



UNIVERSIDADE FEDERAL DE SERGIPE

PRÓ-REITORIA DE PÓS-GRADUAÇÃO E PESQUISA

NÚCLEO DE PÓS-GRADUAÇÃO EM RECURSOS HÍDRICOS

KARINA MILAGRES NEVES

**ESTIMATIVA DE BIOMASSA FLORESTAL INTEGRANDO DADOS LANDSAT-8 E
FOTOGAMETRIA AÉREA DIGITAL EM DIFERENTES ESCALAS: UM ESTUDO
DE CASO EM UMA BACIA HIDROGRÁFICA NO BIOMA MATA ATLÂNTICA**

São Cristóvão – SE

2021

KARINA MILAGRES NEVES

**ESTIMATIVA DE BIOMASSA FLORESTAL INTEGRANDO DADOS LANDSAT-8 E
FOTOGRAMETRIA AÉREA DIGITAL EM DIFERENTES ESCALAS: UM ESTUDO
DE CASO EM UMA BACIA HIDROGRÁFICA NO BIOMA MATA ATLÂNTICA**

Dissertação apresentada ao
Núcleo de Pós-Graduação em
Recursos Hídricos como um dos
requisitos para obtenção do título
de Mestre em Recursos Hídricos.

Orientador: Prof. Dr. André Quintão de Almeida

Coorientador: Prof. Dr. Fábio Guimarães Gonçalves

SÃO CRISTÓVÃO

2021

KARINA MILAGRES NEVES

**ESTIMATIVA DE BIOMASSA FLORESTAL INTEGRANDO DADOS LANDSAT-8 E
FOTOGRAMETRIA AÉREA DIGITAL EM DIFERENTES ESCALAS: UM ESTUDO
DE CASO EM UMA BACIA HIDROGRÁFICA NO BIOMA MATA ATLÂNTICA**

Dissertação apresentada ao Núcleo de Pós-Graduação em Recursos Hídricos como um dos requisitos para obtenção do título de Mestre em Recursos Hídricos.

APROVADA: 19 de maio de 2021



Documento assinado digitalmente
ANDRE QUINTAO DE ALMEIDA
Data: 13/05/2022 18:57:19-0300
Verifique em <https://verificador.itl.br>

Orientador: Prof. Dr. André Quintão de Almeida
Programa de Pós-Graduação em Recursos Hídricos

Prof. Dr. Antônio Heriberto de Castro Teixeira
Programa de Pós-Graduação em Recursos Hídricos

Prof. Dr. Jerônimo Boelsums Barreto Sansevero
Universidade Federal Rural do Rio de Janeiro

Coorientador: Dr. Fábio Guimarães Gonçalves
Canopy Remote Sensing Solutions

SÃO CRISTÓVÃO

2021

FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECA CENTRAL
UNIVERSIDADE FEDERAL DE SERGIPE

N51e Neves, Karina Milagres
Estimativa de biomassa florestal integrando dados Landsat-8 e
fotogrametria aérea digital em diferentes escalas : um estudo de
caso em uma bacia hidrográfica no bioma Mata Atlântica / Karina
Milagres Neves ; orientador André Quintão de Almeida. – São
Cristóvão, SE, 2021.

99 f. : il.

Dissertação (mestrado em Recursos Hídricos) – Universidade
Federal de Sergipe, 2021.

1. Recursos hídricos. 2. Biomassa florestal. 3. Levantamentos
florestais. 4. Ciclo do carbono. 5. Sensoriamento remoto. 6. Modelos
matemáticos. 7. Bacias hidrográficas – Sergipe. 8. Poxim, Rio, Bacia
(SE). I. Redução de Emissões por Desmatamento e Degradação
Florestal (Programa). II. Almeida, André Quintão, orient. III. Título.

CDU 556.18:630:528.8(813.7)

AGRADECIMENTOS

Agradeço a Deus por me guardar, conceder sabedoria e saúde ao longo deste processo e me dar forças para continuar e concluir mais um ciclo.

Aos meus pais, Carmem e Cláudio, por me apoiarem durante todos os momentos e serem exemplo de força e dedicação.

Aos meus irmãos amados, Kamilla e Fellipe, por alegrarem a minha vida. À Neuzinha pelos cuidados e orações.

Ao meu noivo, César, pelo carinho, incentivo e por estar sempre ao meu lado.

Ao professor André Quintão, pela orientação e por compartilhar tanto conhecimento durante essa parceria. Agradeço a paciência, a confiança, a amizade, as oportunidades e todo o apoio dedicado, principalmente, durante esse período de pandemia.

Ao Dr. Fábio Gonçalves, pela co-orientação, oportunidade, suporte e preciosas considerações para o desenvolvimento do trabalho.

A Universidade Federal de Sergipe pela oportunidade. Ao Programa de Pós-Graduação em Recursos Hídricos e a todos os seus professores, por proporcionarem os ensinamentos adquiridos. A Fundação de Apoio à Pesquisa e Extensão de Sergipe pela bolsa de estudos.

A todos professores da Pós-Graduação pelo conhecimento transmitido.

Ao Weslei Santos pela contribuição do decorrer da pesquisa.

Aos membros da banca de avaliação por ter aceitado o convite e contribuírem para o aprimoramento deste trabalho.

Agradeço ainda à turma do PRORH e aos meus amigos que ao longo desta etapa me encorajaram e me apoiaram. Em especial a Angelis, Karen, Rosa Helena e Stéphanie.

A todos aqueles que, mesmo que eu tenha esquecido de mencionar, contribuíram para a conclusão de mais uma etapa.

RESUMO

A estimativa de biomassa acima do solo (BAS) é essencial para orientar as ações de programas de redução de desmatamento, degradação e o monitoramento global do ciclo do carbono. Nesse contexto, é de extrema importância o desenvolvimento de modelos de estimativa de BAS confiáveis e consistentes para o monitoramento. Avanços recentes na combinação de dados tridimensionais e multiespectrais obtidos por Sensoriamento Remoto tem obtido resultados promissores para melhorar a capacidade em estimar a BAS em largas escalas, no entanto, ainda não foram observados estudos analisando melhorias em florestas secundárias de Mata Atlântica. Este estudo teve como principal objetivo estimar a BAS de fragmentos florestais de Mata Atlântica, por imagem multiespectral e por produtos 3D obtidos pela fotogrametria aérea digital (FAD). O segundo objetivo foi desenvolver a abordagem multiescalar para a estimativa de BAS utilizando inventário florestal, FAD e Landsat-8 (L8), para áreas de floresta da bacia hidrográfica do rio Poxim-SE. Inicialmente, um inventário florestal foi conduzido em 30 parcelas, 0,25 ha cada, para estimar a BAS. Para a estimativa de BAS a partir de imagem multiespectral, foram selecionados dados orbitais multiespectrais do sensor OLI do satélite L8. As bandas espectrais, os índices de vegetação e as métricas de textura do L8 foram usadas como variáveis preditoras para a modelagem. Para a obtenção dos dados 3D de FAD, foi realizado um voo com uma aeronave remotamente pilotada (ARP), posteriormente gerado uma nuvem tridimensional de pontos e um modelo digital do terreno (MDT) para a sua normalização. Métricas de Fourier e métricas tradicionais baseadas na altura foram extraídas para cada parcela, e utilizadas como variáveis preditoras. A estimativa de BAS foi realizada pelo ajuste de regressão linear múltipla. Para a modelagem, foram consideradas três fontes de dados, L8, FAD e a combinação (L8 + FAD). O modelo obtido usando dados tridimensionais FAD foi utilizado como BAS de referência dos fragmentos estudados, aumentando o número de parcelas representativas para a área. Para a estimativa de BAS de forma multiescalar, a nível de bacia, foi realizado ajuste de regressão linear múltipla entre obtidos pelo modelo a partir de FAD selecionado e as variáveis preditoras dos dados espectrais do L8. Por fim, o modelo de BAS multiescalar foi utilizado para estimar a BAS das áreas de florestas presentes na bacia hidrográfica do rio Poxim-SE. O modelo baseado na combinação de dados (L8 + FAD) teve melhor desempenho nas estimativas, R^2 de 0,96 e RMQE de 7,46 Mg ha⁻¹ (18,1%). O erro foi 24% inferior as estimativas feitas com dados L8 e FAD de forma individual. Considerando a modelagem para toda a área florestal analisada, observou-se uma leve superestimação dos valores de BAS nos modelos a partir de L8 e L8+FAD. Os resultados indicaram que a combinação de informações de sensoriamento remoto multiespectral e tridimensional aumentou a precisão das características do BAS em nível de parcela. No entanto, considerando todo o trecho de fragmentos florestais secundários analisados, os dados multiespectrais de L8 causaram uma superestimação dos valores de BAS. Em nível de bacia, o modelo multiescalar apresentou um desempenho com R^2 de 0,84 e RMQE de 15,9 Mg ha⁻¹ (33,7%). As áreas de florestas de Mata Atlântica da bacia do Poxim apresentaram uma BAS média de 46,51 Mg ha⁻¹. Os dados de FAD apresentaram potencial para sua utilização como referência para o ajuste de modelos de estimativa de BAS a partir de dados multiespectrais. O desempenho da estimativa de BAS foi consistente em todos os locais e a abordagem de dimensionamento em multiescalar produziu um mapa de BAS para áreas de floresta da bacia do rio Poxim.

Palavras-chave: Carbono. REDD+. *Structure from Motion*. Sensoriamento Remoto. Fourier.

ABSTRACT

The estimation of aboveground biomass (AGB) is essential to guide the actions of programs to reduce deforestation, degradation and the global monitoring of the carbon cycle. In this context, it is extremely important to develop reliable and consistent AGB estimation models for monitoring. Recent advances in the combination of three-dimensional and multispectral data obtained by Remote Sensing have obtained promising results to improve the ability to estimate AGB at large scales, however, studies analyzing improvements in Atlantic Brazilian Forest secondary forests have not yet been observed. The main objective of this study was to estimate the AGB of forest fragments of the Atlantic Brazilian Forest, by multispectral imaging and by 3D products obtained by digital aerial photogrammetry (DAP). The second objective was to develop a multiscale approach to estimate AGB using forest inventory, DAP and Landsat-8 (L8), for the fragments of the Poxim-SE river basin. Initially, a forest inventory was conducted in 30 plots, 0.25 ha each, to estimate AGB values. To estimate AGB from a multispectral image, multispectral orbital data from the L8 satellite OLI sensor were selected and vegetation indices and texture metrics were calculated for each plot. Spectral bands, vegetation indices and texture metrics were used as predictor variables for modeling. To obtain the 3D DAP data, a flight with a Unmanned Aerial Vehicles imagery (UAV) was performed, later a 3D point cloud and a digital terrain model (DTM) were generated for its normalization. Fourier metrics and traditional height-based metrics were extracted for each plot, and used as predictor variables. AGB estimation was performed by multiple linear regression fit. For the modeling, three data sources were considered, L8, DAP-UAV and the combination (L8 + DAP-UAV). The model obtained using three-dimensional DAP-UAV data was used as a reference AGB of the studied fragments, increasing the number of representative plots for the area. For the estimation of multiscale AGB, at the basin level, a multiple linear regression adjustment was performed between the obtained by the model from the selected DAP-UAV and the predictor variables of the spectral data of L8. Finally, the multiscale AGB model was used to estimate the AGB of forest areas present in the Poxim-SE river basin. The model based on the combination of L8 and DAP data (L8 + DAP-UAV) had better performance in the estimates, R^2 of 0.96 and RMSE of 7.46 Mg ha⁻¹ (18.1%). The error was 24% smaller than estimates made with L8 and DAP-UAV data individually. Considering the modeling for the entire forest area analyzed, a slight overestimation of the BAS values was observed in the models from L8 and L8+DAP-UAV. The results indicated that the combination of multispectral and three-dimensional remote sensing information increased the accuracy of plot-level AGB features. However, considering the entire stretch of secondary forest fragments analyzed, the L8 multispectral data caused an overestimation of the AGB values. At the basin level, the multiscale model performed with R^2 of 0.84 and RMSE of 15.9 Mg ha⁻¹ (33.7%). The Atlantic Brazilian Forest areas of the Poxim basin had an average AGB of 46.51 Mg ha⁻¹. The DAP-UAV data showed potential to be used as a reference for the adjustment of biomass estimation models from multispectral data. The performance of the AGB estimation was consistent across all sites and the multiscale scaling approach to the AGB estimation produced a biomass map for the forest fragments of the Poxim River basin.

Keywords: Carbon. REDD +. SfM. *Structure from Motion*. Remote Sensing. Fourier.

LISTA DE TABELAS

Tabela 1 – Características das bandas espectrais do satélite Landsat-8.....	20
Tabela 2 – Medidas de textura calculadas no estudo a partir de dados do satélite Landsat-8.	25
Tabela 3 – Resumo das características das 30 parcelas de inventário amostradas nos fragmentos florestais de Mata Atlântica da bacia do rio Poxim, Sergipe.	37
Tabela 4 – Erros de mensuração calculados para as 30 parcelas localizadas nos fragmentos florestais de Mata Atlântica da bacia do rio Poxim, Sergipe.	38
Tabela 5 – Equações alométricas utilizadas no cálculo da biomassa acima do solo.	38
Tabela 6 – Equações alométricas alternativas utilizadas para o cálculo da incerteza da biomassa.	39
Tabela 7 – Incertezas em nível de parcela nas estimativas de biomassa acima do solo nos fragmentos secundários de Mata Atlântica da bacia do rio Poxim, Sergipe.	39
Tabela 8 – Valores representativos da banda <i>pixel_qa</i> do produto de Landsat-8.....	40
Tabela 9 – Data de aquisição das imagens do produto de Landsat-8.....	41
Tabela 10 – Índices de vegetação calculados a partir de dados do sensor OLI do satélite Landsat-8.	44
Tabela 11 – Métricas de estrutura extraídas da nuvem de pontos derivada de FAD.	50
Tabela 12 – Resultado das estatísticas do ajuste dos modelos de semivariogramas experimentais entre os pontos de grade (50 m x 50 m) de BAS_{IF-FAD}	54
Tabela 13 – Estatísticas descritivas da biomassa aérea acima do solo estimada para 30 parcelas de inventário florestal em fragmentos florestais de Mata Atlântica da bacia do rio Poxim, Sergipe.	58
Tabela 14 – Resultado das estatísticas dos modelos selecionados, dados de ajuste e validação, para a estimativa de BAS pelas diferentes abordagens.	59
Tabela 15 – Distribuição por classe da biomassa acima do solo estimada pelas abordagens BAS_{IF-L8} , BAS_{IF-FAD} e $BAS_{IF-L8+FAD}$ nos fragmentos florestais de Mata Atlântica da bacia do rio Poxim, Sergipe.	68
Tabela 16 – Estatísticas descritivas da biomassa acima do solo estimada por BAS_{IF-FAD} para 40 parcelas selecionadas em relação com as 30 parcelas de inventário	

florestal nos fragmentos florestais secundários de Mata Atlântica da bacia do rio Poxim, Sergipe.....	69
Tabela 17 – Resultado das estatísticas dos dados de ajuste e validação, do modelo multiescalar para a estimativa de BAS nos fragmentos florestais secundários de Mata Atlântica da bacia do rio Poxim, Sergipe.....	70
Tabela 18 – Distribuição da BAS para as áreas de floresta de Mata Atlântica da bacia do rio Poxim, Sergipe.....	78

LISTA DE FIGURAS

Figura 1 – Fluxograma geral para estimativa da biomassa acima do solo nos fragmentos florestais de Mata Atlântica.	32
Figura 2 – Mapa de localização da (A) área original do Bioma Mata Atlântica no Brasil e (B) bacia hidrográfica do rio Poxim no estado de Sergipe.	33
Figura 3 – Localização dos fragmentos florestais de Mata Atlântica analisados na bacia hidrográfica do rio Poxim-SE.....	35
Figura 4 – Localização das 30 parcelas de inventário florestal mensuradas na área de estudo durante o período de agosto a outubro de 2018.....	36
Figura 5 – Composição (A) colorida (bandas azul, verde e vermelho) e (C) falsa cor (bandas NIR, vermelho e verde) de imagens Landsat 8 da bacia hidrográfica do rio Poxim-SE, com destaque nos fragmentos florestais de Mata Atlântica (B e D).	42
Figura 6 – Fluxograma de processos realizados nas imagens Landsat-8.....	45
Figura 7 – Ortomosaico com composição colorida RGB, Modelo Digital do Terreno (MDT), nuvem de pontos e nuvem de pontos normalizada, produzidos por FAD para os fragmentos secundários de Mata Atlântica da bacia do rio Poxim, Sergipe.	48
Figura 8 – Parcelas de biomassa selecionadas no mapa de referência BAS_{IF-FAD} ao longo dos fragmentos florestais de Mata Atlântica da bacia do rio Poxim, Sergipe.	55
Figura 9 – Áreas de florestas de Mata Atlântica mapeadas ao longo da bacia do rio Poxim, Sergipe.	56
Figura 10 – Biomassa estimada pelas abordagens de estimativa direta <i>versus</i> observado por inventário florestal para as 30 parcelas. Gráficos de dispersão a partir dos dados de ajuste e histogramas com a distribuição dos valores RMQE obtidos no procedimento de validação cruzada para as abordagens, BAS_{IF-L8} (A e B), BAS_{IF-FAD} (C e D), $BAS_{IF-L8+FAD}$ (E e F). Os valores de p são para o teste F de Graybill.	63
Figura 11 – Ortomosaico com composição cromática RGB produzido utilizando produtos FAD (A); Mapas de estimativa de BAS (50 m x 50 m) das abordagens BAS_{IF-L8} (B), BAS_{IF-FAD} (C), $BAS_{IF-L8+FAD}$ (D) nos fragmentos florestais de Mata Atlântica da bacia do rio Poxim, Sergipe. O gráfico <i>violin plot</i> representa a distribuição das estimativas de BAS entre os modelos.	67
Figura 12 – Gráfico de dispersão a partir dos dados de ajuste e histogramas com a distribuição dos valores RMQE obtidos no procedimento de validação cruzada para a abordagem multiescalar $BAS_{IF-FAD-L8}$ e valores de referência BAS_{IF-FAD}	71

Figura 13 – Gráficos de dispersão a partir dos dados de ajuste para das estimativas de biomassa do modelo multiescalar $BAS_{IF-FAD-L8}$ e parcelas de inventário florestal.	72
Figura 14 – Mapa de estimativa de biomassa acima do solo (50 m x 50 m) para a o método direto BAS_{IF-L8} (A) e multiescalar $BAS_{IF-FAD-L8}$ (B) nos fragmentos florestais de Mata Atlântica da bacia do rio Poxim, Sergipe. O gráfico de <i>violin plot</i> representa a distribuição dos valores da estimativa de biomassa dos respectivos modelos.	73
Figura 15 – Mapa de estimativa de BAS (50 m x 50 m) em áreas de florestas de Mata Atlântica da bacia do rio Poxim, Sergipe. Os zooms (B, C, D e E) na figura demonstram as variações da BAS. O gráfico de <i>violin plot</i> representa a distribuição dos valores de BAS.	77
Figura 16 – Distribuição da BAS para áreas de florestais de Mata Atlântica de acordo com a elevação da bacia do rio Poxim, Sergipe. O gráfico de <i>violin plot</i> representa a distribuição dos valores de BAS de acordo com as classes de elevação.	79

SUMÁRIO

1	INTRODUÇÃO	13
1.1	OBJETIVOS.....	17
1.1.1	Objetivo Geral.....	17
1.1.2	Objetivos Específicos	17
2	REVISÃO DA LITERATURA.....	18
2.1	ESTIMATIVAS DE BIOMASSA FLORESTAL.....	18
2.2	LANDSAT	19
2.2.1	Índices de vegetação.....	21
2.2.2	Medidas de textura	24
2.3	FOTOGRAMETRIA AÉREA DIGITAL	26
2.4	INTEGRAÇÃO DE DADOS 3D E DADOS ORBITAIS	29
3	MATERIAL E MÉTODOS.....	31
3.1	LOCALIZAÇÃO E CARACTERIZAÇÃO DA ÁREA DE ESTUDO.....	33
3.1.1	Bacia hidrográfica do rio Poxim-SE	33
3.1.2	Fragmentos de Mata Atlântica	34
3.2	INVENTÁRIO FLORESTAL.....	36
3.2.1	Dados de inventário florestal	36
3.2.2	Estimativa da biomassa acima do solo e incertezas associadas.....	38
3.3	DADOS DE LANDSAT-8	40
3.3.1	Aquisição e pré-processamento das imagens	40
3.3.2	Índices de vegetação.....	43
3.3.3	Medidas de textura	45
3.4	DADOS DE FOTOGRAMETRIA AÉREA DIGITAL.....	46
3.4.1	Aquisição das fotografias aéreas.....	46
3.4.2	Processamento fotogramétrico e avaliação dos produtos	46
3.4.3	Métricas FAD derivadas das nuvens de pontos.....	49

3.5	ESTIMATIVA DE BAS PARA OS FRAGMENTOS FLORESTAIS	51
3.5.1	Método direto.....	51
3.5.2	Método multiescalar.....	54
3.5.3	Estimativa de BAS para as áreas de floresta da bacia do rio Poxim	56
4	RESULTADOS E DISCUSSÃO	58
4.1	ESTIMATIVA DE BAS POR INVENTÁRIO FLORESTAL.....	58
4.2	ESTIMATIVA DE BAS POR MÉTODO DIRETO	59
4.2.1	Variáveis selecionadas para os modelos de BAS.....	59
4.2.2	Abordagens de estimativa de BAS	62
4.3	ESTIMATIVA DE BAS POR MÉTODO MULTIESCALAR	69
4.4	ESTIMATIVA DE BAS PARA A BACIA	76
5	CONCLUSÕES	81
	REFERÊNCIAS.....	82

1 INTRODUÇÃO

As florestas tropicais desempenham papel fundamental no ciclo de carbono e na mitigação das mudanças climáticas globais, além de atuarem na regulação dos regimes climáticos locais, no ciclo hidrológico, na ciclagem de nutrientes, na proteção e conservação do solo e da água (BONAN, 2008; FERRAZ, *et al.*, 2014; HEROLD, *et al.*, 2019; LEITE-FILHO *et al.*, 2021; PAN *et al.*, 2011). Dentre as diferentes tipologias florestais, a Mata Atlântica brasileira é considerada uma das principais fontes de biodiversidade do mundo (RIBEIRO *et al.*, 2009). Embora apresente reduzida cobertura original, inferior a 13% (FUNDAÇÃO SOS MATA ATLÂNTICA; INPE, 2019), os fragmentos de Mata Atlântica apresentam estoques significativos de carbono (BECKNELL *et al.*, 2018; CHAZDON; URIARTE, 2016; MAGNAGO *et al.*, 2014), sendo importante conhecer e quantificar o seu estoque.

O carbono presente nas florestas normalmente é quantificado através da mensuração da biomassa acima do solo (BAS) (BRIENEN *et al.*, 2015; DUNCANSON *et al.*, 2021; GIBBS *et al.*, 2007). A quantificação precisa da BAS é fundamental para compreensão das respostas dos ecossistemas às mudanças climáticas globais (IPCC, 2006). Essa quantificação também, é requisito indispensável no fomento de programas que buscam proteger e aumentar os estoques de carbono florestais, como o programa Redução de Emissões por Desmatamento e Degradação de Florestas (REDD+) (IPCC, 2006; KACHAMBA *et al.*, 2016; RODRÍGUEZ-VEIGA *et al.*, 2017).

Tradicionalmente, a estimativa de BAS é realizada por mensurações de inventário florestal com base em amostragem em campo. Contudo, esse método demanda trabalho intensivo, árduo e demorado, com alto custo de implementação e monitoramento, além de ser complexo para uso em locais de difícil acesso (DUBE; MUTANGA, 2015a; PANDIT; TSUYUKI; DUBE, 2018). Portanto, essa abordagem torna-se inviável para grandes áreas e para monitoramento temporal contínuo, dificultando assim, o monitoramento dos impactos extremos das mudanças climáticas e de uso da terra sob a vegetação (LU, 2006; MUTANGA; ADAM; CHO, 2012).

As técnicas de sensoriamento remoto têm sido cada vez mais adotadas para estimativas da BAS e outras características da vegetação, como a altura, o diâmetro e o volume de madeira (ALMEIDA *et al.*, 2020; KUMAR; MUTANGA, 2017; LU, 2006). O sensoriamento remoto possibilita quantificar áreas maiores em menores intervalos

de tempo e custo, o que oferece um ganho considerável no suporte ao mapeamento da BAS em largas escalas, como no caso de florestas tropicais (BACCINI *et al.*, 2012; GONZÁLEZ-FERREIRO *et al.*, 2012; LU, 2006; SAATCHI *et al.*, 2011).

Os sensores ópticos multiespectrais, especialmente os da série Landsat, são frequentemente utilizados na estimativa de indicadores da vegetação (LU, 2006; DUBE, MUTANGA, 2015a; PANDIT; TSUYUKI; DUBE, 2018; WULDER *et al.*, 2012; ZARIN *et al.*, 2016). A vantagem do uso das imagens Landsat se deve às boas resoluções espacial (30m) e temporal (16 dias) e disponibilização gratuita. Além disso, apresentam longas séries históricas (desde a década de 80), possibilitando um monitoramento efetivo da extensão global e dos padrões de perturbação e recuperação da cobertura florestal (KENNEDY; YANG; COHEN, 2010; WULDER *et al.*, 2019; ZHU *et al.*, 2019). No entanto, os dados ópticos orbitais multiespectrais, como os da série Landsat, apresentam problemas de saturação em florestas com níveis elevados de BAS (DUBE; MUTANGA, 2015a; LU *et al.*, 2016, SARKER; NICHOL, 2011). Outra restrição apresentada, é quanto a aplicação da técnica em regiões com elevada nebulosidade (ASNER, 2001; LU *et al.*, 2012), como a região litorânea do Nordeste do Brasil.

Como alternativa às informações multiespectrais, o sensoriamento tridimensional tem sido muito utilizado. O sensor ativo *Light Detection and Ranging* (LiDAR) permite adquirir informações precisas e detalhadas sobre a estrutura vertical e do dossel de florestas (FENG *et al.*, 2017; GREGOIRE *et al.*, 2016; RANA *et al.*, 2014; RODRÍGUEZ-VEIGA *et al.*, 2017; TREUHAFT *et al.*, 2010). Apesar da qualidade da nuvem de pontos tridimensionais gerada, sua pequena cobertura espacial e o elevado custo de aquisição dos dados têm limitado a sua utilização em largas escalas (GONZÁLEZ-JARAMILLO; FRIES; BENDIX, 2019; KACHAMBA *et al.*, 2016).

Uma técnica que sido tem sido amplamente explorada ao longo das últimas duas décadas é a aquisição de dados tridimensionais por meio da fotogrametria aérea digital (FAD) obtidas a bordo de aeronaves remotamente pilotadas (ARPs) (GOODBODY *et al.*, 2019; IGLHAUT, *et al.*, 2019; KACHAMBA *et al.*, 2016; WALLACE *et al.*, 2016). A nuvem de pontos 3D resultante da FAD, fornece produtos de alta qualidade e maior densidade de pontos, semelhante aos dados LiDAR, podendo ser uma alternativa viável na estimativa da BAS em diversos tipos de formações florestais (CAO *et al.*, 2019; GUIMARÃES *et al.*, 2020; KACHAMBA *et al.*, 2016; OTA *et al.*,

2015; PULITI; SOLBERG; GRANHUS, 2019). Como pontos fortes, a FAD apresenta a capacidade de adquirir dados a partir de alturas elevadas e com alta velocidade de voo da ARP, aumentando a área mapeada e reduzindo o custo, quando comparado aos sensores LiDAR (GOODBODY *et al.*, 2019). Esse menor custo favorece o monitoramento contínuo da floresta, e, conseqüentemente, o planejamento, manejo e inventário florestal (ALMEIDA *et al.*, 2020; GOODBODY *et al.*, 2019; IGLHAUT *et al.*, 2019; KACHAMBA *et al.*, 2016).

As nuvens de pontos baseadas em FAD fornecem informações detalhadas sobre o do dossel da floresta (GOODBODY *et al.*, 2019; IGLHAUT *et al.*, 2019). Portanto, o sucesso da obtenção de FAD a bordo de uma ARP, depende de uma boa representação do modelo digital de terreno (MDT) para normalização da nuvem de pontos. Embora essa possa ser uma limitação a depender do tipo de vegetação e complexidade do terreno a ser implementado (ALMEIDA *et al.*, 2020; DIETMAIER *et al.*, 2019; HOBI *et al.*, 2015; WANG *et al.*, 2015; WHITE *et al.*, 2018; ZIELEWSKA-BÜTTNER *et al.*, 2016), em áreas fragmentadas e de florestas com menor densidade e não declivosas, tem sido observado que o MDT gerado pela própria FAD permite a representação do solo sob a vegetação de forma acurada (ALMEIDA *et al.*, 2020; DANDOIS *et al.*, 2013).

Em resposta à ampla disponibilidade de dados de sensoriamento remoto de várias fontes, pesquisas têm sido realizadas para combinar dados complementares de sensoriamento remoto para estimar atributos da vegetação e superar algumas limitações observadas em estudos com o uso de uma única fonte de dados de sensoriamento remoto (KOCH, 2010; NAVARRO *et al.*, 2019; PULITI *et al.*, 2015). Estudos sugerem que há aumento da performance da estimativa de BAS e outras características da vegetação em largas escalas quando usado os dados ópticos multiespectrais e tridimensionais de sensoriamento remoto de forma combinada (CHEN *et al.*, 2012; PHUA *et al.*, 2017; PULITI *et al.*, 2015; TUOMINEN *et al.*, 2017; ZHANG; LIN; 2017) ou adotando novas abordagens de escala com algoritmos sofisticados (BACCINI; ASNER, 2013; BISPO *et al.*, 2020; GONÇALVES, 2014; RÉJOU-MÉCHAIN *et al.*, 2019; SANTOS *et al.*, 2019; WANG *et al.*, 2020).

Embora os avanços das técnicas de sensoriamento remoto, não há pesquisas que avaliem o desempenho de dados FAD e multiespectrais para a Mata Atlântica na literatura. Em adição, poucos são os estudos de estimativa de BAS realizados em remanescentes florestais secundários de Mata Atlântica (ALMEIDA *et al.*, 2020).

Com base no exposto acima, a utilização integrada de informações do satélite Landsat-8 (2D) e da FAD-ARP (3D), como diferentes fontes de dados complementares, apresenta potencial para melhoria nas estimativas de BAS em florestas tropicais secundárias do tipo Mata Atlântica, ao conseguir suprir as limitações apontadas de cada fonte. Além disso, também se almeja que a BAS estimada por FAD-ARP possa servir como referência para o ajuste de modelos multiescalares a partir de dados de sensoriamento remoto multiespectral.

