

CINTHIA PEREIRA DE OLIVEIRA

**BIOMASSA E CARBONO POR MEIO DE INVENTÁRIO CONVENCIONAL E
LiDAR EM FLORESTA SECA NO NORDESTE DO BRASIL**

RECIFE
Pernambuco - Brasil
Fevereiro 2019

CINTHIA PEREIRA DE OLIVEIRA

**BIOMASSA E CARBONO POR MEIO DE INVENTÁRIO CONVENCIONAL E
LiDAR EM FLORESTA SECA NO NORDESTE DO BRASIL**

Tese apresentada ao Programa de Pós-Graduação em Ciências Florestais da Universidade Federal Rural de Pernambuco como requisito para a obtenção do título de Doutor em Ciências Florestais, Linha de Pesquisa Biometria e Manejo Florestal

Orientador:

Prof. Dr. Rinaldo Luiz Caraciolo Ferreira

Co-orientadores:

Prof. Ph.D. José Antônio Aleixo da Silva

Prof. Dr. Emanuel Araújo Silva

RECIFE
Pernambuco - Brasil
Fevereiro 2019

FICHA CATALOGRAFICA

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

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

O48b Oliveira, Cinthia Pereira de
Biomassa e carbono por meio de inventário convencional e LiDAR em floresta
seca no Nordeste do Brasil/ Cinthia Pereira de Oliveira. –
2019.

105 f. : il.

Orientador: Rinaldo Luiz Caraciolo Ferreira.

Coorientadores: José Antônio Aleixo da Silva, Emanuel Araújo
Silva.

Tese (Doutorado) – Universidade Federal Rural de Pernambuco,
Programa de Pós-Graduação em Ciências Florestais, Recife, BR-PE,
2019.

Inclui referências e apêndice(s).

1. Modelos—Sensoriamento remoto 2. Caatinga 3. I. Ferreira, Rinaldo Luiz
Caraciolo, orient. II. Silva, José Antônio Aleixo da, coorient. III. Silva, Emanuel
Araújo, coorient. IV. Título

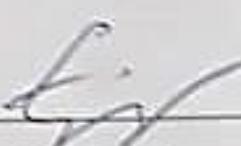
CDD 634.9

CINTHIA PEREIRA DE OLIVEIRA

**BIOMASSA E CARBONO POR MEIO DE INVENTÁRIO CONVENCIONAL E
LIDAR EM FLORESTA SECA NO NORDESTE DO BRASIL**

APROVADA em 26/02/2019

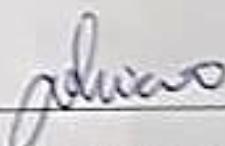
Banca Examinadora



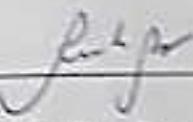
Prof. Dr. Eric Bastos Gorgens
Departamento de Engenharia Florestal/UFVJM



Prof. Dr. Gabriel Paes Marangon
Universidade Federal do Pampa/Campus São Gabriel



Profa. Dra. Josicléda Domiciano Galvino
Departamento de Ciências Geográficas/ UFPE



Profa. Dra. Rute Berger
Departamento de Ciência Florestal/UFRPE

Orientador:



Prof. Dr. Rinaldo Luiz Caraciolo Ferreira
Departamento de Ciência Florestal/UFRPE

**RECIFE-PE
Fevereiro 2019**

À minha família, em especial aos meus pais e irmãos por acreditarem em mim. Aos amigos que conquistei e aos que mantive ao longo desta jornada. Ao meu noivo Robson. E, por último e não menos importante, à minha gata Amora.

Dedico.

AGRADECIMENTOS

Primeiramente a DEUS, por estar comigo em todos os momentos nas escolhas da minha vida, me guiando e protegendo.

À toda minha família pelo apoio, em especial ao meus pais Emilia Zenobia Pereira de Oliveira e Antonio José Viana de Oliveira por acredarem em mim e no meu potencial, meus irmãos Valéria (Leros) e Leandro (Leco), meu cunhado Rogerio, minha avó Alice e as minhas tias Elvira e Elciane Rose por sempre estarem presentes.

À Universidade Federal Rural de Pernambuco – UFRPE, em especial ao Programa de Pós-graduação em Ciências Florestais – PPGCF, que por meio desta oportunidade do doutorado expandi meus conhecimentos e fiz amizades para toda vida.

À Fundação de Amparo a Ciência e Tecnologia de Pernambuco -FACEPE pela concessão da bolsa que fez possível me dedicar integralmente aos estudos e pesquisa do doutorado.

Ao meu Orientador Professor Dr. Rinaldo Luiz Caraciolo Ferreira pela sua orientação e amizade, que fizeram possível esta jornada de aprendizado e expansão tanto da vida adulta como profissional, através de retidão, ética e amizade sincera.

Aos meus Co-orientadores Professor Ph.D. José Antônio Aleixo da Silva e Professor Dr. Emanuel Araujo Silva por todos os ensinamentos.

Ao meu noivo Robson Lima pelo amor, paciência, dedicação e ensinamentos e por estar comigo neste momento.

Aos amigos e irmãos para vida do LABMFN que nunca deixaram eu esmorecer: Cybelle, Nattan, Anderson Mago e Iran. Amo vocês!!!

As minhas Amigas Livi e Aldine por todas as ligações, palavras amigas na hora que a saudade de casa apertou e tinha que segurar.

À cidade de Recife por me apresentar pessoas que ficarão em meu coração: Bel, Jaque (Mãe do Iran), Yara, Dona Tetê, Mayara, Josias e Nathan (Piaui).

A todos que de alguma forma me ajudaram a chegar até aqui e fazem parte desta conquista.

MEU Muito obrigada!!!

*“Desejo que você seja um grande sonhador
E que, entre seus sonhos, sonhe em ter
Um caso de amor com sua qualidade de vida.
Caso o contrário, terá uma dívida enorme com
Sua saúde emocional e com uma mente livre.
Saiba que os melhores seres humanos já traíram:
Traíram seus fins de semanas, seu sono, seu descanso.
Traíram o tempo com as pessoas que mais amam
Desacelere!”*

(Augusto Cury, 2013)

LISTA DE TABELAS

Tabela 1 – Características dendrométricas de espécies arbustivo-arbóreas usadas para desenvolver equações de biomassa local em floresta tropical seca, no semiárido pernambucano, Brasil.....	48
Tabela 2 – Modelos alométricos testados para estimativa de biomassa acima do solo em floresta tropical seca do semiárido pernambucano, Brasil	49
Tabela 3 – Equações alométricas genéricas de abrangência local e pantropical usadas para estimar a biomassa (Kg) acima do solo em floresta tropical seca com base no diâmetro (Db, cm), na altura (Ht, m) e na densidade básica da madeira (WD, gcm ³).....	50
Tabela 4 – Estimativas de parâmetros e índices de adequação dos modelos alométricos para previsão de biomassa em Floresta Tropical Seca, Nordeste do Brasil.....	52
Tabela 5 – Precisão e vieses para previsão de biomassa a partir de modelos pantropicais para floresta tropical seca, no Nordeste do Brasil.	54
Tabela 1 – Valores médios de teor de carbono do compartimento fuste de oito espécies avaliadas por Dalla Lana et al. (2019).	72
Tabela 2 – Valores descritivos (média e desvio padrão) das variáveis dendrométricas e número de indivíduos e fustes totais amostrados nas parcelas permanentes das áreas de estudo (2014).	72
Tabela 3 – Detalhes de aquisição dos dados LiDAR para o estado de Pernambuco em 2014.	73
Tabela 4 – Lista das métricas LiDAR avaliadas no estudo, obtidas a partir de pontos acima de 1,30 do solo por meio da ferramenta <i>cloudmetrics</i> do software FUSION v. 3.8	74
Tabela 5 – Cargas de componentes, valores próprios e porcentagem de variação dos componentes principais (PC) para as métricas LiDAR da área da Transposição.	79
Tabela 6 – Cargas de componentes, valores próprios e porcentagem de variação dos componentes principais (PC) para as métricas LiDAR da área do Correntão.	79
Tabela 7 – Equações lineares múltiplas ajustadas para a estimativa de biomassa, obtidas pelos dados LiDAR, para duas áreas de Caatinga, em Floresta, PE.....	81
Tabela 8 – Equações lineares múltiplas ajustadas para a estimativa de carbono, obtidas pelos dados LiDAR, para duas áreas de Caatinga, em Floresta, PE.....	82

LISTA DE FIGURAS

Figura 1 – Mapa de floresta tropical seca. Fonte: Miles et al. (2006)	18
Figura 2 – Tecnologia LiDAR em funcionamento. Fonte: Directions Magazine (2014).	24
Figura 3 – Representação de sistema LiDAR em uma aeronave tripulada. Fonte: Fancher (2012).....	25
Figura 4 – Representação dos retornos de pulso laser na vegetação. Fonte: Adaptado de Humboldt State University (2017).....	27
Figura 5 – Representação da nuvem de pontos LIDAR dos dados obtidos em área do presente estudo.	28
Figura 6 – Representação de Modelo Digital de Superfície obtido em área do presente estudo.	29
Figura 7 – Representação de Modelo Digital de Terreno obtido em área do presente estudo. 30	
Figura 8 – Representação dos modelos derivados do modelo digital de elevação (MDE). A) modelo digital desuperfície (MDS); B) modelo digital de terreno (MDT) e C) modelo digital de altura copa (CHM). Fonte: SILVA (2013).	31
Figura 1 - Recobrimento e delimitação da área de estudo (A, B e D) e foto do perfil em Floresta (C) submetida ao manejo florestal, no sertão de Pernambuco, Brasil.	47
Figura 2 – Dispersão dos resíduos percentuais para a equação de Schumacher-Hall desenvolvida para previsão de biomassa em floresta tropical seca, no Nordeste do Brasil....	53
Figura 3 – Previsão de biomassa a partir das equações desenvolvidas para o local (a) e a partir de outras equações locais e pantropicais (b); e diferença percentual (bias) das predições de biomassa em nível da árvore por classe de diâmetro para as equações locais (c) e de outras equações locais e pantropicais (d).	54
Figura 4 – Contrastess de médias de predições de AGB entre as melhores equações locais desenvolvidas e equações locais de outras regiões e pantropicais analisadas. Nota: As equações em vermelho indicam que o contraste entre as médias de AGB difere de zero de acordo com o teste Tukey a 95% de probabilidade; AGB = biomassa mensurada em campo (testemunha).	56
Figura 1 – Recobrimento da área de estudo (A, B e D) e foto do perfil em Floresta (C), no sertão de Pernambuco, Brasil.	69
Figura 2 – Procedimento de amostragem utilizado nas duas áreas inventariadas no município de Floresta, Pernambuco	70
Figura 34 – Distribuição da temperatura do ar e da precipitação, ao longo do ano de 2014, da área de estudo da estação meteorológica de Floresta. Fonte: Adaptado de Agritempo (2018).	71
Figura 4 – Fluxograma da metodologia adotada para ajuste de equações de biomassa e predição de carbono com LiDAR de uma área de floresta seca, Floresta-PE.....	78
Figura 5 – Box-plot para biomassa acima do solo e carbono dos estoques estimados por meio de inventário e tecnologia LiDAR nas áreas da Transposição e Correntão. As caixas representam os percentis 25 e 75; as margens representam os percentis 10 e 90. A linha representa a mediana.....	84

OLIVEIRA, CINTHIA PEREIRA DE. Biomassa e carbono por meio de inventário convencional e LiDAR em floresta seca no Nordeste do Brasil. 2019. Orientador: Rinaldo Luiz Caraciolo Ferreira. Coorientadores: José Antônio Aleixo da Silva e Emanuel Araújo Silva.

RESUMO

Nos últimos anos, com a crescente preocupação ambiental quanto às mudanças climáticas, existe a procura por alternativas eficientes em métodos indiretos para estudos da quantificação da biomassa e do estoque de carbono florestal. Este trabalho teve como objetivo obter estimativas de biomassa e carbono por meio de dados advindos de inventário florestal convencional e tecnologia LiDAR em uma floresta seca. No primeiro capítulo, os dados foram coletados a partir de 507 árvores distribuídas entre 14 espécies e 12 gêneros em uma área submetida ao manejo florestal, localizada no município de Floresta, no estado de Pernambuco, com vegetação predominantemente de Caatinga, caracterizada por uma vegetação arbustivo–arbórea. De cada indivíduo, foram mensurados o peso verde acima do solo (fuste e galhos), alturas total e comercial e diâmetro da base (0,30 cm do nível do solo), assim como valores de densidade da madeira, visando o ajuste e a validação de três modelos alométricos de regressão simples (o diâmetro da base como variável explicativa) e cinco de regressão múltipla (variáveis explicativas: o Db, altura total e densidade da madeira). Duas equações locais selecionadas foram comparadas com equações genéricas pantropicais e aplicadas às árvores amostra deste estudo. As previsões de biomassa foram realizadas considerando os dados do inventário de árvores vivas em duas áreas com diferentes históricos de uso, uma com histórico de perturbação maior (correntão) e outra com menos perturbação (transposição). Entre os modelos de biomassa testados, logaritmos de Schumacher-Hall e Chave – Modelo I apresentaram melhor desempenho. Nos modelos pantropicais, houve melhora significativa quando as variáveis altura e densidade foram incluídas; os maiores erros de previsão foram gerados pelas equações de simples entradas locais e pantropicais. No segundo capítulo, utilizamos dados de inventário florestal convencional de duas áreas juntamente com dados do sobrevoo LiDAR, sendo geradas estimativas locais de biomassa a partir de uma equação local desenvolvida e os teores de carbono obtidos de espécies locais. Com dados da tecnologia LiDAR, extraíram-se as métricas da sua nuvem de pontos e foram utilizadas como variável independente. Para a construção dos modelos alométricos de biomassa e carbono por hectare, abordaram-se três tipos de modelos para a análise de dados: Regressão linear múltipla com Componentes Principais – PCA, Regressão linear múltipla e Regressão linear múltipla com *Stepwise*, as equações geradas foram analisadas por meio de comparações de critérios estatísticos. Após a seleção da melhor equação para biomassa e para carbono, geraram-se as estimativas de carbono por área avaliando a nível de parcela. O modelo tanto de TAGB quanto o de TAGC de melhor ajuste foi o de Regressão linear múltipla com *Stepwise*, concluindo, então, que os dados LiDAR podem ser usados para a estimativa de biomassa e carbono total em floresta tropical seca, comprovado por um ajuste considerado nos modelos empregados, havendo uma boa correlação entre as métricas do LiDAR.

Palavras-chave: Modelos, sensoriamento remoto, caatinga.

OLIVEIRA, CINTHIA PEREIRA DE. Biomass and carbon by means of conventional inventory and LiDAR in dry forest in Northeast Brazil. 2019. Advisor: Rinaldo Luiz Caraciolo Ferreira. Co-supervisors: José Antônio Aleixo da Silva and Emanuel Araújo Silva.

ABSTRACT

With the growing environmental concern about climate change in recent years, there has been more demand for efficient alternatives using indirect methods for studies of biomass quantification and forest carbon stock. This work aimed to obtain estimates of biomass and carbon by means of data from conventional forest inventory and LiDAR technology in a dry forest. In the first segment, data were collected from 507 trees distributed among 14 species and 12 genera in an area under forest management with predominantly Caatinga vegetation and characterized by shrub vegetation, located in the municipality of Floresta, in the state of Pernambuco. The green weight above the soil (stem and branches), total and commercial heights and base diameter (0.30 cm of the soil level) were measured for each individual, as well as values of wood density, aiming to adjust and validate three allometric simple regression models (the base diameter as an explanatory variable) and five multiple regression models (explanatory variables: Db, total height and wood density). Two selected local equations were compared with generic pantropical equations and applied to the sample trees of this study. Biomass predictions were performed considering the inventory data of live trees in two areas with different usage histories; one with a history of major disturbance (correntão) and one with less disturbance (transposition). Among the biomass models tested, the Schumacher-Hall logarithms and the Chave-Model I presented better performance. There was a significant improvement in the pantropical models when height and density variables were included; the largest prediction errors were generated by equations of simple local and pantropical inputs. In the second segment, we used conventional forest inventory data from two areas together with LiDAR overfly data, generating local biomass estimates from a developed local equation and the carbon contents obtained from local species. With the data from LiDAR technology, the metrics were extracted from its cloud of points and were used as the independent variable. Next, three types of models were analyzed for data analysis for constructing the allometric models of biomass and carbon per hectare: Multiple Linear Regression with Major Components - PCA, Multiple Linear Regression and Multiple Linear Regression with Stepwise. The generated equations were analyzed by comparing statistical criteria. After selection of the best biomass and carbon equation, the carbon estimates were calculated by area evaluated at the plot level. Both the TAGB and TAGC models of best fit was the Multiple Linear Regression with Stepwise, therefore concluding that the LiDAR data can be used for estimating the biomass and total carbon in a dry tropical forest, as proven by an adjustment considered in the employed models with good correlation between the LiDAR metrics.

Keywords: Models, remote sensing, caatinga.

SUMÁRIO

LISTA DE TABELAS	7
LISTA DE FIGURAS	8
RESUMO	9
1 INTRODUÇÃO GERAL	13
2 REVISÃO DE LITERATURA.....	17
2.1 FLORESTAS TROPICAIS SECAS: DEFINIÇÕES.....	17
2.1.1 CONTEXTO HISTÓRICO E ATUAL	18
2.2 ESTIMATIVAS DE CARBONO E BIOMASSA EM FLORESTA TROPICAL SECA .	19
2.3 SENSORIAMENTO REMOTO – TECNOLOGIA LIDAR.....	23
2.3.1 PRINCÍPIOS.....	23
2.3.2 PULSOS DE LUZ LASER.....	25
2.3.3 DADOS LIDAR.....	26
2.3.4 PÓS-PROCESSAMENTO DE DADOS LIDAR	27
2.3.5 PRODUTOS DO LIDAR	27
2.3.5.1 NUVEM DE PONTOS.....	27
2.3.5.2 MODELOS DIGITAIS DE ELEVAÇÃO (MDE).....	28
□ MODELOS DIGITAIS DE SUPERFÍCIE (MDS).....	28
□ MODELOS DIGITAIS DE TERRENOS (MDT)	29
□ MODELO DIGITAL DAS ALTURAS DAS COPAS (<i>CANOPY HIEGHT MODELS – CHM</i>)	30
2.3.5.3 MÉTRICAS	31
2.3.6 ACURÁCIA DOS DADOS.....	32
REFERÊNCIAS	33
CAPÍTULO 1	44
ESTIMATIVA DE BIOMASSA EM FLORESTA TROPICAL SECA: UMA ABORDAGEM SOBRE EQUAÇÕES GENÉRICAS	44
1 INTRODUÇÃO	44
2 MATERIAL E MÉTODOS.....	46
2.1 ÁREA DE ESTUDO E DADOS COLETADOS	46
2.2 AJUSTE DAS EQUAÇÕES ALOMÉTRICAS	48
2.3 PREDIÇÕES ALOMÉTRICAS	50

3 RESULTADOS E DISCUSSÃO.....	51
3.1 EQUAÇÃO DE BIOMASSA LOCAL	51
3.2 PREDIÇÕES ALOMÉTRICAS POR EQUAÇÕES GENÉRICAS LOCAIS E PANTROPICAIS	53
4 CONCLUSÕES	58
REFERÊNCIAS	59
CAPÍTULO 2	66
MODELAGEM E ESPACIALIZAÇÃO DE BIOMASSA E ESTOQUE DE CARBONO USANDO MÉTRICAS LIDAR, EM FLORESTA TROPICAL SECA, NO NORDESTE DO BRASIL.....	66
1 INTRODUÇÃO	66
2 MATERIAIS E MÉTODOS.....	68
2.1 ÁREA DE ESTUDO.....	68
2.2 ESTIMATIVA DO ESTOQUE DE BIOMASSA / CARBONO EM CAMPO	71
2.3 ESTIMATIVA DO ESTOQUE DE BIOMASSA / CARBONO POR DADOS LIDAR ..	73
2.3.1 OBTENÇÃO DOS DADOS LIDAR	73
2.3.2 PROCESSAMENTO DOS DADOS LIDAR	73
2.4 MODELAGEM DO ESTOQUE DE BIOMASSA / CARBONO POR MEIO DE DADOS LIDAR.....	75
2.4.1 TESTE DOS MODELOS PARA BIOMASSA E CARBONO.....	76
2.5 AVALIAÇÃO DOS MODELOS	77
3 RESULTADOS E DISCUSSÃO.....	78
3.1 EQUAÇÕES PREDITIVAS POR DADOS LIDAR.	80
3.2 PREDIÇÃO DE CARBONO POR ÁREA.....	83
4 CONCLUSÕES	86
REFERÊNCIAS	87
APÊNDICES	91
APÊNDICE 1:LISTA DAS ESPECIES POR ÁREA.....	92
APÊNDICE 2:VALORES DESCRIPTIVOS POR ÁREA.....	94
APÊNDICE 3: COMANDOS NO FUSION	96
APÊNDICE 4:TABELAS DOS MODELOS TESTADOS NAS ÁREAS DE ESTUDO PELO SOFTWARE RSTUDIO.....	102

1 INTRODUÇÃO GERAL

As florestas tropicais secas compreendem cerca de 41,5% da superfície das florestas tropicais e subtropicais do mundo (BLACKIE et al., 2014; SUNDERLAND et al., 2015; BASTIN et al., 2017) e fornecem uma ampla gama de serviços ecossistêmicos, desempenhando, assim, um papel chave e complexo nos estudos sobre as mudanças climáticas globais. No entanto, apesar de sua importância, durante décadas, as florestas tropicais foram consideradas as mais ameaçadas de todas, embora carecessem em estudos em comparação aos sistemas úmidos (HOLM et al., 2012). Um grande declínio mundial na extensão das florestas secas ocorreu devido à degradação florestal e, 97% das florestas remanescentes estão em risco, ameaçadas com a fragmentação de habitats, o aumento da frequência de incêndios e furacões, as mudanças climáticas, a conversão agrícola, as maiores densidades populacionais e, também, a desertificação (MILES et al., 2006; BRANDEIS et al., 2009; BASTIN et al., 2017).

Em uma escala global, o conhecimento atual da extensão da cobertura de árvores e florestas em terras áridas é limitado. Isso é ilustrado por substanciais discordâncias espaciais entre mapas florestais globais recentes baseados em satélite (HANSEN et al., 2013; SEXTON et al., 2016) e pela escassez de estudos, em larga escala, de biomassa de terras secas (DURANT et al., 2012; BASTIN et al., 2017).

No Brasil, as florestas secas ocupam aproximadamente 19% do território nacional e são denominadas, regionalmente, de Caatinga – que, em tupi guarani, significa "mata-branca" (GARIGLIO et al., 2010). Em geral, esse domínio de vegetação vem sofrendo crescente pressão antrópica, principalmente em consequência da remoção de lenha e do estabelecimento de pastagens e campos agrícolas (ALTHOFF et al., 2018), bem como, pela expansão urbana e industrial.

A Caatinga, originalmente, cobria uma área de quase 1 milhão de km², mas apenas cerca de metade desta área é, atualmente, coberta por vegetação lenhosa (GARIGLIO et al., 2010; ALTHOFF et al., 2018). A biomassa florestal é uma das fontes de energia mais importantes nesta região, com uma colheita total de cerca de 10 milhões de m³ de madeira por ano (GARIGLIO et al., 2010). Como resultado, mais de 90% da área de cobertura florestal representa, atualmente, uma vegetação de floresta secundária sob regeneração como parte do ciclo de pousio da agricultura de corte e queima e

como parte do ciclo de regeneração da produção de lenha (GARIGLIO et al., 2010; SAMPAIO et al., 2010).

A remoção da lenha é, comumente, seguida pela queima de resíduos florestais para o estabelecimento de campos agrícolas ou pastagens (SAMPAIO; SILVA, 2005), o que intensifica os impactos sobre o ciclo de carbono e nutrientes nestes ecossistemas (LIMA JÚNIOR et al., 2014; BRAND, 2017). Devido à grande demanda energética da população e da indústria, a extração de lenha é, frequentemente, realizada em ciclos curtos, que não permitem a recuperação da vegetação e podem afetar de forma adversa os processos do ecossistema (ALTHOFF et al., 2018). Portanto, é evidente que estudos sobre biomassa e estoque de carbono precisam ser desenvolvidos e aprimorados localmente para garantir a exploração sustentável, sobretudo, no desenvolvimento de metodologias de análises espaciais destas florestas como ferramentas norteadoras para a implementação de medidas mitigadoras frente às mudanças climáticas.

Enquanto que, no Brasil, essas informações ainda são escassas, as estimativas de biomassa mais recentes na floresta seca em escalas pantropicais, com base em pesquisas de sensoriamento remoto, variam muito, de 105 Mg ha^{-1} para o ano de 2000 para 542 Mg ha^{-1} para o ano de 2010, derivadas de uma amostra global de imagens de média resolução (MILES et al., 2006; BASTIN et al., 2017). Esta disparidade pode ser parcialmente explicada por diferenças nas características de dados de satélite (como resolução espacial), abordagens de mapeamento (como unidade de mapeamento) e definições de floresta (como limites de cobertura de árvore). Isto levou a grandes dúvidas sobre a confiabilidade das estimativas da área florestal global e a questões sobre a real contribuição das florestas para o ciclo global do carbono (BASTIN et al., 2017).

A crescente preocupação ambiental com as mudanças climáticas relacionadas à manutenção de emissões de gases de efeito estufa na atmosfera fez crescer, na mesma proporção, a necessidade de se ter estimativas confiáveis de biomassa (CHAVE et al., 2005; BRANDT et al., 2018). Análises envolvendo estimativas de biomassa e carbono devem ser validadas em campo e são, geralmente, precedidas da realização de inventário florestal, que são estudos que visam reportar informações significativas de determinada vegetação em nível de micro e macroescala. Estas informações são fundamentais para o planejamento e manutenção do setor no cenário atual e, em específico, a quantificação da biomassa florestal. No entanto, há limitações para realização de um inventário completo dentro de um curto espaço de tempo (AVITABILE; CAMIA, 2018).

Solicitadas pelo protocolo de Kyoto para medidas de redução dos gases de efeito estufa, as estimativas precisas da capacidade do estoque de carbono florestal são cruciais tanto para entendimento do funcionamento das florestas como para o estudo do orçamento global de carbono terrestre (CROWTHER et al., 2015; ROOPSIND et al., 2018). A precisão nas estimativas de biomassa é considerada um dos aspectos mais importantes em estudo de biomassa florestal, devendo ser obtida de maneira mais próxima possível dos valores reais e sem custos excessivos, desta forma, não necessita abater árvores como o método direto, utiliza variáveis de fácil obtenção (por ex.: diâmetro, altura e densidade da madeira) em relações quantitativas e matemáticas (CHAVE et al., 2005; FELDPAUSCH et al., 2011; CHAVE et al., 2014; CALDERS et al., 2015).

Na tentativa de redução de custos e tempo em grandes campanhas de inventário florestais para obtenção de dados, tem-se utilizado, cada vez mais, a aplicação de dados provenientes de sensores remotos orbitais para as estimativas de biomassa e estoque de carbono, uma ideia promissora que torna possível a integração de se avaliar a variabilidade espacial da floresta em uma escala regional de estoque e fluxo de carbono em extensas áreas (AVITABILE et al., 2011, 2016; ÁLVAREZ-DÁVILA et al., 2017; DUNCANSON; DUBAYAH, 2018).

Considerado uma das mais bem sucedidas tecnologias de coleta automática de dados para o levantamento e monitoração dos recursos terrestres em escala global, o sensoriamento remoto tem sido uma alternativa discutida de inovação, seus dados vêm tornando-se a principal fonte na estimativa de biomassa florestal acima do solo (*Above Ground Biomass – AGB*), essenciais para modelar a quantificação de carbono (AVITABILE et al., 2011; GHOSH; BEHERA, 2018).

O sensoriamento remoto tem sido uma alternativa discutida e, atualmente, já se tem algumas metodologias eficientes que estão sendo aplicadas para o levantamento da biomassa florestal. Deste modo, pode-se alcançar respostas viáveis que possibilitam as aplicações nas áreas de levantamentos de recursos naturais e mapeamentos temáticos, monitoração ambiental, detecção de desastres naturais, desmatamentos florestais, previsões de safras, cadastramentos multifinalitários, cartografia de precisão, defesa, vigilância e outras (BIJALWAN et al., 2010; AVITABILE et al., 2011; CASTILLO-NÚÑEZ et al., 2011; CASTILLO et al., 2012; FERRAZ et al., 2016; GONÇALVES et al., 2017; BROWN et al., 2018).

Dentre os métodos utilizados por meio de dados de sensoriamento remoto para estudos de estimativa de AGB em florestas, as principais tecnologias adotadas hoje são: *Light*

Detection and Ranging (LiDAR), radar e imagens ópticas passivas (CASTILLO et al., 2012; ESTORNELL et al., 2012; BACCINI; ASNER, 2013; DUNCANSON; DUBAYAH, 2018;).

A tecnologia LiDAR constitui-se em um instrumento de sensoriamento remoto, e, em português, é conhecida como Sistema de Varredura a Laser (SILVA et al., 2017). O LiDAR tem se mostrado uma das alternativas mais eficientes para o inventário da biomassa florestal(BACCINI; ASNER, 2013; BAUWENS et al., 2016; PICARD et al., 2018).

Apesar de o laser não ser uma nova tecnologia, sua utilização na aquisição de dados geográficos é relativamente recente. Não obstante, o emprego da tecnologia LiDAR apresenta grande potencial para aplicações florestais, em termos de sua capacidade de mobilização de uma grande quantidade de pontos com alta precisão e alta velocidade de aquisição de dados da estrutura vertical e horizontal das áreas florestais (BAUWENS et al., 2016; BASTIN et al., 2018; PICARD et al., 2018). No entanto, estudos com esta tecnologia em vegetação de domínio Caatinga ainda são escassos e incipientes.

A presente proposta de estudo fundamenta-se em obter estimativas de biomassa e carbono por meio de dados de inventário florestal convencional e tecnologia LiDAR em uma floresta seca no município de Floresta, Pernambuco.

2 REVISÃO DE LITERATURA

2.1 Florestas Tropicais Secas: definições

As florestas tropicais secas, também conhecidas como TDFs (*Tropical Dry Forests*), são o tipo de cobertura terrestre mais extenso nos trópicos e um dos ecossistemas terrestres mais diversos e menos protegidos. Elas fornecem bens e serviços aos habitantes das regiões áridas e semiáridas, o que as torna especialmente importantes (MILES et al., 2006).

A definição de florestas tropicais secas, em termos mais simples, sugere que estas podem ser consideradas tropicais secas quando ocorrerem em regiões tropicais com características de sazonalidade acentuada na distribuição de chuvas, resultando em vários meses de seca e, assim, ao desenvolverem-se sob tais condições climáticas, compartilham uma estrutura e fisionomia amplamente semelhantes (BULLOCK et al., 1995).

As florestas tropicais secas podem, em um sentido amplo, ser definidas como um tipo de vegetação tipicamente dominado por árvores decíduas (com, pelo menos, 50% das espécies arbóreas presentes caracterizando-se como secas decíduas), no qual, a temperatura média anual é $\geq 25^{\circ}\text{C}$, com precipitação anual total variando entre 700 e 2000 mm, havendo três ou mais meses secos todos os anos (precipitação de $< 100 \text{ mm/mês}$), e podendo haver inclusão de outras formas de tipos de vegetação em sua matriz como: savanas, costas, matas ciliares e manguezais (SANCHEZ-AZOFÉIFA et al., 2005).

A definição de limites para as florestas tropicais, globalmente, tem sido, relativamente, de caráter indiscutível se comparado a definição realizada para florestas secas e savanas (PENNINGTON et al., 2018).

Em ecossistemas de florestas tropicais, as secas representam cerca de 42%. Ao mapear as florestas secas pelo mundo (Figura 1), Miles et al. (2006) verificou que a área total estimada das florestas era cerca de 1.048.700 km², sendo que mais da metade (54,2%) das florestas secas remanescentes estavam localizadas na América do Sul, na América do Norte e Central (25,0%), na África (13,1%), na Eurásia (16,4%), na Australásia (insular) e no Sudeste Asiático (3,8%).

