadas as variáveis que, segundo o modelo, não deveriam ser utilizadas como preditoras de BAS.

Quadro 4.1 – Variáveis selecionadas para serem excluídas dos modelos de predição de BAS. Onde, o prefixo (ex.: VH, B2, RVI) denota a banda ou índice espectral e o sufixo, o período da imagem (seco ou chuvoso).

Sentinel-1	seco	NL_seco CR_seco VV_var_seco VH_savg_seco	VH_seco RVI_seco VV_contrast_seco VH_var_seco	VV_seco VV_savg_seco VH_ent_seco
	chuvoso	NL_chuvoso DPSVI_chuvoso VV_savg_chuvoso VV_var_chuvoso VH_contrast_chuvoso	VH_chuvoso CR_chuvoso VV_contrast_chuvoso VH_ent_chuvoso VH_var_chuvoso	VV_chuvoso RVI_chuvoso VV_corr_chuvoso VH_savg_chuvoso
Sentinel-2	seco	B12_seco B4_seco B6_seco	B2_seco NDVI_seco	B11_seco SAVI_seco
	chuvoso	NDMI_chuvoso B4_chuvoso B3_chuvoso	B12_chuvoso B11_chuvoso B6_chuvoso	NDVI_chuvoso SAVI_chuvoso
Sentinel-1 e Sentinel-2	seco	NL_seco RVI_seco VV_contrast_seco VH_savg_seco B11_seco B4_seco B8_seco	VH_seco CR_seco VV_var_seco VH_contrast_seco B2_seco NDVI_seco	VV_seco VV_savg_seco VH_ent_seco B12_seco B3_seco NDMI_seco
	chuvoso	NL_chuvoso DPSVI_chuvoso VV_savg_chuvoso VV_corr_chuvoso VH_contrast_chuvoso B12_chuvoso B4_chuvoso B8_chuvoso	VH_chuvoso RGI_chuvoso VV_contrast_chuvoso VH_savg_chuvoso VH_var_chuvoso NDVI_chuvoso SAVI_chuvoso	VV_chuvoso RVI_chuvoso VV_var_chuvoso VH_ent_chuvoso NDMI_chuvoso B11_chuvoso B3_chuvoso

Fonte: Elaborado pelo autor.

Este resultado oportunizou, testes empíricos de inserção e remoção destas variáveis nos modelos. Os testes foram realizados diversas vezes, a cada execução da regressão RF, com a finalidade de se atingir os melhores resultados possíveis. O método utilizado para seleção de variáveis se mostrou generalista e ajudou a entender o comportamento das variáveis ao serem trabalhadas de forma combinada. Contudo, ele não foi determinante para a definição dos modelos. No Quadro 4.2, são apresentadas as variáveis que compuseram os modelos finais de predição de BAS.

Quadro 4.2 – Variáveis preditoras de cada modelo.

Modelo	Dados	Variáveis Preditoras			Total
1	S-1	DPSVI_seco RGI_chuvoso VH_contrast_seco VH_corr_chuvoso VV_corr_seco	DPSVI_chuvoso RVI_seco VH_contrast_chuvoso VH_seco VV_ent_seco	RGI_seco RVI_chuvoso VH_corr_seco VH_chuvoso VV_ent_chuvoso	15
2	S-1 + CHM	DPSVI_seco RGI_chuvoso VH_contrast_seco VH_corr_chuvoso VV_corr_seco CHM	DPSVI_chuvoso RVI_seco VH_contrast_chuvoso VH_seco VV_ent_seco	RGI_seco RVI_chuvoso VH_corr_seco VH_chuvoso VV_ent_chuvoso	16
3	S-2	B2_chuvoso B8_chuvoso NDVI_chuvoso SAVI_chuvoso	B3_seco NDMI_seco RENDVI_seco	B8_seco NDVI_seco RENDVI_chuvoso	10
4	S-2 + CHM	B2_chuvoso B8_chuvoso NDVI_chuvoso SAVI_seco	B3_seco NDMI_seco RENDVI_seco SAVI_chuvoso	B8_seco NDVI_seco RENDVI_chuvoso CHM	12
5	S-1 + S-2	B2_chuvoso DPSVI_seco NDVI_chuvoso SAVI_chuvoso VH_ent_chuvoso VH_var_chuvoso VV_ent_chuvoso	B6_seco DPSVI_chuvoso RENDVI_seco VH_seco VH_chuvoso VV_seco VV_savg_seco	B6_chuvoso NDVI_seco RENDVI_chuvoso VH_ent_seco VH_var_seco VV_ent_seco	20
6	S-1 + S-2 + CHM	B2_chuvoso DPSVI_seco RENDVI_chuvoso SAVI_chuvoso VH_ent_chuvoso VV_ent_seco CHM	B6_seco DPSVI_chuvoso RVI_seco VH_seco VH_chuvoso VV_ent_chuvoso	B6_chuvoso RENDVI_seco SAVI_seco VH_ent_seco VH_var_seco VV_savg_seco	19

Fonte: Elaborado pelo autor.

Os modelos foram compostos com diferentes variáveis, em termos espectrais e temporais. A exemplo das bandas VH e VV e índices NDVI e SAVI, utilizados de forma combinada nos períodos seco e chuvoso, à luz do que é proposto por Arantes; Ferreira; Coe, (2016), Khudinyan (2019) e Zimbres et al., (2021), com o objetivo de melhorar a predição de BAS.

4.2 Importância relativa das variáveis

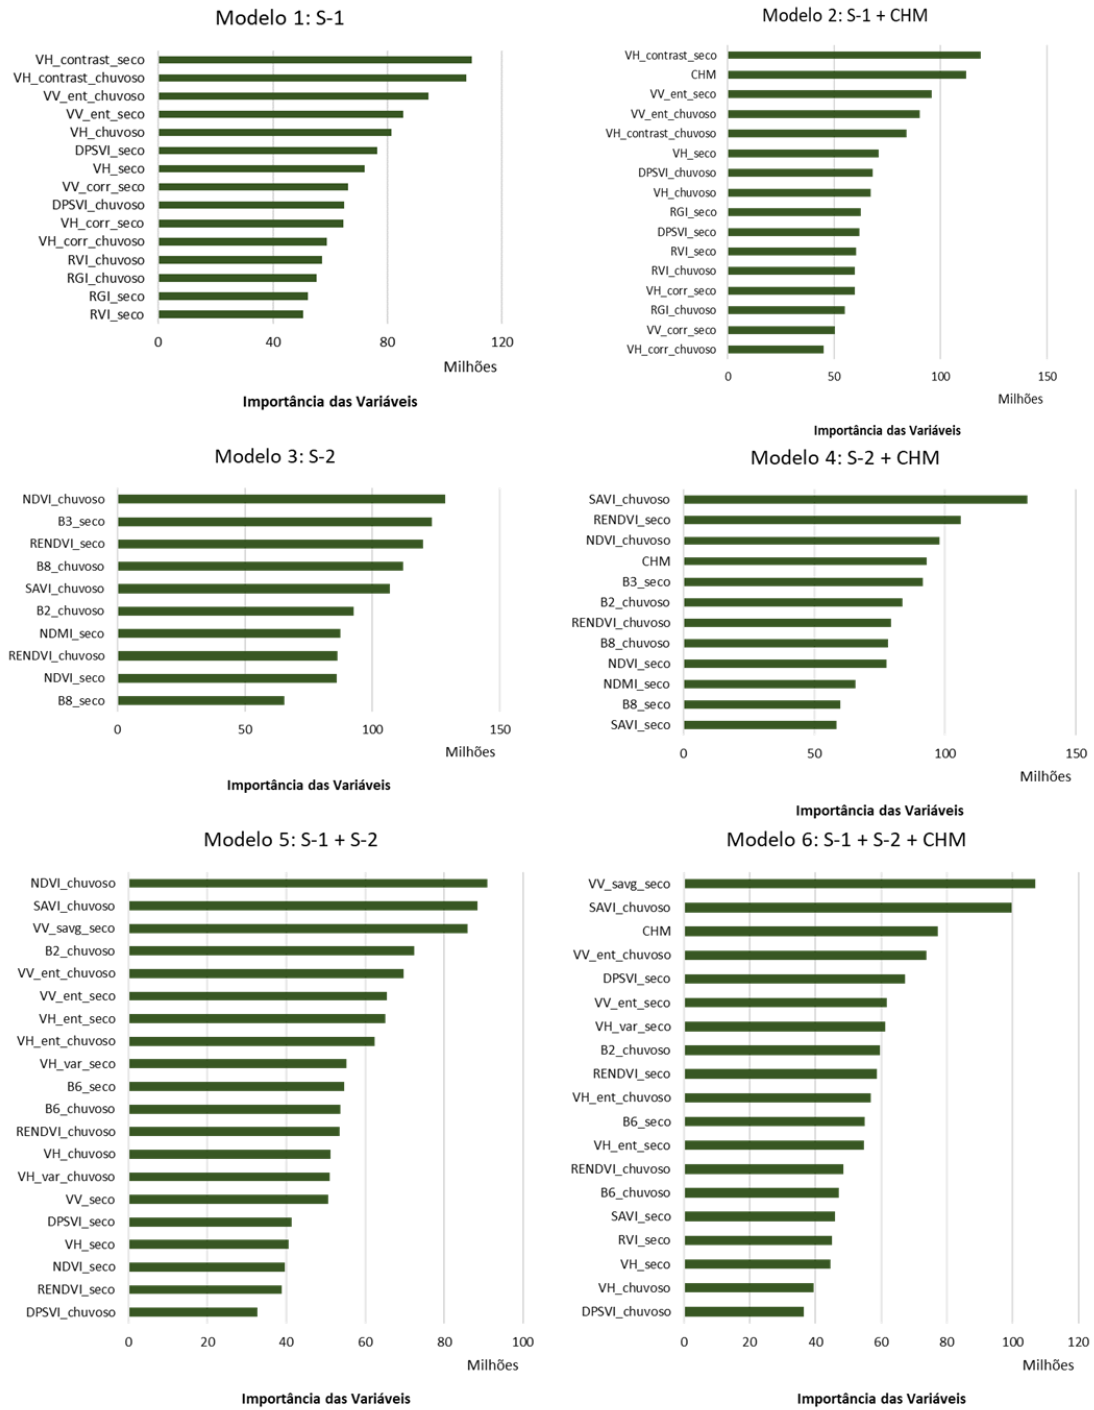
Os gráficos que denotam o ranqueamento de importância das variáveis para cada um dos seis modelos de predição de BAS são apresentados na Figura 4.1. A pontuação para o ranqueamento é baseada no índice de Gini. É importante frisar que, devido a diferença entre os dados dos modelos 1 e 3, por exemplo, ocorrem pontuações com diferentes ordens de grandezas.

Ao analisar os gráficos, se nota que a contribuição de uma mesma variável pode mudar completamente em cada modelo. Nos modelos 1 a 2, atributo de textura contraste, derivado da banda VH no período seco, foi o mais importante para a predição dos modelos. Ademais, observa-se também que a melhor posição no ranqueamento para as bandas de coeficiente de retroespalhamento foi um 5º lugar, para a banda VH no período chuvoso, no modelo 1.