1.1 OBJETIVOS

1.1.1 Objetivo Geral

Avaliar o uso de diferentes fontes de dados de sensoriamento remoto, de forma individual e combinada, para estimar a biomassa acima do solo de fragmentos florestais de Mata Atlântica da bacia hidrográfica do rio Poxim-SE.

1.1.2 Objetivos Específicos

- Estimar e comparar os valores de biomassa acima do solo de cada parcela do inventário com dados: (i) do satélite Landsat-8, (ii) de fotogrametria aérea digital obtida por aeronave remotamente pilotada e (iii) a combinação das duas fontes de dados de sensoriamento remoto.
- Avaliar a abordagem multiescalar de estimativa de biomassa acima do solo utilizando inventário florestal, fotogrametria e Landsat-8, considerando todos os fragmentos analisados.
- Quantificar a biomassa acima do solo da área total de florestas de Mata Atlântica da bacia hidrográfica do rio Poxim-SE utilizando a abordagem multiescalar.

2 REVISÃO DA LITERATURA

2.1 ESTIMATIVAS DE BIOMASSA FLORESTAL

A biomassa acima do solo é definida como a matéria seca do componente lenhoso da vegetação acima do solo, advinda de árvores ou arbustos (DUNCANSON *et al.*; 2021; KUMAR; MUTANGA, 2017). As suas estimativas são a base central dos inventários de carbono e negociações internacionais do comércio de carbono (GIBBS *et al.*, 2007; HOUGHTON, 2005; KUMAR; MUTANGA, 2017). As maiores incertezas nessas estimativas estão relacionadas com as variações espaço-temporais e com a dinâmica da cobertura florestal em países tropicais (ERB *et al.*, 2018; MITCHARD *et al.*, 2012; ZOLKOS; GOETZ; DUBAYAH; 2013). Segundo DUNCANSON *et al.* (2021), para considerar os dados como de referência são necessários dados de alta qualidade com intuito de construir mapas de BAS precisos que permitam as validações dos modelos.

A BAS pode ser estimada de forma direta ou indireta. O método direto é bastante preciso, mas de difícil execução pois requer a derrubada de árvores para obtenção dos dados (KUMAR; MUTANGA, 2017; LU *et al.*, 2016). Por esse motivo, normalmente é feita uma seleção dos indivíduos arbóreos, pois além da natureza destrutiva, requer tempo, custos, podendo apresentar danos à flora (CHAVE; RIERA; DUBOIS, 2001; HOUGHTON; 2005).

Os métodos indiretos, menos precisos que o direto, utilizam equações alométricas associadas às variáveis obtidas por inventário em campo, como diâmetro, altura da árvore e a densidade da madeira (CHAVE *et al.*, 2005; BROWN *et al.*, 1989). O inventário florestal é bastante preciso para escalas locais, no entanto não é praticável para escalas regionais e nacionais. Além do custo elevado, as campanhas demandam tempo e permitem prover apenas uma amostra de toda população de interesse, não possibilitando acompanhar a dinâmica de crescimento e o desenvolvimento contínuo da vegetação (KUMAR; MUTANGA, 2017; MITCHELL; ROSENQVIST; MORA, *et al.*, 2017).

O sensoriamento remoto, técnica que possibilita a estimativa indireta de características da vegetação, vem ganhando destaque nos últimos anos (LU, 2006;

SAATCHI *et al.*, 2011). Por definição é um conjunto de técnicas que possibilitam a aquisição de informações sobre alvos na superfície terrestre, obtido pela interação da radiação eletromagnética (REM) com a superfícies, coletada por sensores (LORENZETTI, 2015). A grande vantagem de sua utilização é a possibilidade de estimativas de BAS em grandes áreas e áreas de difícil acesso, a menor custo e de forma mais rápida, promovendo suporte aos inventários florestais (DUBE; MUTANGA, 2015a; LU, 2006).

A obtenção de informações a partir do sensoriamento remoto varia de acordo com a plataforma de detecção (em solo, aerotransportada ou em satélite) e o princípio físico de coleta de dados. É possível obter informações em duas ou três dimensões dos alvos, com destaque para os dados provenientes de satélites ópticos orbitais multiespectrais (Landsat, MODIS, Sentinel), radar (InSAR, ALOS PALSAR, TerraSAR-X), LiDAR e FAD. Como resultado, a escolha do sensor a ser utilizado deve depender do objetivo e da escala da pesquisa.

Para Jayathunga *et al.* (2018), a ampla disponibilidade do sensoriamento remoto, com os avanços contínuos feitos em sensores, resoluções espectrais, espaciais e temporais permitiu seus usos em conjunto com dados de inventário para obtenção de informações precisas de parâmetros de vegetação em florestas. Destacam-se os dados orbitais multiespectrais Landsat históricos em larga escala para detecção de mudança do uso da terra ao longo do tempo (NAVARRO *et al.*, 2020), bem como os dados tridimensionais obtidos com FAD como soluções práticas para estimativa de BAS em áreas remotas, uma vez que nos permitem desenvolver um levantamento rápido e econômico de atributos florestais (ALMEIDA *et al.*, 2020; DANDOIS; ELLIS, 2013; GOODBODY *et al.*, 2019; IGLHAUT *et al.*, 2019; KACHAMBA *et al.*, 2016; PULITI *et al.*, 2015).

2.2 LANDSAT

A série de satélites Landsat, desenvolvida em colaboração entre a Administração Nacional da Aeronáutica e Espaço, em inglês *National Aeronautics and Space Administration* (NASA) e o Serviço Geológico dos Estados Unidos, em inglês

United States Geological Survey (USGS), fornece o maior registro multiespectral temporal consecutivo da superfície terrestre (USGS, 2019).

O primeiro satélite, nomeado de Landsat-1, foi lançado em 23 de julho de 1972 e permaneceu em órbita até 1978. O Landsat-2 foi lançado em 1975 e obteve imagens até 1982; o Landsat-3 foi lançado em 1978 e permaneceu em atividade até 1983; o Landsat-4 foi lançado em 1983 permaneceu em atividade até 1993; o Landsat-5 foi lançado em 1985 e permaneceu em atividade até 2013; o Landsat-6 foi lançado em 1993, porém não atingiu a órbita; o Landsat-7 foi lançado em 1999, mas desde 2003 tem apresentado falhas no *Scan Line Corrector* (SLC); o último satélite, o Landsat-8, foi lançado em 11 de fevereiro de 2013 e continua ativo (USGS, 2019).

O Landsat-8 apresenta a bordo dois instrumentos imageadores, o *Operational Land Imager* (OLI) e o *Thermal Infrared Sensor* (TIRS) (Tabela 1). Possui resolução radiométrica de 16 bits, resolução temporal de 16 dias e 185 km de faixa imageada. O sensor OLI possui nove bandas espectrais, com resolução espacial de 30m, exceto a banda 8 (pancromática) que possui resolução espacial de 15 m. O sensor TIRS abrange a faixa do infravermelho termal e apresenta duas bandas espectrais de ondas longas, com 100 m de resolução espacial (ROY *et al.*, 2014, USGS,2019).

Tabela 1 – Características das bandas espectrais do satélite Landsat-8.

Banda	Resolução Espectral (μm)
B1 – Costal	0,43 – 0,45
B2 – Azul	0,45 – 0,51
B3 – Verde	0,53 – 0,59
B4 – Vermelho	0,64 – 0,67
B5 – Infravermelho próximo (NIR)	0,85 – 0,88
B6 – Infravermelho médio 1 (SWIR 1)	1,57 – 1,65
B7 – Infravermelho médio 2 (SWIR 2)	2,11 – 2,29
B8 – Pancromática	0,50 – 0,68
B9 – Cirrus	1,36 – 1,38
B10 – Infravermelho termal 1	10,60 – 11,19
B11 – Infravermelho termal 2	11,50 – 12,51

O USGS é o responsável por gerenciar as estações terrestres, operações de processamento e distribuição de dados da missão Landsat. Uma coleção de produtos

Landsat são disponibilizados gratuitamente para apoiar estudos de mudanças na superfície da terra ao longo do tempo (USGS, 2019).

Por conta do grande arquivo de dados disponíveis gratuitamente, a série Landsat tornou-se uma das principais fontes de dados para estimativa indireta de biomassa florestal (LU *et al.*, 2016). As variáveis potenciais das imagens do Landsat incluem bandas espectrais individuais (Tabela 1), índices de vegetação, imagens transformadas e imagens texturais.

2.2.1 Índices de vegetação

Os Índices de Vegetação (IV) foram desenvolvidos para se relacionar estão relacionados com parâmetros biofísicos da vegetação (JENSEN, 2011). Os IV são obtidos através de combinações espectrais de duas ou mais bandas de um sensor realçando a influência espectral da superfície vegetada, e buscando ao mesmo tempo reduzir a contribuição do solo, ângulo zenital do sol, ângulo de visão do sensor e interferência atmosférica (LU, 2006; MOREIRA, 2003; MCDONALD; GEMMELL; LEWIS, 1998, HUETE *et al.*, 2002).

Segundo Lu *et al.* (2004), os principais IV normalmente se baseiam na relação entre os comprimentos de onda vermelho e infravermelho próximo, enfatizando a diferença entre a forte absorção da radiação eletromagnética vermelha e a forte reflexão da radiação infravermelha próxima. Dentre os IV, os principais encontrados na literatura são descritos abaixo:

O índice Razão Simples (*Simple ratio* - SR), proposto por Jordan (1969) foi o primeiro índice de vegetação desenvolvido. É um índice simples, descrito por a pela razão entre as reflectâncias nas bandas do infravermelho próximo e do vermelho.

O Índice de Vegetação por Diferença Normalizada (*Normalized Difference Vegetation Index* - NDVI), proposto por Rouse *et al.* (1973), é expresso como a diferença entre as reflectâncias nas bandas do infravermelho próximo e no vermelho normalizado pela soma das reflectâncias dessas bandas. Este índice separa a vegetação verde do solo exposto e é frequentemente usado em pesquisas relacionadas ao monitoramento regional e global do comportamento da vegetação.

No entanto, segundo Jensen (2011) é um índice muito sensível a variações do substrato sob o dossel, apresentando valores mais elevados em solos mais escuros.

O Índice de Vegetação Transformada (em inglês, *Transformed Vegetation Index* - TVI), desenvolvido por Deering (1975), foi proposto para modificar o NDVI, adicionando a 0,5 e a raiz quadrada do resultado para estabilizar a variância de modo a evitar valores negativos.

O Índice de Vegetação Ajustado ao Solo (em inglês, *Soil-Adjusted Vegetation Index* - SAVI), proposto por Huete (1988), foi estabelecido para minimizar a sensibilidade do NDVI ao solo, incorporando um fator de ajuste de solo constante L no denominador da equação NDVI.

O Índice de Diferença de Vegetação (em inglês, *Difference Vegetation Index* - DVI), proposto por Tucker (1979), é um índice simplificado sensível a mudanças no fundo do solo.

O Índice de Vegetação Ajustado ao Solo Modificado (em inglês, *Modified Soil-Adjusted Vegetation Indices 2* - MSAVI2), sugerido por Qi *et al.* (1994) é baseado em uma modificação do fator L do SAVI, se destinam a melhor corrigir o brilho do fundo do solo em diferentes condições de cobertura vegetal.

O Índice de Vegetação da Diferença Renormalizada (em inglês, *Renormalized Difference Vegetation Index* - RDVI), sugerido por Rougean e Breon (1995), foi desenvolvido para aproveitar a vantagem combinada do Índice de Vegetação por Diferença (DVI = NIR - Vermelho; Jordan, 1969) e do NDVI.

O Índice De Vegetação Ajustado ao Solo Otimizado (em inglês, *Optimized Soil Adjusted Vegetation Index* - OSAVI), proposto por RONDEAUX; STEVEN e BARET (1996), apresentou resultados satisfatórios na redução do ruído do solo em condições de baixa e alta cobertura de vegetação.

O Índice Global de Monitoramento Ambiental (em inglês, *Global Environment Monitoring Index* – GEMI), proposto por Pinty e Verstraete (1992), foi desenvolvido para aplicação em escala global, possibilitando a sua comparação entre ecossistemas diferentes e capaz de mapear grandes áreas.

O Índice de Estresse de Umidade (em inglês, *Moisture Spectral Index* – MSI), proposto por Hunt e Rock, (1989), foi desenvolvido como preditor do potencial da água no dossel da vegetação por meio de dados espectrais.

O Índice de Infravermelho por Diferença Normalizada (em inglês, *Normalized Difference Infrared Index* – NDII), foi proposto por Hardisky; Klemas e Smart (1983) para correlacionar a umidade da planta.

A Razão Simples Modificada (em inglês, *Modified Simple Ratio* – MSR), proposto por Chen (1996), é um aprimoramento do RDVI desenvolvido objetivando linearizar sua relação com os parâmetros biofísicos da vegetação.

2.2.2 Medidas de textura

A textura é uma característica usada para identificar objetos ou regiões de interesse em uma imagem, com base em uma função de variação local na imagem e também está relacionada à resolução espacial e ao tamanho dos objetos da cena dominante (HARALICK; SHANMUGAM; DINSTEIN, 1973). As feições texturais contém informações sobre a distribuição espacial das variações tonais dentro de uma banda, enquanto as feições espectrais descrevem a variação tonal das várias bandas de uma imagem (LOCK; KIRCHNER, 1997).

No sensoriamento remoto aplicado a vegetação, a textura da imagem é uma importante fonte de informação capaz de identificar diferentes aspectos da estrutura do povoamento florestal, incluindo densidade, idade, índice de área foliar em imagens de resolução espacial de média a alta (CHAMPION *et al.*, 2008). Para a representação das Medidas de textura (MT) e de atributos relacionados a ela, Haralick, Shanmugam e Dinstein (1973) propuseram a Matriz de Coocorrência de Níveis de Cinza (em inglês, *Grey Level Cooccurrence Matrix* – GLCM). A GLCM é uma matriz quadrada de dimensão igual a resolução radiométrica da imagem, calculada a partir de um vetor de deslocamento relativo (D, θ) que descreve a distribuição espacial de pares de nível de cinza separados pela distância D , medida em pixels ([1,0]; [1, -1]; [0,1]; [1,1]), na direção θ expressa por ângulos ($0^\circ, 45^\circ, 90^\circ$ e 135°).

Haralick, Shanmugam e Dinstein (1973), determinaram quatorze feições de textura que podem ser extraídas da matriz de co-ocorrência, sendo elas: segundo momento angular, energia, contraste, correlação, homogeneidade (ou momento diferencial inverso), soma da média, variância, soma da variância, diferença da variância, entropia, soma da entropia, diferença da entropia, informação de medidas de correlação e coeficiente de correlação máxima. Abaixo estão descritas as principais métricas observadas na literatura (ECKERT, 2012; LU, 2005; KELSEY; NEFF, 2014) conforme Haralick, Shanmugam e Dinstein (1973):

A métrica média (MT_M) avalia a tendência central dos valores dos níveis de cinza distribuídos na imagem. A variância (MT_V) é uma medida de dispersão que avalia os valores dos níveis de cinza em torno do valor médio. A homogeneidade (MT_H) mede a homogeneidade da imagem e assume valores grandes para diferenças de tons de cinza pequenos nos pares de elementos da imagem. O contraste (MT_C) é uma medida

da quantidade de variação local de níveis de cinza em uma imagem. A métrica segundo momento angular (MT_S) é uma medida da homogeneidade local dos níveis de cinza em uma imagem. A dissimilaridade (MT_D) mede o quanto os elementos são diferentes entre si e assume o maior valor quando a diferença entre eles é grande. A entropia (MT_E) ou grau de dispersão mede a aleatoriedade dos níveis de cinza.

Tabela 2 – Medidas de textura calculadas no estudo a partir de dados do satélite Landsat-8.

Média (MT_M)	$\sum_{i,j=0}^{N-1} iP_{i,j}$
Variância (MT_V)	$\frac{\sum_{ij} (x_{ij} - \mu)^2}{n-1}$
Homogeneidade (MT_H)	$\sum_{i,j=0}^{N-1} i \frac{P_{i,j}}{1+(i-j)^2}$
Contraste (MT_{CO})	$\sum_{i,j=0}^{N-1} iP_{i,j}(i-j)^2$
Dissimilaridade (MT_D)	$\sum_{i,j=0}^{N-1} iP_{i,j} i-j $
Segundo momento angular (MT_S)	$\sum_{i,j=0}^{N-1} iP_{i,j}^2$
Entropia (MT_E)	$\sum_{i,j=0}^{N-1} iP_{i,j}(-\ln P_{i,j})$

Em que: i, j é a linha e coluna; P_{ij} é o valor na célula i, j de uma janela móvel; N é número de linhas ou colunas, x_j = valor de proporção da j -ésima componente do pixel; μ_i = média na direção i ; μ_j = média na direção j ; σ_{2i} = variância de i ; σ_{2j} = variância de j .

Diversos estudos observaram que as métricas de textura têm a capacidade de aumentar a discriminação de informações espaciais e simultaneamente melhorar a estimativa de BAS (ECKERT, 2012; SARKER; NICHOL, 2011; DUBE; MUTANGA, 2015a; KELSEY; NEFF, 2014; 2015; LU, 2005).

Por exemplo, Sarker e Nichol (2011) estimaram a BAS com dados do sensor ALOS AVNIR-2, em uma região montanhosa e subtropical de Hong Kong, China, a partir das abordagens que incluíram a banda espectral simples, índices de vegetação, métricas de textura e relação de métricas de textura. Os resultados indicaram que a inclusão das texturas promoveu aumento na performance do modelo com R^2 de 0,58 para 0,76. Eckert (2012) estimou a BAS para uma floresta tropical em Madagascar,

usando medidas de textura derivadas do WorldView-2 e observou que estas se correlacionam mais com a BAS (valor de R^2 0,84 e RMQE de 6,8%) do que IV e as correlações foram mais fortes em áreas degradadas.

2.3 FOTOGRAMETRIA AÉREA DIGITAL

Nas duas últimas décadas, Aeronaves Remotamente Pilotadas (ARPs) acopladas com uma câmera digital têm sido amplamente utilizadas para coletar informações da vegetação. O uso de ARPs permite a aquisição de dados de altas resoluções, espacial e temporal, podendo suprir as limitações dos dados de satélites orbitais em condições de alta nebulosidade. Comparadas à resolução de imagens coletadas por aviões (resolução ~ metro) ou dados de satélite (resolução de 2 a 30 m), as imagens obtidas com câmeras aéreas a bordo de ARPs podem obter imagens com resoluções espaciais de 5 a 30 cm com voos em baixas alturas com relação ao alvo de interesse (LALIBERTE *et al.*, 2010; MATESE *et al.*, 2015)

O crescente número de estudos na estimativa de BAS utilizando ARPs para aquisição de imagens está relacionado à possibilidade de utilizar nuvem de pontos derivadas da fotogrametria aérea digital para construção de modelos tridimensionais semelhantes aos dados do Sistema de Varredura a Laser, em inglês *Light Detection and Ranging* (LiDAR), e com menor custo de aquisição (GOODBODY *et al.*, 2019; IGLHAUT *et al.*, 2019; KACHAMBA *et al.*, 2016; PULITI *et al.*, 2015).

A estimativa de nuvens de pontos 3D a partir de sequências de imagens bidimensionais é possibilitada pelos algoritmos: *Structure-from-Motion*, emparelhado com o algoritmo *Multi-View Stereo* (MVS) - habitualmente referido a todo processo como apenas SfM. Baseado na estereofotogrametria tradicional, o algoritmo SfM permite o processamento de imagens sobrepostas, sem a necessidade de informações pré-requisitos sobre localização e orientação da câmera, calibração da câmera e/ou pontos de referência pesquisados na cena (IGLHAUT *et al.*, 2019).

A primeira etapa do processo é descrita como transformação de característica invariante em escala, em inglês *Scale-Invariant Feature Transform* (SIFT). Os pontos correlacionados das fotos são extraídos automaticamente, as feições correspondentes entre fotos são identificadas e correlacionadas nas imagens. Em seguida, a coerência dos pontos correspondentes é verificada usando uma

reconstrução grosseira da geometria das imagens e a posição relativa dos pontos-correspondentes (IGLHAUT *et al.*, 2019; LOWE, 2004).

Dado um número suficiente de imagens e correspondências de pontos correspondentes, o SfM realiza ajustes de pacote para calcular simultaneamente poses e parâmetros da câmera e uma nuvem de pontos 3D esparsa da cena. O ajuste do pacote é resolvido usando valores de inicialização obtidos a partir de sequências de pontos correspondentes selecionados aleatoriamente e, complementarmente, parâmetros das câmeras e poses e um refinamento não linear. Em seguida, as saídas do SfM são dimensionadas e georreferenciadas com base nos pontos de controle, e/ou dados dos dispositivos de navegação da câmera ou de sua plataforma (IGLHAUT *et al.*, 2019). As poses da câmera e os parâmetros obtidos do SfM são então aplicados para gerar uma nuvem de pontos tridimensionais densificadas usando algoritmos MVS.

Com base nas nuvens de pontos 3D, é possível gerar Modelos Digitais de Superfície (MDS) e, após a filtragem da vegetação, Modelos Digitais de Terreno (MDT) de forma a representar a estrutura da floresta. Uma revisão para avaliar a crescente adoção da fotogrametria SfM na ciência florestal foi conduzida por IGLHAUT *et al.* (2019). Os autores verificaram que nos últimos cinco anos, 58 artigos científicos foram publicados utilizando a abordagem SfM a bordo de ARPs para obtenção de dados de sensoriamento remoto florestal com fotogrametria SfM.

Em áreas de floresta decídua em Maryland, Estados Unidos, Dandois e Ellis (2013) usaram algoritmos fotogramétricos de visão computacional SfM para extrair a estrutura do dossel e atributos espectrais baseados em imagens aéreas vermelho-verde-azul (RGB). DTMs e modelos de altura de dossel (CHMs) foram gerados a partir de nuvens de pontos usando procedimentos comumente aplicados a nuvens de pontos LiDAR. Os CHMs foram fortes preditores de alturas de árvores medidas em campo ($R^2 = 0,63-0,84$). Os resultados demonstraram que modelos 3D de nuvem de pontos de alta resolução espacial da estrutura da vegetação e a cor (RGB; vermelho-verde-azul) podem ser produzidos aplicando algoritmos de SfM e que a acurácia do modelo digital de terreno é influenciada pela inclinação do terreno, cobertura vegetal e pelo tipo de algoritmo de filtragem empregado.

Em uma floresta nativa de *Eucalyptus pulchella* na Austrália, Wallace *et al.* (2016), verificaram que a técnica de SfM a bordo do ARP quando comparado ao LiDAR, demonstrou ter requisitos operacionais semelhantes sendo ambas as técnicas

capazes de fornecer representações precisas da camada superior do dossel de florestas (altura da árvore erro quadrático médio de 0,92 m para LiDAR e 1,30 m para SfM). Ambas as tecnologias representaram em alta resolução as propriedades do terreno e as camadas baixas da vegetação em áreas de floresta relativamente esparsas. Contudo o SfM falhou ao mensurar a altitude do terreno em áreas de cobertura vegetal densa.

Em uma floresta tropical de Miombo no Malawi, Kachamba *et al.* (2016), investigaram um sistema ARP-FAD de asa fixa para estimativa de BAS em uma área potencial de pequeno e médio porte para projeto REDD +. A partir do algoritmo SfM testaram diferentes métodos para geração do DTM. Foram testados: a filtragem de solo supervisionada com base na classificação visual; filtragem supervisionada do solo com base em regressão logística; filtragem supervisionada do solo com base em regressão quantílica; filtragem não supervisionada do solo com base na missão *Shuttle radar topography mission* (SRTM) e filtragem não supervisionada do solo com base no algoritmo de rede irregular triangular progressiva (TIN). Os resultados indicaram que não há diferenças significativas ($p= 0,985$) entre os DTMs testados, exceto o baseado no SRTM. As estimativas de BAS apresentaram erros semelhantes à de estudos anteriores usando dados de LiDAR em florestas da região.

Em uma floresta tropical do Camboja, Ota *et al.* (2016), investigaram a capacidade do modelo de altura de copa derivado de fotogrametria aérea, usando a abordagem SfM, para estimar a BAS. O DTM foi calculado para os pontos derivados de SfM e derivados de LiDAR e as abordagens comparadas. Concluíram que a estimativa a partir de modelo de altura de copa derivado de FAD pode ser realizada com acurácia ($R^2= 0.79$) a partir da abordagem SfM.

Em um fragmento secundário de Mata Atlântica de Sergipe, Brasil, Almeida *et al.* (2020), exploraram produtos da fotogrametria aérea digital, métricas tradicionais e transformada de Fourier para estimar BAS e outras variáveis florestais de interesse para a área estudada. O modelo para a BAS explicou 93% das variações de biomassa (RMQE = 22,5%) demonstrando o potencial de uso da ferramenta para captar as características dessa floresta em área com dossel fragmentado. Os autores concluíram que a transformada de Fourier de perfis verticais, fornece um ganho significativo de precisão na estimativa de BAS, especialmente quando combinados com métricas tradicionais que descrevem a cobertura do dossel.

2.4 INTEGRAÇÃO DE DADOS 3D E DADOS ORBITAIS

Segundo Réjou-Méchain *et al.* (2019), a extrapolação de estimativas locais para estimativas regionais deve contar com dados de alta resolução como aqueles obtidos por LiDAR ou câmera aérea a bordo de ARPs baseados na fotogrametria, pois ambos os métodos apresentam capacidade para estimar BAS com precisão semelhante à medições de inventário. Esses dados de alta resolução quando incorporados a dados obtidos por satélites oferecem ganho em escala espacial, ou seja, possibilitam a estimativa para grandes áreas.

Em uma área de florestas mediterrâneas na região de Múrcia, Espanha, Durante *et al.* (2019), desenvolveram uma abordagem multiescalar (*upscaling*) para estimar BAS, a partir de dados LiDAR, calibrados com medições de inventário florestal a nível de parcela, índices derivados do sensor multiespectral MODIS e fatores topográficos. Uma validação independente realizada sobre o mapa final de BAS previsto mostrou um modelo estatisticamente robusto (R^2 de 0,70 e RMQE de 10,25 t.ha⁻¹), confirmando a aplicabilidade da extrapolação de medições de inventário para largas escalas. A metodologia proposta forneceu um custo-benefício e demonstrou ser descomplicada de atualizar o modelo, permitindo a geração de mapas em escalas de gestão concordantes com a complexidade da BAS.

Dos Santos *et al.* (2019) exploraram a integração de dados LiDAR multitemporais e imagens Landsat-8 visando a elaboração de uma metodologia para gerar mapas de BAS para o estado do Mato Grosso, Brasil. A abordagem *upscaling* adotada demonstrou o potencial do uso de imagens orbitais multiespectrais e dados LiDAR adquiridos em datas diferentes para estimativas em áreas florestais degradadas.

No Cerrado brasileiro, Bispo *et al.* (2020), combinando dados de inventário, dados LiDAR e imagens de satélite multiespectral e radar (Landsat-8 e ALOS-2/PALSAR-2), produziram o primeiro mapa de alta resolução para a região. Foi adotado o método de *upscaling* de dois estágios a partir de medições de inventário florestal até pontos de nuvens do aerotransportado LiDAR e de estimativas baseadas em LiDAR a imagens de satélite. Os modelos de *random forest* e *Jackknife* foram utilizados para selecionar as variáveis de sensoriamento remoto para estimar a BAS em larga escala. O estudo destacou a necessidade de usar sensoriamento remoto em

combinação com inventários de vegetação local para quantificar efetivamente a variação espacial do BAS em ecossistemas do Cerrado. Os autores observaram um forte relacionamento entre dados de inventário e variáveis obtidas pelo sensoriamento remoto (R^2 de 0,89 e RMQE de $7,58 \text{ Mg ha}^{-1}$).

Em uma área de mangue no nordeste da Ilha de Hainan, China, Wang *et al.* 2020, propuseram um método de *upscaling*, para estimativa de BAS, em diferentes escalas espaciais, usando dados de inventário, dados de LiDAR a bordo de ARP e imagens do Sentinel-2. Neste modelo, os dados do LiDAR-ARP foram usados como uma ponte linear para conectar as medições de inventário à cobertura *wall-to-wall* dos dados Sentinel-2. Os resultados indicaram que o método *upscaling* proposto apresentou melhor desempenho (R^2 de 0,62 e RMQE de $50,36 \text{ Mg ha}^{-1}$) quando comparado ao modelo que relacionava diretamente dados de inventário aos dados Sentinel-2 (R^2 de 0,52 e RMQE de $56,63 \text{ Mg ha}^{-1}$). Por meio de um método de extrapolação de tendência, também inferiram que, na área de estudo, o modelo proposto pode diminuir o número de amostras de inventário necessárias em aproximadamente 37% comparando com aqueles exigidos pelo método tradicional de inventário florestal.