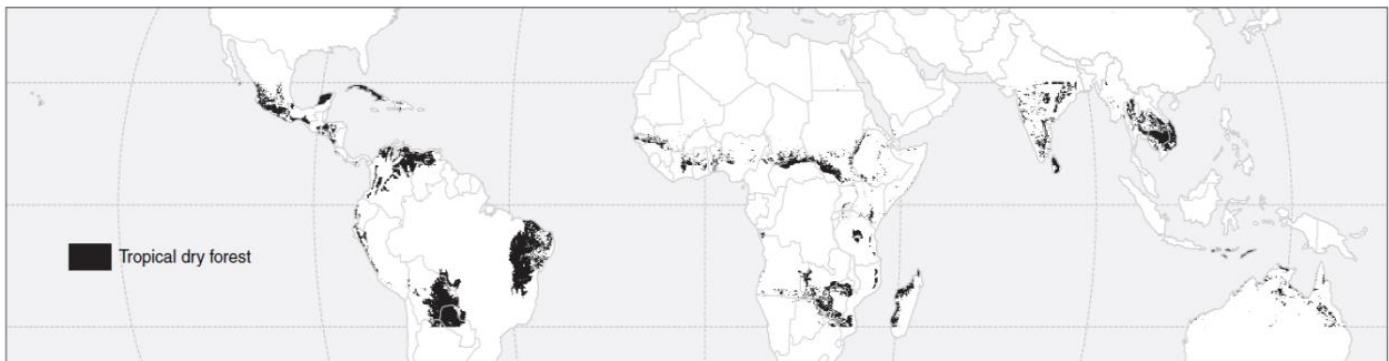


Figura 1 – Mapa de floresta tropical seca. Fonte: Miles et al. (2006)

Já Portillo-Quintero e Sánchez-Azofeifa (2010), em um estudo da avaliação da extensão e conservação das florestas tropicais secas nos continentes americanos, verificaram valores que chegam a 519.597 km², 39% de sua extensão ocorre na América do Norte e Central, 51% na América do Sul e 9% nas ilhas do Caribe.

2.1.1 Contexto histórico e atual

As TDFs, desde o início dos tempos coloniais, foram consideradas a primeira fronteira no desenvolvimento econômico. Reconhecimento, em grande parte, advindo da fertilidade do solo. Assim, as TDFs são expostas a uma combinação de mudanças complexas de uso/cobertura da terra (desmatamento, extração de madeira, agricultura, pastagem e incêndios induzidos por humanos) (CASTILLO et al., 2012).

Na década de 80, estas florestas eram as mais ameaçadas entre os principais tipos de florestas tropicais (JANZEN, 1988), visto que, na região mesoamericana, menos de 2% da floresta tropical seca (TDF) estava intacta para ser considerada digna de conservação (apenas 0,09% das florestas da região mesoamericana recebiam proteção oficial) e, nos anos 2000, a situação não era diferente, visto que altas taxas de perda e degradação de florestas continuavam a ser registradas em muitos países tropicais, onde florestas secas eram presentes (FAO, 2001; MILES et al., 2006).

O colapso das forças socioeconômicas, que impulsionaram a conversão das TDFs para campos agrícolas, resultaram no retorno de suas taxas mais altas, com campos antes usados para agricultura, agora, apresentavam-se cobertos por um mosaico de TDFs secundárias (CASTILLO et al., 2012).

A taxa alarmante, com a qual as florestas tropicais foram sendo modificadas ou completamente destruídas, estimulou o interesse nestes ecossistemas. No entanto, diferente das florestas úmidas, há a necessidade de mais estudos no que diz respeito à composição

taxonômica, taxas de carbono, dados sobre biomassa e características relacionadas (por exemplo, crescimento e produtividade primária), estes últimos sendo de grande utilidade também para a avaliação do potencial de recursos e para o aprofundamento da nossa compreensão da função florestal, especialmente no que diz respeito ao clima e à sazonalidade (MURPHY; LUGO, 1986a).

O bioma Caatinga, com vegetação tipo savana estépica, ocupa, aproximadamente, 9,92% do território nacional brasileiro, distribuída entre os estados do Piauí, Ceará, Rio Grande do Norte, Paraíba, Pernambuco, Sergipe, Alagoas, Bahia e Minas Gerais, com área que cobre, aproximadamente, 844 mil km² (IBGE, 2004). O Ministério do Meio Ambiente (MMA) (BRASIL, 2019) considera que este bioma brasileiro é um dos menos protegidos, já que, aproximadamente, 8,82% de seu território está inserido dentro de unidades de conservação (UC). Gariglio et al. (2010) afirma que sua vegetação nativa recobre cerca de 40% da área original do semiárido nordestino; contudo, a retirada das demais áreas ocorreram, principalmente, para uso na prática agrícola, pecuária extensiva e extração de lenha para fins energéticos.

Além da grande importância social, este tipo de floresta apresenta grande importância ecológica, uma vez que se caracteriza pela alta complexidade e diversidade biológica, resultante da heterogeneidade de microambientes (mosaicos de vegetação) em função das mudanças ambientais em diferentes escalas temporais e espaciais (MURPHY; LUGO, 1986b; WHITMORE, 1990). Informações concisas sobre o estado de conservação e a alteração dos recursos florestais são fundamentais para o seu uso sustentável, sendo necessário realizar estimativas, principalmente, em florestas de países tropicais, que são constantemente submetidas a maiores taxas de mudança (BROWN, 1997).

Até o início do século XX, ocorria uma séria insuficiência de conhecimento científico sobre a Caatinga, em que foi ignorada em relação ao ponto de vista de conservação e, também, dos estudos botânicos (VELLOSO et al., 2002; MORO, 2013). No entanto, veio a ser, nos últimos anos, certificada como uma região natural única, composta por diversas espécies endêmicas e com uma diversidade florística maior do que havia sido catalogado no século passado.

2.2 Estimativas de carbono e biomassa em floresta tropical seca

As estimativas de biomassa por meios de modelos alométricos auxiliam na avaliação das possibilidades energéticas e industriais, especialmente quando se objetiva a utilização de todos os componentes da árvore (raiz, fuste e galhos), bem como constatar o potencial dos

sistemas florestais para armazenamento e/ou sequestro de carbono da atmosfera (CHAVE et al., 2005; DIÉGUEZ-ARANDA et al., 2009; HIGUCHI et al., 2008; VIRGENS et al., 2017).

As florestas tropicais são um importante recurso para os estoques do carbono global e fornecem cerca de 428 Gt de carbono, dividido em vegetação e solos, equitativamente (IPCC, 2000). No entanto, o quantitativo de biomassa armazenada na vegetação, traz, consequentemente, incertezas, parte disto se deve à quantidade desconhecida de desmatamento, degradação, ambiguidade em definições de biomas e biomassas em estoque acima do solo nas florestas tropicais (BROWN, 1997; IPCC, 2000; HOUGHTON, 2005).

Os modelos de biomassa para espécies de florestas tropicais secas surgem como ferramentas valiosas para formuladores de políticas e partes interessadas, como, por exemplo, na assistência de gerentes florestais na estimativa necessária de lenha ou estoques de carbono para o manejo sustentável (TESFAYE et al., 2016).

Para a obtenção das estimativas de carbono e biomassa há dois métodos utilizados usualmente (SILVA, 2013): método direto, onde se realiza o abate de árvores e é tido como um processo trabalhoso e caro; e o método indireto, baseado na aplicação de modelos de regressão, previamente estabelecidos no método direto, utilizando variáveis de inventário (do diâmetro à altura do peito medido a 1,30 m do solo – DAP – e altura total das árvores – Ht), caracterizado por sua agilidade e rapidez, visto que se utilizam variáveis de fácil obtenção em campo.

Na floresta tropical estacional seca, poucos são os estudos que apresentam equações de estimativas de biomassa aérea direta ou indireta e carbono para áreas, grupos de espécies, espécies ou para diferentes partes dos indivíduos (DALLA LANA, 2017).

Um dos primeiros estudos que abordou a estimativa de biomassa em Caatinga, foi o de Kauffman et al. (1993), que buscou quantificar os efeitos do desmatamento e níveis variáveis de corte/gravidade do fogo na perda de nutrientes e redistribuição em uma segunda floresta tropical de crescimento seco (Caatinga), em Serra Talhada, Pernambuco, onde encontrou uma biomassa total de 74 Mg ha^{-1} sem separação de estrutura (tronco, galhos e folhas dos indivíduos) da queima, por meio de método não-destrutivo.

Sampaio et al. (1998), dando continuidade aos estudos de Kauffman et al. (1993) e Sampaio et al. (1993), na mesma área de estudo em Serra Talhada, avaliou os efeitos do corte da vegetação nas densidades, biomassas aéreas e número de indivíduos sob três diferentes intensidades de combustão, após dois e seis anos de intervenções. Por meio de método não-destrutivo (modelo alométrico de regressão), Sampaio et al. (1998) obtiveram biomassas

estimadas para área sem atividade de queima, nos períodos de dois e seis anos, de 6,7 Mg ha⁻¹ e 29,7 Mg ha⁻¹, respectivamente. Para as áreas que apresentaram maior incidência de queima, as biomassas encontradas, para os dois períodos de tempo, foram de 3,6 Mg ha⁻¹ e 16,8 Mg ha⁻¹, respectivamente.

O valor de biomassa da área sem atividade de queima, no período de seis anos, obtido por Sampaio et al. (1998) corrobora com o encontrado por Virgens et al. (2017), que, ao avaliar os estoques e distribuição de biomassa aérea das espécies florestais de maior densidade populacional e, em concomitância, avaliar o potencial de utilização do fator de expansão de biomassa (FEB) médio para estimação de biomassa em área de Caatinga arbórea, obteve um valor de 29,2 Mg ha⁻¹ de biomassa aérea total em Contendas do Sincorá (FLONA), Município de Contendas do Sincorá, Bahia, a partir do método direto (abate das árvores) de quantificação de biomassa. Além disso, separaram as biomassas por compartimento, evidenciando o tronco das árvores com a maior representatividade (73,94%), seguido dos galhos com 25,5% na distribuição de biomassa.

Em estudo ocorrido no Ceará que objetivou quantificar os estoques de biomassa e carbono em Floresta Tropical Seca (FTS) e suas alterações após a mudança de uso e cobertura da terra, Rosa (2018) encontrou, por meio da equação alométrica de potência, uma estimativa de biomassa aérea total variando entre 1,2 Mg ha⁻¹ a 56,51 Mg ha⁻¹, com uma pequena capacidade de estoque em área que foi alterada para uso de pastagem (2,6 Mg ha⁻¹) e altas capacidades de estoque nas áreas de vegetação nativa (Caatinga densa = 56,51 Mg ha⁻¹ e Caatinga aberta = 28,2 Mg ha⁻¹). Em estudos para a estimativa de biomassa em Caatinga, Amorim et al. (2005), por meio de modelos alométricos, encontraram biomassas variando entre 20 e 25 Mg ha⁻¹, na Estação Ecológica do Seridó, no Rio Grande do Norte e, mediante tais informações, caracterizaram a região do Seridó com a tipologia de Caatinga aberta com baixa biomassa aérea.

Sampaio e Freitas (2008) concluem que as biomassas aéreas da vegetação nativa do semiárido variam de 2 a 160 Mg ha⁻¹, esta informação complementa Tiessen et al. (1998), que, por meio de levantamento bibliográfico, inferiu que, na Caatinga, a biomassa arbórea varia de 5-10 Mg ha⁻¹ em formações abertas e de 50-100 Mg ha⁻¹ em formações fechadas. Embora a amplitude de biomassa encontrada pelos estudos não seja grande, ela ocorre devido às condições em que a vegetação de Caatinga se encontra. Se forem condições ambientais mais favoráveis, a biomassa total varia entre 50-150 Mg ha⁻¹ e, se as condições ambientais obtiverem nível mais limitado e forem menos favoráveis, a amplitude da biomassa varia de 20-80 Mg ha⁻¹ (SAMPAIO, 2010).

Alternativas de métodos indiretos nos estudos da quantificação da biomassa e do estoque de carbono florestal são o uso de técnicas de sensoriamento remoto, tais como: processamento digital de imagens de satélite e LiDAR.

A capacidade do LiDAR (*Light Detection and Ranging*) por meio de feixes de laser de penetrar no dossel da floresta, tornou-o uma fonte de dados para caracterização da estrutura da floresta vertical (WHITE et al., 2013) e uma ferramenta útil no aprimoramento de técnicas de obtenção de informações dendrométricas da floresta (altura, diâmetro, volume, área basal, altura e diâmetro de copas) (PEINHOPF, 2012).

A biomassa acima do solo não pode ser medida diretamente por qualquer sensor do espaço, no entanto, parâmetros derivados de distribuição de dados LiDAR podem ser utilizados para estimar a biomassa florestal, apresentando forte potencial em seu monitoramento com precisão. (ESTORNELL et al., 2011; SUN et al., 2011; FAYAD et al., 2016)

Diversos estudos de estimativa da biomassa florestal mostram resultados promissores com aplicação da tecnologia LiDAR, a partir de seus atributos estatísticos descritivos como altura média, percentis de altura e derivados comparáveis (NELSON et al., 1988; LEFSKY et al., 1999; MEANS et al., 1999; PATENAUME et al., 2004; SILVA, 2013; SILVA et al., 2013; LATIFI et al., 2015; FAYAD et al., 2016).

Neste sentido, na estimativa de biomassa em florestas tropicais secas na península de Yucatan, México, Hernandez-Stefanoni et al. (2015) obteve resultados semelhantes entre as médias de biomassa foliar e as obtidas por meio da LiDAR. Já Estornell et al (2011), ao realizar a estimativa da biomassa arbórea de espécies típicas de floresta mediterrânea por dados LiDAR aerotransportados, verificou que, a partir de uma alta densidade de dados LiDAR associada ao modelo digital do terreno (MDT) com erro baixo, é possível obter a estimativa de biomassa arbórea em pequenas áreas com R^2 podendo alcançar valores de 0,73.

A utilização direta dos dados LiDAR na modelagem de parâmetros florestais é, em parte, restringida por sua grande quantidade de dados, uma vez que o número de métricas pode chegar a centenas de variáveis. Assim, após a coleta de dados, é necessário o cálculo de métricas espaciais, para, então, serem utilizadas para a obtenção de equações de predição. O grande número de variáveis poderia, teoricamente, melhorar a precisão dos modelos, no entanto, para uma interpretação mais fácil, o uso de modelos com menos variáveis são mais práticos (NÆSSET, 1997; ZHAO et al., 2009; MURPHY et al., 2010; GÖRGENS et al., 2015b).

A variável altura total (Ht), quando obtida por dados do LIDAR aerotransportado, ganha importância e praticidade; e, quando obtida pelo processamento da nuvem de pontos, pode ser incorporada nos modelos alométricos, assim que realizada a sua normalização e exclusão do conjunto de pontos flutuantes acima do dossel da floresta, para evitar superestimativas (FIGUEIREDO, 2014).

Em estudo realizado na região do Vale do Paraíba, São Paulo, Macedo (2009) comparou dados de LiDAR aos mensurados em campo para plantios clonais de *Eucalyptus*, onde encontrou nível de precisão superior a 90% para volume, altura, diâmetro e número de fustes e de 80% para área de copa. Já Dean et al. (2009), em estudo no sudeste da Louisiana, ao associar a altura das árvores obtidas com o LiDAR à altura de copa viva no dossel de floresta de *Pinus*, por meio da distribuição de probabilidade Weibull truncada, concluiu que os erros não diferiam quando comparados às observações de campo.

Em estimativas de estoque de carbono na biomassa aérea florestal com o uso da tecnologia LiDAR em plantações de *Eucalyptus* spp., Silva (2013) verificou que a estimativa do carbono total com modelo composto por cinco variáveis de classes das métricas do LiDAR (Intensidade, Altura e densidade de copa), aproximou-se dos valores observados e nas relações entre os valores de carbono observado em campo *versus* os estimados pela validação o modelo, mostrou-se altamente estável e as variáveis independentes apresentando o coeficiente de determinação ajustados (R^2_{adj}) com um poder explicativo em torno de 89%.

A partir de estudos que já foram realizados com dados LiDAR, pode-se ver seu uso amplo na área florestal, no entanto, sempre levando-se em consideração de que forma, com que objetivos os dados serão utilizados e com que precisão poderão ser úteis ao resultado esperado.

2.3 Sensoriamento remoto – Tecnologia LiDAR

2.3.1 Princípios

O LiDAR é um método de geração de informações tridimensionais com alta resolução (Figura 2) sobre a forma e características de superfície da Terra e é bastante empregado em coleta de dados de elevação (NOAA, 2012; WHITE et al., 2013)

Figura 2 – Tecnologia LiDAR em funcionamento. Fonte: Directions Magazine (2014).

A aquisição de dados por meio da tecnologia LiDAR é baseada nos princípios



utilizados no sistema de RADAR, com a diferença de que, ao invés do uso de ondas de rádio para localizar os objetos de interesse, são emitidos pulsos laser.

Os sistemas LiDAR utilizam-se da emissão de pulsos laser de uma plataforma com uma elevada frequência de repetição, podem ser obtidos à noite por configurarem um sistema ativo, assim, não precisam da iluminação solar ativa (JENSEN, 2009; GIONGO et al., 2010).

Dentre as plataformas de emissão dos lasers, temos:

- Orbital: o laser é acoplado a um satélite para a emissão dos pulsos, um exemplo de aplicação neste tipo de plataforma é o sensor GLAS (Geoscience Laser Altimeter System) que, a bordo do satélite ICE, chega a alcançar 65 metros e adquire informações sobre topografia e estrutura vertical da vegetação.
- Aérea (*Airborne Laser Scanning – ALS*): ao utilizar uma aeronave para uma perspectiva distante e acima do solo, permite uma cobertura de larga escala de superfície com a medição vertical e horizontal de elevada precisão, chega a cobrir até 50 km² por hora (ZONETE, 2009; NOAA, 2012; GÖRGENS et al., 2014).
- Terrestre (*Terrestrial Laser Scanning – TLS*): é um scanner rotativo montado em uma plataforma elevada, permite rápida coleta de nuvens de pontos, representa a

posição 3D das superfícies e objetos no campo de visão do scanner, incluindo a vegetação herbácea.

O instrumento LiDAR consiste em um sistema de controle, um transmissor e um receptor e, nas plataformas aéreas, é composto, segundo Jensen (2009) e Giongo et al. (2010), por:

- Sensor Laser: que, essencialmente, registra o tempo entre o sinal emitido e o sinal recebido de um determinado ponto.
- Sistema Inercial de Navegação (*Inertial Navigation System – INS*): utiliza uma Unidade de Medição Inercial que contém um arranjo de sensores inerciais com acelerômetros e giroscópios (*roll, pitch e yaw*) para o fornecimento de informações precisas sobre a orientação da antena do LiDAR.
- GPS Diferencial (*Differential Global Positioning System – DGPS*): baseado no uso de um receptor GPS na plataforma aerotransportada e uma estação-base terrestre, ambos trabalhando em conjunto para a determinação da posição da plataforma aerotransportada durante a aquisição de cada um dos pontos (Figura 3).

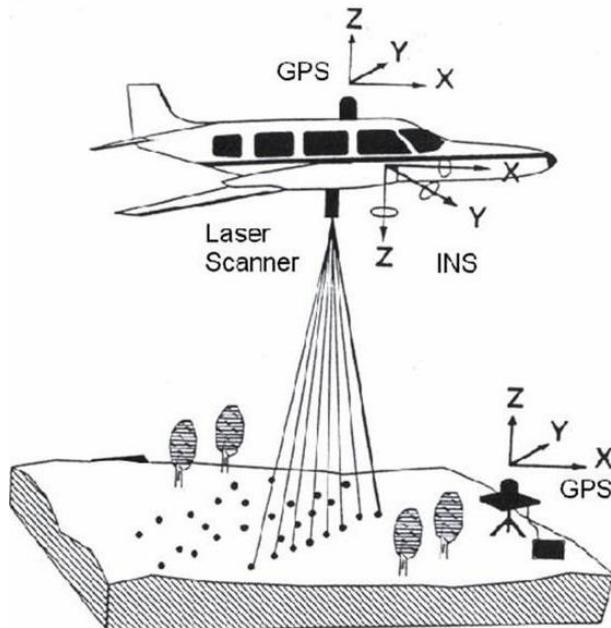


Figura 3 – Representação de sistema LiDAR em uma aeronave tripulada. Fonte: Fancher (2012).

2.3.2 Pulsos de Luz Laser

Nos Sistemas LiDAR, a emissão de pulsos de luz laser desloca-se à velocidade da luz ($c = 3 \times 10^8 \text{ m s}^{-1}$), com uma elevada frequência de repetição e pode chegar a até 100.000 pulsos por segundo, concomitante, o sensor mede o tempo de retorno do sinal laser entre a

plataforma e os alvos (JENSEN, 2009; GIONGO et al., 2010; SILVA, et al. 2013). De acordo com Boland et al. (2004) o cálculo do tempo de percurso de um pulso de luz (t) é obtido por meio da Equação 1:

$$t = 2 \frac{R}{c} t = \left(\frac{R}{c} \right) \quad (\text{Eq. 1})$$

Em que: R = distância entre o sensor LiDAR e o objeto; c = velocidade da luz ($3 \times 10^8 \text{ m s}^{-1}$).

Os pulsos, advindos de uma aeronave, são diretamente enviados em direção ao terreno; sua área de cobertura laser instantânea tem formato aproximadamente circular com cerca de 30 cm de diâmetro, variando conforme a altitude do instrumento LiDAR e o ângulo de envio (JENSEN, 2009).

2.3.3 Dados LiDAR

A aeronave, na linha de voo, direciona pulsos laser no terreno por um espelho de varredura (conjunto óptico de lentes e espelhos) que tem como função orientar os pulsos e, sequencialmente, recebe os sinais de retorno e direciona-os para o receptor. O GPS a bordo envia a posição da plataforma a cada impulso do laser enviado, que é registrado juntamente com a direção de propagação do impulso de luz a partir da unidade de medição inercial, caracterizada como altamente sensível, ligada ao sistema óptico de orientação do feixe. (BALTSAVIAS, 1999; JENSEN, 2009; GÖRGENS et al., 2015a).

A energia transmitida é retroespalhada em direção à aeronave e registrada. Toda a energia contida em um único pulso de saída pode gerar um ou vários retornos, a quantidade deles pode variar conforme a presença de materiais que provoquem um relevo local dentro da área de cobertura laser instantânea (por ex.: grama, folhas, galhos ou pequenas rochas). Assim, a cada retorno, uma camada é gerada do primeiro até o último (JENSEN, 2009; GÖRGENS et al., 2015a), como pode ser visualizado na figura 4 abaixo:

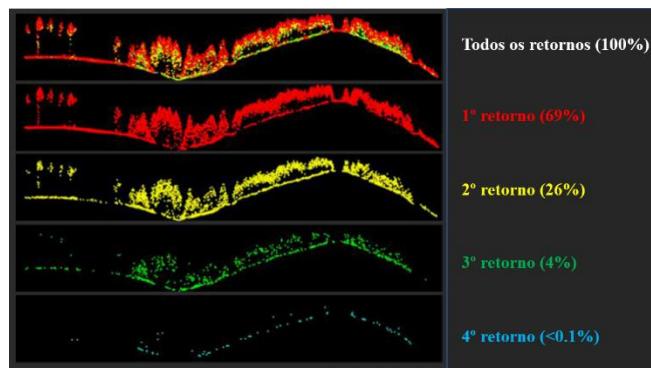


Figura 4 – Representação dos retornos de pulso laser na vegetação. Fonte: Adaptado de Humboldt State University (2017).

Em uma área florestada, captada pelo LiDAR, o pulso é, parcialmente, refletido pelo topo das árvores e o dossel é penetrado pelo restante do sinal, sendo refletido ao interagir com galhos e folhas até ser, totalmente, refletido ao interagir com o solo (MARTINS, 2015). No entanto, em áreas de florestas muito densas, o sinal, ao interagir com os troncos das árvores, pode ser totalmente refletido antes de atingir o solo.

2.3.4 Pós-processamento de dados LiDAR

Com o sobrevoo finalizado e obtidos os dados GPS das unidades de medição inercial e os pulsos recebidos com um único retorno ou múltiplos (retorno intermediário e retorno final), estes dados devem ser transformados em valores digitais de elevação com localizações específicas tridimensionais (x , y , z) da superfície na Terra.

Esse pós-processamento necessita de realização por meio de um software que permitirá associar os seguintes dados (JENSEN, 2009):

- 1) A posição x , y , z da antena LiDAR (DGPS).
- 2) A orientação dos giroscópios *roll*, *pitch* e *yaw* da antena LiDAR (das unidades de medição inercial).
- 3) A informação de cada retorno LiDAR sobre a distância (*range*), identificando-o por um conjunto de coordenadas de latitude, longitude e altitude (x , y , z).

O pós-processamento resulta em uma nuvem de pontos (*masspoint*) com coordenadas tridimensionais e valores de intensidade associados com cada arquivo de retorno do pulso de luz laser, distribuídos, na paisagem, em variadas densidades (Figura 5). As áreas que não apresentam nenhum retorno do LiDAR são conhecidas como *data void*.

Os dados de saída têm formato binário compacto de coordenadas WGS84, podem ser convertidos para coordenadas UTM e/ou em formatos ASCII, que possibilitam que sejam acessados em um SIG (Sistema de Informações Geográficas). O conjunto de dados LiDAR pode ser fornecido com especificações do usuário (hora do dia, intensidade e coordenadas – x , y ou z).

2.3.5 Produtos do LiDAR

2.3.5.1 Nuvem de Pontos

A partir da nuvem de pontos, tem-se informação tridimensional que permite proporcionar a geração de outros dados como o Modelo Digital de Elevação (MDE) e seus derivados: Modelos Digitais de Superfície (MDS), Modelos Digitais de Terrenos (MDT) e Modelos Digital da altura das copas (*Canopy Height Models – CHM*), além das métricas de elevação, parâmetros estatísticos relacionados à elevação da nuvem de pontos.

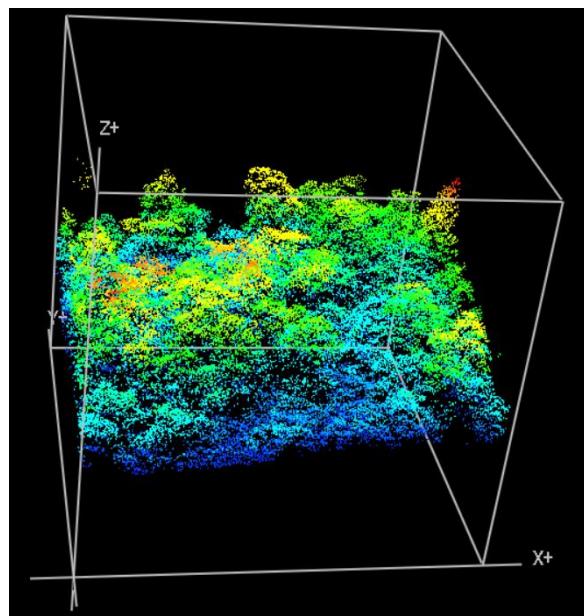


Figura 5 – Representação da nuvem de pontos LIDAR dos dados obtidos em área do presente estudo.

2.3.5.2 Modelos Digitais de Elevação (MDE)

Os MDE são representações em meio digital da configuração espacial de altitude numa área, descrevem a distribuição espacial de uma característica do terreno. O sistema de varredura a laser permite o desenvolvimento de MDEs com alta precisão. Os MDEs contêm as informações de vegetação e edificações e se dividem em:

- Modelos Digitais de Superfície (MDS)

Os MDS permitem representar a superfície do solo e tudo o que está sobre ele, como árvores, arbustos, pessoas, prédios, infraestruturas e outros elementos da paisagem (Figura 6). Dentre as suas principais aplicações, estão a extração da altura e biomassa da vegetação, o mapeamento da vegetação, o estudo da cobertura e o uso do solo etc (JENSEN, 2009; GÖRGENS et al., 2014).

Para a criação do MDS com dados LiDAR, utiliza-se a interpolação ponderada pelo inverso da distância, criando, assim, uma grade (*raster*) com valores de elevação a partir dos retornos localizados no ponto mais alto da nuvem (JENSEN, 2009). Para melhor visualização e realce do terreno, pode-se usar um algoritmo de sombreamento do relevo, a qualidade de um MDS relaciona-se à exatidão e ao nível de detalhamento requerido da superfície.

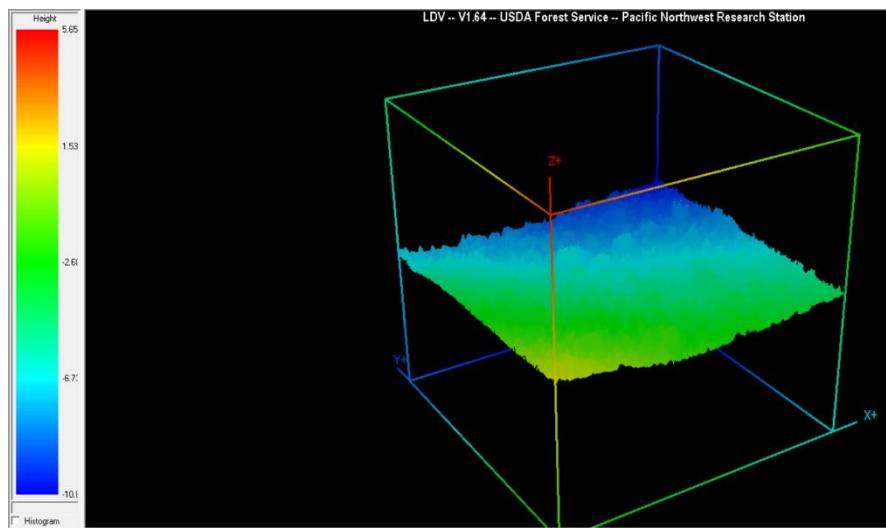


Figura 6 – Representação de Modelo Digital de Superfície obtido em área do presente estudo.

- Modelos Digitais de Terrenos (MDT)

Os MDTs representam o solo nu, podem ser de forma regular (*grid* regular com células de igual dimensão) ou irregular (rede irregular de triângulos – TIN). Dentre suas aplicações, destacam-se a modelagem hidrológica, a visualização do planejamento da paisagem e o monitoramento de ambiente (GÖRGENS et al., 2014).

Quando se utiliza dados de levantamentos lasers aerotransportados para a criação de MDTs, extraem-se, sistematicamente, os pontos com primeiro intermediário e/ou último retornos provenientes de árvores, grama e arbustos, restando somente os pontos localizados na parte mais baixa da nuvem LiDAR.

Para a extração dos pontos, segundo Jensen (2009), são necessários os seguintes procedimentos:

- 1) Filtragem Semiautomática: para a extração da vegetação, usa-se, de forma sistemática, um filtro que identifica os pontos como superfície desnuda do terreno, arbustos, árvores e/ou estruturas feitas pelo homem em cada ponto, caracterizando-os quanto sua elevação e associando-os aos seus *n* vizinhos mais próximos.

2) Edição Manual dos Pontos: refinamento dos pontos que não foram extraídos nos procedimentos de filtragem semiautomática. É realizado por meio da observação tridimensional dos conjuntos de pontos ou da superposição dos pontos de coleta a uma fotografia aérea retificada, o resultado desta edição é utilizado para criar o MDT.

O formato de saída do MDT é *grid (raster)* com representação ordenada da superfície, dividida em celular de igual dimensão (Figura 7). Do mesmo que o MDS, o MDT tem sua qualidade relacionada à exatidão e ao nível de detalhamento exigidos.

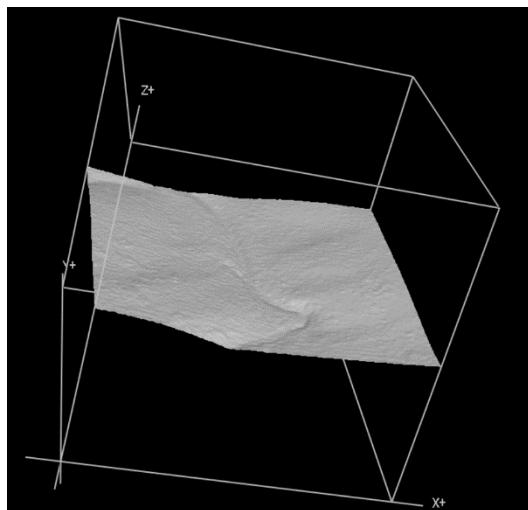


Figura 7 – Representação de Modelo Digital de Terreno obtido em área do presente estudo.

