

GISELLE LEMOS MOREIRA

**MODELAGEM DE VARIÁVEIS BIOFÍSICAS EM FLORESTA TROPICAL SECA
POR MEIO DE GEOTECNOLOGIAS**

**RECIFE
Pernambuco – Brasil
Fevereiro - 2021**

GISELLE LEMOS MOREIRA

**MODELAGEM DE VARIÁVEIS BIOFÍSICAS EM FLORESTA TROPICAL SECA
POR MEIO DE GEOTECNOLOGIAS**

Tese apresentada ao Programa de Pós-Graduação em Ciências Florestais da Universidade Federal Rural de Pernambuco, para obtenção do título de Doutora em Ciências Florestais, linha de pesquisa: Manejo Florestal e Utilização de Produtos Florestais.

Orientador: Prof. PhD. José Antônio Aleixo da Silva

Co-orientador: Prof. Dr. Rinaldo Luiz Caraciolo Ferreira

RECIFE
Pernambuco – Brasil
Fevereiro - 2021

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema Integrado de Bibliotecas da UFRPE
Biblioteca Central, Recife-PE, Brasil

M838m Moreira, Giselle Lemos

Modelagem de variáveis biofísicas em floresta tropical seca por meio de geotecnologias / Giselle Lemos Moreira. – 2021.

168 f. : il.

Orientador: José Antônio Aleixo da Silva.

Coorientador: Rinaldo Luiz Caraciolo Ferreira.

Tese (Doutorado) – Universidade Federal Rural de Pernambuco, Programa de Pós-Graduação em Ciências Florestais, Recife, BR-PE, 2021.

Inclui referências, apêndice(s) e anexo(s).

1. Caatinga 2. Biomassa 3. Florestas tropicais 4. Sensoriamento remoto I. Silva, José Antônio Aleixo da, orient. II. Ferreira, Rinaldo Luiz Caraciolo, coorient. III. Título

CDD 634.9

GISELLE LEMOS MOREIRA

MODELAGEM DE VARIÁVEIS BIOFÍSICAS EM FLORESTA TROPICAL SECA POR
MEIO DE GEOTECNOLOGIAS

APROVADA em 25/02/2021

Banca Examinadora

Prof. Dr. **Fernando Henrique de Lima Gadelha**
(Instituto Federal de Educação, Ciência e Tecnologia de Pernambuco – IFPE)

Prof. Dr. **Hernande Pereira da Silva**
(Universidade Federal Rural de Pernambuco – UFRPE)

Prof. Dr. **Emanuel Araújo Silva**
(Universidade Federal Rural de Pernambuco – UFRPE)

Prof. Dr. **César Augusto Guimarães Finger**
(Universidade Federal de Santa Maria - UFSM)

Orientador:

Prof. PhD. **José Antônio Aleixo da Silva**
(Universidade Federal Rural de Pernambuco - UFRPE)

Discente:

Giselle Lemos Moreira

RECIFE – PE
Fevereiro/2021

DEDICATÓRIA

À minha amada família, minha mãe Adailze, meu pai Josezilton, minhas irmãs Rosyane e Dayane e minha sobrinha Marcelly, por acreditarem em mim. Aos amigos que conquistei e aos que mantive ao longo desta jornada. Ao meu namorado Flávio por todo companheirismo e apoio. E ao meu cachorro, Theo, por alegrar meus dias.

Dedico.

AGRADECIMENTOS

Primeiramente ao Deus que eu acredito, pela dádiva da vida e por estar comigo em todos os momentos me guiando e protegendo.

À toda a minha família pelo incondicional amor, apoio e por sempre estarem presentes, em especial aos meus pais Adailze Maria Lemos Moreira e Josezilton Pires Moreira, minhas irmãs Rosyane e Dayane e minha sobrinha Marcelly.

À Universidade Federal Rural de Pernambuco (UFRPE), em especial ao Programa de Pós-Graduação em Ciências Florestais (PPGCF), pelo ensino e condições de trabalho e ao apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001 - pela bolsa concedida para o desenvolvimento da pesquisa.

Ao meu orientador, Professor PhD. José Antônio Aleixo da Silva, pela valiosa orientação, ensinamentos, dedicação, apoio científico e emocional, incentivo e amizade construída durante essa jornada e ao meu co-orientador Professor Dr. Rinaldo Luiz Caraciolo Ferreira pelos ensinamentos, contribuição e apoio na orientação desta pesquisa.

Aos professores do programa de Pós-Graduação em Ciências Florestais por todos os ensinamentos que enriqueceram a minha vida profissional e pessoal.

Aos amigos e colegas dos laboratórios de Biometria e Manejo Florestal e de Manejo de Florestas Nativas pela companhia durante o período de doutoramento, pelo apoio, ajuda e pelas risadas constantes que alegraram os meus dias.

Aos valiosos laços de amizade criados nessa jornada: César Henrique, Lucidalva Sobrinho, Josias Lucena, Adão Batista, Lúcia Rodrigues, Yana Souza, Weydson Raulino, Géssyca Sena (irmã de coração), Djailson Júnior, Nathan Fonsêca, Lyane Alencar, Jordânia Xavier, Emmanoella Guaraná, Anderson Silva, Gabriela Salami, Mayara Pessoa, Tamires Leal, Lorena de Moura, Rayane Santos e Wesley Lima, obrigada por estarem sempre à disposição para me ajudar e apoiar. Que sorte a minha os encontrar nesta jornada. Saibam que vocês tornaram a minha passagem pela UFRPE mais divertida e amorosa.

Ao meu namorado Flávio Cipriano pelo amor, paciência, apoio, incentivo, dedicação, ensinamentos e por estar comigo neste momento tão importante da minha vida.

Ao meu cachorro Theo que nestes últimos meses foi a luz e alegria dos meus dias.

A todos os que contribuíram, direta ou indiretamente, para que esse momento não fosse somente um sonho, meu muito obrigado. Vocês fazem parte desta conquista!

SUMÁRIO

LISTA DE FIGURAS	9
LISTA DE TABELAS	12
LISTA DE QUADROS	13
LISTA DE ABREVIATURAS E SIGLAS	14
RESUMO	15
ABSTRACT	16
1 INTRODUÇÃO GERAL	17
2 HIPÓTESES	19
3 OBJETIVOS	20
3.1 Objetivo geral	20
3.2 Objetivos específicos	20
4 REVISÃO DE LITERATURA	21
4.1 Florestas tropicais secas	21
4.2 Modelagem	26
4.3 Sensoriamento remoto aplicado à análise da vegetação	27
5 METODOLOGIA GERAL	39
5.1 Área de estudo	39
5.2 Procedimentos adotados	41
CAPÍTULO 1	50
MODELAGEM DE VARIÁVEIS BIOFÍSICAS EM FRAGMENTOS DE FLORESTA TROPICAL SECA POR MEIO DO SISTEMA LASER SCANNER AEROTRANSPORTADO	50
1 INTRODUÇÃO	50
2 MATERIAL E MÉTODOS	53
2.1 Área de Estudo	53
2.2 Estimativas das variáveis biofísicas por meio de inventário florestal	53
2.3 Ajuste do modelo de regressão linear para estimar volume e biomassa com dados LiDAR	53
2.4 Avaliação das equações preditivas de volume e BSA por meio de métricas LiDAR	58
2.5 Distribuição espacial do volume e biomassa	60
3 RESULTADOS E DISCUSSÃO	62
3.1 Dados LiDAR ALS processados	62
3.2 Ajuste do modelo e avaliação das equações preditivas de volume e BSA por meio de métricas LiDAR	65
3.3 Distribuição espacial do volume e biomassa	81
4 CONCLUSÃO	84
CAPÍTULO 2	85

ESTIMATIVA DE VARIÁVEIS BIOFÍSICAS EM FRAGMENTOS DE FLORESTA TROPICAL SECA POR MEIO DA INTEGRAÇÃO DE DADOS DA TECNOLOGIA LIDAR E DE SENSORES ORBITAIS	85
1 INTRODUÇÃO	85
2 MATERIAL E MÉTODOS	87
2.1 Área de estudo	87
2.2 Dados utilizados	87
2.3 Processamento dos dados orbitais	88
2.4 Estimativas das variáveis biofísicas por meio de inventário florestal	92
2.5 Ajuste do modelo de regressão linear para estimar volume e BSA com dados LiDAR e orbitais	92
2.6 Avaliação das equações preditivas de volume e BSA por meio de dados LiDAR e orbitais ..	94
2.7 Distribuição espacial do volume e BSA	94
3 RESULTADOS E DISCUSSÃO	95
3.1 Estimativas das variáveis biofísicas por meio de inventário florestal	95
3.2 Ajuste do modelo e avaliação das equações preditivas de volume e BSA por meio de métricas LiDAR e dados orbitais	95
3.3 Distribuição espacial do volume e biomassa	120
4 CONCLUSÃO	123
CONCLUSÕES GERAIS	124
CONSIDERAÇÕES FINAIS	125
REFERÊNCIAS	126
ANEXOS	137
APÊNDICES.....	145

LISTA DE FIGURAS

Figura 1 – Zoneamento ecológico global.....	21
Figura 2 – Tipologia vegetal do domínio fitogeográfico Caatinga.....	22
Figura 3 – Perfil representativo da savana estépica no domínio fitogeográfico Caatinga.....	23
Figura 4 – Interação da REM x vegetação.....	29
Figura 5 – Distinguição entre um MDS e o MDT.....	36
Figura 6 – Modelo Digital de Altura. (A) Modelo Digital de Superfície; (B) Modelo Digital de Terreno; (C) Modelo Digital de Altura.....	37
Figura 7 – Localização da área de estudo.....	39
Figura 8 – Distribuição da precipitação ao longo dos anos de 2010 a 2015 na estação meteorológica automática de Floresta/PE.....	40
Figura 9 – Localização das unidades amostrais em campo, Floresta, PE.....	41
Figura 10 – Fluxograma metodológico para obtenção das métricas LiDAR por unidade amostral.....	47

CAPÍTULO 1

Figura 1. Fluxograma metodológico para a estimativa do volume e da biomassa seca acima do solo.....	61
Figura 2 – Ortofoto e nuvem de pontos da Área II no software Fusion. A) ortofoto da Área II, B) perspectiva tridimensional da nuvem de pontos de uma amostra da Área II e C) sobreposição da nuvem de pontos na ortofoto da Área II.....	63
Figura 3 – Subprodutos, em formato raster, gerados a partir da nuvem de pontos na Área I.....	64
Figura 4 – Subprodutos, em formato raster, gerados a partir da nuvem de pontos na Área II.....	64
Figura 5 – Gráfico de resíduos padronizados versus volume predito, relação do volume predito versus o observado (N=36) e validação cruzada da equação 1. A linha indica a relação de 1:1.....	67
Figura 6 – Gráfico de resíduos padronizados versus volume predito, relação do volume predito versus o observado (N=36) e validação cruzada da equação 2. A linha indica a relação de 1:1.....	68
Figura 7 – Gráfico de resíduos padronizados versus BSA predita, relação da BSA predita versus a observada (N=36) e validação cruzada da equação 1. A linha indica a relação de 1:1.....	69

Figura 8 – Gráfico de resíduos padronizados versus BSA predita, relação da BSA predita versus a observada (N=36) e validação cruzada da equação 2. A linha indica a relação de 1:1.....	70
Figura 9 – Gráfico de resíduos padronizados versus variável resposta observada (N=36) das equações 1 e 2 para a Área I.....	71
Figura 10 – Gráfico de resíduos padronizados versus volume predito, relação do volume predito versus o observado (N=35) e validação cruzada da equação 1. A linha indica a relação de 1:1.....	73
Figura 11 – Gráfico de resíduos padronizados versus volume predito, relação do volume predito versus o observado (N=35) e validação cruzada da equação 2. A linha indica a relação de 1:1.....	74
Figura 12 – Gráfico de resíduos padronizados versus BSA predita, relação da BSA predita versus a observada (N=35) e validação cruzada da equação 1. A linha indica a relação de 1:1.....	75
Figura 13 – Gráfico de resíduos padronizados versus BSA predita, relação da BSA predita versus a observada (N=35) e validação cruzada da equação 2. A linha indica a relação de 1:1.....	76
Figura 14 – Gráfico de resíduos padronizados versus variável resposta observada (N=35) das equações 1 e 2 para a Área II.....	77
Figura 15 – Espacialização dos estoques de volume e BSA estimados com métricas LiDAR para 2014 nas áreas de estudo I e II, Floresta, PE.....	82

CAPÍTULO 2

Figura 1 – Gráfico de resíduos padronizados versus volume predito, relação do volume predito versus o observado (N=37) e validação cruzada da equação gerada a partir de dados LiDAR e do satélite Landsat 8. A linha indica a relação de 1:1.....	98
Figura 2 – Gráfico de resíduos padronizados versus volume predito, relação do volume predito versus o observado (N=36) e validação cruzada da equação gerada a partir de dados LiDAR e do satélite ResourceSat 2. A linha indica a relação de 1:1.....	99
Figura 3 – Gráfico de resíduos padronizados versus volume predito, relação do volume predito versus o observado (N=35) e validação cruzada da equação gerada a partir de dados LiDAR e do satélite RapidEye. A linha indica a relação de 1:1.....	100
Figura 4 – Gráfico de resíduos padronizados versus BSA predita, relação da BSA predita versus a observada (N=37) e validação cruzada da equação gerada a partir de dados LiDAR e Landsat 8. A linha indica a relação de 1:1.....	101

Figura 5 – Gráfico de resíduos padronizados versus BSA predita, relação da BSA predita versus a observada (N=37) e validação cruzada da equação gerada a partir de dados LiDAR e do satélite ResourceSat. A linha indica a relação de 1:1. Fonte: o autor.....	102
Figura 6 – Gráfico de resíduos padronizados versus BSA predita, relação da BSA predita versus a observada (N=35) e validação cruzada da equação gerada a partir de dados LiDAR e do satélite RapidEye. A linha indica a relação de 1:1.....	103
Figura 7 – Gráficos de resíduos padronizados versus variável resposta observada das equações geradas para a Área I.....	104
Figura 8 – Gráfico de resíduos padronizados versus volume predito, relação do volume predito versus o observado (N=35) e validação cruzada da equação gerada a partir de dados LiDAR e do satélite Landsat 8. A linha indica a relação de 1:1.....	107
Figura 9 – Gráfico de resíduos padronizados versus volume predito, relação do volume predito versus o observado (N=35) e validação cruzada da equação gerada a partir de dados LiDAR e do satélite ResourceSat 2. A linha indica a relação de 1:1.....	108
Figura 10 – Gráfico de resíduos padronizados versus volume predito, relação do volume predito versus o observado (N=35) e validação cruzada da equação gerada a partir de dados LiDAR e do satélite RapidEye. A linha indica a relação de 1:1.....	109
Figura 11 – Gráfico de resíduos padronizados versus BSA predita, relação da BSA predita versus a observada (N=35) e validação cruzada da equação gerada a partir de dados LiDAR e do satélite Landsat 8. A linha indica a relação de 1:1.....	110
Figura 12 – Gráfico de resíduos padronizados versus BSA predita, relação da BSA predita versus a observada (N=38) e validação cruzada da equação gerada a partir de dados LiDAR e do satélite ResourceSat 2. A linha indica a relação de 1:1.....	111
Figura 13 – Gráfico de resíduos padronizados versus BSA predita, relação da BSA predita versus a observada (N=38) e validação cruzada da equação gerada a partir de dados LiDAR e do satélite RapidEye. A linha indica a relação de 1:1.....	112
Figura 14 – Gráficos de resíduos padronizados versus variável resposta observada das equações geradas para a Área II.....	113
Figura 15 – Espacialização dos estoques de volume e BSA estimados com métricas LiDAR e dados orbitais para 2014 nas áreas de estudo I e II, Floresta, PE.....	121

LISTA DE TABELAS

Tabela 1 – Equações para estimativa de volume (m^3) para grupos de espécies características de floresta tropical seca, município de Floresta, Pernambuco, Brasil.....	42
Tabela 2 – Equações para estimativa biomassa seca acima do solo (kg) para oito espécies características de floresta tropical seca, município de Floresta, Pernambuco, Brasil.....	43
Tabela 3 – Estatística descritiva das variáveis respostas das Áreas I e II.....	44

CAPÍTULO 1

Tabela 1 – Coeficiente de determinação ajustado (R_{aj}^2), erro padrão dos resíduos (S_{yx}), raiz quadrada do erro quadrático médio (RMSE) e raiz quadrada do erro quadrático médio da validação cruzada k-fold (RMSEcv) para equações geradas para volume e BSA na Área I.....	66
Tabela 2 – Coeficiente de determinação ajustado (R_{aj}^2), erro padrão dos resíduos (S_{yx}), raiz quadrada do erro quadrático médio (RMSE) e raiz quadrada do erro quadrático médio da validação cruzada k fold (RMSEcv) para as equações geradas para volume e BSA na Área II..	72

CAPÍTULO 2

Tabela 1 – Valores de Irradiância Solar na Exoatmosfera para as bandas do satélite ResourceSat 2.....	90
Tabela 2 – Valores de Irradiância Solar na Exoatmosfera para as bandas do satélite RapidEye.....	90
Tabela 3 – Variáveis selecionadas após análise da correlação linear de Pearson.....	95
Tabela 4 – Coeficiente de determinação ajustado (R_{aj}^2), erro padrão dos resíduos (S_{yx}), raiz quadrada do erro quadrático médio (RMSE) e raiz quadrada do erro quadrático médio da validação cruzada k-fold (RMSEcv) para as equações geradas para volume e BSA na Área I.....	96
Tabela 5 – Coeficiente de determinação ajustado (R_{aj}^2), erro padrão dos resíduos (S_{yx}), raiz quadrada do erro quadrático médio (RMSE) e raiz quadrada do erro quadrático médio da validação cruzada k fold (RMSEcv) para as equações geradas para volume e BSA na Área II.....	105

LISTA DE QUADROS

Quadro 1 – Características espectrais, espaciais, temporais e radiométricas do satélite Landsat 8.....	31
Quadro 2 – Características espectrais, espaciais, temporais e radiométricas do satélite RapidEye.....	32
Quadro 3 – Características espectrais, espaciais, temporais e radiométricas do satélite Resourcesat-2.....	34

CAPÍTULO 1

Quadro 1 – Lista das métricas LiDAR avaliadas no estudo, obtidas a partir de pontos acima de 1,30 do solo por meio da ferramenta cloudmetrics do software FUSION v. 3.8.....	54
--	----

LISTA DE ABREVIATURAS E SIGLAS

ALS – Airborne LiDAR Scanner
BOA – Bottom of Atmosphere
DAP – Diâmetro medido a 1,30 m do solo
MDA – Modelo Digital de Altura
MDE – Modelo Digital de Elevação
MDS – Modelo Digital de Superfície
MDT – Modelo Digital de Terreno
EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária
EVI - Enhanced Vegetation Index
FTS – Floresta tropical seca
IBGE – Instituto Brasileiro de Geografia e Estatística
INS – Inertial Navigation System
LANDSAT – Land Remote Sensing Satellite
LiDAR – Light Detection and Ranging
LISS-III – Linear Imaging Sef-Scanner
NASA – National Aeronautics and Space Administration
ND – Número Digital
NDVI – Normalized Difference Vegetation Index
NIR – Near Infrared
OLI – Operational Land Imager
REIS – RapidEye Earth Imaging System
SAVI – Soil Adjusted Vegetation
SEINFRA – Secretaria de Infraestrutura de Pernambuco
SRHE – Secretaria de Recursos Hídricos e Energéticos
SR – Simple Ratio
SWIR – Short Wave Infrared
TIRS – Thermal Infrared Sensor
TOA – Top Of Atmosphere
USGS – United State Geological Survey

MOREIRA, GISELLE LEMOS. Modelagem de variáveis biofísicas em floresta tropical seca por meio de Geotecnologias. 2021. Orientador: José Antônio Aleixo da Silva. Co-orientador: Rinaldo Luiz Caraciolo Ferreira.

RESUMO

O inventário florestal é um importante instrumento empregado para estimar o potencial produtivo de uma área florestal, entretanto suas técnicas convencionais demandam tempo e em alguns casos, apresentam dificuldade relacionadas ao acesso ou ao tamanho da área. Desta forma, objetivou-se com este estudo avaliar a capacidade da tecnologia LiDAR (Light Detection and Ranging) e de diferentes sensores orbitais na predição das variáveis biofísicas volume e biomassa seca acima do solo (BSA) em áreas de vegetação arbustiva-arbórea em floresta tropical seca. Para tal, o presente trabalho foi dividido em dois capítulos com objetivos específicos. No primeiro capítulo, avaliou-se o potencial das métricas derivadas do sistema LiDAR ALS (Airborne Laser Scanner) na predição de volume e BSA em áreas de floresta tropical seca. O estudo foi conduzido em duas áreas de Caatinga na Fazenda Itapemirim, localizada entre os municípios de Floresta e Betânia, em Pernambuco. Para avaliar o potencial da tecnologia LiDAR foi realizado o ajuste do modelo de regressão linear múltipla, pelo método dos mínimos quadrados ordinários, onde foram utilizadas como variáveis respostas os estoques de volume e BSA, por unidade amostral (u.a.), oriundos dos dados de inventário florestal realizado nas áreas de estudo e como variáveis preditivas as métricas LiDAR de altura (posição, dispersão e proporção), extraídas, por u.a., da nuvem de pontos LiDAR normalizada. A partir dos resultados encontrados, observou-se que as melhores equações para a predição das variáveis biofísicas alcançaram um coeficiente de determinação ajustado (R^2_{aj}) de 0,67, com erro padrão percentual ($S_{yx\%}$) de 20,22% para volume e um R^2_{aj} de 0,75, com $S_{yx\%}$ de 14,71% para BSA, além disto, observou-se que as equações geradas, tanto de volume quanto de BSA, mostraram tendências de superestimar valores mais baixos e subestimar valores mais altos. Desta forma, conclui-se que as equações preditivas de volume e BSA obtidas por meio da tecnologia LiDAR geraram valores tendenciosos comparados aos obtidos por meio do inventário florestal convencional. No segundo capítulo, avaliou-se o potencial da associação entre métricas derivadas da tecnologia LiDAR ALS e dados espectrais de diferentes sensores orbitais na predição de volume e biomassa seca acima do solo em áreas de floresta tropical seca. Para tal, o estudo foi realizado em dois fragmentos de Caatinga na Fazenda Itapemirim, localizada entre os municípios de Floresta e Betânia, em Pernambuco e foram utilizados dados oriundos da tecnologia LiDAR e dados orbitais dos satélites Landsat 8, ResourceSat-2 e RapidEye. Para o ajuste do modelo de regressão linear múltipla foram utilizados como variáveis respostas os estoques de volume e BSA, por u.a., oriundos dos dados de inventário florestal realizado nas áreas de estudo e como variáveis preditivas as métricas LiDAR de altura e valores médios das bandas espectrais e índices de vegetação. Observou-se, a partir dos resultados, que a melhor equação para a predição do volume alcançou um R^2_{aj} de 0,80, com $S_{yx\%}$ de 16,64% e a melhor equação para BSA obteve um R^2_{aj} de 0,82, com $S_{yx\%}$ de 10,84%. Também foi possível observar que as equações ajustadas mostraram tendências de superestimar valores mais baixos e subestimar valores mais altos. Deste modo, conclui-se que as equações preditivas de volume e BSA ajustadas a partir da integração entre dados LiDAR ALS e dados orbitais não foram capazes de gerar resultados com acurácia compatível à obtida por meio do inventário florestal convencional. No geral, conclui-se que a integração de métricas LiDAR ALS e dados orbitais possibilitou a geração de estimativas de volume e BSA mais precisas, quando comparadas à utilização de dados LiDAR ALS de forma isolada.

MOREIRA, GISELLE LEMOS. Modeling of biophysical variables in a dry tropical forest using Geotechnologies. 2021. Advisor: José Antônio Aleixo da Silva. Co-advisor: Rinaldo Luiz Caraciolo Ferreira.

ABSTRACT

The forest inventory is an important instrument used to estimate the productive potential of a forest area, however its conventional techniques require time and, in some cases, present difficulties related to access or the size of the area. Thus, the objective of this study was to evaluate the capacity of LiDAR (Light Detection and Ranging) technology and of different orbital sensors in the prediction of biophysical variables volume and dry aboveground biomass (dry AGB) in areas of shrub-tree vegetation in dry tropical forest. To this end, the present work was divided into two chapters with specific objectives. In the first chapter assessed the potential of the metrics derived from the LiDAR ALS (Airborne Laser Scanner) system in predicting volume and dry AGB in dry tropical forest areas. The study was conducted in two areas of Caatinga at Fazenda Itapemirim, located between the municipalities of Floresta and Betânia, in Pernambuco. To assess the potential of LiDAR technology, the multiple linear regression model was adjusted using the ordinary least squares method, where volume and dry AGB stocks, per sample unit, from the forest inventory data carried out in the study areas were used as response variable and as predictive variables used were height LiDAR metrics (position, dispersion and proportion), extracted, per sample unit, from the normalized LiDAR point cloud. From the results found, it was observed that the best equations for the prediction of biophysical variables reached an adjusted coefficient of determination (Adjusted R-squared) of 0.67, with a percentage standard error (SE%) of 20.22% for volume and an Adjusted R-squared of 0.75, with SE% of 14.71% for dry AGB, in addition, it was observed that the equations generated, both in volume and dry AGB, showed tendencies to overestimate lower values and underestimate higher values. Thus, it is concluded that the predictive equations of volume and dry AGB generated through LiDAR technology generated biased values compared to those obtained through the conventional forest inventory. In the second chapter, the potential of the association between metrics derived from LiDAR ALS technology and spectral data from different orbital sensors in the prediction of volume and dry AGB in areas of dry tropical forest was evaluated. To this end, the study was carried out in two fragments of Caatinga at Fazenda Itapemirim, located between the municipalities of Floresta and Betânia, in Pernambuco and data from LiDAR technology and orbital data from the Landsat 8, ResourceSat-2 and RapidEye satellites were used. For the adjustment of the multiple linear regression model, the response variables were the stocks of volume and dry AGB, per sampling unit, derived from the forest inventory data carried out in the study areas and as predictive variables, the LiDAR metrics of height and average values of spectral bands and vegetation indices. It was observed, from the results, that the best equation for volume prediction reached an Adjusted R-squared of 0.80, with SE% of 16.64% and the best equation for dry AGB obtained an Adjusted R-squared of 0.82, with SE% of 10.84%. It was also possible to observe that the generated equations showed tendencies to overestimate lower values and underestimate higher values. In this way, it is concluded that the predictive equations of volume and dry AGB adjusted from the integration between LiDAR ALS data and orbital data were not able to generate results with accuracy compatible with that obtained through the conventional forest inventory, however they presented good precision. In general, it is concluded that the integration of LiDAR ALS metrics and orbital data enabled the generation of more accurate volume and dry AGB estimates when compared to the use of LiDAR ALS data in isolation.

1 INTRODUÇÃO GERAL

O inventário florestal é um importante instrumento empregado para estimar o potencial produtivo de uma área florestal e subsidiar as análises econômica e ambiental de um empreendimento voltado à exploração e conhecimento dos recursos da floresta.

É por meio do inventário florestal em florestas nativas que informações importantes, tais como, composição florística, dados quantitativos e qualitativos dos produtos madeireiros e não-madeireiros, estimativas do volume e biomassa remanescente e explorável da floresta são obtidos, as quais auxiliam a tomada de decisão para implementação do manejo florestal sustentado.

A maneira mais eficiente para se conhecer o potencial produtivo de uma floresta e o seu estoque madeireiro é por meio da estimativa do volume (SCOLFORO, 2005). Segundo Silveira *et al.* (2008) a quantificação da biomassa florestal também possui grande relevância e serve de base para a tomada de decisões em diversas atividades relacionadas ao manejo dos recursos florestais.

As técnicas convencionais de inventário florestal demandam tempo e em alguns casos, apresentam dificuldade relacionadas ao acesso ou ao tamanho da área. Por estes motivos, estudos sobre o uso de ferramentas de sensoriamento remoto aplicadas ao inventário florestal têm se tornado cada vez mais intensos, com o intuito de auxiliar na obtenção de estimativas de volume, biomassa e carbono, além de reduzir a necessidade de trabalhos de campo, diminuir o tempo de aquisição dos dados e, em alguns casos, aumentar a precisão das estimativas (ZANDONÁ; LINGNAU; NAKAJIMA, 2008).

O sensoriamento remoto promoveu avanços extraordinários na modelagem matemática/estatística, mapeamento e compreensão dos ecossistemas florestais. Diversos são os estudos que utilizaram imagens de sistemas ópticos passivos, tais como, fotografias aéreas (BALENOVIĆ *et al.*, 2015; OTA *et al.*, 2015; OTA *et al.*, 2019) e imagens multiespectrais (FERRAZ *et al.*, 2014; PANDIT; TSUYUKI; DUBE, 2018; OU *et al.*, 2018), para estimar variáveis florestais, tendo como exemplo: altura, volume e biomassa acima do solo. Entretanto, não houve sucesso considerável em prover medidas confiáveis relativas às características tridimensionais de árvores individuais por meio destas técnicas (ZANDONÁ; LINGNAU; NAKAJIMA, 2008).

Com o rápido desenvolvimento da computação aliado aos avanços da tecnologia de detecção remota, os sensores ativos, como o sistema Light Detection and Ranging (LiDAR), surgiram como ferramentas promissoras para auxiliar nas estimativas florestais (NÆSSET; ØKLAND, 2002; POPESCU; ZHAO, 2008).

No contexto florestal o LiDAR captura a estrutura vertical de um dossel florestal, gerando dados de altura. Kini e Popescu (2004) e Lefsky *et al.* (2002a) afirmam que o LiDAR é uma tecnologia alternativa que pode proporcionar a análise espacial na terceira dimensão (Z) da vegetação, além de promover maior precisão das variáveis de inventário florestal que podem ser extraídas com o uso de software de processamento LiDAR adequado.

Diversos estudos têm demonstrado a importância e precisão do uso da tecnologia LiDAR como instrumento de mensuração e planejamento florestal (MAGNUSSEN; NÆSSET; GOBAKKEN, 2010; IOKI *et al.*, 2010; FIGUEIREDO *et al.*, 2014).

Entretanto, são escassos estudos desenvolvidos para áreas de florestas nativas com vegetação do tipo arbustiva, característica de floresta tropical seca (FTS), como a Caatinga no Brasil. Entre os estudos realizados com dados orbitais, destacam-se os estudos desenvolvidos no Brasil por Accioly *et al.* (2002) na Floresta Nacional (Flona) do Araripe, localizada no Estado do Ceará, Almeida *et al.* (2014), na Caatinga do estado de Sergipe e Lima Júnior *et al.* (2014), na Caatinga de Petrolina, Pernambuco, os quais utilizaram dados provenientes do sensor TM do satélite Landsat 5, para estimar variáveis biofísicas como: a área basal, altura média e volume.

Com a tecnologia LiDAR, um dos poucos estudos na área foi conduzido por Estomell *et al.* (2011) que estimaram a biomassa em uma floresta mediterrânea, com predominância de *Quercus coccifera* (arbustos com menos de 2 metros de altura), em Chiva na Espanha, por meio de dados LiDAR ALS (Airborne Laser Scanner) aliados com informações espectrais. Os autores relatam que os resultados encontrados ilustram a viabilidade da metodologia para caracterizar a estrutura arbórea e estimar a biomassa desse tipo de vegetação.

Diante do contexto, este estudo busca contribuir para um maior conhecimento relativo à utilização de geotecnologias na obtenção de informações relativas à vegetação arbustiva-arbórea, presentes em FTS. A necessidade do estudo é justificada pela escassez de estudos voltados a este tipo de vegetação e ao grande potencial das tecnologias de sensoriamento remoto, que poderão servir como base ou auxílio para estimar variáveis biofísicas da floresta, além de auxiliar na gestão e no manejo adequado dos recursos florestais.

2 HIPÓTESES

A presente pesquisa se fundamenta nas seguintes hipóteses:

(i) As métricas oriundas da tecnologia LiDAR ALS podem ser utilizadas para estimar volume e biomassa seca acima do solo para vegetação de floresta tropical seca, com acurácia compatível àquela obtida em inventários florestais convencionais.

(ii) A associação entre métricas derivadas da tecnologia LiDAR ALS e dados espectrais de diferentes sensores orbitais, possibilita a geração de estimativas de volume e biomassa seca acima do solo mais robustas, quando comparadas à utilização de dados LiDAR ALS de forma isolada.

3 OBJETIVOS

3.1 Objetivo geral

Objetivou-se com este estudo avaliar a capacidade da tecnologia LiDAR (aplicada pelo Programa Pernambuco Tridimensional - PE3D) e de diferentes sensores orbitais na predição das variáveis biofísicas volume e biomassa seca acima do solo em área de vegetação arbustiva-arbórea em floresta tropical seca.

3.2 Objetivos específicos

- ✓ Avaliar o potencial das métricas derivadas da tecnologia LiDAR ALS para a predição de volume e biomassa seca acima do solo em áreas de floresta tropical seca, tendo como referência os dados oriundos de inventário florestal convencional;
- ✓ Avaliar o potencial de métricas derivadas da tecnologia LiDAR ALS em conjunto com dados espectrais, puros e transformados, de diferentes sensores orbitais para a predição de volume e biomassa seca acima do solo em áreas de floresta tropical seca, tendo como referência os dados oriundos de inventário florestal convencional;
- ✓ Analisar o desempenho das equações de volume e BSA geradas quanto a capacidade de generalização;
- ✓ Verificar o impacto da utilização de dados orbitais com diferentes resoluções espaciais na predição dos estoques de volume e biomassa seca acima do solo; e
- ✓ Elaborar mapas de distribuição espacial do estoque de volume e biomassa seca acima do solo, a partir das equações obtidas.

4 REVISÃO DE LITERATURA

4.1 Florestas tropicais secas

As florestas tropicais secas (FTS) compõem quase metade das florestas tropicais e subtropicais do mundo (42%), e são consideradas muito importantes do ponto de vista biológico, pois abrigam uma alta complexidade e diversidade biológica, resultante da heterogeneidade espacial e temporal (MILES *et al.*, 2006), como a disponibilidade hídrica, os diferentes tipos de solo, à topografia, etc. Esta heterogeneidade implica em consideráveis diferenças florísticas entre formações de FTS em diferentes continentes (DEXTER *et al.*, 2015), contemplando espécies lenhosas, herbáceas, cactáceas e bromeliáceas.

Apesar da sua importância ambiental, as FTS estão entre os ecossistemas mais ameaçados, menos protegidos e pouco pesquisados do mundo (DEXTER *et al.*, 2015; SILVA *et al.*, 2017).

O zoneamento ecológico global realizado pela FAO (FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS - FAO, 2012) evidencia que as regiões com as maiores áreas de FTS são encontradas na América do Sul, seguida pela África e Índia (Figura 1).

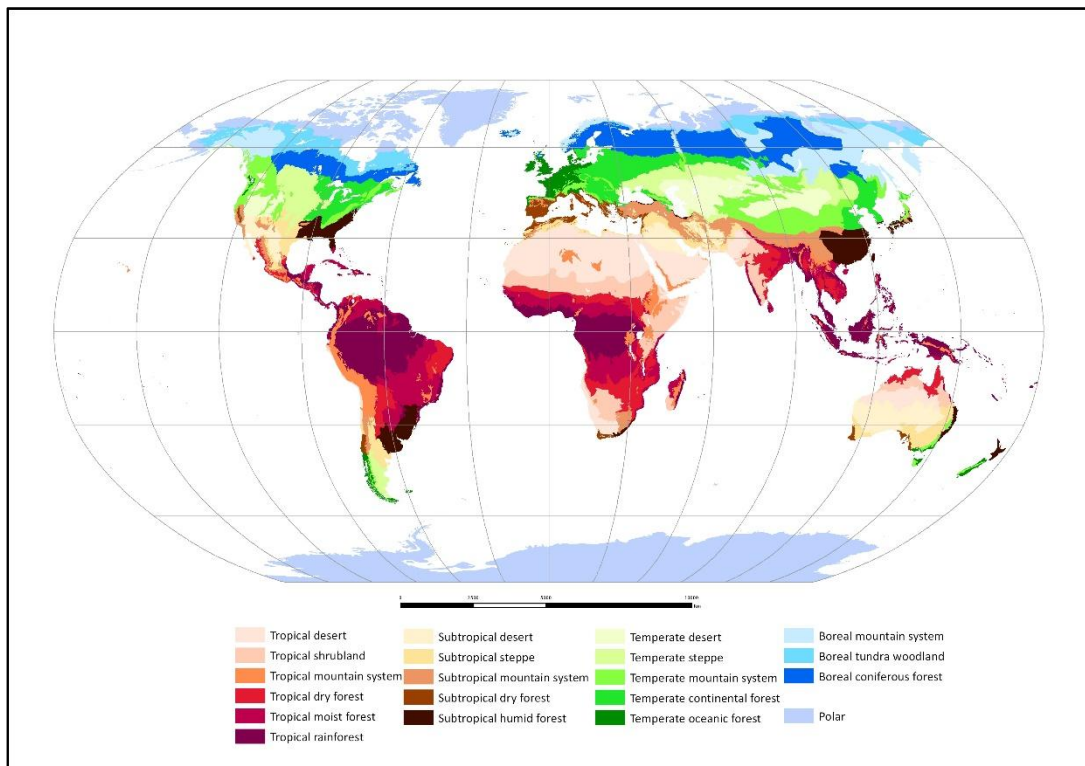


Figura 1 – Zoneamento ecológico global. **Fonte:** FAO (2012).

De forma geral, a FAO define FTS como tendo duas características climáticas básicas: um clima tropical, com chuvas de verão e período seco de 5 a 8 meses e uma precipitação anual variando em torno de 500 a 1500 mm (FAO, 2001). Já para as FTS da América do Sul, a FAO relata que as chuvas podem variar entre 500 a 1000 mm por ano, o período seco também dura entre 5 a 8 meses e as temperaturas são sempre elevadas nas regiões próximas ao Equador (FAO, 2001).

No Brasil, a Caatinga, uma das vegetações brasileiras caracterizadas como FTS, está localizada quase que exclusivamente na Região Nordeste, tendo uma área de ocorrência também no estado de Minas Gerais, Região Sudeste, e é considerada uma das maiores áreas de FTS contínuas do mundo (FAO, 2001; BANDA *et al.* 2016), ocupando uma extensão territorial de 862.818 km², equivalente a 10,1% do território nacional (IBGE, 2019).

De acordo com a FAO (2001) a Caatinga possui uma grande variedade de tipos de vegetação xerófila, com ou sem Cactaceae, podendo ser densa e quase fechada ou muito aberta e semelhante a pseudo-estepe, com uma densidade de árvores e arbustos muito baixa. Ainda de acordo com a FAO (2001) a Caatinga é caracterizada por ser mais ou menos decídua, com árvores de altura baixa (geralmente entre 5 a 10 m), e formada por um estrato de árvores de caule fino, um estrato de arbustos e, por fim, um estrato de herbáceas esparsas.

Segundo o IBGE (2019), a tipologia vegetal dominante da Caatinga é a savana estépica, equivalente a 63,3% da área total da Caatinga, seguida de área de contato (encrave ou ecótono) com 22,21% e em terceiro a Floresta Estacional Decidual, com 8,32% (Figura 2).

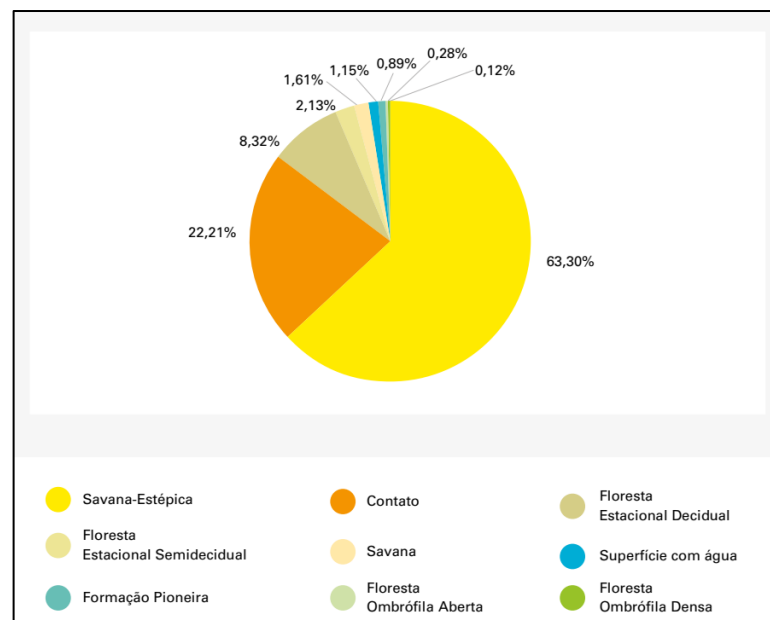


Figura 2 – Tipologia vegetal do domínio fitogeográfico Caatinga. **Fonte:** IBGE (2019).

Veloso *et al.* (1991) também relatam que na Caatinga do Sertão árido existe uma vegetação classificada como savana estépica, reconhecendo quatro fisionomias de acordo com o componente arbóreo: savana estépica florestada, savana estépica arborizada, savana estépica parque e savana estépica gramíneo-lenhosa (Figura 3).




Figura 3 – Perfil representativo da savana estépica no domínio fitogeográfico Caatinga. **Fonte:** Veloso *et al.* (1991).

Essas diferentes fitofisionomias resultam da interação de diversos fatores, como o clima, relevo, geologia e geomorfologia (RODAL *et al.*, 2008).

Outra característica importante da Caatinga é a adaptação da sua vegetação a um ambiente hostil imposto pelo clima quente e pelo estresse hídrico. As diferentes espécies são morfofisiologicamente adaptadas para tolerar longos períodos de estiagem, por meio da sua característica decídua, porte reduzido, folhas pequenas, alta capacidade de rebrota por tocos e raízes, presença de acúleos e espinhos, redução do metabolismo em períodos secos, além de muitas espécies de plantas suculentas que respondem com eficiência aos níveis baixos de precipitação (SILVA *et al.*, 2003; GARIGLIO *et al.*, 2010; SILVA *et al.*, 2017).

O comportamento fisiológico e fenológico diferenciado das espécies florestais da Caatinga, adaptadas às condições de clima adverso, permite que os recursos naturais desse tipo de FTS sejam utilizados como fonte de sobrevivência para parte da população.

4.1.1 Manejo florestal sustentado em florestas tropicais secas

O manejo florestal sustentado é a estratégia mais apropriada para minimizar ou impedir o desmatamento da Caatinga e de outras FTS, conservando a biodiversidade e gerando benefícios socioeconômicos, a partir do fornecimento de matéria-prima para atender às crescentes demandas da sociedade.

De forma legal, a Lei brasileira nº 11.284, de 2 de março de 2006, que dispõe sobre a gestão de florestas públicas para produção sustentável, define o manejo florestal sustentado como a “administração da floresta para a obtenção de benefícios econômicos, sociais e

ambientais, respeitando-se os mecanismos de sustentação do ecossistema objeto de manejo.” (BRASIL, 2006).

Os principais problemas técnicos, econômicos e ecológicos do manejo sustentável em florestas naturais, como a Caatinga, são decorrentes da falta de informações consistentes do crescimento das espécies sob regime de manejo; economicidade do manejo florestal sustentado e a suscetibilidade das espécies florestais à exploração florestal. O desenvolvimento de estudos voltados a estas problemáticas é imprescindível para nortear o desenvolvimento de um manejo florestal sustentado em áreas de Caatinga.

De acordo com Calegário (1998) é fundamental compreender que as futuras características qualitativas e quantitativas de uma floresta, também dependerão da qualidade e quantidade de regeneração natural, e caso isto não seja considerado em um manejo florestal, existe um elevado risco de que a população, até então heterogênea, com elevada diversidade florística, torne-se homogênea, perdendo seu papel ecológico e econômico, uma vez que espécies de interesse comercial podem ser extintas neste processo.

Desta forma, para se atingir a sustentabilidade, que deve ser considerada o princípio básico do manejo florestal, é necessário analisar e verificar os aspectos relativos à capacidade de regeneração natural da floresta e a capacidade das espécies remanescentes de se reproduzirem (CALEGÁRIO, 1998).

Outro fator que pode provocar a insustentabilidade do manejo em florestas naturais está atrelado a não realização de intervenção após a exploração da vegetação, onde há um abandono da área, esperando-se que a recuperação ocorra naturalmente por meio da regeneração por sementes e pela rebrota das cepas. Intervenções como tratamentos silviculturais (indicados para estimular a dinâmica de sucessão e o crescimento) e a reposição florestal de que trata a Lei de política florestal do estado de Pernambuco, nº 11.206, de 31 de março de 1995, em seu Capítulo X (BRASIL, 1995) podem e devem ser aplicadas visando melhorar a qualidade e o sucesso do manejo na floresta.

Para a exploração adequada e de forma sustentável de qualquer tipo de floresta é de fundamental importância estimar seu potencial produtivo, por meio de um inventário florestal para conhecer as espécies que a compõe e por meio das estimativas de volume e biomassa, de forma a subsidiar a tomada de decisões quanto à viabilidade de implementação do manejo florestal sustentado dos produtos madeireiros e/ou não-madeireiros ou até mesmo para estudos sobre sequestro de carbono.

Para a exploração madeireira, as estimativas volumétricas são imprescindíveis, e para obter o volume de uma árvore da forma mais precisa é necessário realizar o seu abate e realizar

a cubagem rigorosa. Entretanto, em alguns casos este procedimento não é viável e por isto foram desenvolvidos métodos não destrutivos que visam obter a estimativa de volume da árvore em pé (SILVA; PAULA NETO, 1979), como por exemplo, os modelos volumétricos, os quais geralmente utilizam como variáveis independentes o diâmetro a 1,30 m de altura do solo (DAP) e a altura total da árvore (Ht) ou comercial. Outras variáveis independentes podem ser coletadas em campo e utilizadas para ajustar os modelos, como diâmetro da base e número de fustes, além destas outras podem ser obtidas por meio de técnicas de sensoriamento remoto, como índices de vegetação, reflectâncias, entre outros.