3 MATERIAL E MÉTODOS

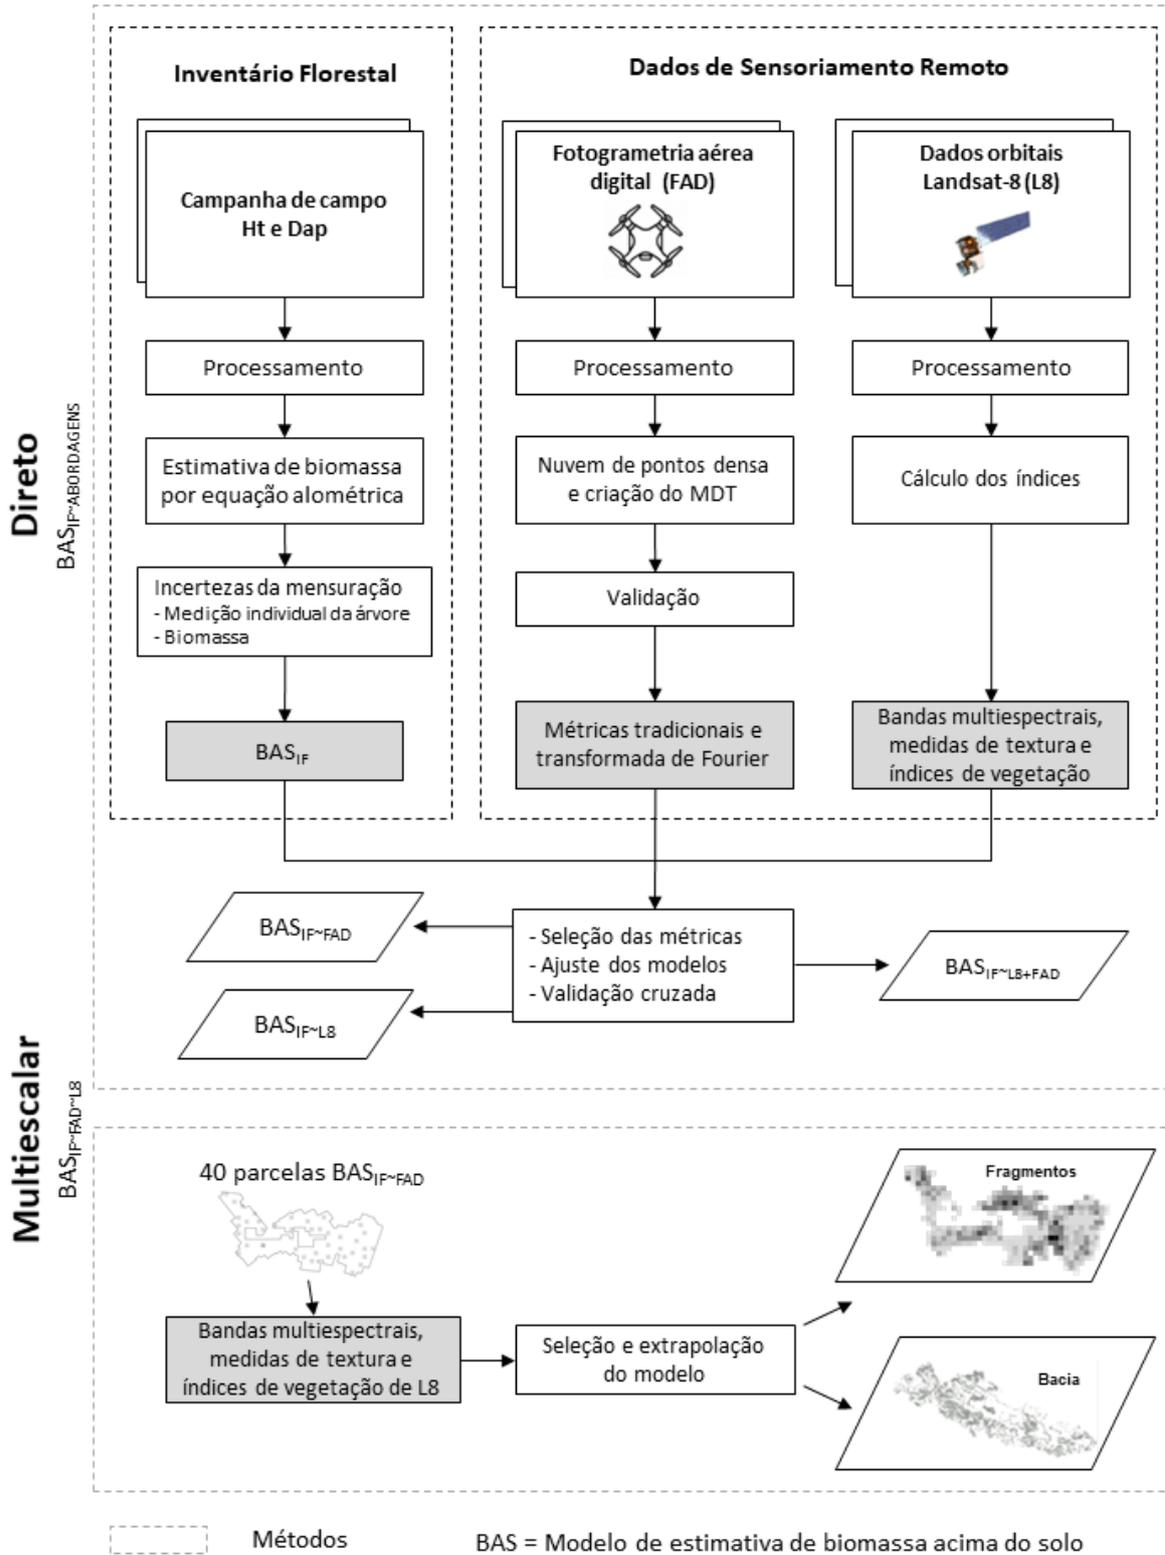
Para alcançar os objetivos propostos da pesquisa, foram utilizados dados coletados durante o inventário florestal da vegetação analisada; e, diferentes fontes e escalas de análises de produtos obtidos por sensoriamento remoto. Inicialmente, foi realizado o inventário florestal tradicional dos fragmentos florestais considerando-se 30 parcelas com 0,25 ha cada. Os valores de diâmetro (dap), densidade da madeira (ρ) e das alturas totais das árvores (ht) foram utilizados para estimar a BAS por equações alométricas existente na literatura.

Os erros de mensuração e alometria na estimativa de BAS foram estimados e propagados. Os produtos e métricas provenientes da FAD foram gerados para todos os fragmentos no mesmo período da campanha de inventário florestal. As medidas espectrais dos fragmentos florestais também foram obtidas de dados orbitais multiespectrais do sensor OLI do satélite Landsat-8. A partir dos dados de BAS obtidos por inventário florestal (BAS_{IF}) e de abordagens de sensoriamento remoto (imagens de satélites e FAD), equações de regressão foram ajustados para estimar a BAS de todos os fragmentos, denominada aqui por abordagem direta (inventário florestal ~ abordagens SR).

Em seguida, uma abordagem multiescalar (inventário florestal ~ FAD ~ Landsat-8) foi adotada para estimar os valores de BAS da vegetação em larga escala. Nesta abordagem multiescalar, os valores de BAS (variável dependente) foram obtidos pelo melhor modelo de regressão FAD (BAS_{IF-FAD}) e as variáveis preditoras dos dados multiespectrais do Landsat-8 (L8). Por fim, o modelo $BAS_{IF-FAD-L8}$ selecionado foi utilizado para estimar a BAS as áreas florestadas da bacia hidrográfica do rio Poxim-SE.

A Figura 1 apresenta as principais etapas executadas neste trabalho. A descrição de cada etapa será apresentada nas próximas seções.

Figura 1 – Fluxograma geral para estimativa da biomassa acima do solo nos fragmentos florestais de Mata Atlântica.



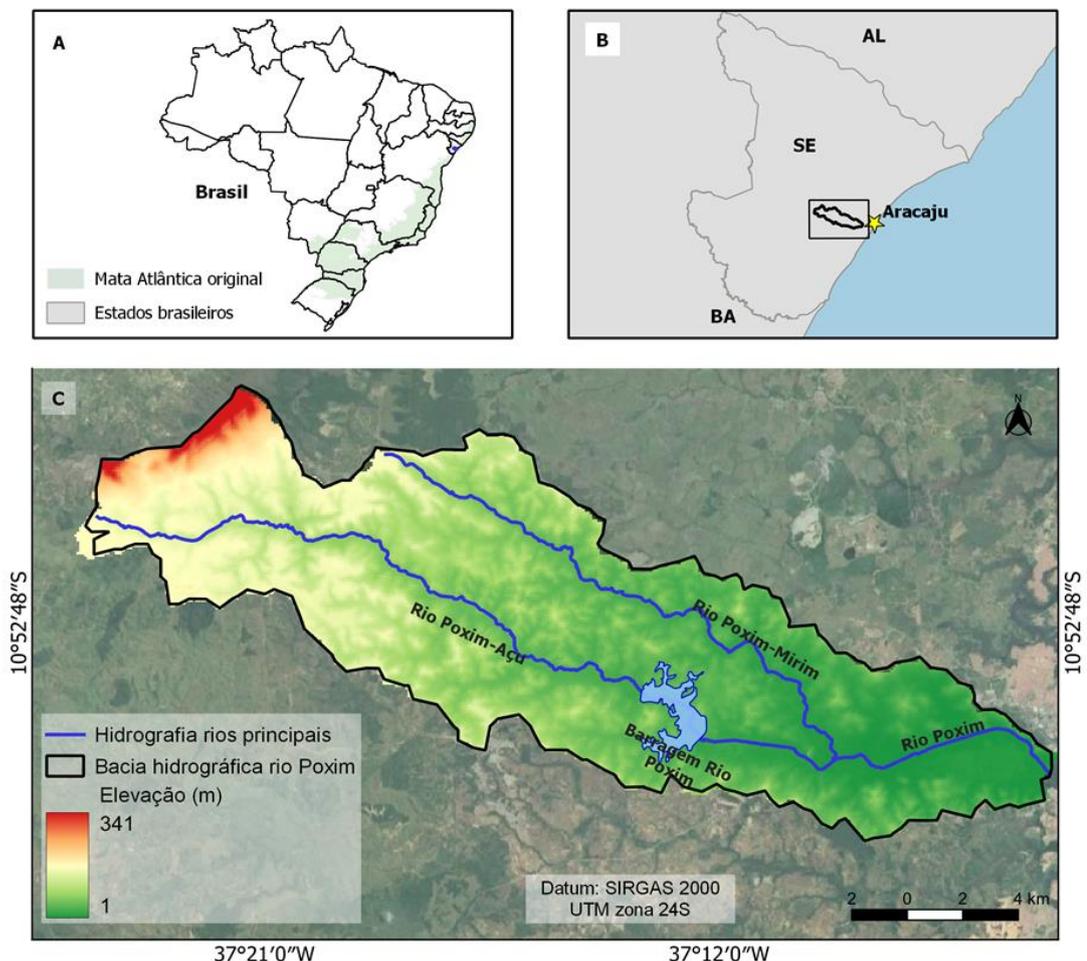
Fonte: Produção da autora.

3.1 LOCALIZAÇÃO E CARACTERIZAÇÃO DA ÁREA DE ESTUDO

3.1.1 Bacia hidrográfica do rio Poxim-SE

A bacia hidrográfica do rio Poxim encontra-se na porção Leste do Estado de Sergipe (Figura 2), abrangendo parte dos Municípios de Itaporanga d'Ajuda, Areia Branca, Laranjeiras, Nossa Senhora do Socorro, São Cristóvão e Aracaju. O rio Poxim é um dos principais afluentes do rio Sergipe e se destaca por fornecer um suprimento importante de água doce para a Grande Aracaju (DE AGUIAR NETTO *et al.*, 2013). Possui uma área total de aproximadamente de 240,18 km² e pertencente a bacia do rio Sergipe.

Figura 2 – Mapa de localização da (A) área original do Bioma Mata Atlântica no Brasil e (B) bacia hidrográfica do rio Poxim no estado de Sergipe.



Fonte: Produção da autora. A imagem de fundo corresponde ao Map data ©2016 Google.

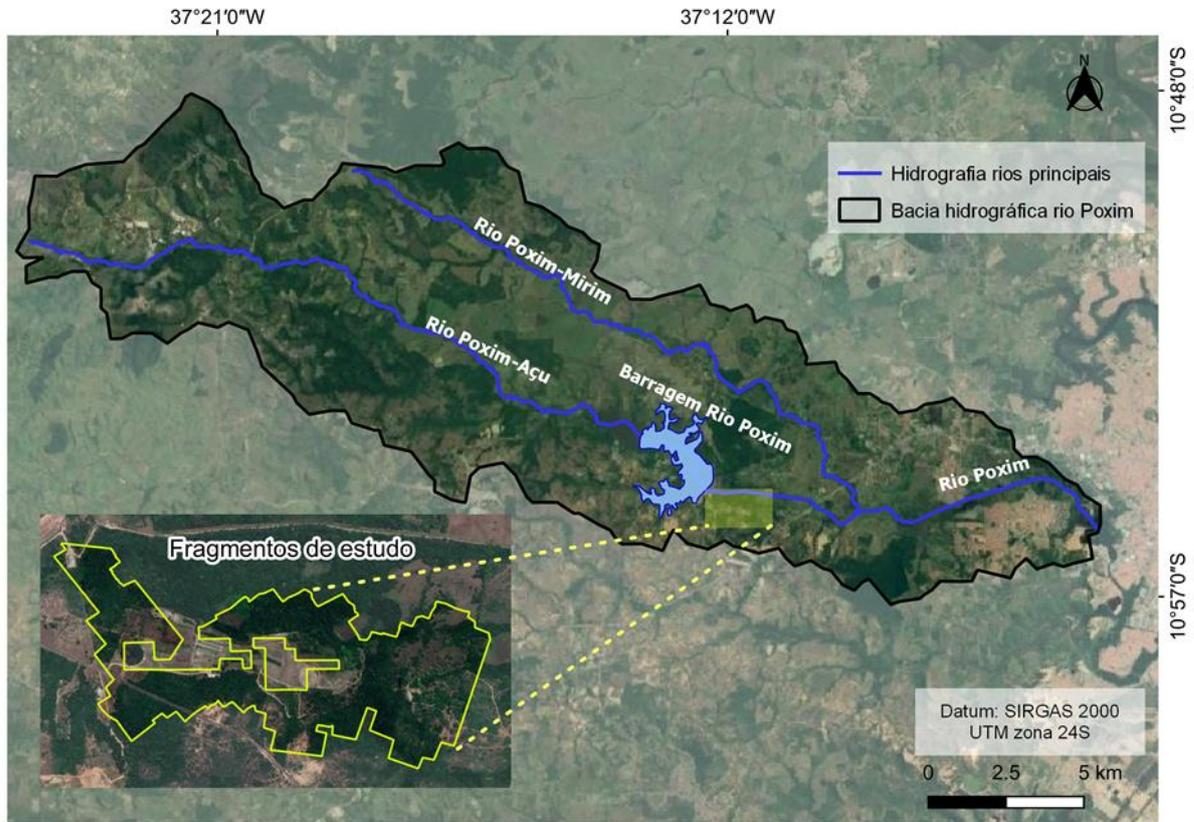
De acordo com a classificação de Köppen (ALVARES *et al.*, 2013), o clima da região é do tipo As, tropical úmido com inverno chuvoso e verão seco, em virtude da proximidade do mar e do baixo relevo, exposto aos ventos alísios. A precipitação média anual é 1300 mm, com período de chuvas distribuído entre os meses de abril a setembro e períodos secos entre outubro (ano corrente) e março (ano posterior). A temperatura média do ar varia entre 23 °C nos meses mais frios (julho a agosto) e 31 °C nos mais quentes (dezembro a janeiro) (SILVA, 2001; SOARES, 2001). A altitude ao longo da bacia varia entre 0 e 222m, sendo a média de 81m. O tipo de solo predominante é o Argissolo Vermelho Amarelo (ROCHA *et al.*, 2014).

Segundo Ferreira *et al.* (2011), apesar de sua importância social e econômica, a hidrográfica do rio Poxim encontra-se em alto estado de degradação ambiental. As atividades predominantes no curso médio dos rios são as pastagens e culturas perenes e temporárias; e em sua foz concentra-se áreas industriais e acentuadamente urbanas.

3.1.2 Fragmentos de Mata Atlântica

Os fragmentos florestais estudados estão situados na porção média da bacia hidrográfica do rio Poxim, SE, com uma área de aproximadamente 100 ha (Figura 2). A vegetação corresponde a Floresta Ombrófila Semidecidual (VELLOSO; RANGEL-FILHO; LIMA, 1991). O tipo de solo predominante no fragmento é Argissolo Vermelho Amarelo Distrófico textura franco-arenosa (EMBRAPA, 1999). O relevo é suave ondulado, com declividade média de 6% e altitude variando entre 14 e 57 m (ALMEIDA *et al.*, 2020).

Figura 3 – Localização dos fragmentos florestais de Mata Atlântica analisados na bacia hidrográfica do rio Poxim-SE.



Fonte: Produção da autora. A imagem de fundo corresponde ao Map data ©2016 Google.

Os fragmentos, de modo geral, apresentam uma vegetação com dossel aberto e poucas áreas com dossel mais fechado. No local foram observados alguns tipos de perturbações, como cortes seletivos de árvores, manchas provenientes de ocorrência de fogo e áreas de conversão para culturas agrícolas (ALMEIDA *et al.*, 2020).

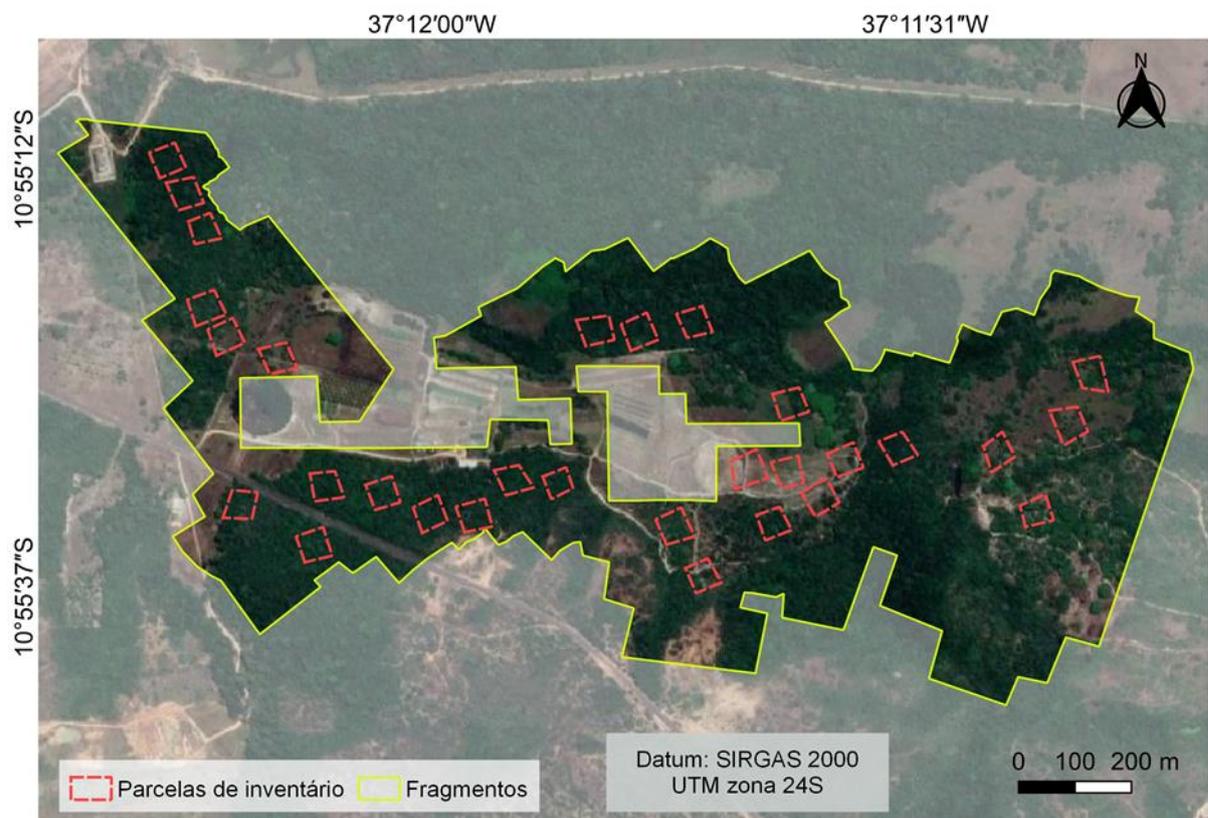
3.2 INVENTÁRIO FLORESTAL

3.2.1 Dados de inventário florestal

Os dados de inventário florestal utilizados no presente estudo foram coletados e disponibilizados por Almeida *et al.* (2020). A campanha de inventário foi realizada entre os meses de agosto a outubro de 2018. Foram alocadas 30 parcelas permanentes quadradas, com dimensões aproximadas de 50 x 50 m (~0,25 ha), dispostas de forma planejada a cobrir toda variação de BAS existente nos fragmentos florestais (Figura 4).

Os quatro vértices de cada parcela foram georreferenciados por um receptor GNSS *Real-Time Kinematic* (RTK) modelo FOIF A60 (www.foif.com), com uma precisão horizontal (X e Y) de 0.92 m.

Figura 4 – Localização das 30 parcelas de inventário florestal mensuradas na área de estudo durante o período de agosto a outubro de 2018.



Fonte: Produção da autora. A imagem de fundo corresponde ao Map data ©2016 Google.

Durante o inventário foram medidas a circunferência a 1,30 m de altura em relação ao nível do solo (*cap*) e a altura total (*ht*) de cada árvore. A *cap* foi obtida com uma fita métrica e convertida posteriormente para diâmetro à 1,30 m do nível do solo (*dap*). Nas parcelas em estágio sucessional avançado, foram mensurados todos os indivíduos com *cap* superior a 15,7 cm, o que corresponde a um *dap* de 5 cm. Nas parcelas de inventário em estágio inicial de desenvolvimento, além mensuração das árvores com *dap* acima de 5 cm, foi contabilizado o número de indivíduos com *dap* entre 2,5 e 5 cm. Os valores de altura das árvores foram estimados de forma visual por um observador da equipe do inventário.

Para a mesma área de estudo, Almeida *et al.* (2020) ajustaram um modelo de regressão linear para corrigir as estimativas de altura visual realizadas pelo observador durante o inventário. O modelo foi ajustado entre os valores pareados de *ht* de 150 árvores medidos pelo observador de forma visual (*ht_o*) e também com o auxílio de um clinômetro eletrônico modelo *Haglöf* (*ht_c*) (<http://www.haglofsweden.com>). Previamente ao início da coleta dos dados de cada parcela de inventário, foram realizadas releituras dos valores de altura, escolhidas de forma aleatória, em cinco árvores da parcela. Os coeficientes do modelo ajustado (R^2 de 0,74 e RMQE de 2,5 m) foram significativos a 5% de probabilidade pelo teste t de Student.

Os dados de inventário das árvores individuais foram utilizados para estimar: diâmetro, altura e número de indivíduos por hectare e área basal por parcela. Um resumo dos atributos da floresta em nível de parcela, é apresentado na Tabela 3.

Tabela 3 – Resumo das características das 30 parcelas de inventário amostradas nos fragmentos florestais de Mata Atlântica da bacia do rio Poxim, Sergipe.

Variável	Sigla	Média	Amplitude	Desvio Padrão
Diâmetro (cm)	<i>dap</i>	9,70	5,0 – 149,28	5,93
Altura (m)	<i>ht</i>	7,01	1,00 – 23,54	3,35
Número de indivíduos (n.ha ⁻¹)	<i>n</i>	970,75	3,38 – 1959,57	581,84
Área basal (m ² .ha ⁻¹)	<i>ab</i>	9,73	0,002 – 25,93	6,49

Fonte: Adaptado de Almeida *et al.* (2020).

Além dos valores de *ht* duplicados para cada uma das cinco árvores de cada parcela, os valores de *dap* também foram remeidos. A partir dos valores duplicados de *dap* e *ht* das árvores, os erros de mensuração foram calculados por Almeida *et al.* (2020), conforme o método de Gonçalves *et al.* (2017) (Tabela 4). O erro total foi

descrito pela Raiz da Média do Quadrado dos Erros (RMQE), o erro sistemático pelo viés e o erro aleatório pelo desvio padrão dos valores remeidos de *ht* e *dap*.

Tabela 4 – Erros de mensuração calculados para as 30 parcelas localizadas nos fragmentos florestais de Mata Atlântica da bacia do rio Poxim, Sergipe.

Variável	Amplitude	RMQE	Erro	
			Viés	Desvio Padrão
Diâmetro (cm)	16,0–95,8	1,0 (2,8%)	-0,008 (0,02%)	1,0 (2,8%)
Altura (m)	3,1–21,5	2,5 (24,2%)	-0,3 (3,4%)	2,5 (24,9%)

Fonte: Almeida *et al.* (2020).

3.2.2 Estimativa da biomassa acima do solo e incertezas associadas

Os valores de biomassa de cada árvore (B_{Arv1}) foram estimados pela equação alométrica estabelecida para florestas tropicais úmidas elaborada por Chave *et al.* (2005). A equação utiliza como entrada os valores estimados de altura corrigida (\hat{h}_{tc}), *dap* e ρ das árvores obtidos a partir do inventário florestal. A ρ de cada árvore identificada na parcela foi obtida com base no estudo realizado por Chave *et al.* (2006) a nível de espécie ou gênero. A biomassa das espécies de palmeiras (B_{palma}) identificadas foi estimada de acordo com a equação descrita por Saldarriaga *et al.* (1988) (Tabela 5).

Tabela 5 – Equações alométricas utilizadas no cálculo da biomassa acima do solo.

Equações	Referências
$B_{Arv1} = \exp (-2,977 + \ln (\rho dap^2 \hat{h}_{tc}))$	Chave <i>et al.</i> (2005)
$B_{palma} = \exp (-6,378 + -0,877 \ln (1/(dap)^2 + 2,151 \ln (\hat{h}_{tc}))$	Saldarriaga <i>et al.</i> (1988)

Em que: B_{Arv1} = biomassa aérea seca da árvore (kg); B_{palma} = biomassa aérea seca de espécies de palmeiras (kg); ρ = densidade da madeira ($g\ cm^{-3}$); *dap* = diâmetro do tronco a 1,30 m do solo (cm); \hat{h}_{tc} = altura total estimada da árvore corrigida (m).

Para os indivíduos com *dap* entre 2,5 e 5 cm nas parcelas de inventário em estágio inicial de desenvolvimento, a biomassa de cada árvore (B_{Arv}) foi estimada considerando o valor de *dap* de 3,25 cm (centro de classe), uma *ht* de dois metros e o valor médio de ρ observado na parcela. Ao final, o valor de B_{Arv} encontrado foi multiplicado pelo número de indivíduos observados dentro na classe (ALMEIDA *et al.*,

2020). Após a estimativa de biomassa individual de cada árvore, os valores foram somados e divididos pela área da parcela, sucedendo na estimativa de BAS por hectare (Mg ha^{-1}).

Os erros de mensuração (σ_M) foram propagados para a equação de estimativa da B_{ARV1} a partir da série de Taylor, conforme equação de Chave *et al.* (2004). Os erros dos valores da ρ foram obtidos pelo trabalho desenvolvido por Chave *et al.* (2006). As incertezas do modelo alométrico selecionado da estimativa de B_{ARV1} foram baseadas nos termos de seleção (σ_S) e no resíduo do modelo (σ_R). O erro de σ_S foi estimado pelo desvio padrão entre os valores de biomassa estimada pela equação B_{ARV1} e as equações alternativas descritas na Tabela 6. O σ_R foi estimado conforme a equação apresentada por Chave *et al.* (2004), Chave *et al.* (2014) e Baskerville (1972).

Tabela 6 – Equações alométricas alternativas utilizadas para o cálculo da incerteza da biomassa.

Equações	Referências
$B_{ARV2} = \exp(-2.134+2.53\ln(\text{dap}))$	Brown <i>et al.</i> (1997)
$B_{ARV3} = \rho \exp(-1.499+2.148 \ln(\text{dap})+0.207 \ln(\text{dap})^2-0.0281 \ln(\text{dap})^3)$	Chave <i>et al.</i> (2005)
$B_{ARV4} = \exp(-0.37+0.333 \ln(\text{dap})+0.933 \ln(\text{dap})^2-0.122 \ln(\text{dap})^3)$	Chambers <i>et al.</i> (2001)
$B_{ARV5} = \exp(-3.1141+0.9719 \ln(\text{dap}^2 \text{ht}_c))$	Brown <i>et al.</i> (1989)

Em que: B_{ARVX} = biomassa aérea seca da árvore (kg); ρ = densidade da madeira (g cm^{-3}); dap = diâmetro do tronco a 1,30 m do solo (cm); ht_c = altura total da árvore corrigida (m).

Para obter o erro ao nível de parcela na escala de hectare, os erros em nível de árvore foram adicionados em quadratura. Em seguida, para obter uma estimativa total das incertezas (mensuração e alométrica) (σ_{BAS}), o erro em nível de parcela foi combinado em quadratura, conforme os princípios de aditividade e independência estatística (GONÇALVES *et al.*, 2017) (Tabela 7). O σ_{BAS} foi incorporado no momento do ajuste dos modelos de estimativa de BAS por sensoriamento remoto.

Tabela 7 – Incertezas em nível de parcela nas estimativas de biomassa acima do solo nos fragmentos secundários de Mata Atlântica da bacia do rio Poxim, Sergipe.

Fonte de erro	Erro médio (%)
Mensuração (σ_M)	6,7
Alométrica (seleção do modelo, σ_S)	6,5
Alométrica (resíduos do modelo, σ_A)	2,6
Total (σ_{BAS})	9,7

Fonte: Almeida *et al.* (2020).

3.3 DADOS DE LANDSAT-8

3.3.1 Aquisição e pré-processamento das imagens

As imagens da coleção “*USGS Landsat 8 Surface Reflectance Tier 1*” foram utilizadas no estudo. O conjunto de dados é ortorretificado e processado para reflectância de superfície a partir do *Land Surface Reflectance Code* (LaSRC) (VERMOTE *et al.*, 2016). Esse produto se destaca por possuir o *CFMask* (FOGA *et al.* 2017; ZHU; WANG; WOODCOCK, 2015), atualmente usado como algoritmo padrão de máscara de nuvem para as missões Landsat (USGS, 2019).

O *CFMask* é uma banda que apresenta a função de máscara. Ele é usado para mapear de forma automatizada as nuvens, a confiabilidade nas nuvens, a sombra da nuvem e os pixels de neve e gelo na imagem. Estes pixels são representados como valores mapeados em bits dentro da banda de qualidade ‘*pixel_qa*’ da coleção. Para cada um desses elementos é atribuído um valor de pixel.

Esse produto foi adotado, no estudo, devido às condições de nebulosidade observadas ao longo do período de aquisição de imagens. A exclusão dos pixels com nuvens ou sombra de nuvens ocorreu através de uma seleção dos valores correspondente a esses atributos na banda *pixel_qa*, conforme a Tabela 8.

Tabela 8 – Valores representativos da banda *pixel_qa* do produto de Landsat-8.

Valor do Pixel	Atributo
2	Sombra de nuvem
3	Neve/nuvem

Fonte: USGS (2019).