- Modelo Digital das alturas das Copas (*Canopy Height Models – CHM*)

O CHM é semelhante ao MDS, mas representa os valores em coordenada Z para a altura dos objetos presentes em uma nuvem de pontos LiDAR em vez da elevação, é conhecido também por modelos digitais de superfície normalizados (normalized Digital Surface Models – nDSM) (SILVA, 2013).

A diferença entre os modelos derivados do Modelo Digital de Elevação pode ser verificada na Figura 8.

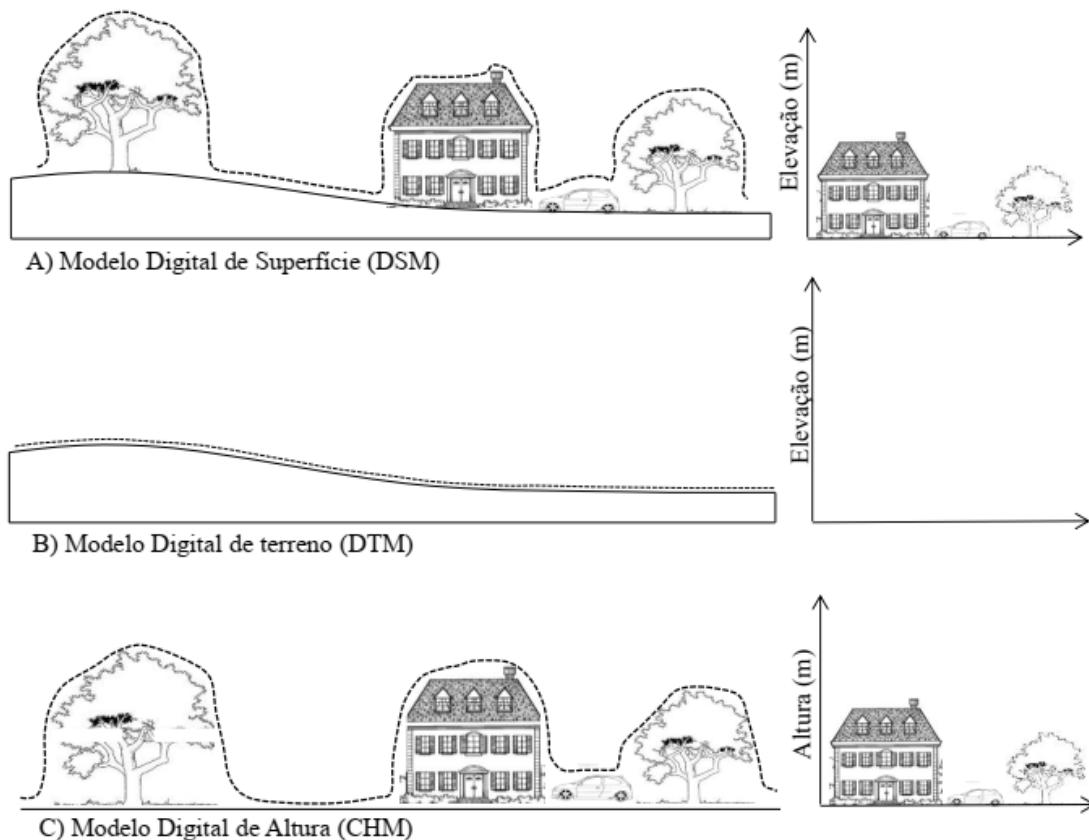


Figura 8 – Representação dos modelos derivados do modelo digital de elevação (MDE). A) modelo digital desuperfície (MDS); B) modelo digital de terreno (MDT) e C) modelo digital de altura copa (CHM). Fonte: SILVA (2013).

2.3.5.3 Métricas

Entre os resultados do processamento da nuvem do LIDAR, tem-se a extração das métricas, estatísticas que atuam em diversas finalidades, dentre elas: caracterização da estrutura vertical e horizontal da área estudada, parametrização da forma de árvores individuais, modelagem de variáveis florestais de interesse por meio da abordagem baseada em área etc (GÖRGENS et al., 2014).

As métricas dividem-se em:

- Métricas de contagem: referentes à aferição de qualidade da nuvem de pontos.
- Métricas de elevação ou altura: associadas a coordenadas de posicionamento vertical dos pontos na nuvem, dividindo-se posição, dispersão e proporção.
- Métricas de intensidade do retorno: relacionadas com energia eletromagnética refletida pelos objetos interceptados pelo pulso de luz laser.
- Métricas topográficas: servem com o propósito de auxiliar na qualificação do MDT por meio dos valores de elevação (dados de declividade, aspectos da face e índices de radiação solar com base na exposição do terreno).

Logo, no pós-processamento dos dados LIDAR, produz-se uma nuvem de pontos que permite gerar muitos outros dados que podem levar às mais variadas aplicações. Desta forma, são estas capacidades únicas que vêm fazendo o sistema LIDAR uma tecnologia útil no sensoriamento remoto para monitoramento florestal e uma fonte potencial de informações da estrutura da vegetação (GÖRGENS et al., 2015a).

2.3.6 Acurácia dos dados

Para a tecnologia LiDAR, tornou-se, cada vez mais, necessário o uso de padrões de acurácia para a determinação da confiabilidade dos seus produtos, já que por parte da comunidade científica, devido ao fato de ser uma ferramenta relativamente nova, houve um certo ceticismo se comparada com os dados de levantamentos tradicionais *in situ* e da fotogrametria (JENSEN, 2009).

Os dados derivados da tecnologia LiDAR têm sua qualidade analisada por dois tipos de acurácia: a relativa, quando se emprega os próprios dados no controle de qualidade, ou a absoluta, quando se faz o uso de dados externos independentes (LÓPEZ, 2013).

É importante abordar duas vertentes a respeito dos fatores influenciadores dos dados obtidos pelo LiDAR. O primeiro é relacionado ao equipamento e o seu uso e, o outro é o fator externo quanto às características de seus alvos.

A acurácia dos dados provenientes do LiDAR sofre influência de erros aleatórios e sistemáticos originados na integração do sistema de posicionamento GNSS (*Global Navigation Satellite System*), do sistema de navegação IMU (*Inertial Measurement Unit*) e nas medidas angulares dos espelhos e das distâncias provenientes do dispositivo de varredura laser, resultando em dados, independentemente, georreferenciados com desalinhamentos angulares e deslocamentos entre as nuvens de pontos 3D relativas a cada faixa de voo de recobrimento de uma área da superfície física pelo sistema LiDAR (DRESCH; SANTOS, 2015). Para a remoção e quantificação destes erros, é necessário o ajustamento de faixas, procedimento utilizado pelos produtores dos dados LiDAR.

A questão da natureza do alvo e sua influência na acurácia da elevação obtida pelo LiDAR é levantado por Jensen (2009) que dá como exemplos de influência a cobertura do solo, a declividade e condições de presença/ausência de folhagem.

REFERÊNCIAS

ALTHOFF, T.D. et al. Adaptation of the century model to simulate C and N dynamics of Caatinga dry forest before and after deforestation. **Agriculture, Ecosystems & Environment**, Amsterdam, v.254, p.26–34, 2018. <https://doi.org/10.1016/j.agee.2017.11.016>.

ÁLVAREZ-DÁVILA, E. et al. Forest biomass density across large climate gradients in northern South America is related to water availability but not with temperature. **PLOS ONE**, San Francisco, v.12, n.3, 2017. <https://doi.org/10.1371/journal.pone.0171072>.

AMORIM, I. L.; SAMPAIO, E. V. S. B.; ARAÚJO, E. L. Flora e estrutura da vegetação arbustiva-arbórea de uma área de caatinga do Sérido, RN, Brasil. **Acta Botanica Brasílica**, São Paulo-SP, v.19, n.3, p. 615-623, 2005. <http://dx.doi.org/10.1590/S0102-33062005000300023>.

AVITABILE, V. et al. Mapping biomass with remote sensing: a comparison of methods for the case study of Uganda. **Carbon Balance and Management**, London, v.6, n.7, 2011. <https://doi.org/10.1186/1750-0680-6-7>.

AVITABILE, V. et al. An integrated pan-tropical biomass map using multiple reference datasets. **Global Change Biology**, Oxford, v.22, n.4, p.1406–1420, 2016. <https://doi.org/10.1111/gcb.13139>.

AVITABILE, V., CAMIA, A. An assessment of forest biomass maps in Europe using harmonized national statistics and inventory plots. **Forest Ecology and Management**, Amsterdam, v.409, p.489–498, 2018. <https://doi.org/10.1016/j.foreco.2017.11.047>.

BACCINI, A., ASNER, G.P. Improving pantropical forest carbon maps with airborne LiDAR sampling. **Carbon Management**, London, v.4, n.6, p.591–600, 2013. <https://doi.org/10.4155/cmt.13.66>.

BALTSAVIAS, E. P. Airborne laser scanning: basic relations and formulas. **ISPRS Journal of Photogrammetry & Remote Sensing**, Amsterdam, v. 54, n. 2-3, p. 199-214, 1999.

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

BASTIN, J-F. et al. Pan-tropical prediction of forest structure from the largest trees. **Global Ecology and Biogeography**, Oxford, v.19, n.11 p.1-18, 2018. <https://doi.org/10.1111/geb.12803>.

BAUWENS, S. et al. Forest inventory with terrestrial LiDAR: a comparison of static and hand-held mobile laser scanning. **Forests**, Basel, v.7, n.6, p.1-17, 2016. <https://doi.org/10.3390/f7060127>.

BIJALWAN, A. et al. Land-use, biomass and carbon estimation in dry tropical forest of Chhattisgarh region in India using satellite remote sensing and GIS. **Journal of Forestry Research**, Berlim, v.21, n.2, p.161–170, 2010. <https://doi.org/10.1007/s11676-010-0026-y>.

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

BOLAND, J. et al. Cameras and sensing system. In: McGlone, J. C. (Ed.). **Manual of photogrammetry**. 5^{ed}. Bethesda: ASPRS, 2004. Chap. 8, p. 629-636.

BRAND, M.A. Potencial de uso da biomassa florestal da caatinga, sob manejo sustentável, para geração de energia. **Ciência Florestal**, Santa Maria-RS, v.27, n.1, p.117-127, 2017. <https://doi.org/10.5902/1980509826452>.

BRANDEIS, T. et al. Allometric equations for predicting Puerto Rican dry forest biomass and volume.In: McRoberts, Ronald E.; Reams, Gregory A.; Van Deusen, Paul C.; McWilliams, William H. (Ed.)**Proceedings of the Eighth Annual Forest Inventory and Analysis Symposium**. Washington: US Department of Agriculture, Forest Service. 2009,p.197-202.

BRANDT, M. et al. Satellite passive microwaves reveal recent climate-induced carbon losses in African drylands. **Nature Ecology & Evolution**, London, v.2, n. 4, p.827–835, 2018. <https://doi.org/10.1038/s41559-018-0530-6>.

BRASIL. Ministério do Meio Ambiente. **Cadastro Nacional de Unidades de Conservação**. Quadro Consolidado das Unidades de Conservação Brasileiras por Bioma. Brasília, DF, 2019.

BROWN, S. **Estimating biomass and biomass changingof tropical forests**: a primer. Rome: FAO Forestry Paper, 1997.

BROWN, C. et al. Tropical peatland vegetation structure and biomass: optimal exploitation of airborne laser scanning. **Remote Sensing**, Basel, v.10, n.5, p.1-21, 2018. <https://doi.org/10.3390/rs10050671>.

BULLOCK; S.H.; MOONEY, H.A.; MEDINA, E.**Seasonally dry tropical forest**. (Eds.). Cambridge: Cambridge University Press, 1995.

CALDERS, K. et al. Nondestructive estimates of above-ground biomass using terrestrial laser scanning. **Methods in Ecology and Evolution**, Hoboken, v.6, n.2, p.198–208, 2015. <https://doi.org/10.1111/2041-210X.12301>.

CASTILLO-NÚÑEZ, M. et al. Delineation of secondary succession mechanisms for tropical dry forests using LiDAR. **Remote Sensing of Environment**, New York, v.115, n.9, p.2217–2231, 2011. <https://doi.org/10.1016/j.rse.2011.04.020>.

CASTILLO, M. et al. LIDAR remote sensing for secondary Tropical Dry Forest identification. **Remote Sensing of Environment**, New York, v.121, p.132–143, 2012. <https://doi.org/10.1016/j.rse.2012.01.012>.

CHAVE, J. et al. Tree allometry and improved estimation of carbon stocks and balance in tropical forests. **Oecologia**, Berlim, v.145, n.1, p.87–99, 2005. <https://doi.org/10.1007/s00442-005-0100-x>.

CHAVE, J. et al. Improved allometric models to estimate the aboveground biomass of tropical trees. **Global Change Biology**, Oxford, v.20, n.10, p.3177–3190, 2014. <https://doi.org/10.1111/gcb.12629>.

CROWTHER, T.W. et al. Mapping tree density at a global scale. **Nature**, London, v.525, p.201–205, 2015. <https://doi.org/10.1038/nature14967>.

DALLA LANA, M. **Quantificação do estoque de carbono e avaliação econômica de alternativas de manejo florestal da Caatinga, Floresta-PE**. 2017. 142f. Tese (Doutorado em Ciências Florestais) – Universidade Federal Rural de Pernambuco, 2017. Disponível em: http://www.ppgcf.ufrpe.br/sites/www.ppgcf.ufrpe.br/files/documentos/mayara_dalla_lana.pdf. Acesso em: 01 jan. 2019.

DEAN, T. J. et al. Measuring heights to crown base and crown median with lidar in a mature, even-aged loblolly pine stand. **Forest Ecology and Management**, Amsterdam, v. 257, n. 1, p. 126-133, 2009. <https://doi.org/10.1016/j.foreco.2008.08.024>.

DIÉGUEZ-ARANDA, U. et al. **Herramientas selvícolas para la gestión forestal sostenible en Galicia**. Galicia: Xunta de Galicia, 2009.

DIRECTIONS MAGAZINE. 2014. Disponivel em: <https://www.directionsmag.com/article/1439>. Acesso em: 02 fev. 2017.

DRESCH, G.; SANTOS, D. R. D. Avaliação automática da acurácia relativa de dados LiDAR aerotransportado. **Boletim de Ciências Geodésicas**, Curitiba, v. 21, n. 4, p. 730-749, 2015.

DUNCANSON, L., DUBAYAH, R. Monitoring individual tree-based change with airborne LiDAR. **Ecology and Evolution**, Oxford, v.8, n.10, p.5079–5089, 2018.
<https://doi.org/10.1002/ece3.4075>.

DURANT, S. M. et al. Forgotten Biodiversity in Desert Ecosystems. **Science**, New York, v.336, n.6087, p.1379–1380, 2012. <https://doi.org/10.1126/science.336.6087.1379>.

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

ESTORNELL, J. et al. Estimation of biomass and volume of shrub vegetation using LiDAR and spectral data in a Mediterranean environment. **Biomass and Bioenergy**, Oxford, v.46, p.710–721, 2012. <https://doi.org/10.1016/j.biombioe.2012.06.023>.

FANCHER, Z. **Using ArcGIS 10.0 to develop a LiDAR to Digital Elevation Model workflow for the U.S. Army Corps of Engineers, Sacramento District Regulatory Division**. Sacramento: American River College. 2012. Disponível em: https://ic.arc.losrios.edu/~veiszep/28fall2012/Fancher/G350_ZFancher.html. Acesso em: 10 fev. 2018.

FAYAD, I. et al. Aboveground biomass mapping in French Guiana by combining remote sensing, forest inventories and environmental data. **International Journal of Applied Earth Observation and Geoinformation**, Enschede, v. 52, p. 502–514, 2016.
<https://doi.org/10.1016/j.jag.2016.07.015>.

FELDPAUSCH, T.R. et al. Height-diameter allometry of tropical forest trees. **Biogeosciences**, Hoboken, v.8, n.5, p.1081–1106, 2011. <https://doi.org/10.5194/bg-8-1081-2011>.

FERRAZ, A. et al. LiDAR detection of individual tree size in tropical forests. **Remote Sensing of Environment**, New York, v.183, p.318–333, 2016.
<https://doi.org/10.1016/j.rse.2016.05.028>.

FIGUEIREDO, E. O. **Modelagem biométrica para árvores individuais a partir do LIDAR em área de manejo de precisão em florestas tropicais na Amazônia Ocidental**. 2014. 86 f. Tese (Doutorado em Ciências de Florestas Tropicais). Instituto Nacional de Pesquisas da

Amazônia, Manaus. 2014. Disponível em: <http://bdtd.inpa.gov.br/handle/tede/1559>. Acesso em: 10 fev. 2018.

FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS- FAO. **Global forest resources assessment 2000**. Main report. Rome: FAO Forestry Paper 140, 2001.

GARIGLIO, M. A. et al. **Uso sustentável e conservação dos recursos florestais da caatinga**. Brasília: Serviço Florestal Brasileiro, 2010.

GHOSH, S.M., BEHERA, M.D. Aboveground biomass estimation using multi-sensor data synergy and machine learning algorithms in a dense tropical forest. **Applied Geography**, Oxford, v.96, p.29–40, 2018. <https://doi.org/10.1016/j.apgeog.2018.05.011>.

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

GONÇALVES, F. et al. Estimating Aboveground Biomass in Tropical Forests: Field Methods and Error Analysis for the Calibration of Remote Sensing Observations. **Remote Sensing**, Basel, v.9, n.1, 2017. <https://doi.org/10.3390/rs9010047>.

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

GÖRGENS, E. B. et al. Stand volume models based on stable metrics as from multiple ALS acquisitions in Eucalyptus plantations. **Annals of Forest Science**, Les Ulis, v. 72, n. 4, p. 489–498, 2015a. <https://doi.org/10.1007/s13595-015-0457-x>.

GÖRGENS, E. B.; MONTAGHI, A.; RODRIGUEZ, L. C. E. A performance comparison of machine learning methods to estimate the fast-growing forest plantation yield based on laser scanning metrics. **Computers and Electronics in Agriculture**, New York, v. 116, p. 221–227 2015b. <https://doi.org/10.1016/j.compag.2015.07.004>.

HANSEN, M.C. et al. High-Resolution Global Maps of 21st-Century Forest Cover Change. **Science**, New York, v.342, p.850–853, 2013. <https://doi.org/10.1126/science.1244693>.

HERNANDEZ-STEFANONI, J. L. et al. Estimating species richness and biomass of tropical dry forests using LIDAR during leaf-on and leaf-off canopy conditions. **Applied Vegetation Science**, Bethesda, v.18, n.4, p. 724–732, 2015. <https://doi.org/10.1111/avsc.12190>.

HIGUCHI, N; SANTOS, J; LIMA, A.N. **Biometria Florestal**. Manaus: Instituto Nacional de Pesquisas da Amazônia, 2008.

HOLM, J.A. et al. Gap model development, validation, and application to succession of secondary subtropical dry forests of Puerto Rico. **Ecological Modelling**, Amsterdam, v.233, p.70–82, 2012. <https://doi.org/10.1016/j.ecolmodel.2012.03.014>.

HOUGHTON, R. A. Aboveground forest biomass and the global carbon balance. **Global Change Biology**, Oxford, v. 11, n.6, p. 945–958, 2005. <https://doi.org/10.1111/j.1365-2486.2005.00955.x>.

HUMBOLDT STATE UNIVERSITY. 2017. Disponível em: http://gsp.humboldt.edu/OLM/Courses/GSP_216_Online/lesson7-1/data.html. Acesso em: 02 fev. 2017.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA -IBGE. **Mapa de Biomas e de Vegetação**, 2004. Disponível em: <https://ww2.ibge.gov.br/home/presidencia/noticias/21052004biomashtml.shtml>. Acesso em: 02 mai. 2017.

IPCC. **IPCC SPECIAL REPORT: SUMMARY FOR POLICYMAKERS. Land Use, Land-Use Change and Forestry**. Washigton: University of North Texas Libraries, 2000.

JANZEN, D.H. Tropical Dry Forests: The Most Endangered Major Tropical Ecosystem. In: Wilson, E.O. and Peters, F.M. (Ed.). **Biodiversity**. Washington: National Academy Press. 1988. p.130-144.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: uma perspectiva em Recursos Terrestres**. Tradução de J. C. N. Epiphanio. São José dos Campos: Parênteses, 2009. Tradução de: Remote Sensing of the environment: na earth resource perspective.

KAUFFMAN, J. B. et al. Biomass and nutrient dynamics associated with slash fires in neotropical dry forests. **Ecology**, Brooklin, v.74, n.1, p.140-151, 1993. <https://doi.org/10.2307/1939509>.

LATIFI, H. et al. Stratified aboveground forest biomass estimation by remote sensing data. **International Journal of Applied Earth Observation and Geoinformation**, Enschede, v. 38, p. 229–241, 2015. <https://doi.org/10.1016/j.jag.2015.01.016>.

LEFSKY, M.A. et al. Surface LiDAR remote sensing of basal area and biomass in deciduous forests of eastern Maryland, USA. **Remote Sensing of Environment**, New York, v. 67, n.1, p. 83-98, 1999. [https://doi.org/10.1016/S0034-4257\(98\)00071-6](https://doi.org/10.1016/S0034-4257(98)00071-6).

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. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/183481/1/Vanderlise.pdf>. Acesso em: 5 fev. 2018.

LÓPEZ, F. J. A. **Fundamentos de Evaluación de la Calidad de la Información Geográfica**. Jaén: Universidad de Jaén, 2013.

MACEDO, R. C. **Estimativa volumétrica de povoamento clonal de Eucalyptus sp através de laserscanner aerotransportado**. 2009. 145 p. Dissertação (Mestrado em Sensoriamento Remoto). Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2009.

MARTINS, B. F. **Uso da tecnologia LiDAR para classificação da capacidade produtiva de povoamentos de eucalipto**. 2015. 24 p. Dissertação (Mestrado em Ciência Florestal). Universidade Federal de Viçosa, Viçosa, 2015.

MEANS, J. E. et al. Use of large-footprint scanning airborne LiDAR to estimate forest stand characteristics in the western Cascades of Oregon. **Remote Sensing of Environment**, New York, v. 67, n.3, p. 298–308, 1999. [https://doi.org/10.1016/S0034-4257\(98\)00091-1](https://doi.org/10.1016/S0034-4257(98)00091-1).

MILES, L. et al. A global overview of the conservation status of tropical dry forests. **Journal of Biogeography**, Oxford, v.33, n.3, p.491–505, 2006. <https://doi.org/10.1111/j.1365-2699.2005.01424.x>.

MORO, M. F. **Síntese florística e biogeográfica do Domínio Fitogeográfico da Caatinga**. 2013. 366 p. Tese (Doutorado em Biologia Vegetal) - Universidade Estadual de Campinas, Campinas, 2013. Disponível em: repositorio.unicamp.br/bitstream/REPOSIP/314962/1/Moro_MarceloFreire_D.pdf. Acesso em: 04 fev. 2019.

MURPHY, P.G., LUGO, A.E. Structure and Biomass of a Subtropical Dry Forest in Puerto Rico. **Biotropica**, Washington, v.18, n.2, p. 89-96, 1986a. <https://doi.org/10.2307/2388750>.

MURPHY, P. G.; LUGO, A. E. Ecology of tropical dry forest. **Annual review of ecology and systematics**, Palo Alto, v. 17, p. 67-88, 1986b. <https://doi.org/10.1146/annurev.es.17.110186.000435>.

MURPHY, M. A.; EVANS, J. S.; STORFER, A. Quantifying *Bufo boreas* connectivity in Yellowstone National Park with landscape genetics. **Ecology**, Brooklyn, v. 91, n. 1, p. 252–261, 2010. <https://doi.org/10.1890/08-0879.1>.

NÆSSET, E. Estimating timber volume of forest stands using airborne laser scanner data. **Remote Sensing of Environment**, New York, v. 61, n. 2, p. 246–253, 1997. [https://doi.org/10.1016/S0034-4257\(97\)00041-2](https://doi.org/10.1016/S0034-4257(97)00041-2).

NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION COASTAL SERVICES CENTER-NOAA. **LiDAR 101: An introduction to LiDAR technology, data, and applications**. Charleston: NOAA Coastal Services Center. 2012.

NELSON, R.; KRABILL, W.; TONELLI, J. Estimating forest biomass and volume using airborne laser data. **Remote Sensing of Environment**, New York, v. 24, n.2, p. 247–267, 1988. [https://doi.org/10.1016/0034-4257\(88\)90028-4](https://doi.org/10.1016/0034-4257(88)90028-4).

PATENAUME, G. et al. Quantifying forest above ground carbon content using LiDAR remote sensing. **Remote Sensing of Environment**, New York, v. 93, n.3, p. 368–380, 2004. <https://doi.org/10.1016/j.rse.2004.07.016>.

PEINHOPF, C. **Determinação de variáveis dendrométricas de Eucalyptus urograndis com dados LiDAR Aerotransportado**. 2012. 55f. Dissertação (Mestrado em Ciências Florestais). Universidade Estadual do Centro - Oeste, Irati, 2012.

PENNINGTON, R.T., LEHMANN, C.E.R., ROWLAND, L.M., 2018. Tropical savannas and dry forests. **Current Biology**, London, v.28, n.9, p.541-545. <https://doi.org/10.1016/j.cub.2018.03.014>.

PICARD, N. et al. Plot-level variability in biomass for tropical forest inventory designs. **Forest Ecology and Management**, Amsterdam, v.430, p.10–20, 2018. <https://doi.org/10.1016/j.foreco.2018.07.052>.

PORTILLO-QUINTERO, C.A; SÁNCHEZ-AZOFÉIFA, G.A. Extent and conservation of tropical dry forests in the Americas. **Biological Conservation**, Essex, v.143, n.1, p. 144–155, 2010. <https://doi.org/10.1016/j.biocon.2009.09.020>.

ROOPSIND, A. et al. Trade-offs between carbon stocks and timber recovery in tropical forests are mediated by logging intensity. **Global Change Biology**, Oxford, v.24, p.2862–2874, 2018. <https://doi.org/10.1111/gcb.14155>

ROSA, G. Q. **Estoque de carbono em diferentes usos da terra e dinâmica das raízes finas em floresta tropical seca.** 2018. 105f. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Federal do Ceará, 2018. Disponível em: http://repositorio.ufc.br/bitstream/riufc/33119/3/2018_dis_gqrosa.pdf. Acesso em: 04 fev. 2019.

SAMPAIO, E.V.S.B.; SALCEDO, I. H; KAUFFMAN, J.B. Effect of different fire severities on coppicing of caatinga vegetation in Serra Talhada, PE, Brazil. **Biotropica**, Lawrence, v.25, n.4, p.452-460, 1993.

SAMPAIO, E. V. S. B. et al. Regeneração da vegetação de caatinga após corte e queima em Serra Talhada. **Pesquisa Agropecuária Brasileira**, Brasília, v.33, n.5, p.621-632, 1998. Disponível em: <http://seer.sct.embrapa.br/index.php/pab/article/view/4890>. Acesso em: 01 fev. 2019.

SAMPAIO, E.V.S.B., SILVA, G.C. Biomass equations for Brazilian semiarid caatinga plants. **Acta Botanica Brasilica**, Porto Alegre-RS, v.19, n.4, p.935–943, 2005. <https://doi.org/10.1590/S0102-33062005000400028>.

SAMPAIO, E. V. S. B.; FREITAS, A. D. S. Produção de biomassa na vegetação nativa do semi-árido nordestino. In: MENEZES, R. S. C.; SAMPAIO, E. V. S. B.; SALCEDO, I. H. (Orgs.). **Fertilidade do solo e produção de biomassa no semi-árido**. Recife: Editora Universitária UFPE, 2008. v. 1, p. 11-26.

SAMPAIO, E. V. S. Características e potencialidades. In: GARIGLIO, M. A. et al. (Orgs.) **Uso sustentável e conservação dos recursos florestais da Caatinga**. Brasília: Serviço Florestal Brasileiro, 2010. p. 29-42.

SAMPAIO, E. et al. Tree biomass estimation in regenerating areas of tropical dry vegetation in northeast Brazil. **Forest Ecology and Management**, Amsterdam, v.259, n.6, p.1135–1140, 2010. <https://doi.org/10.1016/j.foreco.2009.12.028>.

SANCHEZ-AZOFÉIFA, G.A. et al. Research priorities for neotropical dry forests. **Biotropica**, Washington, v.37, n.3, p. 477–485, 2005. <https://doi.org/10.1111/j.1744-7429.2005.00066.x>.

SEXTON, J.O. et al. Conservation policy and the measurement of forests. **Nature Climate Change**, London, v.6, p.192–196, 2016. <https://doi.org/10.1038/nclimate2816>.

SILVA, C. A. Carbono na parte aérea de plantios de Eucalyptus spp. – em nível de árvore por amostragem destrutiva e para talhões inteiros após o ajuste de métricas

LiDAR. 2013. 152 p. Dissertação (Mestrado em Recursos Florestais). Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2013.

SILVA, C. A.; Kaluberg, C.; Hudak, A. et al. Aplicando filtro local máximo (LM) através dos métodos da janela fixa e variável em dados LIDAR para identificação de árvores individuais em um povoamentos de *Eucalyptus*sp.. In: XVI SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, XVI. 2013, Foz do Iguaçu.**Anais...** Foz do Iguaçu: INPE. 2013. P. 6081-6088.

SILVA, C. et al. Impacts of Airborne LiDAR Pulse Density on Estimating Biomass Stocks and Changes in a Selectively Logged Tropical Forest. **Remote Sensing**, Basel, v.9, n.10, 1068, 2017. <https://doi.org/10.3390/rs9101068>.

SUN, G. et al. Forest biomass mapping from LiDAR and radar synergies. **Remote Sensing of Environment**, New York, v.115, n.11, p.2906–2916, 2011. <https://doi.org/10.1016/j.rse.2011.03.021>.

SUNDERLAND, T. et al. Global dry forests: a prologue. **International Forestry Review**, Shropshire, v.17, p.1-9, 2015.

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>.

TIESSEN, H. et al. Carbon sequestration and turnover in semiarid savannas and dry forests. **Climatic Change**, Dordrecht, v. 40, n. 1, p.105-117, 1998. <https://doi.org/10.1023/a:1005342932178>.

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

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

WHITE, J. C. W. et al. **A best practices guide for generating forest inventory attributes from airborne laser scanning data using an area-based approach**. 2 ed. Victoria:Canadian Wood Fibre Centre,2013.

WHITMORE, T.C. **An introduction to tropical rain forests.** London: Oxford University Press. 1990.

ZHAO, K.; POPESCU, S.; NELSON, R. LiDAR remote sensing of forest biomass: a scale-invariant estimation approach using airborne lasers. **Remote Sensing of Environment**, New York, v. 113, n. 1, p. 182–196, 2009. <https://doi.org/10.1016/j.rse.2008.09.009>.

ZONETE, M. F. **Análise do uso da tecnologia laser aerotransportado para inventários florestais em plantios clonais de Eucalyptus sp. no sul da Bahia.** 2009. 95 p. Dissertação (Mestrado em Recursos Florestais). Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2009.

CAPÍTULO 1

ESTIMATIVA DE BIOMASSA EM FLORESTA TROPICAL SECA: UMA ABORDAGEM SOBRE EQUAÇÕES GENÉRICAS

1 INTRODUÇÃO

As florestas tropicais secas são um grande reservatório de biomassa viva acima do solo, desempenham um papel fundamental no ciclo global do carbono e são amplamente reconhecidas como um dos principais ecossistemas que servem como barreira à desertificação (ABICH et al., 2018; GUHA et al., 2018; SALINAS-MELGOZA et al., 2018). Os esforços atuais para quantificar os estoques globais de biomassa e carbono acima do solo, nessas florestas, compreendem a dinâmica e a produtividade (WAGNER et al., 2014; AVITABILE et al., 2016; ALTHOFF et al., 2018), avaliam o potencial de conservação para mitigar as mudanças climáticas (SALIS et al., 2006; BASTIN et al., 2017) e examinam as relações de função ecossistêmica da biodiversidade (CHAVE et al., 2005; 2014; HILTNER et al., 2018). Todos esses casos dependem, quase que exclusivamente, de estimativas robustas de armazenamento de carbono e biomassa acima do solo (AGB).