As estimativas de biomassa florestal são dados indispensáveis nas questões ligadas às áreas de manejo florestal e climáticas, pois no primeiro caso, a biomassa permite o conhecimento do potencial de produção para fins energéticos, sobretudo quando o objetivo é a utilização de todos os componentes da árvore (ou seja, a raiz, o fuste e os galhos) e com relação à área climática, a biomassa é o meio pelo qual são obtidas as estimativas de estoques de carbono, que, por sua vez, são utilizadas para estimar a quantidade de dióxido de carbono (CO₂) que é liberada para a atmosfera em casos, por exemplo, de queimadas (HIGUCHI *et al.*, 2007).

Nas FTS as estimativas de biomassa surgem como importantes ferramentas para elucidar o papel importante destas florestas no ciclo do carbono, bem como, para nortear políticas públicas voltadas ao manejo dessas florestas para produção e colheita de lenha de forma sustentável (TESFAYE *et al.*, 2016).

Para obtenção de estimativas de biomassa florestal, pode-se empregar métodos diretos com a derrubada das árvores para medir a massa real de cada um de seus compartimentos (porém mais caro e demorado) e, métodos indiretos, baseados, principalmente, em dados de inventário florestal aplicados em modelos de regressão linear e não linear, cujas variáveis preditivas mais comuns são o DAP e Ht e variáveis como diâmetro da base, idade, índice de sítio e diâmetro da copa são utilizados ocasionalmente (SOMOGYI *et al.*, 2001).

As FTS apresentam um grande potencial de exploração para as mais diversas finalidades, e em alguns casos, contribuem significativamente para a subsistência rural. Da cera, mel e própolis de abelha ao sequestro de carbono, as FTS fornecem muitos produtos que podem ser comercializados. No mercado consumidor de energia por exemplo, as FTS contribuem com o fornecimento de combustível na forma de lenha e carvão vegetal (BLACKIE *et al.*, 2014).

Segundo EPE (2019) da oferta interna de energia do Brasil em 2018, aproximadamente 45% eram oriundas de fontes renováveis, sendo a lenha e o carvão vegetal responsáveis por 8,4%. No setor agropecuário cerca de 29% do consumo energético total é proveniente do consumo de lenha. No setor residencial 26% do consumo energético provem do consumo de

lenha e carvão vegetal. Já no setor industrial, a lenha e carvão vegetal corresponde a aproximadamente 13% do total energético consumido.

De forma geral, a utilização da lenha apresentou uma queda no consumo final de energia, passando de 7,5 % em 2009 para 6,5 % em 2018. Mesmo diante a diminuição do consumo, a lenha ainda representa uma importante fonte na matriz energética brasileira (EPE, 2019).

No Nordeste, a lenha e o carvão vegetal representam aproximadamente 30% de sua matriz energética, em que os setores industriais com maior demanda são os de gesso, ferro-gusa, têxtil, cal, cerâmica, telhas, tijolos, taninos, corantes, alimentos, além do consumo domiciliar, principalmente em áreas rurais, nas famílias de baixa renda (BRASIL, 2011; 2012). Entretanto, boa parte das demandas desse mercado são atendidas por meio de uma exploração não sustentável e ilegal da Caatinga, o que causa sérios danos ao bioma e sua biodiversidade.

Com relação a exploração da Caatinga, ela vem ocorrendo basicamente de três maneiras: (i) o desmatamento legal, autorizado pelos órgãos competentes, para fins de uso alternativo do solo, como é o caso da agricultura e pastagem, convertendo a vegetação nativa em terras para atividades agrícolas de curta duração, ou pasto para criação de gado e caprinos; (ii) o manejo florestal sustentado, autorizado pelos órgãos competentes, para fins de produção madeireira, e (iii) o desmatamento ilegal, para fins de uso alternativo do solo e produção madeireira (PAREYN, 2010).

Quando uma floresta é explorada de forma predatória, a dinâmica de crescimento das espécies não é respeitada, o que pode resultar em perdas significativas da cobertura florestal e da diversidade de espécies. Segundo Souza (2006), o manejo de uma floresta tem de considerar a conservação de características essenciais, como: a biodiversidade, a estrutura fitossociológica, as distribuições diamétrica e espacial das espécies, o crescimento e a produção, as interações mutualísticas, a biologia reprodutiva, a estrutura genética das espécies, bem como, o valor ecológico, econômico e social das espécies e do ecossistema florestal.

4.2 Modelagem

Um modelo pode ser definido como uma formulação matemática que simula, de forma simplificada, algum aspecto da realidade (VANCLAY, 1994). O processo de desenvolvimento desta simulação é chamado de modelagem.

A modelagem é baseada em hipóteses que buscam representar fenômenos físicos ou biológicos, com o objetivo de gerar uma equação que possa estimar, quantitativamente, o fenômeno estudado a um determinado nível de probabilidade (SILVA, 2015).

A modelagem é empregada em diversos ramos das ciências e, segundo Barrett e Fried (2004), é amplamente utilizada na área florestal com o objetivo de: estimar atributos que não podem ser facilmente medidos; compreender como os ecossistemas florestais funcionam; extrapolar espacialmente os atributos florestais e; projetar como as florestas mudam ao longo do tempo.

Normalmente a modelagem é realizada com variáveis que possuem forte correlação. A análise de regressão é a técnica estatística mais utilizada para ajustar um modelo estocástico (probabilístico) qualquer, que envolva variáveis correlacionadas (DRAPER; SMITH, 1981; SCHNEIDER *et al.*, 2009; PARDOE, 2012).

A regressão pode ser definida como o estudo da relação entre uma ou mais variáveis, cujo objetivo é estimar o valor da variável dependente com base no conhecimento dos valores das variáveis independentes, além de estimar o grau de associação entre duas ou mais variáveis (SILVA; SILVA, 1995).

4.3 Sensoriamento remoto aplicado à análise da vegetação

O sensoriamento remoto pode ser compreendido como uma tecnologia que possibilita a obtenção de imagens e outros dados, da superfície terrestre, por meio da captação e do registro da energia refletida ou emitida pela mesma (FLORENZANO, 2002), o que possibilita o estudo do ambiente terrestre.

O sensoriamento remoto é composto por elementos fundamentais: radiação eletromagnética, fonte, sensor e alvo.

A Radiação Eletromagnética (REM) é considerada o elemento de ligação entre os demais elementos, que são: a “fonte” de REM, que pode ser o Sol ou a Terra para os sensores passivos ou podem ser antenas de micro-ondas e laser para os sensores ativos; o “sensor”, que é o instrumento possibilita a coleta e o registro da REM refletida ou emitida pelo “alvo”, que é o elemento do qual se pretende extrair informações (INPE, 2001).

De forma geral, a radiação eletromagnética pode ser entendida como sendo a propagação de energia que se move (à velocidade da luz, $300.000 \text{ km s}^{-1}$) na forma de ondas por meio de variação temporal dos campos elétrico e magnético (FIGUEIREDO, 2005).

A REM não necessita de um meio material para se propagar, sendo caracterizada por uma frequência (f), que é o número de vezes que uma onda passa em um ponto em unidade de tempo, e pelo comprimento da onda (λ), que é distância entre dois picos de ondas, e estão relacionados pela seguinte fórmula: $c = \lambda f$, onde c é a velocidade da luz.

O conjunto de comprimentos de ondas que formam a REM é denominado de espectro eletromagnético, o qual é subdividido em regiões espectrais em função do tipo de processo físico que dá origem a energia eletromagnética, do tipo de interação que ocorre entre a radiação e o objeto sobre o qual esta incide e da transparência da atmosfera em relação à radiação eletromagnética (FIGUEIREDO, 2005).

Para Florenzano (2002), sensores são equipamentos utilizados na captura e no registro da energia refletida ou emitida pelos objetos da superfície terrestre, possibilitando a aquisição de informações que são invisíveis ao olho humano e podem ser acoplados em diferentes plataformas: terrestres (sensores portáteis, tripés e torres), aéreas (aviões, balões, helicópteros e veículos aéreos não tripulados - VANTs) ou orbitais (satélites).

O alvo representa o objeto do qual se anseia obter informações, o qual recebe a REM oriunda de uma fonte, e poderá absorver, transmitir ou refletir certa quantidade de energia (INPE, 2001).

4.3.1 Interação da vegetação com a energia eletromagnética

O processo de interação REM e uma folha sadia, envolve os três fenômenos físicos: absorvância, reflectância e transmitância espectral (MENEZES; ALMEIDA; BAPTISTA, 2019).

Segundo Moreira (2011), da REM que alcança a superfície da Terra e atinge a planta, parte é absorvida (absorvância) pelos pigmentos presentes na folha e outras partes da planta e participa de processos como a fotossíntese, alteração de estruturas moleculares (fotoconversão), destruição de estruturas moleculares e acelera reações, como a fotoxidação das xantofilas. Outra porção é refletida (reflectância), sendo a mais importante para o sensoriamento remoto, uma vez que é a porção captada pelos sensores, e outra parte que é transmitida (transmitância), como por exemplo, entre as camadas de folhas que compõem a copa, e as camadas que constituem a folha [como a cutícula, parênquima lacunoso e parênquima paliçádico (mesófilo), etc.] (Figura 4.




Figura 4 – Interação da REM x vegetação. **Fonte:** Quartaroli *et al.* (2014).

Entre os órgãos presentes em uma planta, as folhas são as principais estruturas quando o assunto é interação com a REM. Elas desempenham importantes funções vitais, como a respiração, a transpiração e a fotossíntese e dentre estas, a fotossíntese é a única que está diretamente envolvida com a REM (MOREIRA, 2011). A fotossíntese também ocorre em outras partes verdes da planta.

De acordo com Novo (2010), de maneira geral, o comportamento espectral da vegetação se modifica ao longo do ciclo vegetativo. Por outro lado, o comportamento espectral de uma folha está relacionado à sua composição, morfologia e estrutura interna (PONZONI, 2003). No espectro eletromagnético os comprimentos de onda do visível, infravermelho próximo (NIR, near infrared) e infravermelho de ondas curtas (SWIR, short-wave infrared) são as regiões mais utilizadas para caracterizar o comportamento espectral de uma planta, pois sofrem interferência de fatores como: estrutura celular (mesófilo), senescência, concentração de pigmentos e presença de água (PONZONI; SHIMABUKURO; KUPLICH, 2012; JENSEN, 2011).

Deste modo, ao analisar uma planta verde e sadia o comportamento esperado é que na região do visível, nos comprimentos de onda azul e vermelho ocorra a absorção da energia radiante em função da existência de pigmentos presentes nas células do mesófilo (especialmente do parênquima paliçádico) para a produção de fotossíntese como clorofila (65%), xantofilas (29%) e carotenos (6%), enquanto que no comprimentos de onda verde ocorra um decréscimo na absorção e aconteça uma maior reflectância, que faz com que as folhas verdes e saudáveis apresentem uma coloração verde aos olhos humano (JENSEN, 2011; MENEZES; ALMEIDA; BAPTISTA, 2019).

Os dois tipos de clorofila (a e b) existentes na planta são responsáveis pela intensa absorção da REM nos comprimentos de onda do azul e do vermelho, já as absorções realizadas pelas xantofilas e carotenos ocorrem no comprimento de onda do azul, mas normalmente são mascaradas pelas absorções da clorofila (MENEZES; ALMEIDA; BAPTISTA, 2019).

Quando a planta é afetada por um estresse ou entra na senescência, os pigmentos de clorofila podem desaparecer, permitindo a dominância dos demais pigmentos. Segundo Jensen (2011) no outono a produção de clorofila é cessada, e é por esta razão que a coloração amarelada e avermelhada das folhas, proporcionada pelos carotenos e outros pigmentos, torna-se perceptível ao olho humano, uma vez que os carotenos não absorvem energia radiante nestas cores.

A maior reflectância da vegetação verde e sadia está localizada nos comprimentos de onda do NIR (0,7 μm e 1,3 μm) e do SWIR (1,3 μm e 2,5 μm). No NIR este fenômeno ocorre devido à interferência da estrutura celular do mesófilo (especificamente do parênquima esponjoso), no qual 40 a 60% da energia é refletida, 40 a 60% é transmitida e apenas 5 a 10% é absorvida (NOVO, 2010; JENSEN, 2011). Menezes, Almeida e Baptista (2019) relatam que a mudança brusca de reflectância no comportamento espectral da vegetação do visível para NIR ocorre no curto intervalo de comprimento de onda de 0,69 a 0,76 μm (denominado Red-edge, borda vermelha).

No SWIR a reflectância é determinada pelo conteúdo de água nas folhas, ocorrendo picos de reflectância (1,6 μm e 2,2 μm) entre as duas principais bandas de absorção pela água atmosférica (NOVO, 2010; JENSEN, 2011).

Ponzoni (2003) também relata que quanto maior a presença de lacunas na estrutura interna foliar, maior será a reflectância na região do NIR, devido ao processo de espalhamento interno. A estrutura interna das folhas é diferente de uma espécie para outra, assim é possível discriminar as plantas ao utilizar a região do NIR, já que neste intervalo as mesmas apresentam comportamentos específicos de absortância, reflectância e transmitância espectral (CHUVIECO, 1990).

4.3.2 Sistemas sensores orbitais (passivos)

4.3.2.1 Landsat 8

O Landsat 8 é um satélite lançado em 2013, que faz parte da série Landsat que teve início no final da década de 60, a partir de um projeto desenvolvido pela Agência Espacial Americana, que visava obter informações dos recursos naturais terrestres. A série Landsat teve

o primeiro satélite (ERTS-1 ou Landsat-1) lançado em 1972, o qual foi também o primeiro satélite desenvolvido para atuar diretamente em pesquisas de recursos naturais (USGS, 2019).

Os dados gerados pelas espaçonaves Landsat constituem o registro mais longo das superfícies continentais do planeta Terra, visto do espaço (quase 50 anos), sendo considerado um recorde incomparável com relação a qualidade, detalhe, cobertura e valor (NASA, 2020).

O Landsat 8 é uma colaboração entre a NASA e o USGS, foi lançado em 11 de fevereiro de 2013, na Califórnia, começando suas atividades em abril de 2013 (NASA, 2020). O satélite possui dois sensores imageadores, o TIRS (Thermal Infrared Sensor) e OLI (Operational Land Imager), os quais fornecem uma cobertura sazonal global com uma resolução espacial de 30 metros, nas bandas dos comprimentos de onda do visível, NIR e SWIR; 100 metros para as bandas do infravermelho termal (TIR); e 15 metros para a banda pancromática (USGS, 2019).

O sensor OLI é composto por oito bandas espectrais e uma banda pancromática e o sensor TIRS é composto por duas bandas espectrais conforme apresentado no Quadro 1.

Quadro 1 - Características espectrais, espaciais, temporais e radiométricas do satélite Landsat 8

Sensor	Bandas Espectrais	Resolução Espectral (μm)	Resolução Espacial (m)	Resolução Temporal (dias)	Resolução radiométrica (bits)
OLI	Costal/Aerosol (B1)	0,435 – 0,451	30	16	12
	Azul (B2)	0,452 – 0,512			
	Verde (B3)	0,533 – 0,590			
	Vermelho (B4)	0,636 – 0,673			
	NIR (B5)	0,851 – 0,879			
	SWIR 1 (B6)	1,566 – 1,651			
	SWIR 2 (B7)	2,107 – 2,294			
	Pan (B8)	0,503 – 0,676	15		
	Cirrus (B9)	1,363 – 1,384	30		
TIRS	TIR 1 (B10)	10,60 – 11,19	100		
	TIR 2 (B11)	11,50 – 12,51			

Fonte: USGS (2019).

As imagens podem ser encontradas e baixadas gratuitamente nos mecanismos de pesquisa GLOVIS (<http://glovis.usgs.gov/>) e Earth Explorer (<http://earthexplorer.usgs.gov/>) e podem ser encontradas com um padrão de alta qualidade, com o nome de Coleções Nível 1 (Collection Level 1), o que indica que a imagem passou pelo processamento radiométrico e geométrico (com a ortorretificação) (USGS, 2019).

O produto disponibilizado é composto por 13 arquivos, incluindo as bandas de 1-9 (um arquivo por banda) do sensor OLI, bandas 10 e 11 (um arquivo por banda) do sensor TIR (todas

as bandas no formato GeoTIFF), um arquivo de metadados específico do produto (no formato TXT) e uma imagem de avaliação de qualidade (QA).

4.3.2.2 RapidEye

O sistema de observação da terra RapidEye, originado pela empresa alemã RapidEye, é um sistema comercial formado por uma constelação de cinco satélites (TACHYS – RapidEye 1, MATI – RapidEye 2, TROCHIA – RapidEye 3, CHOROS – RapidEye 4 e CHOMA – RapidEye 5) idênticos posicionados em órbita síncrona ao sol (heliossíncrona), que foram lançados de uma só vez, em agosto de 2008, no Cazaquistão (BLACKBRIDGE, 2015).

Em 2013, a empresa RapidEye mudou oficialmente seu nome para BlackBridge, resultado de um processo de dois anos de unificação de todas as empresas da corporação BlackBridge. Em 2015, a empresa Planet Labs Inc., fundada por ex-integrantes da equipe da NASA, anunciou um acordo com a corporação BlackBridge para comprar as empresas geoespaciais BlackBridge, e conseqüentemente sua constelação de satélites RapidEye, e desde então passou a operar, processar e distribuir as imagens geradas pela constelação, a qual foi desativada em abril de 2020, depois de 11 anos de atividades (PLANET LABS INC., 2020).

Todos os cinco satélites foram equipados com sensores idênticos, o sensor RapidEye Earth Imaging System (REIS), que é um sensor multiespectral do tipo pushbroom (sistema de varredura eletrônica), podendo ser referido na literatura como JSS-56 (Jena-Optronik Spaceborne Scanner-56) ou MSI (Multispectral Imager) e que obtêm imagens da Terra nas faixas espectrais do visível (azul, verde e vermelho), do NIR e do Red-edge (Quadro 2).

Quadro 2 – Características espectrais, espaciais, temporais e radiométricas do satélite RapidEye

Instrumento/ Sensor	Bandas Espectrais	Resolução Espectral (μm)	Resolução Espacial (m)	Resolução Temporal (dias)	Resolução radiométrica (bits)
REIS	Azul (B1)	0,440 – 0,510	6,5 m (imageado/ nadir) e 5,0 m (reamostrado/ ortoretificado)	Diariamente (off-nadir) e 5.5 dias (nadir)	12
	Verde (B2)	0,520 – 0,590			
	Vermelho (B3)	0,630 – 0,685			
	Red-edge (B4)	0,690 – 0,730			
	NIR (B5)	0,760 – 0,850			

Fonte: PLANET LABS (2018).

O sistema RapidEye foi primeiro sistema orbital a incluir a banda espectral red-edge, considerada muito sensível a alterações do teor de clorofila das plantas, o que pode provocar grandes diferenças na reflectância e transmitância das folhas. O posicionamento desta banda

corresponde ao aumento abrupto da reflectância entre os comprimentos de onda do visível e do NIR, quando considerada uma planta verde e sadia (MENEZES; ALMEIDA; BAPTISTA, 2019). É muito utilizada para o monitoramento da atividade fotossintética da vegetação, concentração de pigmentos, detecção de estresse hídrico e doenças etc.

No Brasil, de 2012 até a desativação do sistema RapidEye (abril de 2020), as imagens da constelação RapidEye tiveram um papel fundamental na implementação do Programa de Regularização Ambiental, por meio do Cadastro Ambiental Rural (CAR) em nível nacional. O Ministério do Meio Ambiente (MMA) liderou a compra anual de imagens para todo o território brasileiro e por meio da assinatura de acordos de cooperação técnica com o MMA, instituições federais e estaduais de ensino e pesquisa também podem utilizá-las em ações e pesquisas (MMA, 2020). As imagens podem ser solicitadas a partir do geocatálogo do MMA.

4.3.2.3 ResourceSat-2

O Resourcesat-2 é um satélite desenvolvido e operado pela Organização Indiana de Pesquisa Espacial (ISRO, pela Indian Space Research Organization), com bandas espectrais aprimoradas em relação ao satélite que o antecede, o ResourceSat-1 (ou IRS-P6) e foi lançado em 20 de abril de 2011, em Sriharikota, Índia. O objetivo deste satélite é fornecer dados para a gestão integrada de recursos terrestres e hídricos (ISRO, 2011).

No Brasil, o Instituto Nacional de Pesquisas Espaciais (INPE) possui parceria com a Organização Indiana de Pesquisas Espaciais, por meio de um programa de cooperação, para a recepção direta, processamento e distribuição dos dados do satélite Resourcesat-2, sensores LISS-III e AWiFS (INPE, 2015). A Estação de Recepção e Gravação do INPE em Cuiabá (MT) é a responsável por rastrear, armazenar temporariamente e transferir os dados brutos dos sensores LISS-III e AWiFS para a Estação de Recepção e Gravação do INPE em Cachoeira Paulista (SP), a qual tem a função de processar, armazenar e disponibilizar gratuitamente esses dados para toda a comunidade científica e demais usuários do mundo, por meio do catálogo online do INPE (www.dgi.inpe.br/CDSR).

O ResourceSat-2 opera com três instrumentos sensores imageadores: LISS-III (Linear Imaging Sef-Scanner), LISS-IV e AWiFS (Advanced Wide Field Sensor) e diferentes bandas espectrais, especificadas no Quadro 3.

Quadro 3 – Características espectrais, espaciais, temporais e radiométricas do satélite Resourcesat-2

Instrumento/Sensor	LISS-IV	LISS-III	AWiFS
Bandas Espectrais	Verde (B2) Vermelho (B3) NIR (B4) B3 - banda default para mono	Verde (B2) Vermelho (B3) NIR (B4) SWIR (B5)	Verde (B2) Vermelho (B3) NIR (B4) SWIR (B5)
Resolução Espectral (µm)	B2: 0,52-0,59 B3: 0,62-0,68 B4: 0,77-0,86	B2: 0,52-0,59 B3: 0,62-0,68 B4: 0,77-0,86 B5:0,1,55-1,70	B2: 0,52-0,59 B3: 0,62-0,68 B4: 0,77-0,86 B5:0,1,55-1,70
Resolução Espacial (m)	≤ 5,8 m	23,5 m	56 m (nadir)
Resolução Temporal (dias)	5 dias	24 dias	5 dias
Resolução radiométrica (bits)	10	10	12

Fonte: ISRO (2011).

4.3.3 Sistema sensor aerotransportado (ativo)

4.3.3.1 Tecnologia LiDAR

LiDAR deriva do termo em inglês “Light Detecting and Ranging” e, de forma geral, pode ser definida como uma tecnologia que utiliza pulso de luz, especificamente a luz de laser (Light Amplification by Stimulated Emission of Radiation), para estimar distâncias (ou intervalos), baseadas no tempo de emissão e retorno do pulso laser.

O princípio básico de operação do sistema LiDAR ou perfilamento a laser, ou ainda varredura a laser como também é conhecido, baseia-se na emissão, pelo sensor, de milhares pulsos de luz laser por segundo que se propagam à velocidade da luz em direção à superfície ou objeto (alvo) e retornam ao sensor refletidos pelos alvos (LEFSKY *et al.*, 2002a; LIM *et al.*, 2003; GEOSPATIAL TECHNOLOGY AND APPLICATIONS CENTER - GTAC, 2019). Os pulsos de laser utilizados são seguros para a saúde das pessoas e todos os seres vivos (McGAUGHEY, 2020).

Desta forma, a distância entre o sensor e a superfície ou objeto (alvo) é obtida pela determinação do tempo decorrido entre a emissão do pulso de luz laser e a chegada do retorno do pulso no sensor (refletido pelo alvo) (GORGENS; SILVA; RODRIGUEZ, 2014; DONG; CHEN, 2018). Os tempos medidos são então convertidos em dados de distância do sensor usando a expressão 1 (GTAC, 2019).

$$D = r \left(\frac{t}{2} \right) \quad (1)$$

Em que: D: a distância do sensor ao alvo; r: taxa (velocidade da luz) e; t: o tempo (que é dividido por 2, uma vez que a luz deve viajar para o alvo e depois fazer a viagem de volta ao sensor).

O sistema LiDAR é uma tecnologia de sensoriamento remoto ativa, ou seja, possui um sensor que apresenta sua própria fonte de energia, neste caso, uma fonte de luz, o laser, que emite radiação na direção do alvo a ser investigado (LIM *et al.*, 2003; DONG; CHEN, 2018).

Esta tecnologia pode ser utilizada por meio de uma plataforma terrestre fixa ou móvel (veículo automotor), aérea (aeronave) ou orbital (satélite ou estação espacial) (GIONGO; KIRCHNER; MARCHETTI, 2010). Entretanto, o sistema LiDAR que ultimamente mais vem contribuindo com o levantamento de informações espaciais, de pequenas à grandes escalas, é o laser scanner aerotransportado (ALS).

Tipos de dados gerados pela tecnologia LiDAR

Nuvem de pontos

Após a varredura a laser os dados brutos são processados para gerar como produto primário uma nuvem de pontos contendo, no mínimo, as coordenadas tridimensionais (coordenadas x e y e elevação z) de cada ponto (retorno). Os valores de coordenadas e elevação podem ser representativos do solo, topo de edifícios e casas, copa de árvores, linhas de energia elétrica, pontes ou outros tipos de cobertura da superfície terrestre.

De acordo com o sistema de laser scanner utilizado e com a superfície que está sendo escaneada, cada pulso pode ter vários retornos e desta forma, a densidade de pontos (retornos) pode variar enormemente em todo o conjunto de dados. Em contrapartida, a densidade de pulso é muito mais consistente em todo o conjunto de dados e é indicada para ser a medida usada ao se referir à resolução espacial do conjunto de dados (GTAC, 2019).

A partir de uma nuvem de pontos LiDAR alguns produtos secundários, altamente precisos e detalhados (a depender de como os dados são coletados), podem ser originados, entre eles estão: modelos digitais de elevação – MDEs e modelo digital de altura - MDA. A seguir, serão expostas as diferenças entre os modelos, bem como, as etapas para gerá-los.

Modelo Digital de Elevação (MDE)

Segundo Wolf e Dewwitt (2000), um MDE é a forma mais usual para representar uma superfície topográfica, de forma digital, a partir de um conjunto de pontos com coordenadas tridimensionais. Pode ser subdividido em: modelo digital do terreno (MDT) e modelo digital de superfície (MDS).

A obtenção das amostras para confeccionar um MDE pode ser realizada de diversas maneiras, entre elas: levantamentos topográficos, digitalização de cartas topográficas (curvas

de nível, rede hidrográfica, etc.), medidas fotogramétricas, dados altimétricos adquiridos de sensores remotos e levantamentos a laser scanner (nuvem de pontos 3D).

Modelo Digital de Terreno (MDT) e Modelo Digital de Superfície (MDS) a partir de dados LiDAR

Um MDT é a representação matemática (planialtimétrica) da superfície do terreno nu, já um MDS além dos valores de elevação da superfície do terreno apresenta também os valores de elevação de todos os componentes naturais ou artificiais acima do solo, como vegetação, estradas, carros, casas, fios de alta tensão, placas e outras estruturas edificadas pelo homem (WASKLEWICZ *et al.*, 2013) (Figura 5).

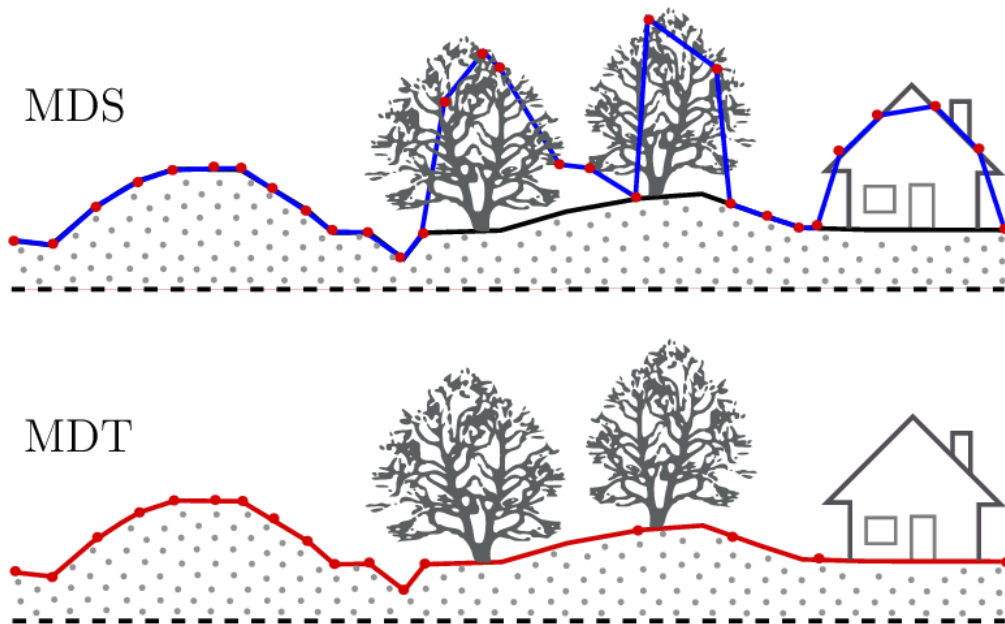


Figura 5 – Distinção entre um MDS e o MDT. **Fonte:** Carrilho (2016).

A obtenção de um MDT e um MDS a partir da nuvem de ponto 3D (irregularmente espaçados) é realizada mediante as seguintes etapas:

Modelo Digital de Altura (MDA)

Após a obtenção do MDT e do MDS é possível gerar o MDA, ao subtrair o MDT do MDS da mesma área. O MDA, ou modelo digital de superfície normalizado (MDSn) como também é conhecido, representa as alturas dos elementos presentes acima da superfície terrestre (HYYPPÄ *et al.*, 2008) (Figura 6).




Figura 6 - Modelo Digital de Altura. (A) Modelo Digital de Superfície; (B) Modelo Digital de Terreno; (C) Modelo Digital de Altura. **Fonte:** Ribeiro *et al.* (2015).

A altura também pode ser obtida ao subtrair o MDT da nuvem de pontos, gerando uma nuvem de pontos normalizada. Para a área florestal, o MDA e/ou a nuvem de pontos normalizada apresentam grande importância, uma vez que possibilitam a análise de cobertura vegetal e a obtenção da altura da copa de árvores.

Métrica LiDAR

Métricas LiDAR são estatísticas que resultam do processamento da nuvem de pontos e que podem atuar com diferentes finalidades, entre as quais estão: a caracterização da estrutura vertical e horizontal de uma área; parametrização da forma de árvores individuais; modelagem de variáveis florestais; modelagem de MDT, etc. (GORGENS; SILVA; RODRIGUEZ, 2014).

As métricas podem ser calculadas com base em nuvem de pontos originais (onde a coordenada Z representa os valores em elevação), ou em nuvem de pontos normalizadas (na qual a coordenada Z representa os valores em altura). Podem ser classificadas como métricas de: contagem, elevação ou altura e intensidade de retorno.

As métricas de contagem podem ser utilizadas para: conferir a qualidade da nuvem de pontos e do levantamento (exemplo a uniformidade por m²); o grau de complexidade vertical

(estratos de uma floresta), etc. As métricas de elevação ou altura são associadas com as coordenadas de posicionamento vertical dos pontos e podem ser divididas em métricas de posição, dispersão e proporção (GORGENS; SILVA; RODRIGUEZ, 2014). A elevação/altura média, máxima, mínima e as métricas de percentil são da categoria posição. A variância, o desvio padrão e o coeficiente de variação são métricas de dispersão, sendo úteis para a caracterização da estrutura do dossel. Porcentagens de retornos são métricas de proporção.

Além de registrar os valores de X, Y e Z para cada ponto, o sistema LiDAR também é capaz de registrar a intensidade do sinal de retorno que é mensurado pela quantidade de energia eletromagnética refletida ou emitida pelos diferentes alvos interceptados pelo pulso laser (JENSEN, 2011).

As métricas de intensidade podem ser empregadas para estudos de identificação de espécies florestais, quantificação de carbono e volume florestal, características fisiológicas de plantas, entre outros. Entretanto, segundo Gorgens, Silva e Rodriguez (2014), mesmo com grande potencial as métricas de intensidade requerem certo grau de cuidado, uma vez que, podem ser afetadas e apresentar ruídos devido às condições atmosféricas e erros inerentes ao equipamento laser.

5 METODOLOGIA GERAL

5.1 Área de estudo

O estudo foi conduzido na Fazenda Itapemirim, pertencente à empresa Agrimex Agroindustrial Excelsior S. A., localizada na parte Leste do município de Floresta e Sul do município de Betânia, em Pernambuco, contemplado com uma extensão territorial de 5.695,65 ha (Figura 7).

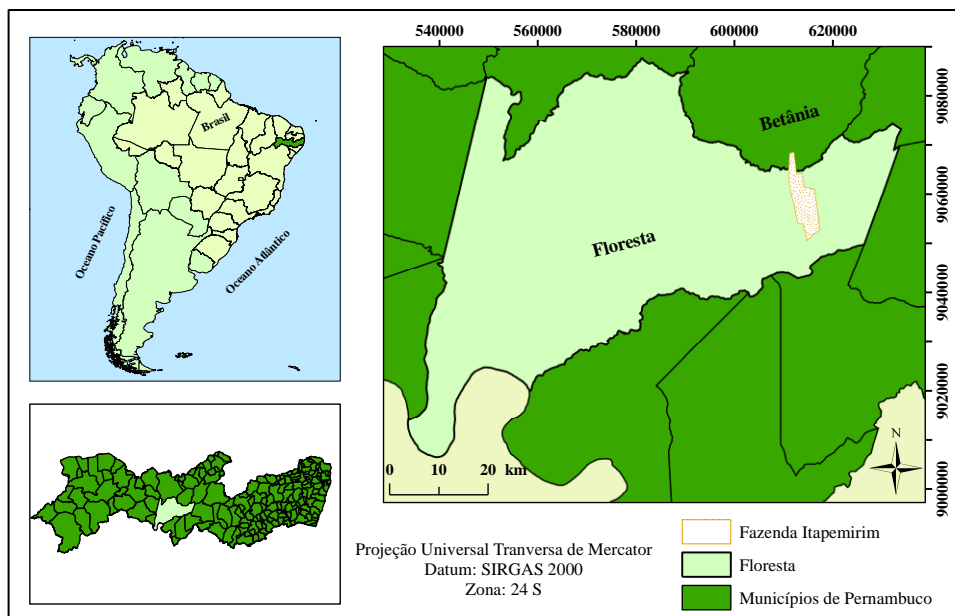


Figura 7 – Localização da área de estudo. **Fonte:** a autora.

Para a base do estudo, foram utilizados dados de inventário florestal de 2014, oriundos de duas áreas florestais com diferentes históricos de usos na Fazenda Itapemirim.

A Área I possui aproximadamente 50 hectares e está localizada nas coordenadas geográficas centrais de $8^{\circ}30'26''$ S e $37^{\circ}58'53''$ W. A vegetação dessa área se encontra em bom estado de conservação e não possui histórico de exploração recente, ocorrendo, entretanto, a eventual retirada de produtos florestais para usos domésticos e manutenção de cercas e a entrada de caprinos para pastejo (SANTOS, 2013).

A Área II também possui cerca de 50 ha e está localizada nas proximidades do km 28 da rodovia PE-360, com coordenadas geográficas centrais de $8^{\circ}33'37''$ S e $37^{\circ}56'39''$ W. A área possui histórico de perturbações antrópicas, entre as quais estão: plantações de algodão, corte raso por meio da técnica do correntão a cerca de 35 anos (1986), além da entrada de caprinos para pastejo e a exploração esporádica de madeira (BARRETO, 2017), que ocorrem até os dias atuais.

De acordo com a classificação de Köppen, o clima da região é do tipo BS'h (tropical semiárido, caracterizado pela aridez e deficiência hídrica), apresentando estação chuvosa entre os meses de janeiro a abril, com precipitações médias anuais em torno de 432 mm e temperatura média anual aproximada de 26° C (CPRM, 2005). Na Figura 8 é possível observar o histórico de precipitação dos anos de 2010 a 2015, na estação meteorológica automática de Floresta/PE, a aproximadamente 60 km de distância das áreas em estudo.




Figura 8 – Distribuição da precipitação ao longo dos anos de 2010 a 2015 na estação meteorológica automática de Floresta/PE. **Fonte:** Adaptado de Instituto Nacional de Meteorologia – INMET.

O solo dominante na área de estudo é do tipo Luvissole Crômico, caracterizado por ser raso e apresentar textura superficial arenosa e o relevo predominante é o suave ondulado (EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA - EMBRAPA, 2018).

A cobertura vegetal dominante é a Caatinga hiperxerófila, caracterizada por vegetação classificada como Savana estépica arborizada, de acordo com a classificação proposta pelo Instituto Brasileiro de Geografia e Estatística (IBGE, 2012). Araújo Filho *et al.* (2001) relatam ainda que a vegetação da área é arbustiva de baixo e médio porte, pouco densa e com presença de cactáceas.

5.2 Procedimentos adotados

5.2.1 Georreferenciamento das unidades amostrais (parcelas)

As 80 unidades amostrais permanentes, distribuídas sistematicamente, sendo 40 unidades amostrais na Área I, instaladas em 2008, por Alves Junior (2010) e 40 unidades amostrais na Área II, instaladas em 2008, por Ferraz (2011) (Figura 9), foram georreferenciadas no ano de 2019, com o auxílio de uma Antena Digital Trimble Catalyst interligada a um dispositivo smartphone que, em conjunto, coletaram as coordenadas indicadas com precisão sub-métrica (30 cm – 75 cm).

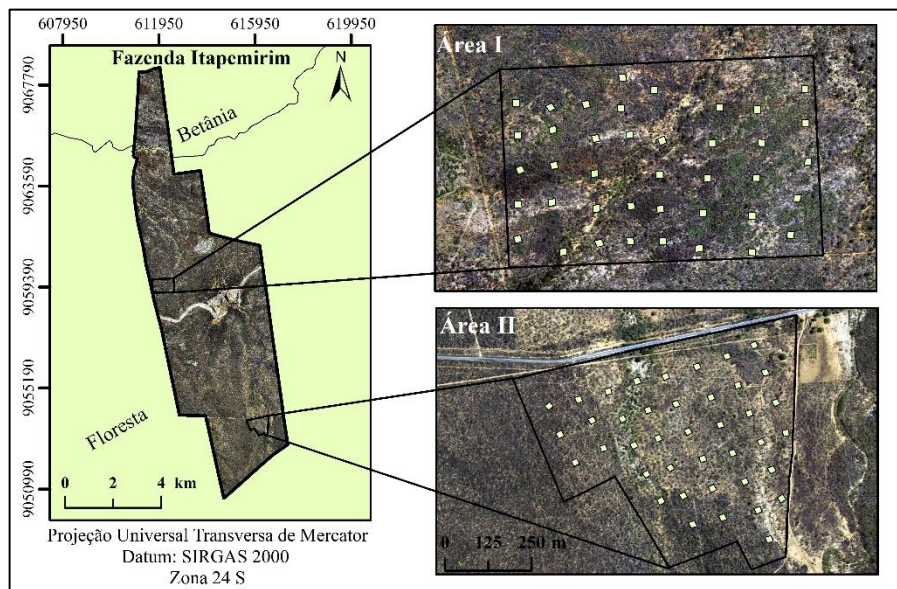


Figura 9 – Localização das unidades amostrais em campo, Floresta, PE. **Fonte:** a autora.

As unidades amostrais apresentam dimensões de 20 m x 20 m (0,04 ha) e estão dispostas em intervalos de aproximadamente 80 m entre si e distanciadas 50 m da área marginal, visando minimizar o efeito de borda.

5.2.2 Estimativas das variáveis biofísicas por meio de inventário florestal

5.2.2.1 Volume

Para obter as estimativas do estoque de volume por unidade amostral no ano de 2014, inicialmente foi realizado o ajuste do modelo não linear de Schumacher-Hall modificado.

$$V_i = \beta_0 (CAB_i^{\beta_1}) (CAP_i^{\beta_2}) (H_i^{\beta_3}) + \varepsilon_i$$

O banco de dados para o ajuste do modelo foi composto por amostras de circunferência à altura da base (CAB, cm), circunferência à altura de 1,30 metros do solo (CAP, cm), altura

total (H, m) e volume (m³) oriundas da cubagem de 351 árvores, pertencentes a dez espécies, na Fazenda Itapemirim realizada por Barreto (2017) e Dalla Lana *et al.* (2018).

Na etapa do ajuste foi desenvolvida uma equação geral, para todas as espécies utilizadas, além de equações para conjuntos de espécies (Tabela 1), que foram agrupadas após uma análise de agrupamento, a qual foi realizada por meio do método vizinho mais próximo e distância euclidiana quadrada como medida de dissimilaridade.

Tabela 1 – Equações para estimativa de volume (m³) para grupos de espécies características de floresta tropical seca, município de Floresta, Pernambuco, Brasil

Espécies agrupadas	Equações	R ² _{aj}	S _{xy}
<i>Anadenanthera colubrina</i> var. <i>cebil</i> (Griseb.) Altschul <i>Aspidosperma pyriforme</i> Mart. <i>Cenostigma bracteosum</i> (Tul.) E. Gagnon & G.P. Lewis; <i>Mimosa ophthalmocentra</i> Mart. ex Benth. <i>Mimosa tenuiflora</i> (Willd.) Poir.	$\hat{V}_i = 0,0000116 (CAB_i^{0,3949})(CAP_i^{1,4760}) (H_i^{0,6080})$	0,96	0,0013 (1)
<i>Commiphora leptophloeos</i> (Mart.) J.B.Gillett <i>Cnidocolus quercifolius</i> Pohl	$\hat{V}_i = 0,00000094 (CAB_i^{0,4199})(CAP_i^{1,4050}) (H_i^{1,9885})$	0,90	0,0018 (2)
<i>Bauhinia cheilantha</i> (Bong.) Steud.;	$\hat{V}_i = 0,000032 (CAB_i^{0,6902})(CAP_i^{0,8994}) (H_i^{0,2402})$	0,94	0,0001 (3)
<i>Croton heliotropiifolius</i> Kunth			
Equação Geral	$\hat{V}_i = 0,0000018 (CAB_i^{0,5887})(CAP_i^{1,2660}) (H_i^{1,5140})$	0,84	0,0025 (4)

CAB_i = circunferência a altura da base (em cm); CAP_i = circunferência a 1,30 m do solo (em cm); H_i = altura total (em metros); R²_{aj} = coeficiente de determinação ajustado e S_{xy} = erro padrão dos resíduos.

Após a obtenção das equações ajustadas (Tabela 1), as mesmas foram utilizadas para estimar o estoque de volume das unidades amostrais nas áreas em estudo para o ano de 2014. Nas equações foram utilizados os dados de circunferência à altura da base (CAB), circunferência à 1,30 m do solo (CAP) e altura total (H) oriundos do inventário florestal realizado em 2014, nas 80 unidades amostrais. O levantamento é realizado anualmente desde 2011, onde são mensuradas todas as árvores vivas com CAP ≥ 6 cm e são medidos o CAP, H e a CAB. As listas com as espécies amostradas no inventário florestal de 2014, podem ser visualizadas no Apêndice 1.

Os valores de volume obtidos para cada árvore analisada foram somados a nível de unidade amostral e convertidos para metros cúbicos por hectare ($m^3 \cdot ha^{-1}$) e desta forma, foram utilizados como referência (variável resposta) para os ajustes de modelos realizados nos dois capítulos deste estudo.

5.2.2.2 BSA

Para obter as estimativas de estoque de biomassa seca acima do solo (BSA) para o ano de 2014, foram utilizadas equações desenvolvidas por Dalla Lana *et al.* (2018), na mesma área de estudo, para oito espécies, além de uma equação geral (Tabela 2) juntamente com os dados de H e CAP (convertido para DAP) obtidos no inventário florestal realizado em 2014, nas 80 unidades amostrais estudadas.

Tabela 2 – Equações para estimativa biomassa seca acima do solo (kg) para oito espécies características de floresta tropical seca, município de Floresta, Pernambuco, Brasil

Espécies	Equações	R ² _{aj}	S _{xy} (%)	
<i>Anadenanthera colubrina</i> var. <i>cebil</i> (Griseb.) Altschul	$\hat{BSA}_i = 48,7255[1 - \exp(-0,1435DAP_i)]^{2,4096}$	0,89	20,69	(5)
<i>Aspidosperma pyriforme</i> Mart.	$\hat{BSA}_i = 0,7858(DAP_i^2 H_i)^{0,4550}$	0,75	26,64	(6)
<i>Bauhinia cheilantha</i> (Bong.) Steud.	$\hat{BSA}_i = 0,0669(DAP_i^{2,2115})(H_i^{0,8155})$	0,97	12,09	(7)
<i>Cnidoscolus quercifolius</i> Pohl	$\hat{BSA}_i = 0,6064(DAP_i^{1,4216})$	0,82	25,51	(8)
<i>Croton heliotropiifolius</i> Kunth	$\hat{BSA}_i = 0,1868(DAP_i^{1,2764})(H_i^{0,9401})$	0,76	18,96	(9)
<i>Mimosa ophthalmocentra</i> Mart. ex Benth.	$\ln \hat{BSA}_i = 1,1118 + 1,7371(\ln DAP_i) - 0,9536(\ln H_i)$	0,88	9,04	(10)
<i>Mimosa tenuiflora</i> (Willd.) Poir.	$\hat{BSA}_i = 0,5084(DAP_i^{1,7121})$	0,94	16,79	(11)
<i>Cenostigma bracteosum</i> (Tul.) E. Gagnon & G.P. Lewis	$\hat{BSA}_i = 6,6205 + 0,0341(DAP_i^2 * H_i)$	0,85	23,40	(12)
Equação Geral	$\ln \hat{BSA}_i = -1,2884 + 1,6102(\ln DAP_i) + 0,4343(\ln H_i)$	0,85	23,46	(13)

BSA = estimativa de biomassa seca acima do solo (kg); DAP_i = diâmetro a 1,30 m do solo (cm); H_i = altura total (m); R²_{aj} = coeficiente de determinação ajustado e S_{xy}(%) = erro padrão dos resíduos percentual. **Fonte:** Dalla Lana *et al.* (2018).

Os valores de estoque de BSA obtidos para cada árvore analisada, foram somados no nível de unidade amostral e convertidos e dimensionados para megagramas por hectare ($Mg \cdot ha^{-1}$) e foram utilizados como variável resposta nos ajustes de modelos realizados nos dois capítulos deste estudo.