No modelo 2, é observado que o produto CHM foi a segunda variável mais importante para a predição do modelo, reforçando a relevância de atributos dendrométricos para a estimativa de biomassa de forma direta e indireta. Entre os índices de radar calculados, o DPSVI foi o que melhor performou nos modelos 1 e 2.

Para os modelos 3 e 4, os índices de vegetação foram as variáveis que atingiram as maiores pontuações. No modelo 3, primeira posição do ranqueamento foi atribuída ao NDVI no período chuvoso, ao passo que no modelo 4, a mesma posição se deu ao SAVI no período chuvoso. Este resultado mostra que, para o estudo da vegetação, é de suma importância que se disponha de índices de vegetação, tendo em vista a potencialização e aperfeiçoamento das análises.

Figura 4.1 – Gráficos da importância das variáveis em cada modelo.



Fonte: Elaborado pelo autor.

As variáveis mais importantes dos modelos 5 e 6 foram respectivamente o NDVI no período chuvoso e a soma das médias, calculada a partir da banda VV no período seco. Acredita-se que a presença do CHM nos modelos 2, 4 e 6

tenha influenciado a importância de variáveis que outrora, se mostraram mais relevantes. No modelo 6, o CHM obteve a terceira posição no ranqueamento, mais uma vez sendo relevante.

Nos testes empíricos que foram realizados, foi experimentada a utilização do NDVI no modelo 6, contudo, a utilização do NDVI na borda do vermelho (RENDVI) mais contribuiu ao modelo, ainda que não tenha estado no topo do ranqueamento. A análise da importância das variáveis auxilia na compreensão do comportamento dos modelos, mas não pode ser entendida como uma verdade absoluta.

Uma vez que a importância de cada variável é relativa e a pontuação se dá a partir de análise estatística, abordagens que testam diferentes variáveis e diferentes modelos se sobressaem no estudo do fenômeno. Esta análise mostrou que é recomendável experimentar as diferentes combinações e avaliar a acurácia de cada modelo, de modo a obter mais evidências para discussão, conforme o tópico seguinte.

4.3 Avaliação da acurácia dos modelos

No presente tópico, são apresentados os resultados acerca das avaliações de acurácia realizadas a partir dos modelos. Primeiro, são apresentados os resultados que referem a análise dos erros de forma absoluta e em seguida, a análise dos erros discriminada pelas diferentes fitofisionomias das amostras de validação.

4.3.1 Avaliação da acurácia absoluta

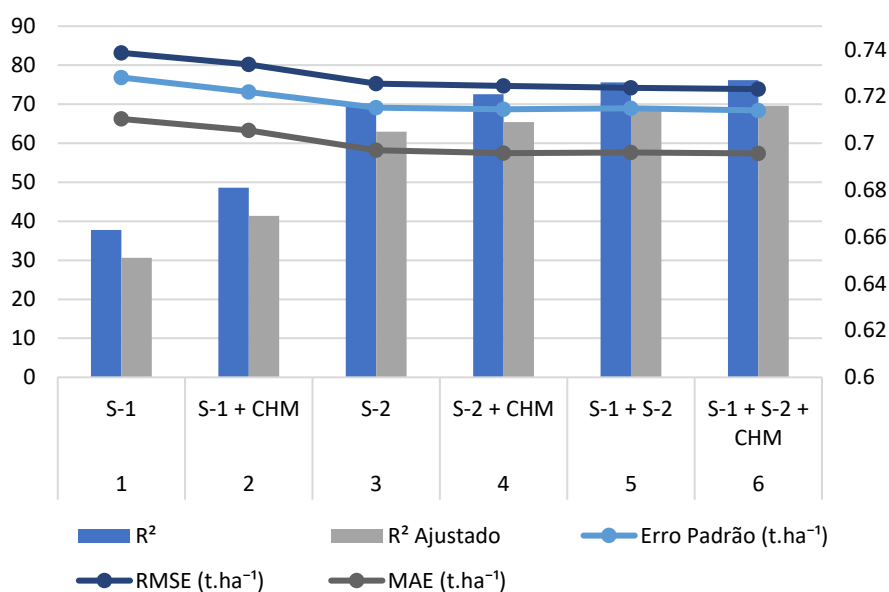
As métricas de acurácia calculadas para os seis modelos de predição de biomassa são apresentadas na Tabela 4.1 e na Figura 4.2. Na tabela, são exibidos o coeficiente de determinação (R^2) e R^2 ajustado, que mitiga o incremento de preditores pouco explicativos no R^2 . São apresentados também, os Erros Padrão a um nível de significância de 5%, e os estimadores RMSE e MAE.

Tabela 4.1 – Avaliação da acurácia absoluta dos modelos.

	Modelo	R^2	R^2 Ajustado	Erro Padrão (t.ha ⁻¹)	RMSE (t.ha ⁻¹)	MAE (t.ha ⁻¹)
1	S-1	0,663	0,651	76,851	83,176	66,236
2	S-1 + CHM	0,681	0,669	73,163	80,163	63,279
3	S-2	0,717	0,705	69,152	75,273	58,226
4	S-2 + CHM	0,721	0,709	68,716	74,671	57,483
5	S-1 + S-2	0,726	0,714	68,977	74,242	57,638
6	S-1 + S-2 + CHM	0,727	0,716	68,415	73,881	57,398

Fonte: Elaborado pelo autor.

Figura 4.2 – Avaliação da acurácia absoluta dos modelos. na coluna principal, à esquerda, os valores referentes ao erro padrão, RMSE e MAE. Na coluna à direita, valores referentes aos coeficientes de determinação.



Fonte: Elaborado pelo autor.

A partir dos coeficientes de determinação calculados, percebe-se que os modelos baseados somente em dados SAR tiveram as piores performances para predição de BAS. Porém, no modelo 2, houve o incremento no R^2 devido a presença do CHM, conforme era esperado. O incremento de 1,8% no valor do R^2 do modelo 2, implica diretamente nos valores de RMSE e MAE

aproximadamente 3 t.ha⁻¹ mais acurados em relação ao modelo 1, ou seja, com erros cerca de 3,5% menores.

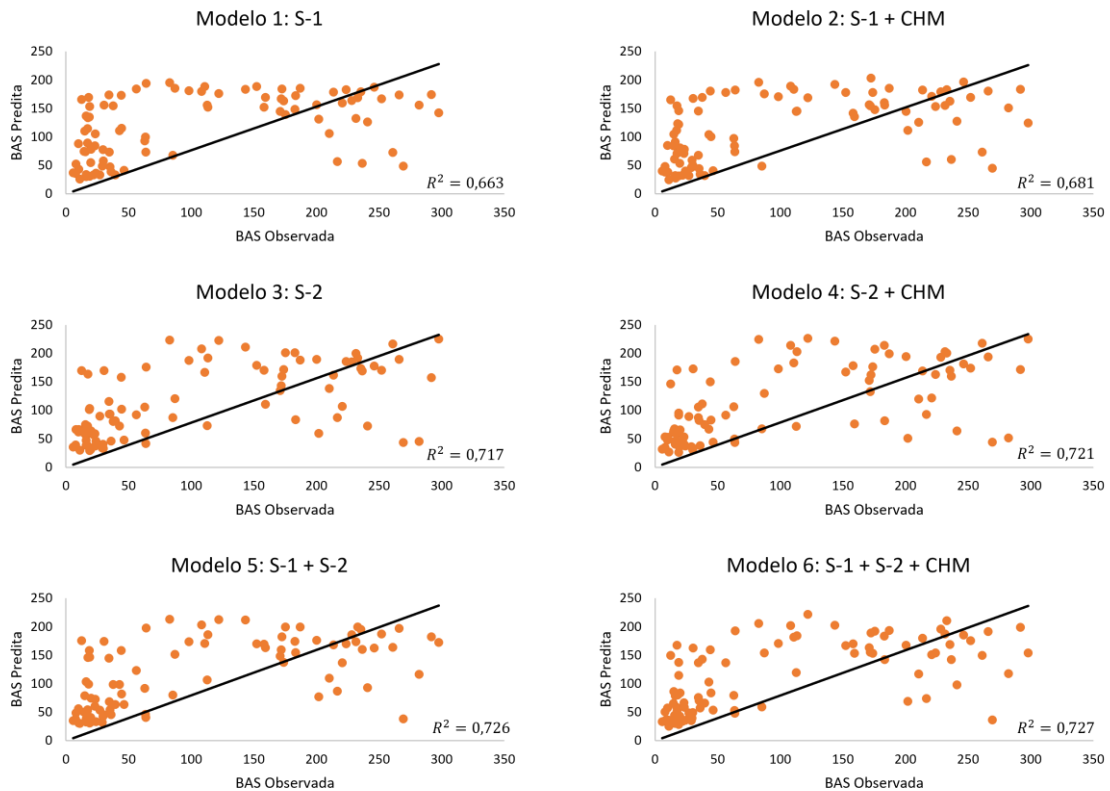
A partir do modelo 3, que utiliza dados ópticos Sentinel-2, se obteve um aumento considerável nos valores de R^2 . O modelo 3 teve R^2 calculado de 0,717 e o modelo 4, devido a adição do CHM, apresentou R^2 0,004 superior. Em termos do erro absoluto, esta fração representou um erro 0,602 t.ha⁻¹ menor pelo RMSE e 0,743 t.ha⁻¹ a partir do MAE.

Em relação ao modelo 2, o modelo 4 atingiu RMSE cerca de 5,5 t.ha⁻¹ inferior. Este resultado mostra que a utilização de dados em amplitude em banda C podem não ser mais efetivos para a estimativa de biomassa em comparação aos dados ópticos. Apesar dos atributos derivados dos dados SAR, à luz de Van Der Sanden (1997), é sabido que na estimativa de biomassa a partir de dados em banda C, a saturação dos valores pode ocorrer por volta de 40 t.ha⁻¹. Desse modo, os modelos que utilizaram apenas dados Sentinel-1, foram diretamente impactados por esta condição.

Os modelos 5 e 6, que combinam dados SAR e ópticos, alcançaram R^2 igual a 0,726 e 0,727, respectivamente. Ao analisar tão somente os números, a diferença é mínima entre eles e o modelo 4. Verificando os valores dos estimadores RMSE e MAE, o modelo 6 culminou no mais baixo RMSE. Assim, o RMSE do modelo 6 foi 0,79 t.ha⁻¹ menor que o do modelo 4 e 0,361 abaixo do modelo 5.

A Figura 4.3 expõe os gráficos de dispersão dos modelos relacionando a biomassa acima do solo predita e observada em t.ha⁻¹.

Figura 4.3 – Gráficos de dispersão dos modelos de predição de biomassa em t.ha⁻¹.



Fonte: Elaborado pelo autor.