Um grande esforço vem sendo desenvolvido por pesquisadores ao empregar técnicas de sensoriamento remoto para estimar a biomassa em florestas tropicais (BACCINI; ASNER, 2013; AVITABILE et al., 2016; KACHAMBA et al., 2017; JUCKER et al., 2017; 2018; BOUVET et al., 2018; GONZALEZ de TANAGO et al., 2018), embora ainda seja comum o AGB ser estimado em níveis locais e pantropicais por modelos alométricos a partir de inventários tradicionais (SAMPAIO et al., 2010; CHAVE et al., 2014; SULLIVAN et al., 2018).

É, portanto, correto afirmar que a obtenção da biomassa por meio de modelos alométricos é, substancialmente, importante nos inventários florestais (por exemplo AVITABILE; CAMIA, 2018; GONZALEZ de TANAGO et al., 2018), principalmente para as áreas de florestas secas desmatadas, pois, além de dar suporte para estimativas da dinâmica de carbono local (ALTHOFF et al., 2018), fornece informações para a compreensão da concentração em diferentes escalas continentais (CHAVE et al., 2005; 2014).

No entanto, em florestas tropicais secas, os modelos alométricos que relacionam a biomassa apenas com o diâmetro da árvore podem ter um desempenho ruim nas previsões de biomassa (NÁVAR et al., 2013; CHATURVEDI; RAGHUBANSI, 2015), principalmente quando comparados com modelos que incluem a altura da árvore e/ou densidade básica da

madeira (ALI; MATTSSON, 2018) e são parametrizados em escalas locais, regionais ou continentais (CHAVE et al., 2014; ABICH et al., 2018). De acordo com Sullivan et al.(2018), existem três motivos pelos quais essas relações alométricas simples tendem a gerar estimativas enviesadas.

Em primeiro lugar, a faixa completa de diâmetros locais pode não ser amostrado, o que significa que as equações derivadas localmente extrapolam o intervalo de dados usado para treiná-los (ELITH; LEATHWICK, 2009); em segundo lugar, as relações não-lineares, como AGBs individuais máximos, podem não ser evidentes em conjuntos menores de dados de treinamento (DUNCANSON et al., 2015) e, em terceiro lugar, as equações podem ser excessivamente influenciados por outliers (árvores que são incomumente altas ou curtas para seu diâmetro).

Os dados de densidade básica da madeira e da altura das árvores são componentes importantes desta relação alométrica, pois a biomassa está, diretamente, ligada à gravimetria da madeira e é, parcialmente, uma função de seus volumes, que é uma função de sua altura, área basal e conicidade do tronco (CHAVE et al., 2005; SULLIVAN et al., 2018). Muito embora a obtenção da densidade básica da madeira e da altura das árvores, nos inventários florestais, não seja uma tarefa fácil (LARJAVAARA; MULLER-LANDAU, 2013; BASTIN et al., 2015), a incorporação de um parâmetro que relate essas variáveis é conhecida por melhorar, marcadamente, as estimativas de biomassa de árvore individual em escalas locais (SAMPAIO; SILVA, 2005; SAMPAIO et al., 2010; LIMA et al., 2017; DALLA-LANA et al., 2018), e também tem um efeito substancial em escalas pantropicais (FELDPAUSCH et al., 2012; SULLIVAN et al., 2018). Como resultado, na prática, isso pode levar à incorporação dessas variáveis no monitoramento de carbono em programas de Redução de Emissões decorrentes do Desmatamento e da Degradação de florestas- REDD+ (PELLETIER et al., 2017; SULLIVAN et al., 2018).

Vários modelos pantropicais foram, portanto, desenvolvidos para estimar a biomassa em florestas tropicais secas, sendo empregados modelos que relacionam a biomassa apenas com o diâmetro (BROWN et al., 1989; BROWN et al., 1997; NÁVAR, 2015); diâmetro, altura e densidade básica (CHAVE et al., 2005); e, mais recentemente, modelos baseados no clima (CHAVE et al., 2014). No entanto, pode-se esperar que essas relações variem em várias escalas ambientais e espaciais (CREZEE, 2015; UBUY et al., 2018), sugerindo que mesmo esses modelos pantropicais ou locais desenvolvidos carecem da sofisticação necessária para muitas aplicações (RUTISHAUSER et al., 2013).

Além disso, seria muito útil entender, em geral, como a densidade básica e a altura da árvore afetam a confiabilidade de modelos em escala local em floresta tropical seca brasileira. Em particular, ecologistas e profissionais, com o objetivo de obter melhor precisão das estimativas de biomassa florestal, beneficiar-se-iam do(s) conhecimento(s) de que os modelos derivados localmente superam, consistentemente, os regionais e pantropicais, principalmente quando verificada a importância da medição da densidade básica e da altura da árvore.

Este trabalho foi desenvolvido com o intuito de gerar uma equação genérica local para previsão de biomassa acima do solo em floresta seca no Nordeste do Brasil. Os objetivos específicos foram (1) examinar como as equações derivados do local afetam os erros de previsão e (2) testar diferentes modelos pantropicais aos dados locais para verificar a melhoria de previsão de biomassa quando um modelo local não está disponível para áreas com e sem alteração em sua estrutura.

2 MATERIAL E MÉTODOS

2.1 Área de estudo e dados coletados

Os dados utilizados no presente estudo foram coletados a partir de árvores colhidas em uma área submetida ao manejo florestal (ALVES JÚNIOR, 2010), localizada no município de Floresta (Figura 1), estado de Pernambuco ($8^{\circ}30'37''S$ e $37^{\circ}59'07''W$). A vegetação é, predominantemente, de Caatinga (floresta tropical seca), caracterizada por vegetação arbustivo–arbórea, com presença de cactáceas e estrato herbáceo (IBGE, 2012).

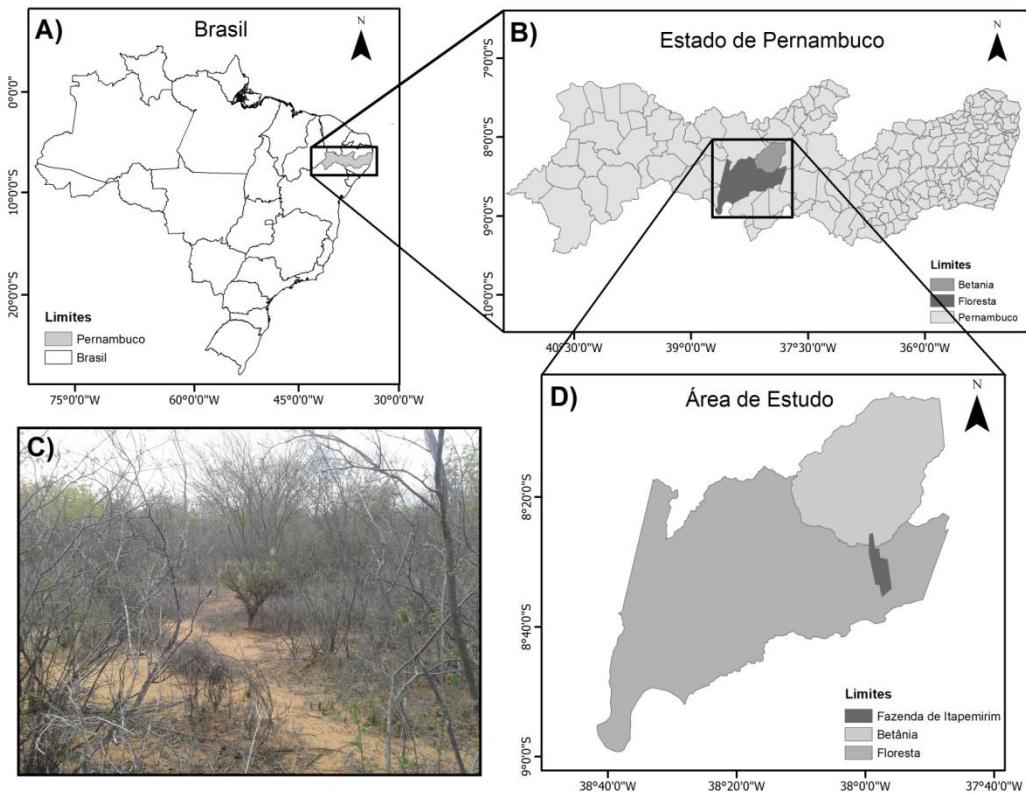


Figura 1 - Recobrimento e delimitação da área de estudo (A, B e D) e foto do perfil em Floresta (C) submetida ao manejo florestal, no sertão de Pernambuco, Brasil.

O clima, segundo a classificação de Köppen, é do tipo BSh, semiárido quente, apresentando precipitação média anual de, aproximadamente, 400 a 500 mm, com período chuvoso de janeiro a abril, e temperatura média anual de 26,1 °C. O município possui uma área de 3.690,3 km² e uma altitude média variando de 300 a 1.050m (EMBRAPA, 2001).

De acordo com Alves Júnior (2010), foram mensurados o peso verde acima do solo (fuste e galhos), alturas total e comercial, diâmetro da base (0,30 cm do nível do solo) e diâmetro da altura do peito (1,30 cm do nível do solo) de 507 árvores distribuídas em 14 espécies e 12 gêneros (Tabela 1).

As árvores foram colhidas com um diâmetro mínimo na base do caule (Db) de 1,9 cm, até o máximo encontrado na área e cobriram uma ampla faixa de amostragem para diâmetro e alturas. Neste estudo, foram considerados os valores locais de densidade da madeira das espécies obtidos por Montoya (2017), e, quando não disponíveis, foi consultado o banco de dados global (CHAVE et al., 2014), disponível em: <https://datadryad.org/handle/10255/dryad.235>. Apesar da falta de dados suficientes, vários estudos recomendam a densidade média de madeira em nível de gênero para avaliação de biomassa (HENRY et al., 2011; UBUY et al., 2018).

Tabela 1 – Características dendrométricas de espécies arbustivo-arbóreas usadas para desenvolver equações de biomassa local em floresta tropical seca, no semiárido pernambucano, Brasil.

Espécies	N	WD	Db(cm)			Ht(m)			Peso verde (kg)		
			Mín	Médio	Máx	Mín	Médio	Máx	Mín	Médio	Máx
<i>Anadenanthera colubrina</i> var. <i>cebil</i> (Griseb.) Altschul	17	0,79	2,55	8,57	18,78	3,20	5,61	8,00	1,30	44,16	145,00
<i>Aspidosperma pyrifolium</i> Mart.	45	0,74	2,07	4,60	9,55	2,50	3,84	5,40	0,50	7,92	52,00
<i>Bauhinia cheilanta</i> (Bong). Steud.	19	0,79	1,91	2,25	3,18	2,10	3,11	4,20	0,15	0,77	2,00
<i>Cnidoscolus phyllacanthus</i> (Muill. Arg.) Pax & L. Hoffm.	5	0,55	7,32	12,29	17,19	5,80	6,58	7,60	17,00	71,90	132,00
<i>Commiphora leptophloeos</i> (Mart.) J.B. Gillett	7	0,39	6,37	17,37	27,37	4,20	6,30	8,30	17,00	215,71	536,00
<i>Croton</i> spp.	68	0,59	1,91	2,58	6,37	2,00	3,27	5,20	0,25	1,55	11,00
<i>Jatropha mollissima</i> Muell. Arg.	5	0,29	2,23	3,18	4,77	2,00	2,82	3,20	0,50	2,18	4,00
<i>Manihot glaziovii</i> Muell. Arg.	4	0,38	4,14	7,64	11,78	4,40	5,60	7,80	8,40	19,23	36,50
<i>Mimosa ophthalmocentra</i> Mart. ex Benth.	81	0,71	1,91	3,33	5,09	3,00	3,89	5,40	0,30	3,72	16,00
<i>Mimosa tenuiflora</i> (Willd.) Poir.	22	1,12	2,23	7,22	16,87	3,20	5,43	9,10	1,50	26,90	149,00
<i>Piptadenia stipulacea</i> (Benth.) Ducke	21	0,74	2,07	3,93	7,00	3,40	5,24	8,80	0,50	6,87	23,00
<i>Poincianella bracteosa</i> (Tul.) L.P.Queiroz	202	0,99	1,91	4,96	14,48	2,10	4,02	6,80	0,50	8,35	45,00
<i>Erythrostemon calycina</i> (Benth.) L.P.Queiroz	3	1,01	2,23	2,33	2,55	3,40	3,57	3,70	0,50	0,97	1,30
<i>Thiloa glaucocarpa</i> (Mart.) Eichl	7	0,63	1,91	2,36	2,71	2,80	3,43	4,00	0,25	0,89	1,10

Em que: n = número de indivíduos colhidos; WD = Densidade aparente da madeira (g cm^{-3}); Db = diâmetro da base (cm); Ht = altura total (m); Min = mínimo; Máx = máximo.

2.2 Ajuste das equações alométricas

Após a medição, os dados biométricos foram divididos aleatoriamente em dois subconjuntos para ajuste e validação de modelos alométricos utilizando a ferramenta de validação cruzada – *Hold-out*, em que os dados são divididos em K partes, e cada parte é usada tanto para treino como para teste, de forma que todas as partes passem por ambos os lados.

Foram testados três modelos alométricos de regressão simples (diâmetro da base como variável explicativa) e cinco modelos de regressão múltipla, sendo as variáveis explicativas o diâmetro da base, altura total e densidade da madeira, combinadas ou não (posteriormente referidos como equações derivadas localmente, Tabela 2).

Os parâmetros dos modelos foram estimados por meio do método dos mínimos quadrados ordinários (OLS – *Ordinary Least Squares*), sendo verificado a significância por meio do teste t ($p = 0,05$). De modo geral, os parâmetros foram estimados usando os dados totais das árvores mensuradas e são assumidos como os verdadeiros parâmetros que representam a alometria.

Tabela 2 – Modelos alométricos testados para estimativa de biomassa acima do solo em floresta tropical seca do semiárido pernambucano, Brasil.

Autor	Modelo	Variáveis
1. Husch	1. AGB = $\exp(\beta_0 + \beta_1 \times \ln(D) + \varepsilon_i)$	AGB = f(Db)
2. Koperzky-Gehrhardt	2. AGB = $\exp(\beta_0 + \beta_1 \times \ln(D)^2 + \varepsilon_i)$	AGB=f(Db)
3. Hohenald-Krenn (FINGER, 1992)	3. AGB = $\exp(\beta_0 + \beta_1 \times \ln(D) + \beta_2 \times \ln(D)^2 + \varepsilon_i)$	AGB =f(Db)
4. Spurr (1952)	4. AGB = $\exp(\beta_0 + \beta_1 \times \ln(D^2 \times Ht))$	AGB =f(Db,Ht)
5. Schumacher-Hall (1933)	5. AGB = $\exp(\beta_0 + \beta_1 \times \ln(D) + \beta_2 \times \ln(Ht) + \varepsilon_i)$	AGB =f(Db,Ht)
6. Chave - Modelo I	6. AGB = $\exp(\beta_0 + \beta_1 \times \ln(D) + \beta_2 \times \ln(Ht) + \beta_3 \times \ln(WD) + \varepsilon_i)$	AGB =f(Db,Ht, WD)
7. Chave - Modelo II	7. AGB = $\exp(\beta_0 + \beta_1 \times \ln(D) + \beta_2 \times \ln(D)^2 + \beta_3 \times \ln(D)^3 + \beta_4 \times \ln(WD) + \varepsilon_i)$	AGB =f(Db,WD)
8. Chave - Modelo III	8. AGB = $\exp(\beta_0 + \beta_1 \times \ln(D^2 \times Ht \times WD) + \varepsilon_i)$	AGB =f(Db,Ht, WD)

Em que: β_i = parâmetros a serem estimados; D = diâmetro medido a 0,30 m do comprimento do tronco (Db cm); Ht = altura total em metros; WD = densidade da madeira em g cm⁻³; AGB = peso verde acima do solo em kg; ε_i = erro aleatório.

As equações locais geradas foram avaliadas, segundo Vanclay (2001) e Schneider et al. (2009), por meio de comparações dos seguintes critérios estatísticos:

– Critério de Informação de Akaike (AIC):

$$AIC = -2LL + 2k \quad (\text{Eq. 1})$$

Em que: LL é a log-verossimilhança e k é o número de parâmetros do modelo. Este critério penaliza a adição de parâmetros nos modelos analisados. Indica a qualidade do ajuste pelas equações. A melhor equação minimiza o valor do AIC.

– Coeficiente de determinação ajustado (R^2_{aj}):

$$R^2_{aj} = R^2 - \left[\frac{k-1}{n-k} \right] \times (1-R^2) \quad (\text{Eq. 2})$$

Em que: R² = coeficiente de determinação; n = número de observações; k já definido anteriormente. Por este critério, quanto mais próximo de um (1,0) ou 100 % for o valor do coeficiente de determinação ajustado, maior será a variação total dos dados explicada pela equação.

– Raiz quadrada do erro médio (RMSE):

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (AGB_i - \bar{AGB}_i)^2}{n}} \quad (\text{Eq. 3})$$

Em que AGB_i é a biomassa observada acima do solo da árvore (i); \widehat{AGB}_i é a estimativa da biomassa e n , o número total de observações. A raiz quadrada do erro médio indica a diferença média quadrática entre os valores observados e estimados. Quanto menor o RMSE, melhor a precisão da estimativa.

– Bias:

$$\text{Bias} = \frac{\sum_{i=1}^n (AGB_i - \overline{AGB}_i)^2}{n} / \overline{AGB} \quad (\text{Eq. 4})$$

Em que \overline{AGB}_i é a média aritmética da biomassa observada. Esta estatística indica uma tendência de sub ou superestimação, sendo uma medida de erro e, também, medida de qualidade nas previsões realizadas, de modo que, quanto menor o erro, maior a eficiência nas generalizações.

2.3 Predições alométricas

As equações alométricas locais desenvolvidas neste estudo foram comparadas com equações genéricas locais/pantropicais desenvolvidas para áreas de florestas secas usando apenas o diâmetro, ou/e em combinação com altura (Ht) e densidade da madeira (WD) como variáveis preditoras (Tabela 3).

Tabela 3 – Equações alométricas genéricas de abrangência local e pantropical usadas para estimar a biomassa (Kg) acima do solo em floresta tropical seca com base no diâmetro (Db, cm), na altura (Ht, m) e na densidade básica da madeira (WD, gcm³).

Autor/Abrangência	Equações - AGB (kg)
Brown et al. (1989): Pan-tropical	$AGB = 34,4703 + 8,0671 \times (Db) + 0,6589 \times (Db^2)$
Brown et al. (1997): Pan-tropical	$AGB = \exp(-1,996 + 2,32 \times \log(Db))$
Návar(2015): Pan-tropical	$AGB = 0,0841 \times Db^{2,41}$
Chave et al.(2005) - Type II.1: Pan-tropical	$AGB = \exp(-1,023 + 1,821 \times \log(Db) + 0,198 \times \log(Db^2) - 0,0272 \times \log(Db^3) + 0,388 \times \log(wd))$
Chave et al.(2005) - Type II.3: Pan-tropical	$AGB = \exp(-0,73 + 1,784 \times \log(Db) + 0,207 \times \log(Db^2) - 0,0281 \times \log(Db^3) + \log(wd))$
Chave et al.(2005) - Type I.1: Pan-tropical	$AGB = \exp(-2,68 + 1,805 \times \log(Db) + 1,038 \times \log(Ht) + 0,377 \times \log(wd))$
Chave et al.(2005) - Type I.5: Pan-tropical	$AGB = \exp(-2,843 + \log(Db^2 \times Ht \times wd))$
Sampaio e Silva(2005): Local	$AGB = 0,0292 \times (Db \times Ht)^{1,6731}$
Dalla-Lana et al. (2018): Local	$AGB = \exp(-1,288 + 1,610 \times \log(Db) + 0,434 \times \log(Ht))$
Barreto et al. (2018): Local	$AGB = 0,38 \times Db^{1,73} \times Ht^{0,11}$

As equações alométricas pantropicais desenvolvidas para florestas tropicais secas foram aplicadas às árvores amostra deste estudo e são, amplamente, empregadas para prever as avaliações de estoque de AGB e C em regiões tropicais de florestas secas quando uma equação local não está disponível (ABICH et al., 2018). Foram feitas comparações entre o

AGB médio observado e o AGB previsto e, para cada equação, o viés do modelo (RSE), o AGB médio e o coeficiente de variação em nível de árvore (CV) foram obtidos conforme as Equações 5, 6 e 7.

$$RSE = \frac{1}{N} \sum_{i=1}^N \frac{[AGB_{ALTi} - AGB_{REFi}]}{AGB_{REFi}} AGB_{REFi} \quad (\text{Eq. 5})$$

$$\overline{AGB}_{(i)} = \frac{1}{N_{(j)}} \sum_{i \in (j)} AGB_{REF}(i) \quad (\text{Eq. 6})$$

$$CV(i)\% = \frac{RSE(i)}{\overline{AGB}(i)} \times 100 \quad (\text{Eq. 7})$$

Em que: AGB_{ALTi} e AGB_{REFi} são a estimativa de biomassa da árvore i obtida das equações desenvolvidas neste estudo e de outras regiões (locais e pan-tropicais) e de referência (AGB da árvore medida em campo), respectivamente. Um alto valor de $CV(i)$ seria aceitável desde que o viés seja baixo, porque, em geral, o modelo é aplicado a muitas árvores dentro de um sítio e, portanto, erros aleatórios tendem a anular-se (CHAVE et al., 2014).

Na segunda parte da validação, as predições de biomassa foram realizadas e comparadas por meio de análise de variância, usando delineamento inteiramente casualizado para verificar se as diferentes equações locais e pantropicais (tratamentos) causaram um efeito significativo na predição média de AGB (kg) a 95% de probabilidade. Quando identificada a diferença significativa, foi empregado o teste Tukey a 95% de probabilidade. Todas as computações e análises foram realizadas utilizando o software estatístico R® (R DEVELOPMENT CORE TEAM, 2017).

3 RESULTADOS E DISCUSSÃO

3.1 Equação de biomassa local

Entre as equações de biomassa desenvolvidas para o local, as obtidas pelos modelos logarítmicos de Schumacher-Hall e Chave – Modelo I (5 e 6) apresentaram melhor desempenho. Ambas equações produziram valores de RMSE, RSE, Bias e CV similares, porém, as melhores previsões indicam uma ligeira superioridade do modelo de Schumacher-Hall, explicando mais de 90% da variância total e menor valor de AIC (Tabela 4). Nota-se, também, que o parâmetro relacionado à densidade básica na equação de Chave – Modelo I não indica, necessariamente, significância estatística nas predições de biomassa. Além disto, com exceção das equações de Koperzyk-Gehrhardt e Chave – Modelo II, os demais modelos

ajustados apresentaram parâmetros significativos ($p < 0,05$) com intervalos de confiança válidos.

Tabela 4 – Estimativas de parâmetros e índices de adequação dos modelos alométricos para previsão de biomassa em Floresta Tropical Seca, Nordeste do Brasil.

Modelos locais	β_0	β_1	β_2	β_3	β_4	AIC	RSE	R^2 aj	RMSE	Bias	CV (%)
1	-2,5851*	2,3599*	-	-	-	702,52	0,4819	0,8715	19,9242	0,2718	3,77
2	-0,5999 ^{ns}	<i>0,6376^{ns}</i>	-	-	-	765,89	0,513	0,8543	65,0296	0,323	4,01
3	-2,1445*	1,8207*	0,1499*	-	-	697,72	0,4791	0,8729	13,5859	0,2705	3,74
4	-3,3722*	1,0053*	-	-	-	577,34	0,4259	0,8996	18,2462	0,2034	3,33
5	-3,5336*	1,9126*	1,2438*	-	-	573,77	0,4240	0,9005	18,285	0,2018	3,31
6	-3,5466*	1,9180*	1,2399*	-0,0406 ^{ns}	-	575,49	0,4243	0,9003	17,658	0,2010	3,32
7	-3,1093*	3,5856*	-0,8313 ^{ns}	0,1681	0,0083 ^{ns}	697,59	0,4777	0,8737	16,532	0,2670	3,73
8	-2,8154*	0,9325*	-	-	-	728,41	0,4943	0,8647	32,304	0,2762	3,86

Nota: Os valores em itálico não são significativos ($p \geq 0,05$) e o melhor modelo está em negrito. * significativo a 0,05.

As equações logarítmicas têm sido utilizadas, constantemente, no estudo das relações biométricas, principalmente, para o desenvolvimento de equações de biomassa em florestas tropicais secas (BROWN et al., 1989; CHAVE et al., 2005; SAMPAIO; SILVA, 2005; PACKARD; BOARDMAN, 2008; UBUY et al., 2018), embora poucos estudos tenham sido aplicados à transformação de volta da escala logarítmica para a escala original usando o fator corretivo (SPRUGEL, 1983). Além disto, R^2 é, frequentemente, usado para descrever a qualidade do ajuste do modelo, no entanto, poucos estudos calcularam o R^2 para dados transformados de volta (ou escala original), evidenciando um uso enganoso de R^2 ; uma vez que, há limitações de uso em modelos não lineares (ANDERSON-SPRECHER, 1994). Outros parâmetros como RMSE e Bias são raramente calculados com base na escala original dos resíduos. Ademais, métodos robustos para alavancar a qualidade do ajuste de modelos, como o critério de informação AIC ou Bayesiano, são pouco usados e devem ser incorporados em rotinas de ajuste de modelo alométrico (VIBRANS et al., 2015).

A equação de Schumacher-Hall selecionada prevê que a transformação logarítmica do diâmetro e da altura para um dado peso verde da árvore diminui o viés na estimativa. Estes resultados suportam a decisão de usar métodos de regressão para construir modelos e estimar seus parâmetros, sugerindo, portanto, que é mais parcimonioso manter um modelo alométrico de dupla entrada, neste caso, o modelo de Schumacher-Hall obtido para a área (Figura 2).

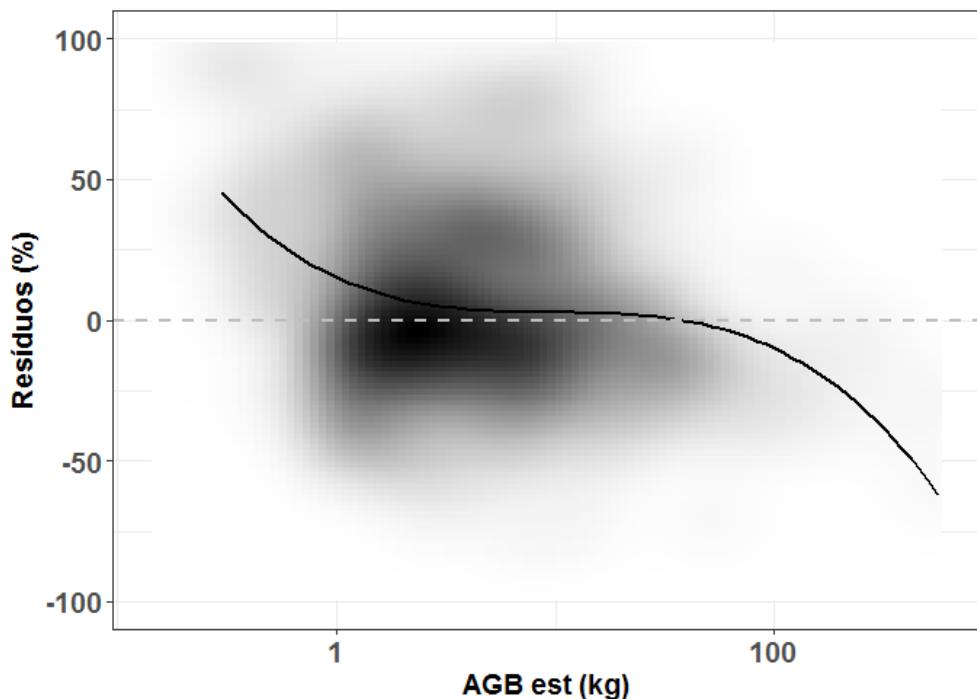


Figura 2 – Dispersão dos resíduos percentuais para a equação de Schumacher-Hall desenvolvida para previsão de biomassa em floresta tropical seca, no Nordeste do Brasil.

No gráfico de dispersão residual (Figura 2), observa-se linha suavizada com tendência nos maiores valores previstos de biomassa, com presença de poucos *outliers* nos menores valores. No entanto, deve-se considerar que os valores discrepantes sugerem uma curvatura, possivelmente, causada pelos erros do modelo, em vez dos dados selecionados para o ajuste (árvores que são incomumente altas ou curtas para seu diâmetro (SULLIVAN et al., 2018).

Estes resultados também estão de acordo com estudos realizados em florestas tropicais secas no Brasil (SAMPAIO; SILVA, 2005; SAMPAIO et al., 2010; BRAHMA et al., 2018; ROITMAN et al., 2018; DALLA-LANA et al., 2018; BARRETO et al. 2018) e em outras regiões nos trópicos (CHÁIDEZ, 2008; NÁVAR, 2009a; 2009b; NÁVAR et al., 2013; NÁVAR, 2015; ABICH et al., 2018).

3.2 Predições alométricas por equações genéricas locais e pantropicais

Para as outras equações locais e para as pantropicais, embora boa parte da variação da biomassa fosse explicada apenas pelo diâmetro, a melhora não foi evidente de forma significativa quando a altura e a densidade da madeira foram incluídas (Tabela 5). No entanto, em todas as predições geradas, a variação de biomassa para árvores de pequeno diâmetro é menor, sendo, similarmente, preditas pelas equações que incluem altura e/ou altura e densidade da madeira. Muito embora exista uma grande divergência nas

previsões para as árvores de maiores diâmetros quando a altura não está inclusa na predição, o que resulta em vieses percentuais, significativamente, maiores do que aqueles modelos que incluem altura (Figura 3).

Tabela 5 – Precisão e vieses para previsão de biomassa a partir de modelos pantropicais para floresta tropical seca, no Nordeste do Brasil.

Equações	Escala	Variável	R ²	RMSE	Bias	CV%
Brown et al. (1989)	Pan-tropical	Db	0,9023	16,0791	7,5796	297,99
Brown et al. (1997)	Pan-tropical	Db	0,8982	14,7558	0,9086	301,47
Návar (2009)	Pan-tropical	Db	0,9049	16,6454	0,3744	251,12
Chave et al. (2005) - Type II.1	Pan-tropical	Db/WD	0,8254	23,4906	2,1383	378,07
Chave et al. (2005) - Type II.3	Pan-tropical	Db/WD	0,6070	32,9759	2,5968	350,73
Chave et al. (2005) - Type I.1	Pan-tropical	Db/Ht/WD	0,8080	25,1675	0,5028	181,96
Chave et al. (2005) - Type I.5	Pan-tropical	Db/Ht/WD	0,6434	28,3263	0,4917	191,58
Sampaio e Silva (2005)	Local	Db/Ht	0,8662	18,8651	0,3236	242,37
Dalla-Lana et al. (2018)	Local	Db/Ht	0,8222	28,0706	1,1956	146,38
Barreto et al. (2018)	Local	Db/Ht	0,8185	27,3953	1,3992	154,21

Em que: R² = coeficiente de determinação; RMSE = raiz quadrática do erro médio (kg); CV = coeficiente de variação (%).