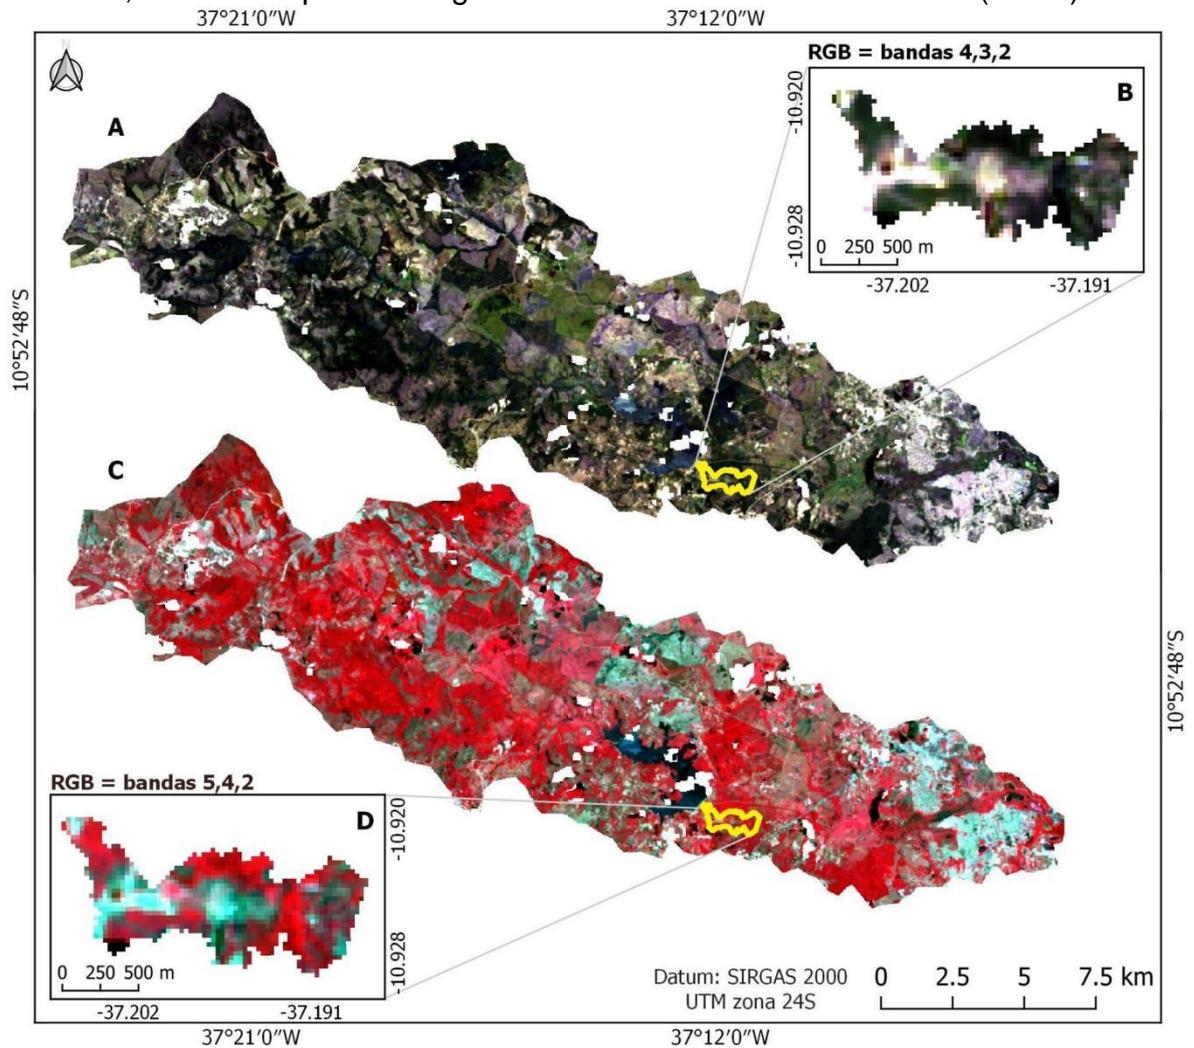
A composição final representa o valor mediano de reflectância de cada pixel compreendido no interior do limite da área de estudo durante a janela de tempo de realização do inventário. Durante esse intervalo de tempo, foram adquiridas seis imagens (Tabela 9) da coleção e processadas por meio da plataforma do *Google Earth Engine* (GEE) (<https://earthengine.google.com/>).

Tabela 9 – Data de aquisição das imagens do produto de Landsat-8.

Data de aquisição	Path/Row
13/08/2018	215/67
29/08/2018	215/67
14/09/2018	215/67
30/09/2018	215/67
16/10/2018	215/67
01/11/2018	215/67

Para as análises com Landsat-8, foram utilizadas seis bandas espectrais (banda 2 – azul; verde – banda 3; vermelho – banda 4; infravermelho próximo (NIR) – banda 5; infravermelho médio, SWIR 1 – banda 6 e SWIR 2 – banda 7). Por último, a composição final dessas bandas espectrais foi exportada no formato .tif. Com base nas bandas no azul, no verde e no vermelho, as composições de pseudo cores naturais (Vermelho, Verde e Azul) e falsa cores (Infravermelho Próximo, Vermelho e Verde) foram construídas para os fragmentos florestais e para toda a bacia do Rio Poxim-SE (Figura 5).

Figura 5 – Composição (A) colorida (bandas azul, verde e vermelho) e (C) falsa cor (bandas NIR, vermelho e verde) de imagens Landsat 8 da bacia hidrográfica do rio Poxim-SE, com destaque nos fragmentos florestais de Mata Atlântica (B e D).



Fonte: Produção da autora.

3.3.2 Índices de vegetação

A partir dos dados ópticos multiespectrais do satélite Landsat-8, foram estimados 12 IVs entre eles: NDVI, DVI, OSAVI, SR, MSR, GEMI, SAVI, MSAVI2, RDVI, MSI, NDII e TVI (Tabela 10). Esses índices, com base na literatura, foram bem-sucedidos como variáveis preditoras na estimativa de biomassa florestal (DUBE; MUTANGA, 2015b; HUETE, 1988; LU *et al.*, 2016; PANDIT; TSUYUKI; DUBE; 2018; ROUSE *et al.*, 1973; SARKER; NICHOL, 2011; TUCKER, 1979). O cálculo dos IVs foi realizado no software R (R CORE TEAM, 2019).

Tabela 10 – Índices de vegetação calculados a partir de dados do sensor OLI do satélite Landsat-8.

Índice de Vegetação	Equação	Referência
NDVI	$\frac{NIR - Verm}{NIR + Verm}$	Rouse <i>et al.</i> , (1973)
DVI	$NIR - Verm$	Tucker (1979)
OSAVI	$\frac{1 + 0,16 * (NIR - Verm)}{NIR + Verm + 0,16}$	Rondeaux <i>et al.</i> (1996)
SR	$\frac{NIR}{Verm} + 1 \sqrt{\left(\frac{NIR}{Verm}\right) + 1}$	Jordan (1969)
MSR	$\frac{1 + (NIR/Verm) - 1}{\sqrt{\left(\frac{NIR}{Verm}\right) + 1}}$	Chen (1996)
GEMI	$n * (1 - 0,25 * n) - \left(\frac{Verm - 0,125}{1 - Verm}\right)$ em que $n = \frac{2*(NIR^2 - Verm^2) + 1,5*NIR + 0,5*Verm}{(NIR + Verm + 0,5)}$	Pinty; Verstraete (1992)
SAVI	$\frac{NIR - Verm}{(NIR + Verm + 0,5) * 1,5}$	Huete (1988)
MSAVI2	$0,5 * ((NIR + 1) - \sqrt{(2 * NIR + 1)^2 - 8(NIR - Verm)})$	Qi <i>et al.</i> (1994)
RDVI	$(NDVI * DVI)^{0,5}$	Roujean; Breon, (1995)
MSI	$\frac{SWIR 2}{NIR}$	Hunt; Rock, (1989)
NDII	$\frac{NIR - SWIR2}{NIR + SWIR2}$	Hardisky; Klemas; Smart, (1983)
TVI	$\frac{NIR - Verm}{NIR + Verm} + 0,5$	Deering (1975)

Em que: *NIR* é a banda do infravermelho próximo – banda 5; *Verm* é a banda do vermelho – banda 4; *SWIR 2* é infravermelho médio – banda 7.

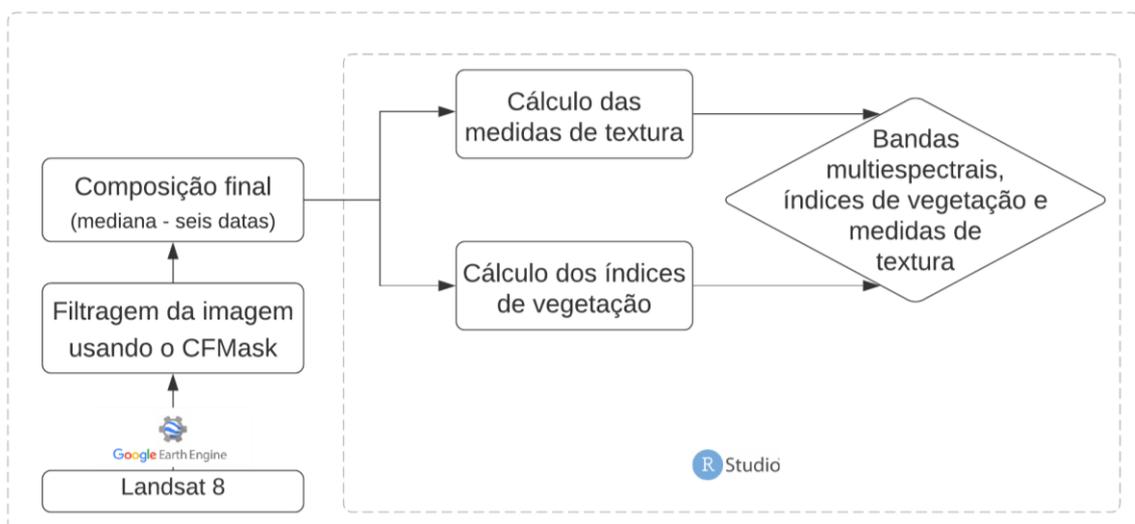
3.3.3 Medidas de textura

As medidas de textura (MT) foram derivadas, a partir das imagens do Landsat-8, utilizando o algoritmo *Gray-Level Co-occurrence Matrices* GLCM, com os parâmetros calculados em quatro direções (0° - horizontal, 45° - diagonal, 90° - vertical e 135° - diagonal) e deslocamentos ($[1,0]$; $[1, -1]$; $[0,1]$; $[1,1]$) (HARALICK; SHANMUGAN; DISTEN, 1973). Para as estimativas das MT, foram utilizadas janelas fixas de tamanho 3x3.

Foram calculadas sete MTs: média (MT_M), variância (MT_V), homogeneidade (MT_H), contraste (MT_C), dissimilaridade (MT_D), segundo momento angular (MT_S) e entropia (MT_E). As MTs também foram obtidas para cinco índices de vegetação (NDVI, OSAVI, MSR, SAVI e GEMI). Como resultado foram gerados 77 diferentes atributos texturais. As MTs foram estimadas pelo software R (R Core Team, 2019), utilizando o pacote GLCM (ZVOLEFF, 2015).

Um total de 95 variáveis independentes foram calculadas para explorar as informações de sensoriamento remoto orbital Landsat-8, incluindo as bandas espectrais, IVs e MTs baseadas na matriz de co-ocorrência. As etapas de processamento realizadas nas imagens ópticas estão apresentadas na Figura 6.

Figura 6 – Fluxograma de processos realizados nas imagens Landsat-8.



Fonte: Produção da autora.

3.4 DADOS DE FOTOGRAMETRIA AÉREA DIGITAL

3.4.1 Aquisição das fotografias aéreas

As fotografias aéreas de alta resolução espacial foram adquiridas, para todos os fragmentos de estudo, por um sensor CMOS 1" (20 *megapixels*) acoplado a uma plataforma multirrotor DJI Phantom 4 Pro (SZ DJI Technology Co., Ltd., Shenzhen, China). As Imagens multiespectrais RGB foram coletadas em 27 de setembro de 2018, durante o inventário florestal, em boas condições, com tempo ensolarado e velocidade do vento inferior a 10 m s⁻¹. A altitude do voo foi definida para 120 metros acima do nível do solo e sobreposição frontal definida de 75% e lateral de 70%.

3.4.2 Processamento fotogramétrico e avaliação dos produtos

As imagens adquiridas pela câmera a bordo da ARP foram processadas no software Agisoft Metashape Professional Edition 1.1.0 (AGISOFT, St. Petersburg, Russia) conforme descrito por Almeida et al. (2020) para gerar informações tridimensionais do terreno e sua superfície no formato de nuvem de pontos (x, y e z). O Metashape é um *software* de fotogrametria que utiliza um conjunto de algoritmos de visão computacional *Structure from Motion* (SfM) e algoritmos de correspondência estéreo fotogramétrica para reconstrução 3D de imagens sobrepostas (IGLHAUT et al., 2019). As imagens coletadas pela câmera a bordo da ARP foram georreferenciadas com 41 pontos de controle. Desses, 31 foram utilizados como pontos de controle e 10 como pontos de checagem.

Os parâmetros definidos para o alinhamento da imagem foram acurácia alta (*accuracy high*), seleção de par referência, pontos principais (*key points*) igual a 40.000, pontos de amarração (*tie points*) igual a 4.000. No posicionamento guiado do marcador foram realocados manualmente 31 pontos de controle e 10 pontos de verificação. Para a construção de nuvens densa de pontos foram definidos qualidade

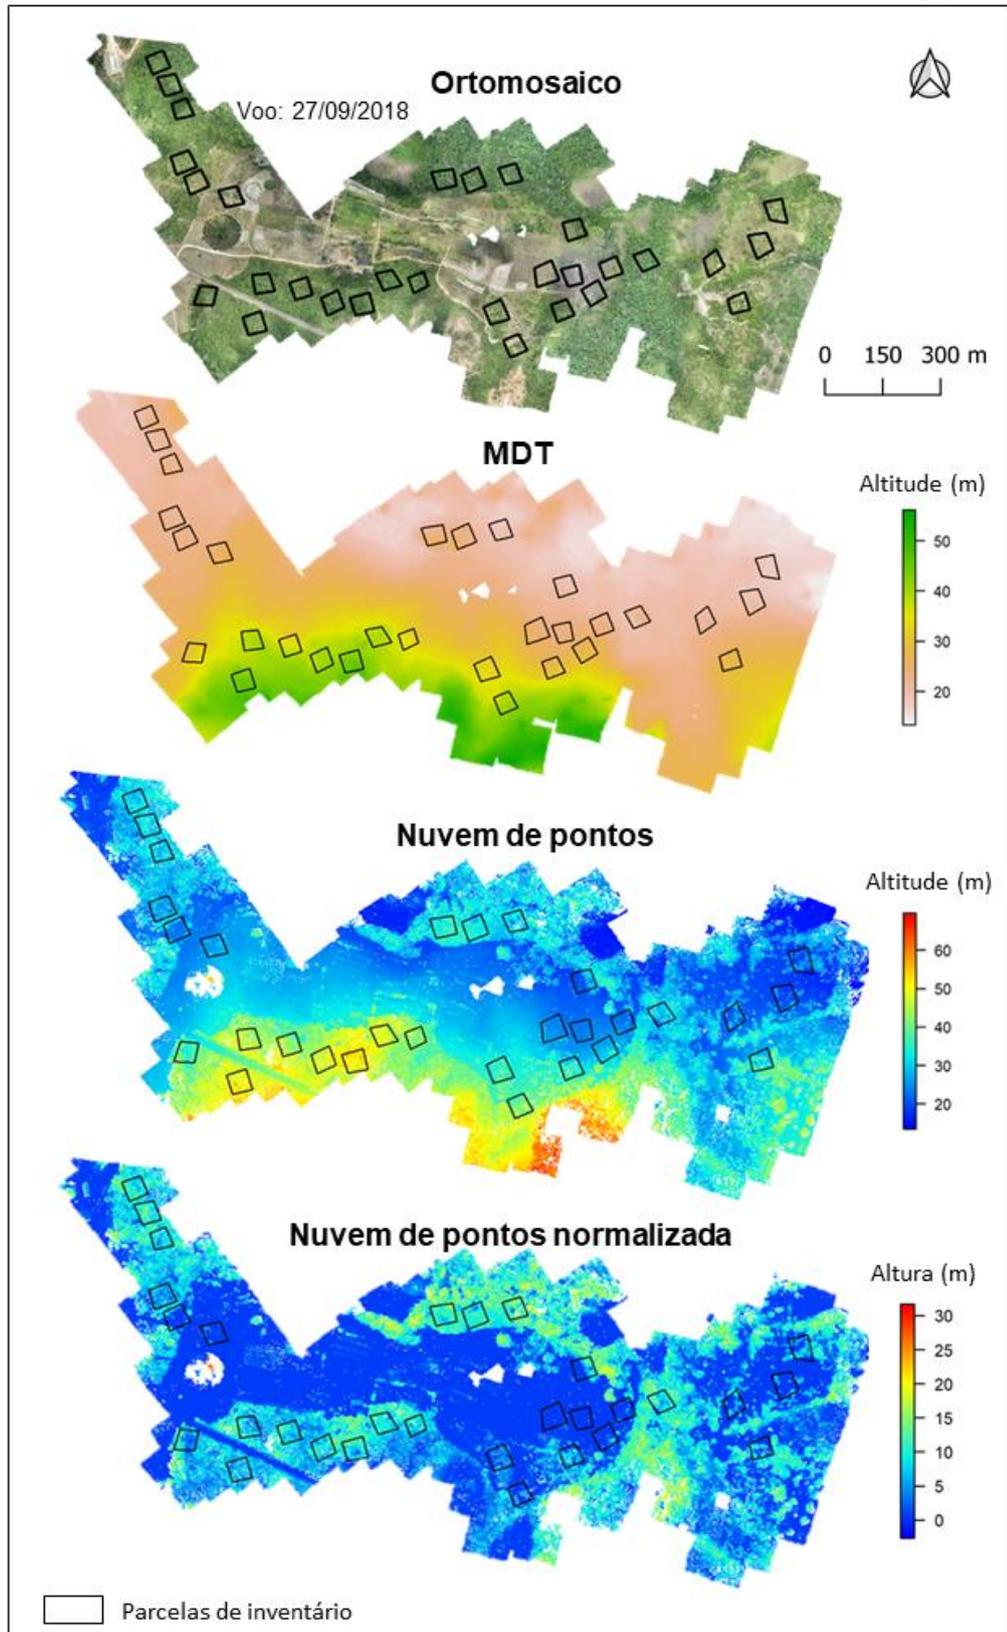
média (*quality médium*) e modo de filtragem suave (*filtering mode mild*). No final do processamento, os valores da RMQE dos pontos de checagem foram de 0,04 (horizontal) e 0,11 (vertical) metros, respectivamente (Almeida *et al.*, 2020).

O MDT foi criado a partir da nuvem de pontos 3D da FAD utilizando o algoritmo Adaptive Triangulated Irregular Network (TIN) desenvolvido por Axelsson (2019), implementado no *Agisoft Metashape*. A nuvem de pontos 3D FAD e o MDT gerados foram exportados no formato de arquivo “.las”. Um ortomosaico com resolução espacial de 20 cm também foi criado e exportado para o formato “.tif”.

A validação dos produtos FAD-ARP foi realizada por Almeida *et al.* (2020). Os valores de altitude do terreno coletados em campo pelo RTK e estimados pelo MDT FAD apresentaram um erro de aproximadamente 1,0 m (RMQE de 4%). As elevações do terreno medidas no campo foram altamente correlacionadas com (r de 0,98) com os valores de altitude do MDT, sendo ligeiramente superestimadas (viés de 0,53 m). Comparando as alturas das 25 maiores árvores de cada parcela de inventário (altura dominante) com os valores do percentil 99% da altura obtida pela nuvem de pontos FAD-ARP, o erro observado pelos mesmos autores foi de 3,0 m (RMQE de 24,7%).

A nuvem de pontos 3D foi normalizada pela subtração do MDT proveniente da FAD. Os principais produtos FAD-ARP gerados durante o processamento são apresentados na Figura 7.

Figura 7 – Ortomosaico com composição colorida RGB, Modelo Digital do Terreno (MDT), nuvem de pontos e nuvem de pontos normalizada, produzidos por FAD para os fragmentos secundários de Mata Atlântica da bacia do rio Poxim, Sergipe.



Fonte: Almeida *et al.* (2020) adaptado pela autora.

3.4.3 Métricas FAD derivadas das nuvens de pontos

A partir da nuvem de pontos 3D normalizada, métricas estruturais tradicionais (NÆSSET *et al.*, 2004) da vegetação a nível de parcela (abordagem de área) foram calculadas. As métricas foram estimadas pela função *cloud_metrics* do pacote *lidR*. Uma altura limiar de 1,5 m foi considerada para remover pontos do solo e separar árvores de vegetação rasteira (ALMEIDA *et al.*, 2020). As métricas FAD foram extraídas no software R (R CORE TEAM, 2019) com o auxílio do pacote ‘*LidR*’ (ROUSSEL *et al.*, 2018).

Além das métricas tradicionais, para cada parcela, foram calculadas métricas baseadas na transformada de Fourier dos perfis verticais da vegetação (ALMEIDA *et al.*, 2020; TREUHAFTH *et al.*, 2015). Os perfis verticais de cada parcela foram gerados dividindo as nuvens de pontos 3D em caixas verticais de 50 cm e contando o número de pontos presentes em cada caixa (GONÇALVES, 2014). Os perfis verticais foram decompostos em 30 frequências de Fourier variando de 0,3 a 0,01 ciclos/m (comprimentos de onda verticais de 3,3 a 100 m), com um passo de 0,01 ciclos/m. Isso resultou em um total de 30 métricas adicionais, que foram representadas pela amplitude do número complexo resultante (amp.01, amp.02, amp.03,..., amp.30). As métricas de Fourier foram estimadas a partir de códigos implementados em R. Todas as métricas apresentadas na Tabela 11 foram estimadas para as 30 parcelas de inventário e posteriormente, para toda a área de estudo para a elaboração dos mapas com a espacialização das variáveis estimadas.

Tabela 11 – Métricas de estrutura extraídas da nuvem de pontos derivada de FAD.

Tipo de métrica	Variável
Altura	Mínimo (H_{min})
	Máximo (H_{max})
	Média (H_{mean})
	Modo (H_{mode})
	Coefficiente de variação (H_{cv})
	Desvio padrão (H_{SD})
	Variância (H_V)
	Interquartil (H_{IQ})
	Assimetria (H_{skew})
	Curtose (H_{kurt})
	Percentis (HP1, HP5, HP10, HP20, HP25, HP30, HP40, HP50, HP60, HP70, HP75, HP80, HP90, HP95, HP99)
	Médias generalizadas da raiz quadrada ($H_{SQRTmeanSQ}$)
	Médias generalizadas da raiz cúbica ($H_{CURTmeanCUBE}$)
	Desvio absoluto médio (HAAD)
	Desvio absoluto mediano da altura mediana ($H_{MAD_{Median}}$)
	Desvio absoluto mediano da moda da altura ($H_{MAD_{Mode}}$)
	Momentos lineares (HL1, HL2, HL3, HL4)
	Altura de assimetria do momento linear (HL_{skew})
	Altura da curtose do momento linear (HL_{kurt})
	<i>Canopy relief ratio</i> (HCRR) $(H_{mean} - H_{min}) / (H_{max} - H_{min})$
Cobertura de copa	Total de todos os retornos (CCH)
	Todos os retornos acima da altura média (CCH_{mean})
	Todos os retornos acima do valor da moda da altura (CCH_{mode})
FFourier	Porcentagem de todos os retornos > altura média em relação ao número total de pontos ($CC\%H_{mean}$)
	Porcentagem de todos os retornos > altura do modo em relação ao número total de pontos ($CC\%H_{mode}$)
FFourier	Amplitudes (amp.01, amp.02, amp.03, ..., amp.30)

Em que: H é a altura; CC é Cobertura de copa.

3.5 ESTIMATIVA DE BAS PARA OS FRAGMENTOS FLORESTAIS

Em estudos de estimativa de biomassa a partir de dados de sensoriamento remoto estão associadas inúmeras fontes de incertezas (DUNCANSON *et al.*, 2021). Ao usar uma “estimativa” (proveniente de dados de sensoriamento remoto) da “estimativa” (proveniente de dados de inventário florestal), devem ser considerados e propagados os erros de mensuração e de alometria (GONÇALVES *et al.*, 2017). Além desses, há outras fontes de incertezas do processo que devem ser consideradas, como o erro de localização das parcelas de inventário florestal, o erro de georreferenciamento dos dados de sensoriamento remoto e o erro temporal, ocorrido entre as datas das medidas realizadas do inventário e o dado de sensoriamento remoto.

Portanto, no momento do ajuste dos modelos de regressão foram considerados e propagados os erros de mensuração e de alometria (seção Estimativa da biomassa acima do solo e incertezas associadas). Os erros de localização das parcelas, georreferenciamento dos dados de sensoriamento remoto e temporal foram desconsiderados na modelagem de BAS, devido: (i), aos baixos erros (RMQE de 0,91 m) de georreferenciamento das parcelas de inventário florestal; (ii), as imagens Landsat-8 serem ortorretificadas (Seção 3.4.1 Aquisição e pré-processamento das imagens); (iii), os baixos erros de georreferenciamento dos produtos FAD-ARP (Seção Processamento fotogramétrico e avaliação dos produtos); e (iv), a concordância temporal entre os dados de inventário florestal e de sensoriamento remoto.

3.5.1 Método direto

O principal método usado para estimar a distribuição espacial de BAS a partir de dados de sensoriamento remoto é relacionar medidas feitas em parcelas de inventário florestal diretamente a métricas de sensoriamento remoto por meio de modelos estatísticos. Essa técnica foi uma das adotadas nesse estudo e para fins de referência nomeada como método direto.

A partir dos dados das 30 parcelas de inventário florestal, a BAS dos fragmentos florestais foi estimada considerando três abordagens: (i), BAS_{IF-L8} , usando variáveis independentes obtidas dos dados espectrais do satélite Landsat-8; (ii), BAS_{IF-FAD} , usando variáveis independentes obtidas por FAD (modelos descritos por ALMEIDA *et al.*, 2020); e (iii), $BAS_{IF-L8+FAD}$, utilizando a combinação de ambas variáveis independentes (Landsat-8 e FAD).

Os modelos de regressão foram ajustados entre os valores de BAS_{IF} e as variáveis independentes de cada uma das abordagens. A busca do melhor subconjunto de variáveis explicativas foi realizada pelo método exaustivo através do pacote *leaps* (LUMLEY, 2020) implementado no R. Essa seleção foi realizada tendo como parâmetros o Critério de Informação Bayesiano (BIC), o coeficiente de determinação (R^2), e a soma de quadrados do resíduo (s^2).

Assim, equações foram ajustadas, com número de variáveis preditoras variando de dois a sete, para estimar a BAS para cada abordagem (BAS_{IF-L8} , BAS_{IF-FAD} e $BAS_{IF-L8+FAD}$). Os modelos foram ajustados esperando-se que possuam um número p de variáveis pequeno, valores de s^2 e BIC reduzidos e coeficiente de determinação ajustado ($R^2_{aj.}$) elevado.

O erro total σ_{BAS} calculado para cada uma das 30 parcelas de inventário foi utilizado como peso em um modelo de regressão linear ponderada. A normalidade e a homocedasticidade dos resíduos dos modelos selecionados foram verificadas pelo teste de Shapiro-Wilk e Bartlett's, ao nível de 5% de probabilidade.

Uma vez elaborado o *ranking* com os melhores modelos, foi avaliado o grau de multicolinearidade entre as variáveis preditoras pelo fator de inflação de variância (VIF). Os modelos que apresentaram VIF maior que 10 foram excluídos da modelagem.

O desempenho de predição de cada modelo selecionado foi avaliado pela técnica validação cruzada. Foram utilizadas 1000 repetições, sendo 80% dos dados utilizados no ajuste dos modelos e 20% na validação. As precisões dos valores de BAS previstos para cada modelo foram avaliadas usando os indicadores estatísticos: Raiz da Média do Quadrado dos Erros (RMQE), RMQE% e o R^2 (equações 4,5 e 6, respectivamente).

$$RMQE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (4)$$

$$RMQE\% = \frac{REQM}{\bar{Y}_i} * 100 \quad (5)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y}_i)^2} \quad (6)$$

Em que: n é o número de observações; Y_i é a variável dependente observada; \hat{Y}_i é a variável dependente estimada; \bar{Y}_i é a média da variável dependente observada.

Os modelos também foram avaliados pelo teste F de Graybill (GRAYBILL, 1976), com nível de probabilidade de 5%, comparando-se os valores observados no inventário florestal e estimados por cada abordagem. Essa estatística calcula a significância de uma regressão simples entre valores observados e estimados, testando a hipótese nula de que o parâmetro b_0 (intercepto) é igual a zero e o parâmetro b_1 (inclinação) é igual a um, no modelo $Y_i = b_0 + b_1x_i + \varepsilon$. Todas as análises estatísticas foram realizadas no software R (R Core Team, 2019).

A estimativa de BAS a partir das variáveis independentes de FAD foi realizada usando a equação desenvolvida por Almeida *et al.* (2020) na mesma área de estudo (Equação 7).

$$BAS = -10,7 * amp.12 + 41,3 * amp.13 - 51,5 * amp.14 + 21,2 * amp.15 + 0,7 * HP20 + 0,6 * CC\%H_{mode} \quad (7)$$

Em que: BAS é biomassa acima do solo ($Mg \text{ ha}^{-1}$); amp é métrica de amplitude derivada da transformada de Fourier; $HP20$ é percentil 20 de altura da nuvem de pontos e $CC\%H_{mode}$ é a fração de todos os pontos acima da altura do modo em relação ao número total de pontos.

Após a seleção do melhor modelo para cada uma das três abordagens foram elaborados mapas para visualização da distribuição espacial de BAS para os fragmentos analisados com resolução espacial de 50 m x 50 m, mesmo tamanho da parcela de inventário florestal.

3.5.2 Método multiescalar

Uma das principais vantagens do uso da técnica multiescalar, ou *upscaling*, é a possibilidade de aumentar o número de amostragem, garantindo ainda mais a representatividade da floresta analisada e os princípios estatísticos e probabilísticos do inventário tradicional florestal.

O modelo obtido usando dados tridimensionais FAD, BAS_{IF-FAD} , permitiu a extrapolação das medições de BAS para novos locais da área de estudo que não mensuradas pelo inventário florestal. O mapa BAS_{IF-FAD} passou a ser a referência de BAS do fragmento estudado, aumentando o número de parcelas representativas para a área.

Diferentes parcelas de FAD foram alocadas, que não coincidiram com as parcelas de IF, na mesma área de estudo. De acordo com DUNCANSON *et al.* (2021), é importante considerar a autocorrelação espacial de dados ao validar o modelo de mapeamento, pois a dependência espacial entre os dados pode resultar em uma grande superestimação do desempenho preditivo do modelo. Para isso, a correlação espacial entre os valores BAS_{IF-FAD} (grade de 50 m x 50 m) do fragmento foi analisada pelo ajuste do semivariograma experimental, análise preliminar nos estudos de avaliação de dependência entre variáveis contínuas no espaço (CURRAN, 1978). Os parâmetros para os modelos ajustados aos semivariogramas são apresentados na Tabela 12.

Tabela 12 – Resultado das estatísticas do ajuste dos modelos de semivariogramas experimentais entre os pontos de grade (50 m x 50 m) de BAS_{IF-FAD} .