5.2.2.3 Estatística descritiva das variáveis biofísicas

Após a obtenção dos estoques de volume e BSA para as unidades amostrais analisadas foi realizada a estatística descritiva das variáveis biofísicas, bem como, o cálculo de erro amostral do inventário florestal (Tabela 3). Para a Área II foi adotado um erro admissível de 20%, uma vez que a área possui maior variabilidade nos estoques de volume e BSA devido ao extenso histórico de perturbações antrópicas sofridas.

Tabela 3 – Estatística descritiva das variáveis respostas das Áreas I e II

Medidas estatísticas	Área I		Área II	
	Volume (m ³ .ha ⁻¹)	BSA (Mg.ha ⁻¹)	Volume (m ³ .ha ⁻¹)	BSA (Mg.ha ⁻¹)
Mínimo	1,67	2,20	0,32	0,47
Máximo	21,19	24,99	19,73	24,52
Média	10,14	13,66	5,57	7,78
Desvio padrão	3,71	4,21	3,46	4,83
Coef. de variação (%)	36,62	30,83	61,99	62,10
Erro amostral	1,19	1,35	1,11	1,54
Erro amostral (%)	11,71	9,86	19,83	19,86
Interv. de confiança (95%)	$8,95 \leq \mu \leq 11,33$	$12,31 \leq \mu \leq 15,00$	$4,47 \leq \mu \leq 6,68$	$6,23 \leq \mu \leq 9,32$
Erro admissível (%)	12,00	12,00	20,00	20,00
Número de amostras	40	40	40	40
Número ótimo de amostras	39	19	40	40

BSA: biomassa seca acima do solo; m³.ha⁻¹: metros cúbicos por hectare; Mg.ha⁻¹: megagramas por hectare.

5.2.3 Aquisição dos dados LiDAR ALS

Os dados LiDAR utilizados neste estudo são oriundos do Programa de Mapeamento Digital Pernambuco Tridimensional (PE3D), da Secretaria de Recursos Hídricos e Energéticos (SRHE), iniciado em 2014, com o objetivo de realizar o levantamento a laser e aerofotogramétrico de todo o território pernambucano.

De acordo com Consórcio Águas de Pernambuco (2017), a área de estudo I está compreendida entre as faixas de voo 478, 479, 479C, 480 e 480C e a área de estudo II está compreendida entre as faixas de voo 483C e 484C2. A varredura na área de estudo foi realizada no dia 10 de agosto de 2014 utilizando o perfilador laser (sensor) modelo ALS 50 -II (Airborne Laser Scanning), desenvolvido pela LEICA Geosystems, embarcado em aeronave do modelo EMB-810 C – Seneca II de prefixo PT-RQA.

A varredura a laser realizada nas faixas que englobam as áreas de estudo I e II consideraram os seguintes parâmetros:

- ✓ Altura de voo (relativa ao solo): 2.800,0 m;
- ✓ Ângulo de abertura (FOV): 30°;

- ✓ Largura da faixa: 1.500,0 m
- ✓ Superposição lateral (entre faixas): Min 13%;
- ✓ Frequência Scanner: 38,4 Hz;
- ✓ Frequência de repetição do laser: 88.600,0 Hz;
- ✓ Densidade média de pontos de retorno: AI = 1,64 pts.m⁻² e AII = 1,43 pts.m⁻²

De acordo com o Consórcio Águas de Pernambuco (2017), após a varredura a laser, foi realizado o processamento para a obtenção da nuvem de pontos (contendo as coordenadas x, y, z e intensidade de retorno do pulso laser) georreferenciada e com formato de saída do tipo LAS (formato específico dos arquivos laser). Em seguida foi efetuada a classificação da nuvem de pontos e a confecção de subprodutos, como MDT, MDS e imagens de intensidade-hipsometria.

Com relação ao subproduto MDT, utilizado neste estudo, a filtragem dos pontos do terreno foi baseada em parâmetros de classificação segundo a declividade da região trabalhada, a distribuição geométrica, altitude e intensidade de retorno do pulso LASER. Em seguida o MDT foi gerado e disponibilizados nos formatos ASCII xyz contendo as coordenadas tridimensionais e RASTER GeoTIFF (pixels com valor de elevação), com resolução radiométrica de 32 bits, ambos os formatos de saída com resolução espacial de 1m definida para a escala 1:5.000 (CONSÓRCIO ÁGUAS DE PERNAMBUCO, 2017).

Quanto a validação dos dados do perfilamento a LASER, segundo o Consórcio Águas de Pernambuco (2017), foi composta de quatro etapas de verificação:

1. A observação da densidade de pontos de retornos, a detecção de eventuais ocorrências de falta de recobrimento lateral e existência de vazios causados pela presença de nuvens densas;
2. A checagem dos parâmetros de configuração do sistema planejados com os realizados, entre os quais estão: altitude média do voo do perfilamento a laser, velocidade da aeronave em relação ao solo, PDOP (GPS), densidade média de pontos de retorno por faixa e densidade média de pontos de retorno sobre toda a área perfilada;
3. A abrangência da área perfilada, verificada visualmente com a superposição da nuvem simplificada de pontos LASER, resultante da cobertura sobre o polígono planejado para voo;
4. Análise da acurácia altimétrica (qualidade vertical do perfilamento), realizada por meio da comparação entre os pontos gerados pelo sensor ALS e os pontos oriundos do levantamento de controle de campo. Nesta etapa foram utilizados um total de 167 pontos de apoio, distribuídos por todo o estado de Pernambuco, referentes ao levantamento de pontos de controle planialtimétrico e ao levantamento de pontos de verificação (check point). O erro aceitável de altimetria exigido pelo contratante na área total levantada era de 25 cm. Os resultados obtidos nesta etapa são apresentados no Anexo A.

Juntamente com o levantamento a laser também foi realizada a cobertura aerofotogramétrica recobrimdo todo o estado de Pernambuco. O recobrimento aerofotogramétrico realizado em todo o Bloco III foi executado no período de 11/07/2014 a 29/11/2014, no qual foi utilizado um sensor modelo ADS40 - SH52 (Airborne Digital Sensor 40), desenvolvido pela LEICA Geosystems (operando com as bandas espectrais vermelho, verde, azul e NIR) e embarcado em uma aeronave do modelo EMB-820C - Navajo de prefixo PT-RAY (CONSÓRCIO ÁGUAS DE PERNAMBUCO, 2017).

Para a validação da aerotriangulação, nos dados provenientes do recobrimento aerofotogramétrico, foram utilizados pontos de controle planialtimétrico e pontos de verificação e os resultados obtidos para o bloco III pode ser observado no Anexo B.

As imagens (ortofotos) obtidas com o levantamento aerofotogramétrico para a área de estudo possuem resolução espacial de 0,50 m, resolução radiométrica de 8 bits e passaram por correção geométrica, com a ortorretificação (utilizando o MDT oriundo do perfilamento a laser), correção radiométrica e validação para cada correção. Além disso, as ortofotos atendem ao Padrão de Exatidão Cartográfica (PEC), referente à Classe A na escala 1:5.000.

Para este estudo a aquisição dos dados LiDAR foi realizada no endereço eletrônico do Programa Pernambuco Tridimensional (<http://www.pe3d.pe.gov.br>), no qual os dados encontram-se disponíveis gratuitamente para download.

5.2.4 Processamento dos dados LiDAR ALS

Os dados obtidos (nuvem de pontos e MDT com resolução espacial de 1 metro) passaram por processamento, com o auxílio dos softwares FUSION versão 3.80 (McGAUGHEY, 2020) e Notepad++ versão 7.8.8, com o intuito de extrair as métricas LiDAR para cada uma das 80 unidades amostrais distribuídas nas áreas de estudo.

As etapas metodológicas para obtenção das métricas podem ser visualizadas no fluxograma apresentado na Figura 10.

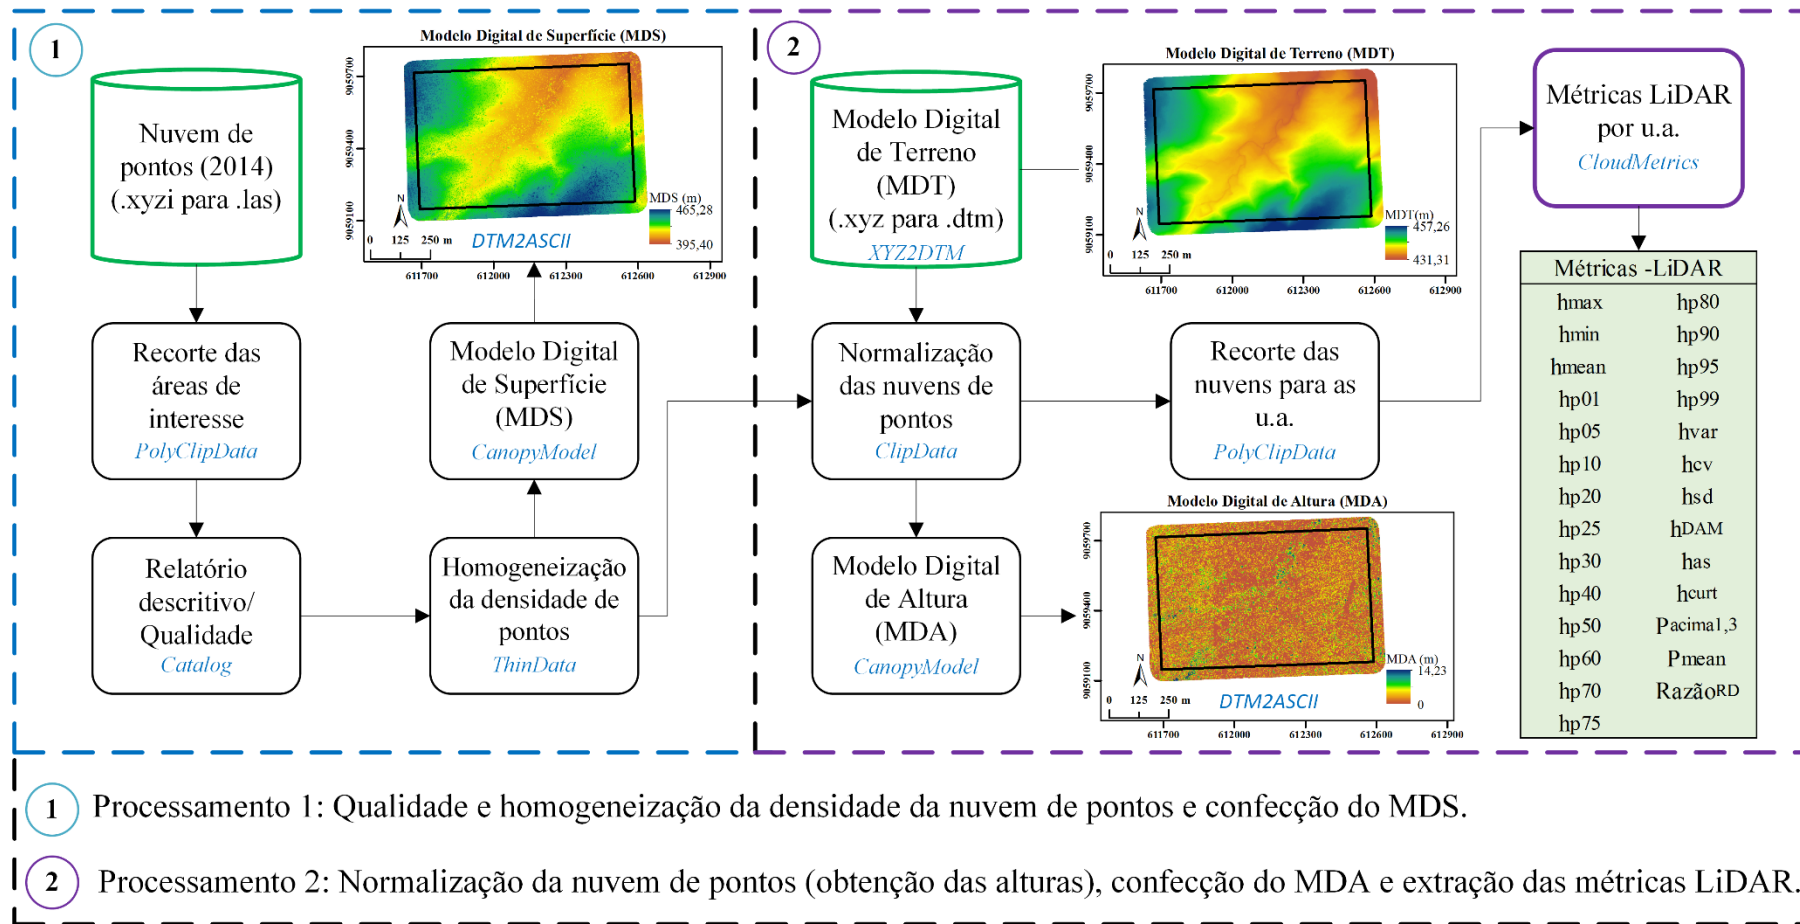


Figura 10 – Fluxograma metodológico para obtenção das métricas LiDAR por unidade amostral. **Fonte:** a autora.

Processamento 1. Qualidade e homogeneização da densidade da nuvem de pontos e confecção do MDS.

Etapa 1. Conversão da nuvem de pontos: a nuvem de pontos das áreas de interesse foi disponibilizada pelo Programa Pernambuco Tridimensional no formato .xyzi, desta forma, inicialmente foi realizada a conversão da nuvem para o formato .las (arquivo binário que contém as informações dos retornos LiDAR).

Etapa 2. Recorte das áreas de interesse: nesta etapa foi realizado o recorte da nuvem, já no formato .las, para as duas áreas de estudo (Área I e Área II), com o comando PolyClipData.

Etapa 3. Relatório descritivo e análise da qualidade da nuvem: após a conversão foi gerado um relatório descritivo, por meio do comando catalog, com as informações que descrevem as nuvens de pontos LiDAR das áreas analisadas. Além das informações descritivas, foi possível realizar a avaliação visual da qualidade das nuvens para detectar a presença de possíveis falhas ou outliers.

Etapa 4. Homogeneização da densidade de pontos: as nuvens de pontos das áreas em estudo tiveram sua densidade de pontos de retorno homogeneizada para 1,2 pontos/m², com o auxílio do comando ThinData. A homogeneização se faz necessária quando a densidade de pontos dentro de um único conjunto de dados LiDAR não é uniforme, o que normalmente ocorre em levantamentos com a sobreposição de duas ou mais faixas de voo (McGAUGHEY, 2020), como foi observado nas áreas de estudo.

Etapa 5. Confecção do Modelo Digital de Superfície (MDS): com a nuvem de pontos homogeneizada foi obtido, por meio do comando CanopyModel, o MDS (formato .dtm) contendo tanto as informações de elevação do terreno nu, como também as informações de elevação dos elementos acima do terreno.

Etapa 6. Conversão do MDS: em seguida, o MDS foi convertido para o formato ascii raster, com o comando DTM2ASCII, para posterior manipulação em SIG.

Processamento 2: normalização da nuvem de pontos (obtenção das alturas), confecção do MDA e extração das métricas LiDAR.

Etapa 1. Conversão do MDT: o MDT disponibilizado pelo Programa Pernambuco Tridimensional no formato .XYZ foi convertido para o formato .dtm, com o comando XYZ2DTM, para posterior normalização da nuvem de pontos. O MDT no formato raster GeoTIFF também foi obtido por meio do Programa Pernambuco Tridimensional para posterior manipulação em SIG.

Etapa 2. Normalização das nuvens de pontos: nesta etapa foi realizada a normalização das alturas das nuvens de pontos por meio do comando ClipData. Assim, no valor de elevação de

cada ponto a elevação foi subtraída do terreno (mediante o MDT.dtm), e o eixo z passa a representar a altura em relação ao solo e não a elevação do ponto.

Etapa 3. Confeção do Modelo Digital de Altura (MDA): após a normalização da nuvem de pontos foi possível confeccionar, por meio do comando CanopyModel, o MDA (formato .dtm), contendo as informações de altura dos elementos acima do terreno.

Etapa 4. Conversão do MDA: em seguida, o MDA foi convertido para o formato ascii raster, com o comando DTM2ASCII, para posterior manipulação em SIG.

Etapa 5. Recorte da nuvem normalizada: nesta etapa, foi utilizado o comando PolyClipData para realizar o recorte das nuvens de pontos normalizadas, com os arquivos vetoriais (shapefiles) contendo a delimitação das 80 unidades amostrais dispostas nas áreas analisadas, com área de 400 m² cada.

Etapa 6. Extração das métricas LiDAR: com o comando CloudMetrics foram calculadas e extraídas as métricas (utilizando um limiar de corte igual a 1,30 m do nível do solo) correspondentes a cada unidade amostral a partir da nuvem normalizada.

O MDS e o MDA foram confeccionados apenas por questões de ilustração da elevação e altura das árvores presentes nas áreas estudadas. As métricas utilizadas na modelagem foram extraídas na nuvem de pontos normalizada (representativa da altura de cada ponto).

Os comandos de processamento das nuvens de pontos LiDAR podem ser visualizados no Apêndice 2. Todos os produtos apresentados estão referenciados no Sistema de Projeção UTM (Universal Transversa de Mercator), Datum horizontal SIRGAS 2000 (Sistema de Referência Geocêntrico para as Américas).

CAPÍTULO 1

MODELAGEM DE VARIÁVEIS BIOFÍSICAS EM FRAGMENTOS DE FLORESTA TROPICAL SECA POR MEIO DO SISTEMA LASER SCANNER AEROTRANSPORTADO

1 INTRODUÇÃO

As Florestas Tropicais Secas (FTS) compõem quase metade das florestas tropicais e subtropicais do mundo (42%), estão distribuídas nos continentes da América, África, Ásia e Oceania e são consideradas importantes habitats de espécies endêmicas da fauna e da flora, além de fornecem uma gama de bens e serviços ecossistêmicos aos habitantes das regiões áridas e semiáridas, o que as torna econômica e socialmente importantes (MILES *et al.*, 2006).

A quantificação dos estoques de volume, biomassa e carbono em FTS é objeto de estudos de diversos pesquisadores que, por meio de diferentes métodos e base de dados, buscam entender a dinâmica, o crescimento, a capacidade produtiva, bem como, a importância ambiental desse tipo de vegetação.

Para conduzir um bom manejo florestal é imprescindível o conhecimento sobre os recursos existentes na floresta, o crescimento e a produtividade, as espécies que compõem a floresta e outras informações e características que auxiliam no suporte ao planejamento e ao manejo.

O volume de madeira de uma floresta é uma das variáveis fundamentais no planejamento e gestão florestal, sendo indispensável para a implementação de planos de manejo sustentável. Além disto, o volume, assim como a biomassa, é uma variável importante para o conhecimento da capacidade produtiva do sítio.

A estimativa de biomassa florestal acima do solo é fator imprescindível aos estudos de estoque de carbono florestal e balanço global de carbono. De acordo com Higuchi *et al.* (1998), na busca para minimizar os impactos ambientais gerados pela atividade florestal, a estimativa de biomassa representa um importante indicador para monitorar e avaliar a exportação de nutrientes após exploração florestal.

No inventário florestal convencional, as medições diretas têm alto grau de precisão, entretanto empregam métodos destrutivos da vegetação, consomem recursos substanciais em termos de tempo e custo financeiro e em grandes escalas espaciais e temporais, essas medições de campo podem se tornar inviáveis.

Desta forma, as medições indiretas podem ser alternativas mais viáveis para a medição de algumas variáveis florestais como a altura total, área basal, o estoque de volume e a

biomassa, uma vez que, implicam em menor mão de obra e menor custo financeiro em alguns casos (a depender da tecnologia utilizadas da extensão da área).

Nas últimas décadas, o sensoriamento remoto e outras geotecnologias têm seguido uma tendência crescente nas aplicações em inventário florestal, principalmente no que tange a mapeamentos em escala regional e global. Diversos estudos demonstram o potencial dos produtos oriundo do sensoriamento remoto (FERRAZ *et al.*, 2014; BALENOVIĆ *et al.*, 2015; MIGUEL *et al.*, 2015; GOMES, 2017).

Com o rápido avanço das técnicas de detecção remota, os sensores ativos, como o sistema Light Detection and Ranging (LiDAR), surgiram no mercado e estão sendo utilizados para auxiliar na obtenção de estimativas florestais mais precisas.

O sistema LiDAR é classificado como um sensor ativo, pois apresenta sua própria fonte de energia, o laser, o qual emite radiação eletromagnética em ondas curtas (ANDERSEN; REUTEBUCH; MCGAUGHEY, 2006). Esta é uma característica que o coloca em vantagem se comparado com sistemas de sensores passivos, uma vez que os scanners a laser não dependem do sol como uma fonte de iluminação e desta forma, a análise dos dados não é prejudicada por sombras causadas por nuvens ou objetos vizinhos (DONG; CHEN, 2018).

Por meio do processamento da nuvem de pontos LiDAR é possível obter o Modelo Digital de Terreno (MDT) que corresponde à elevação da superfície desnuda da terra - solo exposto (sem informações da vegetação ou objeto presente na superfície); o Modelo Digital de Superfície (MDS) que corresponde às informações de elevação de todas as feições na paisagem (natural e artificial: solo exposto, vegetação, edificações, pontes, montanhas, etc.); o Modelo Digital de Altura (MDA) que é semelhante ao MDS, porém os valores na coordenada Z não são representativos da elevação, e sim da altura dos objetos presentes na superfície; e métricas LiDAR, que são estatísticas que descrevem o conjunto de dados LiDAR referente à altura e intensidade dos objetos presentes na nuvem de pontos (JENSEN, 2011; McGAUGHEY, 2020).

Uma das principais abordagens de extração de características para derivar informações da floresta a partir dos dados LiDAR, é baseada na distribuição estatística do modelo digital de altura (MDA) ou da nuvem de pontos normalizada, a partir dos quais, são extraídas diversas estatísticas ou também chamada métricas (da árvore, da parcela ou povoamento inteiro) que são usadas diretamente para a estimação dos dados de inventário florestal, geralmente usando regressão, análise não paramétrica ou discriminante (HYYPÄ *et al.*, 2008).

A tecnologia LiDAR tem sido utilizada, com sucesso, nos últimos anos em diversas aplicações florestais. Means *et al.* (2000) estimaram o volume de uma área florestal composta por *Pseudotsuga menziesii*, localizada no Oregon (Estados Unidos) por meio de dados

provenientes do sistema LiDAR ALS, e relataram a obtenção de bons resultados para a predição. Lefsky *et al.* (2002b) em estudo para estimativa de biomassa para três formações florestais distintas (floresta boreal, floresta temperada de coníferas, floresta temperada decídua), obtiveram resultados promissores nas estimativas.

Muitos outros estudos têm demonstrado a precisão do uso da tecnologia LiDAR como instrumento de mensuração em florestas plantadas (ZONETE *et al.*, 2010; SILVA *et al.*, 2016; SILVA *et al.*, 2017) e em florestas nativas (IOKI *et al.*, 2010; d'OLIVEIRA *et al.*, 2012). Entretanto, poucos são os estudos desenvolvidos em florestas naturais e mais escassos são os desenvolvidos em áreas com vegetação do tipo arbustiva-arbórea, característica de florestas tropicais secas.

Neste contexto, objetivou-se com este estudo avaliar o potencial das métricas derivadas do sistema LiDAR ALS na predição de volume e biomassa seca acima do solo em áreas de floresta tropical seca, tendo como referência os dados oriundos de inventário florestal convencional, bem como, analisar o desempenho das equações geradas quanto a sua capacidade de generalização.

2 MATERIAL E MÉTODOS

2.1 Área de Estudo

O presente trabalho foi desenvolvido em dois fragmentos florestais de Savana estépica arborizada (Área I e Área II), de aproximadamente 50 ha cada, dentro da Fazenda Itapemirim, de propriedade da empresa Agrimex Agroindustrial Excelsior S.A., localizada no município de Floresta, no estado de Pernambuco, conforme descrito na metodologia geral.

2.2 Estimativas das variáveis biofísicas por meio de inventário florestal

As estimativas de volume e biomassa seca acima do solo (BSA) nas Áreas I e II, por meio do inventário florestal convencional, foram realizadas com base nas equações listadas nas tabelas 1 e 2, na metodologia geral.

As estimativas foram realizadas para o ano de 2014, mesmo ano de aquisição dos dados LiDAR (varredura laser scanner na área de estudo). Esta coincidência temporal implica que a estrutura da vegetação permaneceu invariável entre a aquisição de dados LiDAR e a amostragem de campo.

Os valores de estoque de volume ($\text{m}^3.\text{ha}^{-1}$) e BSA ($\text{Mg}.\text{ha}^{-1}$) por unidade amostral, foram utilizados como referência (variável resposta) para o ajuste do modelo de regressão linear múltipla nas áreas em estudo.

2.3 Ajuste do modelo de regressão linear para estimar volume e biomassa com dados LiDAR

Para a modelagem do volume e de BSA, foi utilizado o modelo de regressão linear múltipla, expresso por:

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_n X_{ni} + \varepsilon_i \quad (1)$$

Em que: Y_i = variável resposta; X_i = variáveis preditivas; β_0 , β_1 e β_n = parâmetros do modelo; ε_i = erro da estimativa.

Para compor a lista de variáveis preditivas, foram extraídas da nuvem de pontos, conforme exposto na metodologia geral, um total de 26 métricas (Quadro 1). A partir da nuvem de pontos LiDAR, é possível obter inúmeras métricas relacionadas a vegetação, no entanto, para este estudo foram geradas apenas as métricas frequentemente utilizadas como candidatas a preditoras na modelagem de atributos florestais (GÖRGENS *et al.*, 2015; SILVA, *et al.*, 2015; SILVA *et al.*, 2016).

Quadro 1 – Lista das métricas LiDAR avaliadas no estudo, obtidas a partir de pontos acima de 1,30 do solo, por meio da ferramenta cloudmetrics do software FUSION v. 3.8

Categoria		Métricas LiDAR	Simbologia
Altura	Posição	Altura máxima	h_{\max}
		Altura mínima	h_{\min}
		Altura média	h_{mean}
		Percentil 01 da altura	h_{p01}
		Percentil 05 da altura	h_{p05}
		Percentil 10 da altura	h_{p10}
		Percentil 20 da altura	h_{p20}
		Percentil 25 da altura	h_{p25}
		Percentil 30 da altura	h_{p30}
		Percentil 40 da altura	h_{p40}
		Percentil 50 da altura	h_{p50}
		Percentil 60 da altura	h_{p60}
		Percentil 70 da altura	h_{p70}
		Percentil 75 da altura	h_{p75}
		Percentil 80 da altura	h_{p80}
		Percentil 90 da altura	h_{p90}
		Percentil 95 da altura	h_{p95}
	Percentil 99 da altura	h_{p99}	
	Dispersão	Variância das alturas	h_{var}
		Coefficiente de variação das alturas	h_{cv}
		Desvio padrão das alturas	h_{sd}
		Desvio absoluto médio	h_{DAM}
		Curtose das alturas	h_{curt}
	Proporção (cobertura)	Porcentagem de todos os retornos acima de 1,30 m	$P_{\text{acima}1,3}$
		Porcentagem de todos os retornos acima da altura média	P_{mean}
		Razão relevo dossel	$\text{Razão}_{\text{ORD}}$

As fórmulas das métricas utilizadas neste estudo são descritas (McGAUGHEY, 2020) a seguir:

- Altura máxima (h_{\max}): é o valor mais elevado encontrado no intervalo de medição em metros dentro de cada unidade de amostra.
- Altura mínima (h_{\min}): é o valor mais baixo encontrado no intervalo de medição em metros dentro de cada unidade de amostra.
- Altura média (h_{mean}): é o valor médio de altura dos pontos:

$$h_{\text{mean}} = \frac{1}{n} \times \sum_{i=1}^n h_i \quad (2)$$

Em que: h_i = altura do i -ésimo ponto da nuvem de pontos e n = número de observações (número de pontos na nuvem).

➤ Percentis da altura na nuvem de pontos LiDAR (h_{pi}): é o i -ésimo percentil de n pontos (da nuvem de pontos LiDAR), ordenados em valores em altura, o qual é correspondente ao valor (em altura) que ocupa a posição K do conjunto de dados, como segue na equação a seguir:

$$K = \frac{h_{pi} (n + 1)}{100} \quad (3)$$

Em que: K = valor, em altura, que ocupa o i -ésimo percentil na nuvem de pontos; h_{pi} = o i -ésimo percentil em altura na nuvem de pontos e n = número de observações.

➤ Variância da altura (h_{var}):

$$h_{var} = \frac{1}{n-1} \times \sum_{i=1}^n (h_i - h_{mean})^2 \quad (4)$$

Em que: n = número de observações; h_i = altura do i -ésimo ponto da nuvem de pontos e h_{mean} = altura média.

➤ Desvio padrão da altura (h_{sd}):

$$h_{sd} = \sqrt{\frac{1}{n-1} \times \sum_{i=1}^n (h_i - h_{mean})^2} \quad (5)$$

Em que: n = número de observações; h_i = altura do i -ésimo ponto da nuvem de pontos e h_{mean} = altura média.

➤ Coeficiente de variação da altura (h_{cv}):

$$h_{cv} = \frac{h_{sd}}{h_{mean}} \quad (6)$$

Em que: h_{sd} = desvio padrão da altura e h_{mean} = altura média;

➤ Desvio absoluto médio (h_{DAM}): mede o afastamento médio dos elementos da amostra em relação à média aritmética da altura.

$$h_{DAM} = \frac{\sum_{i=1}^n (|h_i - h_{mean}|)}{n} \quad (7)$$

Em que: h_i = altura do i -ésimo ponto da nuvem de pontos; h_{mean} = altura média e n = número de observações.

➤ Curtose da Altura (h_{curt}): é uma medida de dispersão que determina o achatamento da curva da função de distribuição de frequências.

$$h_{curt} = \frac{\sum_{i=1}^n (h_i - h_{mean})^4}{(n-1)h_{sd}^4} \quad (8)$$

Em que: h_i = altura do i -ésimo ponto da nuvem de pontos; h_{mean} = altura média; h_{sd} = desvio padrão das alturas e n = número de observações.

➤ Razão relevo dossel ($Razão_{ORD}$): Trata-se de uma suavização do dossel, calculado pela razão entre a diferença da altura média e mínima e a diferença entre altura máxima e mínima.

$$\text{Razão}_{\text{RS}} = \frac{h_{\text{mean}} - h_{\text{min}}}{h_{\text{max}} - h_{\text{min}}} \quad (9)$$

Em que: h_{mean} = altura média; h_{min} = altura mínima e h_{max} = altura máxima.

A fim de obter estimativas precisas dos estoques de volume e BSA a partir da tecnologia LiDAR é essencial selecionar as métricas LIDAR (variáveis preditivas) mais significativas para modelagem. Além disto, o número de métricas LIDAR candidatas ao ajuste pode ser muito grande (26 neste estudo), e para obter um modelo mais parcimonioso, ou seja, capaz de proporcionar bom ajuste com o menor número possível de parâmetros, é necessária a utilização de uma boa metodologia para a seleção das variáveis preditivas.

No presente estudo, para a construção das equações preditivas de volume e BSA, as melhores métricas LiDAR candidatas ao ajuste foram selecionadas por meio de uma análise exploratória criteriosa, dividida em duas etapas.

Para a primeira etapa, aplicou-se o coeficiente de correlação linear de Pearson ($r_{x,y}$), por meio da função `cor` presente no pacote `stats` do software R, para análise (verificação direta da matriz de correlação, Apêndice 3) e remoção de variáveis preditivas multicolineares, neste caso, com valores de $r_{x,y} > 0,9$, conforme Hudak *et al.* (2012), Silva *et al.* (2014), Gorgens *et al.* (2015) e Silva *et al.* (2017). Para cada grupo de variáveis altamente correlacionadas (duas ou mais), apenas uma foi escolhida como candidata para o ajuste, neste caso, a variável mais correlacionada com o volume e com a BSA da amostra, excluindo-se as demais.

Na segunda etapa para a seleção das variáveis preditivas foi utilizado o método Stepwise, por meio da função `stepAIC`, pacote MASS do R, o qual seleciona as variáveis que mais contribuem na equação considerando a minimização da estatística Critério de Informação de Akaike (AIC, Akaike information criterion) (FERREIRA, 2013).

Todas as variáveis utilizadas no estudo (respostas e preditivas selecionadas) foram submetidas a uma análise descritiva, bem como, ao teste de normalidade de Shapiro-Wilk (SHAPIRO; WILK, 1965). Também foram realizados ajustes prévios do modelo de regressão linear múltiplo para a análise dos resíduos e verificação da conformidade dos pressupostos de normalidade pelo teste de Shapiro-Wilk (SHAPIRO; WILK, 1965) expresso pela fórmula 10, homocedasticidade pelo teste de Breusch-Pagan (BREUSCH; PAGAN, 1979), fórmula 11 e independência pelo teste de Durbin-Watson (DURBIN; WATSON, 1951) expresso pela fórmula 12:

$$W = \frac{\left(\sum_{i=1}^n a_i x_{(i)} \right)^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (10)$$

Em que: W= estatística do teste; $x_{(i)}$ = valores amostrais ordenados e a_i = constantes geradas a partir das médias, variâncias e covariâncias de uma amostra aleatória de tamanho n proveniente de uma distribuição normal.

$$LM = n R_e^2 (\sim X^2, \text{ com } k - 1) \quad (11)$$

Em que: n = tamanho da amostra; R_e^2 = coeficiente de determinação da regressão dos resíduos quadrados da regressão original, k = número de variáveis preditoras. A estatística do teste segue uma distribuição qui-quadrado, com k - 1.

$$dw = \frac{\left(\sum_{i=2}^n e_i - e_{i-1} \right)^2}{\sum_{i=1}^n e_i^2} \quad (12)$$

Em que: dw = estatística do teste, e_i = resíduo associado à i-ésima observação.

Os testes de Shapiro-Wilk, Breusch-Pagan e Durbin-Watson foram realizados pelas funções `shapiro.test()`, `bptest()` e `dwtest()` do software R.

Em seguida, após a identificação da não normalidade das variáveis respostas da Área II, bem como, da violação dos pressupostos de normalidade e/ou homocedasticidade dos resíduos das equações geradas no ajuste prévio, foi realizada a transformação das variáveis respostas volume ($\text{m}^3 \cdot \text{ha}^{-1}$) e BSA ($\text{Mg} \cdot \text{ha}^{-1}$) pelo método Box-Cox (BOX; COX, 1964), fórmula 13, para estabilizar ou reduzir a variabilidade existente e normalizar os resíduos.

$$y^\lambda = \frac{y^\lambda - 1}{\lambda}, \lambda \neq 0 \quad (13)$$

A análise e identificação do valor adequado de lambda (λ) para cada variável analisada foi realizada por meio da função `boxcox` do pacote MASS do software R.

Após encontrar o valor adequado de λ (0,45 para volume e 0,35 para BSA), foi realizada a transformação dos dados que em seguida passaram por uma análise descritiva e pelo teste de normalidade de Shapiro-Wilk (SHAPIRO; WILK, 1965).

O procedimento de ajuste do modelo de regressão linear múltipla, pelo método dos mínimos quadrados ordinários (OLS), foi realizado utilizando a função `lm` presente no pacote stats do software R.

Para a análise de outliers foi utilizado, em cada equação gerada, o teste de Bonferroni a partir da função outlierTest do pacote car no software R, o qual identifica observações mais extremas, com resíduos estudentizados absolutos elevados. As observações identificadas como outliers foram retiradas da amostra, uma de cada vez, e na sequência foram realizados novamente o ajuste sem a observação e o teste de outliers.

Para cada variável resposta foram consideradas as duas melhores equações, obtidas a partir das variáveis selecionadas pelo método Stepwise. Os coeficientes que compuseram as equações foram analisados quanto a significância a um nível de 95% de probabilidade, pelo teste t de Student.

2.4 Avaliação das equações preditivas de volume e BSA por meio de métricas LiDAR

Inicialmente, as equações geradas para estimar os estoques de volume e BSA foram avaliadas quanto aos pressupostos de normalidade, homocedasticidade e independência dos resíduos, a partir dos testes de Shapiro-Wilk, Breusch-Pagan, Durbin-Watson (fórmulas 10, 11 e 12). Também foi realizada a verificação da ausência de multicolinearidade nas equações por meio do fator de inflação da variação (VIF - Variance Inflation Factor), expresso pela fórmula 14. O limite utilizado para o VIF foi 10.

$$VIF_j = \frac{1}{1 - R_j^2}, j = 1, 2, \dots, p \quad (14)$$

Em que: VIF_j = Fator de inflação da variância; p = número de variáveis preditoras; R_j^2 = coeficiente de determinação, resultante da regressão de X_j sobre as outras variáveis preditivas.

Em seguida, as equações obtidas para cada conjunto de dados foram então comparadas e avaliados de acordo com as medidas de precisão: coeficiente de determinação ajustado (R_{aj}^2), erro padrão dos resíduos (S_{yx}), raiz quadrada do erro quadrático médio (RMSE), bem como, pelo desempenho da capacidade de generalização na validação cruzada k-fold, considerando a raiz quadrada do erro quadrático médio da validação cruzada (RMSEcv).

– Coeficiente de Determinação Ajustado (R_{aj}^2):

$$R_{aj}^2 = 1 - \left[\frac{n-1}{n-p} \right] \times (1 - R^2) \quad (15)$$

Em que: R^2 = coeficiente de determinação; n = número de observações; p = números de parâmetros. Esta medida de precisão indica a proporção da variação total associada à variável

resposta que pode ser explicada pelo modelo ajustado, em que, quanto mais próximo de 1 ou 100 % maior será a variação total explicada pela equação.

– Erro padrão dos resíduos (S_{yx}):

$$S_{yx} = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n - p - 1}} \quad (16)$$

Em que: Y_i = variável resposta observada; \hat{Y}_i = variável estimada; n = o número total de observações e p = números de parâmetros. O Erro padrão dos resíduos expressa o quanto em termos médios os valores observados variam em relação aos valores estimados, e quanto mais próximo de zero, mais eficiente é a regressão.

– Raiz quadrada do erro quadrático médio (RMSE):

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad (17)$$

Em que: Y_i = variável resposta observada; \hat{Y}_i = variável estimada; n = o número total de observações. A raiz quadrada do erro quadrático médio indica a diferença média quadrática entre os valores observados e estimados. Quanto menor o RMSE, melhor a precisão da estimativa.

A validação cruzada k-fold foi escolhida devido ao número limitado de amostras. Neste método k significa o número de subconjuntos no qual os dados de treinamento serão divididos aleatoriamente. Após a divisão, o treinamento da equação é iniciado em k-1, assim o grupo que não faz parte do treinamento é utilizado para teste da equação. Este procedimento é realizado até que cada um dos k subconjuntos tenha servido como conjunto de treinamento e de teste. Por fim, calcula-se a média dos k erros de predição registrados. O erro resultante é então utilizado para avaliar o desempenho da equação. Neste estudo, o k foi igual a 5 e o parâmetro de avaliação foi a RMSEcv.

O procedimento de validação cruzada k-fold foi realizado usando a função trainControl do pacote caret no software R.

Todas as análises estatísticas dos dados foram feitas com o auxílio do software de estatística R[®] (R Development Core Team, 2017).

2.5 Distribuição espacial do volume e biomassa

Nesta etapa, foi utilizada a calculadora raster do software QGIS para aplicar as melhores equações em toda a paisagem da Área I e Área II para mapear a distribuição espacial do volume e da BSA.

As funções `gridmetrics` e `csv2grid` do software FUSION foram utilizadas para auxiliar o processo de espacialização (pixel a pixel - resolução espacial de 20 metros) de cada métrica LiDAR contida nas equações finais de volume e BSA. Foi utilizada uma resolução espacial de 20 m, uma vez que os valores de volume e BSA que serviram de referência para a modelagem são oriundos de unidades amostrais que possuem a dimensão 20 m x 20 m.

Uma visão geral da metodologia é descrita na Figura 1.

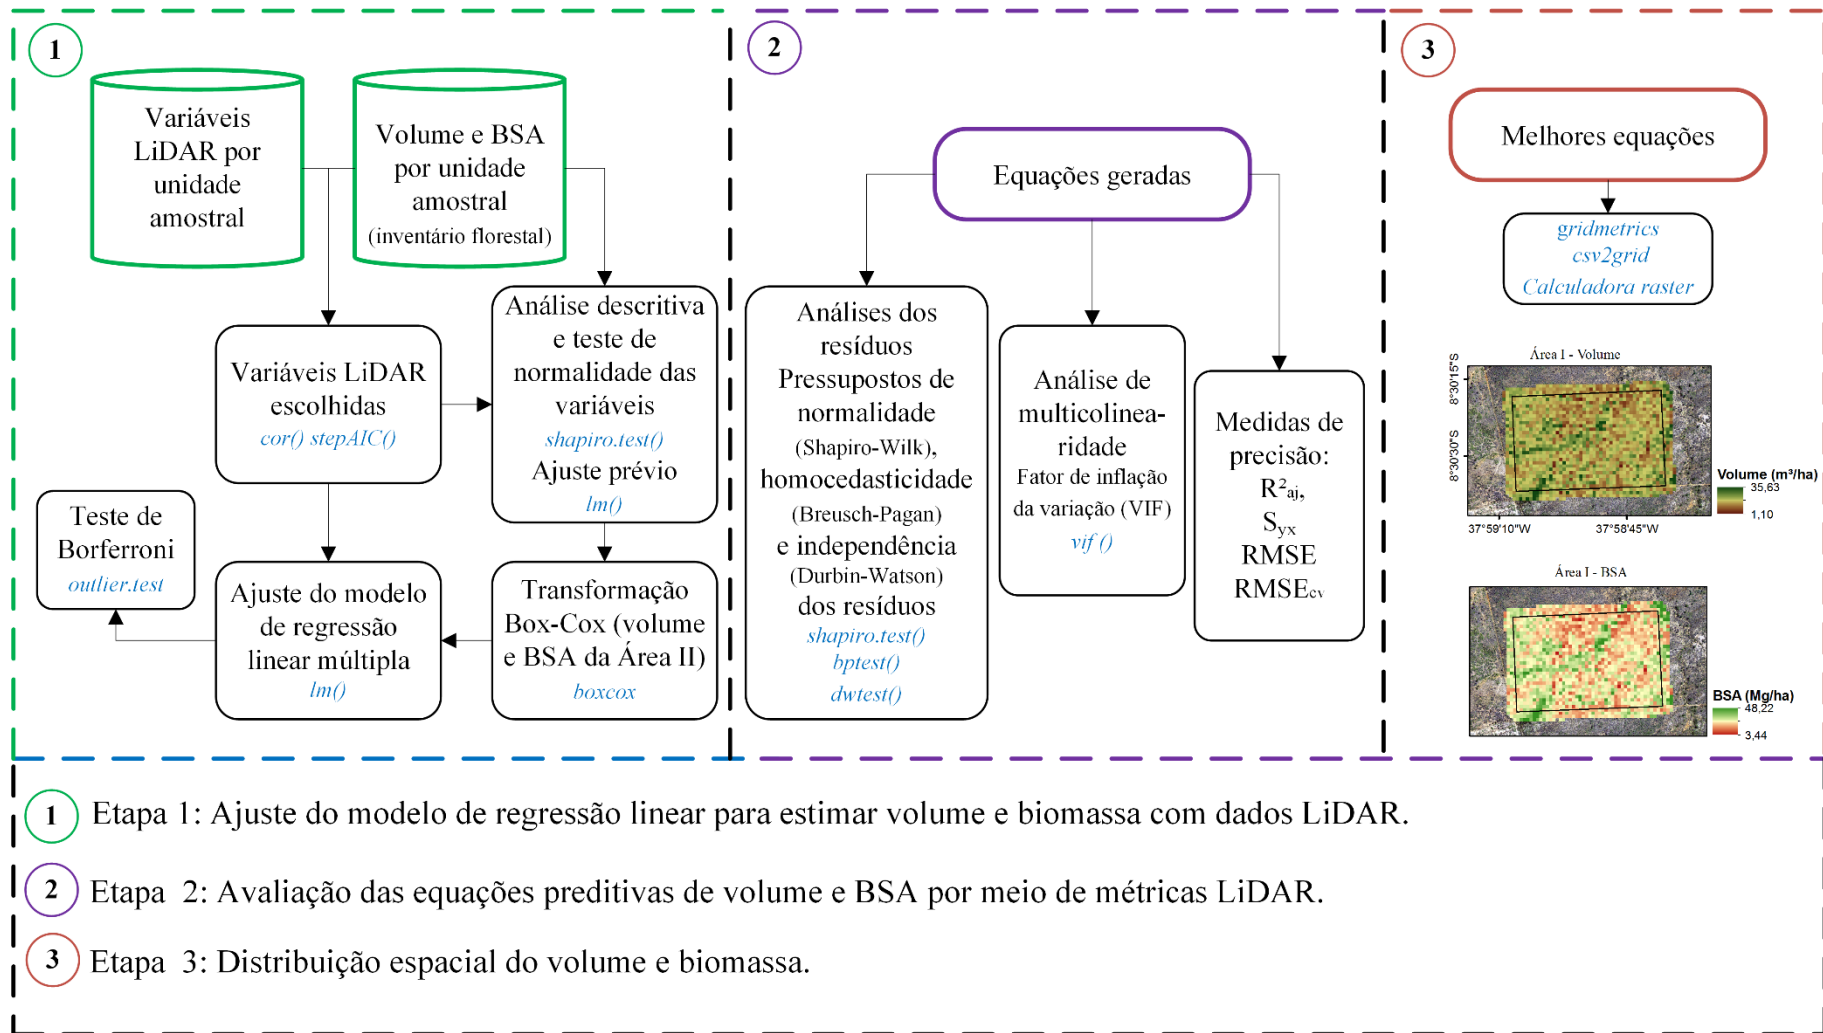


Figura 1 – Fluxograma metodológico para a estimativa do volume e da biomassa seca acima do solo. **Fonte:** autora.

3 RESULTADOS E DISCUSSÃO

3.1 Dados LiDAR ALS processados

De posse da nuvem de pontos bruta para cada área foi possível analisar e verificar sua qualidade, visando identificar possíveis pontos discrepantes.

Nas imagens representativas da área de estudo II, por exemplo (Figura 2), é possível observar a distribuição de pontos de retorno e suas respectivas elevações.