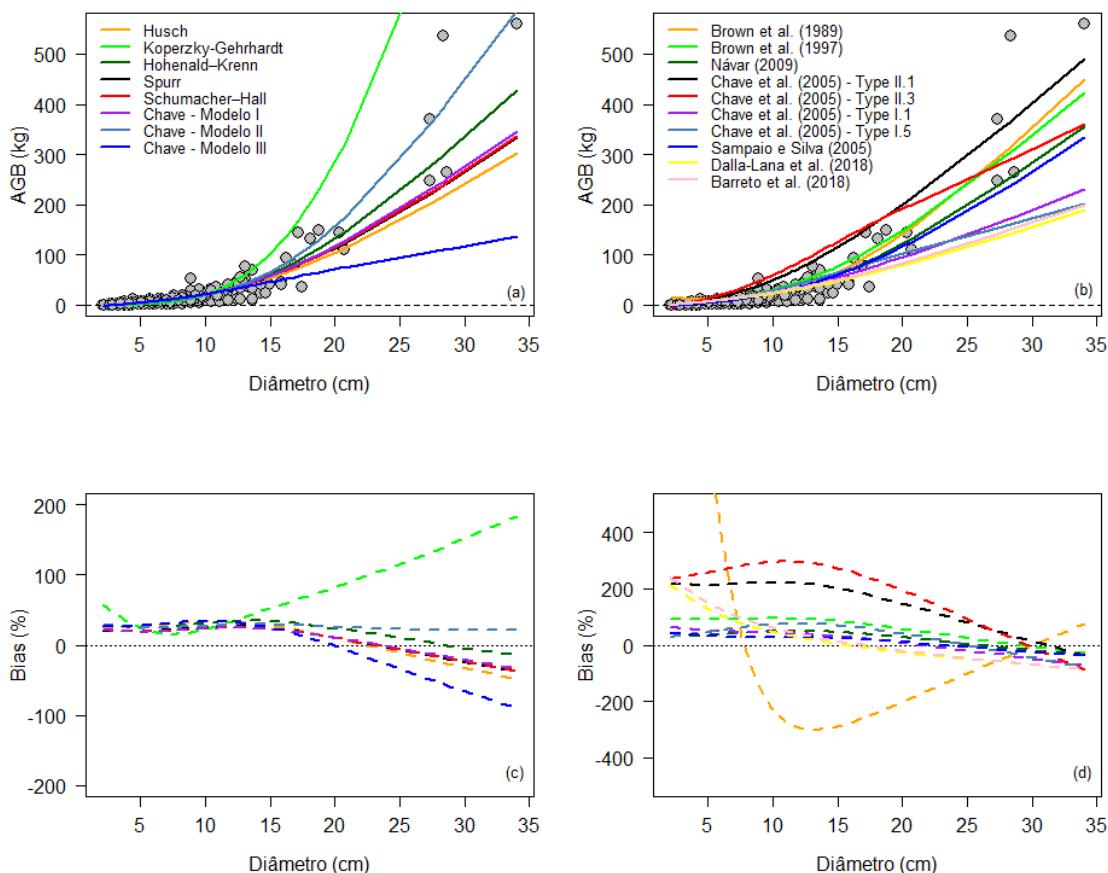


Figura 3 – Previsão de biomassa a partir das equações desenvolvidas para o local (a) e a partir de outras equações locais e pantropicais (b); e diferença percentual (bias) das previsões de biomassa em nível da árvore por classe de diâmetro para as equações locais (c) e de outras equações locais e pantropicais (d).

Em comparação com as equações desenvolvidas neste estudo, os erros médios (RMSE e Bias) da estimativa de biomassa das equações pantropicais validados ao nível da árvore não revelaram diferenças substancialmente visíveis, com exceção da equação local de Koperzky-Gehrhardt (Tabela 4) e a equação pantropical de Brown et al. (1989) (Tabela 5), que empregam apenas o diâmetro como variável preditora. A maior média de $CV_{(i)}$, em todas as comparações, foi de 378% para a equação que usa a densidade da madeira e diâmetro (Chave et al., 2005 – Type II.1); muito embora, a equação de Brown et al. (1989) tenha reportado maior erro absoluto em nível da árvore ($bias = 7,57 \text{ kg}$). O bias médio menor foi de 0,3236 kg para a equação de Sampaio e Silva (2005) que apresenta a mesma estrutura do modelo desenvolvido localmente.

Para as equações pantropicais, estes resultados refletem não apenas valores absolutos, mas, também, uma grande variação percentual, principalmente, quando se inclui densidade da madeira juntamente com diâmetro e altura nas previsões de biomassa. Curiosamente, entretanto, nestas equações, os valores de RMSE, praticamente, dobram quando comparados às equações de outras regiões tropicais que usam apenas o diâmetro ou diâmetro e densidade básica.

As equações locais desenvolvidas tendem a predizer os valores de AGB de maneira mais homogênea e com menor amplitude de erro para as árvores de menor diâmetro, com uma ligeira divergência para árvores com $Db > 15 \text{ cm}$ (viés > 30%, Figura 3c). As equações pantropicais e locais de outras regiões sugerem maiores diferenças por classe de diâmetro, sendo, substancialmente, mais visíveis em árvores menores, principalmente, pela equação de Brown et al. (1989) (Figura 3d).

Estes resultados para a equação pantropical de Brown et al. (1989) são mais perceptíveis quando se considera a análise de variância ($F = 5,97$; $p\text{-valor} < 0,001$; $gl_{(\text{resíduo})} = 4884$) entre as previsões médias, conforme observado (Figura 4 e Tabela 6) entre as melhores equações locais selecionadas neste estudo e entre as demais equações locais de outras regiões e as pantropicais.

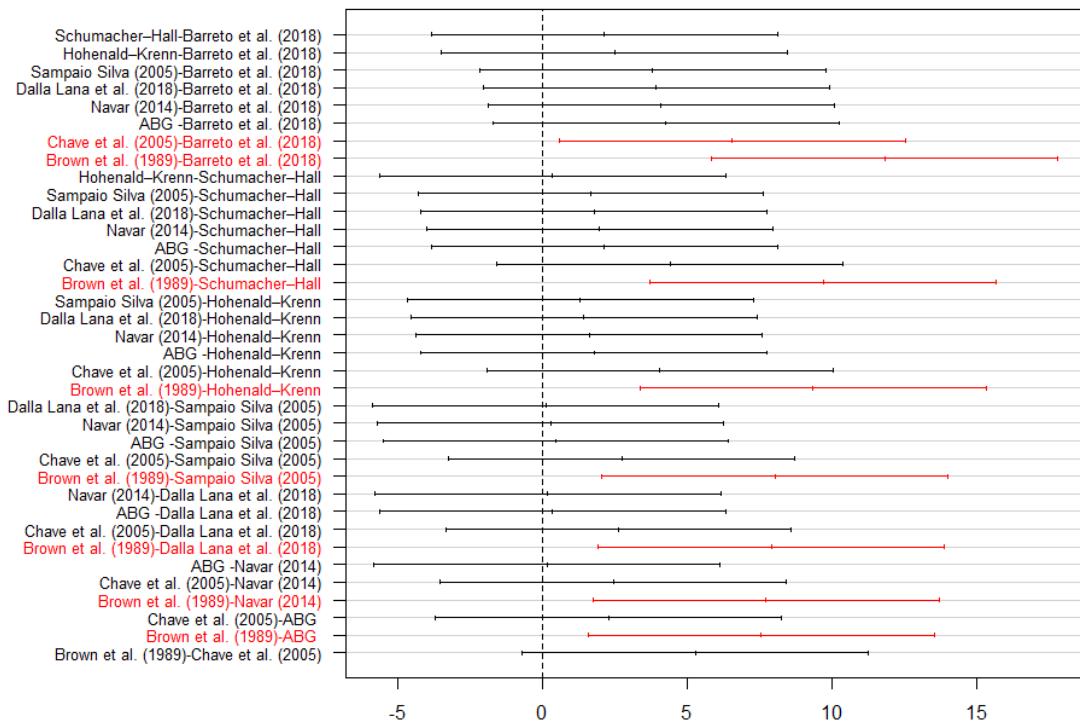


Figura 4 – Contrastos de médias de previsões de AGB entre as melhores equações locais desenvolvidas e equações locais de outras regiões e pantropicais analisadas. Nota: As equações em vermelho indicam que o contraste entre as médias de AGB difere de zero de acordo com o teste Tukey a 95% de probabilidade; AGB = biomassa mensurada em campo (testemunha).

Tabela 6 – Comparação dos contrastes de médias entre a biomassa mensurada em campo (ABG) e previsões de biomassa por equações locais desenvolvidas neste estudo (Hohenald–Krenn e Schumacher–Hall), equações genéricas locais (Dalla Lana et al. (2018), Barreto et al. (2018)) de outras regiões (Sampaio e Silva, 2005) e equações pantropicais.

Equações	Médias de AGB (kg)
Brown et al. (1989)	20,34a
Chave et al. (2005)	15,06ab
ABG mensurada em campo	12,78bc
Navar (2014)	12,61 bc
Dalla Lana et al. (2018)	12,43 bc
Sampaio e Silva (2005)	12,31 bc
Hohenald–Krenn	10,99 bc
Schumacher–Hall	10,64 bc
Barreto et al. (2018)	8,51c

Médias seguidas pela mesma letra não diferem estatisticamente pelo teste Tukey ao nível de 95% de confiança.

Com exceção das equações de Brown et al. (1989) e Barreto et al. (2018), a biomassa média mensurada em campo não difere, estatisticamente, das melhores equações locais desenvolvidas e das equações locais de Dalla-Lana e pantropical de Navar (2014). Estes resultados similares entre as equações alométricas sugerem que seus parâmetros de forma e perfil do tronco (β_1 e β_2) não foram substancialmente diferentes das estimativas dos parâmetros do melhor modelo local. Isto indica que a biomassa não varia muito em escala pantropical e que o modelo local deste estudo poderia ser aplicado em outras partes de florestas secas nos trópicos. Estes resultados ainda podem explicar que existe uma similaridade no tipo de vegetação com diferentes históricos de uso, pelas condições bioclimáticas e tipos de solo; ou características intrínsecas da árvore como fisiologia, rebrota, desenvolvimento adaptativo e bifurcações do tronco (espécies multi-fustes) (ALVAREZ et al., 2011; ALVAREZ et al., 2013; CHAVE et al., 2014).

Este trabalho busca preencher a lacuna sobre a validade de equações alométricas desenvolvidas para florestas tropicais secas, embora algumas pesquisas já tenham sugerido o desenvolvimento de equações individuais para espécies e regiões (CHAVE et al., 2014; LIMA et al., 2017; DALLA-LANA et al., 2018; BARRETO et al. 2018).

Outro ponto importante que deve ser considerado para o desenvolvimento de equações deve estar relacionado aos fatores intra e interespecíficos das espécies, como as variações de densidade básica da madeira (CHAVE et al., 2014), copa da árvore (DUNCANSON et al., 2010; SALAS-MORALES et al., 2018), índice de área foliar e perfis de altura (HELMER et al., 2010) e condições de adaptação e rebrota, além de outras características como dados multi-fustes (ALVAREZ et al., 2011; ALVAREZ et al., 2013). Considerando que tais fatores podem ser, ainda, influenciados por mudanças nos parâmetros estruturais como riqueza, densidade, frequência e dominância, o desenvolvimento de equações alométricas específicas do local e, mais ainda, em nível de espécies, é fundamental para a compreensão da concentração dos estoques de carbono (ABICH et al., 2018).

No entanto, o desenvolvimento de modelos alométricos não é uma tarefa trivial. O fator limitante sempre foi a amostragem destrutiva das árvores para o ajuste e seleção dos modelos. Estimativas precisas de volumes e biomassa de árvores individuais estão, cada vez mais, disponíveis por meio de outras tecnologias, como, por exemplo, o LiDAR (ESTORNELL et al., 2011; 2012; HILDEBRANDT; IOST, 2012). Estas estimativas não requerem a amostragem destrutiva das árvores e podem ser realizadas sistematicamente no campo (DUNCANSON et al., 2017; DUNCANSON; DUBAYAH, 2018). Com a amostragem de campo adequada gerada pelo LiDAR, um sistema poderia ser desenvolvido para a

obtenção de dados biométricos *in situ* da árvore em gradientes ambientais, assim, fornecendo uma solução potencial para os problemas pendentes relacionados à biomassa florestal e ao estoque de carbono.

4 CONCLUSÕES

Estimativas precisas de biomassa local podem ser obtidas pela equação genérica de Schumacher-Hall. Os maiores erros de previsão foram gerados pelas equações de simples entrada locais e pantropicais;

Para o local de estudo, modelos que incluem a densidade da madeira não melhoraram, substancialmente, as previsões de biomassa;

A equação de dupla entrada pantropical de Chave et al. (2005 – Type I.1) sugere que estimativas precisas podem ser geradas para o local na ausência de uma equação genérica específica do local.

REFERÊNCIAS

- ABICH, A. et al. Species-specific allometric equations for improving aboveground biomass estimates of dry deciduous woodland ecosystems. **Journal of Forestry Research**, Berlim, 2018. <https://doi.org/10.1007/s11676-018-0707-5>.
- ALI, A.; MATTSSON, E. Wood density is a sustainability indicator for the management of dry zone homegarden agroforests: Evidences from biodiversity–ecosystem function relationships. **Ecological Indicators**, New York, 2018, <https://doi.org/10.1016/j.ecolind.2018.04.024>.
- ALTHOFF, T.D. et al. Adaptation of the century model to simulate C and N dynamics of Caatinga dry forest before and after deforestation. **Agriculture, Ecosystems & Environment**, Amsterdam, v. 254, p. 26–34, 2018. <https://doi.org/10.1016/j.agee.2017.11.016>.
- ALVAREZ, J.A. et al. Wood productivity of *Prosopis flexuosa* D.C. woodlands in the central Monte: Influence of population structure and tree-growth habit. **Journal of Arid Environments**, London, v. 75, n.1, p.7-13, 2011. <http://dx.doi.org/10.1016/j.jaridenv.2010.09.003>.
- ALVAREZ, J.A. et al. Effects of the pruning intensity and tree size on multi-stemmed *Prosopis flexuosa* trees in the Central Monte, Argentina. **Forest Ecology and Management**, Amsterdam, v.310, p.857–864, 2013. <http://dx.doi.org/10.1016/j.foreco.2013.09.033>.
- ALVES JÚNIOR, F.T. **Estrutura, biomassa e volumetria de uma área de caatinga, Floresta-PE**. 2010. 123f. Tese (Doutorado em Ciências Florestais) - Universidade Federal Rural de Pernambuco, 2010. Disponível em: http://www.ppgcf.ufrpe.br/sites/www.ppgcf.ufrpe.br/files/documentos/francisco_tarcisio_alves_jr_1.pdf. Acesso em: 02 fev. 2018.
- ANDERSON-SPRECHER, R. Model Comparisons and R 2. **The American Statistician**, Washington, v.48, n.2, p. 113-117, 1994. <https://doi.org/10.2307/2684259>.
- AVITABILE, V. et al. An integrated pan-tropical biomass map using multiple reference datasets. **Global Change Biology**, Oxford, v.22, n.4, p.1406–1420, 2016. <https://doi.org/10.1111/gcb.13139>.
- AVITABILE, V.; CAMIA, A. An assessment of forest biomass maps in Europe using harmonized national statistics and inventory plots. **Forest Ecology and Management**, Amsterdam, v.409, p.489–498, 2018. <https://doi.org/10.1016/j.foreco.2017.11.047>.

BACCINI, A.; ASNER, G.P. Improving pantropical forest carbon maps with airborne LiDAR sampling. **Carbon Management**, London, v.4, n.6, p.591–600, 2013 <https://doi.org/10.4155/cmt.13.66>.

BASTIN, J.F. et al. Wood specific gravity variations and biomass of central African tree species: The simple choice of the outer wood. **PLoS ONE**, San Francisco, v.10, n.11, p.1-16. 2015. <http://dx.doi.org/10.1371/journal.pone.0142146>.

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

BARRETO, T. N. A. et al. Ajuste de modelos matemáticos à biomassa seca dos compartimentos de plantas lenhosas em área de caatinga. **Scientia Forestalis**, Piracicaba. v. 46, n. 118, p. 285-295, 2018. <https://doi.org/10.18671/scifor.v46n118.14>.

BOUVET, A. et al. An above-ground biomass map of African savannahs and woodlands at 25 m resolution derived from ALOS PALSAR. **Remote Sensing of Environment**, New York, v.206, p.156–173, 2018. <https://doi.org/10.1016/j.rse.2017.12.030>.

BRAHMA, B. et al. Estimating biomass stocks and potential loss of biomass carbon through clear-felling of rubber plantations. **Biomass and Bioenergy**, Oxford, v.115, p.88–96, 2018. <https://doi.org/10.1016/j.biombioe.2018.04.019>.

BROWN, S.;GILLESPIE, A. J. R.;LUGO, A. E. Biomass Estimation Methods for Tropical Forests with Applications to Forest Inventory Data. **Forest Science**, Bethesda, v.35, n.4, p.881-902, 1989.

BROWN, S. **Estimating biomass and biomass changingof tropical forests: a primer**. Rome: FAO Forestry Paper, 1997.

CHÁIDEZ, J. DE J.N.Allometric equations and expansion factors for tropical dry trees of eastern Sinaloa, Mexico. **Tropical and Subtropical Agroecosystems**, Mérida, v.10, n.1, p.45–52, 2008.

CHATURVEDI, R.K., RAGHUBANSHI, A.S. Allometric Models for Accurate Estimation of Aboveground Biomass of Teak in Tropical Dry Forests of India. **Forest Science**, Bethesda, v.61, n.5,p.938–949, 2015. <https://doi.org/10.5849/forsci.14-190>.

CHAVE, J. et al. Tree allometry and improved estimation of carbon stocks and balance in tropical forests. **Oecologia**, Berlin, v.145, p.87–99, 2005. <https://doi.org/10.1007/s00442-005-0100-x>.

CHAVE, J. et al. Improved allometric models to estimate the aboveground biomass of tropical trees. **Global Change Biology**, Oxford, v.20, p.3177–3190, 2014. <https://doi.org/10.1111/gcb.12629>.

CREZEE, B. **Regional Spatial Variation in Aboveground Biomass, Forest Structure and Species Composition of Bolivian Tropical Dry Forests**. 2015. 79f. Dissertação (Mestrado em Desenvolvimento Sustentável) - Utrecht University, 2015. Disponível em:<https://dspace.library.uu.nl/bitstream/handle/1874/322300/Master%20Thesis%20-Bart%20Crezee.pdf?sequence=2&isAllowed=y>. Acesso em: 02 ago. 2018.

DALLA LANA, M. et al. BIOMASS EQUATIONS FOR CAATINGA SPECIES. Nativa, Sinop-MT, v.6, n.5, p. 517-525, 2018.<http://dx.doi.org/10.31413/nativa.v6i5.5361>.

DUNCANSON, L.I.; NIEMANN, K.O.; WULDER, M.A. Estimating forest canopy height and terrain relief from GLAS waveform metrics. **Remote Sensing of Environment**, New York, v.114, n.1, p.138–154, 2010. <https://doi.org/10.1016/j.rse.2009.08.018>.

DUNCANSON, L.; ROURKE, O.; DUBAYAH, R. Small Sample Sizes Yield Biased Allometric Equations in Temperate Forests. **Scientific Reports**, London, v.5, p.1-13, 2015. <https://doi.org/10.1038/srep17153>.

DUNCANSON, L. et al. Implications of allometric model selection for county-level biomass mapping. **Carbon Balance and Management**, London, v.12, n.1, p.1-11, 2017. <https://doi.org/10.1186/s13021-017-0086-9>.

DUNCANSON, L., DUBAYAH, R. Monitoring individual tree-based change with airborne LiDAR. **Ecology and Evolution**, Oxford, v.8, n.10, p.5079–5089, 2018. <https://doi.org/10.1002/ece3.4075>.

ELITH, J.; LEATHWICK, J.R. Species Distribution Models: Ecological Explanation and Prediction Across Space and Time. **Annual Review of Ecology, Evolution, and Systematics**, Palo Alto, v.40, p.677–697, 2009. <https://doi.org/10.1146/annurev.ecolsys.110308.120159>.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (EMBRAPA). **Diagnóstico Ambiental do Município de Floresta, Pernambuco**. Rio de Janeiro-RJ: EMBRAPA, 2001. (Circular Técnica, ISSN 1517-5146). Disponível

em:<<https://www.infoteca.cnptia.embrapa.br/bitstream/doc/338510/1/circulartecnica10diagambfloresta.pdf>>. Acesso em: 11/05/2018.

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

FELDPAUSCH, T.R. et al. Tree height integrated into pantropical forest biomass estimates. **Biogeosciences**, Katlenberg-Lindau, v.9, n. 8, p.3381–3403, 2012. <https://doi.org/10.5194/bg-9-3381-2012>.

GONZALEZ DE TANAGO, J. et al. Estimation of above-ground biomass of large tropical trees with terrestrial LiDAR. **Methods in Ecology and Evolution**, Hoboken, v.9, n.2, p.223–234, 2018. <https://doi.org/10.1111/2041-210X.12904>.

GUHA, S. et al. 2018. Comparison of biomass in natural and plantation dry forests in India.In: Proceedings of the 1st Global Civil Engineering Conference, 1.,2018, Singapore. **Anais...** Singapore: Springer Singapore. 2018. p. 995–1006.

HELMER, E.H. et al. Mapping tropical dry forest height, foliage height profiles and disturbance type and age with a time series of cloud-cleared Landsat and ALI image mosaics to characterize avian habitat. **Remote Sensing of Environment**, New York, v.114, n.11, p.2457–2473, 2010. <https://doi.org/10.1016/j.rse.2010.05.021>.

HENRY, M. et al. Estimating tree biomass of sub-Saharan African forests: a review of available allometric equations. **Silva Fennica**, Helsinki,v.45, n.3,p.477–569, 2011. Disponível em:http://publications.cirad.fr/une_notice.php?dk=561319. Acesso em: 05 fev. 2018.

HILDEBRANDT, R.; IOST, A. From points to numbers: a database-driven approach to convert terrestrial LiDAR point clouds to tree volumes. **European Journal of Forest Research**, Heidelberg,v.131, n.6,p.1857–1867, 2012. <https://doi.org/10.1007/s10342-012-0638-1>.

HILTNER, U. et al. Simulation of succession in a neotropical forest: High selective logging intensities prolong the recovery times of ecosystem functions. **Forest Ecology and Management**, Amsterdam, v.430, p.517–525, 2018. <https://doi.org/10.1016/j.foreco.2018.08.042>.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA- IBGE. **Manual técnico da vegetação brasileira**, 2012.

KACHAMBA, D. et al. Influence of Plot Size on Efficiency of Biomass Estimates in Inventories of Dry Tropical Forests Assisted by Photogrammetric Data from an Unmanned Aircraft System. **Remote Sensing**, Basel, v.9, n.6, p.1-15, 2017. <https://doi.org/10.3390/rs9060610>.

LARJAVAARA, M., MULLER-LANDAU, H.C. Measuring tree height: a quantitative comparison of two common field methods in a moist tropical forest. **Methods in Ecology and Evolution**, Hoboken, v.4, n.9, p.793–801, 2013. <https://doi.org/10.1111/2041-210X.12071>.

LIMA, R.B. et al. Predicting of biomass in Brazilian tropical dry forest: a statistical evaluation of generic equations. **Anais da Academia Brasileira de Ciências**, Rio de Janeiro-RJ, v.89, n.3, p.1815–1828, 2017. <https://doi.org/10.1590/0001-3765201720170047>.

MONTOYA, J. D. M. **Potencial energético de espécies lenhosas da caatinga para uso de biomassa em plano de manejo florestal**. 2017. 73 f. Dissertação (Mestrado em Ciências Florestais)Universidade Federal Rural de Pernambuco, 2017. Disponível em: http://www.ppgcf.ufrpe.br/sites/www.ppgcf.ufrpe.br/files/documents/dissertacao_juan_diego_marin_montoya.pdf. Acesso em: 10nov. 2018.

NÁVAR, J. Pan tropical biomass equations for Mexico's dry forests. **Agronomía Colombiana**, Bogotá, v.32, n.3, p.367–376, 2015. <https://doi.org/10.15446/agron.colomb.v32n3.45627>.

NÁVAR, J. Allometric equations for tree species and carbon stocks for forests of northwestern Mexico. **Forest Ecology and Management**, Amsterdam, v.257, n.2, p.427–434, 2009a. <https://doi.org/10.1016/j.foreco.2008.09.028>.

NÁVAR, J. Biomass component equations for Latin American species and groups of species. **Annals of Forest Science**, Les Ulis, v.66, n.2, p.208–208, 2009b. <https://doi.org/10.1051/forest/2009001>.

NÁVAR, J. et al. Regional aboveground biomass equations for North American arid and semi-arid forests. **Journal of Arid Environments**, London, v.97, p.127–135, 2013. <https://doi.org/10.1016/j.jaridenv.2013.05.016>.

PACKARD, G.C.; BOARDMAN, T.J. Model Selection and Logarithmic Transformation in Allometric Analysis. **Physiological and Biochemical Zoology**, Chicago, v.81, p.496–507, 2008. <https://doi.org/10.1086/589110>.

PELLETIER, J. et al. Human and natural controls of the variation in aboveground tree biomass in African dry tropical forests. **Ecological Applications**, Tempe, v.27, n.4, p.1578–1593, 2017. <https://doi.org/10.1002/eaap.1550>.

R Core Team (2017). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.

ROITMAN, I. et al. Optimizing biomass estimates of savanna woodland at different spatial scales in the Brazilian Cerrado: Re-evaluating allometric equations and environmental influences. **PloS one**, San Francisco, v.13, p.1-21, 2018.<https://doi.org/10.1371/journal.pone.0196742>.

RUTISHAUSER, E. et al. Generic allometric models including height best estimate forest biomass and carbon stocks in Indonesia. **Forest Ecology and Management**, Amsterdam, v.307, p.219–225, 2013. <https://doi.org/10.1016/j.foreco.2013.07.013>.

SALAS-MORALES, S.H.; GONZÁLEZ, E.J.; MEAVE, J.A. Canopy height variation and environmental heterogeneity in the tropical dry forests of coastal Oaxaca, Mexico. **Biotropica**, Washington, v.50, n.1, p.26–38, 2018. <https://doi.org/10.1111/btp.12491>.

SALINAS-MELGOZA, M.A.; SKUTSCH, M.; LOVETT, J.C. Predicting aboveground forest biomass with topographic variables in human-impacted tropical dry forest landscapes. **Ecosphere**, Washington, v.9, n.1, p.1-20, 2018. <https://doi.org/10.1002/ecs2.2063>.

SALIS, S.M. et al. Estimating the aboveground biomass and wood volume of savanna woodlands in Brazil's Pantanal wetlands based on allometric correlations. **Forest Ecology and Management**, Amsterdam, v.228, n.1-3, p.61–68, 2006. <https://doi.org/10.1016/j.foreco.2006.02.025>.

SAMPAIO, E.V.S.B.; SILVA, G.C. Biomass equations for Brazilian semiarid caatinga plants. **Acta Botanica Brasilica**, Porto Alegre-RS, v.19, n.4, p.935–943, 2005. <https://doi.org/10.1590/S0102-33062005000400028>.

SAMPAIO, E. et al. Tree biomass estimation in regenerating areas of tropical dry vegetation in northeast Brazil. **Forest Ecology and Management**, Amsterdam, v.259, n.6, p.1135–1140, 2010. <https://doi.org/10.1016/j.foreco.2009.12.028>.

SCHNEIDER PR, SCHNEIDER PSP AND SOUZA CAM. **Análise de Regressão aplicada à Engenharia Florestal**. 2^a ed., Santa Maria: FACOS.2009.

SCHUMACHER, F. X.; HALL, F. S. Logarithmic expression of timber-tree volume. *Journal of Agricultural Research*, Washington, v.47, n.9, p.719-734, 1933. Disponível em: <https://naldc.nal.usda.gov/download/IND43968352/PDF>. Acesso em: 04 mar. 2018.

SPRUGEL, D.G. Correcting for Bias in Log-Transformed Allometric Equations. **Ecology**, Brooklyn, v.64, n.1, p.209–210, 1983. <https://doi.org/10.2307/1937343>.

SULLIVAN, M.J.P. et al. Field methods for sampling tree height for tropical forest biomass estimation. **Methods in Ecology and Evolution**, Hoboken, v.9, n.5, p.1179–1189, 2018. <https://doi.org/10.1111/2041-210X.12962>.

UBUY, M.H. et al., Aboveground biomass models for trees and shrubs of exclosures in the drylands of Tigray, northern Ethiopia. **Journal of Arid Environments**, London, v.156, p.9–18, 2018. <https://doi.org/10.1016/j.jaridenv.2018.05.007>.

VANCLAY, J.K. **Modelling forest growth and yield: applications to mixed tropical forests**. Wallingford: CAB International, 2001.

VIBRANS, A.C. et al. Generic and specific stem volume models for three subtropical forest types in southern Brazil. **Annals of Forest Science**, Les Ulis, v.72, n.6, p.865–874, 2015. <https://doi.org/10.1007/s13595-015-0481-x>.

WAGNER, F. et al. Pan-Tropical Analysis of Climate Effects on Seasonal Tree Growth. **PLoS ONE**, San Francisco, v.9, n.3, p.1-15, 2014. <https://doi.org/10.1371/journal.pone.0092337>.

CAPÍTULO 2

MODELAGEM E ESPACIALIZAÇÃO DE BIOMASSA E ESTOQUE DE CARBONO USANDO MÉTRICAS LiDAR, EM FLORESTA TROPICAL SECA, NO NORDESTE DO BRASIL

1 INTRODUÇÃO

Nas últimas décadas, o aumento da concentração de dióxido de carbono (CO_2) na atmosfera e suas consequências sobre o meio ambiente vêm despertando a atenção da sociedade e sendo abordados como uma questão de polêmica mundial (CROWTHER et al., 2015). A elevada concentração de CO_2 na atmosfera é preocupante por gerar o aumento do efeito estufa, provocando, consequentemente, o aquecimento global (ACHARD; HOUSE, 2015; COOMES et al., 2017; BRAHMA et al., 2018). Neste cenário, as áreas de florestas tropicais secas exercem papel relevante e a vegetação de Caatinga no Nordeste brasileiro contribui significativamente com o ciclo global de carbono por meio de estoque em biomassa e carbono acima do solo (SAMPAIO; SILVA, 2005; ALTHOFF et al., 2018).

Atualmente, existe uma rica discussão entre os cientistas de todo o mundo sobre as principais ferramentas e métodos para geração de medidas mitigadoras das mudanças climáticas. A primeira pergunta norteadora a ser respondida é: como mensurar os impactos das mudanças climáticas globais e como diminuir seus avanços? A segunda questão chave é saber quais ferramentas e métodos devem ser utilizados para garantir uma estimativa confiável. Para os ecossistemas de florestas tropicais secas, em muitos casos, as variáveis mais conhecidas por gerarem respostas mais rápidas são a biomassa e o carbono acima do solo.

No entanto, a amostragem destrutiva das árvores é um fator limitante para a calibração de modelos estatísticos, principalmente, devido ao alto custo empregado nos trabalhos de campo (DUNCANSON et al., 2017). Estes métodos, atualmente, baseiam-se em dados de inventário florestal, empregando fatores e equações de carbono que transformam os parâmetros biométricos da floresta, tais como: diâmetro da altura do peito (DAP) e altura (Ht) dos indivíduos em estimativa do estoque de carbono contido na biomassa áerea florestal (SOMOGYI et al., 2007).

Recentemente, as técnicas de sensoriamento remoto, combinadas aos sensores ópticos, têm-se apresentado como uma alternativa viável para a estimativa do estoque de biomassa e carbono em florestas plantadas e naturais (SILVA et al., 2016, 2017). Dentre as técnicas de sensoriamento remoto atuais, o perfilhamento a laser, também conhecido por LiDAR (*Light*

Detection and Raging), tem surgido com destaque no cenário florestal (ASNER et al., 2011; LI et al., 2017), e as estimativas de biomassa e estoque de carbono podem ser obtidas, sistematicamente, no campo de maneira eficiente (DUNCANSON et al., 2017).

O LiDAR é um sistema ativo, seu princípio consiste na emissão de um pulso laser, que, após interagir com um objeto na superfície terrestre, retorna para o sensor em um dado intervalo de tempo. A tecnologia possibilita reproduzir, de forma acurada, Modelos Digitais de Terreno (DTM, modelos que permitem descrever a elevação do terreno livre de objetos), Modelos Digitais de Superfícies (DSM, modelos que permitem descrever a elevação do terreno incluindo os objetos presentes) e Modelos Digitais de Altura (DHM, modelos que descrevem a altura de todos os objetos, tendo os pontos da nuvem, referente ao solo, normalizados a zero).