Modelo	Parâmetro				$\bar{M}.jk$	$\sigma^2.jk$	$R^2.jk$
	C_0	C	a	ide			
Esférico	190,36	925,88	128,00	17,05	-0,008	0,793	0,423
Exponencial	704,91	543144,78	300,93	0,13	-0,006	1,026	0,127
Gaussiano	525,48	612,22	87,33	46,19	-0,008	0,848	0,361
Sentimento	186,68	1463,18	149,99	11,32	-0,011	1,005	0,339

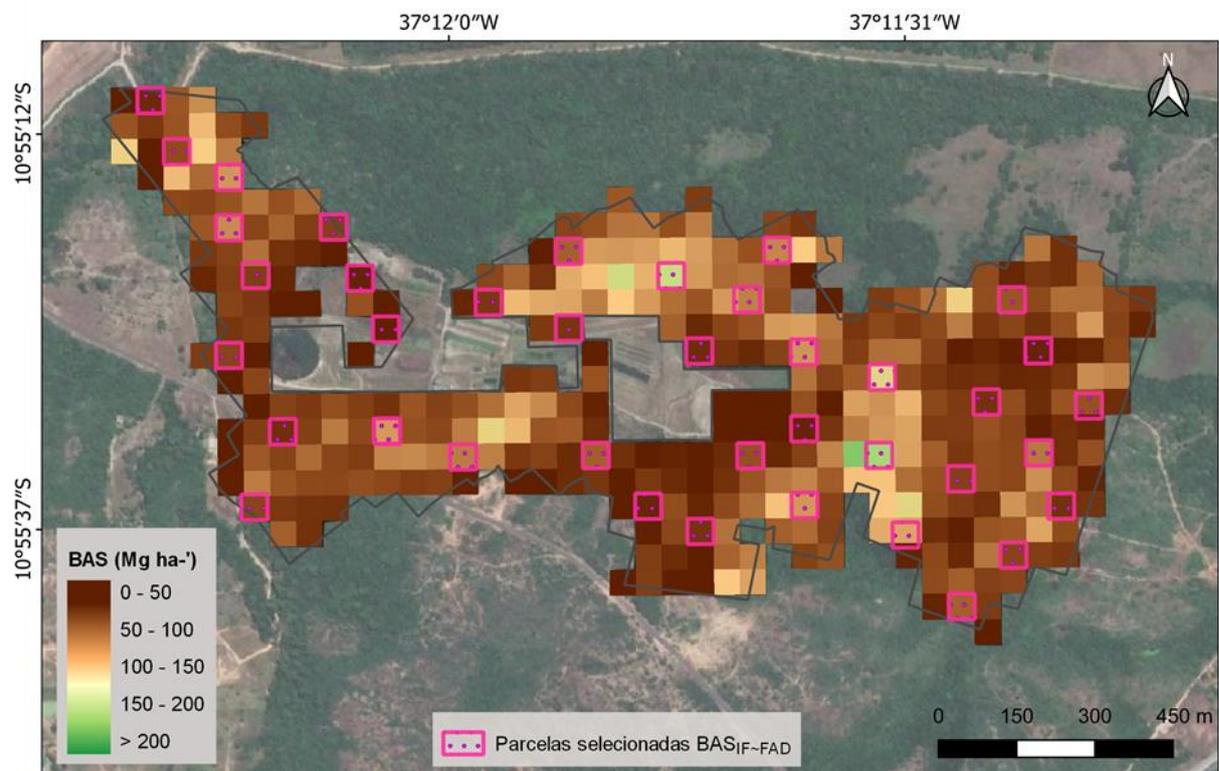
Em que: C_0 = Efeito pepita; C=Patamar; a = Alcance; ide= índice de dependência espacial; $\bar{M}.jk$ = média; $\sigma^2.jk$ = variância; $R^2.jk$ = coeficiente de determinação da validação *jack knifing*.

A seleção do modelo foi realizada com base nas estatísticas dos semivariogramas ajustados (média, variância e coeficiente de determinação). Após a avaliação, o modelo esférico foi o escolhido por apresentar os melhores resultados

estatísticos. Logo, as unidades amostrais foram consideradas independentes no espaço nas distâncias acima de 128 metros.

Respeitando essa distância, a partir do mapa de BAS_{IF-FAD} , foi possível alocar 40 novas parcelas (50 m x 50 m cada) de referência de BAS ao longo da área de fragmentos (Tabela 12). Na Figura 8 é representado o mapa de referência BAS_{IF-FAD} com os respectivos valores de BAS e as 40 parcelas selecionadas para o ajuste entre novo modelo de regressão correlacionando os dados de BAS_{IF-FAD} e métricas Landsat-8 para a subida de escala.

Figura 8 – Parcelas de biomassa selecionadas no mapa de referência BAS_{IF-FAD} ao longo dos fragmentos florestais de Mata Atlântica da bacia do rio Poxim, Sergipe.



Fonte: Produção da autora. A imagem de fundo corresponde ao Map data ©2016 Google.

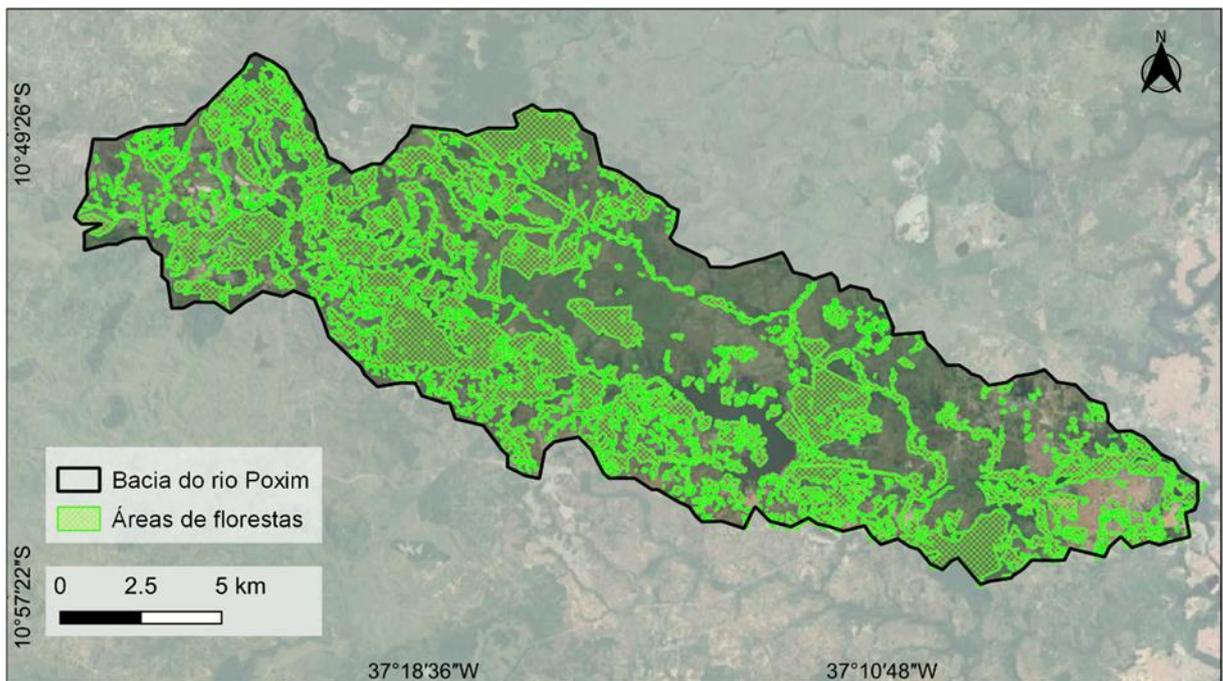
Na segunda escala de análise, um novo modelo de regressão foi ajustado correlacionando os dados de BAS_{IF-FAD} e métricas Landsat-8 nas 40 novas parcelas (Figura 8), obtendo assim um modelo multiescalar de estimativa de BAS ($BAS_{IF-FAD-L8}$). As técnicas estatísticas adotadas de ajuste e avaliação dos modelos foram as mesmas utilizadas no item 3.6.1. Ao final, o modelo proposto foi aplicado para estimar BAS em cada célula de grade (50 m x 50 m) dos fragmentos. As estimativas do modelo multiescalar ($BAS_{IF-FAD-L8}$) foram comparadas (R^2 , RMQE, Viés

e teste F de Graybill) com os valores de BAS estimados por IF e com as estimativas da abordagem direta.

3.5.3 Estimativa de BAS para as áreas de floresta da bacia do rio Poxim

As áreas de florestas de Mata Atlântica pertencentes à bacia foram delimitadas diretamente na imagem Landsat-8, com o auxílio do software livre QGIS versão 3.4.14 (QGIS DEVELOPMENT TEAM, 2020). O mapeamento foi realizado de forma manual, via tela do computador na escala de 1:60.000 (TOBLER, 1988). As áreas de florestas mapeadas ao longo da bacia do rio Poxim são apresentadas na Figura 9.

Figura 9 – Áreas de florestas de Mata Atlântica mapeadas ao longo da bacia do rio Poxim, Sergipe.



Fonte: Produção da autora.

A BAS das áreas de florestas de Mata Atlântica pertencentes à bacia do rio Poxim foi estimada a partir do modelo multiescalar ajustado de melhor desempenho (BAS_{IF-FAD-L8}). O tamanho do *pixel* das métricas Landsat-8 selecionadas no modelo

BAS_{IF-FAD-L8} foi reamostrado para 50 m utilizando a abordagem *nearest neighbor*. Em seguida, o modelo multiescalar foi usado para prever a BAS de toda a bacia.

Além disso, também foi avaliada a distribuição da BAS das áreas de florestas mapeadas de acordo com a elevação da bacia do rio Poxim, Sergipe. Para isso, a elevação da bacia foi dividida em três classes, (i) classe 1 – abaixo de 74,7 metros; (ii) classe 2 – entre 74,4 e 148,3 metros e (iii) classe 3 – acima de 148,3 metros.

4 RESULTADOS E DISCUSSÃO

4.1 ESTIMATIVA DE BAS POR INVENTÁRIO FLORESTAL

As estatísticas descritivas da BAS estimada para as 30 parcelas de inventário florestal dos fragmentos florestais de Mata Atlântica da bacia do rio Poxim-SE são apresentadas na Tabela 13. A BAS dos fragmentos de Mata Atlântica secundária apresentou valores variando entre 0,17 a 134,78 Mg ha⁻¹ e valor médio de 41,22 Mg ha⁻¹.

Tabela 13 – Estatísticas descritivas da biomassa aérea acima do solo estimada para 30 parcelas de inventário florestal em fragmentos florestais de Mata Atlântica da bacia do rio Poxim, Sergipe.

Estatística	BAS_{IF} (Mg ha⁻¹)
Mínimo	0,17
Máximo	134,78
Média	41,22
Desvio padrão da média	35,72

Os valores de BAS encontrado na atual pesquisa foram considerados baixos quando comparados a outros trabalhos de estimativa de BAS realizados em regiões com vegetação de Mata Atlântica em diferentes estados de conservação (ALVES *et al.*, 2010; BARBOSA *et al.*, 2014; SILVEIRA *et al.*, 2019). Os valores menores de BAS observados no estudo possivelmente estão relacionados à condição dos fragmentos florestais secundários analisados. Comparativamente, no estudo realizado por Alves *et al.* (2010), em uma região localizada no Parque Estadual da Serra do Mar-SP, coberta por um dos maiores remanescentes protegidos da Mata Atlântica no Brasil, identificaram um valor médio de BAS de 224,75 Mg ha⁻¹. Silveira *et al.* (2019) em estudo realizado na bacia do rio Doce, Brasil, a BAS média atingiu um valor de 93,72 Mg ha. Já Barbosa *et al.* (2014) em estudo realizado no Vale do Ribeira, localizado no Parque Estadual da Serra do Mar, identificaram BAS média de 54 Mg ha⁻¹ em uma floresta secundária inicial. ⁻¹.

4.2 ESTIMATIVA DE BAS POR MÉTODO DIRETO

4.2.1 Variáveis selecionadas para os modelos de BAS

Os modelos selecionados para as três abordagens de estimativa do método direto (BAS_{IF-L8} , BAS_{IF-FAD} , $BAS_{IF-L8+FAD}$) e seus respectivos desempenhos estatísticos estão apresentados na Tabela 14. Todos os modelos de estimativa de BAS foram selecionados com seis variáveis explicativas, independente da abordagem utilizada, com base nos critérios adotados de seleção do número de variáveis do modelo, R^2 e BIC.

Tabela 14 – Resultado das estatísticas dos modelos selecionados, dados de ajuste e validação, para a estimativa de BAS pelas diferentes abordagens.

Abordagens	Modelo*	Ajuste		Validação	
		R^2	RMQE	R^2_{cv}	$RMQE_{cv}$
BAS_{IF-L8}	NDII + $MT_H B2$ + $MT_D B4$ + $MT_H B7$ + $MT_H MSR$ + $MT_C MSR$	0,94	9,22 (22,4%)	0,88	11,48 (27,9%)
BAS_{IF-FAD}	amp.12 + amp.13 + amp.14 + amp.15 + HP20 + $CC\%H_{mode}$	0,93	9,30 (22,5%)	0,87	12,60 (30,6%)
$BAS_{IF-L8+FAD}$	$MT_D B5$ + $MT_C B7$ + $MT_S MSR$ + H_V + $CC\%H_{mean}$ + amp.20	0,96	7,46 (18,1%)	0,90	9,96 (24,2%)

Em que: * = todos coeficientes foram significativos ao nível de 5%; R^2 = coeficiente de determinação; RMQE = Raiz da Média do Quadrado dos Erros; cv = validação cruzada; Variáveis selecionadas pelos modelos: NDII = Índice infravermelho de diferença normalizada, $MT_H B2$ = Textura homogeneidade da B2; $MT_D B4$ = Textura dissimilaridade da B4; $MT_H B7$ = Textura homogeneidade da B7; $MT_H MSR$ = Textura homogeneidade do índice MSR; $MT_C MSR$ = Textura contraste do índice MSR; amp.# = amplitude da transformada de Fourier na dada frequência especial; HP20 = 20º percentil dos valores de altura da nuvem de pontos; $CC\%H_{mode}$ = porcentagem de pontos acima altura do modo em relação ao número total de pontos; $MT_D B5$ = Textura dissimilaridade da B5; $MT_C B7$ = Textura contraste da B7; $MT_S MSR$ = Textura Segundo Momento do índice MSR; H_V = variância dos valores de altura; $CC\%H_{mean}$ = Porcentagem de todos os retornos acima da altura média em relação ao número total de pontos.

A normalidade e a homocedasticidade dos resíduos dos modelos também foi confirmada pelo teste de *Shapiro-Wilk* e *Bartlett's*, ao nível de 5% de significância. Importante destacar que no momento do ajuste dos modelos do presente estudo, os erros de mensuração e alométricos (Tabela 7) foram considerados, o que fornece mais confiança nos resultados obtidos e descritos na Tabela 14. Ao observar as estatísticas

calculadas, nota-se que as estimativas de ajuste e validação dos dados L8 e FAD, de forma individual, obtiveram valores de R^2 e RMQE (%) muito próximos. A maior acurácia ($R^2 = 0,90$ e $RMQE = 24,2\%$), no entanto, foi obtido pela modelo que integra dados L8 e dados FAD ($BAS_{IF-L8+FAD}$).

Dentre os modelos ajustados (Tabela 14Tabela 12), as MTs fizeram parte de cinco das seis variáveis do modelo BAS_{IF-L8} e parte de três das seis variáveis do modelo $BAS_{C-L8+FAD}$. Comparativamente, as MTs derivadas da imagem Landsat-8 produziram estimativas de BAS melhores do que qualquer banda espectral individual.

O bom desempenho das MTs também estão de acordo com as observações de Kelsey e Nefy (2014), em floresta temperada do Colorado, Estados Unidos ($RMQE$ de $45,6 \text{ Mg ha}^{-1}$ e r de $0,86$) e Dube e Mutanga (2015a), em povoamento de *Eucalyptus dunii*, *Eucalyptus grandis*, *Pinus taeda*, na África do Sul (R^2 médio de $0,68$ e $RMQE$ médio de $19,47\%$), que relataram melhora das estimativas de BAS obtido a partir do uso de métricas de textura do Landsat, em uma janela de tamanho 3×3 pixels. Santos *et al.* (2019), também observaram que, no estado de Mato Grosso, Brasil, as MTs apresentaram correlação maior com a BAS do que os índices de vegetação e imagens de fração.

No modelo com apenas dados L8 foram selecionadas as MTs do índice de vegetação MSR e as bandas do azul, vermelho, infravermelho médio (banda 2, banda 4 e banda 7 - SWIR2). Além desses, também foi selecionado o índice de vegetação NDII. As bandas azuis e vermelho do espectro eletromagnético geralmente apresentam baixos valores de reflectância da radiação eletromagnética (REM) devido à absorção da radiação pelos pigmentos da vegetação (JENSEN, 2011).

À medida que o dossel de vegetação vai se desenvolvendo ocorre um aumento de reflectância no infravermelho próximo, enquanto a sua vegetação vai cada vez mais absorvendo em vermelho em função da fotossíntese. López-Serrano *et al.* (2020), também encontraram a banda vermelha como preditora importante. A banda do infravermelho médio é importante para análise de vegetação, pois é considerada sensível ao conteúdo de umidade presente no dossel florestal. A escolha da banda do SWIR 2 (banda 7) está de acordo com estudos prévios (DUBE; MUTANGA, 2015b; FREITAS; MELLO; CRUZ, 2005; LÓPEZ-SERRANO, *et al.*, 2020).

O índice MSR apresenta informações das bandas do NIR e do vermelho, comprimentos de onda importantes nas estimativas de variáveis de interesse da floresta (JENSEN, 2011; MOREIRA, 2003). O índice de vegetação NDII apresenta

informações das bandas do NIR e SWIR2 expressa o vigor vegetativo das plantas por meio de uma relação entre a banda do infravermelho próximo e as bandas do SWIR2. De acordo com Siachalou, Mallinis e Tsakiri-Strati (2017), os IV limitam a correlação entre bandas espectrais das imagens originais, resumindo em uma única imagem de índice a reflectância registrada em duas ou mais bandas.

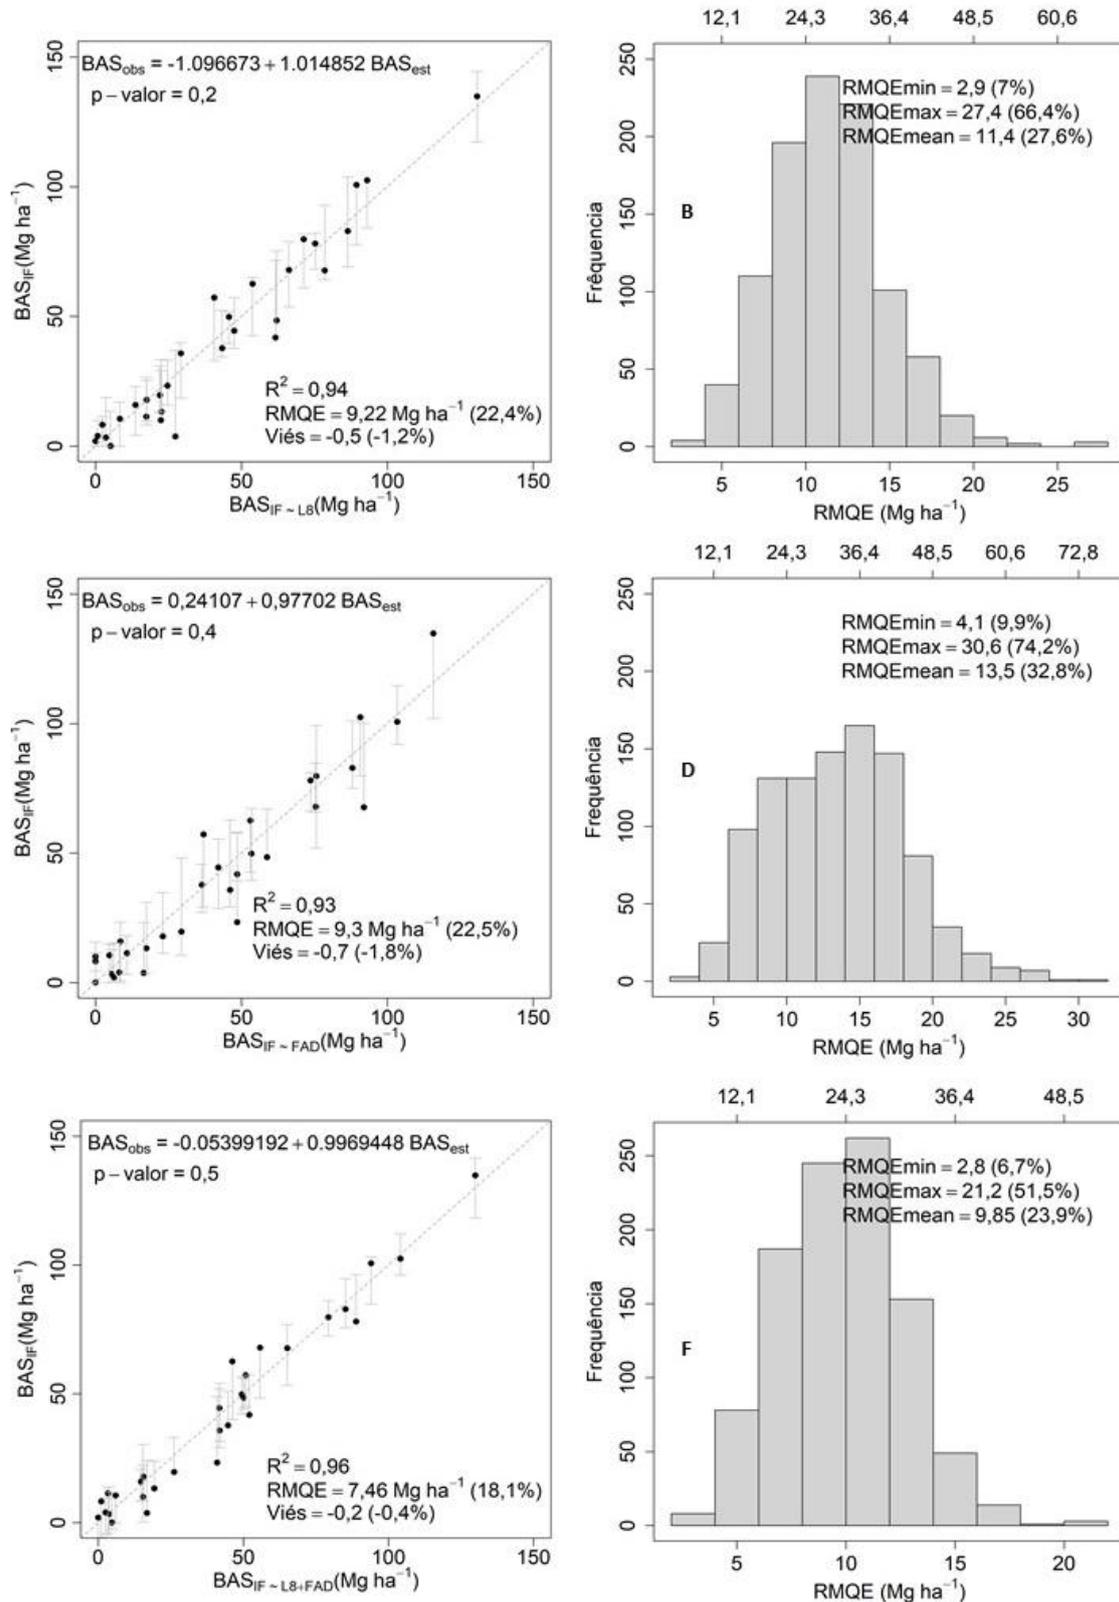
No modelo a partir do uso combinado das variáveis de dados FAD e Landsat-8, foram selecionadas três variáveis FAD e três variáveis Landsat-8, sendo essas três derivadas das MTs. Nesse modelo também foi clara a importância das bandas da região do infravermelho médio (banda 7) e próximo (banda 5) do Landsat-8, faixas espectrais fundamentais para o estudo da vegetação (NOVO, 2010). Na banda do infravermelho próximo, a reflectância é considerada alta resultante da interação da radiação incidente com a estrutura do mesófilo da folha (GATES, 1965; JENSEN, 2011).

Diferente das variáveis espectrais geradas a partir dos dados Landsat-8, as métricas de FAD apresentam relações diretas com a altura da árvore. Dado que duas das variáveis selecionadas representam a estrutura vertical (H_v e $amp.20$) e uma a cobertura de copa média ($CC\%H_{mean}$) do dossel. Como observado por Almeida *et al.* (2020), pode-se verificar mais uma vez a importância dos dois tipos de métricas (de estrutura vertical e cobertura de copa) obtidas por FAD na estimativa de BAS da floresta secundária analisada. A variância (H_v) representa uma medida de dispersão dos valores de altura estimados pela FAD, demonstrando que a variação do tamanho das árvores possui uma relação com a BAS. A $amp.20$ corresponde ao perfil da vegetação com altura aproximada de cinco metros, um pouco abaixo do valor da ht média (7 m) observada no inventário florestal (Tabela 3).

4.2.2 Abordagens de estimativa de BAS

As análises gráficas de dispersão entre os valores observados e estimados pelas três abordagens de estimativa direta, além dos histogramas dos valores de RMQE da etapa de validação estão apresentadas na Figura 10. Observa-se que todas as abordagens apresentaram desempenhos com valores próximos à linha 1:1.

Figura 10 – Biomassa estimada pelas abordagens de estimativa direta *versus* observado por inventário florestal para as 30 parcelas. Gráficos de dispersão a partir dos dados de ajuste e histogramas com a distribuição dos valores RMQE obtidos no procedimento de validação cruzada para as abordagens, BAS_{IF-L8} (A e B), BAS_{IF-FAD} (C e D), $BAS_{IF-L8+FAD}$ (E e F). Os valores de p são para o teste F de Graybill.



Fonte: Produção da autora. Em que: obs = observada; est = estimada.

As estimativas de BAS das três abordagens são consideradas iguais estatisticamente aos valores mensurados no inventário florestal, pelo teste F (p -valor $> 0,05$). Quando se avalia o viés, os modelos analisados apresentaram uma leve tendência a subestimar a BAS (viés inferior a -1,8%).

Ao observar a análise dos histogramas de erros obtidos na validação cruzada (Figura 10B, D e F) nota-se a melhor acurácia do modelo $BAS_{IF-L8+FAD}$. Além do menor erro médio, a abordagem também proporcionou uma redução nos valores mínimo e máximo de RMQE, 2,8 (6,7%) e 21,2 (51,5%), respectivamente (Figura 10F).

O modelo que combina dados L8 e FAD, $BAS_{IF-L8+FAD}$, teve um desempenho superior em prever a BAS da floresta em relação aos modelos que utilizaram apenas uma fonte de informação de sensoriamento remoto. Considerando os resultados obtidos, o viés reduziu para -0,2 m (0,44%) e o RMQE da validação em 13,3% e 20,9% em relação ao modelo BAS_{IF-L8} e BAS_{IF-FAD} , respectivamente. Esses resultados estão de acordo com outros trabalhos encontrados na literatura que também obtiveram melhores resultados usando a combinação de dados complementares para estimativa de variáveis de características da vegetação (PHUA *et al.*, 2017; SINHA; VERMA; AYELE, 2016; TUOMINEN *et al.*, 2017).

Phua *et al.* (2017) estimaram BAS em uma floresta primárias tropicais em Sabah, Malásia e observaram uma redução dos erros de estimativa de aproximadamente 32% ao utilizar combinados os dados LiDAR e Landsat-8 (R^2 de 0,81 e RMQE de 17,36%), quando comparado ao seu uso de apenas dados espectrais (R^2 de 0,63 e RMQE de 25,25%) ou tridimensionais (R^2 de 0,52 e RMQE de 24,22%).

Sinha, Verma e Ayele (2016) estimaram a BAS para uma floresta decídua mista tropical localizada na Índia utilizando dados ópticos do Landsat-5, derivados de IVs e MT e dados de micro-ondas da banda L do ALOS PALSAR. Os resultados usando Landsat TM mostraram correlação fraca (R^2 de 0,295 e RMSE de 35 t ha⁻¹) quando comparado com a polarização Horizontal Horizontal (HH) da banda L do SAR (R^2 de 0,868 e RMSE de 16,06 t ha⁻¹). No entanto, o modelo de previsão teve um desempenho ainda melhor quando o óptico e o SAR foram usados simultaneamente (R^2 de 0,892 e RMSE de 14,08 t ha⁻¹).

Estimando variáveis florestais de uma floresta da Finlândia, Tuominen *et al.* (2017), conseguiram reduzir os erros de estimativa (RMQE) da altura e do diâmetro de árvores em aproximadamente 66% e 54,5%, respectivamente, ao integrar dados FAD a dados Landsat-8. Inclusive verificaram diferença pequena na estimativa entre

os dados LiDAR e FAD (4,8% altura e 1,7% para o diâmetro). Em uma revisão de literatura, não foram encontrados trabalhos que integram o uso de produtos FAD com Landsat-8 para florestas tropicais. Isso reforça a importância da pesquisa e o potencial da técnica a partir dos resultados encontrados nos fragmentos florestais secundários de Mata Atlântica analisados.

O modelo obtido por dados Landsat-8 (BAS_{IF-L8}) apresentou um bom desempenho, em termos de R^2 e RMQE, melhor do que o modelo obtido por dados FAD (BAS_{IF-FAD}) tanto no ajuste como na validação (Tabela 14). A diferença média no RMQE da etapa de validação (27,9% para 30,6%) foi de aproximadamente 10%. Esse resultado difere de outros trabalhos que obtiveram resultados mais acurados na modelagem de variáveis florestais a partir de dados da FAD em comparação aos obtidos por dados orbitais multiespectrais (PULITI *et al.*, 2017; SHEN *et al.*, 2019; TUOMINEN *et al.*; 2017).

O desempenho inferior do modelo BAS_{IF-FAD} (Tabela 14 e Figura 10C e D) pode estar associado à limitação do MDT em representar os valores de altitude sob a vegetação mais densa dos fragmentos. A literatura existente relata a limitação da FAD em representar a estrutura vertical da floresta e o terreno sob vegetação (GOODBODY *et al.*, 2018; GOODBODY *et al.*, 2019; TOMAŠTÍK *et al.*, 2017). Segundo Goodbody *et al.* (2019), normalmente, as altitudes são superestimadas e conseqüentemente, as alturas das árvores subestimadas

Analisando a estimativa da altura dominante nos mesmo fragmentos florestais analisados neste estudo, Almeida *et al.* (2020) observaram uma leve superestimativa (viés igual a 0,6 m) dos valores de altura dominante estimados pela FAD em parcelas com altura dominante acima de 12 metros. Portanto, acredita-se que as alturas das árvores em locais com vegetação mais densa não foram bem representadas pela FAD, apesar do fragmento apresentar vegetação secundária, com muitas clareiras e altamente degradado.