Apoiado na análise dos gráficos, é possível perceber que todos os seis modelos são bons preditores de BAS até as proximidades de 50 t.ha⁻¹. A partir de 100 t.ha⁻¹, os modelos 1 e 2 apresentam estabilidade de sobre-estimação, com baixa aderência à reta, possivelmente devido a saturação da informação SAR (JOSHI et al., 2017). Os modelos 3 e 4 apresentam baixa correlação entre 50 e 200 t.ha⁻¹. Todavia, estes modelos apresentam pontos aderentes à reta entre 200 e 250 t.ha⁻¹.

Os modelos 5 e 6, que combinam os dados SAR e ópticos, apresentam um comportamento de sobre-estimação entre 50 e 150 t.ha⁻¹. Contudo, são sensivelmente aderentes à reta em torno de 230 t.ha⁻¹. O comportamento dos gráficos de dispersão desta pesquisa é semelhante aos resultados obtidos por Zimbres et al. (2021) e Bispo et al. (2020), nos quais, é observada alta correlação entre as predições e os valores observados de biomassa no

Cerrado até aproximadamente 50 t.ha⁻¹, ainda que estes autores tenham obtido R^2 iguais a 0,53 e 0,89, respectivamente.

À vista disso, é possível concluir que os modelos 5 e 6 apresentaram menores incertezas na estimativa de BAS. Assim, comprovando que a combinação entre dados SAR e ópticos para a estimativa de BAS pode derivar resultados mais acurados. Estes resultados foram possíveis a partir da obtenção de informações baseadas em características geométricas, dielétricas e biofísicas da vegetação, sobrepondo limitações inerentes a cada tipo de dado.

4.3.2 Avaliação da acurácia por fitofisionomia

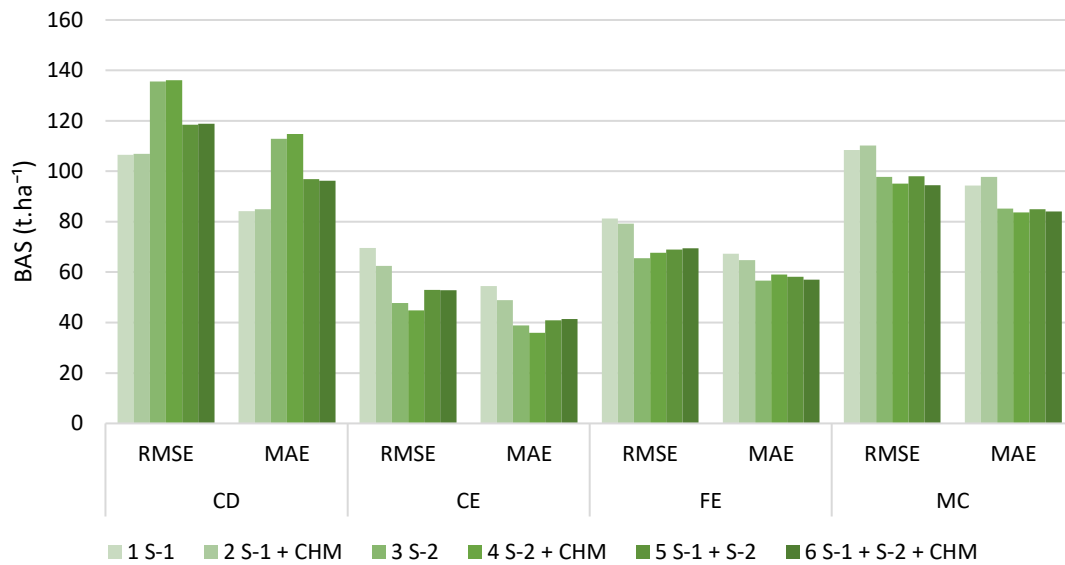
Baseado nos erros de predição, foi possível obter os valores de RMSE e MAE dos modelos para cada uma das quatro fitofisionomias que compuseram o conjunto de dados de amostragem e validação dos modelos. A Tabela 4.2 e a Figura 4.4 apresentam os resultados desta análise.

Tabela 4.2 – Avaliação da Acurácia dos Modelos Por Fitofisionomia.

Modelo		Acurácia Por Fitofisionomia (t.ha ⁻¹)							
		CD		CE		FE		MC	
		RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE
1	S-1	106,484	84,176	69,549	54,497	81,286	67,336	108,397	94,344
2	S-1 + CHM	106,919	84,901	62,492	48,884	79,170	64,802	110,181	97,735
3	S-2	135,555	112,900	47,729	38,881	65,495	56,598	97,765	85,175
4	S-2 + CHM	136,108	114,730	44,859	35,884	67,684	59,030	95,084	83,675
5	S-1 + S-2	118,449	96,893	52,973	40,921	68,927	58,208	97,996	84,970
6	S-1 + S-2 + CHM	118,863	96,229	52,803	41,459	69,460	57,060	94,467	84,034

Fonte: Elaborado pelo autor.

Figura 4.4 – Avaliação da acurácia dos modelos por fitofisionomia.



Fonte: Elaborado pelo autor.

O estudo dos erros da modelagem diferenciando os tipos de vegetação em períodos distintos, possibilita o entendimento mais detalhado da forma como os atributos estão interagindo com a vegetação. Ademais, propicia maior confiabilidade na extração da informação de biomassa de uma determinada fitofisionomia, em detrimento de outras (CHANG; SHOSHANY; OH, 2018; JACON et al., 2021).

Desse modo, foi observado que o *Cerrado Stricto Sensu* foi a fitofisionomia que apresentou menores erros em todos os modelos, sobretudo nos modelos que utilizaram somente dados ópticos. Os erros relacionados às Florestas Estacionais se expuseram com a mesma ordem de grandeza nos modelos 4 a 6. Ao passo que os modelos 1 e 2 foram, pelo menos, 5 t.ha⁻¹ (RMSE) menos acurados em relação aos demais.

Esta situação se repete para o caso das Matas Ciliares, nas quais o RMSE e MAE são equivalentes para modelos 4 a 6, nada obstante, o RMSE e o MAE são pelo menos 9 t.ha⁻¹ maiores nos modelos 1 e 2. O inverso ocorre para o Cerradão / Cerrado Denso, onde os modelos 1 e 2 são mais acurados em relação aos demais.

Logo, os modelos 5 e 6, por possuírem atributos derivados dos dados SAR, performaram melhor que os modelos 3 e 4. Entretanto, os maiores erros foram observados nas formações Florestais. Estas incertezas podem ser explicadas pela saturação dos dados ópticos e características dos dados SAR utilizados.

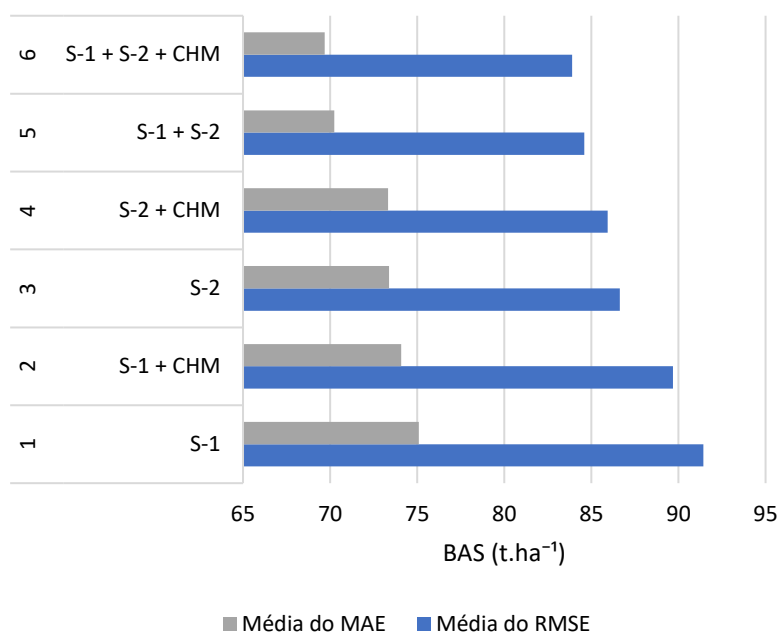
Ponzoni, Shimabukuro e Kuplich (2012) explicam que a saturação da reflectância da vegetação em dados ópticos pode ser atingida devido ao índice de área foliar (IAF). Há formação de dossel no Cerradão e Cerrado Denso, logo, é plausível cogitar que as bandas do sensor MSI utilizadas nesta pesquisa tenham atingido seus respectivos pontos de saturação. Assim, comprometendo a observação do gradiente de reflectância dos dosséis.

Acredita-se que algo semelhante ocorreu com os dados Sentinel-1. Conforme colocado por Le Toan et al. (1992), é esperado que as ondas eletromagnéticas em banda C não penetrem o dossel florestal em sua totalidade, de modo que as folhas e os pequenos galhos componham a principal fonte de retroespalhamento. Assim, não se obtém informações dos troncos e grandes galhos, que conservam os maiores percentuais de BAS. Logo, as informações obtidas nesta faixa do espectro não apresentam forte aderência aos dados adquiridos em campo.

Os maiores erros são observados no Cerradão / Cerrado Denso. Acredita-se que devido a variação de 50% a 70% da cobertura dos dosséis formados por esses subtipos de vegetação, ocorreu a acentuação da mistura espectral dos *pixels* nessas áreas, com a adição de respostas de solo e outros alvos, desse modo, influenciando diretamente a qualidade da estimativa (EMBRAPA, 2022).

As médias dos estimadores RMSE e MAE calculados para cada modelo especificados por fitofisionomia são apresentados na Figura 4.5. O ensejo da Figura 4.4 é denotar a tendência central dos erros por fitofisionomia em cada modelo. Posto isto, se agrega ainda mais subsídios para definir um único modelo para as análises seguintes.

Figura 4.5 – Média dos estimadores RMSE e MAE calculados para cada modelo especificados por fitofisionomia.