Nas Figuras 3 e 4 é possível visualizar os subprodutos gerados em formato raster a partir da tecnologia LiDAR ALS para as áreas de estudos, sendo eles o MDS, o MDT e o MDA, que neste caso contém os valores de altura das copas das árvores.

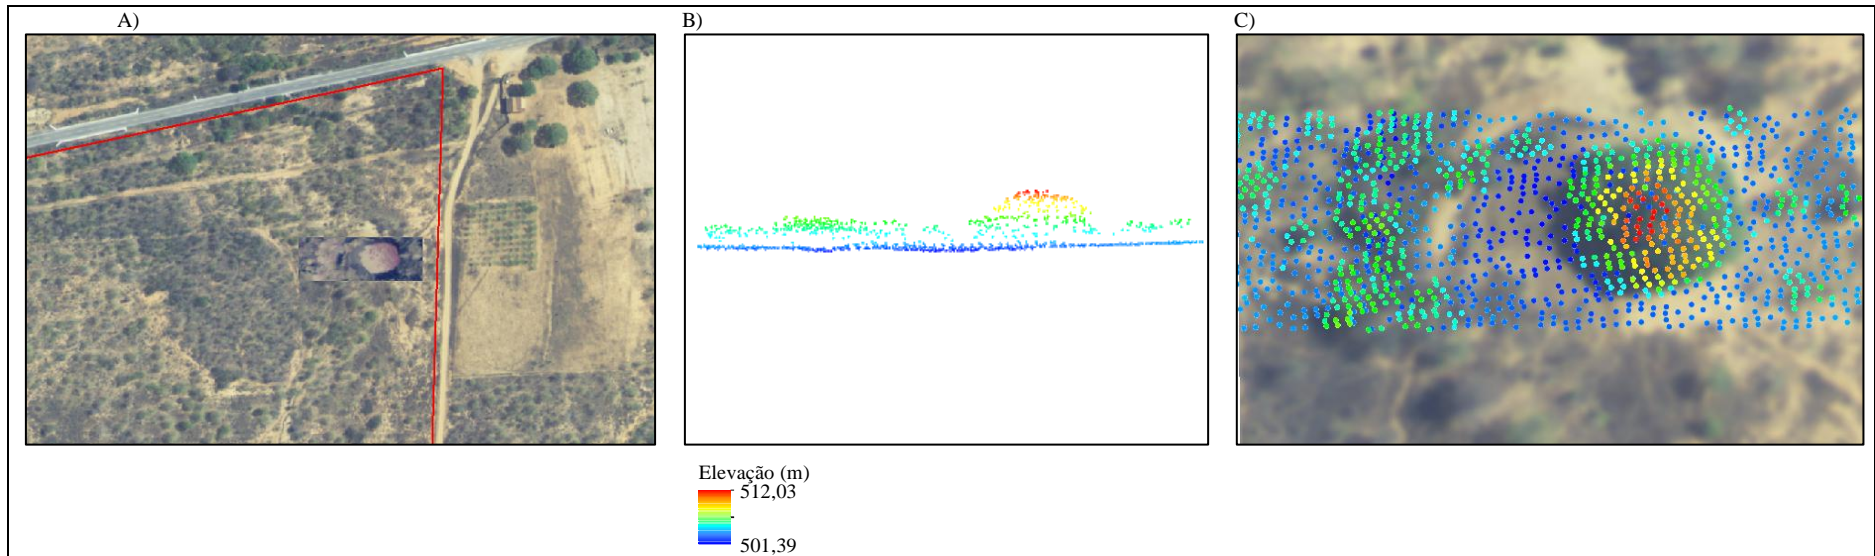


Figura 2 – Ortofoto e nuvem de pontos da Área II no software Fusion. A) ortofoto da Área II, B) perspectiva tridimensional da nuvem de pontos de uma amostra da Área II e C) sobreposição da nuvem de pontos na ortofoto da Área II. **Fonte:** o autor.




Figura 3 – Subprodutos, em formato raster, gerados a partir da nuvem de pontos na Área I. **Fonte:** o autor.




Figura 4 – Subprodutos, em formato raster, gerados a partir da nuvem de pontos na Área II. **Fonte:** o autor.

É conveniente ressaltar que a partir dos dados obtidos pelo inventário florestal na Área I, a altura máxima das árvores nas unidades amostrais foi de 8,7 m e por meio da tecnologia LiDAR a altura máxima foi de 8,4 m. Com relação à Área II, a altura máxima encontrada no inventário florestal foi de 7,2 m e a tecnologia LiDAR estimou uma altura máxima de 6,8.

Observa-se que a diferença entre os valores de altura máxima é baixa, o que evidencia que a tecnologia LiDAR pode gerar bom resultados relacionados à altura das árvores dominantes.

3.2 Ajuste do modelo e avaliação das equações preditivas de volume e BSA por meio de métricas LiDAR

Ao analisar as matrizes de correlação linear de Pearson entre as métricas LiDAR nas duas áreas de estudo (Apêndice 3), observou-se que muitas delas foram altamente multicolineares, ou seja, apresentam $r_{x,y} > 0,90$ entre si. Considerando as 26 métricas LiDAR candidatas à construção das equações preditivas, foram selecionadas para a segunda etapa de seleção das variáveis (Stepwise) 11 métricas (h_{max} , h_{sd} , h_{curt} , h_{p01} , h_{p05} , h_{p10} , h_{p25} , h_{p50} , h_{p80} , $P_{1.30}$ e $R_{AZ.RD}$) para volume e BSA da área I e 13 métricas (h_{min} , h_{max} , h_{sd} , h_{cv} , h_{curt} , h_{p01} , h_{p05} , h_{p10} , h_{p25} , h_{p50} , h_{p90} , $P_{1.30}$ e $R_{AZ.RD}$) para volume e BSA da área II.

Os resultados da análise descritiva das variáveis preditivas selecionadas após a análise dos valores obtidos para $r_{x,y}$, podem ser visualizados no Apêndice 4.

Na Área I, por meio do teste de Bonferroni foram identificados para as equações de volume quatro outliers (observações 4, 9, 16 e 24) e quatro outlier para as equações de BSA (observações 2, 4, 8 e 24) que foram removidos dos ajustes, um de cada vez, com o intuito de melhorar a precisão das equações.

Conforme observado na Tabela 1, a estimativa do volume obtida por meio da equação 1, em função das variáveis h_{p05} , h_{p10} , h_{p25} e $P_{1.3}$, mostrou-se superior com relação as medidas de precisão R^2_{aj} , S_{yx} e RMSE, e por este motivo, foi considerada a melhor equação, dentre as ajustadas, para prever o estoque de volume da Área I. Desta forma, 67% da variação do volume pode ser explicada pelas variáveis da equação, com erro padrão de $\pm 2,05 \text{ m}^3 \cdot \text{ha}^{-1}$, que representa um erro padrão percentual ($S_{yx\%}$) de 20,22%.

Tabela 1 – Coeficiente de determinação ajustado (R^2_{aj}), erro padrão dos resíduos (S_{yx}), raiz quadrada do erro quadrático médio (RMSE) e raiz quadrada do erro quadrático médio da validação cruzada k-fold (RMSE_{cv}) para as equações geradas para volume e BSA na Área I

Variável resposta	Equação	R^2_{aj}	S_{yx}	RMSE	RMSE _{cv}
(1) \hat{V}_i (m ³ .ha ⁻¹)	$- 6,35 + 13,51 h_{p05i} - 22,51 h_{p10i} + 13,66 h_{p25i} + 0,15 P_{1.3i}$	0,67	2,05 (20,22%)	1,90	2,30
(2) \hat{V}_i (m ³ .ha ⁻¹)	$- 7,60 + 1,77 h_{maxi} - 1,31 h_{curti} + 5,12 h_{p05i} + 0,13 P_{1.3i}$	0,63	2,20 (21,70%)	2,04	2,32
(1) \hat{BSA}_i (Mg.ha ⁻¹)	$- 8,24 + 4,85 h_{sdi} + 15,66 h_{p05i} - 16,73 h_{p10i} + 7,43 h_{p25i} + 0,20 P_{1.3i}$	0,75	2,01 (14,71%)	1,83	2,26
(2) \hat{BSA}_i (Mg.ha ⁻¹)	$- 7,52 + 1,19 h_{maxi} + 16,38 h_{p05i} - 19,49 h_{p10i} + 8,39 h_{p25i} + 0,18 P_{1.3i}$	0,74	2,05 (15,01%)	1,87	2,30

(1) e (2) número da equação gerada; S_{yx} , RMSE e RMSE_{cv} expressos em m³.ha⁻¹ para o volume (V) e em Mg.ha⁻¹ para biomassa seca acima do solo (BSA).

Com relação as equações para a estimativa da BSA, verificou-se que os valores de R^2_{aj} foram superiores aos obtidos nas estimativas do volume, atingindo R^2_{aj} máximo de 0,75. A melhor equação foi a 1, composta pelas variáveis h_{sd} , h_{p05} , h_{p10} , h_{p25} e $P_{1.3}$, que juntas são capazes de explicar 75% da variação da BSA, com erro padrão de $\pm 2,01$ Mg.ha⁻¹, o que corresponde a um erro percentual de 14,71%. Esta equação apresentou os melhores resultados em todas as medidas de precisão avaliadas, quando comparada com a equação 2.

A capacidade de generalização é um fator importante para a escolha da melhor equação, pois indica o quão preciso é a equação na prática, ou seja, perante a um novo conjunto de dados. A diferença obtida com validação cruzada k-fold, considerando o RMSE_{cv}, foi considerada baixa, entretanto é importante salientar que não existe uma estimativa não enviesada para tal erro. Os valores de RMSE_{cv} da validação cruzada para a melhor equação de volume e BSA da Área I (2,30 m³.ha⁻¹; 2,26 Mg.ha⁻¹) foram ligeiramente maiores que os RMSE das equações (1,90 m³.ha⁻¹; 1,83 Mg.ha⁻¹).

Os resultados obtidos pelos testes de Shapiro-Wilk, Breusch-Pagan e Durbin-Watson, indicaram que em todas as equações preditivas de volume e BSA para a Área I não houve a violação dos pressupostos da normalidade, homocedasticidade e independência dos resíduos. A análise gráfica dos resíduos padronizados versus valores preditos (Figura 5 - 8), evidencia a aleatoriedade dos resíduos, dispersos em torno de zero e concentrados em sua maioria (95%) entre -2 e 2, o que confirma a homoscedasticidade dos resíduos. Também não foi identificado, pelo fator de inflação de variação (VIF), multicolinearidade nas equações geradas.




Figura 5 – Gráfico de resíduos padronizados versus volume predito, relação do volume predito versus o observado (N=36) e validação cruzada da equação 1. A linha indica a relação de 1:1. **Fonte:** o autor.

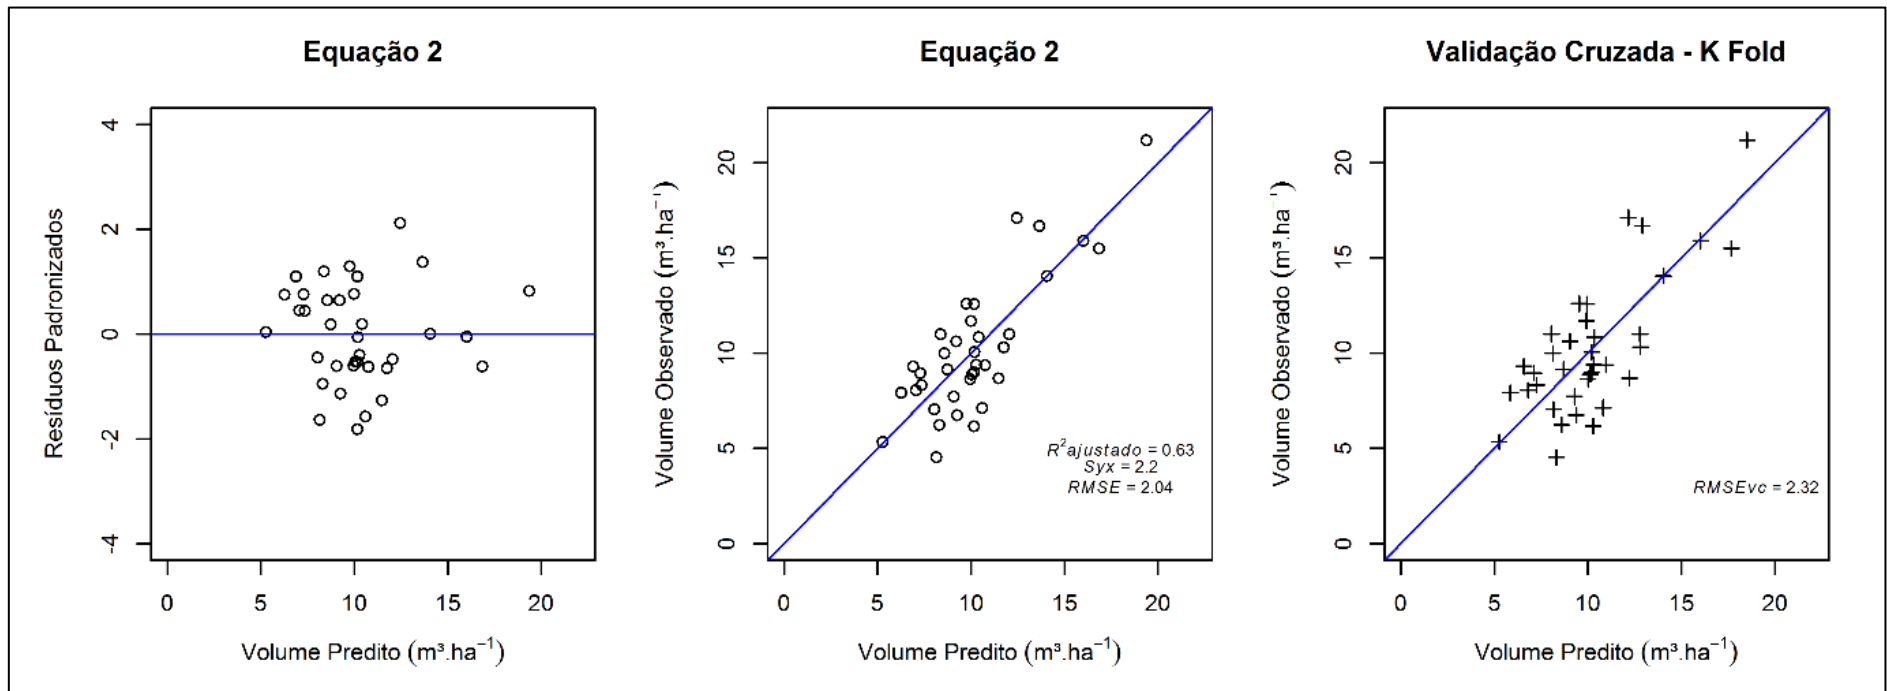


Figura 6 – Gráfico de resíduos padronizados versus volume predito, relação do volume predito versus o observado (N=36) e validação cruzada da equação 2. A linha indica a relação de 1:1. **Fonte:** o autor.




Figura 7 – Gráfico de resíduos padronizados versus BSA predita, relação da BSA predita versus a observada (N=36) e validação cruzada da equação 1. A linha indica a relação de 1:1. **Fonte:** o autor.




Figura 8 – Gráfico de resíduos padronizados versus BSA predita, relação da BSA predita versus a observada (N=36) e validação cruzada da equação 2. A linha indica a relação de 1:1. **Fonte:** o autor.

Na Figura 9 é possível verificar, na área I, que tanto para volume como para BSA, mesmo para as melhores equações, a predição não foi capaz de reproduzir os valores reais, mostrando tendências de superestimar valores mais baixos e subestimar valores mais altos.

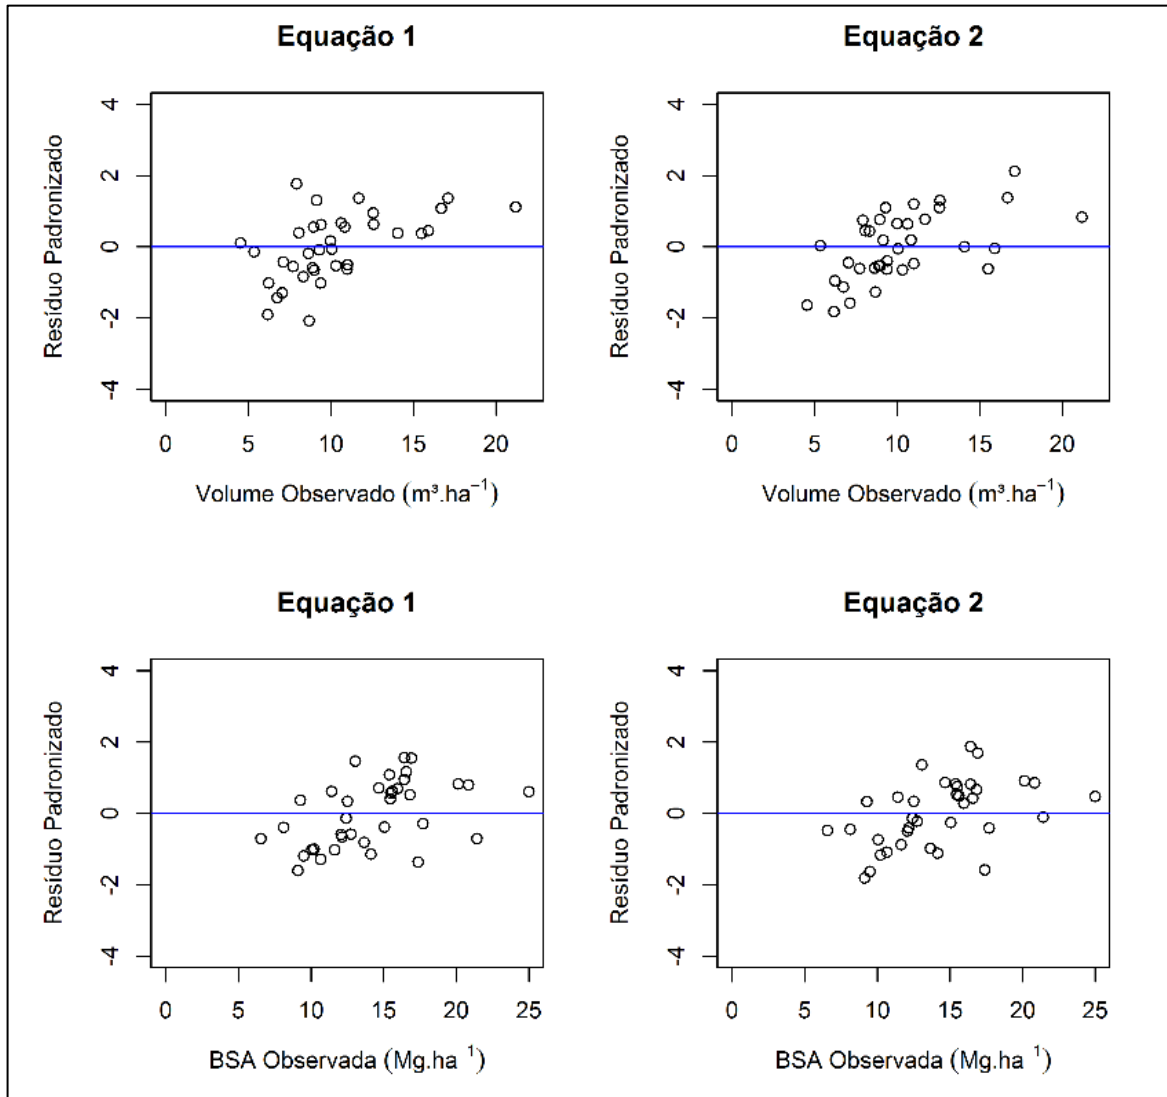


Figura 9 – Gráficos de resíduos padronizados versus variável resposta observada (N=36) das equações 1 e 2 para a Área I. **Fonte:** o autor.

Na Área II, por meio do teste de Bonferroni foram identificados para as equações de volume e BSA cinco outliers (observações 15, 17, 27, 31 e 37) que foram removidos dos ajustes, um de cada vez, com o intuito de melhorar a precisão das equações.

Com relação as equações para a estimativa do volume (variável transformada) para a Área II (Tabela 2), verificou-se que a melhor equação foi o equação 1, composta pelas variáveis, h_{sd} , h_{cv} , h_{p90} e $P_{1.3}$, as quais possuem a capacidade de explicar 65% da variação do volume, com um erro padrão de $1,13 \text{ m}^3.\text{ha}^{-1}$ ($S_{yx\%} = 22,47\%$). Esta equação apresentou os melhores resultados

em todas as medidas de precisão avaliadas, exceto $RMSE_{cv}$, quando comparado com a equação 2.

Tabela 2 – Coeficiente de determinação ajustado (R^2_{aj}), erro padrão dos resíduos (S_{yx}), raiz quadrada do erro quadrático médio (RMSE) e raiz quadrada do erro quadrático médio da validação cruzada k fold ($RMSE_{cv}$) para as equações geradas para volume e BSA na Área II

Variável resposta	Equação	R^2_{aj}	S_{yx}	RMSE	$RMSE_{cv}$
(1) (\hat{V}_i m ³ .ha ⁻¹)'	$-2,31 - 6,26 h_{sd_i} + 17,42 h_{cv_i} + 1,05 h_{p90_i} + 0,01 P_{1,3_i}$	0,65	1,13 (22,47%)	1,05	1,21
(2) (\hat{V}_i m ³ .ha ⁻¹)'	$1,82 - 0,83 h_{p50_i} + 0,55 h_{p90_i} + 0,01 P_{1,3_i}$	0,60	1,21 (24,06%)	1,12	1,26
(1) (\hat{BSA}_i Mg.ha ⁻¹)'	$-2,84 - 4,53 h_{sd_i} + 17,97 h_{cv_i} + 1,21 h_{p25_i} + 0,02 P_{1,3_i}$	0,58	2,55 (35,03%)	2,36	2,74
(2) (\hat{BSA}_i Mg.ha ⁻¹)'	$1,97 - 1,18 h_{p05_i} + 0,81 h_{p10_i} + 0,01 P_{1,3_i}$	0,57	2,44 (33,52%)	2,26	2,46

(1) e (2) número da equação gerada; ' variável transformada; S_{yx} , RMSE e $RMSE_{cv}$ obtido para os dados na escala natural, ou seja, expressos em m³.ha⁻¹ para o volume (V) e em Mg.ha⁻¹ para biomassa seca acima do solo (BSA).

Para a predição da BSA (variável transformada) da Área II a equação 2 (h_{p05} , h_{p10} e $P_{1,3}$) mostrou-se ligeiramente superior, com melhores resultados em quase todas as medidas de precisão, alcançando R^2_{aj} de 0,57 e erro padrão de 2,44 Mg.ha⁻¹ ($S_{yx\%} = 33,52\%$).

As equações geradas para prever a BSA (variável transformada) da Área II apresentaram resultados inferiores nas medidas de precisão R^2_{aj} , S_{yx} e RMSE se comparadas as equações de BSA geradas para a Área I. Por outro lado, os $RMSE_{cv}$ obtidos foram ligeiramente superiores.

Quanto a capacidade de generalização das equações de volume e BSA da Área II, expressa pelo $RMSE_{cv}$ obtido na validação cruzada, foi possível observar que quando submetidas a dados desconhecidos, as equações produzem erros maiores, com diferença entre RMSE e $RMSE_{cv}$ variando de 0,14 a 0,16 m³.ha⁻¹ para volume e 0,20 a 0,38 Mg.ha⁻¹ para BSA, entretanto, o desempenho de generalização foi melhor se comparado as equações da Área I, a qual obteve em suas equações diferenças entre RMSE e $RMSE_{cv}$ variando entre 0,28 a 0,40 m³.ha⁻¹ para volume e 0,43 Mg.ha⁻¹ para BSA.

Assim como nas equações para a Área I, os resultados obtidos pelos testes de Shapiro-Wilk, Breusch-Pagan e Durbin-Watson, indicaram que todas as equações de volume e BSA (variáveis transformadas) para a Área II foram aceitas quanto aos pressupostos da normalidade, homocedasticidade e independência dos resíduos. Observa-se na análise gráfica dos resíduos padronizados versus valores preditos (Figura 10 - 13), a aleatoriedade dos resíduos, dispersos em torno de zero e concentrados em sua maioria (95%) entre -2 e 2, o que caracteriza a homoscedasticidade dos resíduos. O fator de inflação de variação (VIF), não identificou multicolinearidade nas equações obtidas.

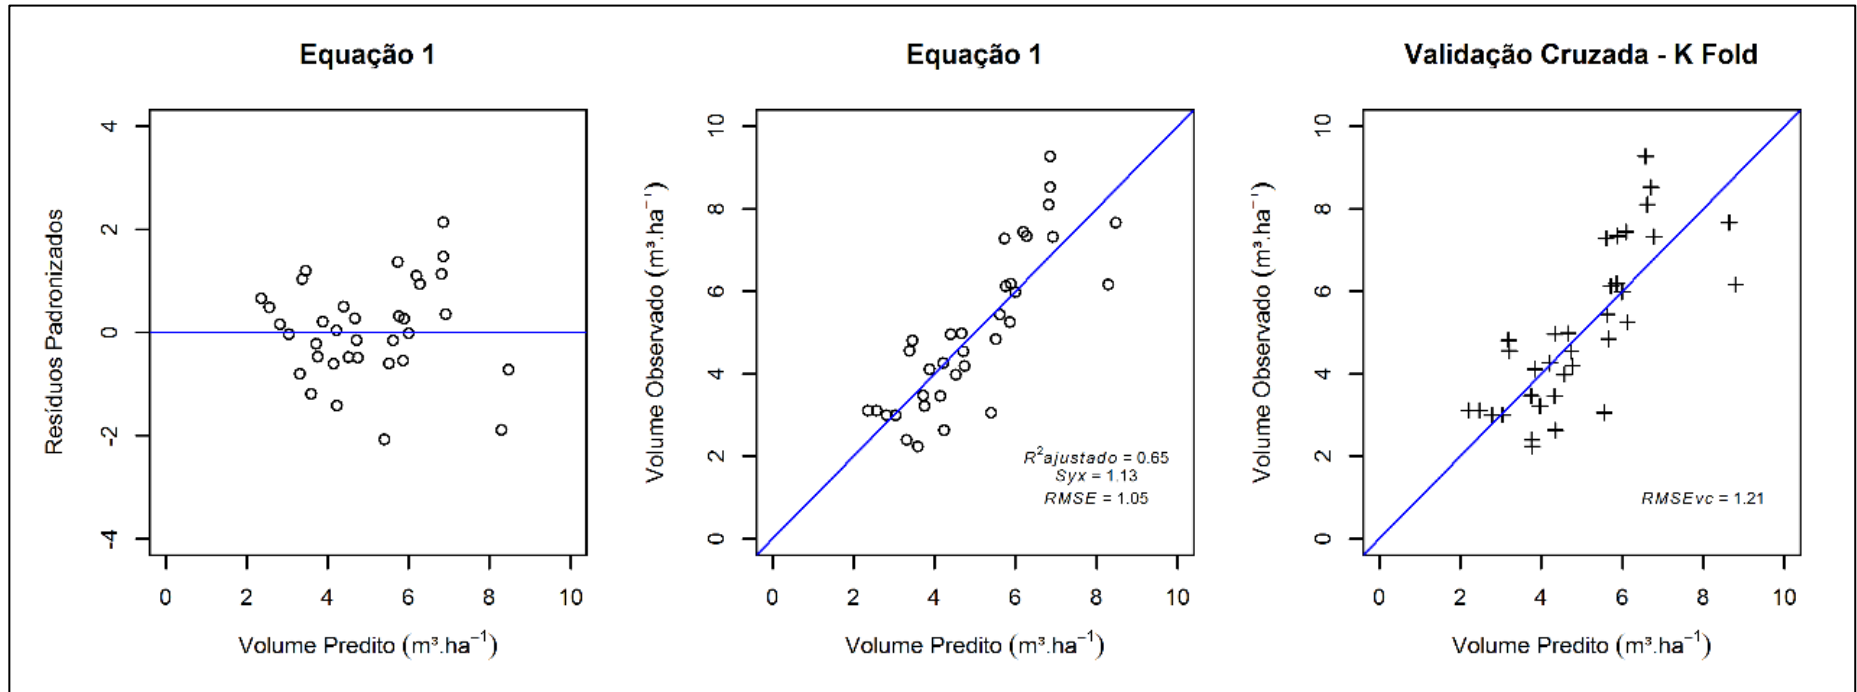


Figura 10 – Gráfico de resíduos padronizados versus volume predito, relação do volume predito versus o observado (N=35) e validação cruzada da equação 1. A linha indica a relação de 1:1. **Fonte:** o autor.

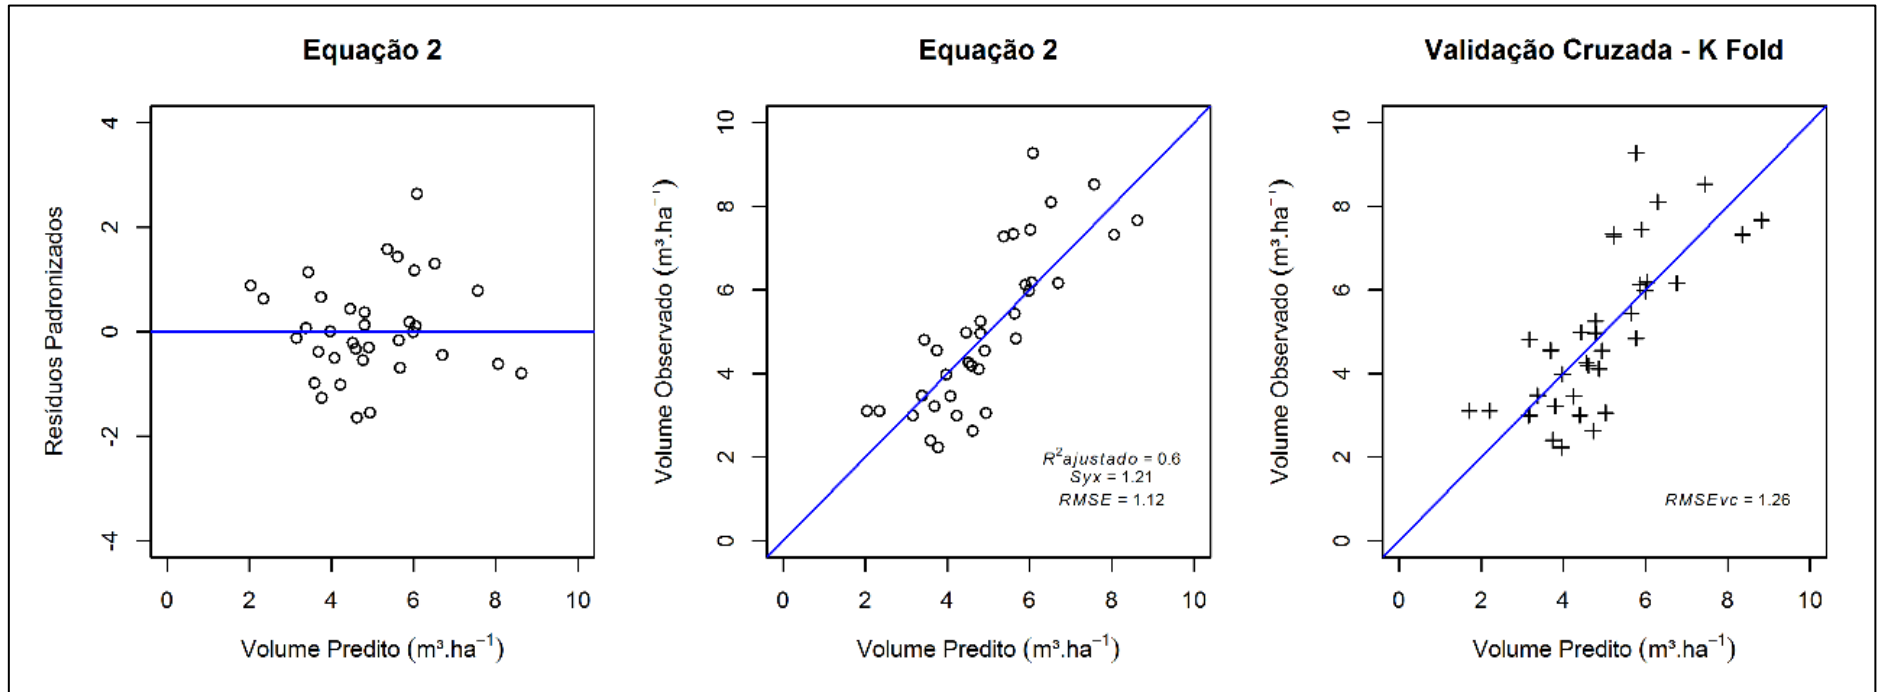


Figura 11 – Gráfico de resíduos padronizados versus volume predito, relação do volume predito versus o observado (N=35) e validação cruzada da equação 2. A linha indica a relação de 1:1. **Fonte:** o autor.

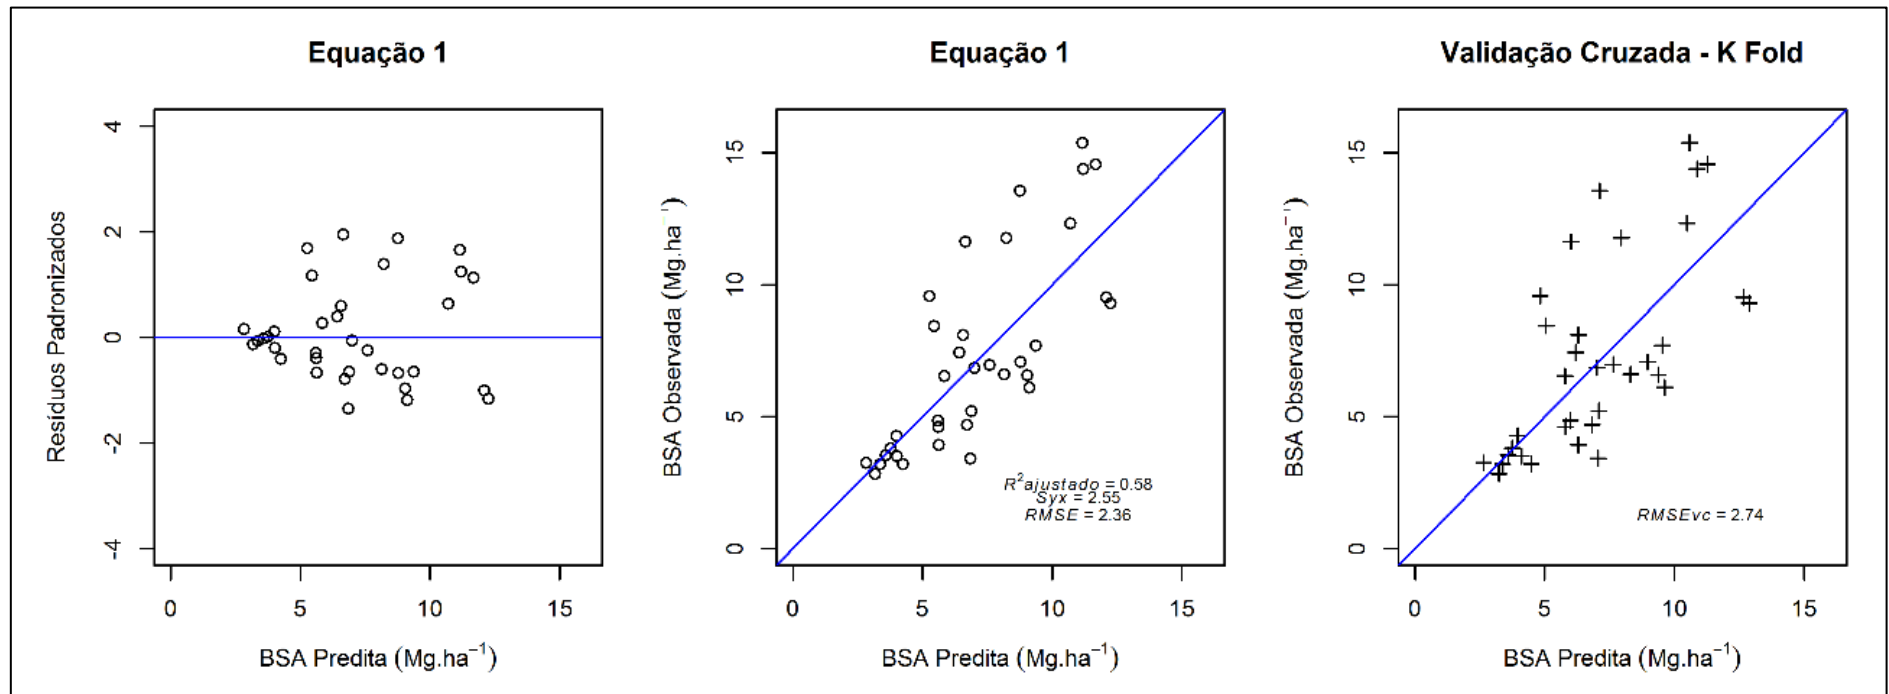


Figura 12 – Gráfico de resíduos padronizados versus BSA predita, relação da BSA predita versus a observada (N=35) e validação cruzada da equação 1. A linha indica a relação de 1:1. **Fonte:** o autor.




Figura 13 – Gráfico de resíduos padronizados versus BSA predita, relação da BSA predita versus a observada (N=35) e validação cruzada da equação 2. A linha indica a relação de 1:1. **Fonte:** o autor.

Na Figura 14 observa-se que, assim como observado para a Área I, todas as equações geradas para a Área II apresentaram tendência de subestimar os valores maiores e superestimar valores mais baixos.

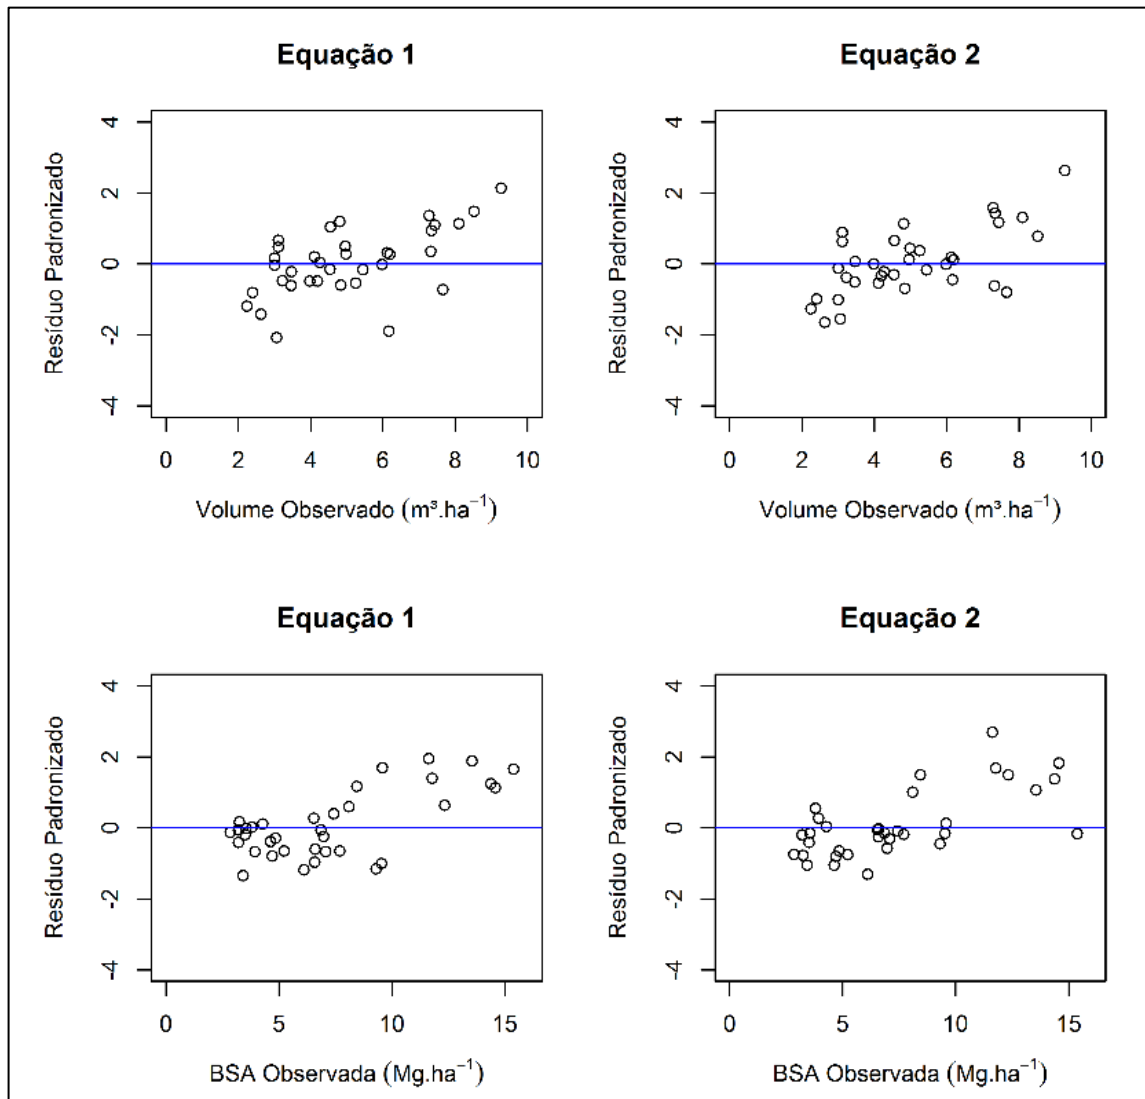


Figura 14 – Gráficos de resíduos padronizados versus variável resposta observada (N=35) das equações 1 e 2 para a Área II. **Fonte:** o autor.

A variável $P_{1,3}$, que corresponde a porcentagem de todos os retornos acima de 1,30 m, apareceu em todas as equações obtidas. Observou-se que esta variável obteve os maiores valores de correlação com as variáveis respostas (transformadas) volume e BSA para a Área II, com $r_{x,y} = 0,73$ para volume e $0,77$ para BSA, como pode ser observado no Apêndice 3.

Com relação à variável h_{p25} (trata-se da altura h na qual 25% de todos os retornos com altura superior a 1,30 metros, estão abaixo dessa altura h) que esteve presente em quatro equações, sendo três de BSA e três das quatro melhores equações ajustadas no estudo, verificou-

se a presença de forte correlação com a variável h_{med} para ambas as áreas de estudo ($r_{x,y} = 0,79$ e $0,92$), a qual pode ser considerada uma boa representante do comportamento vertical de florestas heterogêneas, como a Caatinga (a partir dos dados LiDAR), ao contrário do que se vê em plantios homogêneos, nos quais a h_{max} e os percentis mais altos (h_{p90} , h_{p95} , h_{p99}) obtêm bons desempenhos como variáveis preditivas de atributos biofísicos da vegetação (SILVA, *et al.*, 2014; SILVA *et al.*, 2016; SILVA *et al.*, 2017; LEITE *et al.*, 2020). Desta forma, já era esperada a presença desta variável nas equações neste estudo, uma vez que a h_{med} foi retirada da modelagem por possuir alta correlação com grande parte das variáveis de percentis.

Além disto, os percentis mais baixos, como exemplo h_{p05} , h_{p10} e h_{p25} , normalmente estão relacionados com o estrato inferior da floresta, o sub-bosque, e, portanto, podem estar capturando variações da estrutura horizontal da floresta como a área basal, como relatam Gorgens, Silva e Rodriguez (2014), o que também pode explicar a presença das variáveis h_{p10} e h_{p25} em quatro das oito equações e h_{p05} em cinco equações, uma vez que a área basal apresenta forte correlação com a biomassa e com o volume florestal (HUSCH *et al.*, 1963; SCOLFORO, 2006; BATISTA; COUTO; SILVA FILHO, 2014).

A seleção da variável h_{p25} neste estudo é congruente com o estudo desenvolvido por d'Oliveira *et al.* (2012) em uma área de vegetação heterogênea na Floresta Estadual Antimary no Acre, onde concluíram que a variável h_{p25} , oriunda da tecnologia LiDAR, possui forte poder preditivo dos estoques de volume e biomassa.

Quanto a variável h_{sd} que participou de três equações, das quais duas obtiveram os melhores resultados no estudo e a variável h_{cv} que participou de duas equações estão relacionadas com a caracterização da estrutura do dossel, com a variabilidade da altura do dossel e com a sua rarefação no que tange à passagem dos pulsos LiDAR por meio dos espaços entre os galhos e a folhagem. Em áreas com o dossel florestal esparsa, como é o caso das áreas em estudo, um pulso LiDAR tem maior possibilidade de gerar um segundo e/ou terceiro retorno abaixo da superfície do dossel, identificando árvores do sub-bosque, o que logicamente aumenta a variabilidade dos retornos (d'OLIVEIRA *et al.*, 2012).

Métricas LiDAR relacionadas com a variabilidade das alturas dos retornos (h_{var} , h_{sd} , h_{cv}) são comumente utilizadas em modelagem de atributos biofísicos de florestas naturais, nas quais a altura do dossel é altamente variável (ESTORNELL *et al.*, 2011; d'OLIVEIRA *et al.*, 2012), como é o caso das áreas em estudo.

De forma geral, observa-se que houve uma distinção na configuração das equações de volume das áreas estudadas. Na Área I as métricas que constituíram as equações são relacionadas com a altura média (h_{p25}), estrato inferior da floresta (h_{p05} , h_{p10} e h_{p25}), altura

dominante (h_{\max}) e proporção de pontos acima de 1,30 m ($P_{1.3}$). Já na Área II as equações para estimar o volume foram formadas por métricas mais relacionadas com a variabilidade da altura (h_{sd} e h_{cv}) e proporção de pontos acima de 1,30 m ($P_{1.3}$).

Em contrapartida, as equações para estimar BSA tiveram configurações mais similares entre as áreas estudadas, contando com métricas relacionadas com a altura média, estrato inferior, variabilidade da altura e proporção de pontos acima de 1,30 m (h_{p25} , h_{p05} , h_{p10} , h_{sd} , h_{cv} e $P_{1.3}$) em ambas as áreas.