Os resultados do modelo obtido por dados Landsat-8, BAS_{IF-L8} , podem estar associados aos valores mais baixos de BAS dos fragmentos florestais. O papel das bandas espectrais nas imagens de satélites na modelagem de BAS é dependente da complexidade das estruturas da floresta (LU, 2005). Segundo Lu *et al.* (2012) dados Landsat podem fornecer estimativas de biomassa adequadas para a sucessão secundária, mas não são adequados para estimativas de biomassa de florestas maduras devido a problemas de saturação de dados. Além disso, a inclusão das

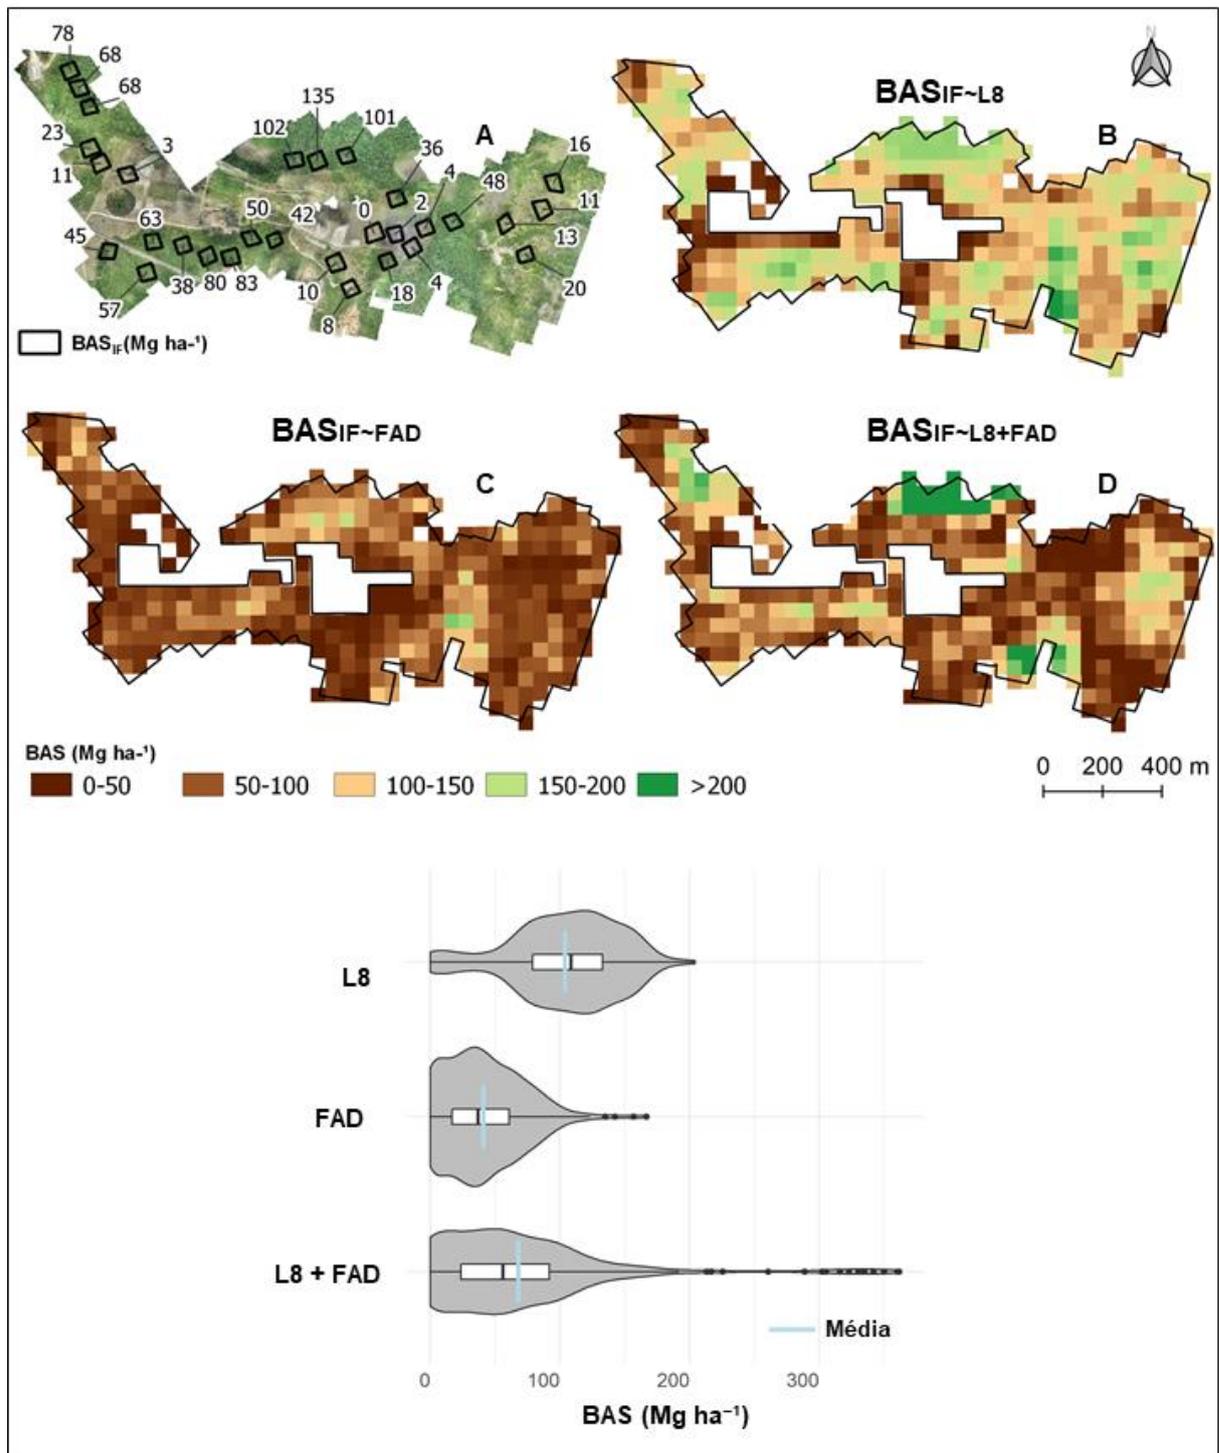
medidas de textura pode ter compensado parcialmente o problema de saturação das bandas do Landat-8 na área de estudo (KELSEY; NEFY, 2014; LÓPEZ-SERRANO *et al.*, 2020).

Quando comparado às médias do inventário com as estimativas de BAS das três abordagens, o modelo $BAS_{IF-L8+FAD}$ apresentou valores mais próximos ($41,40 \text{ Mg ha}^{-1}$) à média obtida pelo inventário florestal ($41,22 \text{ Mg ha}^{-1}$), seguido dos modelos BAS_{IF-L8} ($41,70 \text{ Mg ha}^{-1}$) e BAS_{IF-FAD} ($41,94 \text{ Mg ha}^{-1}$), respectivamente.

Nesse contexto, as três abordagens adotadas de sensoriamento remoto permitiram estimar com acurácia a BAS para os fragmentos analisados. Embora as técnicas tradicionais de inventário possam ser bem-sucedidas para estimativas acerca da média e do total do fragmento, não fornecem informações espaciais para a toda área de estudo. Enquanto as técnicas de sensoriamento remoto possibilitam que estimativas sejam realizadas a nível de *pixel*, mapeando a variabilidade existente em todo o fragmento, garantindo assim maior acurácia com base nos modelos ajustados para as unidades amostrais.

A espacialização para toda a área de estudo dos modelos de melhor desempenho de BAS das três abordagens está representada na Figura 11.

Figura 11 – Ortomosaico com composição cromática RGB produzido utilizando produtos FAD (A); Mapas de estimativa de BAS (50 m x 50 m) das abordagens BAS_{IF-L8} (B), BAS_{IF-FAD} (C), $BAS_{IF-L8+FAD}$ (D) nos fragmentos florestais de Mata Atlântica da bacia do rio Poxim, Sergipe. O gráfico *violin plot* representa a distribuição das estimativas de BAS entre os modelos.



Fonte: Produção da autora. Em que: IF = Inventário Florestal; L8 = Landsat-8; FAD = Fotogrametria Aérea Digital.

A distribuição por classe da espacialização dos modelos de melhor desempenho de BAS das três abordagens está apresentada na Tabela 15. Os modelos BAS_{IF-FAD} e $BAS_{IF-L8+FAD}$ apresentam 66% e 45% das estimativas inferiores a 50 Mg ha^{-1} , respectivamente. Enquanto apenas 11% das estimativas do modelo BAS_{IF-L8} foram inferiores a 50 Mg ha^{-1} (Tabela 15).

Tabela 15 – Distribuição por classe da biomassa acima do solo estimada pelas abordagens BAS_{IF-L8} , BAS_{IF-FAD} e $BAS_{IF-L8+FAD}$ nos fragmentos florestais de Mata Atlântica da bacia do rio Poxim, Sergipe.

Classes de BAS (Mg ha^{-1})	$BAS_{IF-L8}\%$	$BAS_{IF-FAD}\%$	$BAS_{IF-L8+FAD}\%$
0–50	11,26	65,68	45,04
50–100	32,17	31,37	33,51
100–150	42,09	2,41	13,67
150–200	13,94	0,54	3,49
>200	0,54	0,00	4,29

Apesar do desempenho estatístico do modelo com apenas dados espectrais do Landsat-8 (Tabela 14 e Figura 10A e B), esse modelo superestimou espacialmente os valores de BAS dos fragmentos florestais. Nota-se uma grande área de classe de BAS entre 100 e 150 Mg ha^{-1} , representada pela cor alaranjada na Figura 11B e a maior concentração da sua distribuição (Tabela 15). Além do maior valor médio, os valores do primeiro e terceiro percentil de BAS do modelo BAS_{IF-L8} (retângulo horizontal do *violin plot*, Figura 11) foram superiores em relação aos demais. A forma do *violin plot* permite observar também que as estimativas do modelo Landsat-8 se concentraram nas classes de BAS acima de 100 Mg ha^{-1} . Ao comparar a porção nordeste do mapa do modelo BAS_{IF-L8} com a mesma área do ortomosaico, fica evidenciado ainda mais a superestimativa espacial da BAS.

Pela análise do ortomosaico e dos valores referentes as BAS das parcelas de inventário florestal (retângulos pretos), pode-se perceber que na região nordeste da área de estudo são observados valores baixos de biomassa (Figura 11A), diferente do estimado pelo modelo BAS_{IF-L8} . Esse desempenho no momento da espacialização dos valores de BAS pode estar relacionada com a autocorrelação espacial dos valores de BAS estimados nas 30 parcelas de inventário florestal (Figura 11A). Ao gerar estimativas fora do intervalo utilizado no processo de ajuste, o desempenho preditivo

do modelo para toda a área de estudo pode ter sido afetado (DUNCANSON *et al.*, 2021).

Por outro lado, como esperado, os modelos que apresentaram variáveis oriundas de dados obtiveram uma representação espacial de BAS mais próxima da variação observada no inventário (Figura 11C e D).

4.3 ESTIMATIVA DE BAS POR MÉTODO MULTIESCALAR

As estatísticas descritivas das 40 novas parcelas selecionadas do mapa referência BAS_{IF-FAD} são comparadas com a BAS estimada nas 30 parcelas de inventário florestal dos fragmentos florestais secundários de Mata Atlântica da bacia do rio Poxim-SE são apresentadas na Tabela 16.

Tabela 16 – Estatísticas descritivas da biomassa acima do solo estimada por BAS_{IF-FAD} para 40 parcelas selecionadas em relação com as 30 parcelas de inventário florestal nos fragmentos florestais secundários de Mata Atlântica da bacia do rio Poxim, Sergipe.

Estatística ($Mg\ ha^{-1}$)	BAS_{IF} (n = 30)	BAS_{IF-FAD} (n = 40)
Mínimo	0,17	1,06
Máximo	134,78	157,06
Média	41,22	47,31
Desvio padrão da média	35,72	40,24

Nota-se uma correspondência entre os valores de BAS estimados por inventário florestal e os estimados para as parcelas de BAS_{IF-FAD} , comprovando o potencial dos dados FAD em estimar a BAS na área de estudo e a possibilidade de utilizado como dado de referência. Assim como observado por Navarro *et al.* (2019), a comparação entre os valores obtidos por FAD e do inventário florestal mostram que é possível fazer medidas conservadoras e realistas de BAS das árvores a partir dos modelos fotogramétricos 3D. Vale ressaltar mais uma vez que os fragmentos avaliados no estudo passaram nos últimos anos por um acentuado processo de desmatamento e degradação florestal, o que favorece a utilização de dados FAD.

No método de estimativa multiescalar, avaliado no estudo para estimativa de BAS, foram considerados as parcelas de referência BAS_{IF-FAD} e a imagem

multiespectral Landsat-8. O modelo selecionado no método multiescalar ($BAS_{IF-FAD-L8}$) e seu desempenho estatístico está apresentado na Tabela 17. A normalidade e a homocedasticidade dos resíduos dos modelos foi confirmada pelo teste de Shapiro-Wilk e Bartlett's, ao nível de 5% de significância. O modelo de regressão final, $BAS_{IF-FAD-L8}$, explicou 84% da variação de BAS com um RMQE de $15,9 \text{ Mg ha}^{-1}$ (34%).

Tabela 17 – Resultado das estatísticas dos dados de ajuste e validação, do modelo multiescalar para a estimativa de BAS nos fragmentos florestais secundários de Mata Atlântica da bacia do rio Poxim, Sergipe.

Modelo*	Ajuste		Validação	
	R ²	RMQE	R ² cv	RMQE cv
MSR + MT _D B5 + MT _D NDVI + MT _E NDVI + MT _C GEMI + MT _E SAVI	0,84	15,92 (33,7%)	0,77	18,52 (39,2%)

Em que: * = todos coeficientes foram significativos ao nível de 5%, R² = coeficiente de determinação; RMQE = Raiz da Média do Quadrado dos Erros; cv = validação cruzada; Variáveis selecionadas pelos modelos: MSR = Razão Simples Modificada; MT_DB5 = Textura dissimilaridade da B5; MT_DNDVI = Textura dissimilaridade do índice NDVI; MT_ENDVI = Textura entropia do índice NDVI; MT_CGEMI = Textura contraste do índice GEMI; MT_ESAVI = Textura entropia do índice SAVI.

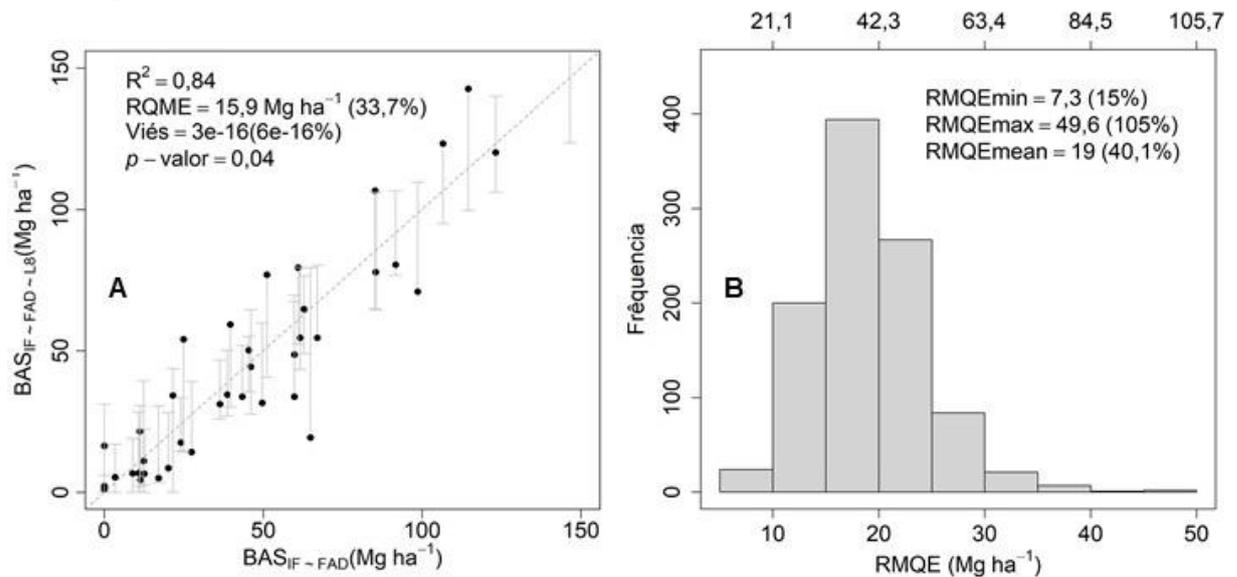
A importância das MTs nos modelos de estimativa de BAS ficou evidente novamente nessa seleção. Das seis variáveis selecionadas no modelo, cinco foram as MTs derivadas da imagem Landsat-8, sendo quatro MTs estimadas a partir de IV (NDVI, GEMI e o SAVI) e uma da banda espectral do infravermelho próximo (banda 5). Apenas o índice de vegetação MSR foi selecionado na sua escala original. Observa-se também nesse modelo a forte relação do NDVI com a BAS, que foi selecionado na forma de Dissimilaridade (MT_DNDVI) e Entropia (MT_ENDVI). Em florestas degradadas da Amazônia brasileira, Santos *et al.* (2019), estimaram a BAS de forma multiescalar utilizando dados de inventário, LiDAR e Landsat-8, e observaram também a importância da inclusão das medidas de textura para um melhor desempenho do modelo.

Na etapa de validação, o modelo multiescalar $BAS_{IF-FAD-L8}$ explicou 77% da variação da BAS com um RMQE de $18,52 \text{ Mg ha}^{-1}$ (39%). Em Santos *et al.* (2019), encontraram um erro de estimativa de BAS de 49,08% na etapa de validação. Em Bispo *et al.* (2020) utilizaram um método de aumento de escala com dados LiDAR e imagens de satélite multiespectral e radar (Landsat-8 e ALOS-2/PALSAR-2) para o Cerrado brasileiro e encontraram um erro de estimativa de 43% (R² de 0,89, RMQE

de 7,58 Mg ha⁻¹ e viés de 0,43 Mg ha⁻¹) para a relação entre os dados de inventário florestal e as variáveis de sensoriamento remoto.

As análises gráficas de dispersão entre os valores estimados pelo modelo multiescalar BAS_{IF-FAD-L8} e pelo modelo de referência BAS_{IF-FAD} são apresentados na Figura 12, além dos histogramas dos valores de RMQE da etapa de validação. As estimativas de BAS foram consideradas diferentes entre si pelo teste F de Graybill (GRAYBILL, 1976) ao nível de 5% de significância. Nota-se uma maior dispersão dos valores de BAS em relação a reta 1:1 (Figura 12A), apesar disso, não foi observada tendência nas estimativas. O erro máximo de validação observado foi de aproximadamente 50 Mg ha⁻¹.

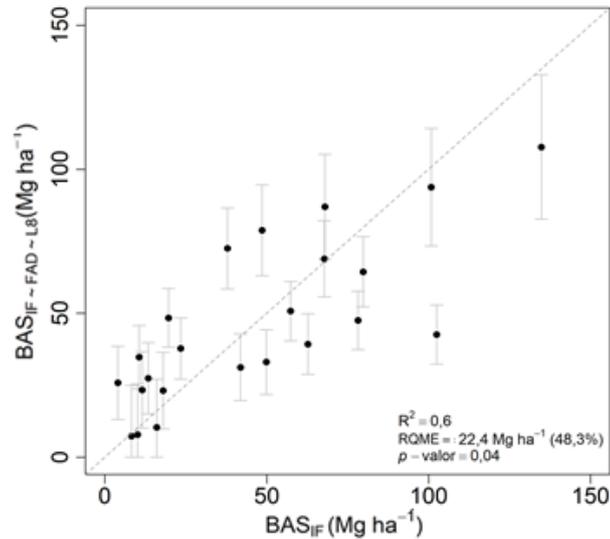
Figura 12 – Gráfico de dispersão a partir dos dados de ajuste e histogramas com a distribuição dos valores RMQE obtidos no procedimento de validação cruzada para a abordagem multiescalar BAS_{IF-FAD-L8} e valores de referência BAS_{IF-FAD}.



Fonte: Produção da autora.

A comparação entre os valores de BAS estimados no inventário (30 parcelas) e o modelo multiescalar é apresentada na Figura 13. As estimativas de BAS são consideradas estatisticamente diferentes (p valor = 0,04) pelo teste F de Graybill (GRAYBILL, 1976), ao nível de 5% de significância. A correlação verificada foi de R^2 igual a 0,6 e erro de estimativa de 48,3%. No geral, não foi observada nenhuma tendência de estimativa.

Figura 13 – Gráficos de dispersão a partir dos dados de ajuste para das estimativas de biomassa do modelo multiescalar $BAS_{IF-FAD-L8}$ e parcelas de inventário florestal.

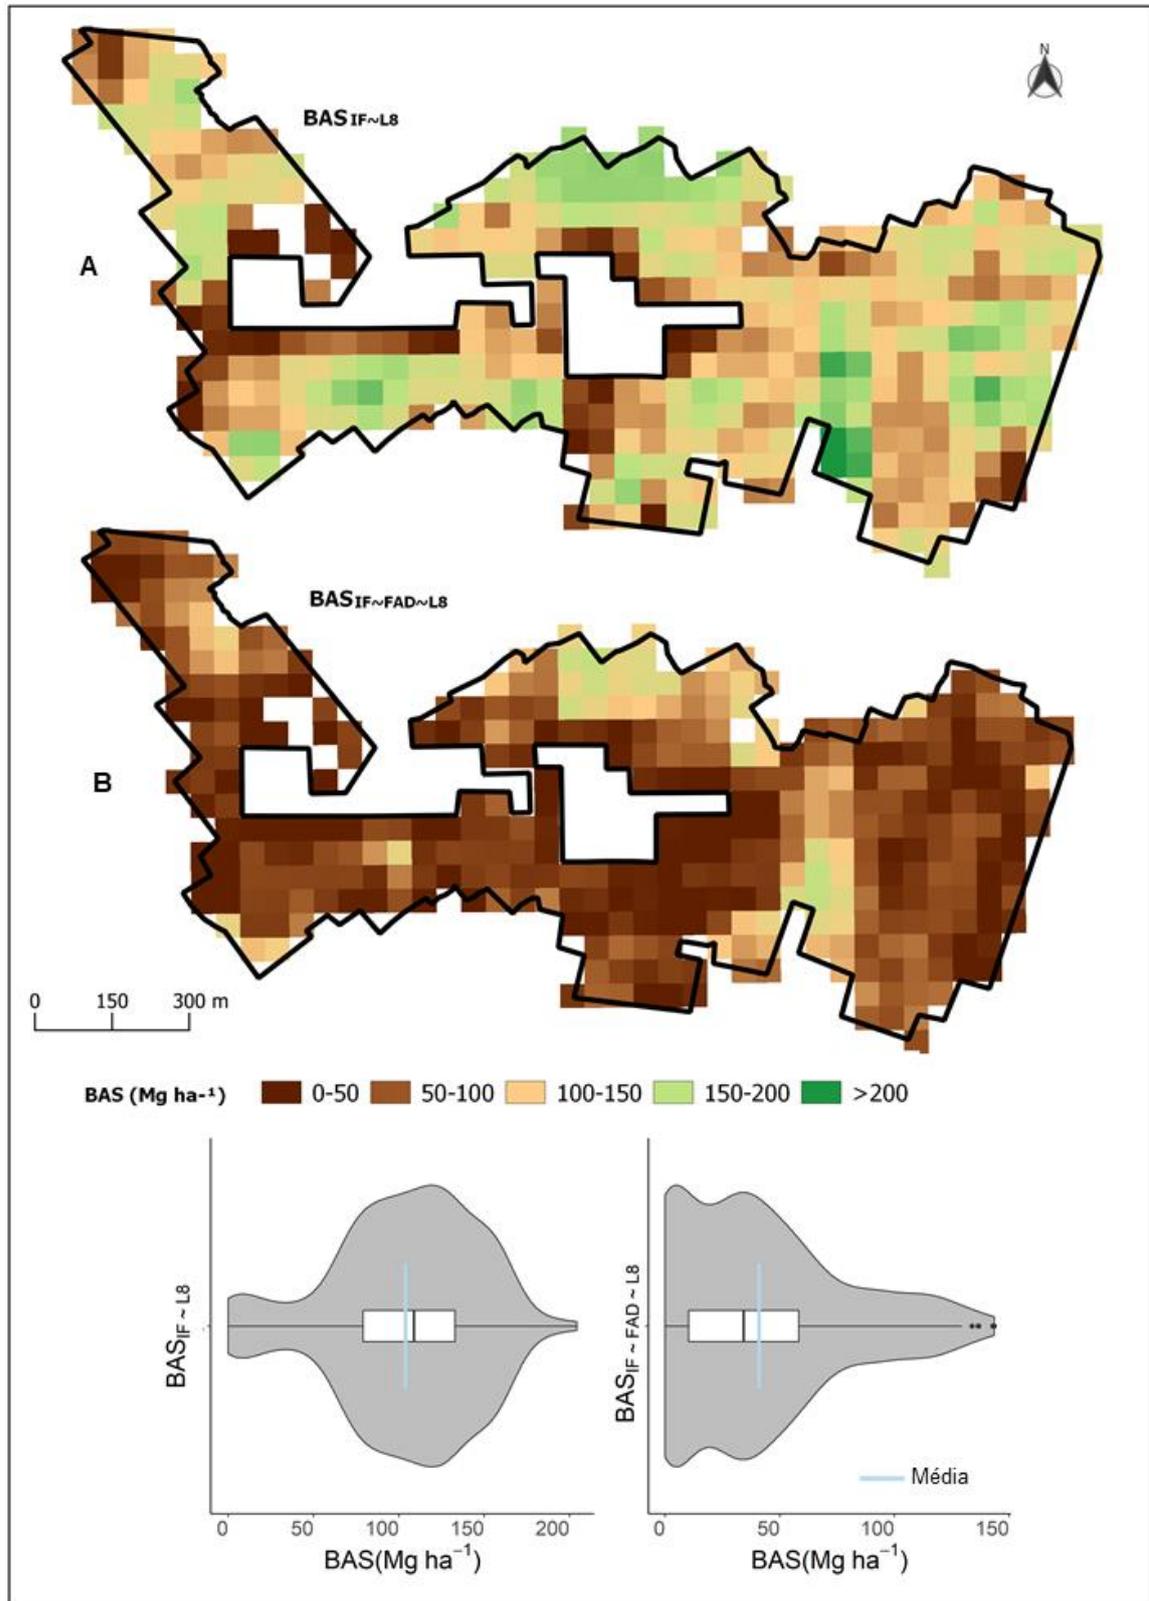


Fonte: Produção da autora. Em que: p-valor é referente ao teste F de Graybill.

O modelo multiescalar quando comparado ao modelo direto a partir de apenas dados Landsat-8, BAS_{IF-L8} , apresenta menor R^2 e maior RMSE (Tabela 14 e Tabela 17). Em contrapartida, Wang *et al.* (2020), obtiveram um modelo multiescalar $IF \sim LiDAR \sim Sentinel-2$ com um desempenho moderado (R^2 de 0,62 e RMSE de 50,36 $Mg\ ha^{-1}$) para estimar BAS de manguezais na China, mas superior ao modelo direto $IF \sim Sentinel\ 2$ (R^2 de 0,52 e RMSE de 56,63 $Mg\ ha^{-1}$). Essa diferença pode estar relacionada à fonte de dados usada, vegetação estudada e por esse estudo considerar a autocorrelação espacial de dados ao validar o modelo de mapeamento BAS_{IF-FAD} .

A espacialização (50 m x 50 m) para toda a área de estudo do modelo BAS multiescalar $BAS_{IF-FAD-L8}$ selecionado de melhor desempenho está representada na Figura 14. Os valores de BAS variaram entre 0 a 143,55 $Mg\ ha^{-1}$. A BAS média é 40,98 $Mg\ ha^{-1}$. Nota-se que quando comparado a espacialização do modelo de estimativa direto produzido apenas pelas variáveis Landsat-8, o BAS_{IF-L8} apresenta um número maior de *pixels* distribuídos nas classes maiores de BAS (acima de 100 $Mg\ ha^{-1}$) (Figura 14).

Figura 14 – Mapa de estimativa de biomassa acima do solo (50 m x 50 m) para a o método direto $BAS_{IF \sim L8}$ (A) e multiescalar $BAS_{IF \sim FAD \sim L8}$ (B) nos fragmentos florestais de Mata Atlântica da bacia do rio Poxim, Sergipe. O gráfico de *violin plot* representa a distribuição dos valores da estimativa de biomassa dos respectivos modelos.



Fonte: Produção da autora.

Avaliando a distribuição da BAS dos modelos espacializados, pelo formato do *violin plot* percebe-se que a valores estimados pelo modelo multiescalar se concentraram nas classes de BAS inferior a 50 Mg ha^{-1} (Figura 14), resultado mais próximo ao da realidade observada no campo. Nota-se também que o valor médio (linha vertical azul no interior do *boxplot*, $41,0 \text{ Mg ha}^{-1}$) se aproximou mais do valor obtido no inventário ($41,22 \text{ Mg ha}^{-1}$).

Mesmo que o método direto a partir das variáveis Landsat-8 tenha sido mais acurado a nível de parcelas, é importante levar em conta a capacidade de generalização do método de estimativa e os resultados obtidos para todo o fragmento. Nesse sentido, as variáveis independentes da FAD apresentaram serem mais aptas à espacialização para a área de estudo, tanto no método multiescalar, que tem como referências dados obtidos por FAD, quanto no método direto.

O desempenho do modelo $\text{BAS}_{\text{IF-FAD-L8}}$ em espacializar a BAS para toda a área de estudo, pode estar relacionado com a ausência de correlação espacial das 40 parcelas de referência de BAS utilizadas no momento do ajuste. Como já apresentado anteriormente, a dependência espacial entre os dados pode resultar em uma grande superestimação do desempenho preditivo do modelo (DUNCANSON *et al.*, 2021).

A performance do modelo pode ser atribuída às características da área de estudo, como a baixa densidade de indivíduos e presença de clareiras. A alta acurácia observada nos modelos está de acordo com estudos que encontram resultados melhores em áreas com menor densidade de dossel (DANDOIS; OLANO; ELLIS, 2015; WALLACE *et al.* 2016).

A utilização de variáveis independentes de FAD como dados de referência para o método multiescalar demonstrou ser uma alternativa interessante devido à qualidade apresentada no estudo. As estimativas encontradas de BAS utilizando dados FAD demonstraram serem capazes de fornecer estimativas confiáveis, conforme observado por Almeida *et al.* (2020) e Navarro *et al.* (2018), apresentando dados similares aos de inventário florestal a menor custo e tempo.

A vantagem do uso método multiescalar é a possibilidade, utilizando apenas dados tridimensionais, de extrapolar a estimativa de BAS além das parcelas amostradas pelo inventário. A obtenção de informações por meio do sensoriamento remoto de toda a área garante maior representatividade da vegetação analisada e possibilita estimativas com maior acurácia. Enquanto o inventário florestal apresenta cobertura restrita apenas às parcelas amostradas durante o campo.