Apesar da tecnologia LiDAR ser uma alternativa eficiente e bastante aplicada ao inventário florestal em países como Estados Unidos, Finlândia e Suécia, existem, ainda, obstáculos para o seu uso em outros países, como o Brasil. As limitações não são derivadas do funcionamento da tecnologia em si, mas, principalmente, pelo fato de ainda ser uma tecnologia emergente no Brasil (SILVA et al., 2017). A elaboração de metodologias de processamento voltadas às necessidades brasileiras ainda é recente. Neste aspecto, justifica-se a execução deste trabalho, principalmente, pela busca de um avanço técnico-científico que proporcione a elaboração de rotinas que auxiliem nos processos de aquisição e processamentos de dados LiDAR. Buscando, assim, atingir, com eficiência, as estimativas do estoque de biomassa e carbono acima do solo em floresta tropical seca brasileira.

Em particular, o uso da tecnologia LiDAR com a capacidade de medir diretamente e com precisão os atributos (métricas) da vegetação em uma escala vertical, proporcionará o desenvolvimento de um sistema com a finalidade de amostrar o estoque de biomassa e carbono *in situ* das árvores em gradientes ambientais, fornecendo uma solução potencial para problemas pendentes relacionados à biomassa florestal e estoque de carbono acima do solo (SAATCHI et al., 2009; AVITABILE et al., 2011). As estimativas de biomassa e carbono em níveis local e regional bem como a espacialização destas variáveis por meio de mapas, podem fornecer um panorama geral de biodiversidade e estrutura das florestas (MARTINUZZI et al., 2013; NELSON et al., 2017; BECKNELL et al., 2018). Para a floresta seca do semiárido brasileiro, em Pernambuco, estas informações são de extrema importância para possíveis pagamentos por serviços ambientais e outros projetos voltados para redução de emissões decorrentes do desmatamento e da degradação de florestas (REDD +).

Devido à grande importância dos recursos florestais da Caatinga, a quantificação e

mapeamento da biomassa e estoque de carbono por meio de métricas LiDAR é um fator chave para atender aos aspectos legais concernentes à gestão sustentável, conciliando, principalmente, a produção sustentável de madeira e a manutenção do estoque de carbono na área. Esta tarefa constitui uma das principais ferramentas de planejamento a longo prazo, pois, além de dimensionar o estoque e a produtividade da floresta, gera informações que irão direcionar a manutenção dos ecossistemas por meio da conservação e/ou preservação (MOHEBALIAN; AGUILAR, 2018).

Neste sentido, este trabalho foi desenvolvido com o intuito de gerar informações de biomassa e estoque de carbono usando métricas LiDAR em duas áreas de floresta tropical seca no município de Floresta, Pernambuco. Especificamente, pretende-se: a) estimar a biomassa e o estoque de carbono totais para as parcelas inventariadas em duas áreas, usando uma equação local; b) desenvolver uma equação para a estimativa de biomassa e estoque de carbono usando métricas LiDAR para duas diferentes áreas de floresta seca inventariadas em Pernambuco.

2 MATERIAIS E MÉTODOS

2.1 Área de estudo

O trabalho foi realizado na Fazenda Itapemirim, em duas áreas de Caatinga com diferentes históricos de uso. Sua extensão é de, aproximadamente, 60 km² (Figura 1D), localizada no Município de Floresta, na mesorregião do São Francisco, em Pernambuco (8°30'37"S e 37°59'07" W).

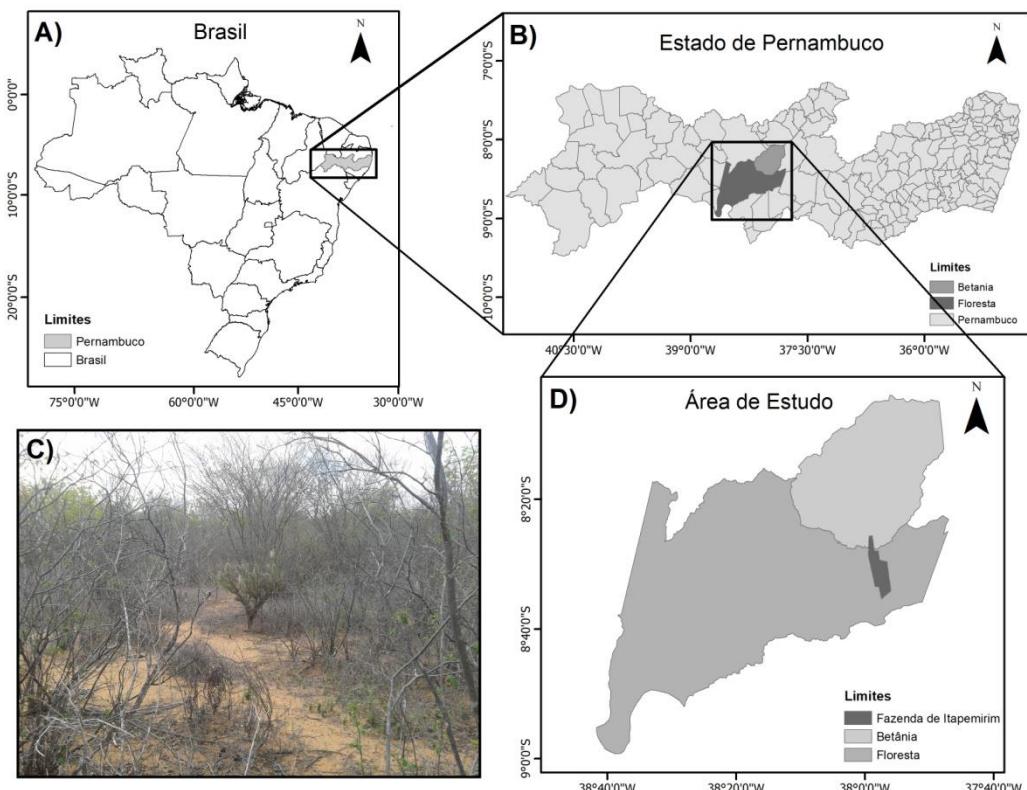


Figura 1 – Recobrimento da área de estudo (A, B e D) e foto do perfil em Floresta (C), no sertão de Pernambuco, Brasil.

As duas áreas deste estudo diferenciam-se pelas condições de histórico de uso. A primeira chamada de “transposição” com 40 parcelas permanentes de 400 m² (20 x 20 m) possui uma extensão aproximada de 50 ha e é considerada uma área que possui um histórico de uso com atividades de menor impacto (55 anos de menores perturbações antrópicas). A segunda área, também com 40 parcelas permanentes de 400 m² (20 x 20 m), denominada “correntão”, sofreu exploração madeireira por meio da técnica correntão, em 1987, para plantio de eucalipto (PIMENTEL, 2012), porém, foi abandonada e encontra-se em processo de regeneração há 29 anos (Figura 2). Para o levantamento das 80 parcelas em estudo, foi utilizada uma Antena Digital Trimble Catalyst interligada a um dispositivo smartphone que, em conjunto, são capazes de rastrear sinais L1/L2C GPS, E1 Galileo e G1 Glonass. A coleta das coordenadas foi realizada com precisão sub-métrica (30 cm – 75 cm).

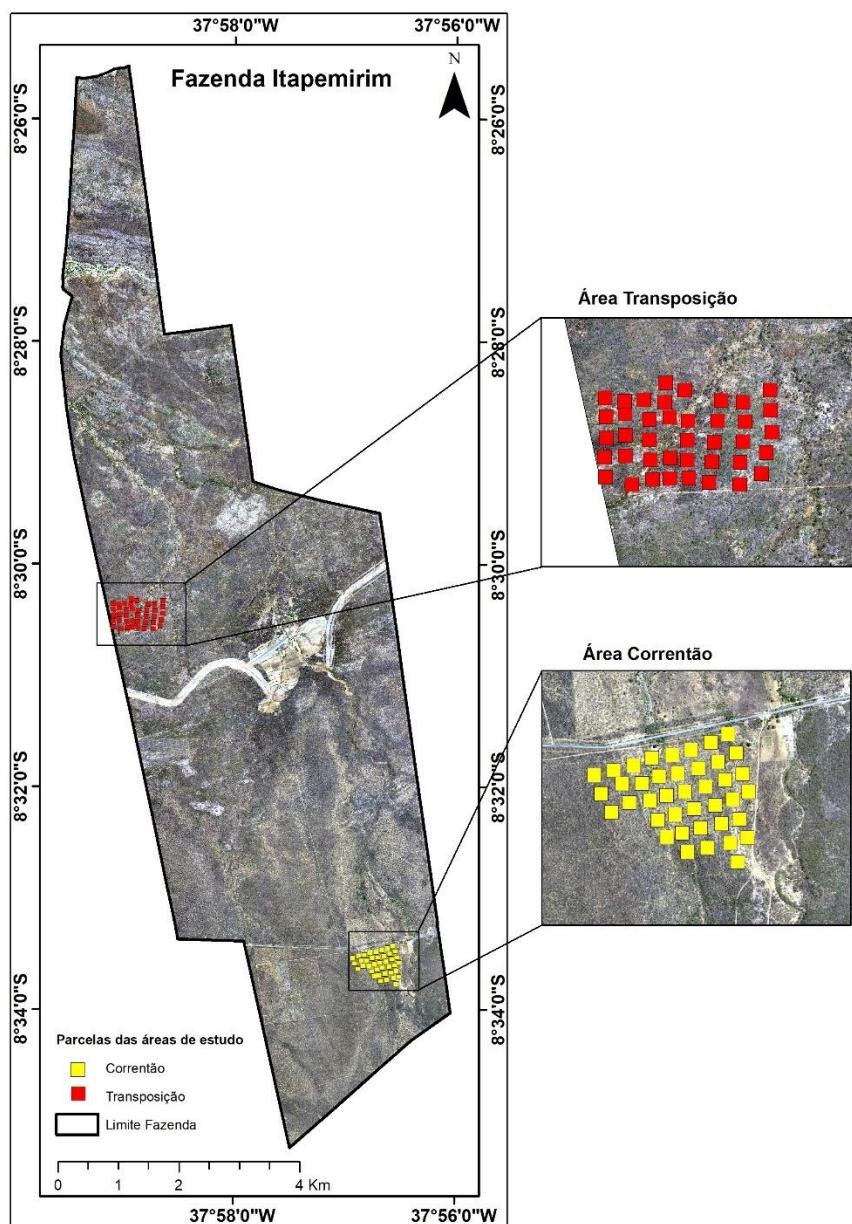


Figura 2 – Procedimento de amostragem utilizado nas duas áreas inventariadas no município de Floresta, Pernambuco

Nas áreas do estudo, a vegetação é, predominantemente, de Caatinga (floresta tropical seca), isto é, do tipo savana-estépica, caracterizada por vegetação arbustivo-arbórea, com presença de cactáceas e estrato herbáceo (IBGE, 2012). O clima, segundo a classificação de Köppen, é do tipo BSh, semiárido quente, apresentando precipitação média anual de, aproximadamente, 400 mm, com período chuvoso de janeiro a abril, e temperatura média anual de 26,1 °C. Sua distribuição, em temperatura e precipitação ao longo do ano estudado (2014), nos municípios pertencentes à área de estudo, está representada na Figura 3. O

município possui uma área de e 3.690,3 km² e uma altitude média variando de 300 a 1.050m (EMBRAPA, 2001).

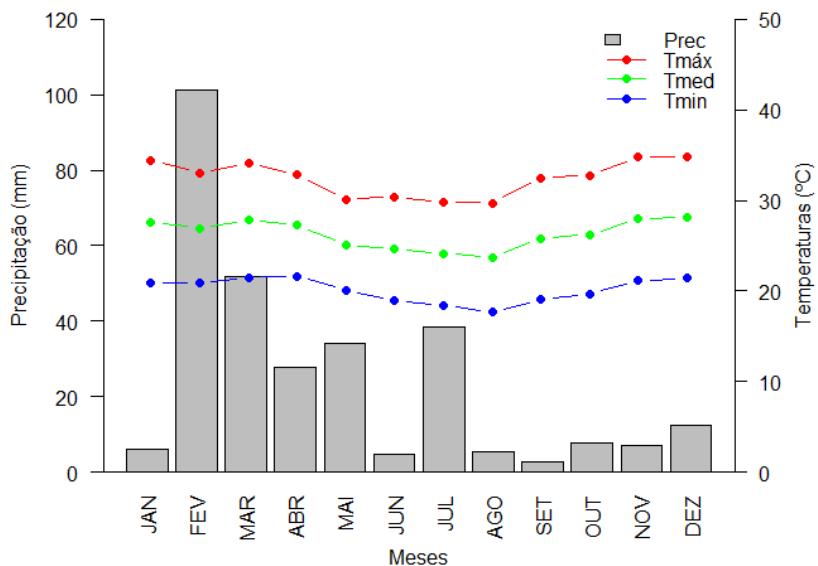


Figura 3 – Distribuição da temperatura do ar e da precipitação, ao longo do ano de 2014, da área de estudo da estação meteorológica de Floresta. Fonte: Adaptado de Agritempo (2018).

2.2 Estimativa do estoque de biomassa / carbono em campo

Em cada área, foram utilizadas parcelas já inventariadas para facilitar a logística e a coleta de dados (Figura 2). No total, 40 parcelas, com dimensão de 20 x 20 m (400 m²) em cada área, são monitoradas desde o ano de 2008 e estão distribuídas de forma sistemática e distanciadas entre si a 80 m, com 50 m da bordadura (SILVA, 2017). Todos os indivíduos arbustivo-arbóreos com circunferência medida a 1,30 m de altura do solo (CAP) \geq 6,0 cm foram identificados, etiquetados e mensurados, bem como mensuradas as alturas totais (Ht) por meio de clinômetro. Nas estimativas de biomassa e carbono, as 40 parcelas de cada área foram as repetições para a modelagem.

Em cada parcela, nas diferentes áreas, foram geradas estimativas locais de biomassa a partir de uma equação local ajustada conforme foi descrito no Capítulo 1 (Equação 1), com posterior conversão para estoque de carbono (Mg ha⁻¹).

$$\text{TAGB} = \exp(-3,5336 + 1,9126 \times \ln(\text{Db}) + 1,2438 \times \ln(\text{Ht})) \quad (\text{Eq. 1})$$

Em que: Db é diâmetro da base da árvore (0,30 m) em cm; Ht é a altura da árvore (m).

A Equação 1 reportou um valor de Critério de Informação de Akaike (AIC) de 573,77; Coeficiente de Determinação Ajustado (R^2_{Adj}) de 0,90; erros quadrados absolutos (RMSE) de 18,28 e viés de 0,20 kg árvore⁻¹, respectivamente.

Para as estimativas dos estoques de carbono (Mg ha⁻¹), a biomassa estimada foi convertida usando a fração média de carbono das espécies lenhosas na mesma área de estudo encontrada por Dalla Lana et al. (2019) por espécies (Tabela 1) e, na ausência do teor de carbono de alguma espécie inventariada, foi utilizada a média do teor de carbono de todas as espécies amostradas.

Tabela 1 – Valores médios de teor de carbono do compartimento fuste de oito espécies avaliadas por Dalla Lana et al. (2019).

Espécie	\bar{x}
<i>Anadenanthera colubrina</i> var. <i>cibil</i> (Griseb.) Altschul	46,6
<i>Aspidosperma pyrifolium</i> Mart.	47,4
<i>Bauhinia cheilanta</i> (Bong). Steud.	46,1
<i>Cnidoscolus quercifolius</i> Pohl	46,8
<i>Croton heliotropifolius</i> Kunth	48,5
<i>Mimosa ophthalmocentra</i> Mart. ex Benth.	47,5
<i>Mimosa tenuiflora</i> (Willd.) Poir.	47,4
<i>Poincianella bracteosa</i> (Tul.) L. P. Queiroz	44,8
Média	46,9

Em síntese, os dados de inventário florestal analisados para este estudo, bem como as previsões de biomassa e carbono foram do ano de 2014 e estão resumidos na Tabela 2 e Apêndice 1 e 2. A escolha desse ano de monitoramento foi definida de acordo com o ano de sobrevoo LiDAR nas áreas.

Tabela 2 – Valores descritivos (média e desvio padrão) das variáveis dendrométricas e número de indivíduos e fustes totais amostrados nas parcelas permanentes das áreas de estudo (2014).

Áreas	DAP (cm)		Ht (m)		AGB (Mg ha ⁻¹)		AGC (Mg ha ⁻¹)		Nº Parcelas	Nº Ind.	Nº Fuste
	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ	\bar{x}	σ			
Transposição	3,85	2,37	3,97	0,95	9,327	5,442	4,66	27	40	1728	4576
Correntão	11,44	5,4	3,64	0,92	24,94	24,95	12,47	12,47	40	996	2903

2.3 Estimativa do estoque de biomassa / carbono por dados LiDAR

2.3.1 Obtenção dos dados LiDAR

Os dados LiDAR utilizados neste estudo foram disponibilizados pelo Programa Pernambuco Tridimensional (PE3D) inserido no Programa de Sustentabilidade Hídrica de Pernambuco (PSHPE), cujo objetivo foi o de realizar o mapeamento para todo o território do Estado de Pernambuco, tendo, dentre os seus serviços, o recobrimento aerofotogramétrico e perfilamento a laser. Para obtenção das nuvens de pontos, foi realizado um sobrevoo em uma aeronave BEM-810 C – Seneca II – Prefixo PT-RQA, em agosto de 2014, nas áreas com as características descritas conforme a Tabela 3.

Tabela 3 – Detalhes de aquisição dos dados LiDAR para o estado de Pernambuco em 2014.

Atributo	Valores
Sistema LiDAR	ALS-50 LEICA
Altitude do vôo (m)	3.068
Data de aquisição	10/08/2014
Angulo de abertura (°)	34,5
Frequência do Scanner (Kz; Hz)	36,8 Hz
Densidade de pulsos (pulses·m ⁻²)	0,5
Datum	Sirgas 2000

2.3.2 Processamento dos dados LiDAR

As nuvens de pontos das áreas analisadas foram obtidas no site do Programa Pernambuco Tridimensional (<http://www.pe3d.pe.gov.br/mapa.php>) no formato “.xyzi” e modificadas para o formato “.las” por meio do software *LAS Utility*, resultando na produção de um relatório descritivo de diversas características importantes do conjunto de dados LiDAR.

Dessa forma, foram filtrados da nuvem de pontos LiDAR os retornos que se encontravam na superfície do solo (pontos na superfície do solo). O passo seguinte, para as duas áreas, foi obter os Modelos Digitais de Terreno (MDT) e o de Superfície (MDS).

Para realizar as posteriores análises com as métricas somente das árvores, foi necessário, primeiramente, normalizar os dados, tendo como critério de utilização apenas as métricas geradas a partir de 1,30 m do nível do solo. Esta tarefa foi realizada por meio da subtração dos dados de MDS por MDT. O passo seguinte foi obter o Modelo Digital de altura de copas (CHM), para se obter o valor de métrica para cada parcela das duas áreas, foi necessário realizar o recorte por parcela, utilizando o *shapefile* das parcelas com a nuvem de

pontos, utilizando-se a ferramenta “PolyclipDATA” do software Fusion 3.8 para a extração das métricas.

Com as métricas LiDAR, pôde-se calcular uma série de estimativas de parâmetros estatísticos descritivos da nuvem de pontos. Ao final do processamento dos dados, em cada unidade amostral, nas diferentes áreas, foram geradas 26 métricas, as quais são mais empregadas em estudos de estimativa de biomassa e carbono, categorizadas segundo a sua origem e simbologia calculadas (Tabela 4).

Tabela 4 – 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.

Categoría	Métricas LiDAR	Simbologia
Altura	Altura máxima	Elev.maximum
	Altura mínima	Elev.minimum
	Altura media	Elev.mean
	Altura modal	Elev.mode
	Desvio padrão das alturas	Elev.stddev
	Coeficiente de variação da altura	Elev.CV
	Assimetria da altura	Elev.skewness
	Curtose da altura	Elev.kurtosis
	Mediana dos desvios absolutos da média geral	Elev.MAD.median
	Percentil 01 da altura	Elev.P01
	Percentil 05 da altura	Elev.P05
	Percentil 10 da altura	Elev.P10
	Percentil 20 da altura	Elev.P20
	Percentil 25 da altura	Elev.P25
	Percentil 30 da altura	Elev.P30
	Percentil 40 da altura	Elev.P40
	Percentil 50 da altura	Elev.P50
	Percentil 60 da altura	Elev.P60
	Percentil 70 da altura	Elev.P70
	Percentil 75 da altura	Elev.P75
	Percentil 80 da altura	Elev.P80
	Percentil 90 da altura	Elev.P90
	Percentil 95 da altura	Elev.P95
	Percentil 99 da altura	Elev.P99
Densidade de copa	Relação do relevo do dossel ¹	Canopy.relief.ratio
	Porcentagem de todos os retornos acima de 1.30 ²	Percentage.all.returns.above.1.30

¹Canopyreliefratio ((HMEAN 2 HMIN)/(HMAX 2 HMIN)); Percentage.all.returns.above 1.30.

Algumas das principais métricas usadas na predição de biomassa e carbono são descritas a seguir:

Elev.maximum = *Altura máxima*: é o valor mais elevado encontrado no intervalo de medição em metros dentro de cada unidade de amostra, considerando variações a cada metro no eixo do caminhamento.

Elev.mean = *Altura média*: é o valor médio dos pontos mais altos, considerando variações a cada metro no intervalo de medição em metros dentro de cada unidade de amostra (Equação 2).

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

Elev.stddev = Desvio padrão da altura na nuvem de pontos LiDAR:

$$\text{Elev.stddev} = \sqrt{\frac{1}{n-1} \times \sum_{i=1}^n (h_i - h_{\text{med}})^2} \quad (\text{Eq. 3})$$

Onde: h_{med} = Altura média da nuvem de pontos.

Elev.CV = Coeficiente de variação em altura na nuvem de pontos LiDAR:

$$h_{\text{cv}} = \frac{h_{\text{desv}}}{h_{\text{med}}} \quad (\text{Eq. 4})$$

Percentis da altura na nuvem de pontos LiDAR (h_{pi}): O i -ésimo percentil de n pontos representados, tradicionalmente, na nuvem de pontos LiDAR, ordenados em valores em altura. É correspondente ao valor que ocupa a posição K do conjunto de dados, como segue na equação a seguir (Equação 5):

$$K = \frac{h_{pi}(n+1)}{100} \quad (\text{Eq. 5})$$

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

2.4 Modelagem do estoque de biomassa / carbono por meio de dados LiDAR

Para construção, validação e aplicação dos modelos preditivos de biomassa e carbono florestal, nas diferentes áreas, foram utilizados os softwares *LiDARData_AnalysisTools*, “R Project for Statistical Computing” (R DEVELOPMENT CORE TEAM, 2017).

O software *LiDAR Data_Analysis Tools* é um programa desenvolvido pelo *USDA Forest Service – Remote Sensing Applications Center*, escrito em linguagem Python, que trabalha como interface do R. O *LiDAR Data_Analysis Tools* foi projetado para agilizar o processo de análise de regressão estatística envolvendo métricas LiDAR geradas pelo Serviço Florestal Norte Americano e, de fato, funciona como uma interface gráfica para acessar os pacotes de modelagem estatística disponíveis no R que simplificam o processamento de grandes volumes de dados (SILVA et al., 2017).

2.4.1 Teste dos modelos para biomassa e carbono

Para a construção dos modelos alométricos de biomassa e carbono por hectare em função das métricas LiDAR para as duas áreas, foram utilizadas três abordagens de análise de dados: Regressão linear múltipla com Componentes Principais – PCA, Regressão linear múltipla e Regressão linear múltipla com *Stepwise*.

Primeiro, foi utilizada a técnica de componentes principais – PCA, sendo aplicada às métricas LiDAR selecionadas, e aquelas com maior probabilidade de contribuir para o desenvolvimento do modelo foram identificadas ao inspecionar os autovetores em cada componente principal (PC). Em seguida, foram usadas as métricas com maior carregamento nos PCs como variáveis de entrada em modelos de regressão linear multivariada que previam a biomassa por hectare.

No presente estudo, o PCA foi aplicado sobre as métricas LiDAR selecionadas usando a função *prcomp* do pacote de estatísticas no software R (R CORE TEAM, 2017). Uma matriz de correlação derivada das métricas de LiDAR forneceu a base para os cálculos de autovalores e autovetores e para a subsequente determinação dos escores de PC. Cada escore representou uma métrica transformada da combinação linear das métricas de LiDAR. Ao analisar os autovetores e o escore do PC, pode-se estabelecer diferenças na contribuição de cada métrica LiDAR para a variabilidade no conjunto de dados, bem como a similaridade nas métricas calculadas (SILVA et al., 2017).

Em segundo lugar, foi aplicada técnica de modelagem tradicional, empregando a regressão linear múltipla. Desta forma, assumiu-se que existe uma relação linear entre uma variável Y (biomassa; carbono) e k variáveis independentes, x_j ($k =$ métricas da nuvem de pontos LiDAR) conforme expressa na Equação 6.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \epsilon \quad (\text{Eq. 6})$$

Em que: $Y =$ TAGB ou TAGC (Mg ha^{-1}); $\beta_0 =$ intercepto no eixo Y; $\beta_i =$ coeficiente angular da i-ésima variável explicativa; $k =$ número de variáveis explicativas; $\epsilon =$ erro aleatório.

Dentre as métricas geradas pelo processamento de dados LiDAR, para a construção dos modelos, uma análise criteriosa foi realizada no processo de seleção das melhores métricas da nuvem de pontos LiDAR candidatas à modelagem. Para esta seleção, primeiramente, foi aplicado o teste de correlação linear de Pearson (r), para obter a correlação entre as variáveis preditivas e avaliar a possível existência de colinearidade entre elas. As variáveis que apresentaram $r > 0,9$ foram excluídas da análise para evitar a presença de colinearidade.

Em terceiro lugar, foi aplicada técnica de modelagem de regressão linear múltipla com *Stepwise* por meio da função *regsubsets* do pacote “*leaps*” do software R, para a obtenção de subconjuntos de variáveis independentes candidatas à composição dos modelos definitivos para biomassa e carbono nas diferentes áreas. Por este método, foi realizada uma busca exaustiva para a seleção das melhores combinações de variáveis independentes por meio da minimização do critério de informação da Akaike (AIC) e, também, rearranjo em subconjuntos que, posteriormente, deram origem aos modelos selecionados.

2.5 Avaliação dos modelos

Em todos os métodos de modelagem descritos, os parâmetros dos modelos foram estimados usando métodos de Mínimos Quadrados Ordinários (OLS – Ordinary Least Squares). Em geral, os parâmetros foram estimados usando todas as parcelas amostradas em cada área e foram assumidos como verdadeiros, permitindo representar a biomassa e o estoque de carbono em cada local.

Para cada um dos critérios estabelecidos para estimativa de biomassa, as equações obtidas foram analisadas por meio de comparações de critérios estatísticos obtidos, conforme as Equações 7, 8 e 9.

– Critério de Informação de Akaike (AIC):

$$AIC = -2LL + 2k \quad (\text{Eq. 7})$$

Em que: LL é a log-verossimilhança e k é o número de parâmetros do modelo. Este critério penaliza a adição de parâmetros nos modelos analisados. Indica a qualidade do ajuste pelas equações. A melhor equação minimiza o valor do AIC.

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

$$R^2_{aj} = R^2 - \left[\frac{k-1}{n-k} \right] \times (1-R^2) \quad (\text{Eq. 8})$$

Em que: R^2 = coeficiente de determinação; n = número de observações; k já definido anteriormente. Por este critério, quanto mais próximo de um (1,0) ou 100 % for o valor do coeficiente de determinação ajustado, maior será a variação total dos dados explicada pela equação.

– Raiz quadrada do erro médio (RMSE):

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad (\text{Eq. 9})$$

Em que: Y_i é a variável resposta (biomassa e/ou carbono) observada em campo (i); \hat{Y} é a estimativa (biomassa e/ou carbono) e n , o número total de observações. A raiz quadrada do

erro médio indica a diferença média quadrática entre os valores observados e estimados. Quanto menor o RMSE, melhor a precisão da estimativa (MEHTÄTALO et al., 2006).

Após a seleção da melhor equação de biomassa e carbono a partir das métricas LiDAR, foram feitas comparações entre as estimativas obtidas por dados de inventário convencional e por dados LiDAR por área demonstradas em um gráfico boxplot feito no *RStudio*. A metodologia adotada pode ser visualizada na Figura 4.

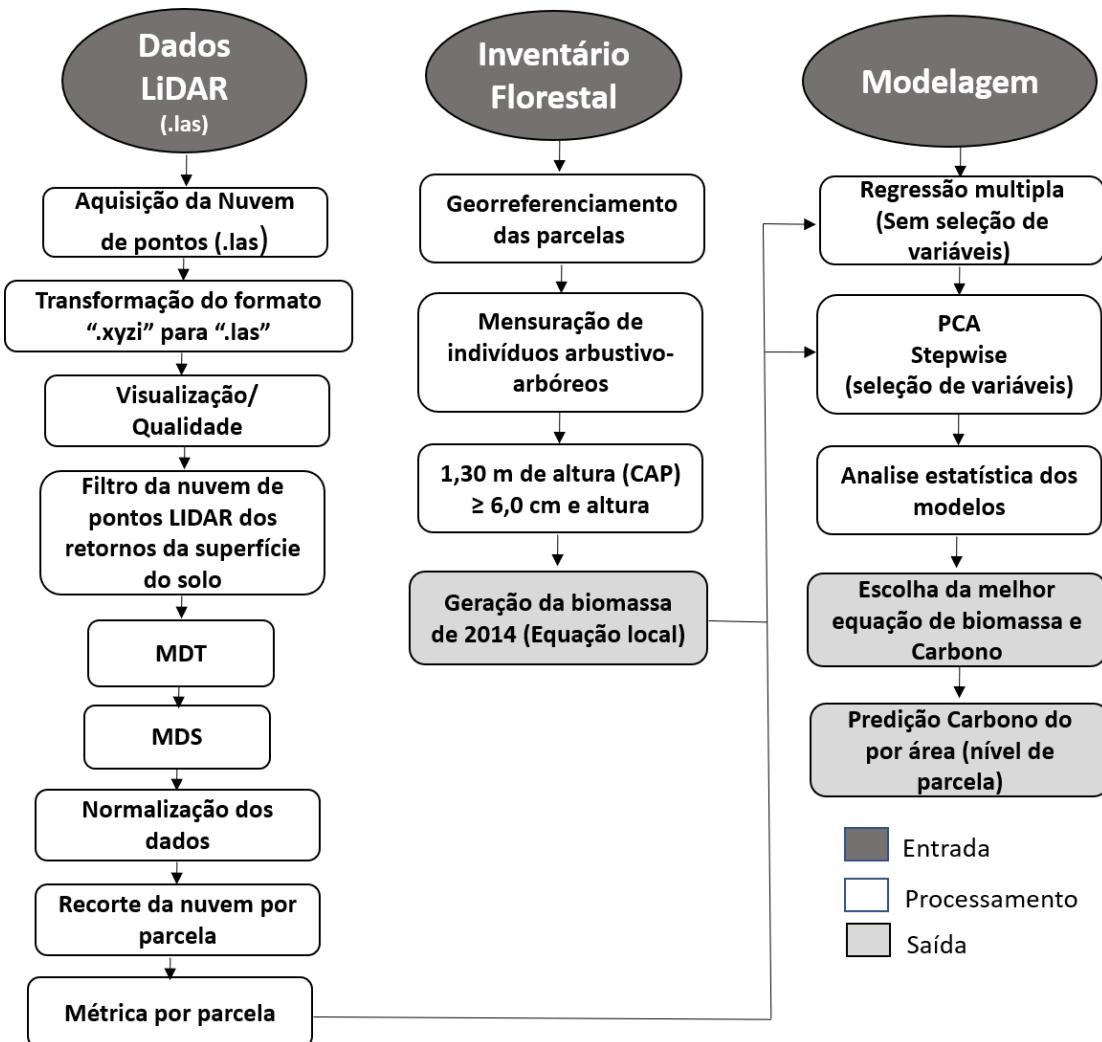


Figura 4 – Fluxograma da metodologia adotada para ajuste de equações de biomassa e predição de carbono com LiDAR de uma área de floresta seca, Floresta-PE.