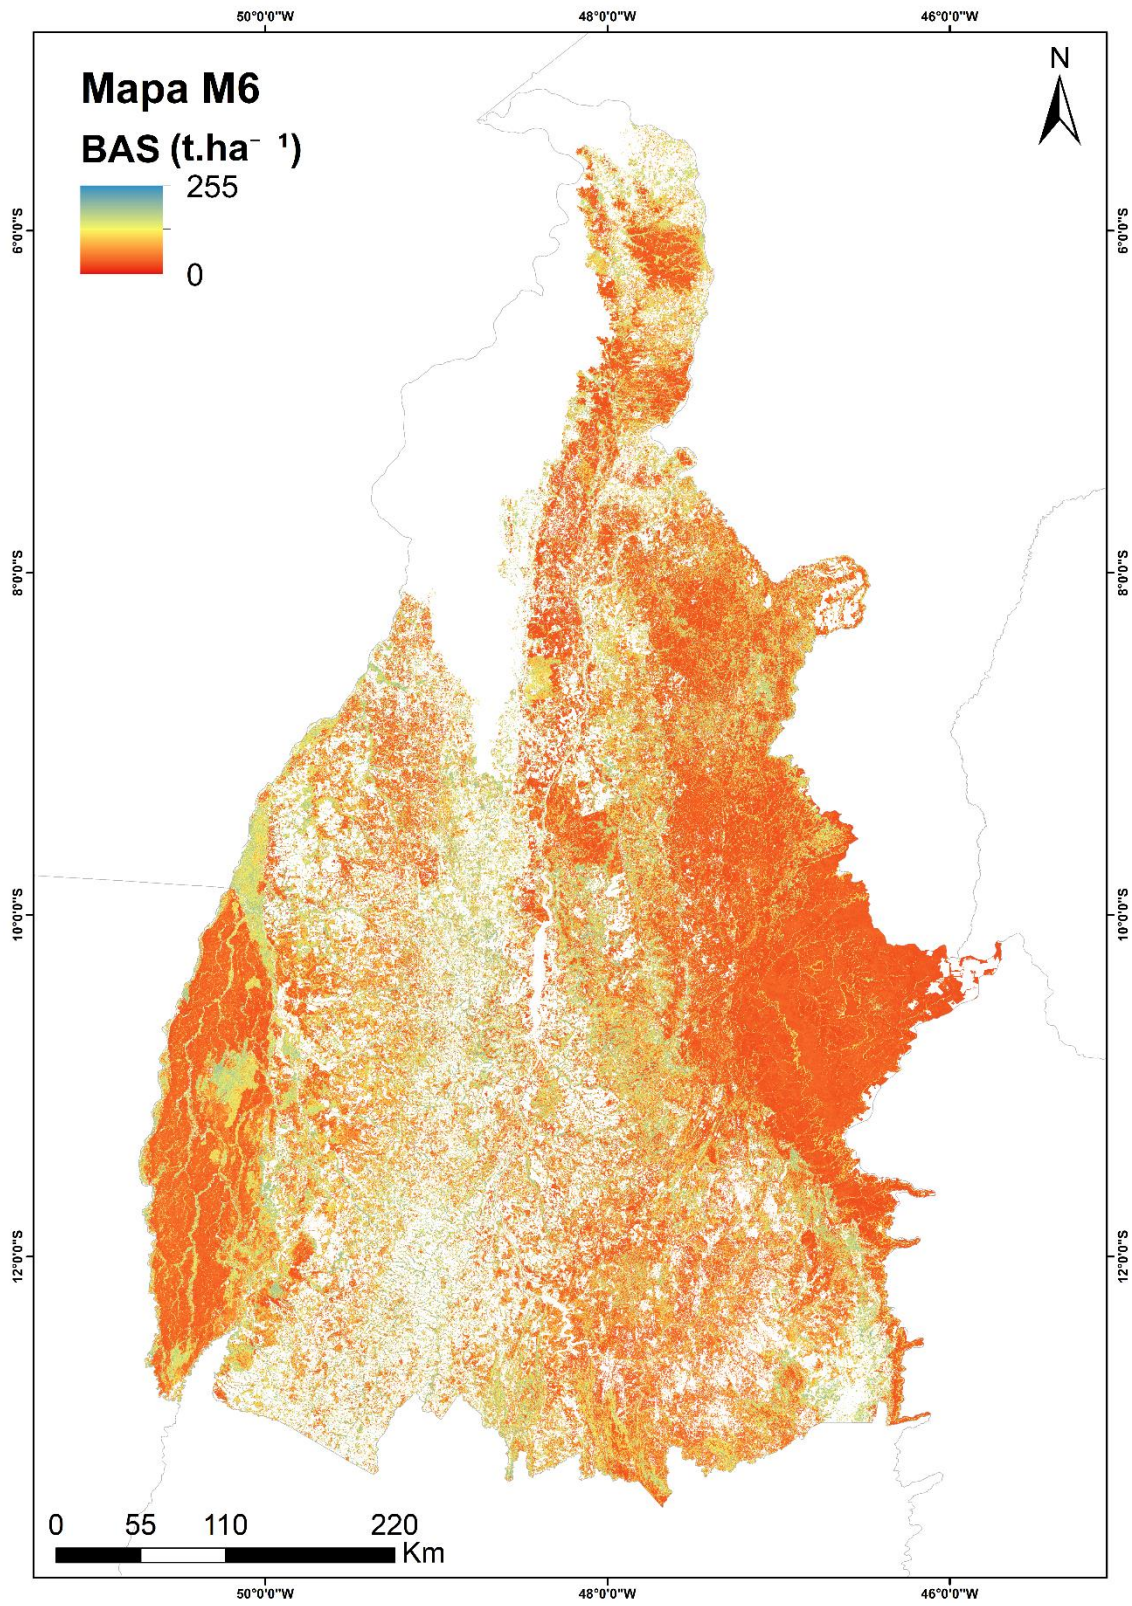
Fonte: Elaborado pelo autor.

Diante das análises realizadas, não há razões para discordar que dentre os mapas gerados, o mapa de BAS derivado do modelo 6 constitui-se como o mapa mais acurado da presente pesquisa. A seguir, ele é mencionado como M6, a fim de simplificar a nomenclatura nas análises onde ele é confrontado com os mapas de BAS descritos na Seção 3.3.9.

4.4 Mapa de BAS para o Cerrado tocantinense

Como principal resultado desta pesquisa, o mapa de BAS para o ano de 2019 M6 é exibido na Figura 4.6. O arquivo final é apresentado com *pixels* de 10 x 10 metros, em 8 *bits*, contendo valores de BAS que podem variar entre 0 e 255 t.ha⁻¹. Sobre o mapa, criou-se uma máscara a partir dos dados de classificação do uso e cobertura da terra do projeto MapBiomass Brasil. Desse modo, alvos diferentes da biomassa de vegetação nativa não são exibidos e não influenciam as estatísticas da imagem.

Figura 4.6 – Mapa de BAS do Cerrado Tocantinense para o Ano de 2019.



Fonte: Elaborado pelo autor.


A partir do mapa M6, é possível obter a biomassa acima do solo com erros conhecidos para o cerrado tocantinense. O valor máximo de BAS do mapa M6 corresponde a 241 t.ha⁻¹ e BAS média é de aproximadamente 82 t.ha⁻¹. É sabido que para análises regionais e a depender da aplicação dos dados, o emprego de resoluções mais finas não é usual.

O produto desta pesquisa busca não restringir o usuário final e oferece o produto na melhor resolução possível. Por possuir *pixels* de 10 metros, a transição entre diferentes alvos e a delimitação de bordas é suavizada em relação a mapas com resoluções maiores que 10 metros. Este detalhamento possibilita a obtenção dos valores de biomassa em regiões de faixas estreitas, a exemplo de áreas de Mata de Ciliar, Áreas de Proteção Permanente (APPs) ou Áreas de Reserva Legal (ARLs).

Na Figura 4.7 são apresentados recortes de cada um dos 6 mapas produzidos nesta pesquisa, para efeito de ilustração. Na figura é mostrado um recorte da região de Palmas, capital do estado do Tocantins. Nela, é possível observar os contornos à margem do Rio Tocantins para todos os mapas, bem como os fragmentos de vegetação na área urbana da cidade de Palmas.

A aplicação do mapa M6 poderá, dentre outras aplicações, subsidiar estudos de caráter urbano, uma vez que contempla fragmentos de vegetação em áreas urbanas. Ometto et al. (2014) ressaltam a importância de se produzir mapas de BAS de alta resolução, como o desta pesquisa, com o objetivo de atender as agendas ambientais e do clima. Contudo, os autores expõem a dificuldade oriunda da produção destes mapas, sobretudo no que diz respeito aos erros e incertezas.

Figura 4.7 – Recortes dos mapas BAS produzidos para a região de Palmas – TO.



Fonte: Elaborado pelo autor.

O mapa M6 está disponível para comunidade através do *link*: https://code.earthengine.google.com/?asset=users/simoes_philipe/Results/AGB_MaskedM6. e pode ser utilizado a partir da plataforma GEE. O mapa também pode ser exportado via *Google Drive* para utilização em *softwares* de sistemas de informação geográfica.

4.5 Comparação com mapas de referência

Os resultados da avaliação de acurácia do Mapa M6 em relação aos mapas de Baccini et al. (2012) (B12), ESA (2020) (C20) e Zimbres et al. (2021) (Z21) são apresentados na Tabela 4.3. Nela são exibidos os valores de RMSE e MAE absolutos e discriminados por fitofisionomia. Por uma questão de compatibilidade, conforme colocado no tópico 3.3.9, o Mapa M6 teve seus *pixels* reamostrados para as dimensões de 30 x 30, 100 x 100 e 500 x 500 metros, para a comparação com os mapas B12, C20 e Z21, respectivamente.

Tabela 4.3 – Comparação do mapa M6 com os mapas de referência B12, C20 e Z21.

Mapa	RMSE	MAE	Erros Por Fitofisionomia (t.ha ⁻¹)							
			CD		CE		FE		MC	
			RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE
Z21	102.958	64.276	171.811	162.357	17.868	13.658	140.989	120.435	95.730	75.545
M6 30m	75.089	51.354	118.317	95.939	49.307	39.108	66.635	54.662	99.849	91.921
C20	82.981	51.205	137.574	120.721	38.528	28.187	117.418	102.319	116.509	95.656
M6 100m	85.365	55.495	139.190	119.980	43.103	31.744	90.267	77.333	106.654	92.728
B12	91.206	68.690	145.999	139.903	46.100	38.210	156.131	140.227	97.518	82.235
M6 500m	96.446	66.787	148.227	132.448	41.278	28.341	109.135	87.418	121.592	102.394

Fonte: Elaborado pelo autor.


Fundamentado nos resultados do RMSE e MAE absolutos, observa-se que o Mapa M6 teve melhor performance que mapa Z21. A diferença do RMSE e MAE foi de cerca de 27 e 12 t.ha⁻¹, respectivamente. Na comparação da acurácia absoluta, estas foram as maiores diferenças encontradas. Zimbres et al. (2021) explicam que a maior fonte de erro de seus mapas é derivada da amostragem, incluindo a localização das parcelas de BAS que foram utilizadas.

Enfatiza-se que, os autores reportaram a exclusão de parcelas correspondentes de Florestas Ripárias, mais precisamente em relação às

Matas de Galeria no Estado do Tocantins, do mesmo modo que foi realizado na presente pesquisa. Uma vez que o mapa Z21 foi produzido para toda a extensão do Cerrado, é legítimo considerar que o efeito dos erros tenha sido intensificado no Estado do Tocantins, dado que estes autores reportam um erro de absoluto de $43,36 \text{ t.ha}^{-1}$ para a biomassa oriunda de Formações Florestais.

Na Figura 4.8 tem-se o gráfico que mostra a magnitude dos estimadores RMSE e MAE na comparação dos diferentes mapas. Os erros dos Mapas M6 reamostrados são maiores em todas as comparações, exceto no que se refere ao MAE do Mapa M6 com *pixels* de 500 metros. O MAE do Mapa M6 (500m) foi $0,097 \text{ t.ha}^{-1}$ menor em relação ao seu análogo B12. Neste caso, esta diferença não é significativa, uma vez que cada *pixel* corresponde a 25 ha.


Figura 4.8 – Magnitude dos estimadores RMSE e MAE.