Os resultados obtidos para este estudo são superiores aos encontrados por Estornell *et al.* (2011) em estudo para estimar a biomassa seca de vegetação arbustiva de pequeno porte em Valência, Espanha, por meio das métricas LiDAR h_{\max} , h_{med} , h_{p80} , h_{p90} e h_{p95} de forma individual, onde obtiveram R^2 oscilando entre 0,37 a 0,48. Em contraste com o presente estudo, os autores utilizaram apenas uma variável preditiva LiDAR para compor as equações de biomassa e isso pode ter influenciado nos baixos resultados de R^2 .

Em estudos realizados em florestas homogêneas o desempenho das métricas LiDAR na estimativa do volume e da biomassa são superiores se comparados com áreas heterogêneas, como as do presente estudo. No estudo realizado por Zonete *et al.* (2010), por exemplo, os autores utilizaram métricas LiDAR para estimar variáveis de inventário, como área basal e volume de plantios clonais de eucalipto e relataram que as equações obtidas, resultaram em R^2 de 0,96 e RMSE de 0,0852 para volume e R^2 de 0,92 e RMSE de 0,1742 para área basal, utilizando densidade de pontos de retorno (1,5 pontos.m⁻²) similar ao da presente pesquisa (1,2 pontos.m⁻²).

Utilizando o algoritmo Random Forest e métricas LiDAR, Silva *et al.* (2017), desenvolveram equações para estimar a biomassa em plantios de Pinus, composta pelas variáveis h_{p99} , h_{cv} e h_{as} , a qual resultou em um R^2_{aj} de 0,98 e RMSE de 5.98%. Rex *et al.* (2019) ajustaram equações para estimar a biomassa acima do solo de *Araucaria angustifolia*, a partir das áreas de copa individuais obtidas por meio da tecnologia LiDAR, os resultados indicaram bom desempenho das equações geradas, com R^2 de 0,96 e 0,98. Ambos os estudos relatados utilizaram densidade de pontos de retornos igual a 4 pontos.m⁻², superior à densidade de pontos utilizada neste estudo.

Ioki *et al.* (2010) utilizaram métricas LiDAR de altura e densidade de copa além de índices de vegetação para modelar o volume de árvores em uma floresta subtropical na cidade de Suita no Japão. Utilizando as métricas de forma individual para prevê o volume, as melhores equações foram: a que utilizou a altura média (h_{mean} - $R^2_{aj} = 0,73$), seguido da que utilizou o percentil 50 da altura (h_{p50} - $R^2_{aj} = 0,71$). Quando as métricas foram combinadas, a melhor

previsão foi encontrada quando o percentil 75 da altura (h_{p75}) e fração apenas de vegetação (d_{OVF}) foram utilizadas como variáveis preditivas, resultando em um R^2_{aj} de aproximadamente 0,76 e um erro quadrático médio de $41,90 \text{ m}^3 \text{ ha}^{-1}$.

No estudo realizado por Wan-Mohd-Jaafar *et al.* (2017) em duas florestas em Negeri, Malaysia para estimar biomassa acima do solo, as métricas h_{p80} e largura da copa (CW) foram as que melhor se ajustaram aos dados, como evidenciado pelo valor R^2_{aj} de 0,63 e erro quadrático médio de 14,8%, resultado similar ao encontrado neste estudo.

d'Oliveira *et al.* (2012) realizaram modelagem para estimar volume e biomassa acima do solo na Floresta Estadual Antimary no Acre, a partir de regressão linear múltipla e métricas LiDAR, com densidade de pulso de 25 pulsos.m^2 . No estudo, a melhor equação para estimar volume explicou 69% da variação do volume ($R^2 = 0,69$, erro quadrático médio $30,48 \text{ m}^3.\text{ha}^{-1}$) e a melhor equação para estimar biomassa explicou 72% da variação da biomassa acima do solo ($R^2 = 0,72$, erro quadrático médio $40,20 \text{ Mg}.\text{ha}^{-1}$) e ambas as equações foram compostas pelas variáveis preditivas h_{p25} e h_{var} .

Os estudos citados evidenciam que a tecnologia LiDAR é uma ferramenta promissora para prever volume e biomassa de florestas homogêneas, entretanto, fornece resultados moderados para estimativas de variáveis biofísicas em florestas heterogêneas.

De maneira geral, os valores moderados de R^2_{aj} obtidos neste estudo, assim como os erros (S_{yx} e RMSE) podem estar relacionados à estrutura (heterogênea) e características da vegetação, bem como, a possíveis erros de precisão do MDT e a densidade de pontos dos dados LiDAR (considerada baixa neste estudo), como comprovado por Estornell *et al.* (2011) ao estudar modelos para estimar biomassa seca da vegetação arbustiva de pequeno porte em Valência, Espanha.

Nas florestas tropicais secas, como a Caatinga por exemplo, muitas das espécies arbóreas possuem uma arquitetura complexa, que perfilham ou bifurcam, gerando vários fustes tortuosos, o que dificulta o ajuste de modelos que representem bem as variáveis biofísicas dessa vegetação.

Também é importante salientar que, apesar das equações utilizadas neste estudo para estimar os estoques de volume e BSA no campo serem adequadas para uso nas áreas de estudo, a precisão das estimativas (de 2014) deve ser considerada como uma limitação deste estudo. Esta fonte de incerteza no desenvolvimento das equações em função dos dados LiDAR foi aceita devido a inexistência de uma verdade de campo (valor real) para as variáveis respostas.

O método empregado no presente estudo para a estimativa de volume e BSA em áreas de Caatinga a partir de geotecnologias tem a vantagem de ser um método não destrutivo e capaz de realizar estimativas em áreas extensas de forma prática e rápida

3.3 Distribuição espacial do volume e biomassa

Os mapas temáticos de espacialização do volume e da BSA foram gerados a partir das melhores equações para cada área estudada. As equações selecionadas foram:

Área I

$$\hat{V}_i = -6,35 + 13,51h_{p0\bar{s}_i} - 22,51h_{p1q_i} + 13,66h_{p2\bar{s}_i} + 0,15P_{1,3_i}$$

$$\hat{BSA}_i = -8,24 + 4,85h_{sd_i} + 15,66h_{p0\bar{s}_i} - 16,73h_{p1q_i} + 7,43h_{p2\bar{s}_i} + 0,20P_{1,3_i}$$

Área II

$$\hat{V}_i' = -2,31 - 6,26h_{sd_i} + 17,42h_{cv_i} + 1,05h_{p9q_i} + 0,01P_{1,3_i}$$

$$\hat{BSA}_i' = 1,97 - 1,18h_{p0\bar{s}_i} + 0,81h_{p1q_i} + 0,01P_{1,3_i}$$

Em que: ' = variável transformada, com $\lambda = 0,45$ para volume e $0,35$ para BSA.

Na figura 15 observa-se os mapas temáticos de espacialização do volume e da BSA para as áreas de estudo I e II.

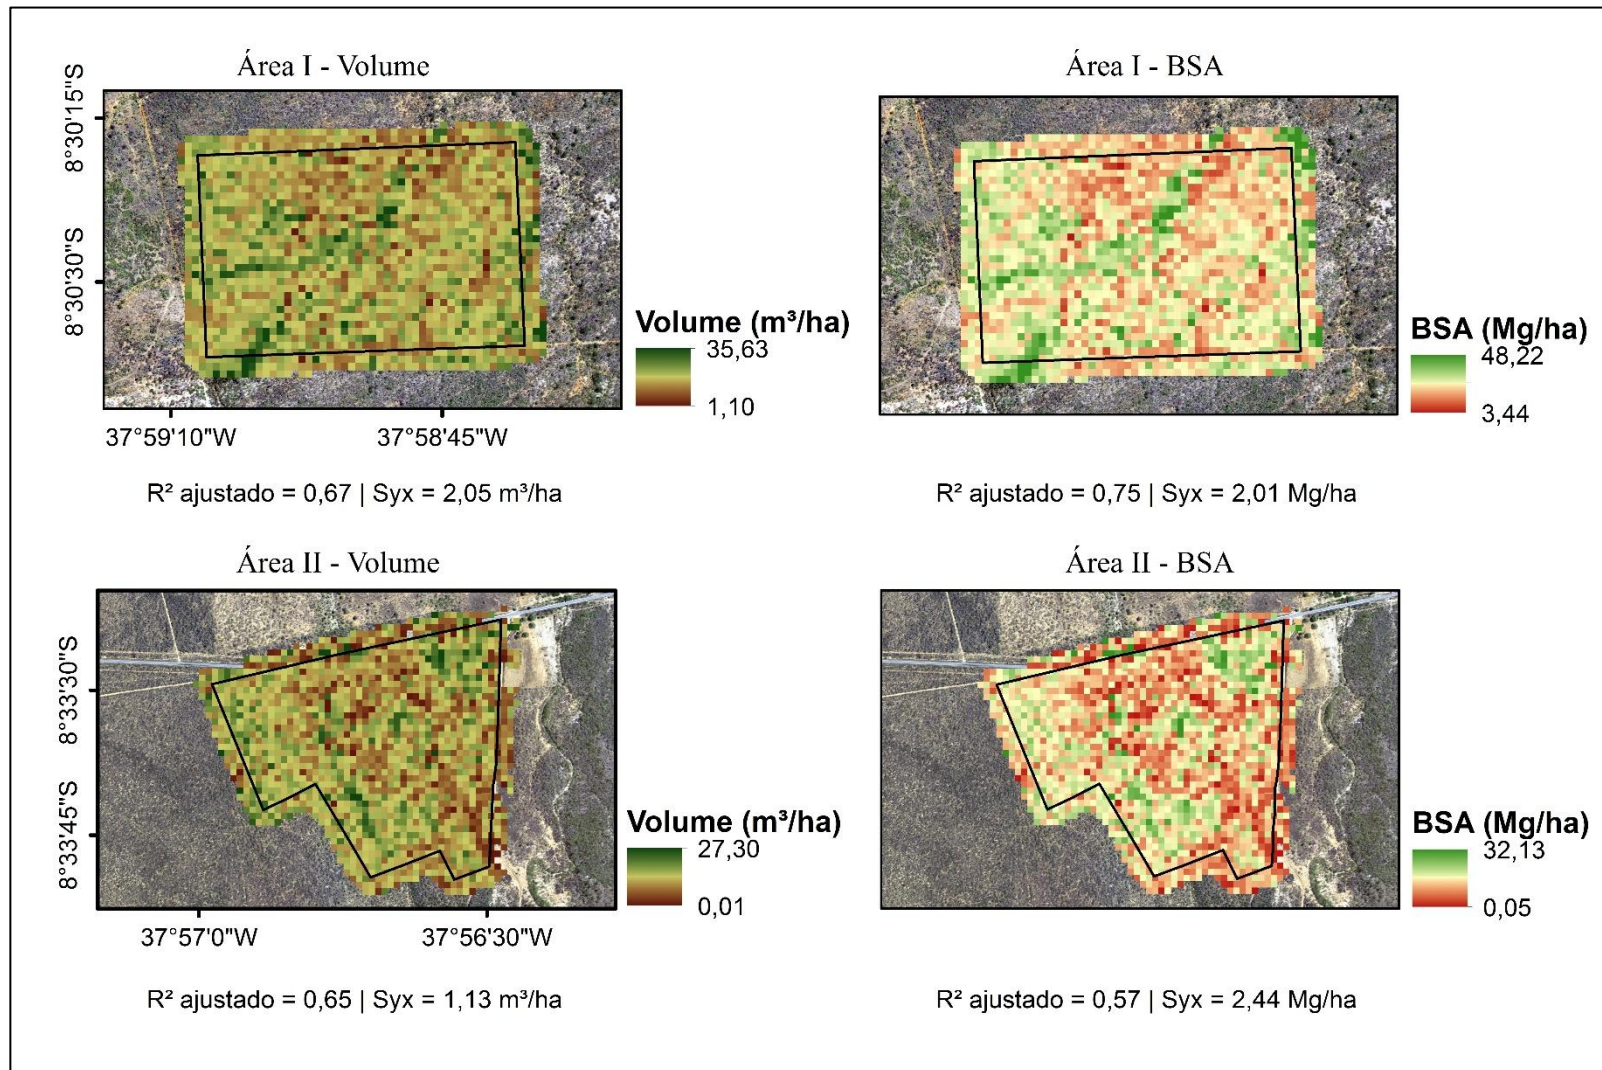


Figura 15 – Espacialização dos estoques de volume e BSA estimados com métricas LiDAR para 2014 nas áreas de estudo I e II, Floresta, PE.
Fonte: o autor.

Verificou-se que, tanto para a Área I quanto para a Área II, os valores de volume e BSA estimados e espacializados foram condizentes com o desempenho das equações, em outras palavras, no geral, as unidades amostrais com valores de volume e BSA mais elevados obtiveram valores subestimados na espacialização e as unidades amostrais com valores mais baixos foram superestimados na espacialização. Na Área I, por exemplo, os valores mais elevados de volumes observados foram identificados nas unidades amostrais 6 e 36, com 21,19 e 17,11 $\text{m}^3.\text{ha}^{-1}$, respectivamente e a equação gerou estimativas para essas unidades amostrais (valor médio dos pixels da parcela) de 17,38 e 13,76 $\text{m}^3.\text{ha}^{-1}$. Já os menores valores de volume equivalem as unidades amostrais 24 e 14, com volume observado de 1,67 e 4,54 $\text{m}^3.\text{ha}^{-1}$, respectivamente e na espacialização os valores estimados para essas unidades amostrais foram de 11,25 e 8,66, $\text{m}^3.\text{ha}^{-1}$.

4 CONCLUSÃO

As equações preditivas de volume e BSA, geradas por meio da tecnologia LiDAR, geraram valores tendenciosos comparados aos obtidos por meio do inventário florestal convencional.

Quanto à capacidade de generalização, verificada por meio da validação cruzada k-fold, as equações de volume e BSA apresentaram, em sua maioria, resultados considerados satisfatórios, registrando diferenças entre RMSE e RMSEcv baixas.

Com relação a espacialização das variáveis biofísicas estudadas, constatou-se que os valores de volume e BSA estimados e espacializados para toda a extensão das áreas I e II, a partir das melhores equações obtidas no estudo, foram condizentes com o desempenho das equações, superestimando valores menores e subestimando valores maiores de volume e BSA observados.

CAPÍTULO 2

ESTIMATIVA DE VARIÁVEIS BIOFÍSICAS EM FRAGMENTOS DE FLORESTA TROPICAL SECA POR MEIO DA INTEGRAÇÃO DE DADOS DA TECNOLOGIA LIDAR E DE SENSORES ORBITAIS

1 INTRODUÇÃO

As Florestas Tropicais Secas (FTS) em sua grande maioria são encontradas na América do Sul, seguida pela África e Índia (FAO, 2012). Do ponto de vista biológico as FTS são consideradas importantes pois abrigam uma alta complexidade e diversidade faunística e florística, resultante da heterogeneidade espacial e temporal (MILES *et al.*, 2006), além disto, fornecem uma gama de bens e serviços ecossistêmicos aos habitantes das regiões áridas e semiáridas, o que as tornam econômica e socialmente importantes (FAO, 2012).

Apesar de sua abrangência e importância, as FTS ainda são um dos ecossistemas florestais mais ameaçados do mundo (BANDA *et al.*, 2016; SILVA *et al.*, 2017), devido aos processos de desmatamento ilegal e manejo inadequado da vegetação.

O inventário florestal convencional é um importante instrumento empregado para estimar o potencial produtivo de uma área florestal e subsidiar as análises econômica e ambiental de um empreendimento voltado à exploração e conhecimento dos recursos da floresta. Entretanto, a vegetação das FTS é altamente variável no espaço e capturar toda a gama de variabilidade em amplas extensões espaciais utilizando apenas dados de campo é um desafio, além de ser caro e demorado.

Nas últimas décadas, a necessidade de quantificar os bens e serviços ecossistêmicos das áreas florestais em grandes escalas espaciais e temporais tem impulsionado o desenvolvimento de ferramentas de sensoriamento remoto aplicadas ao inventário florestal.

A predição de variáveis florestais, como a biomassa, por meio de técnicas de sensoriamento remoto é imprescindível para o monitoramento periódico e em larga escala, o que contribui para subsidiar não apenas os estudos locais, mas também os estudos regionais e globais, e proporciona resultados que servirão de apoio para tomadores de decisão de gestores (WILKIE; FINN, 1996; LIMA JÚNIOR *et al.*, 2014).

O rápido avanço das técnicas de detecção remota passiva e a disponibilidade de imagens orbitais de alta resolução espacial tem contribuído para estimar variáveis florestais com base na associação entre as propriedades espectrais (radiância/reflectância) refletidas pelos

componentes da vegetação e a variável de interesse, como biomassa (WATZLAWICK; KIRCHNER; SANGUETTA, 2009), volume e carbono.

Por outro lado, sensores remotos ativos, como é o caso da tecnologia LiDAR, proporcionam grandes ganhos para as estimativas florestais, uma vez que permitem a detecção direta da distribuição tridimensional do dossel e sub-dossel da floresta, bem como da topografia (LEFSKY *et al.*, 2002a; GORGENS; SILVA; RODRIGUEZ, 2014).

Com relação as FTS, diversos são os estudos que relacionam variáveis biofísicas da floresta com informações espectrais derivadas de sensores orbitais passivos, de diferentes resoluções espaciais (GASPARRI *et al.*, 2010; ALMEIDA *et al.*, 2014; LIMA JÚNIOR *et al.*, 2014). Entretanto, são escassos estudos que abordem o potencial da tecnologia LiDAR e da integração de geotecnologias distintas para a predição e espacialização de variáveis florestais em áreas de FTS.

Seguindo esta tendência, a utilização e a associação de produtos oriundos de sensoriamento remoto, como as imagens orbitais e dados LiDAR ALS, podem contribuir na produção de informações sólidas para áreas extensas, de forma a incrementar os dados de inventário florestal, o que dispensa ou diminui as periódicas visitas a campo, e ainda auxiliar na gestão e no manejo adequado dos recursos florestais.

Neste contexto, objetivou-se com este estudo avaliar o potencial da associação entre métricas derivadas da tecnologia LiDAR ALS e dados espectrais de diferentes sensores orbitais na predição de volume e biomassa seca acima do solo em áreas de floresta tropical seca, bem como, analisar o desempenho das equações geradas quanto a sua capacidade de generalização.

2 MATERIAL E MÉTODOS

2.1 Área de estudo

O presente trabalho foi desenvolvido em dois fragmentos florestais de Savana estépica arborizada (Área I e Área II), de aproximadamente 50 ha cada, dentro da Fazenda Itapemirim, de propriedade da empresa Agrimex Agroindustrial Excelsior S.A., localizada no município de Floresta, no estado de Pernambuco, conforme descrito na metodologia geral.

2.2 Dados utilizados

Para a realização da pesquisa foi utilizado o seguinte banco de dados:

- Estimativas de campo de volume e BSA para o ano de 2014;
- Software de estatística R[®] (R DEVELOPMENT CORE TEAM, 2017);
- Software QGIS (EQUIPE DE DESENVOLVIMENTO QGIS, 2018);
- Software FUSION (McGAUGHEY, 2020);
- Métricas da nuvem de pontos LiDAR, obtidas conforme descrito na metodologia geral e selecionadas por meio da análise da correlação de Pearson, conforme descrito no capítulo 1;
- Bandas espectrais da imagem de média resolução espacial (30 m) do satélite Landsat 8, sensor OLI, datada de 06 de fevereiro de 2015 e disponível gratuitamente no mecanismo de pesquisa Earth Explorer (<https://earthexplorer.usgs.gov/>). Para o estudo foram utilizadas apenas as bandas espectrais azul (B2), verde (B3), vermelho (B4), NIR (B5), SWIR 1 (B6) e SWIR 2 (B7), no formato GeoTIFF, projeção Universal Transversa de Mercator (UTM), Datum World Geodetic System 1984 (WGS84) e processamento Nível 1 - L1TP (Level 1 Precision Terrain Corrected), o que indica que a imagem passou pelo processamento radiométrico e geométrico (com a ortorretificação);
- Bandas espectrais da imagem de média resolução espacial (23,5 m) do satélite ResourceSat-2, sensor LISS-III, de 31 de janeiro de 2015, disponíveis, sem custos, para toda a comunidade no catálogo online do INPE (www.dgi.inpe.br/CDSR). Foram utilizadas as quatro bandas espectrais do sensor LISS III: verde (B2), vermelho (B3), NIR (B4) e SWIR (B5), com projeção UTM, Datum WGS84 e processamento Nível 2, ou seja, as imagens estão corrigidas radiométrica e geometricamente (registro);
- Bandas espectrais da imagem de alta resolução espacial (5 m) do satélite RapidEye, sensor REIS, correspondente a 28 de novembro de 2014, e disponível gratuitamente no GeoCatálogo do MMA (<http://geocatalogo.mma.gov.br/>) para pesquisas. Para o desenvolvimento do estudo foram utilizadas as cinco bandas espectrais do sensor REIS: azul (B1), verde (B2), vermelho (B3), red-edge (B4) e NIR (B5), no formato GeoTIFF, projeção UTM, Datum WGS84 e com

processamento Nível 3A, que corresponde à imagem com correção radiométrica e geométrica (com a ortorretificação). As imagens do satélite RapidEye são disponibilizadas com um empilhamento das 5 bandas. Desta forma, para a separação de bandas foi realizada com o auxílio do módulo split raster bands no QGIS.

As imagens RapidEye foram utilizadas, visando demonstrar o potencial de imagens com resolução espacial similar. A constelação RapidEye foi desativada em abril de 2020, entretanto imagens de anos anteriores ainda podem ser adquiridas pela empresa responsável, a Planet Labs Inc.

2.3 Processamento dos dados orbitais

2.3.1 Correção geométrica

Para as imagens dos satélites Landsat 8 e RapidEye não foi necessário realizar correção geométrica, visto que já são georreferenciadas e ortorretificadas. Entretanto, para a imagem do satélite Landsat 8 foi necessário realizar a reprojeção para o hemisfério Sul, uma vez que, são orientadas ao norte verdadeiro.

Embora a imagem do satélite ResourceSat-2, sensor LISS-III, sejam georreferenciadas com os dados do satélite, apresentam deslocamentos posicionais que podem ser atribuídos ao terreno. Desta forma, aplicou-se uma nova correção geométrica da imagem utilizada (registro), adotando como referência a imagens RapidEye, ortorretificada.

2.3.2 Conversão de números digitais em reflectância espectral no topo da atmosfera

As imagens de satélite são distribuídas para o público em números digitais calibrados (ND ou Q_{Cal}). Antes de realizar a correção atmosférica em uma imagem é necessário realizar conversões dos ND das imagens para valores de parâmetros físicos como radiância e posteriormente, reflectância (PONZONI; SHIMABUKURO, 2009).

Desta forma, para atender aos objetivos do presente estudo, inicialmente foi necessário transformar os ND das imagens para reflectância espectral no topo da atmosfera (reflectância TOA; sigla do inglês Top-of-atmosphere reflectance), também chamada de reflectância aparente, de acordo com os parâmetros associados a cada sensor (encontrados no arquivo de metadados das imagens).

➤ Landsat 8 – Sensor OLI

Para a imagem do satélite Landsat 8 a conversão direta de ND para reflectância TOA foi realizada para as bandas espectrais B2, B3, B4, B5, B6 e B7 do sensor OLI, de acordo com a Fórmula 1 (USGS, 2019).

$$\rho_{\lambda} = \frac{(M_p Q_{cal} + A_p)}{\cos(\theta_{sz})} \quad (1)$$

Em que: ρ_{λ} : reflectância espectral no topo da atmosfera medida ao nível do sensor (adimensional); M_p : fator de escala multiplicativo para reflectância (REFLECTANCE_MULT_BAND_n, onde n é o número da banda); A_p : fator de escala aditivo para reflectância (REFLECTANCE_ADD_BAND_n); Q_{cal} : valor quantizado do pixel calibrado da imagem de nível 1 (a banda em DN) e θ_{sz} : ângulo zenital solar local (graus).

➤ ResourceSat 2 – Sensor LISS-III

Para a imagem do satélite ResourceSat 2, as bandas B2, B3, B4 e B5 foram calibradas convertendo os ND para valores de radiância espectral (Fórmula 2) e posteriormente, para reflectância TOA (Fórmula 3).

$$L_{\lambda} = \frac{(L_{máx\lambda} - L_{mín\lambda})}{(Q_{calmáx} - Q_{calmín})} (Q_{cal} - Q_{mín}) + L_{mín\lambda} \quad (2)$$

Em que: L_{λ} : radiância espectral registrada no sensor [W/(m² sr μm)]; Q_{cal} : valor quantizado do pixel calibrado (número digital – ND); $Q_{calmín}$: mínimo valor quantizado do pixel calibrado (ND) correspondente à $L_{mín\lambda}$; $Q_{calmáx}$: máximo valor quantizado do pixel calibrado correspondente à $L_{máx\lambda}$; $L_{mín\lambda}$: radiância espectral registrada no sensor que é escalonado de acordo com o $Q_{calmín}$ [W/(m² sr μm)] e $L_{máx\lambda}$ = radiância espectral registrada no sensor que é escalonado de acordo com o $Q_{calmáx}$ [W/(m² sr μm)].

$$\rho_{\lambda} = \frac{(\pi)(L_{\lambda})(d^2)}{(ESUN_{\lambda})(\cos\theta_s)} \quad (3)$$

Em que: ρ_{λ} : reflectância espectral no topo da atmosfera registrada no sensor (reflectância TOA); π : constante matemática igual a ~ 3,14159; L_{λ} : radiância espectral registrada no sensor [W/(m² sr μm)]; d: distância entre a Terra e o Sol no dia da aquisição da imagem, em unidades astronômicas; $ESUN_{\lambda}$: irradiância solar na exoatmosfera média [W/(m² μm)] e θ_s : ângulo zenital solar, em graus (= 90° - elevação solar).

Para as bandas da imagem do sensor LISS - III os valores de irradiância solar na exoatmosfera ($ESUN_{\lambda}$) são fornecidos na Tabela 1, segundo Pandya, Murali e Kirankumar (2012).

Tabela 1 – Valores de Irradiância Solar na Exoatmosfera para as bandas do satélite ResourceSat 2.

Banda Espectral	Irradiância Solar na Exoatmosfera (W/m²μm)
Green – 2	1.850,05
Red – 3	1.588,86
Red Edge - 4	1.106,72
Infrared - 5	241,80

Fonte: Pandya, Murali e Kirankumar (2012).

➤ RapidEye – Sensor REIS

Para a imagem do satélite RapidEye, as bandas B1, B2, B3, B4 e B5 foram submetidas à conversão dos DN para radiância espectral, a qual foi obtida multiplicando o valor de DN (banda em ND) pelo valor de escala radiométrica fornecido no arquivo de metadados da imagem, conforme exibido na Fórmula 4 (BLACKBRIDGE, 2015).

$$L_{\lambda} = DN_{(i)} * \text{fator de escala radiométrica}_{(i)}$$

(4)

Em que: L_{λ} : radiância espectral registrada no sensor [W/(m² sr μm)]; $ND_{(i)}$: valor do pixel da banda i e fator de escala radiométrica: fator de escala radiométrica específico para banda i.

A partir dos valores da radiância, calculou-se a reflectância TOA, conforme a Fórmula 3, descrita anteriormente.

Para as bandas da imagem do satélite RapidEye os valores de irradiância solar na exoatmosfera ($ESUN_{\lambda}$) são fornecidos na Tabela 2, conforme Blackbridge (2015).

Tabela 2 – Valores de Irradiância Solar na Exoatmosfera para as bandas do satélite RapidEye.

Banda Espectral	Irradiância Solar na Exoatmosfera (W/m²μm)
Blue - 1	1.997,8
Green - 2	1.863,5
Red - 3	1.560,4
Red Edge - 4	1.395,0
Infrared - 5	1.124,4

Fonte: BLACKBRIDGE (2015).

2.3.3 Correção atmosférica e a obtenção da reflectância espectral da superfície

Os valores de refletância no topo da atmosfera obtidos na etapa anterior representam a resposta espectral dos alvos da superfície terrestre e da atmosfera. Desta forma, para minimizar a interferência da atmosfera nos valores de refletância foram aplicadas técnicas de correção atmosférica, obtendo-se assim, a reflectância de superfície (reflectância BOA; sigla do inglês Bottom-of-Atmosphere reflectance).

Para a correção atmosférica das imagens utilizadas foi escolhido o modelo de transferência radiativa 6S (Second Simulation of the Satellite Signal in the Solar Spectrum) desenvolvido por Vermote *et al.* (1997) e para sua aplicação foram utilizados os seguintes parâmetros de entrada: data, hora, longitude e latitude (obtidas no arquivo de metadados de cada imagem), altitude do terreno, modelo de atmosfera (tropical), modelo de aerossóis (continental), e visibilidade (25 km, padrão).

A correção atmosférica foi realizado com o auxílio do módulo i.atcorr integrado ao software QGIS.

2.3.4 Cálculo dos índices de vegetação

Após a correção atmosférica, foi possível obter os valores de reflectância de superfície e em seguida calcular os índices de vegetação.

Os índices de vegetação utilizados neste estudo foram os mais comumente usados na literatura com bons resultados para regiões semiáridas. A seguir são apresentados os índices utilizados:

➤ Razão Simples (SR – Simple Ratio): Baseado na razão entre a banda do NIR, cujos valores crescem com o aumento da vegetação e a banda do vermelho, cujos valores decrescem com o aumento da vegetação, o que o torna altamente sensível à presença de vegetação. Foi proposto por Jordan (1969) e pode ser calculado pela Fórmula 5.

$$SR = \frac{\rho_{NIR}}{\rho_{RED}} \quad (5)$$

Em que: ρ_{NIR} reflectância da banda infravermelho próximo (NIR) e ρ_{RED} = reflectância da banda vermelho (RED).

➤ Índice de vegetação por diferença normalizada (NDVI – Normalized Difference Vegetation Index): Índice padronizado que propõe eliminar diferenças sazonais do ângulo do Sol, além de minimizar os efeitos da atenuação atmosférica. Foi criado por Rouse *et al.* (1974) e pode ser obtido pela Fórmula 6.

$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \quad (6)$$

Em que: ρ_{NIR} = reflectância da banda NIR e ρ_{RED} = reflectância da banda RED.

➤ Índice de Vegetação Ajustado ao Solo (SAVI – Soil Adjusted Vegetation Index): Possui a propriedade de minimizar os efeitos da resposta do solo na resposta do dossel da vegetação ao incorporar uma constante de ajuste de solo, o fator L. Normalmente, em regiões de vegetação característica de Caatinga se utiliza o valor 0,5 para fator L, que corresponde a uma densidade vegetal intermediária. Este índice foi proposto por Huete (1988) e pode ser calculado de acordo com a Fórmula 7.

$$SAVI = 1 + L \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED} + L} \quad (7)$$

Em que: ρ_{NIR} = reflectância da banda NIR; ρ_{RED} = reflectância da banda RED e L = constante de ajuste do solo, neste caso 0,5.

➤ Índice de Vegetação Melhorado 2 (EVI2 – Enhanced Vegetation Index 2): Foi proposto para corrigir os efeitos do solo e da atmosfera (fumaça, partículas de poluição do ar e poeira), além de ser mais sensível ao sinal da vegetação com elevada biomassa. Foi desenvolvido por Jiang *et al.* (2008) e pode ser obtido por meio da Fórmula 8.

$$EVI2 = 2,5 \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + 2,4 * \rho_{RED} + 1,0} \quad (8)$$

Em que: ρ_{NIR} = reflectância da banda NIR; ρ_{RED} = reflectância da banda RED.

2.4 Estimativas das variáveis biofísicas por meio de inventário florestal

As estimativas de volume e biomassa seca acima do solo (BSA) nas Áreas I e II, por meio do inventário florestal convencional, foram realizadas para o ano de 2014, com base nas equações listadas nas Tabelas 1 e 2, na metodologia geral.

Os valores de estoque de volume ($m^3 \cdot ha^{-1}$) e BSA ($Mg \cdot ha^{-1}$) por unidade amostral, foram utilizados como referência (variável resposta) para o ajuste do modelo de regressão linear múltipla nas áreas em estudo.

2.5 Ajuste do modelo de regressão linear para estimar volume e BSA com dados LiDAR e orbitais

A lista de variáveis preditivas foi composta pelas métricas da nuvem de pontos LiDAR, obtidas conforme descrito na metodologia geral e selecionadas por meio da análise da correlação de Pearson, descrita no capítulo 1, e pelas bandas de reflectância espectral e os índices de vegetação, derivados dos diferentes sensores remotos.

Para a extração dos valores das bandas espectrais e dos índices de vegetação por unidade amostral foi utilizada uma janela espectral de tamanho 5 x 5 pixels e calculada a média aritmética dos valores dos pixels.

Os ajustes do modelo de regressão linear múltipla, pelo método dos mínimos quadrados ordinários (OLS) foram realizados a partir da integração dos dados LiDAR e os dados de um satélite específico, gerando uma equação para volume e uma para BSA para cada integração.

Inicialmente, para a construção das equações preditivas de volume e BSA, os valores médios das bandas espectrais e os índices de vegetação, por unidade amostral, passaram por uma análise exploratória, dividida em duas etapas. Na primeira etapa, aplicou-se o coeficiente de correlação linear de Pearson ($r_{x,y}$), para análise (verificação direta da matriz de correlação, Apêndice 5) e remoção de variáveis preditivas multicolineares, neste caso, com valores de $r_{x,y} > 0,9$. Para cada grupo de variáveis altamente correlacionadas (duas ou mais), apenas uma foi escolhida como candidata para o ajuste, neste caso, a variável mais correlacionada com o volume e com a BSA da amostra, excluindo-se as demais. Em um segundo momento, aplicou-se o método Stepwise no conjunto de variáveis espectrais e LiDAR, o qual seleciona as variáveis que mais contribuem na equação considerando a minimização da estatística Critério de Informação de Akaike (AIC, Akaike information criterion) (FERREIRA, 2013).

Todas as variáveis utilizadas no estudo (respostas e preditivas selecionadas) foram submetidas a uma análise descritiva, bem como, ao teste de normalidade de Shapiro-Wilk (SHAPIRO; WILK, 1965). Também foram realizados ajustes prévios do modelo de regressão linear múltiplo para a análise dos resíduos e verificação da conformidade dos pressupostos de normalidade pelo teste de Shapiro-Wilk, homocedasticidade pelo teste de Breusch-Pagan e independência pelo teste de Durbin-Watson, conforme descrito no capítulo 1.

Para a análise de outliers foi utilizado, em cada equação gerada, o teste de Bonferroni, o qual identifica observações mais extremas, com resíduos estudentizados absolutos elevados. As observações identificadas como outliers foram retiradas da amostra, uma de cada vez, e na sequência foram realizados novamente o ajuste sem a observação e o teste de outliers.

Os coeficientes que compuseram as equações foram analisados quanto a significância a um nível de 95% de probabilidade, pelo teste t de Student.

Todas as análises estatísticas dos dados foram feitas com o auxílio do software de estatística R[®] (R Development Core Team, 2017).

2.6 Avaliação das equações preditivas de volume e BSA por meio de dados LiDAR e orbitais

A avaliação das equações ajustadas para as áreas em estudo foi realizada conforme descrito na seção 2.4 do capítulo 1.

2.7 Distribuição espacial do volume e BSA

Nesta etapa, foi realizada a distribuição espacial do volume e da BSA em toda a paisagem da Área I e Área II, utilizando as melhores equações e com o auxílio da calculadora raster do software QGIS.

As funções `gridmetrics` e `csv2grid` do software FUSION foram utilizadas para auxiliar o processo de espacialização (pixel a pixel - resolução espacial de 20 metros) de cada métrica LiDAR contida nas equações finais de volume e BSA. Além das métricas LiDAR, também foram utilizadas as bandas espectrais e os índices de vegetação.

3 RESULTADOS E DISCUSSÃO

3.1 Estimativas das variáveis biofísicas por meio de inventário florestal

A partir do inventário florestal realizado no ano de 2014, nas 40 unidades amostrais da Área I e aplicação das equações descritas na metodologia geral, observou-se um estoque de volume médio de $10,14 \text{ m}^3.\text{ha}^{-1}$, com desvio padrão de $\pm 3,71 \text{ m}^3.\text{ha}^{-1}$ e BSA média de $13,66 \text{ Mg}.\text{ha}^{-1}$ com desvio padrão de $\pm 4,21 \text{ Mg}.\text{ha}^{-1}$.

Para a Área II, observou-se um volume médio de $5,57 \text{ m}^3.\text{ha}^{-1}$, com desvio padrão de $\pm 3,46 \text{ m}^3.\text{ha}^{-1}$ e BSA média de $7,78 \text{ Mg}.\text{ha}^{-1}$ com desvio padrão de $\pm 4,83 \text{ Mg}.\text{ha}^{-1}$.

A estatística descritiva e a distribuição dos estoques de volume e BSA ao longo das unidades amostrais podem ser observadas na Tabela 1 e Figura 2 e 3 do capítulo 1.

3.2 Ajuste do modelo e avaliação das equações preditivas de volume e BSA por meio de métricas LiDAR e dados orbitais

Ao analisar as matrizes de correlação linear de Pearson entre as variáveis LiDAR (Apêndice 3) e orbitais (Apêndice 5) nas duas áreas de estudo, observou-se que muitas delas foram altamente multicolineares, sendo necessário a exclusão de algumas dessas variáveis. Desta forma, foram selecionadas para a segunda etapa de seleção (Stepwise) as variáveis descritas na Tabela 3.

Tabela 3 – Variáveis selecionadas após análise da correlação linear de Pearson

Área de estudo	Origem dados utilizados	Variáveis selecionadas
Área I	LiDAR e Landsat 8	h_{\max} , h_{sd} , h_{curt} , h_{p01} , h_{p05} , h_{p10} , h_{p25} , h_{p50} , h_{p80} , $P_{1.30}$, $R_{AZ.RD}$, B2, B3, B4, B5, B6, SAVI, NDVI e SR.
	LiDAR e ResourceSat 2	h_{\max} , h_{sd} , h_{curt} , h_{p01} , h_{p05} , h_{p10} , h_{p25} , h_{p50} , h_{p80} , $P_{1.30}$, $R_{AZ.RD}$, B2, B3, SAVI, NDVI, EVI2 e SR.
	LiDAR e RapidEye	h_{\max} , h_{sd} , h_{curt} , h_{p01} , h_{p05} , h_{p10} , h_{p25} , h_{p50} , h_{p80} , $P_{1.30}$, $R_{AZ.RD}$, B1, B2, B3, B4, B5, NDVI, EVI2 e SR.
Área II	LiDAR e Landsat 8	h_{\min} , h_{\max} , h_{sd} , h_{cv} , h_{curt} , h_{p01} , h_{p05} , h_{p10} , h_{p25} , h_{p50} , h_{p90} , $P_{1.30}$, $R_{AZ.RD}$, B2, B4, B5, SAVI e SR.
	LiDAR e ResourceSat 2	h_{\min} , h_{\max} , h_{sd} , h_{cv} , h_{curt} , h_{p01} , h_{p05} , h_{p10} , h_{p25} , h_{p50} , h_{p90} , $P_{1.30}$, $R_{AZ.RD}$, B3, B4, B5, SAVI, NDVI, EVI2 e SR.
	LiDAR e RapidEye	h_{\min} , h_{\max} , h_{sd} , h_{cv} , h_{curt} , h_{p01} , h_{p05} , h_{p10} , h_{p25} , h_{p50} , h_{p90} , $P_{1.30}$, $R_{AZ.RD}$, B1, B3, B4, B5, SAVI e SR.

Na Área I, por meio do teste de Bonferroni foram identificados para as equações geradas a partir dos dados LiDAR e Landsat 8 três outliers para volume e BSA (observações 6, 24 e 38). Para as equações geradas a partir da junção dos dados LiDAR e ResourceSat 2 foram

identificados quatro outliers para volume (observações 9, 34, 36 e 38) e três outliers para BSA (observações 6, 24 e 38). Já as equações geradas a partir dos dados LiDAR e RapidEye foram identificados cinco outliers para volume (observações 6, 24, 31, 38 e 40) e cinco outliers para BSA (observações 6, 24, 31, 38 e 11). Os outliers foram removidos dos ajustes, um de cada vez, com o intuito de melhorar a precisão das equações.

Conforme observado na Tabela 4, a equação de volume obtida por meio da junção dos dados provenientes da tecnologia LiDAR e do satélite ResourceSat 2, sensor LISS, mostrou-se superior em todas as medidas de precisão avaliadas, quando comparada com as demais equações geradas para volume. Esta equação, composta pelas variáveis NDVI, h_{sd} e h_{p05} , possui a capacidade de explicar 80% da variação do volume, com erro padrão de $\pm 1,60 \text{ m}^3.\text{ha}^{-1}$, o que corresponde a um erro padrão percentual ($S_{yx\%}$) de 16,64%.

Tabela 4 – Coeficiente de determinação ajustado (R^2_{aj}), erro padrão dos resíduos (S_{yx}), raiz quadrada do erro quadrático médio (RMSE) e raiz quadrada do erro quadrático médio da validação cruzada k-fold (RMSE_{cv}) para as equações geradas para volume e BSA na Área I

	Variável resposta	Equação	R^2_{aj}	S_{yx}	RMSE	RMSE _{cv}
LiDAR + Landsat 8	\hat{V}_i ($\text{m}^3.\text{ha}^{-1}$)	$-22,22 + 77,87 B5_i + 15,03 \text{NDVI}_i + 4,03 h_{sd_i} + 4,28 h_{p01_i}$	0,68	1,76 (17,79%)	1,64	1,90
	\hat{BSA}_i ($\text{Mg}.\text{ha}^{-1}$)	$-20,14 + 135,43 B5_i + 13,50 \text{NDVI}_i - 2,20 h_{max_i} + 14,71 h_{sd_i} + 6,62 h_{p05_i} - 3,59 h_{p80_i} + 0,06 P_{1.3_i}$	0,82	1,46 (10,84%)	1,29	1,66
LiDAR + ResourceSat 2	\hat{V}_i ($\text{m}^3.\text{ha}^{-1}$)	$-44,42 + 58,98 \text{NDVI}_i + 5,24 h_{sd_i} + 5,40 h_{p05_i}$	0,80	1,60 (16,64%)	1,43	1,65
	\hat{BSA}_i ($\text{Mg}.\text{ha}^{-1}$)	$-46,12 + 90,87 \text{NDVI}_i - 14,90 \text{EVI2}_i + 0,65 h_{curt_i} - 10,69 h_{p01_i} + 11,30 h_{p05_i} - 3,96 h_{p50_i} + 3,39 h_{p80_i} + 6,21 \text{Raz.RD}_i$	0,79	1,58 (11,73%)	1,37	1,95
LiDAR + RapidEye	\hat{V}_i ($\text{m}^3.\text{ha}^{-1}$)	$-20,50 + 83,51 B5_i - 149,00 \text{EVI2}_i + 14,88 \text{SR}_i + 4,93 h_{sd_i} - 7,72 \text{RD}_i$	0,77	1,61 (16,83%)	1,47	1,81
	\hat{BSA}_i ($\text{Mg}.\text{ha}^{-1}$)	$-23,64 + 106,77 B5_i + 16,01 \text{NDVI}_i - 155,88 \text{EVI2}_i + 9,59 \text{SR}_i + 1,57 h_{p80_i} + 0,11 P_{1.3_i}$	0,81	1,91 (14,10%)	1,71	2,14

S_{yx} , RMSE e RMSE_{cv} expressos em $\text{m}^3.\text{ha}^{-1}$ para o volume (V) e em $\text{Mg}.\text{ha}^{-1}$ para biomassa seca acima do solo (BSA).

Com relação as equações para a estimativa da BSA, verificou-se que a equação em função dos dados oriundos da tecnologia LiDAR e do Landsat 8, sensor OLI, obteve os melhores resultados em todas as medidas de precisão avaliadas, atingindo um R^2_{aj} de 0,82, com erro padrão de $\pm 1,46 \text{ Mg}.\text{ha}^{-1}$, o que corresponde a um erro padrão percentual de 10,84%.

Quanto a capacidade de generalização das melhores equações (volume e BSA) da Área I, analisada por meio da validação cruzada k-fold, constatou-se que os valores de RMSE_{cv} ($1,65 \text{ m}^3.\text{ha}^{-1}$; $1,66 \text{ Mg}.\text{ha}^{-1}$) foram ligeiramente maiores que os RMSE das equações geradas ($1,43 \text{ m}^3.\text{ha}^{-1}$; $1,29 \text{ Mg}.\text{ha}^{-1}$).

Os resultados obtidos pelos testes de Shapiro-Wilk, Breusch-Pagan e Durbin-Watson, indicaram que em todas as equações preditivas de volume e BSA para a Área I não houve a

violação dos pressupostos da normalidade, homocedasticidade e independência dos resíduos. Também não foi identificado, pelo fator de inflação de variação (VIF), multicolinearidade nas equações geradas.

A distribuição dos resíduos padronizados, bem como, a relação entre a variável observada versus a predita pelas equações ajustadas e pela validação cruzada podem ser observadas nas Figuras 1 a 6.