Ainda com relação a obtenção de dados, outra vantagem é a possibilidade de reduzir o número de parcelas a serem mensuradas em campo, o que acarreta uma redução de custos e maior agilidade no processo. Wang *et al.* (2020), por exemplo, observaram que o seu modelo multiescalar proposto possibilitou a redução significativa de 37% do número de amostras de campo necessárias em comparação com aqueles exigidos pelo inventário florestal na área de estudo.

O método multiescalar proporciona um ganho espacial devido a possibilidade de realizar a extrapolação das métricas precisas de FAD para áreas maiores usando dados orbitais multiespectrais. Além disso, os dados multiespectrais Landsat-8 possibilitam utilizar séries temporais das imagens para monitorar o comportamento da BAS ao longo dos anos (NGUYEN *et al.*, 2020; WULDER *et al.*, 2019).

O estudo ilustra os potenciais do uso de dados FAD, capazes de fornecer estimativas confiáveis para dados de referência ao método multiescalar. O resultado do modelo BAS_{IF-FAD} apresentou desempenho da estimativa de BAS similares aos dados de inventário florestal, além de possibilitar o aumento do número de parcelas de inventário através da FAD de modo a melhorar as estimativas de BAS de grandes áreas.

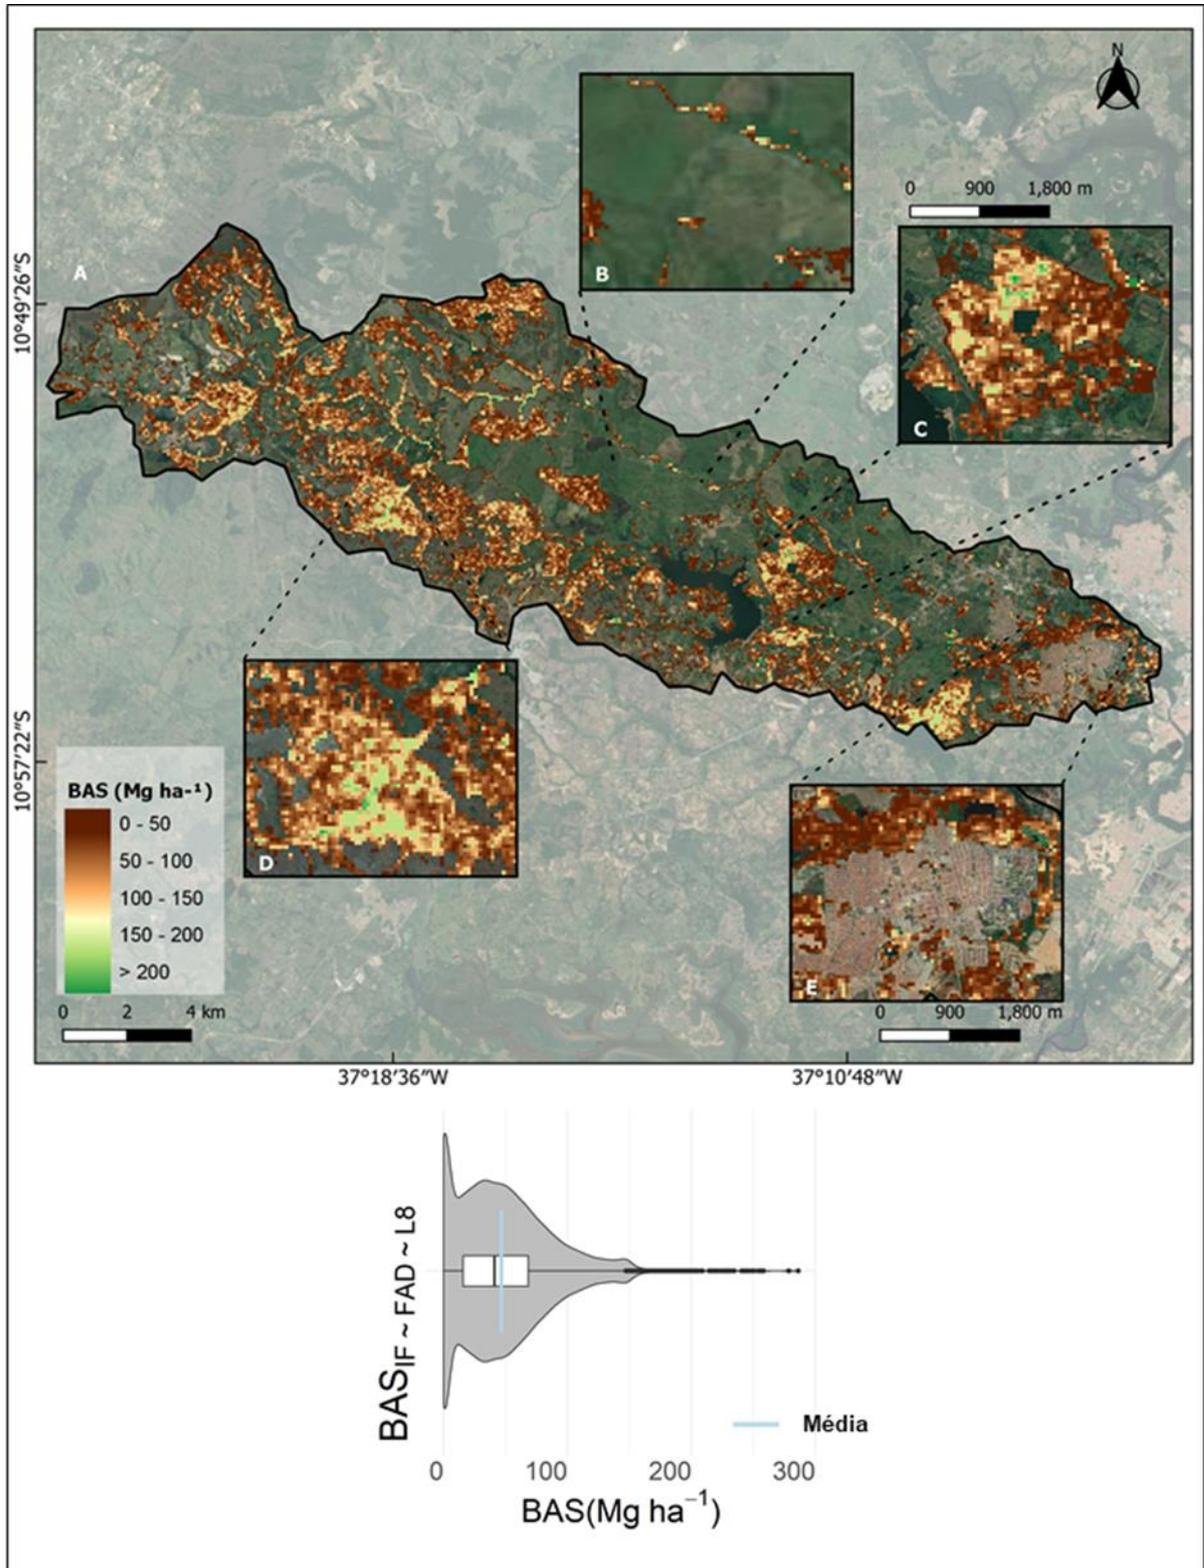
Deve-se frisar que durante esse estudo não foi possível incluir dados FAD de diferentes locais da bacia de estudo, de forma a cobrir mais variações da BAS na região. As estimativas de BAS quando realizadas em escalas regionais ou maiores, necessitam apresentar um maior número de área de inventário de forma a considerar as variações potenciais das características da vegetação. Em Wang *et al.* (2020) ao estender o estudo da escala local (uma área de estudo) para a escala regional na ilha de Hainan (combinando dados de duas reservas de estudo) observaram que a estimativa de BAS foi melhorada.

Como sugestão é recomendado para os próximos trabalhos incluírem diferentes voos realizados por ARP em pontos da área de pesquisa. De maneira a explorar maior variação da BAS da bacia, e assim aumentar o número de parcelas de referência e conseqüentemente o poder preditivo do modelo multiescalar. A ferramenta se apresenta como economicamente viável, algo particularmente importante em locais onde menos dados estão disponíveis, como as florestas tropicais. Portanto, são necessárias mais pesquisas avaliando a combinação entre dados FAD e L8 com o intuito de aumentar a precisão dos dados de biomassa em nível regional.

4.4 ESTIMATIVA DE BAS PARA A BACIA

O modelo multiescalar $BAS_{IF-FAD-L8}$ foi usado para estimar a BAS para toda a cobertura florestal identificada na bacia de estudo. A área total de florestas mapeadas ao longo da bacia foi de 8.057,89 hectares. A espacialização da estimativa de BAS para as áreas de florestas é apresentada na Figura 15. Os valores de BAS ao longo da bacia variam entre 0 a 286,11 $Mg\ ha^{-1}$. A BAS média é 46,51 $Mg\ ha^{-1}$, um valor médio próximo ao observado para os fragmentos da área de estudo (41,22 $Mg\ ha^{-1}$).

Figura 15 – Mapa de estimativa de BAS (50 m x 50 m) em áreas de florestas de Mata Atlântica da bacia do rio Poxim, Sergipe. Os zooms (B, C, D e E) na figura demonstram as variações da BAS. O gráfico de *violin plot* representa a distribuição dos valores de BAS.



Fonte: Produção da autora. A imagem de fundo corresponde ao Map data ©2016 Google.

Próximo ao exutório da bacia, observa-se uma grande aglomeração urbana e um reduzido número de fragmentos (Figura 15E). Na margem esquerda (Figura 15B) observa-se uma menor presença de vegetação, em decorrência de uma forte aptidão agrícola dessa parte da bacia. Já na Figura 15C e D estão destacadas as áreas de maiores valores de BAS estimadas na bacia.

A distribuição e proporção da BAS para as áreas de floresta identificadas ao longo da bacia é apresentada na Tabela 18. A BAS da bacia pode ser considerada baixa. Aproximadamente 90% da BAS da bacia concentra-se entre os menores valores de biomassa (abaixo de 100 Mg ha⁻¹). Enquanto a contribuição da BAS acima de 100 Mg ha⁻¹ é inferior a 10%.

Tabela 18 – Distribuição da BAS para as áreas de floresta de Mata Atlântica da bacia do rio Poxim, Sergipe.

Classes de BAS (Mg ha ⁻¹)	Área (ha)	%
0–50	4762,86	59,11
50–100	2509,77	31,15
100–150	701,29	8,70
150–200	2508,53	0,92
>200	10,00	0,12
Total	8057,89	100,00

Considerando a área total da bacia hidrográfica do rio Poxim, estima-se que apenas 33,6% da bacia apresenta áreas de floresta da Mata Atlântica. Nessas áreas mapeadas percebe-se uma acentuada fragmentação/isolamento e uma reduzida área individual. Resultado também observado em outros trabalhos realizados ao longo da bacia (DE AGUIAR NETTO *et al.*, 2013; FERREIRA *et al.*, 2011; JESUS *et al.*, 2015).

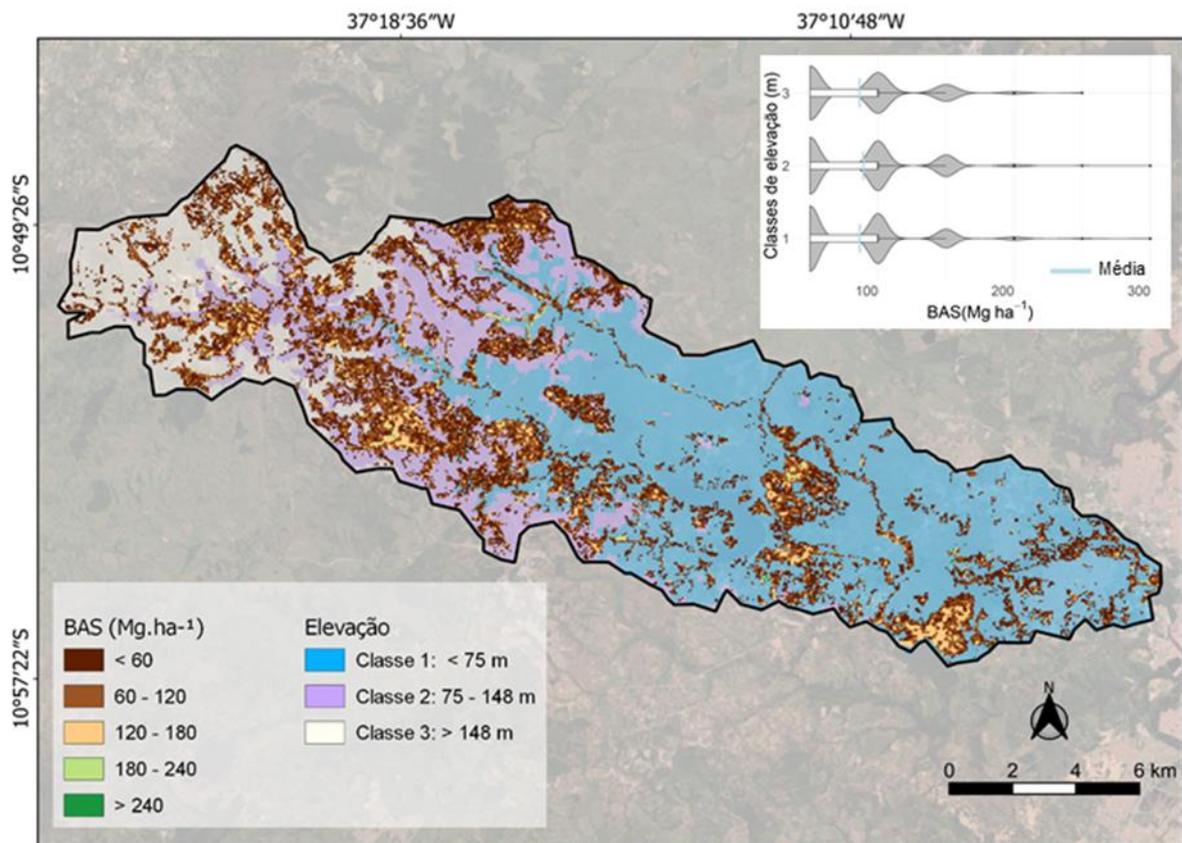
Segundo Ribeiro *et al.* (2009) aproximadamente 80% dos fragmentos florestais de Mata Atlântica do território brasileiro são menores que 50 ha e em sua maioria possuem menos de 30% de cobertura florestal nativa. Esse percentual apresenta-se como um limite crítico para a conservação da biodiversidade a longo prazo (BANKS-LEITE *et al.*, 2014).

De modo geral, ao longo da bacia hidrográfica do Poxim são relatadas perturbações antropogênicas. Essas atividades antrópicas envolvem corte seletivo de árvores, substituição de áreas de mata nativa por áreas de pastagens, incêndios,

abertura de clareiras e desenvolvimento urbano não regulamentado (DE AGUIAR NETTO *et al.*, 2013; JESUS *et al.*, 2015). Ferreira *et al.* (2011) também observaram que as 20 principais nascentes dos rios e tributários, que compõem a bacia hidrográfica do rio Poxim, 90% apresentam alterações decorrentes da acelerada antropização, 65% delas com elevada degradação (sem raio mínimo de 50 m de vegetação) e 50% ocupadas por agricultura e 35% pastagens.

A distribuição da BAS das áreas de floresta identificadas de acordo com a elevação da bacia do rio Poxim é apresentada na Figura 16.

Figura 16 – Distribuição da BAS para áreas de florestais de Mata Atlântica de acordo com a elevação da bacia do rio Poxim, Sergipe. O gráfico de *violin plot* representa a distribuição dos valores de BAS de acordo com as classes de elevação.



Fonte: Produção da autora. A imagem de fundo corresponde ao Map data ©2016 Google.

A combinação de variáveis espectrais e topográficas, como elevação do terreno, podem influenciar na distribuição da BAS ao longo da área de estudo (NAVARRO *et al.*, 2020; RAJPUT *et al.*, 2015; SILVEIRA *et al.*, 2019). Silveira *et al.* (2019) observaram que 73,60% dos remanescentes florestais da bacia hidrográfica do rio Doce, MG, foram influenciados diretamente, em termos de BAS, pela elevação

montanhosa. Ao contrário do constatado por Silveira *et al.* (2019), a distribuição da BAS é considerada constante ao longo da bacia do rio Poxim (linha azul do *violin plot*, Figura 16). Esse resultado pode ser explicado pela baixa elevação e variabilidade da bacia estudada, concentrada em elevações inferiores a 74,7 metros (classe 1).

5 CONCLUSÕES

O uso de dados de fotogrametria aérea digital obtida por aeronave remotamente pilotada e dados ópticos multiespectrais da série Landsat-8 apresentaram potencial para estimar com precisão, de forma independente ou em conjunto, a biomassa acima do solo em áreas degradadas quando comparado ao inventário florestal tradicional. É recomendada a utilização de dados de textura e índices de vegetação para a estimativa de biomassa a partir de imagens orbitais Landsat-8.

A combinação de dados Landsat-8 e de fotogrametria aérea digital apresentou melhor desempenho em estimar a biomassa acima do solo. Embora as três abordagens do método direto apresentaram resultados precisos.

O mapa produzido pela fotogrametria aérea digital apresentou valores semelhantes ao encontrado por inventário florestal tradicional, podendo ser utilizado como referência para a calibração de modelos de estimativa de biomassa a partir de dados orbitais multiespectrais na ausência de dados de inventário.

O modelo multiescalar proposto combinando dados de inventário florestal, fotogrametria aérea digital e dados multiespectrais do Landsat-8 proporcionou a elaboração de modelo para estimativas precisas de biomassa acima do solo para a bacia do rio Poxim e aumento do número de amostras. O desenvolvimento desse modelo permite a utilização em uma série temporal de dados orbitais a fim de explorar as análises e estudos que abordam a dinâmica da biomassa florestal.

No entanto, para análises futuras é sugerido a utilização de maiores áreas de florestas sobrevoadas por aeronave remotamente pilotada de forma a obter maior variação na biomassa florestal aérea da bacia e aumentar o poder preditivo do modelo.

REFERÊNCIAS

AGISOFT, L. L. C. **Agisoft Metashape User Manual, Professional edition, Version 1.0**. Agi Soft LLC, St. Petersburg, Rússia. Disponível em: <https://www.agisoft.com/p.f./metashape-pro_1_0_en.p.f.>, (acessado em 5 de fevereiro de 2020).

ALMEIDA, A.; GONÇALVES, F.; SILVA, G.; SOUZA, R.; TREUHAFT, R.; SANTOS, W.; LOUREIRO, D.; FERNANDES, M. Estimating structure and biomass of a secondary Atlantic forest in Brazil using fourier transforms of vertical profiles derived from UAV photogrammetry point clouds. **Remote Sensing**, v. 12, n. 21, p. 3560, 2020.

ALVARES, C.A.; STAPE, J.L.; SENTELHAS, P.C.; GONÇALVES, J.L. de M.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2013.

ALVES, L. F.; VIEIRA, S. A.; SCARANELLO, M. A.; CAMARGO, P. B.; SANTOS, F. A.; JOLY, C. A.; MARTINELLI, L. A. Forest structure and live aboveground biomass variation along an elevational gradient of tropical Atlantic moist forest (Brazil). **Forest ecology and management**, v. 260, n. 5, p. 679–691, 2010.

ASNER, G.P. Cloud cover in Landsat observations of the Brazilian Amazon. **International journal of remote sensing**, n. 22, v. 18, p. 3855–3862, 2001.

AXELSSON, P. Processing of laser scanner data—algorithms and applications. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 54, n. 2, p. 138–147, 1 jul. 1999.

BACCINI, A G.S.J.; ASNER, G.P. Improving pantropical forest carbon maps with airborne LiDAR sampling. **Carbon Management**, v. 4, n. 6, p. 591–600, 2013.

BACCINI, A.G.S.J.; 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. Estimated carbon dioxide emissions from tropical deforestation improved by carbon-density maps. **Nature climate change**, v. 2, n. 3, p.182–185, 2012.

BANKS-LEITE, C.; PARDINI, R.; TAMBOSI, L.R.; PEARSE, W.D.; BUENO, A.A.; BRUSCAGIN, R.T.; CONDEZ, T.H.; DIXO, M.; IGARI, A.T.; MARTENSEN, A.C.;

METZGER, J.P. Using ecological thresholds to evaluate the costs and benefits of set-asides in a biodiversity hotspot. **Science**, .v. 345, n. 6200, p. 1041–1045, 2014.

BARBOSA, J. M.; MELENDEZ-PASTOR, I.; NAVARRO-PEDREÑO, J.; BITENCOURT, M. D. Remotely sensed biomass over steep slopes: An evaluation among successional stands of the Atlantic Forest, Brazil. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 88, p. 91-100, 2014.

BASKERVILLE, G.L. Use of Logarithmic Regression in the Estimation of Plant Biomass. **Canadian Journal of Forest Research**, v. 2, n. 1, p.49–53, 1972.

BECKNELL, J.M.; KELLER, M.; PIOTTO, D.; LONGO, M.; DOS SANTOS, M.N.; SCARANELLO, M.A.; DE OLIVEIRA CAVALCANTE, R.B.; PORDER, S. Landscape-scale lidar analysis of aboveground biomass distribution in secondary Brazilian Atlantic Forest. **Biotropica**, v. 50, n. 3, p. 520–530, 2018.

BISPO, P.D.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, p. 2685, 2020.

BONAN, G. B. Forests and climate change: Forcings, Feedbacks, and the Climate Benefits of Forests. **Science**, v. 320, n. 5882, p. 1444–1449, 2008.

BRIENEN, R. J. W.; PHILLIPS, O. L.; FELDPAUSCH, T. R.; GLOOR, E.; BAKER, T. R.; LLOYD, J.; LOPEZ-GONZALEZ, G.; MONTEAGUDO-MENDOZA, A.; MALHI, Y.; LEWIS, S. L.; VÁSQUEZ MARTINEZ, R.; ALEXIADES, M.; ÁLVAREZ DÁVILA, E.; ALVAREZ-LOAYZA, P.; ANDRADE, A.; ARAGÃO, L. E. O. C.; ARAUJO-MURAKAMI, A.; ARETS, E. J. M. M.; ARROYO, L.; AYMARD, G. A.; BÁNKI, O. S.; BARALOTO, C.; BARROSO, J.; BONAL, D.; BOOT, R. G. A.; CAMARGO, J. L. C.; CASTILHO, C. V.; CHAMA, V.; CHAO, K. J.; CHAVE, J.; COMISKEY, J. A.; CORNEJO VALVERDE, F.; COSTA, L.; OLIVEIRA, E. A.; DI FIORE, A.; ERWIN, T. L.; FAUSET, S.; FORSTHOFER, M.; GALBRAITH, D. R.; GRAHAME, E. S.; GROOT, N.; HÉRAULT, B.; HIGUCHI, N.; HONORIO CORONADO, E. N.; KEELING, H.; KILLEEN, T. J.; LAURANCE, W. F.; LAURANCE, S.; LICONA, J.; MAGNUSSEN, W. E.; MARIMON, B. S.; MARIMON JUNIOR, B. H.; MENDOZA, C.; NEILL, D. A.; NOGUEIRA, E. M.; NUÑEZ, P.; PALLQUI CAMACHO, N. C.; PARADA, A.; PARDO MOLINA, G.; PEACOCK, J.; PEÑA-CLAROS, M.; PICKAVANCE, G. C.; PITMAN, M. C. A.; POORTER, L.; PRIETO, L.; QUESADA, C. A.; RAMIREZ, F.; RAMIREZ-ANGULO, H.; RESTREPO, Z.; ROOPSIND, A.; RUDAS, A.; SALOMÃO, R. P.;

SCHWARZ, M.; SILVA, N.; SILVA ESPEJO, J. E.; SILVEIRA, M.; STROPP, J.; TALBOT, J.; TEER STEEGE, H.; TERAN-AGUILAR, J.; TERBOGH, J.; THOMAS CAESAR, R.; M. , T.; TORELLO RAVENTOS, M.; UMETSU, R. K.; VAN DER HEIJDEN, G. M. F.; VAN DER HOUT, P.; GUIMARÃES VIEIRA, I. C.; VIEIRA, S. A.; E. , V.; VOS, V. A.; ZAGT, R. J. Long-term decline of the Amazon carbon sink. **Nature**, n. 519, v. 7543, p. 344–348, 2015.

BROWN, S. Estimating biomass and biomass change of tropical forests: a primer. **Food & Agriculture Org.**, v. 134, 1997.

BROWN, S.; GILLESPIE, A.J.; LUGO, A.E. Biomass estimation methods for tropical forests with applications to forest inventory data. **Forest science**, v. 35, n. 4, p. 881–902, 1989.

CAO, Z.; MA, R.; DUAN, H.; XUE, K. Effects of broad bandwidth on the remote sensing of inland waters: Implications for high spatial resolution satellite data applications. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 153, p. 110–122, 2019.

CHAMPION, I.; DUBOIS-FERNANDEZ, P.; GUYON, D.; COTTREL, M. Radar image texture as a function of forest stand age. **International Journal of Remote Sensing**, v. 29, n. 6, p. 1795–1800, 2008.

CHAVE, J.; ANDALO, C.; BROWN, S.; CAIRNS, M.A.; CHAMBERS, J.Q.; EAMUS, D.; FÖLSTER, H.; FROMARD, F.; HIGUCHI, N.; KIRA, T. Tree allometry and improved estimation of carbon stocks and balance in tropical forests. **Oecologia**, v. 145, n. 1, p. 87–99, 2005.

CHAVE, J.; CONDIT, R.; AGUILAR, S.; HERNANDEZ, A.; LAO, S.; PEREZ, R. Error propagation and scaling for tropical forest biomass estimates. **Philosophical Transactions of the Royal Society of London. Series B: Biological Sciences**, v. 359, n. 1443, p. 409–420, 2004.

CHAVE, J.; MULLER-LANDAU, H.C.; BAKER, T.R.; EASDALE, T.A.; TER STEEGE, H.; WEBB, C.O. Regional and phylogenetic variation of wood density across 2456 neotropical tree species. **Ecological Applications**, v. 16, n. 6, p. 2356–2367, 2006.

CHAVE, J.; RIÉRA, B.; DUBOIS, M.A. Estimation of biomass in a neotropical forest of French Guiana: spatial and temporal variability. **Journal of Tropical Ecology**, p. 79–96, 2001.

CHAZDON, R.L.; URIARTE, M. Natural regeneration in the context of large-scale forest and landscape restoration in the tropics. **Biotropica**, v. 48, n. 6, p. 709–715, 2016.

CHEN, J. M. Evaluation of vegetation indices and a modified simple ratio for boreal applications. **Canadian Journal of Remote Sensing**, v. 22, n. 3, p. 229–242, 1996.

CHEN, Q.; LAURIN, G.V.; BATTLES, J.J.; SAAH, D. Integration of airborne lidar and vegetation types derived from aerial photography for mapping aboveground live biomass. **Remote Sensing of Environment**, v. 121, p. 108–117, 2012.

CURRAN, P. J. The semivariogram in remote sensing: An introduction. **Remote Sensing of Environment**, v. 24, n. 3, p. 493–507, 1988.

DANDOIS, J. P.; ELLIS, E. C. High spatial resolution three-dimensional mapping of vegetation spectral dynamics using computer vision. **Remote Sensing of Environment**, v. 136, p. 259–276, 2013.

DANDOIS, J. P.; OLANO, M.; ELLIS, E. C. Optimal altitude, overlap, and weather conditions for computer vision UAV estimates of forest structure. **Remote Sensing**, v. 7, n. 10, p. 13895–13920, 2015.

DE AGUIAR NETTO, A.O.; GARCIA, C.A.B.; ALVES, J.D.P.H.; FERREIRA, R.A. ;DA SILVA, M.G. Physical and chemical characteristics of water from the hydrographic basin of the Poxim River, Sergipe State, Brazil. **Environmental monitoring and assessment**, v. 185, n. 5, p. 4417–4426, 2013.

DE JESUS, E. N.; FERREIRA, R. A.; ARAGÃO, A. G.; SANTOS, T. I. S.; ROCHA, S. L. Estrutura dos fragmentos florestais da bacia hidrográfica do rio Poxim-SE, como subsídio à restauração ecológica. **Revista Árvore**, v. 39, n. 3, p. 467–474, 2015.

DEERING, D.W.; ROUSE, J.W.; HAAS, R.H.; SCHEL, J.A. Measuring Forage Production of Grazing Units from Landsat MSS Data. **Proceedings of the 10th International Symposium of Remote Sensing of Environment**, Ann Arbor, MI, USA, 6–10 October 1975; II, p. 1169–1178.

DIETMAIER, A.; MCDERMID, G.J.; RAHMAN, M.M.; LINKE, J.; LUDWIG, R. comparison of LiDAR and Digital Aerial Photogrammetry for Characterizing Canopy Openings in the Boreal Forest of Northern Alberta. **Remote Sensing**, v. 11, n. 16, p. 919, 2019.

DUBE, T.; MUTANGA, O. Investigating the robustness of the new Landsat-8 Operational Land Imager derived texture metrics in estimating plantation forest aboveground biomass in resource constrained areas. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 108, p. 12–32, 2015a.

DUBE, T.; MUTANGA, O. Evaluating the utility of the medium-spatial resolution Landsat 8 multispectral sensor in quantifying aboveground biomass in uMgeni catchment, South Africa. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 101, n. 1 p. 36–46, 2015b.

DUNCANSON, L.; ARMSTON, J.; DISNEY, M.; AVITABILE, V.; BARBIER, N.; CALDERS, K.; CARTER, S.; CHAVE, J.; HEROLD, M.; MACBEAN, N. AND MCROBERTS, R.; 2021. **Aboveground Woody Biomass Product Validation Good Practices Protocol**. Version 1.0.

DURANTE, P.; MARTÍN-ALCÓN, S.; GIL-TENA, A.; ALGEET, N.; TOMÉ, J. L.; RECUERO, L.; PALACIOS-ORUETA, A.; OYONARTE, C. Improving Aboveground Forest Biomass Maps: From High-Resolution to National Scale. **Remote Sensing**, v. 11, n. 7, p. 795, 2019.

ECKERT, S. Improved forest biomass and carbon estimations using texture measures from WorldView-2 satellite data. **Remote Sensing**, v. 4, n. 1, p. 810–829, 2012.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (EMBRAPA). **Sistema brasileiro de classificação de solos**. Brasília: Embrapa, 1999. 412p.

ERB, K.H.; KASTNER, T.; PLUTZAR, C.; BAIS, A.L.S.; CARVALHAIS, N.; FETZEL, T.; GINGRICH, S.; HABERL, H.; LAUK, C.; NIEDERTSCHEIDER, M.; PONGRATZ, J. Unexpectedly large impact of forest management and grazing on global vegetation biomass. **Nature**, v.553, n. 7686, p. 73–76, 2018.