3 RESULTADOS E DISCUSSÃO

Os valores de elevação mínima, média e máxima que correspondem às alturas das árvores obtidas pelas métricas LiDAR variaram de 1,49 a 4,77 metros, com média de 3,06 m para a área do Correntão. Para a área da Transposição, ocorreu pouca diferença nas elevações mínimas por parcela (1,39 m), porém, com menor elevação média (2,88 m) e maior elevação

máxima (5,05 m). A maior concentração de biomassa e carbono total por hectare foi observada na área do Correntão, com valores que variam de 0,61 a 129 Mg ha⁻¹, com uma média de 24,93. As estimativas de TAGB para todas as parcelas da área da Transposição variaram de 1,22 a 29,37 Mg ha⁻¹, com um valor médio de 9,32 Mg ha⁻¹.

A análise de componentes principais das métricas da Transposição produziu três componentes principais que sintetizaram 85,6% da variabilidade nos dados (Tabela 5). O primeiro componente principal (PC1) das métricas desta área teve alta carga de todas as variáveis com contribuição máxima da elevação média (0,996). Já para as métricas da área do Correntão, observou-se, também, três componentes principais que sintetizaram 82,8% da variabilidade nos dados (Tabela 6). O primeiro componente principal (PC1) para as métricas desta área teve cargas máximas para elevação máxima e elevação média. Os componentes principais que representaram apenas uma pequena quantidade de variância não foram utilizados na análise de regressão.

Tabela 5 – Cargas de componentes, valores próprios e porcentagem de variação dos componentes principais (PC) para as métricas LiDAR da área da Transposição.

Componente principal	Componentes (Autovetores)												
	Elev. Minimum	Elev. maximum	Elev. mean	Elev. mode	Elev. stddev	Elev. CV	Elev. skewness	Elev. kurtosis	Elev. MAD. median	Elev. P01	Elev. Auto valores	Var (%)	
PC1	0,285	0,678	0,996	0,759	0,719	0,333	-0,231	-0,192	0,689	0,420	12,463	51,929	
PC2	-0,395	0,621	0,070	-0,020	0,675	0,902	0,738	0,151	0,590	-0,508	5,841	76,266	
PC3	0,622	0,281	-0,009	-0,070	-0,027	0,016	0,597	0,672	-0,203	0,602	2,255	85,663	

Em que: Elev.minimum = Altura mínima; Elev.maximum = Altura máxima; Elev.mean = Altura média; Elev.mode = Altura modal; Elev.stddev = Desvio padrão das alturas; Elev.CV = Coeficiente de variação da altura; Elev.skewness = Assimetria da altura; Elev.kurtosis = Curtose da altura; Elev.MAD.median = Mediana dos desvios absolutos da média geral; Elev.P01 = Percentil 01 da altura.

Tabela 6 – Cargas de componentes, valores próprios e porcentagem de variação dos componentes principais (PC) para as métricas LiDAR da área do Correntão.

Componente principal	Componentes (Autovetores)												
	Elev. minimum	Elev. maximum	Elev. mean	Elev. mode	Elev. stddev	Elev. CV	Elev. skewness	Elev. kurtosis	Elev. MAD.median	Elev. P01	Elev. Auto valores	Var(%)	
PC1	0,019	0,825	0,999	0,709	0,708	0,158	-0,192	0,170	0,557	0,305	13,233	55,136	
PC2	-0,130	0,423	0,018	-0,302	0,675	0,943	0,708	-0,179	0,633	-0,234	4,119	72,299	
PC3	0,765	-0,283	0,016	-0,106	0,074	0,110	-0,103	-0,805	0,359	0,636	2,524	82,815	

Em que: Elev.minimum = Altura mínima; Elev.maximum = Altura máxima; Elev.mean = Altura média; Elev.mode = Altura modal; Elev.stddev = Desvio padrão das alturas; Elev.CV = Coeficiente de variação da altura; Elev.skewness = Assimetria da altura; Elev.kurtosis = Curtose da altura; Elev.MAD.median = Mediana dos desvios absolutos da média geral; Elev.P01 = Percentil 01 da altura.

3.1 Equações Preditivas por dados LiDAR.

Para cada área, as variáveis que não contribuíram significativamente para a predição de TAGB e TAGC foram eliminadas, simultaneamente, durante a análise.

Com base nas estatísticas de ajuste, para as duas áreas, o modelo de regressão *Stepwise* foi considerado o mais adequado para predição de TAGB e TAGC, muito embora, o erro de predição do modelo múltiplo tenha sido, ligeiramente, inferior, já modelos desenvolvidos utilizando a técnica de componentes principais das métricas LiDAR tiveram desempenho insatisfatório (AIC maior).

Nas equações preditivas de biomassa para a Transposição, o coeficiente de determinação (R^2_{aj}) dos modelos variou de 0,17 a 0,42 e o RMSE de 3,18 a 5,99 Mg ha⁻¹ (Tabela 7). Modelos com valores mais altos de R^2 e menores RMSE indicam melhor predição de TAGB. Para a área Transposição, as variáveis preditoras mais significativas para a equação e, portanto, as mais adequadas para predição da TAGB local, foram Altura minima (Elev.minimum), Altura máxima (Elev.maximum), Altura media (Elev.mean) e Percentil 01 da altura (Elev.P01); as duas últimas encontradas em todos as equações geradas. Para a área do Correntão, a equação final prevê que o estoque total de biomassa pode ser mais significativo a partir das métricas Altura máxima (Elev.maximum), Altura media (Elev.mean), Coeficiente de variação da altura (Elev.CV), Curtose da altura (Elev.kurtosis), Percentil 01 da altura (Elev.P01), Percentil 10 da altura (Elev.P10), Percentil 30 da altura (Elev.P30), Percentil 75 da altura (Elev.P75) e Relação do relevo do dossel (Canopy.relief.ratio).

Nas equações preditivas de carbono para a Transposição, o coeficiente de determinação (R^2_{aj}) dos modelos variou de 0,17 a 0,57 e o RMSE de 6,18 a 7,15 Mg ha⁻¹; e, na Correntão, o coeficiente de determinação (R^2_{aj}) chegou de -0,10 a 0,22 e o RMSE de 13,6 a 28,4 Mg ha⁻¹ (Tabela 8). Para a área Transposição, as variáveis preditoras mais significativas para a equação, e, portanto, as mais adequadas para predição da TAGC local, foram Altura minima (Elev.minimum), Altura média (Elev.mean), Altura modal (Elev. Mode), Percentil 01 da altura (Elev.P01), Percentil 20 da altura (Elev.P20), Percentil 50 da altura (Elev.P50) e Percentil 90 da altura (Elev.P90). Para a área do Correntão, a equação final prevê que o estoque total de carbono é significativo a partir das métricas Altura máxima (Elev. Maximum), Altura media (Elev.mean), Coeficiente de variação da altura (Elev.CV), Curtose da altura (Elev.kurtosis), Percentil 01 da altura (Elev.P01), Percentil 10 da altura (Elev.P10), Percentil 30 da altura (Elev.P30), Percentil 75 da altura (Elev.P75) e Relação do relevo do dossel (Canopy.relief.ratio).

Tabela 7 – Equações lineares múltiplas ajustadas para a estimativa de biomassa, obtidas pelos dados LiDAR, para duas áreas de Caatinga, em Floresta, PE.

Área	Equações preditivas de biomassa	R ² adj	RMSE
Regressão Múltipla	$\text{TAGB} = -86,809 -33,295(\text{Elev.minimum}) + 5,446(\text{Elev.maximum}) + 195,226(\text{Elev.mean}) + 3,774 (\text{Elev.mode}) -92,658(\text{Elev.stddev}) + 206,851(\text{Elev.CV}) + 13,627(\text{Elev.skewness}) -1,734 (\text{Elev.kurtosis}) + 24,360(\text{Elev.MAD.median}) + 29,676(\text{Elev.P01}) -25,707(\text{Elev.P10}) -64,704(\text{Elev.P20}) + 49,118(\text{Elev.P25}) -26,958(\text{Elev.P30}) -44,133(\text{Elev.P50}) -21,226(\text{Elev.P60}) -11,419(\text{Elev.P75}) 2,295(\text{Elev.P80}) -27,855(\text{Elev.P90}) -15,740(\text{Elev.P95}) + 98,142(\text{Canopy.relief.ratio}) + 0,024(\text{Percentage.allreturns.above.1.30})$	0,1924	3,18
Transposição			
Regressão Stepwise	$\text{TAGB} = \mathbf{-21,08 -35,756 (\text{Elev.minimum}) + 119,784 (\text{Elev.mean}) + 4,582 (\text{Elev.mode}) -63,752 (\text{Elev.stddev}) + 101,103 (\text{Elev.CV}) + 27,823 (\text{Elev.P01}) -17,626 (\text{Elev.P10}) -29,152(\text{Elev.P20}) -44,745 (\text{Elev.P50}) -18,032 (\text{Elev.P90})}$	0,4239	3,51
Regressão PCA	$\text{TAGB} = 9,145 + 0,607(\text{Dim.1}) + 1 (\text{Dim.3})$	0,1723	5,99
Regressão Múltipla	$\text{TAGB} = 341,760 + 0,932(\text{Elev.minimum}) + 123,520(\text{Elev.maximum}) -298,028(\text{Elev.mean}) + 1,734(\text{Elev.mode}) -14,288(\text{Elev.stddev}) + 712,426(\text{Elev.CV}) -8,027(\text{Elev.skewness}) -36,267(\text{Elev.kurtosis}) + 103,257(\text{Elev.MAD.median}) + 114,736(\text{Elev.P01}) + 79,665(\text{Elev.P10}) + 54,843(\text{Elev.P20}) + 39,873(\text{Elev.P25}) + 90,032(\text{Elev.P30}) + 20,564(\text{Elev.P50}) + 5,063(\text{Elev.P60}) -129,573(\text{Elev.P75}) -33,779(\text{Elev.P80}) + 57,286(\text{Elev.P90}) 53,403(\text{Elev.P95}) + 519,378(\text{Canopy.relief.ratio}) -0,103(\text{Percentage.allreturns.above.1.30})$	0,4239	13,61
Correntão			
Regressão Stepwise	$\text{TAGB} = \mathbf{-269,86 + 145,44(\text{Elev. maximum}) -402,19(\text{Elev.mean}) + 440,13(\text{Elev.CV}) -53,26(\text{Elev.kurtosis}) + 88,49(\text{Elev.P01}) + 93,09(\text{Elev.P10}) + 165,73 (\text{Elev.P30}) -67,6(\text{Elev.P75}) + 673,35(\text{Canopy.relief.ratio})}$	0,533	14,76
Regressão PCA	$\text{TAGB} = 30,270 -6,465 (\text{Dim.3})$	0,09621	28,45

Em que: Elev.minimum = Altura mínima; Elev.maximum = Altura máxima; Elev.mean = Altura média; Elev.mode = Altura modal; Elev.stddev = Desvio padrão das alturas; Elev.CV = Coeficiente de variação da altura; Elev.skewness = Assimetria da altura; Elev.kurtosis = Curtose da altura; Elev.MAD.median = Mediana dos desvios absolutos da média geral; Elev.P01 = Percentil 01 da altura; Elev.P20 = Percentil 20 da altura; Elev.P25 = Percentil 25 da altura; Elev.P30 = Percentil 30 da altura; Elev.P50 = Percentil 50 da altura; Elev.P60 = Percentil 60 da altura; Elev.P75 = Percentil 75 da altura; Elev.P80 = Percentil 80 da altura; Elev.P90 = Percentil 90 da altura; Elev.P95 = Percentil 95 da altura; Canopy.relief.ratio = Relação do relevo do dossel; Percentage.allreturns.above.1.30 = Porcentagem de todos os retornos acima de 1.30.

Tabela 8 – Equações lineares múltiplas ajustadas para a estimativa de carbono, obtidas pelos dados LiDAR, para duas áreas de Caatinga, em Floresta, PE.

Área	Equações preditivas de carbono	R ² aj	RMSE
Regressão Múltipla	TC = -43,404 -16,647(Elev.minimum) + 2,723(Elev.maximum) + 97,613(Elev.mean) + 1,887(Elev.mode) -46,329(Elev.stddev) + 103,425(Elev.CV) + 6,813(Elev.skewness) -0,867(Elev.kurtosis) +12,180(Elev.MAD.median) + 14,838(Elev.P01) - 12,853(Elev.P10) -32,352(Elev.P20) + 24,559(Elev.P25) -13,479(Elev.P30) -22,06(Elev.P50) -10,613(Elev.P60) - 5,709(Elev.P75) +1,147(Elev.P80) -13,927(Elev.P90) -7,870(Elev.P95) + 49,071(Canopy.relief.ratio) + 0,012(Percentage.allreturns.above.1.30)	0,1924	6,04
Transposição			
Regressão Stepwise	TC= -10,540-17,878(Elev.minimum) 59,891(Elev.mean) + 2,291(Elev.mode) -31,876(Elev.stddev) 50,551(Elev.CV) +13,911(Elev.P01) -8,813(Elev.P10) -14,576(Elev.P20) -22,372(Elev.P50) -9,0159(Elev.P90)	0,5716	6,18
Regressão PCA	TC = 4,5727 + 0,3036(Dim.1) + 0,7354(Dim.4)	0,1723	7,15
Regressão Múltipla	TC = 79,991+ 24,864(Elev.minimum) -104,043(Elev.maximum) +261,094(Elev.mean) + 6,231(Elev.mode) +399,325(Elev.stddev) -518,389(Elev.CV)+79,638(Elev.skewness) +24,478(Elev.kurtosis) -9,308(Elev.MAD.median) - 79,998(Elev.P01) -37,320(Elev.P10) +6.003(Elev.P20) -76,229(Elev.P25) -5,941(Elev.P30) +65,822(Elev.P50) - 50,516(Elev.P60) +36,131(Elev.P75) -46,125(Elev.P80) +25,630(Elev.P90) -86,721(Elev.P95) -55,834(Canopy.relief.ratio) +0,7015(Percentage.allreturns.above.1.30)	-0,105	22,94
Correntão			
Regressão Stepwise	TC = -17,234 -58,239(Elev. maximum) +267,346(Elev.mean) + 104,764(Elev.stddev) +54,867(Elev.skewness) -42.1867 (Elev.P01) -36.6351(Elev.P10) -45.9202 (Elev.P25) -51.9556 (Elev.P80) -38.9300 (Elev.P80) +0.4855(Percentage.all.return s.above.1.30)	0,2221	23,88
Regressão PCA	TC = 30,270 -6,465 (Dim.3)	0,1921	31,87

Em que: Elev.minimum= Altura mínima; Elev.maximum = Altura máxima; Elev.mean = Altura média; Elev.mode = Altura modal; Elev.stddev = Desvio padrão das alturas; Elev.CV = Coeficiente de variação da altura; Elev.skewness = Assimetria da altura; Elev.kurtosis = Curtose da altura; Elev.MAD.median = Mediana dos desvios absolutos da média geral; Elev.P01 = Percentil 01 da altura; Elev.P20 = Percentil 20 da altura; Elev.P25 = Percentil 25 da altura; Elev.P30 = Percentil 30 da altura ; Elev.P50 = Percentil 50 da altura; Elev.P60 = Percentil 60 da altura; Elev.P75 = Percentil 75 da altura; Elev.P80 = Percentil 80 da altura; Elev.P90 = Percentil 90 da altura; Elev.P95 = Percentil 95 da altura; Canopy.relief.ratio = Relação do relevo do dossel; Percentage.allreturns.above.1.30 = Porcentagem de todos os retornos acima de 1.30.

3.2 Predição de carbono por área

Na Figura 5 são mostradas informações descritivas sobre a biomassa e o carbono para as áreas analisadas e comparadas as estimativas obtidas por meio de inventário e tecnologia LiDAR. A maior variação encontrada foi na estimativa de biomassa na área do Correntão, tanto com dados de inventário quanto nos de LiDAR, e a menor dispersão foi encontrada nas estimativas de carbono da área da Transposição com os dados de inventário. A média da biomassa acima do solo, considerando a estimativa obtida por dados de inventário, foi de $8974,07 \text{ Mg ha}^{-1}$ na área da Transposição e $18881,07 \text{ Mg ha}^{-1}$ na área do Correntão. Já para estimativas obtidas por dados LiDAR, a média de biomassa foi de $9190,58 \text{ Mg ha}^{-1}$ para a área da Transposição e de $21338,17 \text{ Mg ha}^{-1}$ para a área do Correntão. A média de carbono, na estimativa por inventário, apresentou valores de $4663,29 \text{ Mg ha}^{-1}$ na área da Transposição e $8619,12 \text{ Mg ha}^{-1}$ na área do Correntão. Por estimativas apresentadas por meio de dados LiDAR, as médias foram de $4663,29 \text{ Mg ha}^{-1}$ na área da Transposição e $12469,47 \text{ Mg ha}^{-1}$ na área do Correntão. A menor biomassa encontrada foi de $4,71 \text{ Mg ha}^{-1}$, na área do Correntão, por dados LiDAR e a maior foi de $129007,33 \text{ Mg ha}^{-1}$, também na área do Correntão e, também, por dados LiDAR.

Quando se compararam as áreas, nota-se que a área de menor histórico de perturbação, conhecida como Transposição, apresentou um menor estoque de carbono do que a área do Correntão (Figura 5). Nos inventários realizados nas duas áreas (Apêndice 2), o DAP observado foi superior na área em que havia menor número de árvores, no nosso caso, a do Correntão (996 indivíduos) e, assim, uma menor competição para o desenvolvimento das espécies e, consequentemente, influenciando, de maneira substancial, os valores de biomassa e carbono preditos; enquanto a área com menor estoque de carbono, a da Transposição, apresentou, em seu inventário, 1728 indivíduos.

Esses resultados não são apenas numéricos absolutos das variáveis inventariadas, mas, também, de outras variáveis obtidas da tecnologia LiDAR e que devem ser consideradas para uma melhor interpretação dos resultados obtidos neste trabalho, elas são: a densidade de pulsos emitidas pelo LiDAR, as características dos fustes da vegetação estudada e o efeito estresse hídrico sobre as folhas.

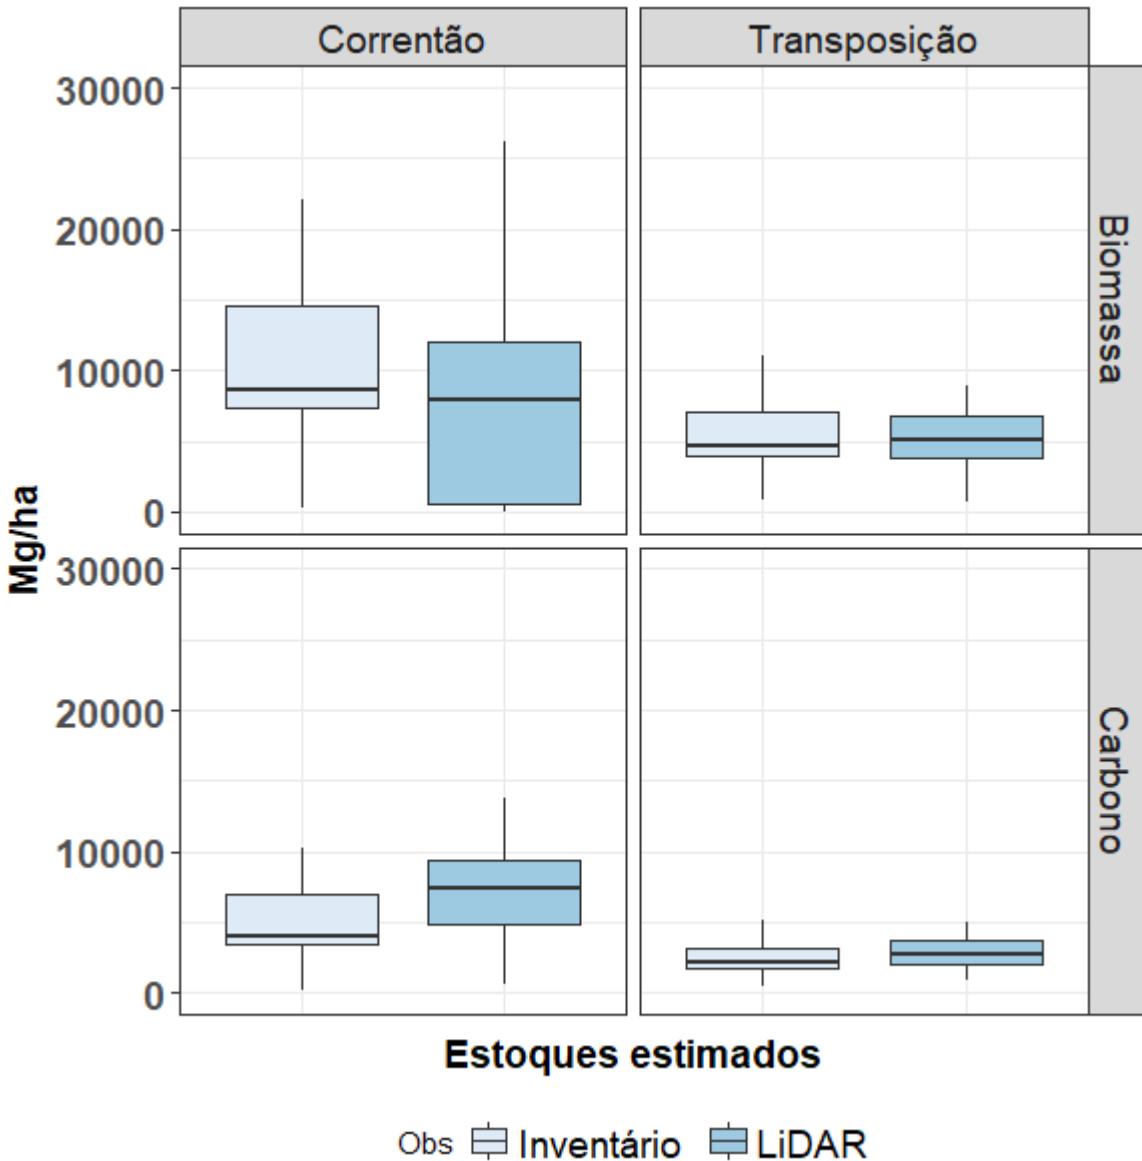


Figura 5 – Box-plot para biomassa acima do solo e carbono dos estoques estimados por meio de inventário e tecnologia LiDAR nas áreas da Transposição e Correntão. As caixas representam os percentis 25 e 75; as margens representam os percentis 10 e 90. A linha representa a mediana.

Os resultados preliminares deste estudo indicam que as métricas LiDAR forneceram estimativas confiáveis de TAGB e TAGC para as duas áreas de estudo. Os resultados mostram uma boa relação estatística entre os dados de biomassa de campo e as métricas de altura (elevação), sugerindo-as como importante preditora de biomassa local, principalmente, quando são selecionadas via método *Stepwise*. No entanto, em ambas áreas, a relação foi mais fraca quando todas as métricas foram incorporadas ao processo de modelagem tradicional ou quando se

utilizou a regressão com componentes principais. Apenas as categorias individuais das métricas de altura (mínima, média e máxima) explicaram mais de 40% da variância. Isto sugere que a incorporação de dados de métricas de alturas pode ser necessária para melhorar a predição da TAGB e TAGC.

Os valores de R^2 e RMSE das equações de melhor ajuste variam em estudos similares que usaram dados e métricas LiDAR para estimar e mapear a biomassa acima do solo de árvores em florestas secas. Anderson et al. (2018) em Idaho (EUA) relatou valores de R^2 de 0,36 a 0,71 e valores de RMSE de 99 a 175 Mg ha⁻¹ com base em dados de aprendizado de máquina. Hernández-Stefanoni et al. (2015), em uma floresta tropical seca, no México, relatou R^2 de 0,77 e RMSE de 21.6 a 25.7 Mg ha⁻¹ com base em dados de regressão linear e LiDAR. Li et al. (2017), também em Idaho (EUA), relatou R^2 de 0,87 e RMSE de 3,59 kg, com base em regressão linear e dados de cobertura vegetal percentual derivada de ALS. Chen et al. (2015), na Amazônia, relatou R^2 variando de 0,38 a 0,64, com base em modelos de efeitos mistos e dados LiDAR de sistemas agroflorestais. Em todos estes casos, as estimativas de biomassa pelas metodologias testadas mostraram resultados satisfatórios.

A equação TAGB de melhor ajuste consistiu em 10 variáveis preditoras LiDAR para a área da Transposição e 9 variáveis preditoras LiDAR para a área do Correntão. Estas variáveis indicam que o perfil vertical da vegetação em diferentes elevações (alturas mínimas, médias e máximas) são preditoras promissoras para a TAGB. A estimativa e o mapeamento da TAGB para a floresta de estudo foram baseados no modelo *best-fit*. O padrão de distribuição espacial da TAGB está relacionado à estrutura e composição da paisagem da floresta, onde as áreas de baixa TAGB correspondem a áreas com baixa cobertura florestal, e áreas de alta biomassa correspondem a áreas densamente florestadas. O TAGB médio geral para duas áreas é de 32 Mg ha⁻¹, é comparável e está dentro da faixa de valores relatados para florestas tropicais secas maduras em pesquisas anteriores, fato que indica que a abordagem de modelagem usada neste estudo fornece previsões razoáveis de TAGB (MARTINUZZI et al., 2013; KACHAMBA et al., 2017; NAVEENKUMAR et al., 2017).

Uma possível fonte de erro nas predições de biomassa pode ser a densidade de pontos adotada. Nos dados utilizados, foram adotados 0,5 (pulsos/m²), enquanto, nos trabalhos de quantificação de carbono, geralmente, trabalha-se com 4 a 25 pontos (SILVA et al., 2014; FIGUEIREDO et al., 2016; COOMES et al., 2017; NELSON et al., 2017). Silva et al. (2017), por

meio de testes com densidade de pontos, verificou que a redução da densidade pode resultar na diminuição do R^2 e no aumento no RMSE, além de, possivelmente, aumentar a variância das estimativas do AGB. Leitold et al. (2015), em seus estudos, obtive viés nas estimativas de altura que se traduziram em erros de 80–125 Mg ha⁻¹, quando o operador trabalhava com a densidade de pulsos abaixo de 4 m².

Quando as densidades de pulso são de moderadas a altas, as mudanças são invariantes, afetando, relativamente pouco, os resultados, no entanto, a partir da queda do pulso para 1/m², as métricas relacionadas à cobertura (cobertura do dossel, densidade de árvores e cobertura de arbustos) tornam-se mais sensíveis à mudança desta densidade (MAGNUSSON et al., 2007). Deste modo, o aumento do RMSE pode ser explicado pela classificação menos precisa dos retornos do solo (SILVA et al., 2017). Contudo, é válido ressaltar que a baixa densidade de pontos também pode ser relacionada a bons resultados, dependendo da variável a ser estudada, como, por exemplo, métricas de dossel (THOMAS et al., 2006) ou volume (TAKAHASHI et al., 2010). Além disto, a TAGC para a área de estudo foi estimada com base na TAGB e na fração média de carbono das árvores; quaisquer erros na estimativa da TAGB estender-se-iam às estimativas da TAGC. Ainda assim, os resultados deste estudo indicam que o modelo TAGB forneceu estimativas confiáveis de TAGB para a área de estudo.

4 CONCLUSÕES

A partir do trabalho desenvolvido, pôde-se verificar que os dados LiDAR ou serem usados para a estimativa de biomassa e carbono total em floresta tropical seca, tem-se ajuste considerável nos modelos empregados e embora sejam preliminares, sugerem que estão dentro do padrão obtido no inventário.

A densidade de pulsos mesmo não sendo uma variável dentro dos modelos, pode ser influenciadora indireta na precisão deles, assim podendo recomendando-se que para trabalhos futuros sejam testados dados com uma densidade maior de pulsos.

Este estudo forneceu informações importantes sobre a distribuição de TAGB e TAGC na área de estudo, que pode ser usada para gerenciar a reserva para o sequestro de carbono. Além de abrir precedente para comparação em trabalhos futuros desenvolvidos a partir dos dados LiDAR do Programa Pernambuco Tridimensional no meio florestal.

REFERÊNCIAS

- ACHARD, F., HOUSE, J.I. Reporting carbon losses from tropical deforestation with Pan-tropical biomass maps. **Environmental Research Letters**, Bristol,v.10,p.1-3, 2015. <https://doi.org/10.1088/1748-9326/10/10/101002>.
- ALTHOFF, T.D. et al. Adaptation of the century model to simulate C and N dynamics of Caatinga dry forest before and after deforestation. **Agriculture, Ecosystems & Environment**, Amsterdam,v.254, p.26–34, 2018. <https://doi.org/10.1016/j.agee.2017.11.016>.
- ANDERSON, K.E. et al. Estimating vegetation biomass and cover across large plots in shrub and grass dominated drylands using terrestrial LiDAR and machine learning. **Ecological Indicators**, New York,v.84, p.793–802, 2018. <https://doi.org/10.1016/j.ecolind.2017.09.034>.
- ASNER, G.P. A universal airborne LiDAR approach for tropical forest carbon mapping. **Oecologia**, Berlim, v.168, n.4, p.1147–1160, 2011. <https://doi.org/10.1007/s00442-011-2165-z>.
- AVITABILE, V. et al. Mapping biomass with remote sensing: a comparison of methods for the case study of Uganda. **Carbon Balance and Management**, London,v.6, n.7, p.1-14, 2011. <https://doi.org/10.1186/1750-0680-6-7>.
- BECKNELL, J.M. et al. Landscape-scale LiDAR analysis of aboveground biomass distribution in secondary Brazilian Atlantic Forest. **Biotropica**, Washington,v.50, n.3,p.520–530, 2018. <https://doi.org/10.1111/btp.12538>.
- BRAHMA, B. et al. Estimating biomass stocks and potential loss of biomass carbon through clear-felling of rubber plantations. **Biomass and Bioenergy**,Oxford,v.115, p.88–96, 2018. <https://doi.org/10.1016/j.biombioe.2018.04.019>.
- CHEN, Q. et al. Modeling and Mapping Agroforestry Aboveground Biomass in the Brazilian Amazon Using Airborne LiDAR Data. **Remote Sensing**,Basel,v.8, 2015. <https://doi.org/10.3390/rs8010021>.
- COOMES, D.A. et al. Area-based vs tree-centric approaches to mapping forest carbon in Southeast Asian forests from airborne laser scanning data. **Remote Sensing of Environment**, New York-US,v.194, p.77–88, 2017. <https://doi.org/10.1016/j.rse.2017.03.017>.

CROWTHER, T.W. et al. Mapping tree density at a global scale. **Nature**, London, v.525, p.201–205, 2015. <https://doi.org/10.1038/nature14967>.

DALLA LANA, M. et al. Carbon Content in Shrub-tree Species of the Caatinga. **Floresta e Ambiente**, Seropedica, v. 26, n. 2, p. 1-11, 2019. <https://doi.org/10.1590/2179-8087.061717>.

DUNCANSON, L. et al. Implications of allometric model selection for county-level biomass mapping. **Carbon Balance and Management**, London, v.12, n.18, p.1-11, 2017. <https://doi.org/10.1186/s13021-017-0086-9>.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (EMBRAPA). **Diagnóstico Ambiental do Município de Floresta, Pernambuco**. Rio de Janeiro-RJ: EMBRAPA, 2001. (Circular Técnica, ISSN 1517-5146). Disponível em: <<https://www.infoteca.cnptia.embrapa.br/bitstream/doc/338510/1/circulartecnica10diagambfloresta.pdf>>. Acesso em: 11/05/2018.

FIGUEIREDO, E.O. et al. LIDAR-based estimation of bole biomass for precision management of an Amazonian forest: Comparisons of ground-based and remotely sensed estimates. **Remote Sensing of Environment**, New York, v.187, p.281–293, 2016. <https://doi.org/10.1016/j.rse.2016.10.026>.

HERNÁNDEZ-STEFANONI, J.L. et al. Estimating species richness and biomass of tropical dry forests using LIDAR during leaf-on and leaf-off canopy conditions. **Applied Vegetation Science**. Bethesda, v.18, n.4, 724–732, 2015. <https://doi.org/10.1111/avsc.12190>.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. **Manual técnico da vegetação brasileira**, 2012.