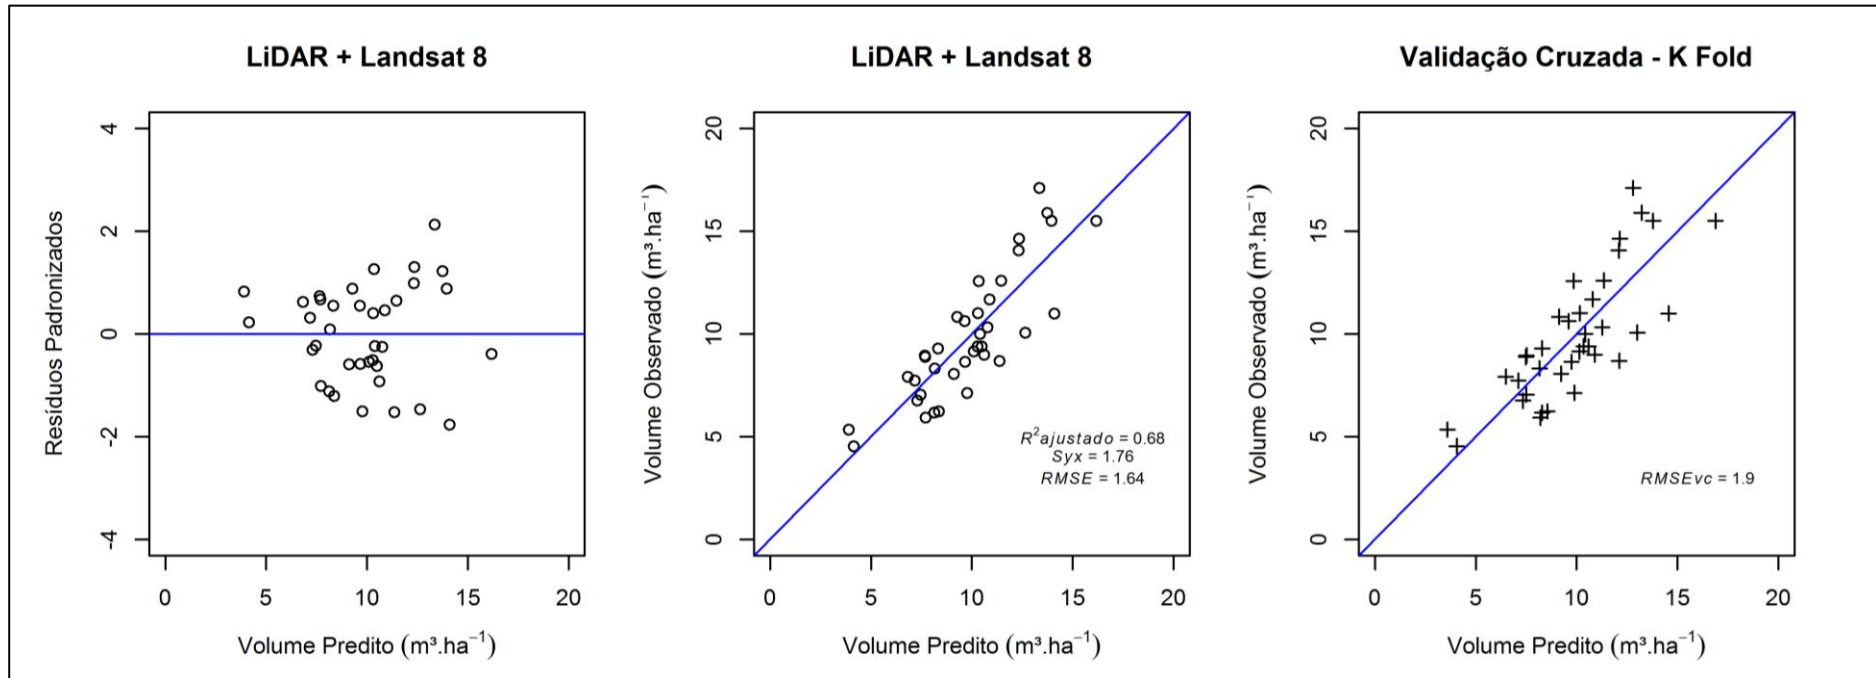


Figura 1 – Gráfico de resíduos padronizados versus volume predito, relação do volume predito versus o observado (N=37) e validação cruzada da equação gerada a partir de dados LiDAR e do satélite Landsat 8. A linha indica a relação de 1:1. **Fonte:** o autor.




Figura 2 – Gráfico de resíduos padronizados versus volume predito, relação do volume predito versus o observado (N=36) e validação cruzada da equação gerada a partir de dados LiDAR e do satélite ResourceSat 2. A linha indica a relação de 1:1. **Fonte:** o autor.




Figura 3 – Gráfico de resíduos padronizados versus volume predito, relação do volume predito versus o observado (N=35) e validação cruzada da equação gerada a partir de dados LiDAR e do satélite RapidEye. A linha indica a relação de 1:1. **Fonte:** o autor.

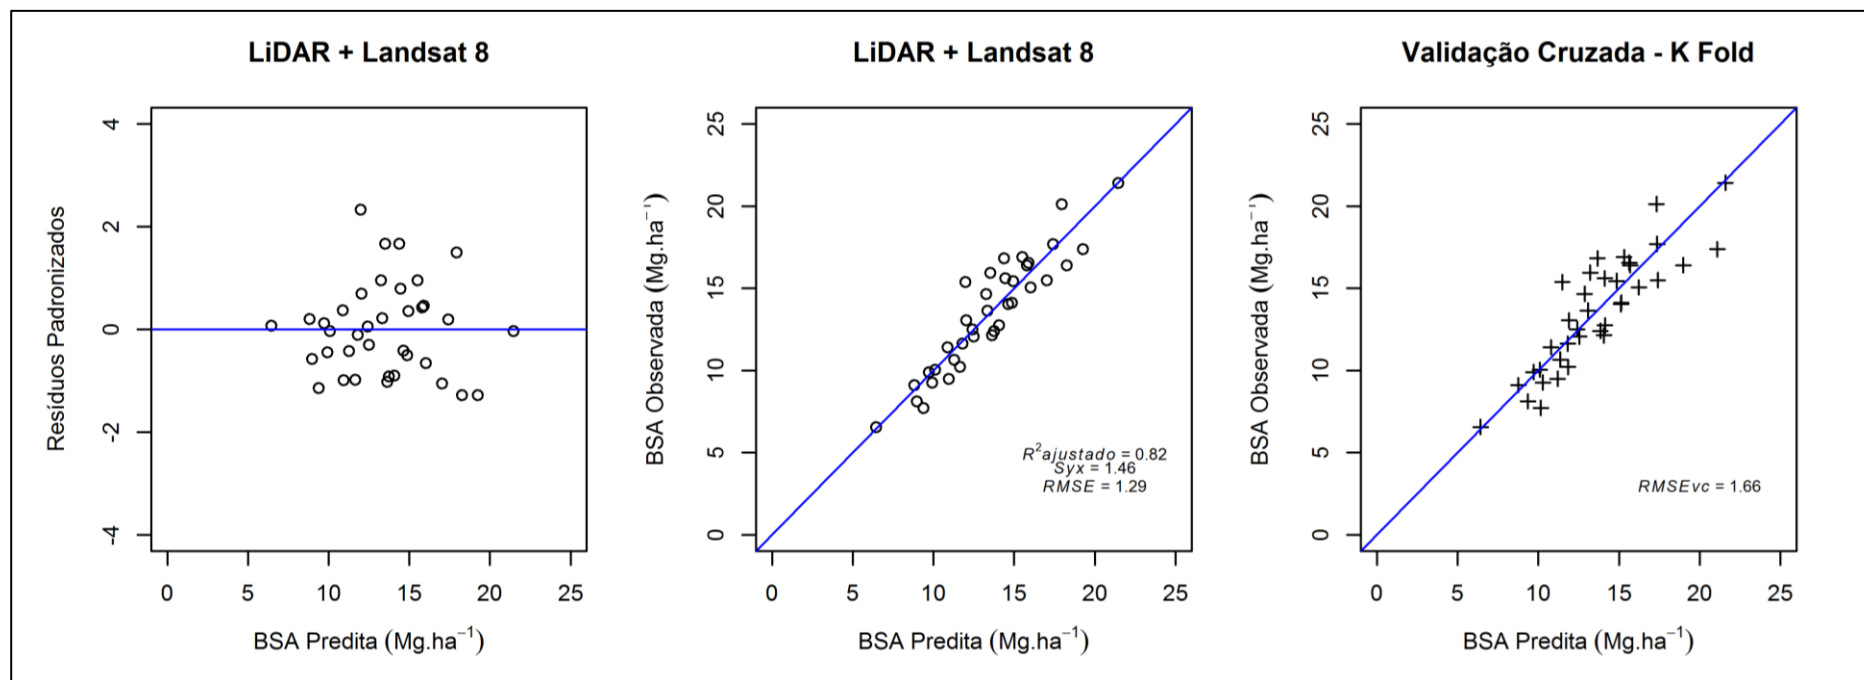


Figura 4 – Gráfico de resíduos padronizados versus BSA predita, relação da BSA predita versus a observada (N=37) e validação cruzada da equação gerada a partir de dados LiDAR e Landsat 8. A linha indica a relação de 1:1. **Fonte:** o autor.




Figura 5 – Gráfico de resíduos padronizados versus BSA predita, relação da BSA predita versus a observada (N=37) e validação cruzada da equação gerada a partir de dados LiDAR e do satélite ResourceSat. A linha indica a relação de 1:1. **Fonte:** o autor.




Figura 6 – Gráfico de resíduos padronizados versus BSA predita, relação da BSA predita versus a observada (N=35) e validação cruzada da equação gerada a partir de dados LiDAR e do satélite RapidEye. A linha indica a relação de 1:1. **Fonte:** o autor.

Na Figura 7 é possível observar a relação gráfica dos resíduos padronizados versus a variável resposta observada das equações obtidas para a Área I. Verificou-se que, todas as equações apresentaram tendências de superestimar valores mais baixos e subestimar valores mais altos.

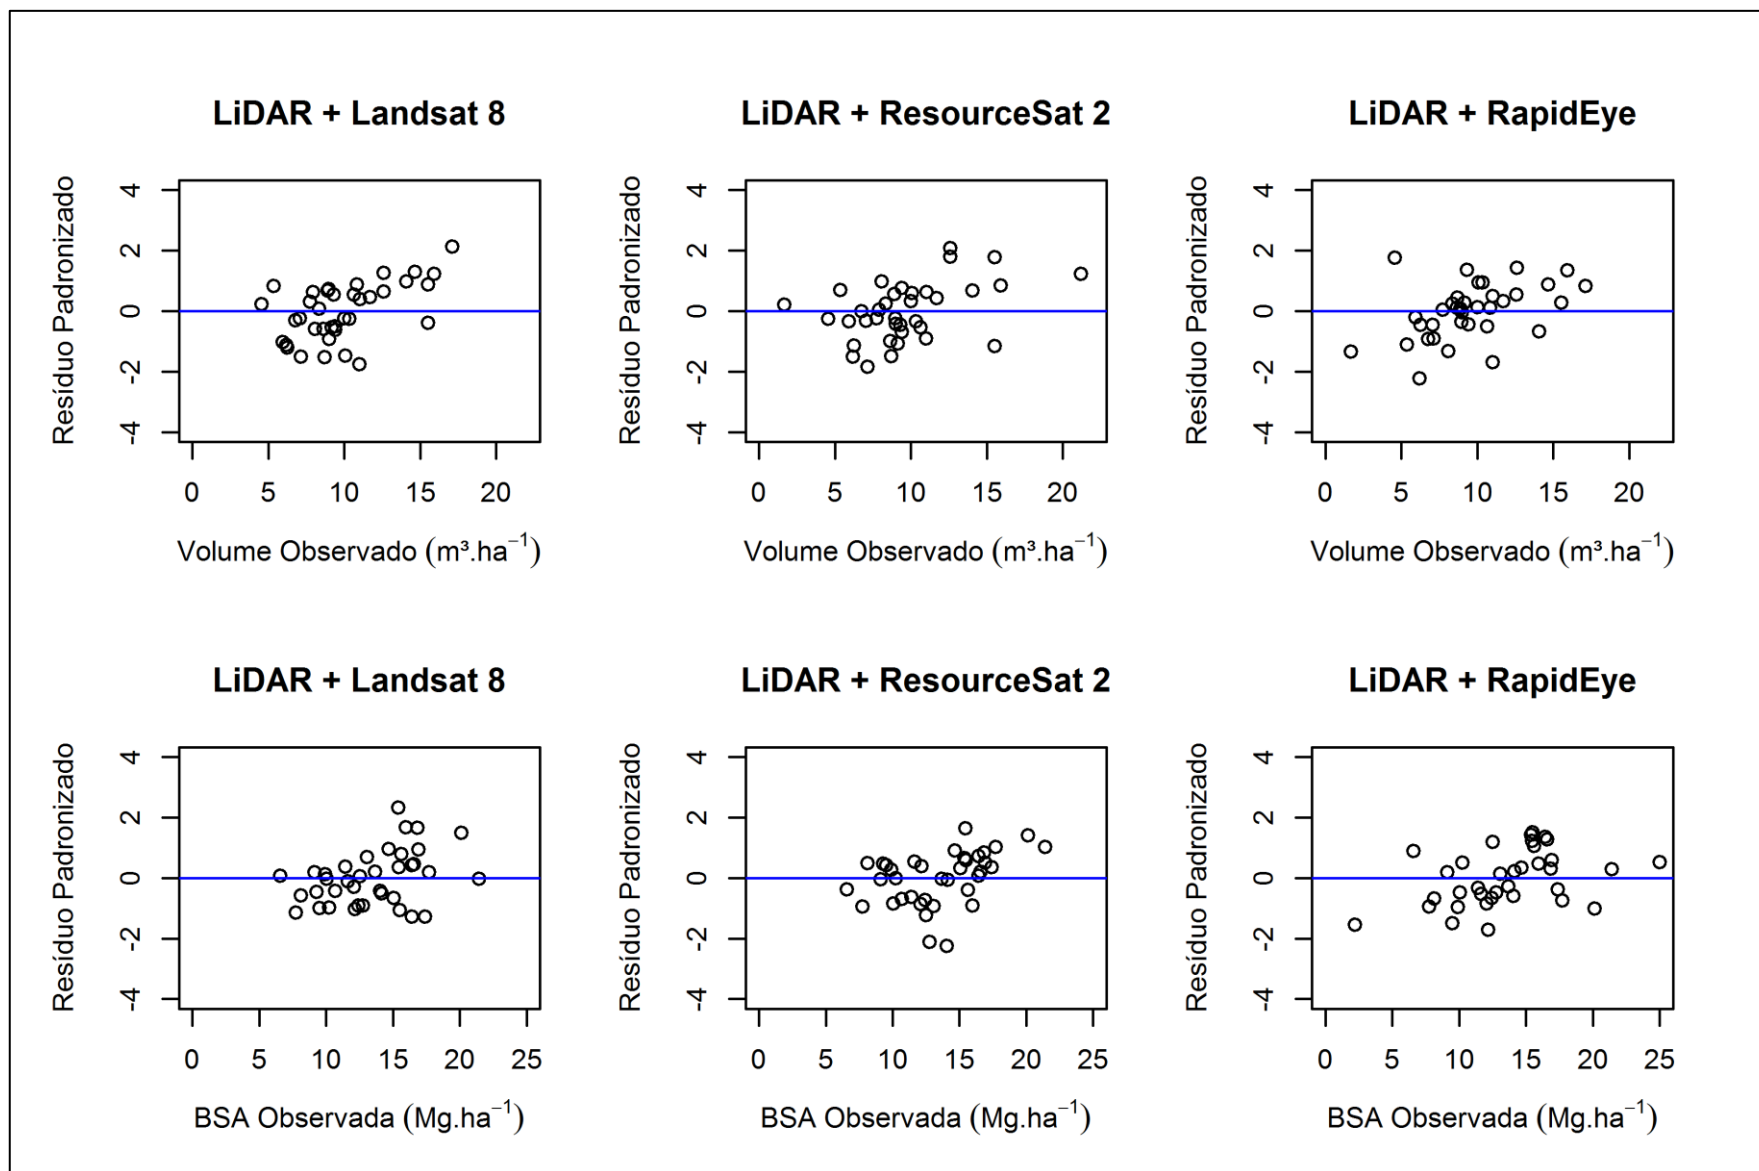


Figura 7 – Gráficos de resíduos padronizados versus variável resposta observada das equações geradas para a Área I. **Fonte:** o autor.

Na Área II, por meio do teste de Bonferroni foram identificados, para as equações geradas a partir dos dados LiDAR e Landsat 8, cinco outliers para volume (observações 15, 17, 27, 31 e 37) e cinco para BSA (observações 15, 11, 27, 37 e 38). Para as equações geradas a partir da junção dos dados LiDAR e ResourceSat 2 foram identificados quatro outliers para volume (observações 15, 17, 27, 31 e 37) e dois para BSA (observações 15 e 37). Já as equações geradas a partir dos dados LiDAR e RapidEye foram identificados cinco outliers para volume (observações 15, 17, 27, 31 e 37) e dois outliers para BSA (observações 15 e 37). Os outliers foram removidos dos ajustes, um de cada vez, com o intuito de melhorar a precisão das equações.

Com relação as equações para a estimativa do volume para a Área II (Tabela 5), verificou-se que a melhor equação foi a proveniente da junção entre os dados LiDAR e ResourceSat 2, composta pelas variáveis NDVI, SR, h_{sd} , h_{cv} , h_{p90} e $P_{1.3}$, as quais possuem a capacidade de explicar 70 % da variação do volume, com um erro padrão de $\pm 1,06 \text{ m}^3.\text{ha}^{-1}$ ($S_{yx\%} = 21,08\%$). Esta equação apresentou os melhores resultados em todas as medidas de precisão avaliadas, quando comparado com as demais equações ajustadas para volume.

Tabela 5 – Coeficiente de determinação ajustado (R^2_{aj}), erro padrão dos resíduos (S_{yx}), raiz quadrada do erro quadrático médio (RMSE) e raiz quadrada do erro quadrático médio da validação cruzada k fold (RMSE_{cv}) para as equações geradas para volume e BSA na Área II

	Variável resposta	Equação	R^2_{aj}	S_{yx}	RMSE	RMSE _{cv}
LiDAR + Landsat 8	\hat{V}_i ($\text{m}^3.\text{ha}^{-1}$)	$-17,82 - 1,68 B5_i - 33,34 h_{sdi} + 92,66 h_{cvi} + 5,60 h_{p90i} + 0,07 P_{1.3i}$	0,63	1,16 (23,07%)	1,06	1,27
	\hat{BSA}_i ($\text{Mg}.\text{ha}^{-1}$)	$-61,35 + 2,34 SR - 71,74 h_{sd} + 258,68 h_{cv} + 17,45 h_{p25} + 0,16 P_{1.3}$	0,77	1,96 (26,18%)	1,78	2,18
LiDAR + ResourceSat 2	\hat{V}_i ($\text{m}^3.\text{ha}^{-1}$)	$-31,60 + 25,58 NDVI_i - 1,16 SR_i - 39,26 h_{sdi} + 105,81 h_{cvi} + 6,59 h_{p90i} + 0,06 P_{1.3i}$	0,70	1,06 (21,08%)	0,95	1,15
	\hat{BSA}_i ($\text{Mg}.\text{ha}^{-1}$)	$-26,42 + 83,63 B3_i - 42,31 B5_i + 37,50 NDVI_i + 10,52 h_{mini} - 35,11 h_{sdi} + 126,73 h_{cvi} - 11,12 h_{p01i} + 9,99 h_{p25i} + 0,11 P_{1.3i}$	0,82	1,77 (23,51%)	1,52	1,95
LiDAR + RapidEye	\hat{V}_i ($\text{m}^3.\text{ha}^{-1}$)	$-25,75 + 149,42 B3_i - 120,48 B4_i + 5,08 SR_i - 33,50 h_{sdi} + 93,05 h_{cvi} + 5,38 h_{p90i} + 0,07 P_{1.3i}$	0,68	1,08 (21,48%)	0,95	1,22
	\hat{BSA}_i ($\text{Mg}.\text{ha}^{-1}$)	$-83,39 + 443,17 B3_i - 268,25 B5_i + 26,73 SR_i - 48,11 h_{sdi} + 186,74 h_{cvi} + 11,77 h_{p25i} + 0,17 P_{1.3i}$	0,78	1,93 (25,63%)	1,71	2,13

S_{yx} , RMSE e RMSE_{cv} obtido para os dados na escala natural, ou seja, expressos em $\text{m}^3.\text{ha}^{-1}$ para o volume (V) e em $\text{Mg}.\text{ha}^{-1}$ para biomassa seca acima do solo (BSA).

Para a predição da BSA da Área II a equação oriunda dos dados LiDAR e ResourceSat 2, em função das variáveis B3, B5, NDVI, h_{min} , h_{sd} , h_{cv} , h_{p01} , h_{p25} e $P_{1.3}$, mostrou-se ligeiramente superior, com melhores resultados em quase todas as medidas de precisão, e com a capacidade de explicar 82% da variação da BSA, com erro padrão de $\pm 1,77 \text{ Mg}.\text{ha}^{-1}$ ($S_{yx\%} = 23,51\%$).

Quanto a capacidade de generalização das equações de volume e BSA da Área II, expressa pelo RMSEcv obtido na validação cruzada, foi possível observar que todas as equações apresentaram RMSEcv levemente superiores, com diferença entre RMSE e RMSEcv variando de 0,20 a 0,27 m³.ha⁻¹ para volume e 0,40 a 0,43 Mg.ha⁻¹ para BSA.

Assim como nas equações para a Área I, a normalidade, homocedasticidade e independência dos resíduos das equações geradas na Área II não foram rejeitadas pelos testes de Shapiro-Wilk, Breusch-Pagan e Durbin-Watson. O fator de inflação de variação (VIF), não identificou multicolinearidade nas equações obtidas.

A distribuição dos resíduos padronizados, a relação entre a variável observada versus a predita pelas equações ajustadas e pela validação cruzada podem ser observadas nas Figuras 8 a 13.




Figura 8 – Gráfico de resíduos padronizados versus volume predito, relação do volume predito versus o observado (N=35) e validação cruzada da equação gerada a partir de dados LiDAR e do satélite Landsat 8. A linha indica a relação de 1:1. **Fonte:** o autor.




Figura 9 – Gráfico de resíduos padronizados versus volume predito, relação do volume predito versus o observado (N=35) e validação cruzada da equação gerada a partir de dados LiDAR e do satélite ResourceSat 2. A linha indica a relação de 1:1. **Fonte:** o autor.

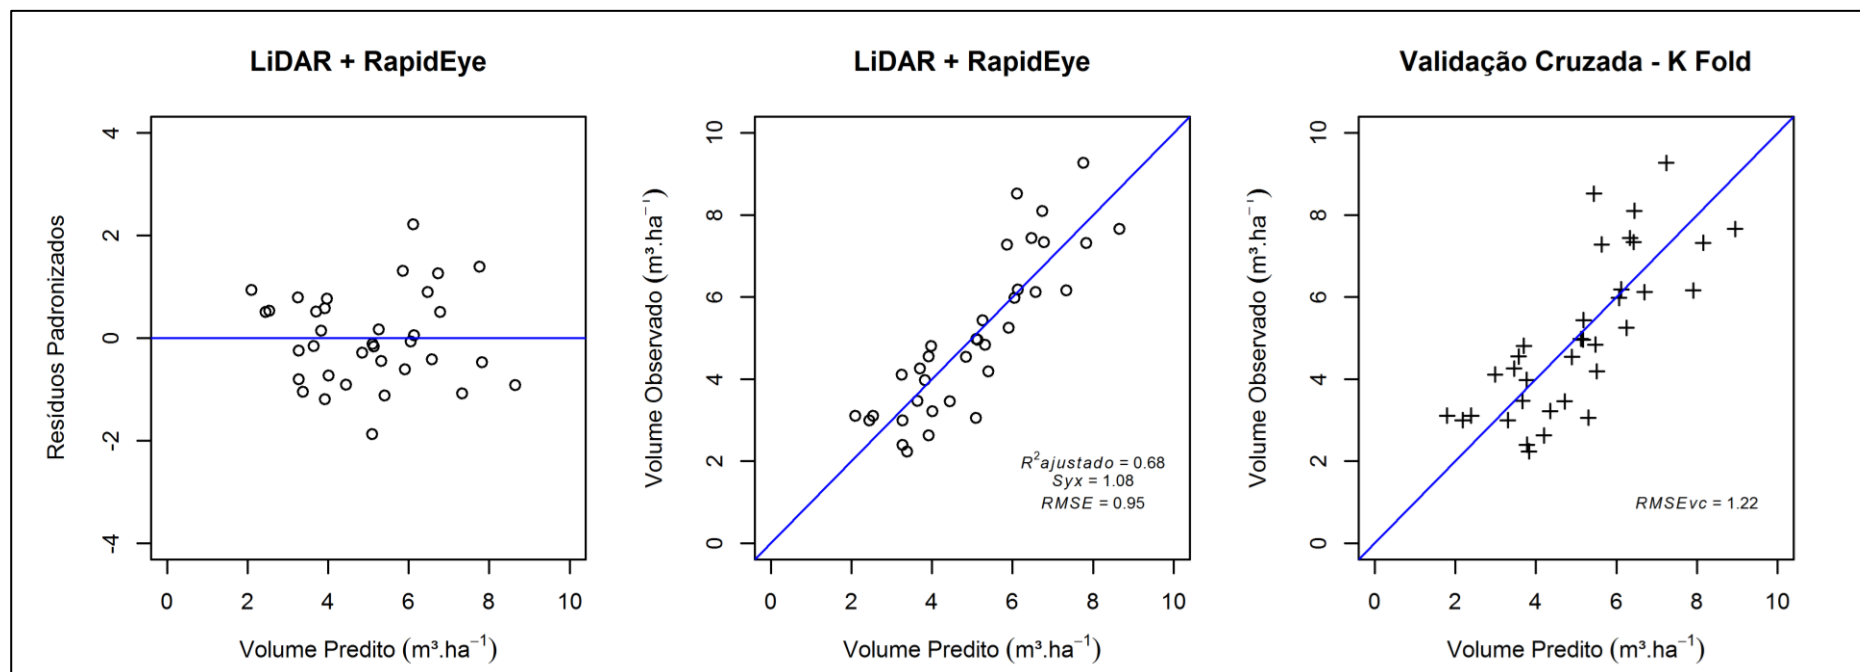


Figura 10 – Gráfico de resíduos padronizados versus volume predito, relação do volume predito versus o observado (N=35) e validação cruzada da equação gerada a partir de dados LiDAR e do satélite RapidEye. A linha indica a relação de 1:1. **Fonte:** o autor.




Figura 11 – Gráfico de resíduos padronizados versus BSA predita, relação da BSA predita versus a observada (N=35) e validação cruzada da equação gerada a partir de dados LiDAR e do satélite Landsat 8. A linha indica a relação de 1:1. **Fonte:** o autor.




Figura 12 – Gráfico de resíduos padronizados versus BSA predita, relação da BSA predita versus a observada (N=38) e validação cruzada da equação gerada a partir de dados LiDAR e do satélite ResourceSat 2. A linha indica a relação de 1:1. **Fonte:** o autor.




Figura 13 – Gráfico de resíduos padronizados versus BSA predita, relação da BSA predita versus a observada (N=38) e validação cruzada da equação gerada a partir de dados LiDAR e do satélite RapidEye. A linha indica a relação de 1:1. **Fonte:** o autor.

Na Figura 14 é possível verificar, na área II, que tanto para volume como para BSA, as equações geradas não foram capazes de reproduzir os valores reais, mostrando tendência de superestimar valores mais baixos e subestimar valores mais altos, assim como as equações da Área I.




Figura 14 – Gráficos de resíduos padronizados versus variável resposta observada das equações geradas para a Área II. **Fonte:** o autor.

As equações geradas para prever o volume e a BSA da Área I apresentaram resultados superiores nas medidas de precisão R^2_{aj} , S_{yx} , $S_{yx\%}$ e RMSE se comparadas as equações de volume e BSA geradas para a Área II, o que pode estar relacionado com a menor variabilidade das variáveis respostas da Área I, área que não possui histórico de perturbações antrópicas tão intensas quanto a Área II.

As métricas LiDAR de dispersão, h_{sd} que está presente em dez equações das doze equações geradas neste estudo e h_{cv} que participou de seis equações, expressam a variabilidade e a estrutura do dossel da floresta. Em florestas naturais com o dossel mais aberto, e consequentemente com a altura do dossel altamente variável, como é o caso das áreas em estudo, as métricas LiDAR relacionadas com a variabilidade são frequentemente usadas e indicadas para a modelagem de atributos biofísicos da floresta (ESTORNELL *et al.*, 2011; d'OLIVEIRA *et al.*, 2012).

Com relação a variável $P_{1,3}$, foi possível verificar que a mesma obteve os maiores valores de correlação com as variáveis respostas volume e BSA para a Área II, com $r_{x,y} = 0,68$ para volume e 0,72 para BSA (Apêndice 3), o que justifica sua presença nas seis equações ajustadas para a Área II. A variável $P_{1,3}$ também está presente em duas equações da Área I.

Quanto à variável h_{p25} , presente em três equações da Área II, verificou-se a presença de forte correlação com a variável h_{med} da Área II ($r_{x,y} = 0,92$), a qual, em se tratando de dados LiDAR, pode ser considerada como uma métrica apropriada para representar o comportamento vertical de florestas heterogêneas, como as FTS, ao contrário do que se vê em estudos realizados em plantios homogêneos, como de *Pinus* sp. e *Eucalyptus* sp. nos quais as métricas LiDAR h_{max} , h_{p90} , h_{p95} e h_{p99} são as mais representativas da estrutura vertical do plantio e são fortes candidatas a compor equações para estimar atributos biofísicos da vegetação (SILVA, *et al.*, 2014; SILVA *et al.*, 2016; SILVA *et al.*, 2017). Desta forma, a presença da variável h_{p25} nas equações da Área II deste estudo já era esperada, uma vez que a h_{med} foi retirada da modelagem por possuir alta correlação com grande parte das variáveis de percentis.

As métricas de percentis mais baixos comumente estão relacionados com o estrato inferior da floresta, o sub-bosque, e de acordo com Gorgens, Silva e Rodriguez (2014), podem estar capturando variações da estrutura horizontal da floresta como a área basal, o que pode explicar a presença das variáveis h_{p01} e h_{p05} em equações da Área I e h_{p01} e h_{p25} em equações da Área II, visto que a área basal apresenta forte correlação com a biomassa e com o volume florestal (HUSCH *et al.*, 1963; SCOLFORO, 2006; BATISTA; COUTO; SILVA FILHO, 2014).

Métricas LiDAR que caracterizam a altura dominante do dossel (h_{\max} , h_{p90} , h_{p80}) também fizeram parte das equações em ambas as áreas em estudo.

Com relação às variáveis oriundas das imagens orbitais, observa-se que as bandas correspondentes ao vermelho (B4 para o satélite Landsat 8 e B3 para os satélites RapidEye e ResourceSat 2) e ao NIR (B5 para os satélites Landsat 8 e RapidEye e B4 para o satélite ResourceSat 2) estiveram presentes em três e seis das equações ajustadas no estudo, respectivamente, o que já era esperado, visto que o comportamento espectral da folha nestas faixas espectrais é bem característico, o que as tornam as faixas espectrais mais utilizadas em estudos de vegetação.

Considerando uma folha isolada, a reflectância na faixa do vermelho, apresenta baixos valores em virtude da absorção da radiação eletromagnética por pigmentos presentes nas células do mesófilo, como a clorofila, a xantofila e o caroteno, já na faixa do NIR ocorre alta reflectância devido a influência da estrutura celular da folha (MENEZES; ALMEIDA; BAPTISTA, 2019). Com relação a dosséis florestais a variação da reflectância nas faixas do vermelho e do NIR dependem da arquitetura do dossel e da quantidade de folhas, mas de forma geral, a curva espectral é bem similar à de uma folha isolada (PONZONI; SHIMABUKURO; KUPLICH, 2012).

No presente estudo, verificou-se que para a Área II a correlação de Pearson entre as bandas vermelho e NIR com as variáveis respostas (volume e BSA) foram mais baixas se comparadas com as da Área I (Apêndice 5). Isto pode estar relacionado ao fato de que a Área II possui dossel mais esparsos devido as intensas perturbações antrópicas sofridas na área, o que ocasiona a interferência da reflectância do solo exposto que se soma à do dossel, o que altera os valores de reflectância da vegetação (MENEZES; ALMEIDA; BAPTISTA, 2019). Outros fatores como, tecido vegetal não fotossintético, componentes herbáceos e gramíneos, formados no início da estação chuvosa (época de aquisição das imagens), disponibilidade de água no solo e na superfície das folhas também podem alterar a reflectância do dossel florestal nas bandas analisadas.

Quanto aos índices de vegetação, observou-se que o NDVI foi o índice que mais esteve presente nas equações ajustadas, sendo sete no total (cinco na Área I), seguido pelo SR, presente em seis equações (quatro foram na Área II) e do EVI2 que integrou 3 equações na Área I. O SAVI foi o único índice que não integrou nenhuma das equações ajustadas.

De forma geral, os índices de vegetação estão associados a parâmetros biofísicos da vegetação, e são eficazes em detectar mudanças na quantidade de biomassa verde, conteúdo de clorofila e estresse hídrico a nível de dossel, além de minimizar os efeitos da topografia,

geometria de aquisição e iluminação da cena, que são fatores que influem nos valores de reflectância da vegetação nas faixas espectrais (PONZONI; SHIMABUKURO; KUPLICH, 2012), o que explica a presença dos índices de vegetação em onze das doze equações ajustadas no estudo.

Esperava-se que os índices de vegetação SAVI e EVI2 fizessem parte das equações geradas para a Área II (dossel esparso), uma vez que são indicados para minimizar a influência do solo sobre a resposta espectral do dossel da floresta. Todavia, mesmo apresentando, na maioria dos casos, correlação de Pearson razoável com as variáveis respostas analisadas da Área II (Apêndice 5), tanto o SAVI quanto o EVI2 não foram eficientes na modelagem. Este resultado pode estar relacionado com o início do período chuvoso (época de aquisição das imagens), o qual influencia na formação de biomassa herbácea e gramínea, recobrando o solo, antes exposto no período em que as chuvas não são frequentes, ou até mesmo nulas, e neste caso, índices de vegetação como o NDVI e o SR (presentes nas equações geradas para a Área II) são influenciados positivamente, como pode ser observado nas correlações de Pearson com as variáveis respostas (Apêndice 5).

Estudos orbitais em áreas de caatinga arbórea, com data da coleta da imagem realizada no período de chuvas, índices de vegetação como o NDVI podem ser usado sem prejuízos maiores, como no caso do solo exposto (DIODATO *et al.* 2021).

Observa-se que houve uma distinção na configuração das equações de volume das áreas estudadas. Na Área I as variáveis que constituíram as equações são relacionadas com a variabilidade do dossel (h_{sd}), estrato inferior da floresta (h_{p01} e h_{p05}), além de dados espectrais e índices de vegetação (B5, NDVI, EVI2 e SR). Já na Área II as equações para estimar o volume foram formadas por métricas mais relacionadas com a altura dominante (h_{p90}), variabilidade do dossel (h_{sd} e h_{cv}), proporção de pontos acima de 1,30 m ($P_{1.3}$) e dados espectrais e índices de vegetação (B3, B4, B5, NDVI e SR).

As equações de BSA também apresentaram distinção entre as áreas estudadas. Na Área I as variáveis que constituíram as equações são relacionadas com o estrato inferior da floresta (h_{p01} e h_{p05}), altura dominante (h_{max} e h_{p80}), proporção de pontos acima de 1,30 m ($P_{1.3}$), além de dados espectrais e índices de vegetação (B5, NDVI, EVI2 e SR). Na Área II as equações para estimar a BSA foram compostas por métricas mais relacionadas com a variabilidade do dossel (h_{sd} e h_{cv}), estrato inferior da floresta (h_{p01} e h_{p25}), proporção de pontos acima de 1,30 m ($P_{1.3}$) e dados espectrais e índices de vegetação (B3, B5, NDVI e SR).

Com relação a utilização de dados orbitais com diferentes resoluções espaciais na predição dos estoques de volume e BSA, observou-se que o melhor resultado foi encontrado

com a junção dos dados LiDAR com dados oriundo de imagens do satélite ResourceSat 2 (sensor LISS III), com resolução espacial de 23,5 m. Das quatro equações geradas com dados provenientes desta junção, três foram consideradas as melhores equações do estudo, duas na Área II, com erro padrão percentual de 21,08 % para o volume e 23,51 % para a BSA, e uma na Área I, com $S_{yx\%}$ de 16,64 % para o volume.

Também foi possível verificar que a junção LiDAR e dados do satélite Landsat 8 (sensor OLI), com média de resolução espacial (30 m), originou a melhor equação para BSA da Área I, com R^2_{aj} de 0,82 e $S_{yx\%}$ de 10,84 %. Resultado similar foi encontrado por Pandit, Tsuyuki e Dube (2018) que utilizaram o algoritmo Random Forest e dados do sensor Multi-espectral (MSI), do satélite Sentinel-2 de média resolução espacial, para estimar a biomassa acima do solo na zona de amortecimento do Parque Nacional Parsa, Nepal e relataram que a melhor equação ajustada, composta por 18 variáveis preditivas, foi capaz de explicar 81% da variação da biomassa, com um RMSE% de 15,44%.

Ao contrário do que se esperava, as equações geradas a partir dos dados LiDAR em conjunto com dados do satélite RapidEye, (sensor REIS), com alta resolução espacial (5 m), não foram superiores às equações geradas com a junção de dados LiDAR e de satélites com resolução espacial média. Este resultado pode ter sofrido influência da época de aquisição da imagem do satélite RapidEye, dia 28 de novembro de 2014, que, como pode ser observado na imagem 12 da metodologia geral, foi o início da estação chuvosa entre os anos de 2014 e 2015. A chuva do referido mês se deu entre os dias 17, 19 e 20, bem próximos da data de aquisição da imagem, o que talvez não tenha sido tempo suficiente para a vegetação responder à umidade do solo. Já a aquisição das imagens dos satélites Landsat 8 e ResourceSat 2, foi em as datas (janeiro e fevereiro de 2015) onde a vegetação teve tempo suficiente para responder à precipitação ocorridas nos meses anteriores.

Resultados semelhantes foram encontrados por Macedo *et al.* (2017) que, por meio de índices de vegetação oriundos de bandas espectrais do satélite Pléiades de alta resolução espacial (0,5 m), estimaram o volume em plantios de *Eucalyptus* sp. e relataram resultados de R^2_{aj} oscilando entre 0,53 a 0,74 e Motlagh *et al.* (2018) que ao utilizarem índices de vegetação calculados a partir das bandas espectrais do satélite SPOT-6 (de alta resolução espacial, 6 m) para estimar a biomassa acima do solo em fragmentos florestais ao Norte do Iran, relataram a obtenção de um R^2_{aj} máximo de 0,62. Entretanto, ao contrário do presente estudo, os autores das pesquisas citadas utilizaram apenas uma variável preditiva (índice de vegetação) em cada equação ajustada, o que pode justificar os resultados moderados de R^2_{aj} mesmo com dados orbitais de alta resolução espacial.

O estudo desenvolvido por Nguyen e Kappas (2020) também corroboram com os resultados encontrados na presente pesquisa, pois ao utilizar dados espectrais e índices de vegetação oriundo do satélite SPOT-6 com alta resolução espacial (6 m) para estimar a biomassa acima do solo na Reserva Natural de Xuan Lien, Vietnã, obtiveram para a melhor equação ajustada um R^2_{aj} de 0,74, com RMSE de 61,24 Mg.ha⁻¹.

Contudo, é conveniente salientar que as equações geradas com a integração dos dados LiDAR e dados orbitais do RapidEye também apresentaram bons resultados.

Os resultados encontrados nesta pesquisa são superiores a outros trabalhos realizados em florestas tropicais secas, que utilizaram apenas dados orbitais, como os desenvolvidos por: Almeida *et al.* (2014) que modelaram o volume de madeira a partir de bandas espectrais e índices de vegetação provenientes do sensor TM do Landsat 5, em fragmentos de Caatinga localizados no estado de Sergipe, e encontraram um R^2 de 0,60, com alto RMSE de 32 m³.ha⁻¹ (42,00%), mesmo utilizando na metodologia, semelhantemente ao realizado no presente trabalho, a extração das variáveis preditivas por tamanho de janela (3x3 pixels); e Lima Júnior *et al.* (2014) que ao ajustar um modelo para estimar a biomassa lenhosa em áreas de Caatinga, no município de Petrolina, em Pernambuco, obtiveram para a equação ajustada um R^2 de 0,70, com um desvio padrão de 8,43 Mg.ha⁻¹, entretanto, diferentemente do presente estudo, os autores utilizaram apenas o NDVI, oriundo do sensor TM do satélite Landsat 5, como variável preditiva, o que pode explicar o resultado moderado da equação gerada.

Os resultados encontrados também são superiores ao encontrado por Gasparri *et al.* (2010), que utilizaram dados do satélite Landsat 7, sensor ETM (bandas e índices de vegetação) para estimar a biomassa aérea em áreas de floresta subtropical seca, na região do Chaco, Argentina e encontraram um R^2 de 0,66 para a equação ajustada.

Melhores resultados foram identificados no estudo realizado por Deb *et al.* (2017) que utilizaram dados do satélite Resourcesat-2, sensor AWiFS (56 m de resolução espacial) para modelar a biomassa em florestas secas intercaladas com pastagem na Índia e alcançaram R^2 oscilando entre 0,89 a 0,98, mesmo utilizando apenas o NDVI como variável preditiva. Este desempenho superior ao encontrado no presente estudo se deve em partes a utilização de diferentes métodos de modelagem, como modelos não lineares e inteligência artificial.

Em um remanescente de Cerrado no Tocantins, Santos *et al.* (2017) realizaram estudo para estimar o volume florestal utilizando apenas dados do satélite Landsat 8 (sensor OLI) e relatam que a melhor equação ajustada explicou 49,00% da variação do volume, com erro padrão percentual de 43,48%. O erro elevado encontrado pelos autores pode estar atrelado a

alta variabilidade encontrada para o volume observado em campo ($CV = 60,00\%$), assim como verificado no presente estudo para o volume observado da Área II ($65,35\%$).

Vários são os estudos desenvolvidos para estimar variáveis biofísicas a partir da junção de duas tecnologias de sensoriamento remoto. Para melhorar a capacidade de previsão da biomassa aérea para uma floresta dominada por eucaliptos no Nordeste da Austrália, Ediriweera *et al.* (2014), utilizaram a fusão de variáveis derivadas da tecnologia LiDAR e do satélite Landsat 5 e destacaram que a fusão aumentou o desempenho preditivo da biomassa para a floresta de eucalipto, alcançando um R^2 de 0,83, com um RMSE relativo de 12,0%, resultado similar ao encontrado neste estudo.

Utilizando dados do sensor hiperespectral aerotransportado HYDICE, com resolução espacial de 1,6 metros e do LiDAR ALS para estimar a biomassa em área de floresta tropical úmida Clark *et al.* (2011) relataram bons desempenhos para as equações ajustadas, com R^2 entre 0,91 e 0,92 e RMSE entre 36,9 e 35,8 $Mg.ha^{-1}$, respectivamente. As razões que contribuíram para a superioridade da pesquisa citada em relação ao presente estudo podem ser: o maior número de amostras utilizadas pelos autores, melhor resolução espacial, densidade média da nuvem de pontos LiDAR superior (9 pontos/ m^2), bem como a maior uniformidade do dossel da floresta e, conseqüentemente, maior uniformidade da reflectância do dossel florestal, que tende a não ter tanta interferência da reflectância de outros alvos, como por exemplo, o solo exposto.

Observa-se que a integração entre tecnologia LiDAR ALS e dados orbitais se torna útil, uma vez que, os dados do LiDAR modelam melhor as informações relacionadas à altura das árvores e os dados espectrais modelam melhor as propriedades da vegetação, como densidade e diferença entre tipos de vegetação (EGBERTH *et al.*, 2017) e, desta forma, a combinação entre métricas LiDAR, bandas espectrais e índices de vegetação podem gerar melhores estimativas das variáveis biofísicas volume e biomassa, como visto no presente estudo.

De maneira geral, os erros de estimativas encontrados nas equações ajustadas podem ser decorrentes do grau de precisão das equações utilizadas no presente estudo para a obtenção do volume e da BSA em campo, associados aos erros originados durante a medição das árvores amostrais, assim como, do tamanho reduzido da amostra (unidades amostrais).

Podem ainda estar relacionados com o tempo entre as datas de medição em campo, escaneamento do sensor LiDAR ALS e passagem dos sensores dos satélites pelas áreas em estudo, bem como, com a baixa densidade de pontos de retorno obtida no escaneamento LiDAR.

3.3 Distribuição espacial do volume e biomassa

Os mapas temáticos de espacialização do volume e da BSA foram gerados a partir das melhores equações para cada área estudada. As equações selecionadas foram:

Área I

$$\hat{V}_i = -44,42 + 58,98NDVI_i + 5,24h_{sd_i} + 5,40h_{p05_i}$$

$$\hat{BSA}_i = -20,14 + 135,43B5_i + 13,50NDVI_i - 2,20h_{max_i} + 14,71h_{sd_i} + 6,62h_{p05_i} - 3,59h_{p80_i} + 0,06P_{1..3}$$

Área II

$$\hat{V}_i = -31,60 + 25,58NDVI_i - 1,16SR_i - 39,26h_{sd_i} + 105,81h_{cv_i} + 6,59h_{p90_i} + 0,06P_{1..3}$$

$$\hat{BSA}_i = -26,42 + 83,63B3_i - 42,31B5_i + 37,50NDVI_i + 10,52h_{min_i} - 35,11h_{sd_i} + 126,73h_{tv_i} - 11,12h_{p01_i} + 9,99h_{p25_i} + 0,11P_{1..3}$$

Na figura 15 observa-se os mapas temáticos de espacialização do volume e da BSA para as áreas de estudo I e II.