FENG, Y.; LU, D.; CHEN, Q.; KELLER, M.; MORAN, E.; DOS-SANTOS, M.N.; BOLFE, E.L.; BATISTELLA, M. Examining effective use of data sources and modeling algorithms for improving biomass estimation in a moist tropical forest of the Brazilian Amazon. **International Journal of Digital Earth**, n. 10, v. 10, p. 996–1016, 2017.

FERRAZ, S. F.; FERRAZ, K. M.; CASSIANO, C. C.; BRANCALION, P. H. S.; DA LUZ, D. T.; AZEVEDO, T. N.; TAMBOSI, L. R.; METZGER, J. P. How good are tropical forest patches for ecosystem services provisioning?. **Landscape ecology**, v. 29, n. 2, p. 187–200, 2014.

FERREIRA, R.A.; DE AGUIAR NETTO, A.D.O.; SANTOS, T.I.S.; SANTOS, B.L.; MATOS, E.L.D. Nascentes da sub-bacia hidrográfica do rio Poxim, estado de Sergipe: da degradação à restauração. **Revista Árvore**, v. 35, n. 2, p. 265–277, 2011.

FOGA, S.; SCARAMUZZA, P.L.; GUO, S.; ZHU, Z.; DILLEY JR, R.D.; BECKMANN, T.; SCHMIDT, G.L.; DWYER, J.L.; HUGHES, M.J.; LAUE, B. Cloud detection algorithm comparison and validation for operational Landsat data products. **Remote Sensing of Environment**, v. 194, p. 379–390, 2017.

FREITAS, S.R.; MELLO, M.C.S.; CRUZ, C.B.M. Relationships between forest structure and vegetation indices in Atlantic Rainforest. **Forest Ecology and Management**, v. 218, n. 1–3, p. 353–362, 2005.

FUNDAÇÃO SOS MATA ATLÂNTICA; INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS – INPE. **Atlas dos Remanescentes Florestais da Mata Atlântica, período 2017-2018**. Relatório Técnico. São Paulo, 2019. 35 p.

GATES, D.M.; KEEGAN, H.J.; SCHLETER, J.C.; WEIDNER, V.R. Spectral properties of plants. **Applied optics**, v. 4, n. 1, p. 11–20, 1965.

GIBBS, H. K.; BROWN, B.; NILES, J. O.; FOLEY, J. Monitoring and estimating tropical forest carbon stocks: Making REDD a reality. **Environmental Research Letters**, v. 2, n. 4, 2007.

GONÇALVES, F. G. **Vertical Structure and Aboveground Biomass of Tropical Forests from Lidar Remote Sensing**. Ph.D. Thesis, Oregon State University, Corvallis, OR, USA, 2014.

GONÇALVES, F.; TREUHAFT, R.; LAW, B.; ALMEIDA, A.; WALKER, W.; BACCINI, A.; DOS SANTOS, J.R.; GRAÇA, P. Estimating aboveground biomass in tropical forests: field methods and error analysis for the calibration of remote sensing observations. **Remote Sensing**, v. 9, n. 47, p. 1–23, 2017.

GONZÁLEZ-FERREIRO, E.; DIÉGUEZ-ARANDA, U.; MIRANDA, D. Estimation of stand variables in *Pinus radiata* D. Don plantations using different LiDAR pulse densities. **Forestry**, v.85, n.2, p.281–292, 2012.

GONZÁLEZ-JARAMILLO, V.; FRIES, A.; BENDIX, J. AGB estimation in a tropical mountain forest (TMF) by means of RGB and multispectral images using an unmanned aerial vehicle (UAV). **Remote Sensing**, v.11, n.12, p.1413, 2019.

GOODBODY, T. R.; COOPS, N. C.; HERMOSILLA, T.; TOMPALSKI, P.; & CRAWFORD, P. Assessing the status of forest regeneration using digital aerial photogrammetry and unmanned aerial systems. **International Journal of Remote Sensing**, v. 39, n. 15–16, p. 5246-5264, 2018.

GOODBODY, T. R. H.; COOPS, N. C.; WHITE, J. C. Digital Aerial Photogrammetry for Updating Area-Based Forest Inventories: A Review of Opportunities, Challenges, and Future Directions. **Current Forestry Reports**, v. 5, p. 55–75, 2019.

GRAYBILL, F. A. **Theory and application of the linear model**. Belmont: Duxbury Press, 1976. 704p.

GREGOIRE, T.G.; NÆSSET, E.; MCROBERTS, R.E.; STÅHL, G.; ANDERSEN, H.E.; GOBAKKEN, T.; ENE, L.; NELSON, R. Statistical rigor in LiDAR-assisted estimation of aboveground forest biomass. **Remote Sensing of Environment**, v. 173, p. 98–108, 2016.

GUIMARÃES, N.; PÁDUA, L.; MARQUES, P.; SILVA, N.; PERES, E.; SOUSA, J.J. Forestry remote sensing from unmanned aerial vehicles: A review focusing on the data, processing and potentialities. **Remote Sensing**, v. 12, n. 6, p. 1046, 2020.

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

HARDISKY, M. A.; KLEMAS, V.; SMART, M. The influence of soil salinity, growth form, and leaf moisture on the spectral radiance of. **Spartina alterniflora**, v. 49, p. 77–83, 1983.

HEROLD, M.; CARTER, S.; AVITABILE, V.; ESPEJO, A.B.; JONCKHEERE, I.; LUCAS, R.; MCROBERTS, R.E.; NÆSSET, E.; NIGHTINGALE, J.; PETERSEN, R.; REICHE, J.; ROMIJN, E.; ROSENQVIST, A.; ROZENDAAL, D.M.A.; SEIFERT, F.M.; SANZ, M.J.; DE SY, V.(2019) The role and need for space-based forest biomass-related measurements in environmental management and policy. **Surveys in Geophysics**, v. 40, n. 4, p. 757–778, 2019.

HOBBI, M.L.; GINZLER, C.; COMMARMOT, B; BUGMANN, H. Gap pattern of the largest primeval beech forest of Europe revealed by remote sensing. **Ecosphere**, v. 6, n. 5, p. 1–15, 2015.

HOUGHTON, R. A. Aboveground Forest Biomass and the Global Carbon Balance. **Global Change Biology**, v. 11, n. 6, p. 945–958, 2005.

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

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

HUNT JR, ROCK, B. Detection of changes in leaf water content using Near- and Middle-Infrared reflectances. **Remote Sensing of Environment**, v.30, n.1, p. 43–54, 1989.

IGLHAUT, J.; CABO, C.; PULITI, S.; PIERMATTEI, L.; O'CONNOR, J.; ROSETTE, J. Structure from motion photogrammetry in forestry: A review. **Current Forestry Reports**, v. 5, n. 3, p. 155–168, 2019.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC). **IPCC Guidelines for national greenhouse gas inventories**. Prepared by the National Greenhouse Gas Inventories Programme. Eggleston, H.S.; Buendia, L.; Miwa, K.; Ngara T.; Tanabe, K. editors. IGES, Japan, 2006.

JAYATHUNGA, S.; OWARI, T.; TSUYUKI, S. Evaluating the performance of photogrammetric products using fixed-wing UAV imagery over a mixed conifer–broadleaf forest: comparison with airborne laser scanning. **Remote Sensing**, v.10, n. 2, p. 187, 2018.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. 2. Ed. São Paulo: Parêntese, 2011, 598 p.

JORDAN, C. F. Derivation of leaf area index from quality of light on the Forest floor. **Ecology**, v.50, n.4, p.663–666, 1969.

KACHAMBA, D.J.; ØRKA H.O.; 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, p. 968, 2016.

KELSEY, K. C.; NEFF, J. C. Estimates of aboveground biomass from texture analysis of landsat imagery. **Remote Sensing**, v. 6, n. 1, p. 6407–6422, 2014.

KENNEDY, R.E.; YANG, Z.; COHEN, W.B. Detecting trends in forest disturbance and recovery using yearly Landsat time series: 1. LandTrendr-Temporal

segmentation algorithms. **Remote Sensing of Environment**, n. 114, v. 12, p. 2897–2910, 2010.

KOCH B. Status and future of laser scanning, synthetic aperture radar and hyperspectral remote sensing data for forest biomass assessment. **ISPRS Journal of Photogrammetry and Remote Sensing**. v. 65, n. 6, p. 581–90, 2010.

KUMAR, L.; MUTANGA, O. Remote sensing of above-ground biomass. **Remote Sensing**, v. 9, n. 9, p. 935, 2017.

LALIBERTE, A. S.; HERRICK, J. E.; RANGO, A.; WINTERS, C. Acquisition, Orthorectification, and Object-based Classification of Unmanned Aerial Vehicle (UAV) Imagery for Rangeland Monitoring. **Photogrammetric Engineering & Remote Sensing**, v. 76, n. 6, p. 661–672, 2010.

LEITE-FILHO, A.T.; SOARES-FILHO, B.S.; DAVIS, J.L.; ABRAHÃO, G.M.; BÖRNER, J. Deforestation reduces rainfall and agricultural revenues in the Brazilian Amazon. **Nature Communications**, v. 12, p. 2591, 2021.

LOCK, R. E. M.; KIRCHNER, F. F. Classificação de imagens multiespectrais de LANDSAT TM e feições de textura: mapeamento da cobertura da terra. **Floresta**, v. 27, n. 12, p. 41–58, 1997.

LÓPEZ-SERRANO, P.M.; CÁRDENAS DOMÍNGUEZ, J.L.; CORRAL-RIVAS, J.J.; JIMÉNEZ, E.; LÓPEZ-SÁNCHEZ, C.A.; VEGA-NIEVA, D.J. Modeling of Aboveground Biomass with Landsat 8 OLI and Machine Learning in Temperate Forests. **Forests**, v. 11, n. 11, 2020.

LORENZETTI, J. A. **Princípios Físicos de Sensoriamento Remoto**. 1 ed. São Paulo: Edgard Blucher, 2015, 292p.

LOWE, D. G. Distinctive image features from scale-invariant keypoints. **International journal of computer vision**, v. 60, n. 2, p. 91–110, 2004.

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

LU, D. Aboveground biomass estimation using Landsat TM data in the Brazilian Amazon. **International Journal of Remote Sensing**, v. 26, n. 12, p. 2509–2525, 2005.

LU D.; CHEN, Q.; WANG, G.; LIU, L.; LI, G.; MORAN, E. A survey of remote sensing-based aboveground biomass estimation methods in forest ecosystems. **International Journal of Digital Earth**, n. 9, v. 1, p. 63–105, 2016.

LU, D.; CHEN, Q.; WANG, G.; MORAN, E.; BATISTELLA, M.; ZHANG, M.; VAGLIO LAURIN, G.; SAAH, D. Aboveground forest biomass estimation with Landsat and LiDAR data and uncertainty analysis of the estimates. **International Journal of Forestry Research**, 2012.

LU, D.; MAUSEL, P.; BRONDIZIO, E.; MORAN, E. Relationships between forest stand parameters and Landsat TM spectral responses in the Brazilian Amazon Basin. **Forest ecology and management**, v. 198, n. 1-3, p. 149–167, 2004.

LUMLEY, T. **Regression Subset Selection**, [s.ed.], [s.l.]. Disponível em: <<https://cran.r-project.org/web/packages/leaps/leaps.pdf>>. Acesso em: 03 set. 2020.

MAGNAGO, L.F.S.; EDWARDS, D.P.; EDWARDS, F.A.; MAGRACH, A.; MARTINS, S.V.; LAURANCE, W.F. Functional attributes change but functional richness is unchanged after fragmentation of Brazilian Atlantic forests. **Journal of Ecology**, v. 102, n. 2, p. 475–485, 2014.

MATESE, A.; TOSCANO, P.; DI GENNARO, S. F.; GENESIO, L.; VACCARI, F. P.; PRIMICERIO, J.; BELLI, C.; ZALDEI, A.; BIANCONI, R.; GIOLI, B. Intercomparison of UAV, Aircraft and Satellite Remote Sensing Platforms for Precision Viticulture. **Remote Sensing**, v. 7, n. 3, p. 2971–2990, 2015.

MCDONALD, A.J.; GEMMELL, F.M.; LEWIS, P.E. Investigation of the utility of spectral vegetation indices for determining information on coniferous forests. **Remote Sensing of Environment**, v. 66, n. 3, p. 250–272, 1988.

MITCHARD, E.T.A.; SAATCHI, S. S.; WHITE, L.J.T.; ABERNETHY, K. A.; JEFFERY, K. J.; LEWIS, S. L.; COLLINS, M.; LEFSKY, M. A.; LEAL, M. E.; WOODHOUSE, I. H.; MEIR, P. Mapping tropical forest biomass with radar and spaceborne LiDAR in Lopé National Park, Gabon: overcoming problems of high biomass and persistent cloud. **Biogeosciences**, v. 9, n. 1, p. 179–191, 2012.

MITCHELL, A.L.; ROSENQVIST, A.; MORA, B. Current remote sensing approaches to monitoring forest degradation in support of countries measurement, reporting and verification (MRV) systems for REDD+. **Carbon Balance Manage**, v. 12, n. 9, 2017.

MOREIRA, A.M. **Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação**. Ed Editora UFV, 2a Ed.; Viçosa MG, 2003.

MUTANGA, O.; ADAM, E.; CHO, M.A. High density biomass estimation for wetland vegetation using WorldView-2 imagery and random forest regression algorithm. **International Journal of Applied Earth Observation and Geoinformation**, v. 18, p. 399–406, 2012.

NÆSSET, E.; GOBAKKEN, T.; HOLMGREN, J.; HYYPPÄ, H.; HYYPPÄ, J.; MALTAMO, M.; NILSSON, M.; OLSSON, H.; PERSSON, Å.; SÖDERMAN, U. Laser scanning of forest resources: the Nordic experience. **Scandinavian Journal of Forest Research**, v. 19, n. 6, p.482–499, 2004.

NAVARRO, A.; YOUNG, M.; ALLAN, B.; CARNELL, P.; MACREADIE, P.; IERODIACONOU, D. The application of Unmanned Aerial Vehicles (UAVs) to estimate above-ground biomass of mangrove ecosystems. **Remote Sensing of Environment**, v. 242, p. 111747, 2020.

NAVARRO, J. A.; ALGEET, N.; FERNÁNDEZ-LANDA, A.; ESTEBAN, J.; RODRÍGUEZ-NORIEGA, P.; GUILLÉN-CLIMENT, M. L. Integration of uav, sentinel-1, and sentinel-2 data for mangrove plantation aboveground biomass monitoring in senegal. **Remote Sensing**, v. 11, n.1, p. 77, 2019.

NAVARRO, J.A.; FERNÁNDEZ-LANDA, A.; TOMÉ, J.L.; GUILLÉN-CLIMENT, M.L.; OJEDA, J.C. Testing the quality of forest variable estimation using dense image matching: a comparison with airborne laser scanning in a Mediterranean pine forest. **International Journal of Remote Sensing**, v. 39, n. 14, p. 4744–4760, 2018.

NOVO, E. M. L. M. **Sensoriamento Remoto: Princípios e Aplicações**. 2. ed. São Paulo: Edgard Blucher. 2010. 388p.

NGUYEN, L. H.; JOSHI, D. R.; CLAY, D. E.; HENEBRY, G. M. Characterizing land cover/land use from multiple years of Landsat and MODIS time series: A novel approach using land surface phenology modeling and random forest classifier. **Remote Sensing of Environment**, v. 238, p. 111017, 2020.

OTA, T.; OGAWA, M.; SHIMIZU, K.; KAJISA, T.; MIZOUE, N.; YOSHIDA, S.; TAKAO, G.; HIRATA, Y.; FURUYA, N.; SANO, T.; SOKH, H.; MA, V.; ITO, E.; TORIYAMA, J.; MONDA, Y.; SAITO, H.; KIYONO, Y.; CHANN, S.; KET, N. Aboveground biomass estimation using structure from motion approach with aerial photographs in a seasonal tropical forest. **Forests**, v. 6, n. 11, p. 3882–3898, 2015.

PAN, Y.; BIRDSEY, R.A.; FANG, J.; HOUGHTON, R.; KAUPPI, P.E.; KURZ, W.A.; PHILLIPS, O.L.; SHVIDENKO, A.; LEWIS, S.L.; CANADELL, J.G.; CIAIS, P.; R. B. JACKSON, R.B.; PACALA, S.W.; MCGUIRE, A.D.; PIAO, S.; RAUTIAINEN, A.;

STEPHEN SITCH, S.; HAYES, D. A large and persistent carbon sink in the world's forests. **Science**, v. 333, n. 6045, p. 988–993, 2011.

PANDIT, S.; TSUYUKI, S.; DUBE, T. Landscape-Scale Aboveground Biomass Estimation in Buffer Zone Community Forests of Central Nepal: Coupling In Situ Measurements with Landsat 8 Satellite Data. **Remote Sensing**, v. 10, n. 11, p. 1848, 2018.

PHUA, M.H.; JOHARI, S.A.; WONG, O.C.; IOKI, K.; MAHALI, M.; NILUS, R.; COOMES, D.A.; MAYCOCK, C.R.; HASHIM, M. Synergistic use of Landsat 8 OLI image and airborne LiDAR data for above-ground biomass estimation in tropical lowland rainforests. **Forest ecology and management**, v. 406, p. 163–171, 2017.

PINTY, B.; VERSTRAETE, M. M. GEMI: a non-linear index to monitor global vegetation from satellites. **Vegetation**, v. 1, n. 101, p.15–20, 1992.

PULITI, S.; ENE, L.T.; GOBAKKEN, T.; NÆSSET, E. Use of partial-coverage UAV data in sampling for large scale forest inventories. **Remote Sensing of Environment**, v. 194, p. 115–126, 2017.

PULITI, S.; ØRKA, H. O.; GOBAKKEN, T.; NÆSSET, E. Inventory of small forest areas using an unmanned aerial system. **Remote Sensing**, v. 7, n. 1, p. 9632–9654, 2015.

PULITI S.; SOLBERG, S.; GRANHUS, A. Use of uav photogrammetric data for estimation of biophysical properties in forest stands under regeneration. **Remote Sensing**. v. 11, n. 3 p. 233, 2019.

QGIS DEVELOPMENT TEAM. (2020). **QGIS geographic information system**. Beaverton, OR: Open Source Geospatial Foundation.

QI, J.; CHEHBOUNI, A.; HUETE, A. R.; KERR, Y. H.; SOROOSHIAN, S. A modified soil adjusted vegetation index. **Remote Sensing of Environment**, v. 48, n. 1, p. 199–126, 1994.

R CORE TEAM. **R: a language and environment for statistical computing** (R version 3.5.2.). Vienna: R Foundation for Statistical Computing, 2019.

RAJPUT, B.S.; BHARDWAJ, D.R.; PALA, N.A. Carbon dioxide mitigation potential and carbon density of different land use systems along an altitudinal gradient in north-western Himalayas. **Agroforestry Systems**, v. 89, n. 3, p. 525–536, 2015.

RANA, P.; KORHONEN, L.; GAUTAM, B.; TOKOLA, T. Effect of field plot location on estimating tropical forest above-ground biomass in Nepal using airborne laser scanning data. **ISPRS journal of photogrammetry and remote sensing**, v. 94, p. 55–62, 2014.

RÉJOU-MÉCHAIN, M.; BARBIER, N.; COUTERON, P.; PLOTON, P.; VINCENT, G.; HEROLD, M.; MERMOZ, S.; SAATCHI, S.; CHAVES, J.; DE BOISSIEU, F.; FÉRET, J. B.; TAKOUDJOU, S. M.; PÉLISSIER, R. Upscaling forest biomass from field to satellite measurements: Sources of errors and ways to reduce them. **Surveys in Geophysics**, v. 40, n. 4, p. 881–911, 2019.

RIBEIRO, M.C.; METZGER, J.P.; MARTENSEN, A.C.; PONZONI, F.J.; HIROTA, M.M. The Brazilian Atlantic Forest: How much is left, and how is the remaining forest distributed? Implications for conservation. **Biological Conservation**, v. 142, n. 6 p. 1141–1153, 2009.

ROCHA, R.M.; LUCAS, A.A.T.; ALMEIDA, C.A.P.D.; MENEZES NETO, E.L.; NETTO, A.D.O.A. Caracterização morfométrica da sub-bacia do rio Poxim-Açu, Sergipe, Brasil. **Revista Ambiente & Água**, v. 9, n. 2, p. 276–287, 2014.

RODRÍGUEZ-VEIGA, P.; WHEELER J.; LOUIS V.; TANSEY K.; BALZTER H. Quantifying forest biomass carbon stocks from space. **Current Forestry Reports**, v. 3, n. 1, p. 1–18, 2017.

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

ROUJEAN, J.L.; BREON, F.M. Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. **Remote sensing of Environment**, v. 51, n. 3, p. 375–384, 1995.

ROUSE, J. W.; HAAS, R. H.; SCHELL J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS. p.309-317. In: **Earth resources technology satellite**. Washington, D.C: Goddard Space Flight Center, 1973.

ROUSSEL, J.-R.; AUTY, D. lidR: Airborne LiDAR Data Manipulation and Visualization for Forestry Applications. R package version 3.0.3, 2020.

ROY, D.P.; WULDER, M.A.; LOVELAND, T.R.; WOODCOCK, C.E.; ALLEN, R.G.; ANDERSON, M.C.; HELDER, D.; IRONS, J.R.; JOHNSON, D.M.; KENNEDY, R.; SCAMBOS, T.A.; SCHAAF, C.B.; SCHOTT, J.R.; SHENG, Y.; VERMOTE, E.F.; BELWARD, A.S.; BINDSCHADLER, R.; COHEN, W.B.; GAO, F.; HIPPLE, J.D.; HOSTERT, P.; HUNTINGTON, J.; JUSTICE, C.O.; KILIC, A.; KOVALSKYY, V.; LEE,

Z.P.; LYMBURNER, L.; MASEK, J.G.; JMCCORKEL, J.; SHUAI, Y.; TREZZA, R.; VOGELMANN, J.; WYNNE, R.H.; ZHU, Z Landsat-8: Science and product vision for terrestrial global change research. **Remote sensing of Environment**, v. 145, p. 154–172, 2014.

SAATCHI, S.S.; HARRIS, N.L.; BROWN, S.; LEFSKY, M.; MITCHARD, E.T.; SALAS, W.; ZUTTA, B.R.; BUERMANN, W.; LEWIS, S.L.; HAGEN, S.; PETROVA, S. Benchmark map of forest carbon stocks in tropical regions across three continents. **Proceedings of the national academy of sciences**, v. 108, n. 24, p. 9899–9904, 2011.

SALDARRIAGA, J.; WEST, D.; THARP, M.; UHL, C. Long-term chronosequence of forest succession in the upper Rio Negro of Colombia and Venezuela. **Journal of Ecology**, v. 76, n. 4, p. 938–958, 1988.

SANTOS, E. G. D.; SHIMABUKURO, Y. E.; MOURA, Y. M. D.; GONÇALVES, F. G.; JORGE, A.; GASPARINI, K. A.; ARAI, E.; DUARTE, V.; OMETTO, J.P. Multi-scale approach to estimating aboveground biomass in the Brazilian Amazon using Landsat and LiDAR data. **International Journal of Remote Sensing**, v. 40, n. 22, p. 8635–8645, 2019.

SARKER, L.R.; NICHOL, J.E. Improved forest biomass estimates using ALOS AVNIR-2 texture indices. **Remote Sensing of Environment**, v. 115, n. 4, p. 968–977, 2011.

SHEN, X; CAO, L.; YANG, B.; XU, Z.; WANG, G. Estimation of forest structural attributes using spectral indices and point clouds from UAS-based multispectral and RGB imageries. **Remote Sensing**, v. 11, n. 7, p. 800, 2019.

SIACHALOU, S.; MALLINIS, G.; TSAKIRI-STRATI, M. Analysis of time-series spectral index data to enhance crop identification over a Mediterranean rural landscape. **IEEE Geoscience and Remote Sensing Letters**, v. 14, n. 9, p. 1508–1512, 2017.

SILVA, Z.F.B. **Cenário atual da secção urbana do rio Poxim**. São Cristóvão: Universidade Federal de Sergipe- UFS/Gestão de Recursos Hídricos, 2001. 85p.

SILVEIRA, E. M.; SILVA, S. H. G.; ACERBI-JUNIOR, F. W.; CARVALHO, M. C.; CARVALHO, L. M. T.; SCOLFORO, J. R. S.; WULDER, M. A. Object-based random forest modelling of aboveground forest biomass outperforms a pixel-based approach in a heterogeneous and mountain tropical environment. **International Journal of Applied Earth Observation and Geoinformation**, v. 78, p. 175–188, 2019.

SINHA, P.; VERMA, N. K.; AYELE, E. Urban built-up area extraction and change detection of Adama municipal area using time-series Landsat images. **International Journal of Advanced Remote Sensing and GIS**, v. 5, n. 8, p. 1886–1895, 2016.

SOARES, J.A. **O rio Poxim, processo urbano e meio ambiente**. São Cristóvão: Universidade Federal de Sergipe- UFS/Gestão de Recursos Hídricos, 2001. 67p.

TOBLER, W. Measuring Spatial Resolution Proceedings. **Land Resources Information Systems Conference**. Beijing, 1987. p. 12–16.

TOMAŠTÍK, J.; MOKROŠ, M.; SALOŇ, Š.; CHUDÝ, F.; TUNÁK, D. Accuracy of photogrammetric UAV-based point clouds under conditions of partially-open forest canopy. **Forests**, v. 8, n. 5, p. 151, 2017.

TREUHAF, R.N.; GONÇALVES, F.G.; DRAKE, J.B.; CHAPMAN, B.D.; DOS SANTOS, J.R.; DUTRA, L.V.; GRAÇA, P.M.L.A.; PURCELL, G.H. Biomass estimation in a tropical wet forest using Fourier transforms of profiles from lidar or interferometric SAR. **Geophysical Research Letters**, v. 37, n. 23, 2010.

TREUHAF, R.N. NEUMANN, M.; KELLER, M.M.; GONCALVES, F.G.; SANTOS, J.R.. Tropical-Forest Biomass Dynamics from X-Band, TanDEM-X DATA. In **AGU Fall Meeting Abstracts** (v. 2015, pp. B51L-03), 2015.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, n. 2, p.127–150, 1979.

TUOMINEN, S.; PITKÄNEN, T.; ANDRAS B.; KANGAS, A. Improving Finnish multi-source national forest inventory by 3D aerial imaging. **Silva Fennica** v. 51, n. 4, p.1–21, 2017.

UNITED STATES GEOLOGICAL SURVEY (USGS). **Landsat 8 (L8) Data Users Handbook**. U.S. Geological Survey: Sioux Falls, SD, USA, 2019.

VELLOSO, H. P.; RANGEL-FILHO, A. L. R.; LIMA, J. C. A. **Classificação da vegetação brasileira adaptada a um Sistema universal**. Rio de Janeiro: IBGE, 1991. 123p.

VERMOTE, E.; JUSTICE, C.; CLAVERIE, M. AND FRANCH, B. Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product. **Remote Sensing of Environment**, v. 185, p. 46–56, 2016.

- WALLACE, L.; LUCIEER, A.; MALENOVSKÝ, Z.; TURNER, D.; VOPĚNKA, P. Assessment of forest structure using two UAV techniques: A comparison of airborne laser scanning and structure from motion (SfM) point clouds. **Forests**, v. 7, n. 3, p. 62, 2016.
- WANG, D.; WAN, B.; LIU, J.; SU, Y.; GUO, Q.; QIU, P.; WU, X. Estimating aboveground biomass of the mangrove forests on northeast Hainan Island in China using an upscaling method from field plots, UAV-LiDAR data and Sentinel-2 imagery. **International Journal of Applied Earth Observation and Geoinformation**, v. 85, p. 101986, 2020.
- WANG, Z.; GINZLER, C.; WASER, L.T. A novel method to assess short-term forest cover changes based on digital surface models from image-based point clouds. **Forestry: An International Journal of Forest Research**, v. 88, n. 4, p. 429–440, 2015.
- WHITE, J.C.; TOMPALSKI, P.; COOPS, N.C.; WULDER, M.A. Comparison of airborne laser scanning and digital stereo imagery for characterizing forest canopy gaps in coastal temperate rainforests. **Remote Sensing of Environment**, v. 208, p. 1–14, 2018.
- WULDER, M.A.; LOVELAND, T.R.; ROY, D.P.; CRAWFORD, C.J.; MASEK, J.G.; WOODCOCK, C.E.; ALLEN, R.G.; ANDERSON, M.C.; BELWARD, A.S.; COHEN, W.B.; DWYER, J. Current status of Landsat program, science, and applications. **Remote Sensing of Environment**, v. 225, p. 127–147, 2019.
- WULDER, M.A.; MASEK, J.G.; COHEN, W.B.; LOVELAND, T.R.; WOODCOCK, C.E. Opening the archive: How free data has enabled the science and monitoring promise of Landsat. **Remote Sensing of Environment**, n. 122, p. 2–10, 2012.
- ZARIN, D.J.; HARRIS, N.L.; BACCINI, A.; AKSENOV, D.; HANSEN, M.C.; AZEVEDO-RAMOS, C.; AZEVEDO, T.; MARGONO, B.A.; ALENCAR, A.C.; GABRIS, C.; ALLEGRETTI, A.; POTAPOV, P.; FARINA, M.; WALKER, W.S.; SHEVADE, V.S.; LOBODA, T.V.; TURUBANOVA, S.; TYUKAVINA, A. Can carbon emissions from tropical deforestation drop by 50% in 5 years?. **Global change biology**, v. 22, n. 4, p. 1336–1347, 2016.
- ZHANG, J.; LIN, X. Advances in fusion of optical imagery and LiDAR point cloud applied to photogrammetry and remote sensing. **International Journal of Image and Data Fusion**, v. 8, n. 1, p. 1–31, 2017.

ZHU, Z.; WANG, S.; WOODCOCK, C.E. Improvement and expansion of the Fmask algorithm: Cloud, cloud shadow, and snow detection for Landsats 4–7, 8, and Sentinel 2 images. **Remote Sensing of Environment**, v. 159, p. 269–277, 2015.

ZHU, Z.; WULDER, M.A.; ROY, D.P.; WOODCOCK, C.E.; HANSEN, M.C.; RADELOFF, V.C.; HEALEY, S.P.; SCHAAF, C.; HOSTERT, P.; STROBL, P.; PEKEL, J.F. Benefits of the free and open Landsat data policy. **Remote Sensing of Environment**, v. 224, p. 382–385, 2019.

ZIELEWSKA-BÜTTNER, K.; ADLER, P.; EHMANN, M.; BRAUNISCH, V. Automated Detection of Forest Gaps in Spruce Dominated Stands Using Canopy Height Models Derived from Stereo Aerial Imagery. **Remote Sensing**, v. 8, n. 3, p. 175, 2016.

ZOLKOS, S.G.; GOETZ, S.J.; DUBAYAH, R. A meta-analysis of terrestrial aboveground biomass estimation using lidar remote sensing. **Remote Sensing of Environment**, v. 128, p. 289–298, 2013.