Fonte: Elaborado pelo autor.

Ao analisar os erros por tipo de vegetação, observa-se as curvas dos erros da Figura 4.9 assemelham-se às da Figura 4.4. Para as regiões de Cerradão / Cerrado Denso, o o mapa Z21 derivou os maiores erros, reafirmando a hipótese de que parte significativa do erro deve-se ao tipo de vegetação e não exclusivamente ao dado SAR de banda C, uma vez que Zimbres et al. (2021) utilizaram dados em banda L. Nesta mesma fitofisionomia, o Mapa M6 derivou os menores erros, da ordem de 118 t.ha^{-1} (RMSE) e 95 t.ha^{-1} (MAE).

Figura 4.9 – Comparação dos erros dos mapas por fitofisionomia.



Fonte: Elaborado pelo autor.

Em contrapartida, o mapa Z21 obteve erros abaixo de 20 t.ha⁻¹ no Cerrado *Stricto Sensu*, uma vez que os erros dos demais mapas compreenderam o intervalo entre 38 e 49 t.ha⁻¹ com base no RMSE, e 28 e 39 t.ha⁻¹ a partir do MAE. Para as Matas Ciliares, os erros se concentraram entre 95 e 121 t.ha⁻¹ (RMSE) e 75 e 102 t.ha⁻¹ (MAE), de modo que somente o Mapa M6 (100m) performou melhor que seu opositor (C20). Nas regiões de Floresta Estacional ocorreu a maior variação dos valores dos estimadores RMSE e MAE.

Nestas regiões, reiteradamente o Mapa M6 desempenhou melhor que os seus respectivos opositores. Ainda que tenham sido degradados, os Mapas M6 se valem da resolução espacial inicial equivalentes às dimensões das parcelas utilizadas para treinamento e validação. Desse modo, é altamente recomendável distanciar-se de procedimentos que promovam a propagação de erros aleatórios e sistemáticos na etapa de amostragem.

Na Tabela 4.4 estão contidos os valores da BAS média das três grandes formações do Cerrado (florestal, savânica e campestre), obtidas a partir dos mapas em estudo. No que concerne ao mapa M6, a BAS média em formações florestais é sobre-estimada quando comparada aos demais mapas. Este é um

ponto de atenção, dado que os erros do Mapa M6 por vezes, foi inferior aos demais.

Tabela 4.4 – Biomassa acima do solo média dos Mapas M6, B12, C20 e Z21 de estudo em $t.ha^{-1}$, de acordo com os tipos de vegetação do MapBiomass Brasil (Coleção 5) 2019.

Tipo de Vegetação	M6	M6 30m	M6 100m	M6 500m	Z21	C20	B12
Florestal	150.404	149.465	139.676	96.684	85.868	103.618	95.825
Savânica	77.757	74.148	62.840	47.468	39.268	50.235	65.192
Campestre	38.869	35.548	32.106	29.737	23.618	6.676	28.356

Fonte: Elaborado pelo autor.

Em relação as formações savânicas e campestres, os resultados são mais aderentes entre si. O que é de grande valia, dado que esta pesquisa não contou com amostras correspondentes a BAS oriunda de Formações Campestres. Por fim, ressalta-se a importância da continuidade da produção de Mapas de Biomassa, objetivando diminuir os erros das estimativas e mantê-las atualizadas.

5 CONCLUSÕES E RECOMENDAÇÕES

Esta pesquisa resultou no primeiro mapa de BAS para o Cerrado Tocantinense com 10 metros de resolução. Além disso, discuti e apresentou uma das abordagens possíveis para combinação entre dados ópticos e de micro-ondas para a estimativa de biomassa acima do solo. Outrossim, ressaltou a importância de basear a escolha da variável não somente em algoritmos, mas também na literatura.

Dentre os seis modelos concebidos e avaliados para a estimativa de BAS, o modelo 6, que combinou dados Sentinel-1, Sentinel-2 e o produto CHM obteve o maior R^2 e os menores erros, avaliados pelos estimadores RMSE e MAE. A partir dele, gerou-se o denominado Mapa M6, que foi confrontado com o mapa de Zimbres et al. (2021), que é o estado da arte no que tange a quantificação e distribuição espacial da BAS no Cerrado brasileiro. Além disso, o Mapa M6 também foi avaliado em relação ao mapa de Baccini et al. (2012) e o Produto CCI (ESA, 2020).

Dentre os mapas gerados, o mapa de BAS para o Cerrado Tocantinense M6, apresentou os menores erros, sendo o RMSE igual à 73,881 t.ha⁻¹ e MAE à 57,398 t.ha⁻¹. Na avaliação em relação à outros mapas, este performou melhor que o mapa de Zimbres et al. (2021). Contudo, uma vez que o mapa M6 foi reamostrado para resoluções mais grosseiras, de 100 e 500 metros, ocorreu de os mapas de Baccini et al., (2012) e ESA (2020) apresentarem melhores resultados.

As análises e avaliações realizadas mostraram que o produto desta pesquisa é compatível em termos científicos e de acurácia com o estado da arte de mapas de BAS. Além disso, as análises também provaram que a combinação entre dados SAR e ópticos é relevante e fundamental para aumentar a acurácia das estimativas.

A indisponibilidade de dados em banda L atuais e de fonte aberta, limita a obtenção de melhores resultados para a estimativa de BAS. Uma vez estes dados disponíveis, novos conjuntos de variáveis preditoras podem ser

combinados, a exemplo do estudo de Omar, Misman e Kassim (2017), que combinam dados PALSAR-2 e Sentinel-1 para a estimativa de BAS na Malásia.

Os dados Sentinel-2 se mostraram essenciais para as predições de biomassa. De tal modo, que a diferença entre dos R^2 entre os modelos 4 e 5 é de apenas 0,005. A continuidade da missão Sentinel-2, no escopo do programa Copernicus, é essencial para que futuramente, análises de mudanças no uso e cobertura do solo e distribuição de BAS sejam passíveis de análise ao longo do tempo.

A quantidade e qualidade dos dados de campo atendeu as expectativas do trabalho, contudo, é desejável que em próximos trabalhos, sejam utilizadas amostras de BAS que contemplem, também, as formações campestres. É compreensível a dificuldade para realizar a coleta de parâmetros biofísicos da vegetação em campo, sobretudo em áreas remotas e inóspitas.

É necessário que a partir de então, haja convergência entre a utilização dos melhores dados possíveis oriundos de sensores remotos, a exemplo de dados em banda L e P, em conjunto com amostras altamente representativas, com a finalidade de derivar mapas de BAS em largas escalas, de alta e média resolução e com erros abaixo dos patamares atuais.

Assim, a comunidade dispõe de mais um produto para subsidiar os estudos e aplicações no que concerne aos estoques de carbono no Cerrado Tocantinense. Desse modo, buscando se aproximar dos objetivos das agendas do meio ambiente e do clima, que em seu cerne, tem pretensão de evoluirmos a uma sociedade mais justa, sustentável e com maior qualidade de vida.

REFERÊNCIAS BIBLIOGRÁFICAS

AQUINO, F. G.; WALTER, B. M. T.; RIBEIRO, J. F. Dinâmica de populações de espécies lenhosas de Cerrado, Balsas, Maranhão. **Revista Árvore**, v. 31, n. 5, p. 793–803, 2007. Disponível em: <https://doi.org/10.1590/S0100-67622007000500003>.

ARANTES, A. E.; FERREIRA, L. G.; COE, M. T. The seasonal carbon and water balances of the Cerrado environment of Brazil: past, present, and future influences of land cover and land use. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 117, p. 66–78, 2016. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2016.02.008>.

ATTEMA, E. P. W.; ULABY, F. T. Vegetation modeled as a water cloud. **Radio Science**, v. 13, n. 2, p. 357–364, 1978. Disponível em: <https://doi.org/10.1029/RS013i002p00357>.

BACCINI, A.; GOETZ, S. J.; WALKER, W. S.; LAPORTE, N. T.; SUN, M.; SULLA-MENASHE, D.; HACKLER, J.; BECK, P. S. A.; DUBAYAH, R.; FRIEDL, M. A.; SAMANTA, S.; HOUGHTON, R. A. Estimated carbon dioxide emissions from tropical deforestation improved by carbon-density maps. **Nature Climate Change**, v. 2, n. 3, p. 182–185, 2012. Disponível em: <https://doi.org/10.1038/nclimate1354>.

BAO, N.; LI, W.; GU, X.; LIU, Y. Biomass estimation for semiarid vegetation and mine rehabilitation using Worldview-3 and Sentinel-1 SAR imagery. **Remote Sensing**, v. 11, n. 23, e 2855, 2019. Disponível em: <https://doi.org/10.3390/rs11232855>.

BARRETT, B.; NITZE, I.; GREEN, S.; CAWKWELL, F. Assessment of multi-temporal, multi-sensor radar and ancillary spatial data for grasslands monitoring in Ireland using machine learning approaches. **Remote Sensing of Environment**, v. 152, p. 109–124, 2014. Disponível em: <https://doi.org/10.1016/j.rse.2014.05.018>.

BISPO, P. C.; SANTOS, J. R.; VALERIANO, M. M.; TOUZI, R.; SEIFERT, F. M. Integration of polarimetric PALSAR attributes and local geomorphometric variables derived from SRTM for forest biomass modeling in central Amazonia. **Canadian Journal of Remote Sensing**, v. 40, n. 1, p. 26–42, 2014. Disponível em: <https://doi.org/10.1080/07038992.2014.913477>.

BISPO, P. C.; RODRÍGUEZ-VEIGA, P.; ZIMBRES, B.; DO COUTO DE MIRANDA, S.; HENRIQUE GIUSTI CEZARE, C.; FLEMING, S.; BALDACCHINO, F.; LOUIS, V.; RAINS, D.; GARCIA, M.; DEL BON ESPÍRITO-SANTO, F.; ROITMAN, I.; PACHECO-PASCAGAZA, A. M.; GOU, Y.; ROBERTS, J.; BARRETT, K.; FERREIRA, L. G.; SHIMBO, J. Z.; ALENCAR, A.; BUSTAMANTE, M.; WOODHOUSE, I. H.; EYJI SANO, E.; OMETTO, J. P.; TANSEY, K.; BALZTER, H. Woody aboveground biomass mapping of the Brazilian Savanna with a multi-sensor and machine learning approach. **Remote**

Sensing, v. 12, n. 17, e 2685, 2020. Disponível em:
<https://doi.org/10.3390/rs12172685>.

BOUVET, A.; MERMOZ, S.; LE TOAN, T.; VILLARD, L.; MATHIEU, R.; NAIDOO, L.; ASNER, G. P. An above-ground biomass map of African savannahs and woodlands at 25 m resolution derived from ALOS PALSAR. **Remote Sensing of Environment**, v. 206, p. 156–173, 2018. Disponível em:
<https://doi.org/10.1016/j.rse.2017.12.030>.

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

BREIMAN, L. Consistency for a simple model of random forests. **Statistics**, 2004.