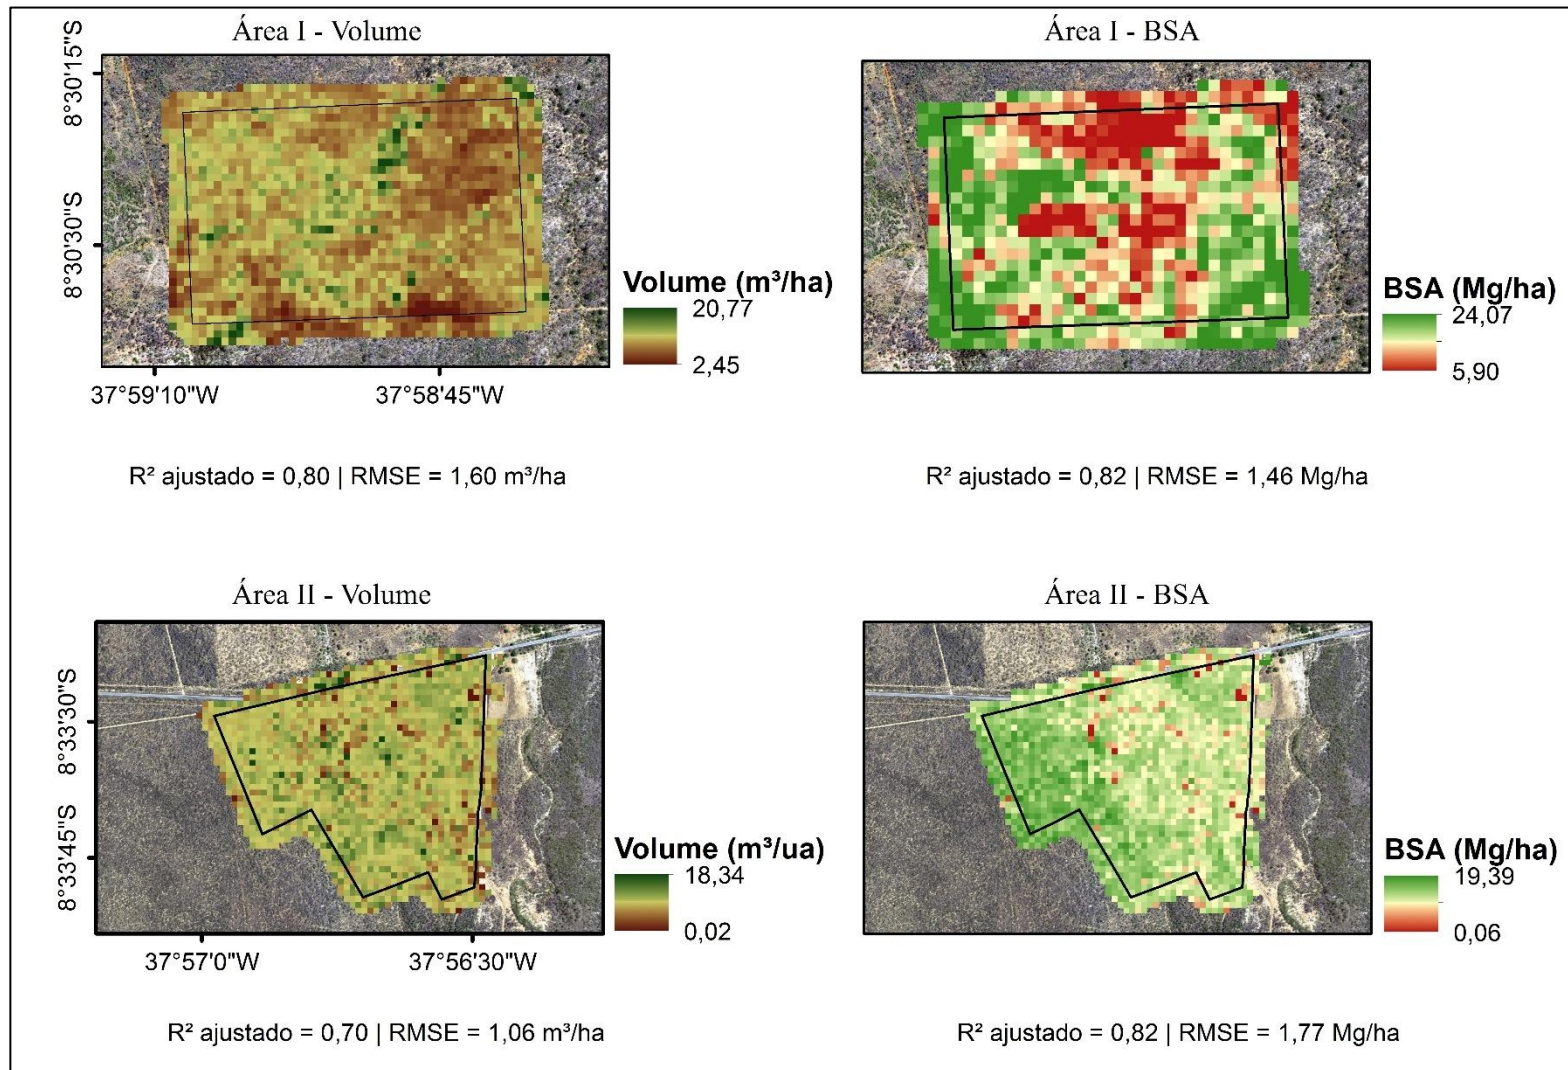


Figura 15 – Espacialização dos estoques de volume e BSA estimados com métricas LiDAR e dados orbitais para 2014 nas áreas de estudo I e II, Floresta, PE. **Fonte:** o autor.

Foi possível observar que as equações utilizadas para espacializar o volume e a BSA, em ambas as áreas em estudo apresentou tendência de superestimar valores menores e subestimar valores maiores, como foi possível verificar nas unidades amostrais das Áreas I e II.

Na Área I, por exemplo, os maiores valores de BSA foram localizados nas unidades amostrais 6 e 26, com 24,99 e 21,41 $\text{Mg}\cdot\text{ha}^{-1}$, respectivamente e na espacialização as estimativas foram 20,83 e 17,78 $\text{Mg}\cdot\text{ha}^{-1}$. Os menores valores foram encontrados nas unidades amostrais 24 e 14, com 2,20 e 6,56 $\text{Mg}\cdot\text{ha}^{-1}$, respectivamente, entretanto na espacialização os valores estimados foram 6,78 e 9,51 $\text{Mg}\cdot\text{ha}^{-1}$, respectivamente.

Já para Área II, os valores mais elevados de volumes observados foram identificados nas unidades amostrais 37 e 31, com 19,73 e 15,25 $\text{m}^3\cdot\text{ha}^{-1}$, respectivamente e a equação gerou estimativas para estas unidades amostrais (valor médio dos pixels da parcela) de 12,38 e 11,96 $\text{m}^3\cdot\text{ha}^{-1}$. Já os menores valores de volume equivalem as unidades amostrais 15 e 27, com volume observado de 0,32 e 0,33 $\text{m}^3\cdot\text{ha}^{-1}$, respectivamente e na espacialização os valores estimados para estas unidades amostrais foram de 5,15 e 5,46, $\text{m}^3\cdot\text{ha}^{-1}$.

De maneira geral é conveniente salientar que o método empregado no presente estudo para a espacialização dos atributos florestais por meio das equações ajustadas fornece muito mais detalhes espaciais, o que pode ser tão importante para decisões de manejo quanto para órgãos estaduais e federais responsáveis pela fiscalização, pela manutenção e pela conservação de áreas florestal.

4 CONCLUSÃO

As equações preditivas de volume e BSA geradas a partir da integração entre dados LiDAR ALS e dados orbitais não foram capazes de gerar resultados com acurácia compatível à obtida por meio do inventário florestal convencional.

Observou-se que, na validação cruzada, as equações de volume e BSA apresentaram diferenças entre RMSE e RMSEcv consideradas baixas, o que indica uma capacidade de generalização satisfatória.

Verificou-se que a integração entre dados LiDAR ALS e dados orbitais com média resolução espacial gerou as melhores equações para estimar os estoques de volume e BSA das áreas de florestas tropicais secas estudadas.

Quanto a espacialização das variáveis biofísicas volume e BSA, observou-se que os valores de volume e BSA estimados e espacializados para toda a extensão das áreas I e II, a partir das melhores equações obtidas no estudo, foram condizentes com o desempenho das equações, com tendência de superestimar valores menores e subestimar valores menores.

CONCLUSÕES GERAIS

Conclui-se que o uso exclusivo de dados proveniente da tecnologia LiDAR para estimar volume e BSA em áreas de floresta tropical seca, não forneceu acurácia compatível àquela obtida em inventários florestais convencionais.

Observou-se que o uso de métricas LiDAR ALS e dados orbitais confirma nossa hipótese inicial de que a combinação dos dois tipos de dados possibilita a geração de estimativas de volume e BSA mais precisas, quando comparadas à utilização de dados LiDAR ALS de forma isolada.

Quanto a capacidade de generalização, observou-se que todas as equações ajustadas para volume e BSA apresentaram erros ligeiramente maiores aos obtidos na fase de ajuste.

Verificou-se que a utilização de dados LiDAR ALS em conjunto com dados orbitais de média resolução espacial gerou equações com melhores desempenhos para estimar os estoques de volume e BSA das áreas de florestas tropicais secas estudadas.

Observou-se que, na espacialização das variáveis biofísicas para toda a extensão da área de estudo, as equações apresentaram tendência de superestimar valores menores e subestimar valores menores.

CONSIDERAÇÕES FINAIS

Os resultados encontrados nesta pesquisa, evidenciam que a integração entre tecnologia LiDAR ALS e dados orbitais são capazes de gerar estimativas de volume e BSA em áreas de FTS com boa precisão, entretanto com limitações de uso. Dessa forma, no que se refere a FTS, a metodologia aqui empregada é indicada para auxiliar e nortear a tomada de decisão para implementação do manejo florestal sustentado, bem como para identificar potenciais áreas para conservação.

Recomenda-se que mais estudos sejam desenvolvidos visando aumentar a precisão das estimativas de variáveis biofísicas em FTS, utilizando diferentes densidade da nuvem de pontos de retorno LiDAR, a análise individual das árvores, LiDAR terrestre, bem como a utilização de imagens de sensores hiperespectrais em conjunto com dados LiDAR.

REFERÊNCIAS

- ACCIOLY, L. J. O. *et al.* Relações empíricas entre a estrutura da vegetação e dados do sensor TM/LANDSAT. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 6, n. 3, p. 492-498, 2002. <https://doi.org/10.1590/S1415-43662002000300019>.
- ALMEIDA, A. Q. *et al.* Relações empíricas entre características dendrométricas da Caatinga brasileira e dados TM Landsat 5. **Pesquisa Agropecuária Brasileira**, Brasília, v. 49, n. 4, p. 306-315, 2014. <https://doi.org/10.1590/S0100-204X2014000400009>.
- ALVES JUNIOR, F. T. **Estrutura, biomassa e volumetria de uma área de caatinga, Floresta – PE**. 2010. 123 f. Tese (Doutorado em Ciências Florestais) – Universidade Federal Rural de Pernambuco, Departamento de Ciência Florestal, Recife.
- ANDERSEN, H. E.; REUTEBUCH, S. E.; McGAUGHEY, R. J. A rigorous assessment of tree height measurements obtained using airborne LiDAR and conventional field methods. **Canadian Journal of Remote Sensing**, London, v. 32, n. 5, p. 355-366, 2006. <http://dx.doi.org/10.5589/m06-030>.
- ARAÚJO FILHO, J. C. *et al.* **Diagnóstico Ambiental do Município de Floresta, Pernambuco**. Rio de Janeiro: Embrapa, 2001. 20 p. (Circular Técnica n. 10, ISSN 1517-5146).
- BALENOVIĆ, I. *et al.* Estimation of the mean tree height of forest stands by photogrammetric measurement using digital aerial images of high spatial resolution. **Annals of Forest Research**, Voluntari, v. 58, n. 1, p. 125-143, 2015. <https://doi.org/10.15287/afr.2015.300>.
- BANDA, K. R. *et al.* 2016. Plant diversity patterns in neotropical dry forests and their conservation implications. **Science**, Washington, v. 353, p. 1383-1387. <https://doi.org/10.1126/science.aaf5080>.
- BARRETO, T. N. A. **Avaliação de modelos e métodos geoestatísticos para estimativa de biomassa em área de caatinga**. 2017. 100 f. Tese (Doutorado em Ciências Florestais) – Universidade Federal Rural de Pernambuco, Departamento de Ciência Florestal, Recife.
- BARRETT, T. M.; FRIED, J. S. Modeling. *In*: BURLEY, J.; EVANS, J.; YOUNGQUEST, J. A. **Encyclopedia of Forest Sciences**, Spain: Elsevier, 2004. p. 426-433.
- BATISTA, J. L. F.; COUTO, H. T. Z.; SILVA FILHO, D. F. **Quantificação de recursos florestais: árvores arvoredos e florestas**. 1. ed. São Paulo, 2014. 384p.
- BLACKBRIDGE. **Satellite Imagery Product Specifications**. 2015. Disponível em: <http://lps16.esa.int/posterfiles/paper1213/%5BRD16%5D_RE_Product_Specifications_ENG_Apr15.pdf>.
- BLACKIE, R. *et al.* 2014. Tropical dry forests: The state of global knowledge and recommendations for future research. **Discussion Paper**. Bogor, Indonesia: CIFOR.
- BOX, G. E. P.; COX, D. R. An analysis of transformations. **Journal of the Royal Society**, v. 26, n. 2, p. 211-252, 1964.

BRASIL. Lei nº 11.206, de 31 de março de 1995. Dispõe sobre a Política Florestal do Estado de Pernambuco e dá outras providências. **Diário Oficial do Estado de Pernambuco**, Recife, PE, 1995.

BRASIL. Lei nº 11.284, de 2 de março de 2006. Dispõe sobre a gestão de florestas públicas para a produção sustentável; institui, na estrutura do Ministério do Meio Ambiente, o Serviço Florestal Brasileiro - SFB; cria o Fundo Nacional de Desenvolvimento Florestal – FNDF. **Diário Oficial [da] República Federativa do Brasil**, Brasília - DF, 3 de março 2006.

BRASIL. MINISTÉRIO DO MEIO AMBIENTE. **Subsídios para a Elaboração do Plano de Ação para a Prevenção e Controle do Desmatamento na Caatinga**. Brasília, DF: MMA, 2011. 128 p.

BRASIL. MINISTÉRIO DO MEIO AMBIENTE. **Manejo para produção de lenha**. 2012. Disponível em: <<https://www.mma.gov.br/informma/item/8513-manejo-para-produ%C3%A7%C3%A3ode-lenha>>. Acesso em: 07 de ago. 2020.

BREUSCH T. S.; PAGAN, A. R. A Simple Test for Heteroscedasticity and Random Coefficient Variation. **Econometrica**, New Haven, CT, v. 47, p. 1287-1294, 1979.

CALEGÁRIO, N. Estudo da regeneração natural visando a recuperação de áreas degradadas e o manejo florestal. In: SCOLFORO, J. R. S. **Manejo Florestal**. Lavras: UFLA/FAEPE, 1998. p. 301-313.

CARRILHO, A. C. **Aplicação de técnicas de processamento e análise de imagens para detecção de edificações e vegetação a partir de dados LiDAR**. 2016. 72 f. Dissertação (Mestrado em Ciências Cartográficas) - Universidade Estadual Paulista, Faculdade de Ciências e Tecnologia, Presidente Prudente, 2016.

CHUVIECO, E. **Fundamentos de teledetección espacial**. Madrid: Rialp, 1990. 453 p.

CLARK, M. L. *et al.* Estimation of tropical rain forest aboveground biomass with small-footprint lidar and hyperspectral sensors. **Remote Sensing of Environment**, Amsterdam, v. 115, n. 11, p. 2931-2942, 2011. <https://doi.org/10.1016/j.rse.2010.08.029>.

CONSORSÓCIO ÁGUAS DE PERNAMBUCO. **Relatório final de atividades executadas Bloco III**. Recife, 2017. 126 p. (Relatório Técnico).

CPRM - SERVIÇO GEOLÓGICO DO BRASIL. **Projeto cadastro de fontes de abastecimento por água subterrânea**: Diagnóstico do município de Floresta, estado de Pernambuco. Recife: CPRM/PRODEEM, 2005. 12p.

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

D'OLIVEIRA, M. V. N. *et al.* Estimating forest biomass and identifying low-intensity logging areas using airborne scanning lidar in Antimary State Forest, Acre State, Western Brazilian Amazon. **Remote Sensing of Environment**, Amsterdam, v. 124, p. 479-491, 2012. <https://doi.org/10.1016/j.rse.2012.05.014>.

DEB, D. *et al.* An alternative approach for estimating above ground biomass using Resourcesat-2 satellite data and artificial neural network in Bundelkhand region of India. **Environmental Monitoring and Assessment**, v. 189, n. 576, p. 1-12, 2017. <https://doi.org/10.1007/s10661-017-6307-6>.

DEXTER, K.G. *et al.* Floristics and biogeography of vegetation in seasonally dry tropical regions. **International Forestry Review** – Special Issue: Global Dry Forests, v. 17(S2), p. 10-32, 2015.

DIODATO, M. A. *et al.* Índice de Vegetação. In: PARANHOS FILHO, A. C. *et al.* **Geotecnologias para Aplicações Ambientais**. Maringá, PR: Uniedusul, 2021. p. 288-300.

DONG, P.; CHEN, Q. **LiDAR remote sensing and applications**. Boca Raton, Florida: Taylor & Francis, 2018. 200p.

DRAPER, N. M.; SMITH, H. **Applied regression analysis**. 2.ed., New York: Wiley. 1981. 709p.

DURBIN, J. E; WATSON, G.S. Testing for serial correlation in least squares regression II. **Biometrika**, Oxford, v.38, p. 159-177, 1951.

EDIRIWEERA, S. *et al.* Estimating above-ground biomass by fusion of LiDAR and multispectral data in subtropical woody plant communities in topographically complex terrain in North-eastern Australia. **Journal of Forestry Research**, v. 25, n. 4, p. 761–771, 2014. <https://doi.org/10.1007/s11676-014-0485-7>.

EGBERTH, M. *et al.* Combining airborne laser scanning and Landsat data for statistical modeling of soil carbon and tree biomass in Tanzanian Miombo woodlands. **Carbon Balance Management**, v. 12, n. 8, 2017. <https://doi.org/10.1186/s13021-017-0076-y>.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA - EMBRAPA. **Sistema brasileiro de classificação de solos**. 5 ed. Rio de Janeiro: EMBRAPA, 2018. 355p.

EMPRESA DE PESQUISA ENERGÉTICA - EPE. **Balço Energético Nacional 2019: Ano base 2018**. Rio de Janeiro: EPE, 2019. 300p.

EQUIPE DE DESENVOLVIMENTO QGIS, 2018. **Sistema de Informação Geográfica QGIS**. Fundação Geoespacial de Código Aberto.

ESTORNELL, J. *et al.* Estimation of shrub biomass by airborne LiDAR data in small forest stands. **Forest Ecology Management**, Amsterdam, v. 262, n. 9, p. 1697-1703, 2011. <http://dx.doi.org/10.1016/j.foreco.2011.07.026>.

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

FERREIRA, D. F. **Recursos computacionais utilizando R**. Lavras, MG. 2013, 238p.

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

FIGUEIREDO, D. **Conceitos Básicos de Sensoriamento Remoto**. 2005. Disponível em: <http://www.conab.gov.br/conabweb/download/SIGABRASIL/manuais/conceitos_sm.pdf>. Acesso em 06 jul. 2020.

FLORENZANO, T. G. **Imagens de satélite para estudos ambientais**. São Paulo: Oficina de Textos, 2002.

FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS - FAO. **Global ecological zoning for the global forest resources assessment 2000 - Final report**. Forest Resources Assessment Programme. Rome, 2001. Disponível em: <<http://www.fao.org/docrep/006/ad652e/ad652e00.HTM>>.

FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS - FAO. **Global ecological zones for fao forest reporting: 2010 Update**. Forest Resources Assessment Working Paper 179. Rome, 2012. Disponível em: <<http://www.fao.org/3/a-ap861e.pdf>>.

GARIGLIO, M. A. *et al.* (Org.). **Uso sustentável e conservação dos recursos florestais da caatinga**. Brasília, DF: Serviço Florestal Brasileiro, 2010, 368p.

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

GIONGO, M. *et al.* LiDAR: princípios e aplicações florestais. **Pesquisa Florestal Brasileira**, Colombo: v. 30, n. 63, p. 231-244, 2010. <http://dx.doi.org/10.4336/2010.pfb.30.63.231>.

GOMES, V. P. *et al.* **Avaliação espacial da estrutura vertical de espécies vegetais e biomassa em áreas de Caatinga com dados LIDAR**. 2017, 65p. Dissertação (Mestrado em Desenvolvimento e Meio Ambiente) - Universidade Federal de Pernambuco, 2017.

GÖRGENS, E. B.; SILVA, A. G. P.; RODRIGUEZ, L. C. E. **LiDAR: aplicações florestais**. 1. ed. Curitiba, PR: CRV, 2014. 132 p.

GÖRGENS, E. B. *et al.* Stand volume models based on stable metrics as from multiple ALS acquisitions in Eucalyptus plantations. **Annals of Forest Science** 72:489–498, 2015. <http://dx.doi.org/10.1007/s13595-015-0457-x>.

GEOSPATIAL TECHNOLOGY AND APPLICATIONS CENTER - GTAC -. **Lidar Introduction Tutorial**. Salt Lake City, Utah, 2019. Disponível em: <https://www.fs.fed.us/eng/rsac/lidar_training/Introduction_to_Lidar/player.html>. Acesso: 19 jul. 2019.

HIGUCHI, N. *et al.* Biomassa da parte aérea da vegetação de floresta tropical úmida de terra-firme da Amazônia Brasileira. **Acta Amazônica**, Manaus, v. 28, p. 153-165, 1998. <http://dx.doi.org/10.1590/1809-43921998282166>.

HIGUCHI, N. *et al.* **Noções básicas de manejo florestal**. Manaus, 2007. 274 p.

HUDAK, A. T. *et al.* Quantifying aboveground forest carbon pools and fluxes from repeat LiDAR surveys. **Remote Sensing of Environment**, Amsterdam, v. 123, p. 25-40, 2012. <https://doi.org/10.1016/j.rse.2012.02.023>.

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

HUSCH, B.; MILLER, C. I.; BEERS, T. W. **Forest mensuration**. 3 ed. Malabar: Krieger Publishing Company, 402 p., 1963.

HYYPÄ, J. *et al.* Review of methods of small-footprint airborne laser scanning for extracting forest inventory data in boreal forests. **International Journal of Remote Sensing**, Inglaterra, v. 29, n. 5, p. 1339-1366, 2008. <http://dx.doi.org/10.1080/01431160701736489>.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. **Biomass e sistema costeiro-marinho do Brasil**: compatível com a escala 1:250 000. Rio de Janeiro: IBGE, 2019. 168p. (Série de Relatórios Metodológicos, v.45)

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

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS - INPE. **Introdução ao Sensoriamento Remoto**. São José dos Campos, 2001. Disponível em: <http://www.agr.feis.unesp.br/hrsilva/sr_dpi7.PDF>. Acesso em 06 de jul. 2020.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS - INPE. **Relatório Executivo 2014**. São José dos Campos, 2015. Disponível em: <http://antigo.mctic.gov.br/mctic/export/sites/institucional/contratos_gestao_organizacaoes_sociais/arquivos/TCG/INPE/RELATORIO-EXECUTIVO-2014-INPE.pdf>. Acesso em 08 de jul. de 2020.

IOKI, K. *et al.* Estimating stand volume in broad-leaved forest using discrete-return LiDAR: plot-based approach. **Landscape and Ecological Engineering**, New York, v. 6, n. 1, p. 29-36, 2010.

ISRO – INDIAN SPACE RESEARCH ORGANIZATION - ISRO. **ResourceSat-2 Data Users Handbook**. Hyderabad: National Remote Sensing Centre. 2011. 142p.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos: Parêntese. xviii, 2011, 598 p.

JIANG, Z. *et al.* Development of a two-band enhanced vegetation index without a blue band. **Remote Sensing of Environment**, Amsterdam, v. 112, p. 3833– 3845, 2008. <https://doi.org/10.1016/j.rse.2008.06.006>.

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. <https://doi.org/10.2307/1936256>.

KINI, A. U.; POPESCU, S. C. TreeVaw: A versatile tool for analyzing forest canopy Lidar data – a preview with an eye towards future. Kansas City, MO: **SPRS Images to Decision: Remote Sensing Foundation for GIS Applications**, 2004. 472 p.

LEITE, R. V. *et al.* Estimating stem volume in eucalyptus plantations using airborne LiDAR: a comparison of area- and individual tree-based approaches. **Remote Sensing**, v. 12, p. 9, 2020. <https://doi.org/10.3390/rs12091513>.

LEFSKY, M. A. *et al.* Lidar Remote Sensing for Ecosystem Studies. **BioScience**. Oxford, v. 52, n. 1, p. 19-30, 2002a. [https://doi.org/10.1641/00063568\(2002\)052\[0019:LRSFES\]2.0.CO;2](https://doi.org/10.1641/00063568(2002)052[0019:LRSFES]2.0.CO;2).

LEFSKY, M. A. *et al.* Lidar Remote Sensing of Above-Ground Biomass in Three Biomes. **Global Ecology and Biogeography**, v. 11, n. 5, p. 393-399, 2002b. <https://doi.org/10.1046/j.1466-822x.2002.00303.x>.

LIM, K. C. K. *et al.* LiDAR remote sensing of forest structure. **Progress in Physical Geography**, Thousand Oaks, v. 27, n. 1, p. 88-106, 2003. <https://doi.org/10.1191/0309133303pp360ra>.

LIMA JÚNIOR, C. *et al.* Estimativa de biomassa lenhosa da caatinga com uso de equações alométricas e índice de vegetação. **Scientia Forestalis**, Piracicaba, SP, v.42, n.102, p.289-298, 2014.

MACEDO, F. L. Estimativa do volume de madeira para *Eucalyptus sp.* com imagens de satélite de alta resolução espacial. **Scientia Forestalis**, Piracicaba, v. 45, n. 114, p. 237-247, 2017. <https://doi.org/10.18671/scifor.v45n114.01>.

MAGNUSSEN, S.; NÆSSET, E.; GOBAKKEN, T. Reliability of LiDAR derived predictors of forest inventory attributes: a case study with Norway spruce. **Remote Sensing of Environment**, Amsterdam, v. 114, n. 4, p. 700-712, 2010. <https://doi.org/10.1016/j.rse.2009.11.007>.

MARTÍNEZ-YRIZAR, A. Biomass distribution and primary productivity of tropical dry forest. p.326-345. **In:** STEPHEN, H.B.; MOONEY, H.A.; MEDINA, E. (Eds.). *Seasonally drytropical forests*. Cambridge: Cambridge University, 1995.

McGAUGHEY, R. J. **FUSION/LDV**: Software for LiDAR Data Analysis and Visualization, Version 3.80. US Department of Agriculture, Forest Service, Pacific Northwest Research Station, University of Washington: Seattle, WA, USA. 2020.

MEANS, J. E. *et al.* Predicting forest stand characteristics with airborne scanning LiDAR. **Photogrammetric Engineering & Remote Sensing**, Bethesda, v. 66, n. 11, p. 1367-1371, 2000.

MENEZES, P. R.; ALMEIDA, T.; BAPTISTA, G. M. M. **Reflectância dos materiais terrestres**. 1. ed. São Paulo: Oficina de Textos, 2019. 336 p.

MIGUEL, E. P. *et al.* Redes neurais artificiais para a modelagem do volume de madeira e biomassa do cerrado com dados de satélite. **Pesquisa agropecuária brasileira**, Brasília, v. 50, n. 9, p. 829-839, 2015. <http://dx.doi.org/10.1590/S0100-204X2015000900012>.

MILES, L. *et al.* A global overview of the conservation status of tropical dry forests. **Journal of Biogeography**. [s.l.], v. 33, p. 491–505. 2006. <https://doi.org/10.1111/j.1365-2699.2005.01424.x>.

MINISTERIO DO MEIO AMBIENTE - MMA. **Programa de Regularização Ambiental**. 2020. Disponível em: <<http://geocatalogo.mma.gov.br/sobre.jhtml>>. Acessado em 20 de ago. 2020.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 4. ed. São José dos Campos: UFV, 2011. 422p.

MOTLAGH, M. G. *et al.* Estimating and mapping forest biomass using regression models and Spot-6 images (case study: Hyrcanian forests of north of Iran). **Environmental Monitoring and Assessment**, v. 190, n. 352, p. 1-14, 2018. <https://doi.org/10.1007/s10661-018-6725-0>.

NÆSSET, E.; ØKLAND, T. Estimating tree height and tree crown properties using airborne scanning laser in a boreal nature reserve. **Remote Sensing of Environment**, Amstedam, v. 79, p. 105-15, 2002.

NATIONAL AERONAUTICS AND SPACE ADMINISTRATION - NASA. **Visão geral do Landsat 8**. 2020. Disponível em: <<https://landsat.gsfc.nasa.gov/landsat-8/>>. Acesso em: 24 ago. 2020.

NGUYEN, T. D.; KAPPAS, M. Estimating the Aboveground Biomass of an Evergreen Broadleaf Forest in Xuan Lien Nature Reserve, Thanh Hoa, Vietnam, Using SPOT-6 Data and the Random Forest Algorithm. **International Journal of Forestry Research**, v. 2020, p. 1-13, 2020. <https://doi.org/10.1155/2020/4216160>.

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

OTA, T. *et al.* 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. <https://doi.org/10.3390/f6113882>.

OTA, T. *et al.* Estimating selective logging impacts on aboveground biomass in tropical forests using digital aerial photography obtained before and after a logging event from an unmanned aerial vehicle. **Forest Ecology and Management**, v. 433, p. 162-169, 2019. <https://doi.org/10.1016/j.foreco.2018.10.058>.

OU, G. *et al.* Improving aboveground biomass estimation of pinus densata forests in yunnan using landsat 8 imagery by incorporating age dummy variable and method comparison. **Remote Sensing**, v. 11, n. 7, 2019. <https://doi.org/10.3390/rs11070738>.

PANDIT, S.; TSUYUKI, S.; DUBE, T. Estimating Above-Ground Biomass in Sub-Tropical Buffer Zone Community Forests, Nepal, Using Sentinel 2 Data. **Remote Sensing**. v. 10, n. 601, p. 2-18, 2018. <https://doi.org/10.3390/rs10040601>.

PANDYA, M. R.; MURALI, K. R.; KIRANKUMAR, A. S. Quantification and Comparison of Spectral Characteristics of Sensors on Board Resourcesat-1 and Resourcesat-2 Satellites. **Remote Sensing Letters**, v. 4, n. 3, p. 306-314, 2012. <https://doi.org/10.1080/2150704X.2012.727491>.

PARDOE, I. **Applied regression modeling**. 2 ed. New Jersey: John Wiley & Sons; 2012. 346p.

PAREYN, F. G. C. Os recursos florestais nativos e a sua gestão no estado de Pernambuco - o papel do manejo florestal sustentável. *In*: GARIGLIO, M. A. *et al.* (Org.). **Uso sustentável e conservação dos recursos florestais da caatinga**. Brasília: Serviço Florestal Brasileiro, 2010. p. 99-112.

PLANET LABS Inc. **Planet imagery product specifications**. 2018. 98p. Disponível em: <<https://assets.planet.com/docs/Combined-Imagery-Product-Spec-Dec-2018.pdf>>.

PLANET LABS Inc. **Historic RapidEye Constellation Captures Last Light**. 2020. Disponível em: <<https://www.planet.com/pulse/historic-rapideye-constellation-captures-last-light/>>. Acesso em: 31 ago. 2020.

PONZONI, F. J. Sensoriamento remoto no estudo da vegetação: diagnosticando a mata atlântica. *In*: RUDORFF, B. F. T.; MORAES, E. C.; PONZONI, F. J. *et al.*, (Ed.). VI Curso de uso de sensoriamento remoto no estudo do meio ambiente. São José dos Campos: INPE, 2003. cap. 8. Disponível: <http://ecologia.ib.usp.br/lepac/bie5759/CAP8_FJPonzoni.pdf>. Acesso em: 27 jun. 2020.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento Remoto no estudo da vegetação**. São José dos Campos, SP: Ed. Parêntese, 138 p., 2009.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto aplicado ao estudo da vegetação**. 2. ed. São José Dos Campos: Saraiva, 2012. 160 p.

POPESCU, S. C.; ZHAO, K. A voxel-based LiDAR method for estimating crown base height for deciduous and pine trees. **Remote Sensing of Environment**, Amsterdam, v. 112, n. 3, p. 767-781, 2008. <https://doi.org/10.1016/j.rse.2007.06.011>.

QUARTAROLI, C. F.; VICENTE, L. E.; ARAUJO, L. S. Sensoriamento remoto. *In*: TÔSTO, S. G. *et al.* (Ed.). **Geotecnologias e geoinformação**. Brasília, DF: Embrapa, 2014. p. 215-248 (livro técnico)

R DEVELOPMENT CORE TEAM, 2017. **R Development Core Team: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria. Disponível em: <<http://www.R-project.org/>>.

REX, F. E. *et al.* Estimating Above-Ground Biomass of *Araucaria angustifolia* (Bertol.) Kuntze Using LiDAR Data. **Floresta e Ambiente**. Seropédica, RJ, v. 26 n. 4, 2019. <https://doi.org/10.1590/2179-8087.110717>.

RODAL, M. J. N. *et al.* Estrutura da vegetação caducifólia espinhosa (Caatinga) de uma área do sertão central de Pernambuco. **Hoehnea**, São Paulo, SP, v. 35, n. 2, p. 209-217, 2008. <http://dx.doi.org/10.1590/S2236-89062008000200004>.

ROUSE, J. W. *et al.* Monitoring vegetation systems in the Great Plains with ERTS. **In: Third Earth Resources Technology Satellite-1 Symposium**. NASA SP-351, Greenbelt, Md., Woshington DC. p. 301–317, 1974.

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

SANTOS, M. S. *et al.* Estimativa de parâmetros florestais em área de Cerrado a partir de imagens do sensor OLI Landsat 8. **Floresta**, Curitiba, v. 47, n. 1, p. 75-83, 2017. <https://doi.org/10.5380/rf.v47i1.47988>.

SCHNEIDER, P. R.; SCHNEIDER, P. S. P.; SOUZA, C. A. M. **Análise de regressão aplicada à Engenharia Florestal**. 2. ed. Santa Maria: FACOSUFMS, 2009. 294 p.

SCOLFORO, J. R. S. **Biometria florestal: modelos de crescimento e produção florestal**. Lavras: UFLA. 2006, 393 p. (Texto acadêmico).

SCOLFORO, J. R. S. **Manejo florestal**. Lavras: UFLA. 2005, 352 p. (Texto acadêmico).

SHAPIRO, S. S.; WILK, M. B. An analysis of variance test for normality (complete samples), **Biometrika**, Oxford v. 52, p. 591-611, 1965.

SILVA, J. A. A.; PAULA NETO, F. **Princípios básicos de dendrometria**. Recife: Imprensa Universitária da UFRPE, 1979, 198 p. (Apostila didática)

SILVA, J. A. A.; SILVA, I. P. **Estatística experimental aplicada à ciência florestal**. 2.ed. Recife: Imprensa Universitária da UFRPE, v.1. 292p. 1995.

SILVA, J. M. C. *et al.* **Biodiversidade da caatinga: áreas e ações prioritárias para a conservação**. Brasília, DF: Ministério do Meio Ambiente: Universidade Federal de Pernambuco, 2003. 382 p.

SILVA, C. A. *et al.* Mapping aboveground carbon stocks using LiDAR data in eucalyptus spp. plantations in the state of São Paulo, Brazil. **Scientia Forestalis**, Piracicaba, SP, v. 42, p.591–604, 2014.

SILVA, J. A. A. Conceitos e Princípios Básicos de Modelagem Matemática em Ciências Florestais. **Anais da Academia Pernambucana de Ciência Agronômica**, Recife, vols. 11/12, p.195-215, 2015.

SILVA, C. A. *et al.* A principal component approach for predicting the stem volume in Eucalyptus plantations in Brazil using airborne LiDAR data. **Forestry**, v. 89, n. 4, p. 422-433, 2016. <https://doi.org/10.1093/forestry/cpw016>.

SILVA, J. M. C.; TABARELLI, M.; LEAL, I. R. 2017. **Caatinga: The Largest Tropical Dry Forest Region in South America**. Springer International Publishing. 487p. <https://doi.org/10.1007/978-3-319-68339-3>.

SILVA, C. A. *et al.* Predicting stem total and assortment volumes in an industrial *Pinus taeda* L. Forest plantation using airborne laser scanning data and random forest. **Forests**, Basel, v. 8, n. 7, p. 254- 267, 2017. <https://doi.org/10.3390/f8070254>.

SILVA, C. A. *et al.* Predição da biomassa aérea em plantações de *Pinus taeda* L. por meio de dados LiDAR aerotransportado. **Scientia Forestalis**, Piracicaba, v. 45, n. 115, p. 527-539, 2017. <https://dx.doi.org/10.18671/scifor.v45n115.10>.

SILVEIRA, P. *et al.* O estado da arte na estimativa de biomassa e carbono em formações florestais. **Floresta**, Curitiba, PR, v. 38, n. 1, 2008. <http://dx.doi.org/10.5380/ufpr.v38i1.11038>.

SOMOGYI, Z. *et al.* Indirect methods of large-scale forest biomass estimation. **European Journal of Forest Research**, v. 126, p. 197-207, 2001. <http://dx.doi.org/10.1007/s10342-006-0125-7>.

SOUZA, C. L.; PONZONI, F. J. Avaliação de índices de vegetação e de bandas TM/Landsat para estimativa de volume de madeira em floresta implantada de *Pinus* spp. **In: Anais do Simpósio Brasileiro de Sensoriamento Remoto**, 1998, Santos. São José dos Campos: INPE; 1998. p. 1537-1547.

SOUZA, M. J. N. A problemática ambiental: cenários para o Bioma Caatinga no Nordeste do Brasil. **In: SILVA, J. B. et al. (Org.). Panorama da geografia brasileira**. São Paulo: Annablume, 2006. v.2, p.119-133.

SRINIVAS, K.; SUNDARAPANDIAN, S. Biomass and carbon stocks of trees in tropical dry forest of East Godavari region, Andhra Pradesh, India, **Geology, Ecology, and Landscapes**, v. 3, n. 2, p. 114-122, 2018. <https://doi.org/10.1080/24749508.2018.1522837>.

TESFAYE, M.A. *et al.* Aboveground biomass equations for sustainable production of fuelwood in a native dry tropical afro-montane forest of Ethiopia. **Annals of Forest Science**, Les Ulis, v. 73, n. 2, p. 411-423, 2016. <https://doi.org/10.1007/s13595-015-0533-2>.

THOMAS, C. *et al.* Comparação de equações volumétricas ajustadas com dados de cubagem e análise de tronco. **Ciência Florestal**, Santa Maria, v. 16, n. 3, p. 319-327, 2006.

USGS – United States Geological Service. **Landsat 8 (L8) Data Users Handbook**. Versão 5.0. Department of the Interior U.S. Geological Survey, South Dakota. 2019. 115p.

VANCLAY, J. K. 1994. **Modelling forest growth and yield**: applications to mixed tropical forests. CAB International, Wallingford, U.K. 312 p.

VELOSO, H. P.; RANGEL-FILHO, A. L. R.; LIMA, J. C. A. **Classificação da vegetação brasileira adaptada a um sistema universal**. Rio de Janeiro, RJ: IBGE, 1991. 124 p.

VERMOTE, E. F. *et al.* Second simulation of the satellite signal in the solar spectrum: an overview. **IEEE Transactions on Geoscience and Remote Sensing**, v. 35, p. 675-686, 1997.

WAN-MOHD-JAAFAR, W. S. *et al.* Modelling individual tree aboveground biomass using discrete return lidar in lowland dipterocarp forest of Malaysia. **Journal of Tropical Forest Science**, Kepong, v. 29, n. 4, p. 465-484, 2017. <https://doi.org/10.26525/jtfs2017.29.4.465484>.

WASKLEWICZ, T. *et al.* Digital Terrain Modeling. **In:** Shroder, J. (Editor in Chief), Bishop, M.P. (Ed.), *Treatise on Geomorphology*. Academic Press, San Diego, CA, vol. 3, *Remote Sensing and GIScience in Geomorphology*, p. 130-161, 2013.

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

WILKIE, D. S.; FINN, J. T. **Remote sensing imagery for natural resources monitoring: a guide for first-time users**. New York: Columbia University Press, 1996. 295 p.

WOLF, P. R.; DEWITT, B. A. **Elements of Photogrammetry: with applications in GIS**. Boston: McGraw-Hill, 2000.

ZANDONÁ, D. F.; LINGNAU, C.; NAKAJIMA, N. Y. Varredura a laser aerotransportado para estimativa de variáveis dendrométricas. **Scientia Forestalis**, Piracicaba, v. 36, n. 80, p. 295-306, 2008.

ZONETE, M. F.; RODRIGUEZ, L. C. E.; PACKALÉN, P. Estimación de parâmetros biométricos de plantios clonais de eucalipto no sul da Bahia: uma aplicação da tecnologia laser aerotransportada. **Scientia Forestalis**, Piracicaba, v. 38, n. 86, p. 225-235, 2010.

ANEXOS

ANEXO A

Tabela 1 – Resultados da verificação do perfilamento a laser

Pontos	Qualidade Vertical				
	Coordenadas de Campo			Nuvem	Resultado
	E	N	H	H lidar	dH
BA-01	596424,819	9111990,853	471,500	471,160	-0,340
BA-01_01	575281,118	9117677,294	420,950	421,204	0,254
BA-01_02	588483,480	9127802,380	577,550	577,910	0,360
BA-01_03	598734,806	9133579,549	987,780	988,121	0,341
BA-01_04	593306,414	9122606,420	455,890	455,704	-0,186
BA-01_05	613063,377	9130166,296	465,550	465,725	0,175
BA-01_06	615391,151	9111518,852	532,210	532,268	0,058
BA-01_07	610263,237	9093776,885	455,800	455,501	-0,299
BA-01_08	595322,394	9102266,841	484,860	484,874	0,014
BA-01_09	580940,080	9096690,489	426,270	426,234	-0,036
BA-01_10	574685,366	9108876,864	469,500	469,573	0,073
BA-01_11	565577,841	9070202,345	386,880	386,816	-0,064
BA-01_12	573376,639	9094853,991	420,960	421,021	0,061
BA-01_13	563131,656	9118521,476	425,960	425,628	-0,332
BA-01_14	565791,202	9131409,276	493,410	493,517	0,107
BA-01_15	549206,459	9114468,355	435,160	435,027	-0,133
BA-01_16	566532,300	9100753,647	435,970	435,759	-0,211
BA-01_17	550274,395	9087578,525	378,050	378,105	0,055
BA-01_18	591375,737	9112544,758	481,250	481,360	0,110
BA-01_19	615867,096	9126616,034	481,160	481,220	0,060
BA-01_20	615432,346	9084788,417	493,820	493,963	0,143
BA-02	600645,591	9017697,233	456,110	456,224	0,114
BA-02_01	582597,639	9009320,365	329,240	329,449	0,209
BA-02_02	586009,301	9017613,227	414,250	414,461	0,211
BA-02_03	606419,988	9030990,613	492,870	493,194	0,324
BA-02_04	610416,106	9038105,724	548,500	548,266	-0,234
BA-02_05	619047,057	9033536,046	603,460	603,129	-0,331
BA-02_06	614660,213	9030144,918	449,160	449,270	0,110
BA-02_07	611387,116	9027251,860	437,900	437,787	-0,113
BA-02_08	624757,624	9015082,633	360,580	360,409	-0,171
BA-02_09	618223,402	9013856,373	382,450	382,462	0,012
BA-02_10	607658,774	9005163,074	486,660	486,864	0,204
BA-02_11	566528,327	9024323,287	310,340	310,117	-0,223
BA-02_12	568943,027	9047384,021	343,800	343,663	-0,137
BA-02_13	565094,418	9023079,576	321,940	321,664	-0,276
BA-02_14	593922,669	9011689,127	350,050	349,926	-0,124
BA-02_15	593706,393	8987017,984	337,220	337,090	-0,130

BA-02_16	622062,554	9063105,968	455,150	454,918	-0,232
----------	------------	-------------	---------	---------	--------

Continua...

...Continuação

Pontos	Qualidade Vertical				
	Coordenadas de Campo			Nuvem	Resultado
	E	N	H	H lidar	dH
BA-02_17	627613,403	9040209,594	513,850	514,008	0,158
BA-03_02	669280,422	9096992,079	520,100	520,393	0,293
BA-03_03	639705,669	9085949,578	492,620	492,833	0,213
BA-03_04	637836,528	9098773,201	542,080	542,292	0,212
BA-03_05	642355,301	9105780,635	601,250	601,417	0,167
BA-03_06	628199,337	9110161,704	558,030	558,311	0,281
BA-03_07	633638,667	9120985,048	541,520	541,938	0,418
BA-03_08	655957,888	9123136,212	585,870	586,094	0,224
BA-03_09	652011,273	9114168,656	549,630	549,680	0,050
BA-03_10	674502,980	9115042,918	561,800	562,050	0,250
BA-03_12	650384,225	9151601,672	575,590	575,963	0,373
BA-03_13	656547,735	9141774,029	581,300	581,426	0,126
BA-03_14	652955,162	9130964,598	735,080	735,121	0,041
BA-03_15	674532,771	9133339,450	578,180	578,134	-0,046
BA-03_16	654258,032	9094159,773	477,720	477,736	0,016
BA-03_17	696226,594	9116906,061	601,700	601,997	0,297
BA-03_18	697172,077	9111353,698	589,560	589,719	0,159
BA-03_19	621856,755	9138446,573	540,930	540,974	0,044
BA-03_19A	630827,767	9142880,466	545,210	545,515	0,305
BA-03_20	622896,703	9098181,769	516,450	516,378	-0,072
BA-03_20A	629170,044	9128470,518	519,970	520,340	0,370
BA-03_21	629537,800	9088988,471	506,520	506,559	0,039
BA-03_21A	627586,210	9103178,850	553,590	553,669	0,079
BA-03_22	630535,228	9090003,604	506,210	506,355	0,145
BA-03_23	627117,802	9072689,622	485,080	485,230	0,150
BA-04	666666,532	9064217,205	522,600	522,914	0,314
BA-04_01	674733,401	9067522,255	521,960	522,235	0,275
BA-04_05	666739,147	9047373,903	500,080	500,383	0,303
BA-04_06	643444,022	9056274,814	406,360	406,739	0,379
BA-04_06R	643430,146	9056266,786	406,480	406,801	0,321
BA-04_07	658231,436	9059887,861	494,990	495,165	0,175
BA-04_07R	658233,047	9059890,888	494,930	495,061	0,131
BA-04_08	653418,203	9068814,527	453,170	453,408	0,238
BA-04_09	658344,089	9085229,477	462,960	463,196	0,236
BA-04_12	657212,923	9034378,120	409,040	409,077	0,037
BA-04_13	657297,014	9020647,443	492,690	492,732	0,042
BA-04_24	625166,831	9061524,853	469,930	469,661	-0,269
BA-04_25	627813,308	9040173,464	511,930	512,077	0,147
BA-04_26	621498,731	9021314,725	422,090	421,737	-0,353
BA-05_03	701630,750	9139592,068	642,100	641,946	-0,154

BA-05_04	694373,963	9144594,796	606,250	606,345	0,095
Continua...					
...Continuação					
Qualidade Vertical					
Pontos	Coordenadas de Campo			Nuvem	Resultado
	E	N	H	H lidar	dH
BA-05_05	696817,533	9150742,854	615,310	615,303	-0,007
BA-05_06	699501,057	9160264,523	606,110	606,032	-0,078
BA-05A	710326,479	9176746,344	615,630	615,662	0,032
BA-05A_01	715523,847	9181854,234	647,580	647,615	0,035
BA-05A_03	709830,983	9172056,603	608,330	608,463	0,133
BA-05A_04	699256,321	9169893,070	590,030	590,015	-0,015
BA-05A_05	690415,370	9172347,168	583,540	583,446	-0,094
BA-05A_06	702559,011	9176783,819	630,640	630,484	-0,156
BA-05A_07	706649,287	9179633,499	617,550	617,579	0,029
BA-05A_08	699510,719	9184053,038	627,890	627,800	-0,090
BA-05A_09	708473,398	9184428,552	657,390	657,495	0,105
BA-05A_10	712030,945	9182104,357	631,190	631,277	0,087
BA-05A_11	674739,459	9180714,658	745,300	745,106	-0,194
BA-05A_12	656882,121	9163189,193	572,490	572,534	0,044
BA-05A_13	673889,326	9164829,991	600,530	600,097	-0,433
BA-05A_HV9	708478,016	9184423,702	657,420	657,502	0,082
CK-001C	556877,015	9106266,348	408,820	408,483	-0,337
CK-002C	554661,675	9039969,822	356,070	356,279	0,209
CK-003C	569813,974	9126736,846	466,310	466,193	-0,117
CK-004C	578478,858	9076513,797	441,180	441,140	-0,040
CK-005C	568169,406	9026066,164	319,940	319,787	-0,153
CK-006C	612267,111	9094567,352	462,500	462,667	0,167
CK-007C	611266,052	9026971,533	431,390	431,294	-0,096
CK-008	599270,867	9114876,311	463,040	463,149	0,109
CK-009	594784,103	9057187,630	404,380	404,039	-0,341
CK-010	628300,108	9110172,324	559,940	560,001	0,061
CK-011	624165,922	9028830,458	521,180	521,255	0,075
CK-012	643287,558	9125982,736	598,370	598,548	0,178
CK-013	637756,613	9051156,497	614,650	614,923	0,273
CK-014	702694,230	9173547,086	599,130	599,114	-0,016
CK-019	683567,997	9151854,656	582,317	582,581	0,264
HV-1023	714043,659	9168938,188	679,880	679,817	-0,063
HV-1024	721862,634	9173983,959	671,840	671,762	-0,078
HV-1025	713947,031	9183655,734	657,040	657,139	0,099
HV-1026	698920,094	9193509,959	718,270	718,009	-0,261
HV-1027	684259,212	9193929,544	822,270	822,486	0,216
HV-1028	669608,719	9184399,037	811,070	811,496	0,426
HV-1029	654608,037	9169372,734	758,280	758,844	0,564
HV-1030	640347,591	9160186,396	751,480	751,847	0,367

HV-1031	624962,133	9152902,558	786,040	786,224	0,184
---------	------------	-------------	---------	---------	-------

Continua...