KACHAMBA, D. et al. Influence of Plot Size on Efficiency of Biomass Estimates in Inventories of Dry Tropical Forests Assisted by Photogrammetric Data from an Unmanned Aircraft System. **Remote Sensing**, Basel, v.9, 610, 2017. <https://doi.org/10.3390/rs9060610>.

LEITOLD, V. et al. Airborne LiDAR-based estimates of tropical forest structure in complex terrain: opportunities and trade-offs for REDD+. **Carbon Balance and Management**, London, v.10, n.3, p.1-12, 2015. <https://doi.org/10.1186/s13021-015-0013-x>.

LI, A. et al. LiDAR Aboveground Vegetation Biomass Estimates in Shrublands: Prediction, Uncertainties and Application to Coarser Scales. **Remote Sensing**, Basel, v.9, n.6, p.1-15, 2017. <https://doi.org/10.3390/rs9090903>.

MAGNUSSON, M. et al. Effects on Estimation Accuracy of Forest Variables Using Different Pulse Density of Laser Data. **Forest Science**. Bethesda, v.53, n.6, p.619-626. 2007. Disponível em: <https://pub.epsilon.slu.se/3651/>. Acesso em: 22 jun. 2018.

MARTINUZZI, S. et al. Quantifying Tropical Dry Forest Type and Succession: Substantial Improvement with LiDAR. **Biotropica**, Washington, v.45, n.2, p.135–146, 2013. <https://doi.org/10.1111/j.1744-7429.2012.00904.x>.

MEHTÄTALO, L. et al. The use of quantile trees in the prediction of the diameter distribution of a stand. **Silva Fennica**, Helsinki, v.40, p.3, p.501-516, 2006. <https://doi.org/10.14214/sf.333>.

MOHEBALIAN, P.M., AGUILAR, F.X. Beneath the Canopy: Tropical Forests Enrolled in Conservation Payments Reveal Evidence of Less Degradation. **Ecological Economics**, New York, v.143, p.64–73, 2018. <https://doi.org/10.1016/j.ecolecon.2017.06.038>.

NAVEENKUMAR, J.; ARUNKUMAR, K.S.; SUNDARAPANDIAN, S. Biomass and carbon stocks of a tropical dry forest of the Javadi Hills, Eastern Ghats, India. **Carbon Management**, London, v.8, n.5-6, p.351–361, 2017. <https://doi.org/10.1080/17583004.2017.1362946>.

NELSON, R. et al. LiDAR-based estimates of aboveground biomass in the continental US and Mexico using ground, airborne, and satellite observations. **Remote Sensing of Environment**, New York, v.188, p.127–140, 2017. <https://doi.org/10.1016/j.rse.2016.10.038>.

PIMENTEL, D. J. O.N. **Dinâmica da vegetação lenhosa em área de caatinga, Floresta-PE**. 2012. 62f. Dissertação (Mestrado em Ciências Florestais) - Universidade Federal Rural de Pernambuco, 2012. Disponível em: http://www.ppgcf.ufrpe.br/sites/www.ppgcf.ufrpe.br/files/documentos/diogo_jose_oliveira_pimentel.pdf. Acesso em: 22 jun. 2017.

R CORE TEAM. 2017. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.

SAATCHI, S. et al. Mapping landscape scale variations of forest structure, biomass, and productivity in Amazonia. **Biogeosciences Discussions**, Katlenberg-Lindau, v.6, p.5461–5505, 2009. <https://doi.org/10.5194/bgd-6-5461-2009>.

SAMPAIO, E.V., SILVA, G.C. Biomass equations for Brazilian semiarid caatinga plants. **Acta Botanica Brasílica**. Porto Alegre-RS, v.19, n.4, p.935–943, 2005.<http://dx.doi.org/10.1590/S0102-33062005000400028>.

SILVA, C.A., KLAUBERG, C., HUDAOK, A.T. Mapping aboveground carbon stocks using LiDAR data in Eucalyptus spp. plantations in the state of São Paulo, Brazil. **Scientia Forestalis**, Piracicaba-SP, v. 42, n. 104, p. 591-604, 2014. Disponível em:<https://www.ipef.br/publicacoes/scientia/nr104/cap13.pdf>. Acesso em: 17 mar. 2018.

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

SILVA, C., et al. Impacts of Airborne LiDAR Pulse Density on Estimating Biomass Stocks and Changes in a Selectively Logged Tropical Forest. **Remote Sensing**, Basel, v.9, n.10, p.1-19, 2017. <https://doi.org/10.3390/rs9101068>.

SOMOGYI, Z. et al. Indirect methods of large-scale forest biomass estimation. **European Journal of Forest Research**, Heidelberg, v.126, n.2, p.197–207, 2007. <https://doi.org/10.1007/s10342-006-0125-7>.

TAKAHASHI, T. et al. Stand volume estimation by combining low laser-sampling density LiDAR data with QuickBird panchromatic imagery in closed-canopy Japanese cedar (*Cryptomeria japonica*) plantations. **Journal International Journal of Remote Sensing**, London, v.31, n.5, p.1281–1301, 2010. <https://doi.org/10.1080/01431160903380623>.

THOMAS, V. et al. Mapping stand-level forest biophysical variables for a mixedwood boreal forest using LiDAR: an examination of scanning density. **Canadian Journal of Forest Research**, Ottawa, v.36, p.34–47, 2006. <https://doi.org/10.1139/x05-230>.

APÊNDICES

APÊNDICE 1:LISTA DAS ESPECIES POR ÁREA

Tabela 1: Lista das espécies arbustiva-arbóreas da área Transposição e número de fustes, Floresta, PE.

<u>Espécie</u>	<u>Número de Fuste</u>
<i>Anadenanthera colubrina</i> var. <i>cebil</i> (Griseb.) Altschul	103
<i>Aspidosperma pyrifolium</i> Mart.	467
<i>Bauhinia cheilantha</i> (Bong.) Steud.	138
<i>Cnidoscolus bahianus</i> (Ule) Pamorto & K.Hoffm.	8
<i>Cnidoscolus quercifolius</i> Pohl	147
<i>Combretum glaucocarpum</i> Mart.	13
<i>Commiphora leptophloeos</i> (Mart.) J.B.Gillett	31
<i>Croton heliotropiifolius</i> Kunth	103
<i>Cynophalla flemortouosa</i> (L.) J.Presl	5
<i>Erythrostemon calycina</i> (Benth.) L.P.Queiroz	4
<i>Jatropha mollissima</i> (Pohl) Baill.	48
<i>Libidibia ferrea</i> (Mart. Tul.) L.P.Queiroz	4
<i>Manihot carthaginensis</i> subsp. <i>glaziovii</i> (Müll.Arg.) Allem	26
<i>Mimosa ophthalmocentra</i> Mart. ex Benth.	404
<i>Mimosa tenuiflora</i> (Willd.) Poir.	51
<i>Myracrodruon urundeuva</i> Allemão	159
<i>Neocalyptrocalyx longifolium</i> (Pohl) Baill.	3
<i>Piptadenia stipulacea</i> (Benth.) Ducke	58
<i>Poincianella bracteosa</i> (Tul.) L.P.Queiroz	2764
<i>Sapium glandulosum</i> (L.) Morong	13
<i>Schinopsis brasiliensis</i> Engl.	19
<i>Senna macranthera</i> (DC. ex Collad.) H.S.Irwin & Barneby	1
<i>Spondias tuberosa</i> Arruda	7
Total Geral	4576

Tabela 2: Lista das espécies arbustiva-arbóreas da área Correntão e número de fustes, Floresta, PE.

Espécies	Número de fustes
<i>Anadenanthera colubrina</i> var. <i>cebil</i> (Griseb.) Altschul	6
<i>Aspidosperma pyrifolium</i> Mart.	45
<i>Bauhinia cheilanta</i> (Bong). Steud.	3
<i>Cnidoscolus bahianus</i> (Ule) Pax & L. Hoffm.	5
<i>Cnidoscolus phyllacanthus</i> (Müll. Arg.) Pax & L. Hoffm.	104
<i>Commiphora leptophloeos</i> (Mart.) J.B. Gillett	7
<i>Cordia leucocephala</i> Moric.	1
<i>Croton blanchetianus</i> Baill.	107
<i>Croton rhamnifolius</i> H.B.K.	17
<i>Jatropha mollissima</i> Muell. Arg.	57
<i>Manihot glaziovii</i> Muell. Arg.	2
<i>Mimosa ophthalmocentra</i> Mart. ex Benth.	356
<i>Mimosa tenuiflora</i> (Willd.) Poir.	24
<i>Myracrodum urundeuva</i> . (Engl.) Fr. All.	53
<i>Piptadenia stipulacea</i> (Benth.) Ducke	10
<i>Pityrocarpa moniliformis</i> (Benth.) Luckow & Jobson	213
<i>Poincianella bracteosa</i> (Tul.) L.P.Queiroz	1821
<i>Schinopsis brasiliensis</i> Engl.	14
<i>Senna macranthera</i>	8
<i>Sideroxylon obtusifolium</i> (Roem. & Schult.) T.D. Penn.	3
<i>Thiloa glaucocarpa</i> (Mart.) Eichl	47
Total Geral	2903

APÊNDICE 2: VALORES DESCRIPTIVOS POR ÁREA

Tabela 3: Valores da média da altura e diâmetro à 1,30 m do solo (DAP), número de indivíduos e de fustes na área da Transposição, Floresta, PE.

Parcela	Altura	DAP	Número de indivíduos	Número de fustes
1	3,3	3,0	89	187
2	4,1	3,8	43	128
3	4,2	4,2	62	93
4	4,1	3,5	30	92
5	3,4	3,1	61	198
6	5,5	5,0	67	115
7	3,9	3,9	40	76
8	4,4	3,6	42	78
9	4,4	4,1	39	130
10	3,8	4,3	23	74
11	3,3	4,1	38	128
12	3,3	4,0	25	105
13	3,2	3,1	70	180
14	3,3	3,4	24	102
15	3,6	4,2	55	138
16	4,2	5,3	34	90
17	3,9	3,5	34	91
18	4,1	3,4	20	91
19	3,9	3,3	41	156
20	3,7	5,2	25	67
21	3,6	4,4	44	76
22	3,5	3,7	47	134
23	3,9	3,4	53	140
24	3,7	3,3	16	33
25	3,8	3,8	38	84
26	4,8	4,1	66	106
27	3,7	4,4	52	108
28	4,2	3,8	41	78
29	3,4	4,4	33	102
30	2,8	3,2	32	77
31	2,8	3,5	53	163
32	3,1	3,2	41	193
33	3,9	5,0	44	88
34	3,6	4,6	32	93
35	3,0	2,9	51	191
36	3,8	4,5	44	131
37	3,6	7,1	35	66
38	3,7	4,8	41	136
39	3,4	3,3	55	119
40	2,8	3,6	48	139
TOTAL			1728	4576

Tabela 4: Valores da média da altura e diâmetro à 1,30 m do solo (DAP), número de indivíduos e de fuste na área da Correntão, Floresta, PE.

Parcela	Altura média	DAP médio	Número de individuos	Número de Fustes
1	4,1	9,7	115	174
2	3,5	9,8	65	144
3	3,8	10,5	55	78
4	3,2	9,1	43	96
5	3,8	10,8	48	82
6	3,7	10,7	37	132
7	3,4	12,3	30	56
8	3,9	11,5	11	98
9	3,4	11,7	50	88
10	4,1	11,2	14	114
11	4,0	12,1	53	86
12	5,4	21,3	4	14
13	3,7	13,2	12	27
14	4,3	13,5	5	31
15	4,1	18,2	2	3
16	4,0	9,8	28	106
17	4,5	12,4	39	120
18	4,2	11,7	17	75
19	3,9	11,7	31	61
20	4,6	11,3	16	63
21	4,6	11,3	37	95
22	3,6	13,3	4	15
23	5,1	10,6	50	113
24	3,9	13,5	5	31
25	4,0	12,5	5	34
26	3,5	10,0	28	128
27	3,3	10,3	3	6
28	3,8	12,0	10	35
29	4,4	15,0	8	32
30	4,0	12,4	22	77
31	4,9	14,3	19	101
32	4,6	17,8	9	36
33	4,8	16,5	8	20
34	3,3	12,2	3	16
35	4,8	20,2	2	16
36	3,8	16,0	6	21
37	3,6	9,7	62	295
38	3,6	11,5	28	105
39	3,9	14,2	7	37
40	3,6	15,3	5	42
TOTAL			996	2903

APÊNDICE 3: COMANDOS NO FUSION

Área Correntão

OLIVEIRA, C. P.

```
:: # Engenheira Florestal e Mestre
:: # Doutoranda pela UFRPE
:: # Pós Graduação em Ciência Florestal
:: # Recife, Pernambuco - BR
:: # cinthia.florestal@gmail.com
:: # cinthia
:: # Skype:
:: #-----#
```

```
::
#*****#
*****#
:: #-----Processamento da nuvem de pontos LiDAR - Área Correntão -----
#
```

```
:: #----- FUSION/LDV -----#
::
```

```
#*****#
*****#
:: Obs: Ctrl+Q para ativar a linha de comando e F5 para rodar
```

```
:: #-----#
:: # A) ##### Diretórios #####
:: #-----#
```

```
:: Processamento
set
PROD_DIR=C:\LIDAR_CAAATINGA\04_PROCESSAMENTO\4.2_FLORESTA_CORRENT
cd %PROD_DIR%
```

```
:: Nuvem de pontos LiDAR
set
LAS_DIR=C:\LIDAR_CAATINGA\02_DADOS\FLORESTA_CORRENT\01_NUVEM_LAS
```

```
:: Nome do projeto
set PROJ=LIDAR_CORRENT
```

```
:: Shapefile parcelas
set
SHP=C:\LIDAR_CAATINGA\02_DADOS\FLORESTA_CORRENT\03_SHP_PARCELAS\pa
rcelas_corrent.shp
```

```
:: #-----#
```

```

:: # B) ##### Processamento #####
:: #-----#
:: 0) # Catalog- LiDAR Overview: Produces a set of descriptive reports describing several
    important characteristics of LIDAR data sets
:: 0) # Catalog- Resumo dos dados LiDAR: Produz um relatório descritivo de diversas
    características importantes do conjunto de dados LiDAR
mkDir 00_catalog
C:\FUSION\catalog /density:1,1,2 %LAS_DIR%\*.las %PROD_DIR%\00_catalog\%PROJ%

:: 1) # GroundFilter: GroundFilter is designed to filter a cloud of LIDAR returns to identify
    those returns that lie on the probable ground surface (bare-earth points)
:: 1) # GroundFilter: é utilizado para filtrar da nuvem de pontos LIDAR os retornos que se
    encontram na superfície do solo (pontos na superfície do solo)
mkDir 01_groundfilter
C:\FUSION\groundfilter      /smooth:8      %PROD_DIR%\01_groundfilter\%PROJ%_solo.las
5 %LAS_DIR%\*.las

:: 2) # Digital terrain model (DTM): Gridded surface model using collections of random points.
:: 2) # Modelo Digital de Terreno (MDT): Criar o MDT contruido através da interpolação dos
    pontos aleatórios da etapa 2
mkDir 02_dtm
C:\FUSION\GridSurfaceCreate %PROD_DIR%\02_dtm\%PROJ%_dtm.dtm 1 M M 1 24 0
0 %PROD_DIR%\01_groundfilter\%PROJ%_solo.las
C:\FUSION\dtm2ascii %PROD_DIR%\02_dtm\%PROJ%_dtm.dtm

:: 3) # Digital surface Model (DSM): Creates a canopy surface model using a LIDAR point cloud
:: 3) # Modelo Digital de Superficie (MDS): Criar o MDS contruido através da interpolação dos
    pontos LIDAR dos primeiros retornos
mkDir 03_dsm
C:\FUSION\canopymodel %PROD_DIR%\03_dsm\%PROJ%_dsm.dtm 1 M M 1 24 0
0 %LAS_DIR%\*.las
C:\FUSION\dtm2ascii %PROD_DIR%\03_dsm\%PROJ%_dsm.dtm

:: 4) # Normalization of LiDAR data: Creates sub-samples of LIDAR data for various analysis
    tasks. However, this case it is used to normalize of LiDAR data.
:: 4) # Normalização dos dados LIDAR: Criar sub-amostras de dados LIDAR para várias tarefas
    de análise
mkDir 04_LASheight
C:\FUSION\clipdata      /dtm:%PROD_DIR%\02_dtm\%PROJ%_dtm.dtm      /height      /zmin:0
/zmax:80      %LAS_DIR%\*.las      %PROD_DIR%\04_LASheight\%PROJ%_normalizado.las
613489.92 9053359.96 616876.50 9055626.81

REM :: 5) # Canopy Height Model (CHM): Creates a canopy height model using a LIDAR point
    cloud
:: 5) # Modelo Digital de altura de copas: cria o modelo digital de altura do dossel usando a
    nuvem de pontos LIDAR

```

```

mkDir 05_chm
C:\FUSION\canopymodel %PROD_DIR%\05_chm%\%PROJ%_chm.dtm 1 M M 1 24 0
0 %PROD_DIR%\04_LASheight%\%PROJ%_normalizado.las
C:\FUSION\dtm2ascii %PROD_DIR%\05_chm%\%PROJ%_chm.dtm

:: 6) # PolyclipDATA: clips point data (LAS) using polygons stored in ESRI shapefiles - Use it to
clip the sample plots
REM :: 6) # PolyclipDATA: recorta os pontos (LAS) usando os poligonos em arquivo formato
ESRI - Utilizado para recortar os dados dentro das parcelas
mkDir 06_polyclipdata
C:\FUSION\PolyClipData /multifile
/shape:3,* %SHP% %PROD_DIR%\06_polyclipdata%\%PROJ%_.las %PROD_DIR%\04_LASheight%\%PROJ%_normalizado.las

REM :: 7) # CloudMetrics: Computes a variety of statistical parameters describing a LIDAR data
set
REM :: 7) # CloudMetrics:Calcula varios parâmetros estatísticos que descrevem os dados LIDAR
mkDir 07_cloudmetrics
C:\FUSION\CloudMetrics /id /minht:1.30
/above:1.30 %PROD_DIR%\06_polyclipdata\*.las %PROD_DIR%\07_cloudmetrics%\%PROJ%_
metrics.csv

REM :: 8) GridMetrics computes a series of descriptive statistics for a LIDAR data se.
REM :: 8) GridMetrics calcula varias estatísticas descritivas para uma base de dados LIDAR
mkDir 08_gridmetrics
C:\FUSION\GridMetrics /minht:1.30 /noground 1.30
5 %PROD_DIR%\08_gridmetrics%\%PROJ%_grid.csv %PROD_DIR%\04_LASheight\*.las

REM :: CSV para ASCII-> HMAX: Altura maxima:
C:\FUSION\csv2grid %PROD_DIR%\08_gridmetrics%\%PROJ%_grid_all_returns_elevation_stat
s.csv 7 %PROD_DIR%\08_gridmetrics%\%PROJ%_HMAX_FC.asc

```

Área Transposição
 # OLIVEIRA, C. P.
 :: # Engenheira Florestal e Mestre
 :: # Doutoranda pela UFRPE
 :: # Pós Graduação em Ciência Florestal
 :: # Recife, Perbambuco - BR
 :: # cinthia.florestal@gmail.com
 :: # cinthia
 :: # Skype:
 :: -----#

```

::
#*****#
*****#

```

```

:: -----Processamento da nuvem de pontos LiDAR - Área Transposição -----
---#
:: ----- FUSION/LDV -----#
:: :
#*****#
*****#
:: Obs: Ctrl+Q para ativar a linha de comando e F5 para rodar

:: #
:: # A) ##### Diretórios #####
:: #

:: Processamento
set PROD_DIR=C:\LIDAR_CAATINGA\04_PROCESSAMENTO\4.1_FLORESTA_TRANSPO
cd %PROD_DIR%

:: Nuvem de pontos LiDAR
set
LAS_DIR=C:\LIDAR_CAATINGA\02_DADOS\FLORESTA_TRANSPO\01_NUVEM_LAS

:: Nome do projeto
set PROJ=LiDAR_TRANSPO

:: Shapefile parcelas
set
SHP=C:\LIDAR_CAATINGA\02_DADOS\FLORESTA_TRANSPO\03_SHP_PARCELAS\parc
elas_transposica.shp

:: #
:: # B) ##### Processamento #####
:: #

:: 0) # Catalog- LiDAR Overview: Produces a set of descriptive reports describing several
important characteristics of LIDAR data sets
:: 0) # Catalog- Resumo dos dados LiDAR: Produz um relatório descritivo de diversas
características importantes do conjunto de dados LiDAR
mkDir 00_catalog
C:\FUSION\catalog /density:1,1,2 %LAS_DIR%\*.las %PROD_DIR%\00_catalog%\%PROJ%


:: 1) # GroundFilter: GroundFilter is designed to filter a cloud of LIDAR returns to identify
those returns that lie on the probable ground surface (bare-earth points)
:: 1) # GroundFilter: é utilizado para filtrar da nuvem de pontos LIDAR os retornos que se
encontram na superfície do solo (pontos na superfície do solo)
mkDir 01_groundfilter
C:\FUSION\groundfilter      /smooth:8      %PROD_DIR%\01_groundfilter%\%PROJ%_solo.las
5 %LAS_DIR%\*.las

```

```

:: 2) # Digital terrain model (DTM): Gridded surface model using collections of random points.
:: 2) # Modelo Digital de Terreno (MDT): Criar o MDT contruido através da interpolação dos
    pontos aleatórios da etapa 2
mkDir 02_dtm
C:\FUSION\GridSurfaceCreate %PROD_DIR%\02_dtm%\%PROJ%_dtm.dtm 1 M M 1 24 0
0 %PROD_DIR%\01_groundfilter%\%PROJ%_solo.las
C:\FUSION\dtm2ascii %PROD_DIR%\02_dtm%\%PROJ%_dtm.dtm

:: 3) # Digital surface Model (DSM): Creates a canopy surface model using a LIDAR point cloud
:: 3) # Modelo Digital de Superficie (MDS): Criar o MDS contruido através da interpolação dos
    pontos LIDAR dos primeiros retornos
mkDir 03_dsm
C:\FUSION\canopymodel %PROD_DIR%\03_dsm%\%PROJ%_dsm.dtm 1 M M 1 24 0
0 %LAS_DIR%\*.las
C:\FUSION\dtm2ascii %PROD_DIR%\03_dsm%\%PROJ%_dsm.dtm

:: 4) # Normalization of LiDAR data: Creates sub-samples of LIDAR data for various analysis
    tasks. However, this case it is used to normalize of LiDAR data.
:: 4) # Normalização dos dados LIDAR: Criar sub-amostras de dados LIDAR para várias tarefas
    de análise
mkDir 04_LASheight
C:\FUSION\clipdata /dtm:%PROD_DIR%\02_dtm%\%PROJ%_dtm.dtm /height /zmin:0
/zmax:80 %LAS_DIR%\*.las %PROD_DIR%\04_LASheight%\%PROJ%_normalizado.las
610083.00 9057999.07 613475.64 9060282.36

REM :: 5) # Canopy Height Model (CHM): Creates a canopy height model using a LIDAR point
    cloud
:: 5) # Modelo Digital de altura de copas: cria o modelo digital de altura do dossel usando a
    nuvem de pontos LIDAR
mkDir 05_chm
C:\FUSION\canopymodel %PROD_DIR%\05_chm%\%PROJ%_chm.dtm 1 M M 1 24 0
0 %PROD_DIR%\04_LASheight%\%PROJ%_normalizado.las
C:\FUSION\dtm2ascii %PROD_DIR%\05_chm%\%PROJ%_chm.dtm

:: 6) # PolyclipDATA: clips point data (LAS) using polygons stored in ESRI shapefiles - Use it to
    clip the sample plots
REM :: 6) # PolyclipDATA: recorta os pontos (LAS) usando os poligonos em arquivo formato
    ESRI - Utilizado para recortar os dados dentro das parcelas
mkDir 06_polyclipdata
C:\FUSION\PolyClipData
/multifile
/shape:3,* %SHP% %PROD_DIR%\06_polyclipdata%\%PROJ%_.las %PROD_DIR%\04_LASheight%\%PROJ%_normalizado.las

REM :: 7) # CloudMetrics: Computes a variety of statistical parameters describing a LIDAR data
    set
REM :: 7) # CloudMetrics:Calcula varios parâmetros estatísticos que descrevem os dados LIDAR

```

```
mkDir 07_cloudmetrics  
C:\FUSION\CloudMetrics /id /minht:1.30  
/above:1.30 %PROD_DIR%\06_polyclipdata\*.las %PROD_DIR%\07_cloudmetrics%\%PROJ%  
metrics.csv
```

REM :: 8) GridMetrics computes a series of descriptive statistics for a LIDAR data se.
REM :: 8) GridMetrics calcula varias estatísticas descritivas para uma base de dados LIDAR
mkDir 08_gridmetrics

```
C:\FUSION\GridMetrics /minht:1.30 /noground 1.30  
5 %PROD_DIR%\08_gridmetrics%\%PROJ%\grid.csv %PROD_DIR%\04_LASheight\*.las
```

REM :: CSV para ASCII-> HMAX: Altura maxima:
C:\FUSION\csv2grid %PROD_DIR%\08_gridmetrics%\%PROJ%\grid_all_returns_elevation_stat
s.csv 7 %PROD_DIR%\08_gridmetrics%\%PROJ%\HMAX_FC.asc

APÊNDICE 4:TABELAS DOS MODELOS TESTADOS NAS ÁREAS DE ESTUDO PELO SOFTWARE RSTUDIO.

Tabela 5: Valores da Regressão PCA na área da Transposição, Floresta, PE.

Coeficientes	Estimativa	Erro padrão	t value	Pr(> t)
(Intercept)	9	10.487	9	4,70E-09***
Dim.1	0,6072	0,2949	2	0,05*
Dim.4	1	0,8238	2	0,0863*
R ² aj	rse	rmse	rmse%	AIC
0,1723	5,4530	5,9925	63,2683	179,2742

R²aj= Coeficiente de determinação ajustado; rse= viés do modelo; rmse= Raiz quadrada do erro médio; rmse% = Raiz quadrada do erro médio em porcentagem; AIC= Critério de Informação de Akaike.

Tabela 6:Valores da Regressão PCA na área da Correntão, Floresta, PE.

Coeficientes	Estimativa	Erro padrão	t value	Pr(> t)
(Intercept)	30	5	6	2.58e-06***
Dim.3	-6	3	-2	0.0598*
R ² aj	rse	rmse	rmse%	AIC
0,09621	26,6400	28,4540	97,3035	267,1950

R²aj= Coeficiente de determinação ajustado; rse= viés do modelo; rmse= Raiz quadrada do erro médio; rmse% = Raiz quadrada do erro médio em porcentagem; AIC= Critério de Informação de Akaike.

Tabela 7: Valores da Regressão Múltipla na área da Transposição, Floresta, PE.

Coeficientes	Estimativa	Erro padrão	t value	Pr(> t)
(Intercept)	-87	64	-1	0,1902
Elev.minimum	-33	20	-2	0,1161
Elev.maximum	5	8	0,673	0,5097
Elev.mean	195	103	2	0,0756*
Elev.mode	4	2	2	0,136
Elev.stddev	-93	85	-1	0,2897
Elev.CV	207	128	2	0,1238
Elev.skewness	14	12	1	0,2783
Elev.kurtosis	-2	2	-0,902	0,3799
Elev.MAD.median	24	38	0,638	0,5321
Elev.P01	30	21	1	0,1684
Elev.P10	-26	20	-1	0,2227
Elev.P20	-65	25	-3	0,0189*
Elev.P25	49	43	1	0,2728
Elev.P30	-27	36	-0,757	0,4592
Elev.P50	-44	30	-1	0,1573
Elev.P60	-21	22	-0,987	0,3377
Elev.P75	-11	22	-0,531	0,6026
Elev.P80	2	16	0,143	0,8878
Elev.P90	-28	14	-2	0,0606*
Elev.P95	-16	17	-0,908	0,3763
Canopy.relief.ratio	98	84	1	0,2614
Percentage.all.returns.above.1.30	0,02401	0,16744	0,143	0,8876
R ² aj	rse	Rmse	rmse%	AIC
0,1924	4,8910	3,1886	34,1881	254,2811

R²aj= Coeficiente de determinação ajustado; rse= viés do modelo; rmse= Raiz quadrada do erro médio; rmse% = Raiz quadrada do erro médio em porcentagem; AIC= Critério de Informação de Akaike.

Tabela 8: Valores da Regressão Múltipla na área da Correntão, Floresta, PE.

Coeficientes	Estimativa	Erro padrão	t value	Pr(> t)
(Intercept)	-342	334	-1	0,32
Elev.minimum	0,932	95	0,01	0,9923
Elev.maximum	124	56	2	0,0424*
Elev.mean	-298	540	-0,552	0,5885
Elev.mode	2	15	0,119	0,907
Elev.stddev	-14	510	-0,028	0,978
Elev.CV	712	1.295	0,55	0,5893
Elev.skewness	-8	51	-0,156	0,8777
Elev.kurtosis	-36	34	-1	0,3014
Elev.MAD.median	103	138	0,749	0,4642
Elev.P01	115	86	1	0,2009
Elev.P10	80	87	0,915	0,3729
Elev.P20	55	93	0,588	0,5642
Elev.P25	40	175	0,228	0,8222
Elev.P30	90	201	0,448	0,6598
Elev.P50	21	98	0,211	0,8355
Elev.P60	5	103	0,049	0,9613
Elev.P75	-130	142	-0,915	0,3728
Elev.P80	-34	125	-0,271	0,7897
Elev.P90	57	60	0,955	0,3527
Elev.P95	-53	74	-0,719	0,482
Canopy.relief.ratio	519	403	1	0,2149
Percentage.all.returns.above.1.30	-0,1031	0,4157	-0,248	0,8072
R ² aj	rse	Rmse	rmse%	AIC
0,2996	20,8800	13,6103	54,5744	370,3812

R²aj= Coeficiente de determinação ajustado; rse= viés do modelo; rmse= Raiz quadrada do erro médio; rmse% = Raiz quadrada do erro médio em porcentagem; AIC= Critério de Informação de Akaike.

Tabela 9: Regressão *Stepwise* na área da Transposição, Floresta, PE.

Coeficientes	Estimativa	Erro padrão	t value	Pr(> t)
(Intercept)	-21	22	-0,938	0,35608
Elev.minimum	-36	12	-3	0,00697**
Elev.mean	120	34	4	0,00149**
Elev.mode	5	2	3	0,00826**
Elev.stddev	-64	34	-2	0,06877*
Elev.CV	101	69	1	0,15547
Elev.P01	28	14	2	0,05412*
Elev.P10	-18	9	-2	0,07103*
Elev.P20	-29	10	-3	0,00798**
Elev.P50	-45	15	-3	0,00699**
Elev.P90	-18	8	-2	0,04165*
R ² aj	rse	rmse	rmse%	AIC
0,4239	4,1310	3,5172	37,7117	238,1286

R²aj= Coeficiente de determinação ajustado; rse= viés do modelo; rmse= Raiz quadrada do erro médio; rmse% = Raiz quadrada do erro médio em porcentagem; AIC= Critério de Informação de Akaike.

Tabela 10: Regressão *Stepwise* na área da Correntão, Floresta, PE.

Coeficientes	Estimativa	Erro padrão	t value	Pr(> t)
(Intercept)	-269,86	106,15	-3	0,01641*
Elev.maximum	145,44	22,91	6	5,30E-07***
Elev.mean	-402,19	132,76	-3	0,005**
Elev.CV	440,13	234,73	2	0,07055*
Elev.kurtosis	-53,26	18,44	-3	0,00712**
Elev.P01	88,49	32,11	3	0,00987**
Elev.P10	93,09	43,6	2	0,04102*
Elev.P30	165,73	64,74	3	0,01575*
Elev.P75	-67,6	50,36	-1	0,18958
Canopy.relief.ratio	673,35	147,43	5	7,88E-05***
R ² aj	rse	rmse	rmse%	AIC
0,533	17,0500	14,7640	59,2005	350,8903

R²aj= Coeficiente de determinação ajustado; rse= viés do modelo; rmse= Raiz quadrada do erro médio; rmse% = Raiz quadrada do erro médio em porcentagem; AIC= Critério de Informação de Akaike.