BROWN, S. **Estimating biomass and biomass change of tropical forests: a primer**. 1997. Disponível em:
<https://www.fao.org/docrep/w4095e/w4095e00.HTM>.

CARTUS, O.; SANTORO, M.; KELLNDORFER, J. Mapping forest aboveground biomass in the Northeastern United States with ALOS PALSAR dual-polarization L-band. **Remote Sensing of Environment**, v. 124, p. 466–478, 2012. Disponível em: <https://doi.org/10.1016/j.rse.2012.05.029>.

CASSOL, H. L. G. **Estimativa de biomassa e estoque de carbono em um fragmento de floresta ombrófila mista com uso de dados ópticos de sensores remotos**. 2013. 143p. Dissertação (Mestrado em Sensoriamento Remoto) - Universidade Federal do Rio Grande do Sul (UFRGS), Porto Alegre, 2013. Disponível em: <http://hdl.handle.net/10183/79773>.

CASSOL, H. L. G. **Aplicação dos dados polarimétricos alos / palsar-2 para modelagem de biomassa**. 2017. 267p. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2017. Disponível em: <http://urlib.net/8JMKD3MGP3W34P/3PULANE>.

CASSOL, H. L. G.; SHIMABUKURO, Y. E.; BEUCHLE, R.; ARAGÃO, L. E. O. C. Sentinel-1 time-series analysis for detection of forest degradation by selective logging. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 19., Santos-SP, Brasil. **Anais...** 2019. p. 755-758. Disponível em: <https://proceedings.science/sbsr-2019/papers/sentinel-1-time-series-analysis-for-detection-of-forest-degradation-by-selective-logging>.

CHANG, J. G.; SHOSHANY, M.; OH, Y. Polarimetric radar vegetation index for biomass estimation in desert fringe ecosystems. **IEEE Transactions on Geoscience and Remote Sensing**, v. 56, n. 12, p. 7102–7108, 2018. Disponível em: <https://doi.org/10.1109/TGRS.2018.2848285>.

CHAVE, J.; ANDALO, C.; CAIRNS, C.; BROWN, S.; CAIRNS, M. A.; CHAMBERS, J. Q.; EAMUS, D.; FOLSTER, H.; FROMARD, F.; HIGUCHI, N.; KIRA, T.; LESCURE, J. P.; NELSON, B. W.; OGAWA, H.; PUIG, H.; RIÉRA, B.; YAMAKURA, T. Tree allometry and improved estimation of carbon stocks and balance in tropical forests. **Oecologia**, v. 145, p. 87–99, 2005. Disponível em: <https://doi.org/10.1007/s00442-005-0100-x>.

CHEN, L. et al. Biomass estimation and uncertainty analysis based on CBERS-02 CCD camera data and field measurement. **Science China Series E-Technology Sciences**, v. 48, p. 116–128, 2005. Disponível em: <https://doi.org/10.1007/BF03039429>.

CHEN, Y.; LI, L.; LU, D.; LI, D. Exploring bamboo forest aboveground biomass estimation using Sentinel-2 data. **Remote Sensing**, v. 11, n. 1, e 7, 2018. Disponível em: <https://doi.org/10.3390/rs11010007>.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. 3.ed. Boca Raton: CRS Press, 2019. 346p.

COPERNICUS. **Copernicus in detail**. Disponível em: <https://www.copernicus.eu/en/about-copernicus/copernicus-detail>. Acesso em: 3 mar. 2021.

COUGO, M.; SOUZA-FILHO, P.; SILVA, A.; FERNANDES, M.; SANTOS, J.; ABREU, M.; NASCIMENTO, W.; SIMARD, M. Radarsat-2 backscattering for the modeling of biophysical parameters of regenerating mangrove forests. **Remote Sensing**, v. 7, n. 12, p. 17097–17112, 2015. Disponível em: <https://doi.org/10.3390/rs71215873>.

CUNHA, N. R. S.; LIMA, J. E.; GOMES, M. F. M.; BRAGA, M. J. A intensidade da exploração agropecuária como indicador da degradação ambiental na região dos Cerrados, Brasil. **Revista de Economia e Sociologia Rural**, v. 46, n. 2, p. 291–323, 2008. Disponível em: <https://doi.org/10.1590/S0103-20032008000200002>.

DI MARTINO, G.; DI SIMONE, A.; IODICE, A.; RICCIO, D. Benchmarking framework for multitemporal SAR despeckling. **IEEE Transactions on Geoscience and Remote Sensing**, v. 60, n. 3, p. 1596–1615, 2014. Disponível em: <https://doi.org/10.1109/TGRS.2021.3074435>.

DIAZ, J. C. F.; CARTER, W. E.; SHRESTHA, R. L.; GLENNIE, C. L. **LIDAR remote sensing**. [S.l.: s.n., s.d.]. v. 1 930–980 p. ISBN (978-3-319-23386-4).

DRAKE, J. B.; KNOX, R. G.; DUBAYAH, R. O.; CLARK, D. B.; CONDIT, R.; BLAIR, J. B.; HOFTON, M. Above-ground biomass estimation in closed canopy neotropical forests using lidar remote sensing: factors affecting the generality of relationships. **Global Ecology and Biogeography**, v. 12, n. 2, p. 147–159, 2003. Disponível em: <https://doi.org/10.1046/j.1466-822X.2003.00010.x>.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (EMBRAPA). **Cerrado denso**. Disponível em: <https://www.embrapa.br/cerrados/colecao-entomologica/bioma-cerrado/cerrado-sentido-restrito/cerrado-denso>. Acesso em: 25 jul. 2022.

EUROPEN SPACE AGENCY (ESA). **CCI biomass product user guide**. [S.l.]: ESA, 2020.

EUROPEN SPACE AGENCY (ESA). **Sentinel-1: overview**. Disponível em: <https://sentinel.esa.int/web/sentinel/missions/sentinel-1/overview>. Acesso em: 22 mar. 2021a.

EUROPEN SPACE AGENCY (ESA). **Sentinel-1: instrument payload**. Disponível em: <https://sentinel.esa.int/web/sentinel/missions/sentinel-1/instrument-payload>. Acesso em: 22 mar. 2021b.

EUROPEN SPACE AGENCY (ESA). **User guides: Sentinel-1 SAR - Interferometric Wide Swath**. Disponível em: <https://sentinel.esa.int/web/sentinel/user-guides/sentinel-1-sar/acquisition-modes/interferometric-wide-swath>. Acesso em: 22 mar. 2021c.

EUROPEN SPACE AGENCY (ESA). **User guides - Sentinel-2 MSI - overview**. Disponível em: <https://sentinel.esa.int/web/sentinel/user-guides/sentinel-2-msi/overview>. Acesso em: 22 mar. 2021d.

EUROPEN SPACE AGENCY (ESA). **User guides - Sentinel-2 MSI - revisit and coverage**. Disponível em: <https://sentinel.esa.int/web/sentinel/user-guides/sentinel-2-msi/revisit-coverage>. Acesso em: 22 mar. 2021e.

EUROPEN SPACE AGENCY (ESA). **Radiometric - resolutions - Sentinel-2 MSI: user guides**. Disponível em: <https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-2-msi/resolutions/radiometric>. Acesso em: 27 jun. 2022.

FASSNACHT, F. E.; POBLETE-OLIVARES, J.; RIVERO, L.; LOPATIN, J.; CEBALLOS-COMISSO, A.; GALLEGUILLOS, M. Using Sentinel-2 and canopy height models to derive a landscape-level biomass map covering multiple vegetation types. **International Journal of Applied Earth Observation and Geoinformation**, v. 94, e102236, 2021. Disponível em: <https://doi.org/10.1016/j.jag.2020.102236>.

FELFILI, J. M.; ALVIM CARVALHO, F.; HAIDAR, R. F. Manual para o monitoramento de parcelas permanentes nos biomas cerrado e pantanal. In: WORKSHOPS DA REDE DE PARCELAS PERMANENTES DOS BIOMAS CERRADO E PANTANAL, 2005, Bonito-MS; Alto Paraíso de Goiás-GO. **Anais...** 2005.

FIGUEIREDO FILHO, D. B.; SILVA, D.; SILVA JÚNIOR, J. A. Desvendando os mistérios do coeficiente de correlação de Pearson (r). **Revista Política Hoje**, v. 18, n. 1, p. 115–146, 2009. Disponível em: <http://dx.doi.org/10.11606/issn.2237-4485.lev.2014.132346>.

FORKUOR, G.; BENEWINDE ZOUNGRANA, J. B.; DIMOBE, K.; OUATTARA, B.; VADREVU, K. P.; TONDOH, J. E. Above-ground biomass mapping in West African dryland forest using Sentinel-1 and 2 datasets: a case study. **Remote Sensing of Environment**, v. 236, e 111496, 2020. Disponível em: <https://doi.org/10.1016/j.rse.2019.111496>.

GEDI ECOSYSTEM LIDAR. **Mission overview**. Disponível em: <https://gedi.umd.edu/mission/mission-overview/>. Acesso em: 22 mar. 2021a.

GEDI ECOSYSTEM LIDAR. **Specifications**. Disponível em: <https://gedi.umd.edu/instrument/specifications/>. Acesso em: 22 mar. 2021b.

GIBBS, H. K.; BROWN, S.; NILES, J. O.; FOLEY, J. A. Monitoring and estimating tropical forest carbon stocks: making REDD a reality. **Environmental Research Letters**, v. 2, n. 4, e045023, 2007. Disponível em: <http://dx.doi.org/10.1088/1748-9326/2/4/045023>.

GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18–27, 2017. Disponível em: <https://doi.org/10.1016/j.rse.2017.06.031>.

GUERINI FILHO, M.; KUPLICH, T. M.; QUADROS, F. L. F.; GUERINI, M.; KUPLICH, T. M.; QUADROS, F. L. F. Estimating natural grassland biomass by vegetation indices using Sentinel 2 remote sensing data. **International Journal of Remote Sensing**, v. 41, n. 8, p. 2861–2876, 2020. Disponível em: <https://doi.org/10.1080/01431161.2019.1697004>.

Haidar, R. F.; DIAS, R. R.; FELFILI, J. M. **Mapeamento das regiões fitoecológicas e inventário florestal do Estado do Tocantins**. Palmas: Governo do Estado, 2013.

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

HUANG, X.; ZINITI, B.; TORBICK, N.; DUCEY, M. Assessment of forest above ground biomass estimation using multi-temporal C-band Sentinel-1 and polarimetric L-band Palsar-2 data. **Remote Sensing**, v. 10, n. 9, e1424, 2018. Disponível em: <https://doi.org/10.3390/rs10091424>.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p. 295–309, 1988.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE).

Tocantins, panorama. Disponível em:

<https://cidades.ibge.gov.br/brasil/to/panorama>. Acesso em: 21 mar. 2021.