...Continuação

Pontos	Qualidade Vertical				
	Coordenadas de Campo			Nuvem	Resultado
	E	N	H	H lidar	dH
HV-1032	609778,285	9139243,193	678,370	678,279	-0,091
HV-1033	595091,478	9137910,730	876,380	876,333	-0,047
HV-1034	580574,437	9136223,855	677,870	678,163	0,293
HV-1035	566092,286	9142944,769	621,430	621,535	0,105
HV-1036	547520,143	9142644,920	594,670	594,367	-0,303
HV-1037	547835,515	9030429,781	315,320	315,160	-0,160
HV-1038	566095,235	9004537,441	330,530	330,400	-0,130
HV-1039	580822,599	8980605,080	261,570	261,785	0,215
HV-1040	595720,907	8988749,174	339,170	339,143	-0,027
HV-1041	609646,030	8988532,908	303,190	302,954	-0,236
HV-1042	624860,018	9004580,019	347,460	347,008	-0,452
HV-1043	639840,140	9015372,975	431,490	431,733	0,243
HV-1044	654587,606	9009305,843	551,050	551,194	0,144
HV-1045	669265,732	9002485,359	411,280	411,659	0,379
HV-1050C	547041,709	9052901,437	325,190	324,893	-0,297
HV-1051C	547248,612	9067159,740	364,670	364,539	-0,131
HV-1052C	561924,020	9142853,865	549,390	549,065	-0,325
HV-1053C	561857,853	9076527,406	385,500	385,385	-0,115
HV-1054C	561294,704	9006124,751	372,070	372,012	-0,058
HV-1055C	573160,962	9145382,862	531,320	531,677	0,357
HV-1056C	587940,360	9132666,936	946,030	946,378	0,348
HV-1057C	566944,742	9050335,045	350,890	350,708	-0,182
HV-1058C	569362,181	9035374,037	336,280	335,998	-0,282
HV-1059C	577000,343	9032247,245	330,740	331,012	0,272
HV-1060C	584550,686	9030677,642	354,310	354,473	0,163
HV-1061C	587273,121	9066476,113	424,410	424,129	-0,281
HV-1062C	580246,538	9011929,964	334,390	334,606	0,216
HV-1063C	573957,060	9011035,663	323,230	323,232	0,002
HV-1064C	588157,901	8971455,421	265,370	265,485	0,115
HV-1065C	601989,123	9133594,821	1132,000	1131,757	-0,243
HV-1066C	616493,530	9144011,310	744,790	744,953	0,163
HV-1067C	605920,597	9054426,900	455,870	456,072	0,202
HV-1068C	606176,567	9019499,378	455,440	455,723	0,283
HV-1069C	612495,239	9054012,983	493,610	493,630	0,020
HV-1070C	617054,735	9078961,398	459,090	459,209	0,119
HV-1071C	601547,684	8985704,959	285,260	285,539	0,279
HV-1072C	616701,543	8994670,892	318,700	318,710	0,010
HV-1073	631696,907	9155637,544	792,310	792,379	0,069
HV-1074	647228,795	9167709,566	780,560	780,858	0,298
HV-1075C	594144,537	9017664,891	423,650	423,360	-0,290

HV-1076C	602534,667	9087568,595	469,220	469,353	0,133
----------	------------	-------------	---------	---------	-------

Continua...

...Continuação

Qualidade Vertical					
Pontos	Coordenadas de Campo			Nuvem	Resultado
	E	N	H	H lidar	dH
HV-1077	625229,832	9046654,457	611,270	611,270	0,000
HV-1078	632604,245	9020619,999	363,940	363,989	0,049
HV-1079	633240,805	9077323,942	513,980	514,240	0,260
HV-1080	647093,908	9070182,366	447,410	447,981	0,571
HV-1081	647788,216	9004744,728	496,320	496,452	0,132
HV-1082	694566,586	9193551,235	743,260	743,260	0,000
HV-1083	697600,312	9120412,027	653,120	653,090	-0,030
	Media (m)		0,0513		
	Desvio Padrao (m)		0,2104		
	RMS (m)		0,2159		

Fonte: Consórcio Águas de Pernambuco (2017).

ANEXO B

Quadro 1 - Resultados da Aerotriangulação – Bloco III - Sub 01 A 04

Item Avaliado	Valor Admissível	Resultado (m)		Situação
<i>Resíduos máximos nos pontos de controle (TXY)</i>	2 X GSD(100 cm)	XY	0,32	Aprovado
		Z	0,10	
<i>RMS dos Pontos de Controle</i>	1 X GSD (50 cm)	XY	0,20	Aprovado
		Z	0,06	
<i>Resíduos máximos nos pontos de verificação (check)</i>	2 X GSD (100 cm)	XY	0,27	Aprovado
		Z	0,67	

Quadro 2 - Resultados da Aerotriangulação – Bloco III - SUB 05 A 11A

Item Avaliado	Valor Admissível	Resultado (m)		Situação
<i>Resíduos máximos nos pontos de controle (TXY)</i>	2 X GSD(100 cm)	XY	0,20	Aprovado
		Z	0,06	
<i>RMS dos Pontos de Controle</i>	1 X GSD (50 cm)	XY	0,09	Aprovado
		Z	0,03	
<i>Resíduos máximos nos pontos de verificação (check)</i>	2 X GSD (100 cm)	XY	0,29	Aprovado
		Z	0,25	

Quadro 3 - Resultados da Aerotriangulação – Bloco III - SUB 05 A 11B

Item Avaliado	Valor Admissível	Resultado (m)		Situação
<i>Resíduos máximos nos pontos de controle (TXY)</i>	2 X GSD(100 cm)	XY	0,34	Aprovado
		Z	0,10	
<i>RMS dos Pontos de Controle</i>	1 X GSD (50 cm)	XY	0,20	Aprovado
		Z	0,05	
<i>Resíduos máximos nos pontos de verificação (check)</i>	2 X GSD (100 cm)	XY	0,23	Aprovado
		Z	0,21	

Quadro 4 - Resultados da Aerotriangulação – Bloco III - SUB 12 A 15

Item Avaliado	Valor Admissível	Resultado (m)		Situação
<i>Resíduos máximos nos pontos de controle (TXY)</i>	2 X GSD(100 cm)	XY	0,27	Aprovado
		Z	0,23	
<i>RMS dos Pontos de Controle</i>	1 X GSD (50 cm)	XY	0,17	Aprovado
		Z	0,09	
<i>Resíduos máximos nos pontos de verificação (check)</i>	2 X GSD (100 cm)	XY	0,25	Aprovado
		Z	0,76	

Quadro 5 - Resultados da Aerotriangulação – Bloco III - SUB 16 A 19

Item Avaliado	Valor Admissível	Resultado (m)		Situação
<i>Resíduos máximos nos pontos de controle (TXY)</i>	2 X GSD(100 cm)	XY	0,09	Aprovado
		Z	0,15	
<i>RMS dos Pontos de Controle</i>	1 X GSD (50 cm)	XY	0,07	Aprovado
		Z	0,09	
<i>Resíduos máximos nos pontos de verificação (check)</i>	2 X GSD (100 cm)	XY	0,65	Aprovado
		Z	0,35	

Quadro 6 - Resultados da Aerotriangulação – Bloco III - SUB 20 A 23

Item Avaliado	Valor Admissível	Resultado (m)		Situação
<i>Resíduos máximos nos pontos de controle (TXY)</i>	<i>2 X GSD(100 cm)</i>	XY	0,22	Aprovado
		Z	0,21	
<i>RMS dos Pontos de Controle</i>	<i>1 X GSD (50 cm)</i>	XY	0,13	Aprovado
		Z	0,09	
<i>Resíduos máximos nos pontos de verificação (check)</i>	<i>2 X GSD (100 cm)</i>	XY	0,31	Aprovado
		Z	0,23	

Quadro 7 - Resultados da Aerotriangulação – Bloco III - SUB 24 A 27

Item Avaliado	Valor Admissível	Resultado (m)		Situação
<i>Resíduos máximos nos pontos de controle (TXY)</i>	<i>2 X GSD(100 cm)</i>	XY	0,31	Aprovado
		Z	0,24	
<i>RMS dos Pontos de Controle</i>	<i>1 X GSD (50 cm)</i>	XY	0,16	Aprovado
		Z	0,11	
<i>Resíduos máximos nos pontos de verificação (check)</i>	<i>2 X GSD (100 cm)</i>	XY	0,25	Aprovado
		Z	0,48	

Quadro 8 - Resultados da Aerotriangulação – Bloco III - SUB 28 A 31

Item Avaliado	Valor Admissível	Resultado (m)		Situação
<i>Resíduos máximos nos pontos de controle (TXY)</i>	<i>2 X GSD(100 cm)</i>	XY	0,23	Aprovado
		Z	0,19	
<i>RMS dos Pontos de Controle</i>	<i>1 X GSD (50 cm)</i>	XY	0,15	Aprovado
		Z	0,10	
<i>Resíduos máximos nos pontos de verificação (check)</i>	<i>2 X GSD (100 cm)</i>	XY	0,52	Aprovado
		Z	0,55	

Quadro 9 - Resultados da Aerotriangulação – Bloco III - SUB 32 A 35

Item Avaliado	Valor Admissível	Resultado (m)		Situação
<i>Resíduos máximos nos pontos de controle (TXY)</i>	<i>2 X GSD(100 cm)</i>	XY	0,19	Aprovado
		Z	0,08	
<i>RMS dos Pontos de Controle</i>	<i>1 X GSD (50 cm)</i>	XY	0,10	Aprovado
		Z	0,05	
<i>Resíduos máximos nos pontos de verificação (check)</i>	<i>2 X GSD (100 cm)</i>	XY	0,47	Aprovado
		Z	0,65	

Fonte: Consórcio Águas de Pernambuco (2017).

APÊNDICES

APÊNDICE 1

Quadro 1 – Espécies amostradas, por família, em inventário florestal contínuo realizado no ano de 2014 na Área I, no município de Floresta, PE.

Família	Nome comum	Nome Científico
ÁREA I		
Anacardiaceae	Aroeira	<i>Myracrodruon urundeuva</i> Allemão
	Baraúna	<i>Schinopsis brasiliensis</i> Engl.
	Umbuzeiro	<i>Spondias tuberosa</i> Arruda
Apocynaceae	Pereiro	<i>Aspidosperma pyrifolium</i> Mart.
Burseraceae	Imburana de Cambão	<i>Commiphora leptophloeos</i> (Mart.) J.B.Gillett
Capparaceae	Feijão bravo	<i>Cynophalla flexuosa</i> (L.) J.Presl
Combretaceae	Sipaúba	<i>Combretum glaucocarpum</i> Mart.
Euphorbiaceae	Faveleira	<i>Cnidoscolus quercifolius</i> Pohl
	Maniçoba	<i>Manihot carthaginensis</i> subsp. <i>glaziovii</i> (Müll.Arg.) Allem
	Quebra faca	<i>Croton heliotropiifolius</i> Kunth
	Burra leiteira	<i>Sapium glandulosum</i> (L.) Morong
	Faveleira brava	<i>Cnidoscolus bahianus</i> (Ule) Pax & K.Hoffm.
	Pinhão bravo	<i>Jatropha mollissima</i> (Pohl) Baill.
	Icó	<i>Neocalyptocalyx longifolium</i> (Pohl) Baill.
Fabaceae	Catingueira	<i>Cenostigma bracteosum</i> (Tul.) Gagnon & G.P. Lewis
	Jurema de embira	<i>Mimosa ophthalmocentra</i> Mart. ex Benth.
	Angico	<i>Anadenanthera colubrina</i> var. <i>cebil</i> (Griseb.) Altschul
	Mororó	<i>Bauhinia cheilantha</i> (Bong.) Steud.
	Jurema preta	<i>Mimosa tenuiflora</i> (Willd.) Poir.
	Jurema branca	<i>Piptadenia stipulacea</i> (Benth.) Ducke
	Calycina	<i>Erythrostemon calycina</i> (Benth.) L.P.Queiroz
	Pau ferro	<i>Libidibia ferrea</i> (Mart. Tul.) L.P.Queiroz
	Pau besouro	<i>Senna macranthera</i> (DC. ex Collad.) H.S.Irwin & Barneby
Olacaceae	Ameixa	<i>Ximenia americana</i> L.

Quadro 2 – Espécies amostradas, por família, em inventário florestal contínuo realizado no ano de 2014 na Área II, no município de Floresta, PE.

Família	Nome comum	Nome Científico
ÁREA II		
Anacardiaceae	Aroeira	<i>Myracrodruon urundeuva</i> Allemão
	Baraúna	<i>Schinopsis brasiliensis</i> Engl.
Apocynaceae	Pereiro	<i>Aspidosperma pyriforme</i> Mart.
Boraginaceae	Moleque duro	<i>Cordia leucocephala</i> Moric.
Burseraceae	Imburana de Cambão	<i>Commiphora leptophloeos</i> (Mart.) J.B.Gillett
	Sipaúba	<i>Thiloa glaucocarpa</i> (Mart.) Eichl
Euphorbiaceae	Faveleira	<i>Cnidoscolus quercifolius</i> Pohl
	Faveleira brava	<i>Cnidoscolus bahianus</i> (Ule) Pax & L. Hoffm.
	Quebra faca	<i>Croton heliotropiifolius</i> Kunth
	Maniçoba	<i>Manihot carthaginensis</i> subsp. <i>glaziovii</i> (Müll.Arg.) Allen
	Marmeleiro	<i>Croton blanchetianus</i> Baill.
Fabaceae	Catingueira	<i>Cenostigma bracteosum</i> (Tul.) Gagnon & G.P. Lewis
	Jurema de embira	<i>Mimosa ophthalmocentra</i> Mart. ex Benth.
	Pinhão bravo	<i>Jatropha mollissima</i> (Pohl) Baill.
	Angico	<i>Anadenanthera colubrina</i> var. <i>cebil</i> (Griseb.) Altschul
	Mororó	<i>Bauhinia cheilantha</i> (Bong.) Steud.
	Jurema branca	<i>Piptadenia stipulacea</i> (Benth.) Ducke
	Jurema preta	<i>Mimosa tenuiflora</i> (Willd.) Poir.
	Quipembe	<i>Pityrocarpa moniliformis</i> (Benth.) Luckow & Jobson
	Pau besouro	<i>Senna macranthera</i> (DC. ex Collad.) H.S.Irwin & Barneby
Sapotaceae	Quixabeira brava	<i>Sideroxylon obtusifolium</i> (Roem. & Schult.) T.D. Penn.

APÊNDICE 2

Processamento da nuvem de pontos da Área I: Comandos do FUSION editados no Notepad++

```

:: A) Diretório
:: Atribuindo um diretório de saída dos produtos gerados pela rotina de processamento
set DIR=C:\FUSION_DADOS\DADOS_PROCESSADOS
cd %DIR%

:: B) Rotina de Processamento
:: Processamento I - Qualidade e homogeneização da nuvem de pontos e confecção do MDS.

:: Etapa 1) # Recorte das áreas de interesse (Área I, com um buffer de 50 metros no entorno da área):
:: Etapa 1) # Syntax = PolyClipData [switches] PolyFile OutputFile DataFile
PolyClipData C:\FUSION_DADOS\PARCELAS_A1\A1_buffer.shp C:\FUSION_DADOS\DADOS_LAS\mdeR1.las C:\FUSION_DADOS\DADOS_LAS\nuvem1.las

:: Etapa 2) # Relatório descritivo e análise da qualidade da nuvem.
:: Etapa 2) # Syntax = Catalog [switches] datafile [catalogfile]
mkdir 1_catalog
catalog /density:1,1,3 C:\FUSION_DADOS\DADOS_LAS\nuvemR1.las %DIR%\1_catalog\AREA1

:: Etapa 3) # Homogeneização da densidade de pontos:
:: Etapa 3) # Syntax = ThinData [switches] OutputFile Density CellSize DataFile
ThinData C:\FUSION_DADOS\DADOS_LAS\nuvem1H.las 1.2 1 C:\FUSION_DADOS\DADOS_LAS\nuvemR1.las

:: Etapa 4) # Confecção do Modelo Digital de Superfície (MDS) no formato .dtm e conversão do formato .dtm para o formato ascii raster:
:: Etapa 4) # Syntax = CanopyModel [switches] surfacefile cellsize xyunits zunits coordsys zone horzdatum vertdatum datafile1 datafile2...
:: Etapa 4) # Syntax = DTM2ASCII [switches] inputfile [outputfile] (o inputfile por ser omitido)
mkdir 2_mds
canopymodel %DIR%\2_mds\AREA1_mds.dtm 1 M M 1 24 0 0 C:\FUSION_DADOS\DADOS_LAS\nuvem1H.las
dtm2ascii %DIR%\2_mds\AREA1_mds.dtm

:: Etapa 5) # Conversão do Modelo Digital de Terreno (MDT):
:: Etapa 5) # XYZ2DTM [switches] surfacefile xyunits zunits coordsys zone horzdatum vertdatum datafile1 [datafile2...datafileN]
xyz2dtm %DIR%\mdt\AREA1_mdt.dtm M M 1 24 0 0 %DIR%\mdt\MDT_AI

:: Etapa 6) # Normalização da nuvem de pontos Lidar:
:: Etapa 6) # Syntax = ClipData [switches] InputSpecifier SampleFile [MinX MinY MaxX MaxY]

```

mkDir 3_LASheight

```
ClipData /dtm:%DIR%\mtd\AREA1_mdt.dtm /height /zmin:0 /zmax:50 C:\FUSION_DADOS\DADOS_LAS\nuvem1H.las %DIR%\3_LASheight\AREA1_normalizado.las
611624 9059098 612637 9059801
```

:: Etapa 7) # Confecção do Modelo Digital de Altura (MDA) no formato .dtm e conversão do formato .dtm para o formato ascii raster:

:: Etapa 7) # Syntax = CanopyModel [switches] surfacefile cellsize xyunits zunits coordsys zone horizdatum vertdatum datafile1 datafile2...

:: Etapa 7) # Syntax = DTM2ASCII [switches] inputfile [outputfile] (converte o arquivo no formato dtm em formato ascii raster)

mkDir 4_mda

```
canopymodel %DIR%\4_mda\AREA1_mda.dtm 1 M M 1 24 0 0 %DIR%\3_LASheight\AREA1_normalizado.las
```

```
dtm2ascii %DIR%\4_mda\AREA1_mda.dtm
```

:: Etapa 8) # Recorte da nuvem normalizada para as unidades amostrais de interesse (40 polígonos armazenados em arquivos de formato ESRI):

:: Etapa 8) # Syntax = PolyClipData [switches] PolyFile OutputFile DataFile (shape:nº, significa a coluna que contem o id das parcelas

mkDir 5_polyclipdata

```
PolyClipData /multifile /shape:1,* C:\FUSION_DADOS\PARCELAS_A1\Parcelas_A1.shp %DIR%\5_polyclipdata\AREA1.las
```

```
%DIR%\3_LASheight\AREA1_normalizado.las
```

:: Etapa 9) # Extração das métricas LiDAR:

:: Etapa 9) # Syntax = CloudMetrics [switches] InputDataSpecifier OutputFileName

mkDir 6_cloudmetrics

```
CloudMetrics /id /minht:1.30 /above:1.30 %DIR%\5_polyclipdata\*.las %DIR%\6_cloudmetrics\AREA1_metrics.csv
```

Obs. Os mesmos comandos e parâmetros foram utilizados para o processamento da nuvem de pontos da Área II, modificando apenas o banco de dados.

APÊNDICE 3

Tabela 1 – Correlação de Pearson entre as variáveis LiDAR e as variáveis respostas utilizadas na Área I

	V	BSA	hmin	hmax	hmed	hsd	hvar	hcv	hcurt	hDAM	hp01	hp05	hp10	hp20	hp25	hp30	hp40	hp50	hp60	hp70	hp75	hp80	hp90	hp95	hp99	Raz.RD	P1.3	Pmed	
V	1,00																												
BSA	0,88	1,00																											
hmin	-0,02	-0,03	1,00																										
hmax	0,61	0,55	-0,14	1,00																									
hmed	0,62	0,52	0,19	0,72	1,00																								
hsd	0,56	0,50	-0,20	0,90	0,74	1,00																							
hvar	0,52	0,49	-0,11	0,84	0,75	0,97	1,00																						
hcv	0,40	0,38	-0,38	0,80	0,41	0,88	0,82	1,00																					
hcurt	0,09	0,07	-0,16	0,35	-0,17	0,06	0,01	0,24	1,00																				
hDAM	0,54	0,50	-0,18	0,84	0,76	0,98	0,96	0,86	-0,09	1,00																			
hp01	0,13	0,05	0,94	-0,12	0,26	-0,20	-0,11	-0,43	-0,16	-0,19	1,00																		
hp05	0,26	0,18	0,79	0,00	0,46	-0,10	-0,02	-0,41	-0,19	-0,09	0,89	1,00																	
hp10	0,26	0,20	0,62	0,10	0,56	-0,06	-0,02	-0,41	-0,14	-0,06	0,72	0,87	1,00																
hp20	0,35	0,27	0,38	0,33	0,76	0,20	0,22	-0,17	-0,06	0,18	0,48	0,70	0,88	1,00															
hp25	0,39	0,28	0,38	0,35	0,79	0,23	0,24	-0,16	-0,10	0,22	0,48	0,70	0,87	0,98	1,00														
hp30	0,46	0,33	0,34	0,44	0,87	0,36	0,37	-0,03	-0,15	0,35	0,44	0,65	0,80	0,94	0,98	1,00													
hp40	0,54	0,39	0,28	0,46	0,90	0,44	0,43	0,07	-0,21	0,45	0,37	0,59	0,72	0,86	0,90	0,95	1,00												
hp50	0,55	0,43	0,21	0,56	0,95	0,58	0,58	0,22	-0,24	0,60	0,28	0,50	0,60	0,80	0,84	0,91	0,97	1,00											
hp60	0,56	0,45	0,16	0,61	0,97	0,67	0,66	0,33	-0,28	0,70	0,23	0,43	0,53	0,74	0,78	0,87	0,92	0,98	1,00										
hp70	0,60	0,50	0,09	0,67	0,97	0,73	0,71	0,40	-0,28	0,77	0,16	0,36	0,47	0,69	0,74	0,83	0,88	0,95	0,99	1,00									
hp75	0,60	0,53	0,05	0,72	0,95	0,83	0,85	0,52	-0,26	0,87	0,10	0,28	0,35	0,58	0,61	0,72	0,77	0,88	0,94	0,96	1,00								
hp80	0,57	0,53	0,06	0,73	0,93	0,86	0,88	0,57	-0,26	0,90	0,10	0,26	0,31	0,52	0,56	0,67	0,72	0,84	0,91	0,93	0,99	1,00							
hp90	0,60	0,54	0,01	0,82	0,92	0,93	0,92	0,69	-0,16	0,94	0,03	0,19	0,26	0,48	0,51	0,62	0,69	0,80	0,86	0,90	0,95	0,97	1,00						
hp95	0,61	0,57	-0,04	0,89	0,87	0,89	0,92	0,76	-0,04	0,94	-0,01	0,13	0,21	0,43	0,45	0,56	0,62	0,72	0,79	0,83	0,89	0,91	0,97	1,00					
hp99	0,60	0,55	-0,13	0,99	0,73	0,92	0,87	0,82	0,34	0,85	-0,10	0,02	0,10	0,33	0,34	0,44	0,47	0,56	0,61	0,66	0,73	0,74	0,84	0,91	1,00				
Raz.RD	-0,16	0,04	0,12	-0,20	-0,13	-0,21	-0,25	-0,17	-0,07	-0,20	0,00	-0,05	0,01	0,00	-0,03	-0,04	-0,05	-0,08	-0,10	-0,11	-0,16	-0,16	-0,16	-0,17	-0,21	1,00			
P1.3	0,37	0,53	-0,43	0,37	0,06	0,18	0,14	0,24	0,23	0,16	-0,35	-0,26	-0,08	-0,02	-0,03	-0,06	-0,07	-0,03	0,01	0,07	0,07	0,09	0,10	0,20	0,31	0,00	1,00		
Pmed	0,34	0,48	-0,41	0,20	0,08	0,05	0,02	0,03	0,05	0,06	-0,32	-0,21	0,00	0,06	0,06	0,03	0,05	0,08	0,09	0,12	0,09	0,08	0,04	0,10	0,14	0,04	0,93	1,00	

Tabela 2 – Correlação de Pearson entre as variáveis LiDAR e as variáveis respostas utilizadas na Área II

	V	BSA	V'	BSA'	hmin	hmax	hmed	hsd	hvar	hcv	hcurt	hDAM	hp01	hp05	hp10	hp20	hp25	hp30	hp40	hp50	hp60	hp70	hp75	hp80	hp90	hp95	hp99	Raz.RD	P1.30	Pmed	
V	1																														
BSA	0,83	1																													
V'	0,96	0,83	1																												
BSA'	0,81	0,98	0,86	1																											
hmin	-0,21	-0,41	-0,33	-0,48	1,0																										
hmax	0,48	0,44	0,49	0,47	-0,14	1,0																									
hmed	0,25	0,27	0,31	0,30	0,10	0,86	1,0																								
hsd	0,14	0,12	0,17	0,14	-0,01	0,80	0,74	1,0																							
hvar	0,13	0,11	0,15	0,14	-0,03	0,80	0,73	0,99	1,0																						
hcv	-0,01	-0,07	-0,02	-0,07	-0,08	0,37	0,17	0,78	0,77	1,0																					
hcurt	0,43	0,49	0,38	0,48	-0,33	0,33	0,07	-0,11	-0,13	-0,21	1,0																				
hDAM	0,11	0,07	0,15	0,11	0,00	0,73	0,71	0,97	0,96	0,75	-0,30	1,0																			
hp01	-0,03	-0,19	-0,14	-0,25	0,87	0,05	0,28	-0,05	-0,08	-0,28	-0,12	-0,06	1,0																		
hp05	0,14	0,05	0,13	-0,03	0,55	0,51	0,72	0,28	0,27	-0,21	0,09	0,24	0,76	1,0																	
hp10	0,20	0,28	0,27	0,28	0,25	0,59	0,8	0,33	0,31	-0,23	0,25	0,27	0,50	0,85	1,0																
hp20	0,24	0,31	0,32	0,33	0,11	0,64	0,87	0,40	0,38	-0,20	0,27	0,33	0,34	0,76	0,89	1,0															
hp25	0,26	0,34	0,34	0,36	0,08	0,74	0,92	0,48	0,46	-0,13	0,29	0,40	0,32	0,74	0,85	0,95	1,0														
hp30	0,25	0,31	0,25	0,34	0,09	0,77	0,93	0,51	0,49	-0,11	0,26	0,44	0,33	0,75	0,84	0,93	0,99	1,0													
hp40	0,24	0,28	0,24	0,30	0,08	0,79	0,95	0,56	0,55	-0,05	0,18	0,52	0,29	0,72	0,81	0,90	0,96	0,97	1,0												
hp50	0,20	0,23	0,20	0,25	0,06	0,82	0,97	0,71	0,70	0,16	0,04	0,71	0,23	0,63	0,72	0,81	0,88	0,90	0,94	1,0											
hp60	0,17	0,20	0,24	0,21	0,09	0,81	0,97	0,74	0,73	0,19	-0,05	0,75	0,22	0,63	0,71	0,78	0,83	0,86	0,92	0,99	1,0										
hp70	0,20	0,21	0,22	0,24	0,09	0,83	0,97	0,78	0,77	0,24	-0,09	0,80	0,22	0,62	0,69	0,78	0,83	0,85	0,90	0,97	0,98	1,0									
hp75	0,20	0,22	0,24	0,26	0,07	0,82	0,97	0,79	0,79	0,27	-0,10	0,81	0,20	0,61	0,68	0,77	0,83	0,84	0,88	0,94	0,96	0,99	1,0								
hp80	0,22	0,24	0,27	0,28	0,06	0,82	0,95	0,81	0,80	0,30	-0,14	0,83	0,17	0,58	0,67	0,75	0,79	0,81	0,86	0,92	0,95	0,98	0,99	1,0							
hp90	0,27	0,27	0,32	0,32	0,04	0,89	0,95	0,86	0,86	0,37	0,00	0,84	0,15	0,61	0,67	0,74	0,8	0,81	0,84	0,89	0,91	0,94	0,95	0,96	1,0						
hp95	0,30	0,32	0,35	0,36	0,00	0,92	0,93	0,87	0,86	0,41	0,15	0,81	0,12	0,59	0,68	0,73	0,79	0,80	0,82	0,88	0,87	0,90	0,91	0,91	0,97	1,0					
hp99	0,41	0,40	0,43	0,43	-0,10	0,98	0,88	0,85	0,85	0,42	0,28	0,78	0,04	0,53	0,61	0,67	0,75	0,76	0,79	0,84	0,83	0,85	0,85	0,86	0,93	0,96	1,0				
Raz.RD	-0,23	-0,03	-0,19	-0,04	-0,06	-0,01	0,42	0,03	0,01	-0,34	-0,3	0,11	0,03	0,21	0,41	0,56	0,50	0,47	0,50	0,47	0,48	0,45	0,45	0,43	0,27	0,19	0,04	1,0			
P1.30	0,68	0,72	0,73	0,77	-0,36	0,62	0,47	0,21	0,22	-0,15	0,37	0,22	-0,11	0,25	0,41	0,43	0,45	0,46	0,46	0,43	0,43	0,44	0,43	0,46	0,47	0,46	0,56	0,03	1,0		
Pmed	0,67	0,71	0,72	0,76	-0,38	0,62	0,48	0,2	0,22	-0,17	0,37	0,22	-0,11	0,24	0,4	0,42	0,46	0,48	0,49	0,46	0,46	0,46	0,44	0,46	0,46	0,45	0,55	0,07	0,99	1,0	

³Variáveis transformadas.

APÊNDICE 4

Tabela 1 – Estatística descritiva das variáveis LiDAR e das variáveis respostas utilizadas na Área I

Variáveis	Estatística Descritiva - Área I				
	Mínimo	Máximo	Média	Desvio padrão	Coefficiente de variação
Volume	1,67	21,19	10,14	3,71	36,62
BSA	2,20	24,99	13,66	4,21	30,83
h _{max}	2,94	8,40	4,84	1,19	24,59
h _{sd}	0,38	1,97	0,79	0,30	37,97
h _{curt}	1,64	10,40	3,09	1,53	49,51
h _{p01}	1,32	2,32	1,52	0,19	12,50
h _{p05}	1,44	2,59	1,71	0,24	14,04
h _{p10}	1,52	2,60	1,90	0,25	13,16
h _{p25}	1,67	3,23	2,30	0,33	14,35
h _{p50}	1,92	4,10	2,79	0,43	15,41
h _{p80}	2,29	6,33	3,48	0,69	19,83
P _{1.3}	8,70	62,26	33,82	12,29	36,35
Raz _{.RD}	0,24	0,67	0,43	0,09	20,93

Tabela 2 – Estatística descritiva das variáveis LiDAR e das variáveis respostas utilizadas na Área II

Variáveis	Estatística Descritiva - Área II				
	Mínimo	Máximo	Média	Desvio padrão	Coef. de variação
Volume	0,32	19,73	5,57	3,46	65,35
BSA	0,47	24,52	7,78	4,83	64,14
Volume'	0,60	3,88	2,08	0,62	29,81
BSA'	0,77	3,10	1,97	0,47	23,86
h _{min}	1,33	2,11	1,53	0,17	11,11
h _{max}	3,34	6,80	4,71	0,79	16,77
h _{sd}	0,45	1,16	0,76	0,16	21,05
h _{cv}	0,17	0,36	0,25	0,04	16,00
h _{curt}	1,30	3,60	2,53	0,54	21,34
h _{p01}	1,40	2,27	1,63	0,18	11,04
h _{p05}	1,59	2,59	1,86	0,20	10,75
h _{p10}	1,70	2,65	2,06	0,24	11,65
h _{p25}	1,89	3,32	2,47	0,35	14,17
h _{p50}	2,20	3,89	2,97	0,42	14,09
h _{p90}	2,88	5,72	3,94	0,61	15,48
P _{1.3}	6,67	75,24	44,27	21,25	48,00
Raz _{.RD}	0,34	0,58	0,46	0,06	13,04

'Variáveis transformadas.

APÊNDICE 5

Tabela 1 – Correlação de Pearson entre as variáveis do satélite Landsat 8 e as variáveis respostas utilizadas na Área I

	V	BSA	B2	B3	B4	B5	B6	B7	SAVI	NDVI	EVI2	SR
V	1,00											
BSA	0,88	1,00										
B2	-0,17	-0,22	1,00									
B3	-0,34	-0,37	0,44	1,00								
B4	-0,37	-0,49	0,62	0,78	1,00							
B5	0,68	0,78	-0,19	-0,30	-0,31	1,00						
B6	-0,41	-0,47	0,52	0,62	0,45	-0,26	1,00					
B7	-0,41	-0,41	0,55	0,64	0,31	-0,31	0,98	1,00				
SAVI	0,33	0,37	-0,44	-0,40	0,68	0,37	-0,43	-0,57	1,00			
NDVI	0,70	0,74	-0,30	-0,56	0,62	0,68	-0,58	-0,60	0,52	1,00		
EVI2	0,32	0,36	-0,43	-0,38	0,66	0,37	-0,40	-0,55	1,00	0,50	1,00	
SR	0,30	0,21	-0,64	-0,54	0,89	0,33	-0,72	-0,82	0,88	0,55	0,87	1,00

Tabela 2 – Correlação de Pearson entre as variáveis do satélite ResourceSat 2 e as variáveis respostas utilizadas na Área I

	V	BSA	B2	B3	B4	B5	SAVI	NDVI	EVI2	SR
V	1,00									
BSA	0,88	1,00								
B2	-0,49	-0,45	1,00							
B3	-0,38	-0,34	0,17	1,00						
B4	0,47	0,39	-0,88	-0,65	1,00					
B5	0,43	0,40	-0,90	-0,05	0,93	1,00				
SAVI	0,69	0,79	-0,24	0,51	0,21	0,18	1,00			
NDVI	0,72	0,81	-0,30	0,49	0,74	0,11	0,89	1,00		
EVI2	0,40	0,36	0,80	-0,10	0,91	0,47	-0,20	-0,18	1,00	
SR	-0,22	-0,16	0,38	-0,21	0,67	0,37	-0,13	-0,02	0,83	1,00

Tabela 3 – Correlação de Pearson entre as variáveis do satélite RapidEye e as variáveis respostas utilizadas na Área I

	V	BSA	B1	B2	B3	B4	B5	SAVI	NDVI	EVI2	SR
V	1,00										
BSA	0,88	1,00									
B1	-0,12	-0,12	1,00								
B2	-0,09	-0,11	0,87	1,00							
B3	-0,55	-0,56	0,69	0,71	1,00						
B4	-0,25	-0,27	0,79	0,92	0,76	1,00					
B5	0,40	0,44	0,24	0,29	-0,03	0,29	1,00				
SAVI	0,63	0,68	0,03	0,07	-0,33	-0,10	0,32	1,00			
NDVI	0,68	0,73	-0,07	-0,01	-0,44	-0,17	0,32	0,93	1,00		
EVI2	0,35	0,43	-0,19	0,05	0,40	-0,01	0,16	0,30	0,26	1,00	
SR	-0,25	-0,20	-0,77	-0,59	-0,67	-0,60	-0,06	0,08	0,15	0,51	1,00

Tabela 4 – Correlação de Pearson entre as variáveis do satélite Landsat 8 e as variáveis respostas utilizadas na Área II

	V	BSA	B2	B3	B4	B5	B6	B7	SAVI	NDVI	EVI2	SR
V	1,00											
BSA	0,83	1,00										
B2	0,14	0,07	1,00									
B3	-0,16	-0,40	-0,17	1,00								
B4	-0,28	-0,44	-0,24	0,95	1,00							
B5	0,07	-0,18	0,08	0,78	-0,62	1,00						
B6	-0,32	-0,50	-0,28	0,91	0,96	0,52	1,00					
B7	-0,34	-0,51	-0,28	0,89	0,96	0,47	0,99	1,00				
SAVI	0,42	0,45	0,37	-0,50	-0,70	0,12	-0,75	-0,80	1,00			
NDVI	0,35	0,52	0,29	-0,85	-0,96	-0,39	-0,96	-0,98	0,87	1,00		
EVI2	0,42	0,44	0,37	-0,46	-0,67	0,16	-0,72	-0,77	1,00	0,84	1,00	
SR	0,33	0,50	0,22	-0,85	-0,94	-0,40	-0,94	-0,96	0,84	0,99	0,82	1,00

Tabela 5 – Correlação de Pearson entre as variáveis do satélite ResourceSat 2 e as variáveis respostas utilizadas na Área II

	V	BSA	B2	B3	B4	B5	SAVI	NDVI	EVI2	SR
V	1,00									
BSA	0,83	1,00								
B2	0,16	-0,04	1,00							
B3	-0,33	-0,45	0,38	1,00						
B4	0,39	0,20	0,95	-0,73	1,00					
B5	0,44	0,68	-0,60	-0,58	0,60	1,00				
SAVI	-0,59	-0,67	-0,24	0,87	0,30	0,49	1,00			
NDVI	0,65	0,69	-0,30	0,73	0,32	0,53	0,75	1,00		
EVI2	-0,06	-0,11	-0,20	-0,28	0,16	-0,18	-0,02	0,14	1,00	
SR	0,49	0,37	-0,02	0,56	0,82	0,46	0,21	0,28	0,51	1,00

Tabela 6 – Correlação de Pearson entre as variáveis do satélite RapidEye e as variáveis respostas utilizadas na Área II

	V	BSA	B1	B2	B3	B4	B5	SAVI	NDVI	EVI2	SR
V	1,00										
BSA	0,83	1,00									
B1	-0,39	-0,55	1,00								
B2	-0,27	-0,52	0,87	1,00							
B3	-0,38	-0,49	0,85	0,96	1,00						
B4	-0,10	-0,40	0,67	0,88	0,89	1,00					
B5	0,22	0,14	0,28	0,61	-0,56	0,84	1,00				
SAVI	0,54	0,36	-0,51	-0,23	-0,32	0,01	0,55	1,00			
NDVI	0,61	0,64	-0,81	-0,69	-0,79	-0,45	0,06	0,79	1,00		
EVI2	0,54	0,35	-0,49	-0,21	-0,30	0,03	0,57	1,00	0,78	1,00	
SR	0,63	0,66	-0,78	-0,68	-0,77	-0,43	0,07	0,78	1,00	0,77	1,00

APÊNDICE 6

Tabela 1 – Estatística descritiva das variáveis oriundas do satélite Landsat 8 utilizadas na Área I

Variáveis	Estatística Descritiva - Area I				
	Mínimo	Máximo	Média	Desvio Padrão	Coefficiente de Variação
B2	0,0004	0,0188	0,0105	0,0040	38,0369
B3	0,0004	0,0149	0,0052	0,0038	73,6863
B4	0,0224	0,0709	0,0402	0,0118	29,3396
B5	0,1422	0,1891	0,1698	0,0115	6,7668
B6	0,1989	0,2956	0,2479	0,0233	9,4026
SAVI	0,2262	0,3444	0,2801	0,0308	10,9825
NDVI	0,3112	0,7518	0,6118	0,1036	16,9285
SR	2,7120	7,5250	4,6400	1,2697	27,3641

Tabela 2 – Estatística descritiva das variáveis oriundas do satélite ResourceSat 2 utilizadas na Área I

Variáveis	Estatística Descritiva - Area I				
	Mínimo	Máximo	Média	Desvio Padrão	Coefficiente de Variação
B2	0,0852	0,1290	0,1110	0,0088	7,8820
B3	0,0993	0,1508	0,1250	0,0143	11,4400
SAVI	0,5609	0,7942	0,6698	0,0433	6,4613
NDVI	0,5579	0,7884	0,6902	0,0359	5,2049
SR	4,6880	7,6870	5,9730	0,5945	9,9538
EVI2	0,2094	0,4877	0,3736	0,0221	5,9154

Tabela 3 – Estatística descritiva das variáveis oriundas do satélite RapidEye utilizadas na Área I

Variáveis	Estatística Descritiva - Area I				
	Mínimo	Máximo	Média	Desvio Padrão	Coefficiente de Variação
B1	0,0214	0,0561	0,0312	0,0077	24,7720
B2	0,0431	0,1042	0,0616	0,0110	17,8361
B3	0,0739	0,1542	0,0961	0,0155	16,1603
B4	0,1009	0,1770	0,1258	0,0158	12,5560
B5	0,1398	0,1978	0,1656	0,0157	9,4594
SAVI	0,0503	0,3327	0,0976	0,0737	75,5690
NDVI	0,2948	0,6480	0,2948	0,1010	34,2527
SR	1,4740	2,1400	1,7470	0,1550	8,8692
EVI2	0,0448	0,0912	0,0703	0,0111	15,7503

Tabela 4 – Estatística descritiva das variáveis oriundas do satélite Landsat 8 utilizadas na Área II

Variáveis	Estatística Descritiva - Area II				
	Mínimo	Máximo	Média	Desvio Padrão	Coefficiente de Variação
B2	0,0001	0,0219	0,0115	0,0070	60,3298
B3	0,0023	0,0440	0,0232	0,0108	46,6944
B4	0,0430	0,1097	0,0746	0,0189	25,3504
B5	0,1953	0,2738	0,2339	0,0204	8,7213
B6	0,2591	0,3927	0,3287	0,0367	11,1624
B7	0,1822	0,3186	0,2421	0,0376	15,5505
SAVI	0,2362	0,3728	0,2961	0,0326	11,0242
NDVI	0,3800	0,6582	0,5930	0,0785	13,2378
SR	2,9260	4,8520	3,9110	0,7470	19,1000
EVI2	0,2230	0,3628	0,2826	0,0333	11,7921

Tabela 5 – Estatística descritiva das variáveis oriundas do satélite ResourceSat 2 utilizadas na Área II

Variáveis	Estatística Descritiva - Area II				
	Mínimo	Máximo	Média	Desvio Padrão	Coefficiente de Variação
B3	0,1153	0,2055	0,1509	0,0237	15,7130
B4	0,3017	0,4069	0,3447	0,0286	8,2859
B5	0,8056	1,0000	0,9121	0,0685	7,5083
SAVI	0,5054	0,7949	0,6945	0,0735	10,5876
NDVI	0,5319	0,8791	0,7215	0,0527	7,3010
SR	4,8660	7,1540	6,2850	0,5826	9,2692
EVI2	0,1966	0,4053	0,3338	0,0131	3,9245

Tabela 6 – Estatística descritiva das variáveis oriundas do satélite RapidEye utilizadas na Área II

Variáveis	Estatística Descritiva - Area II				
	Mínimo	Máximo	Média	Desvio Padrão	Coefficiente de Variação
B1	0,0134	0,0514	0,0308	0,0092	29,9385
B2	0,0460	0,1025	0,0708	0,0122	17,2505
B3	0,0767	0,1593	0,1124	0,0184	16,3276
B4	0,1215	0,1945	0,1554	0,0162	10,4426
B5	0,1877	0,2678	0,2274	0,0229	10,0662
SAVI	0,0904	0,1633	0,1219	0,0193	15,8679
NDVI	0,2525	0,5918	0,3406	0,0593	17,4067
SR	1,6750	2,7870	2,0580	0,2855	13,8745
EVI2	0,0819	0,1524	0,1122	0,0186	16,5364