INSTITUTO CHICO MENDES DE CONSERVAÇÃO DA BIODIVERSIDADE (ICMBIO). **Cerrado**. Disponível em:

<https://www.icmbio.gov.br/portal/unidadesdeconservacao/biomas-brasileiros/cerrado>. Acesso em: 18 fev. 2021.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Monitoramento do desmatamento no Cerrado brasileiro por satélite: Projeto**

Monitoramento do Cerrado. Disponível em:

<http://cerrado.obt.inpe.br/monitoramento-do-desmatamento-no-cerrado-brasileiro-por-satelite/>. Acesso em: 3 mar. 2021.

JACON, A.D.; GALVÃO, L.S.; DALAGNOL, R.; SANTOS, J.R. Aboveground biomass estimates over Brazilian savannas using hyperspectral metrics and machine learning models: experiences with Hyperion/EO-1. **GIScience & Remote Sensing**, n. 58, v. 7, p. 1112-1129, 2021. Disponível em: <http://dx.doi.org/10.1080/15481603.2021.1969630>.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. [S.l.: s.n.], 2009.

JOSHI, N.; BAUMANN, M.; EHAMMER, A.; FENSHOLT, R.; GROGAN, K.; HOSTERT, P.; JEPSEN, M.; KUEMMERLE, T.; MEYFROIDT, P.; MITCHARD, E.; REICHE, J.; RYAN, C.; WASKE, B. A review of the application of optical and radar remote sensing data fusion to land use mapping and monitoring. **Remote Sensing**, v. 8, n. 1, 2016. Disponível em: <https://doi.org/10.3390/rs8010070>.

JOSHI, N.; MITCHARD, E. T. A.; BROLLY, M.; SCHUMACHER, J.; FERNÁNDEZ-LANDA, A.; JOHANNSEN, V. K.; MARCHAMALO, M.; FENSHOLT, R. Understanding “saturation” of radar signals over forests. **Scientific Reports**, v. 7, n. 1, p. 1–11, 2017. Disponível em: <https://doi.org/10.1038/s41598-017-03469-3>.

KACHAMBA, D.; ØRKA, H.; GOBAKKEN, T.; EID, T.; MWASE, W. Biomass estimation using 3d data from unmanned aerial vehicle imagery in a tropical woodland. **Remote Sensing**, v. 8, n. 11, 2016. Disponível em: <https://doi.org/10.3390/rs8110968>.

KHUDINYAN, M. **The use of remotely sensed data for forest biomass monitoring: a case of forest sites in North-Eastern Armenia**. 2019. Disponível em: <https://run.unl.pt/bitstream/10362/63694/1/TGEO0209.pdf>. Acesso em: 23 mar. 2021

KUMAR, A.; KISHORE, B. S. P. C.; SAIKIA, P.; DEKA, J.; BHARALI, S.; SINGHA, L. B.; TRIPATHI, O. P.; KHAN, M. L. Tree diversity assessment and above ground forests biomass estimation using SAR remote sensing: a case study of higher altitude vegetation of North-East Himalayas, India. **Physics and Chemistry of the Earth, Parts A/B/C**, v. 111, p. 53–64, 2019. Disponível em: <https://doi.org/10.1016/j.pce.2019.03.007>.

KUMAR, L.; MUTANGA, O. Remote sensing of above-ground biomass. **Remote Sensing**, v. 9, n. 9, p. 935, 2017. Disponível em: <https://doi.org/10.3390/rs9090935>.

KUMAR, L.; SINHA, P.; TAYLOR, S.; ALQURASHI, A. F. Review of the use of remote sensing for biomass estimation to support renewable energy generation. **Journal of Applied Remote Sensing**, v. 9, n. 1, e097696, 2015. Disponível em: <https://doi.org/10.1117/1.JRS.9.097696>.

KUPLICH, T. M.; CURRAN, P. J.; ATKINSON, P. M. Relating SAR image texture to the biomass of regenerating tropical forests. **International Journal of**

Remote Sensing, v. 26, n. 21, p. 4829–4854, 2005. Disponível em: <https://doi.org/10.1109/IGARSS.2003.1294615>.

LAURIN, G. V.; BALLING, J.; CORONA, P.; MATTIOLI, W.; PAPALE, D.; PULETTI, N.; RIZZO, M.; TRUCKENBRODT, J.; URBAN, M. Above-ground biomass prediction by Sentinel-1 multitemporal data in central Italy with integration of ALOS2 and Sentinel-2 data. **Journal of Applied Remote Sensing**, v. 12, n. 01, p. 1, 2018. Disponível em: <https://doi.org/10.1117/1.JRS.12.016008>.

LE TOAN, T.; BEAUDOIN, A.; RIOM, J.; GUYON, D. Relating forest biomass to SAR data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 30, n. 2, p. 403–411, 1992. Disponível em: <https://doi.org/10.1109/36.134089>.

LEWIS, A.; LACEY, J.; MECKLENBURG, S.; ROSS, J.; SIQUEIRA, A.; KILLOUGH, B.; SZANTOI, Z.; TADONO, T.; ROSENQVIST, A.; GORYL, P.; MIRANDA, N.; HOSFORD, S. Ceos Analysis Ready Data for Land (CARD4L) overview. **International Geoscience and Remote Sensing Symposium (IGARSS)**, v. 2018, p. 7407–7410, 2018. Disponível em: <https://doi.org/10.1109/IGARSS.2018.8519255>.

LIU, Y.; GONG, W.; XING, Y.; HU, X.; GONG, J. Estimation of the forest stand mean height and aboveground biomass in northeast china using SAR Sentinel-1b, multispectral Sentinel-2a, and DEM imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 151, p. 277–289, 2019. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2019.03.016>.

LU, D. The potential and challenge of remote sensing - based biomass estimation. **International Journal of Remote Sensing**, p.1297-1328, 2007. Disponível em: <https://doi.org/10.1080/01431160500486732>.

LU, D.; LI, G.; MORAN, E.; DUTRA, L.; BATISTELLA, M. A comparison of multisensor integration methods for land cover classification in the Brazilian Amazon. **GIScience and Remote Sensing**, v. 48, n. 3, p. 345–370, 2011. Disponível em: <https://doi.org/10.2747/1548-1603.48.3.345>.

MACKEY, B.; KORMOS, C. F.; KEITH, H.; MOOMAW, W. R.; HOUGHTON, R. A.; MITTERMEIER, R. A.; HOLE, D.; HUGH, S. Understanding the importance of primary tropical forest protection as a mitigation strategy. **Mitigation and Adaptation Strategies for Global Change**, v. 25, n. 5, p. 763–787, 2020. Disponível em: <https://doi.org/10.1007/s11027-019-09891-4>

MAPBIOMAS BRASIL. **Mapbiomas Brasil**. Disponível em: <https://mapbiomas.org/pt/project>. Acesso em: 21 jun. 2022.

MENZE, B. H.; KELM, B. M.; MASUCH, R.; HIMMELREICH, U.; BACHERT, P.; PETRICH, W.; HAMPRECHT, F. A. A comparison of random forest and its Gini importance with standard chemometric methods for the feature selection and classification of spectral data. **BMC Bioinformatics**, v. 10, p. 1–16, 2009. Disponível em: <https://doi.org/10.1186/1471-2105-10-213>.

MIRANDA, S. C.; BUSTAMANTE, M.; PALACE, M.; HAGEN, S.; KELLER, M.; FERREIRA, L. G. Regional variations in biomass distribution in Brazilian Savanna Woodland. **Biotropica**, v. 46, n. 2, p. 125–138, 2014. Disponível em: <https://doi.org/10.1111/btp.12095>.

MITCHARD, E. T. A. The tropical forest carbon cycle and climate change. **Nature**, v. 559, n. 7715, p. 527–534, 2018. Disponível em: <https://doi.org/10.1038/s41586-018-0300-2>.

MITCHARD, E. T. A.; SAATCHI, S. S.; LEWIS, S. L.; FELDPAUSCH, T. R.; WOODHOUSE, I. H.; SONKÉ, B.; ROWLAND, C.; MEIR, P. Measuring biomass changes due to woody encroachment and deforestation/degradation in a forest–savanna boundary region of central Africa using multi-temporal L-band radar backscatter. **Remote Sensing of Environment**, v. 115, n. 11, p. 2861–2873, 2011. Disponível em: <https://doi.org/10.1016/j.rse.2010.02.022>.

MITCHARD, E. T. A.; SAATCHI, S. S.; WOODHOUSE, I. H.; NANGENDO, G.; RIBEIRO, N. S.; WILLIAMS, M.; RYAN, C. M.; LEWIS, S. L.; FELDPAUSCH, T. R.; MEIR, P. Using satellite radar backscatter to predict above-ground woody biomass: a consistent relationship across four different African landscapes. **Geophysical Research Letters**, v. 36, n. 23, p. 1–6, 2009. Disponível em: <https://doi.org/10.1029/2009GL040692>.

MOORE, D. S.; MCCABE, G. P.; CRAIG, A. B. **Introduction to the practice of statistics**. [S.l.]: W. R. Freeman, 2016.

MULLISSA, A. G.; MARCOS, D.; TUIA, D.; HEROLD, M.; REICHE, J. DeSpeckNet: generalizing deep learning-based SAR image despeckling. **IEEE Transactions on Geoscience and Remote Sensing**, v. 60, p. 1–15, 2020. Disponível em: <https://doi.org/10.1109/TGRS.2020.3042694>.

MULLISSA, A.; VOLLRATH, A.; ODONGO-BRAUN, C.; SLAGTER, B.; BALLING, J.; GOU, Y.; GORELICK, N.; REICHE, J. Sentinel-1 SAR backscatter analysis ready data preparation in google earth engine. **Remote Sensing**, v. 13, n. 10, p. 1954, 2021. Disponível em: <https://doi.org/10.3390/rs13101954>.

NASIRZADEHDIZAJI, R.; BALIK SANLI, F.; ABDIKAN, S.; CAKIR, Z.; SEKERTEKIN, A.; USTUNER, M. Sensitivity analysis of multi-temporal Sentinel-1 SAR parameters to crop height and canopy coverage. **Applied Sciences**, v. 9, n. 4, p. 655, 2019. Disponível em: <https://doi.org/10.3390/app9040655>.

NOVO, E. M. L. D. M. **Sensoriamento remoto: princípios e aplicações**. 4. ed. São Paulo: Blucher, 2010. 387p.

NUTHAMMACHOT, N.; ASKAR, A.; STRATOULIAS, D.; WICAKSONO, P. Combined use of Sentinel-1 and Sentinel-2 data for improving above-ground biomass estimation. **Geocarto International**, v. 37, n. 2, p. 366–376, 2020. Disponível em: <https://doi.org/10.1080/10106049.2020.1726507>.

OLIVEIRA-FILHO, A. T.; RATTER, J. A. A study of the origin of central brazilian forests by the analysis of plant species distribution patterns. **Edinburgh Journal of Botany**, v. 52, n. 2, p. 141–194, 1995. Disponível em: <https://doi.org/10.1017/S096042860000949>.

OLIVEIRA, P. S.; MARQUIS, R. J. **The Cerrados of Brazil: ecology and natural history of a neotropical Savanna**. [S.l.]: Columbia University Press, 2002. 409 p.

OMAR, H.; MISMAN, M.; KASSIM, A. Synergetic of Palsar-2 and Sentinel-1a sar polarimetry for retrieving aboveground biomass in dipterocarp forest of malaysia. **Applied Sciences**, v. 7, n. 7, e 675, 2017. Disponível em: <https://doi.org/10.3390/app7070675>.

OMETTO, J. P.; AGUIAR, A. P.; ASSIS, T.; SOLER, L.; VALLE, P.; TEJADA, G.; LAPOLA, D. M.; MEIR, P. Amazon forest biomass density maps: tackling the uncertainty in carbon emission estimates. **Climatic Change**, v. 124, n. 3, p. 545–560, 2014. Disponível em: <https://doi.org/10.1007/s10584-014-1058-7>.

PALOSCIA, S.; MACELLONI, G.; PAMPALONI, P.; SIGISMONDI, S. The potential of c- and l-band sar in estimating vegetation biomass: the ERS-1 and JERS-1 experiments. **IEEE Transactions on Geoscience and Remote Sensing**, v. 37, n. 4, p. 2107–2110, 1999. Disponível em: <https://doi.org/10.1109/36.774723>

PARDINI, M.; ARMSTON, J.; QI, W.; LEE, S. K.; TELLO, M.; CAZCARRA BES, V.; CHOI, C.; PAPATHANASSIOU, K. P.; DUBAYAH, R. O.; FATOYINBO, L. E. Early lessons on combining lidar and multi-baseline SAR measurements for forest structure characterization. **Springer Netherlands**, v. 40, p. 803–837, 2019. Disponível em: <https://doi.org/10.1007/s10712-019-09553-9>.

PARRESOL, B. R. Assessing tree and stand biomass: a review with examples and critica comparisons. **Forest Science**, v. 45, n. 4, 1999. Disponível em: <https://www.srs.fs.usda.gov/pubs/1180>

PERIASAMY, S. Significance of dual polarimetric synthetic aperture radar in biomass retrieval: an attempt on Sentinel-1. **Remote Sensing of Environment**, v. 217, p. 537–549, 2018. Disponível em: <https://doi.org/10.1016/j.rse.2018.09.003>.

PHAM, T. D.; YOKOYA, N.; XIA, J.; HA, N. T.; LE, N. N.; NGUYEN, T. T. T.; DAO, T. H.; VU, T. T. P.; PHAM, T. D.; TAKEUCHI, W. Comparison of machine learning methods for estimating mangrove above-ground biomass using multiple source remote sensing data in the Red River Delta Biosphere Reserve, Vietnam. **Remote Sensing**, v. 12, n. 8, e1334, 2020. Disponível em: <https://doi.org/10.3390/rs12081334>.

PONZONI, F.J.; SHIMABUKURO, Y.E.; KUPLICH, T.M. **Sensoriamento remoto da vegetação**. 2. ed. São Paulo: Oficina de Texto, 2012. 178p.

POTAPOV, P.; LI, X.; HERNANDEZ-SERNA, A.; TYUKAVINA, A.; HANSEN, M.

C.; KOMMAREDDY, A.; PICKENS, A.; TURUBANOVA, S.; TANG, H.; SILVA, C. E.; ARMSTON, J.; DUBAYAH, R.; BLAIR, J. B.; HOFTON, M. Mapping global forest canopy height through integration of GEDI and Landsat data. **Remote Sensing of Environment**, v. 253, e 112165, 2021. Disponível em: <https://doi.org/10.1016/j.rse.2020.112165>.

POWELL, S. L.; COHEN, W. B.; HEALEY, S. P.; KENNEDY, R. E.; MOISEN, G. G.; PIERCE, K. B.; OHMANN, J. L. Quantification of live aboveground forest biomass dynamics with Landsat time-series and field inventory data: a comparison of empirical modeling approaches. **Remote Sensing of Environment**, v. 114, n. 5, p. 1053–1068, 2010. Disponível em: <https://doi.org/10.1016/j.rse.2009.12.018>.

QI, W.; SAARELA, S.; ARMSTON, J.; STÅHL, G.; DUBAYAH, R. Forest biomass estimation over three distinct forest types using TanDEM-X InSAR data and simulated GEDI lidar data. **Remote Sensing of Environment**, v. 232, e 111283, 2019. Disponível em: <https://doi.org/10.1016/j.rse.2019.111283>.

QURESHI, A.; PARIVA; BADOLA, R.; HUSSAIN, S. A. A review of protocols used for assessment of carbon stock in forested landscapes. **Environmental Science & Policy**, v. 16, p. 81–89, 2012. Disponível em: <https://doi.org/10.1016/j.envsci.2011.11.001>.

RIBEIRO, J.F.; WALTER, B.M.T. Fitofisionomias do bioma Cerrado. In: SANO, S. M.; ALMEIDA, S. P. (Ed.). **Cerrado: ambiente e flora**. Planaltina: EMBRAPA, 1998. p.87–166.

ROITMAN, I.; BUSTAMANTE, M. M. C.; HAIDAR, R. F.; SHIMBO, J. Z.; ABDALA, G. C.; EITEN, G.; FAGG, C. W.; FELFILI, M. C.; FELFILI, J. M.; JACOBSON, T. K. B.; LINDOSO, G. S.; KELLER, M.; LENZA, E.; MIRANDA, S. C.; PINTO, J. R. R.; RODRIGUES, A. A.; DELITTI, W. B. C.; ROITMAN, P.; SAMPAIO, J. M. Optimizing biomass estimates of savanna woodland at different spatial scales in the Brazilian Cerrado: re-evaluating allometric equations and environmental influences. **PLoS ONE**, v. 13, n. 8, p. 1–21, 2018. Disponível em: <https://doi.org/10.1371/journal.pone.0196742>.

ROUSE, J.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS. **NASA Special Publication**, v. 351, n. 1974, p. 309–317, 1973.

SAARELA, S.; HOLM, S.; HEALEY, S.; ANDERSEN, H.-E.; PETERSSON, H.; PRENTIUS, W.; PATTERSON, P.; NÆSSET, E.; GREGOIRE, T.; STÅHL, G. Generalized hierarchical model-based estimation for aboveground biomass assessment using gedi and Landsat data. **Remote Sensing**, v. 10, n. 11, 1832, 2018. Disponível em: <https://doi.org/10.3390/rs10111832>.

SIBANDA, M.; MUTANGA, O.; ROUGET, M. Examining the potential of Sentinel-2 MSI spectral resolution in quantifying above ground biomass across different fertilizer treatments. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 110, p. 55–65, 2015. Disponível em:

<http://dx.doi.org/10.1016/j.isprsjprs.2015.10.005>.

SILVEIRA, P. Estimativa da biomassa e carbono acima do solo em um fragmento de floresta ombrófila densa utilizando o método da derivação do volume comercial. **Floresta**, v. 40, n. 4, p. 789–800, 2010. Disponível em: <http://dx.doi.org/10.5380/rf.v40i4.20330>.

SILVEIRA, P.; KOEHLER, H. S.; SANQUETTA, C. R.; ARCE, J. E. O estado da arte na estimativa de biomassa e carbono em formações florestais. **Floresta**, v. 38, n. 1, p. 185–206, 2008. Disponível em: <http://dx.doi.org/10.5380/rf.v38i1.11038>.

SMALL, D. Flattening gamma: radiometric terrain correction for SAR imagery. **IEEE Transactions on Geoscience and Remote Sensing**, v. 49, n. 8, p. 3081–3093, 2011. Disponível em: <https://doi.org/10.1109/TGRS.2011.2120616>.

SOMOGYI, Z.; CIENCIALA, E.; MÄKIPÄÄ, R.; MUUKKONEN, P.; LEHTONEN, A.; WEISS, P. Indirect methods of large-scale forest biomass estimation. **European Journal of Forest Research**, v. 126, n. 2, p. 197–207, 2007. Disponível em: <https://doi.org/10.1007/s10342-006-0125-7>.

SOUSA, P. A. B.; BORGES, R. S. A. T.; DIAS, R. R. Atlas do Tocantins - subsídios ao planejamento da gestão territorial. Palmas: SEPLAN, 2012.

SANDEN, V.D. J. J. **Radar remote sensing to support tropical forest management**. 330p. Tese (Doutorado) - Wageningen Agricultural University, Wageningen, 1997.

VASHUM, T. K.; JAYAKUMAR, S. Methods to estimate above-ground biomass and carbon stock in natural forests: a review. **Journal of Ecosystem & Ecography**, v. 2, n. 4, 2012. Disponível em: <https://doi.org/10.4172/2157-7625.1000116>.

VREUGDENHIL, M.; WAGNER, W.; BAUER-MARSCHALLINGER, B.; PFEIL, I.; TEUBNER, I.; RÜDIGER, C.; STRAUSS, P. Sensitivity of Sentinel-1 backscatter to vegetation dynamics: an austrian case study. **Remote Sensing**, v. 10, n. 9, e1396, 2018. Disponível em: <https://doi.org/10.3390/rs10091396>.

WANG, J.; XIAO, X.; BAJGAIN, R.; STARKS, P.; STEINER, J.; DOUGHTY, R. B.; CHANG, Q. Estimating leaf area index and aboveground biomass of grazing pastures using Sentinel-1, Sentinel-2 and Landsat images. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 154, p. 189–201, 2019. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2019.06.007>.

WATZLAWICK, L. F.; KIRCHNER, F. F.; SANQUETTA, C. R. Estimativa de biomassa e carbono em floresta com araucaria utilizando imagens do satélite Ikonos II. **Ciência Florestal**, v. 19, n. 2, p. 169–181, 2009. Disponível em: <https://doi.org/10.5902/19805098408>.

WOODHOUSE, I. H. **Introduction to microwave remote sensing**. Boca Raton: CRC Press, 2006. 400p.

WOODHOUSE, I. H.; MITCHARD, E. T. A.; BROLLY, M.; MANIATIS, D.; RYAN, C. M. Radar backscatter is not a “direct measure” of forest biomass. **Nature Climate Change**, v. 2, n. 8, p. 556–557, 2012. Disponível em: <https://doi.org/10.1038/nclimate1601>.

ZIMBRES, B.; RODRÍGUEZ-VEIGA, P.; SHIMBO, J. Z.; DA CONCEIÇÃO BISPO, P.; BALZTER, H.; BUSTAMANTE, M.; ROITMAN, I.; HAIDAR, R.; MIRANDA, S.; GOMES, L.; ALVIM CARVALHO, F.; LENZA, E.; MARACAHIPES-SANTOS, L.; ABADIA, A. C.; DO PRADO JÚNIOR, J. A.; MENDONÇA MACHADO, E. L.; DIAS GONZAGA, A. P.; DE CASTRO NUNES SANTOS TERRA, M.; DE MELLO, J. M.; SOARES SCOLFORO, J. R.; RODRIGUES PINTO, J. R.; ALENCAR, A. Mapping the stock and spatial distribution of aboveground woody biomass in the native vegetation of the Brazilian Cerrado biome. **Forest Ecology and Management**, v. 499, e119615, 2021. Disponível em: <https://doi.org/10.1016/j.foreco.2021.119615>.