



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

sid.inpe.br/mtc-m21c/2018/08.21.00.13-TDI

**ESTIMATIVA DE BIOMASSA, EM ÁREAS
DEGRADADAS E NÃO DEGRADADAS, POR MEIO DE
ISOLAMENTO DE ÁRVORES COM DADOS LIDAR**

Anderson Jorge

Dissertação de Mestrado do
Curso de Pós-Graduação
em Sensoriamento Remoto,
orientada pelo Dr. Yosio Edemir
Shimabukuro, aprovada em 22 de
agosto de 2018.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3RM3KFS>>

INPE
São José dos Campos
2018

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE
Gabinete do Diretor (GBDIR)
Serviço de Informação e Documentação (SESID)
CEP 12.227-010
São José dos Campos - SP - Brasil
Tel.:(012) 3208-6923/7348
E-mail: pubtc@inpe.br

**COMISSÃO DO CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO
DA PRODUÇÃO INTELECTUAL DO INPE (DE/DIR-544):****Presidente:**

Dr. Marley Cavalcante de Lima Moscati - Centro de Previsão de Tempo e Estudos
Climáticos (CGCPT)

Membros:

Dra. Carina Barros Mello - Coordenação de Laboratórios Associados (COCTE)

Dr. Alisson Dal Lago - Coordenação-Geral de Ciências Espaciais e Atmosféricas
(CGCEA)

Dr. Evandro Albiach Branco - Centro de Ciência do Sistema Terrestre (COCST)

Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia e Tecnologia
Espacial (CGETE)

Dr. Hermann Johann Heinrich Kux - Coordenação-Geral de Observação da Terra
(CGOBT)

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação - (CPG)

Silvia Castro Marcelino - Serviço de Informação e Documentação (SESID)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon

Clayton Martins Pereira - Serviço de Informação e Documentação (SESID)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Simone Angélica Del Ducca Barbedo - Serviço de Informação e Documentação
(SESID)

André Luis Dias Fernandes - Serviço de Informação e Documentação (SESID)

EDITORAÇÃO ELETRÔNICA:

Marcelo de Castro Pazos - Serviço de Informação e Documentação (SESID)

Murilo Luiz Silva Gino - Serviço de Informação e Documentação (SESID)



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

sid.inpe.br/mtc-m21c/2018/08.21.00.13-TDI

**ESTIMATIVA DE BIOMASSA, EM ÁREAS
DEGRADADAS E NÃO DEGRADADAS, POR MEIO DE
ISOLAMENTO DE ÁRVORES COM DADOS LIDAR**

Anderson Jorge

Dissertação de Mestrado do
Curso de Pós-Graduação
em Sensoriamento Remoto,
orientada pelo Dr. Yosio Edemir
Shimabukuro, aprovada em 22 de
agosto de 2018.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3RM3KFS>>

INPE
São José dos Campos
2018

Dados Internacionais de Catalogação na Publicação (CIP)

Jorge, Anderson.

J768e Estimativa de biomassa, em áreas degradadas e não degradadas, por meio de isolamento de árvores com dados LiDAR / Anderson Jorge. – São José dos Campos : INPE, 2018. xvii + 77 p. ; (sid.inpe.br/mtc-m21c/2018/08.21.00.13-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2018.

Orientador : Dr. Yosio Edemir Shimabukuro.

1. Sensoriamento Remoto. 2. LiDAR. 3. Detecção de árvores individuais. 4. Biomassa viva acima do solo. I.Título.

CDU 630*54:528.8



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

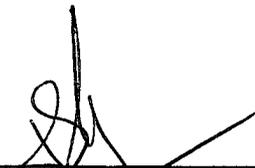
This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

Aluno (a): **Anderson Jorge**

Título: "ESTIMATIVA DE BIOMASSA, EM ÁREAS DEGRADADAS E NÃO DEGRADADAS, POR MEIO DE ISOLAMENTO DE ÁRVORES COM DADOS LIDAR"

Aprovado (a) pela Banca Examinadora
em cumprimento ao requisito exigido para
obtenção do Título de **Mestre** em
Sensoriamento Remoto

Dr. **Thales Sehn Körting**



Presidente / INPE / São José dos Campos - SP
 Participação por Vídeo - Conferência
 Aprovado **Reprovado**

Dr. **Yosio Edemir Shimabukuro**



Orientador(a) / INPE / São José dos Campos - SP
 Participação por Vídeo - Conferência
 Aprovado **Reprovado**

Dr. **Vagner Alex Pesck**



Convidado(a) / UNICENTRO / Itaiti - PR
 Participação por Vídeo - Conferência
 Aprovado **Reprovado**

Este trabalho foi aprovado por:

maioria simples

unanimidade

São José dos Campos, 22 de agosto de 2018

“Se você só fizer o que sabe, nunca será nada além do que já é.”

Mestre Shifu

RESUMO

Á

OEA ~ aae 8aeA^Á • [Á Á& à^|c |aeAae^||ae^ ^Á & ||^Á [Á • caa| Á [ÁT ae ÁÖ| •• [Á Á
 T VEA &ae q } aeA^ |áaeA^Á q { ae • aeÁ [|^ • caEÁae^|ae á [Á aeaeaeae [• • |ae^ ae^ • Á
 ~ ^Á& } d á ~ ^ Á } aeaeÁ Áae { ^ } d ÁaeÁc { } |^ ae |ae } aeÁ : |aeÁ^cá [Áae Á^Áae Á
 ^ • c aeÁUÁ |á & q aeÁ • Á^ • [] • |c |Á |Á | Á^Á Á • c aeÁ Á ÁCO₂EUÁaeà } [Á { Á
 | |^ • cae Á • Á • d & caa [Á |á & q ae^ ^ } eÁ { Áae { ae • aeÁ Á [á^Á^Ác |aeá caa [Á { Á
 ~ ae caaA^ • Á áae^ |^ } eÁ á^ |^ } á^ } á [Á aeÁ q e } • caaA^ Á { ae } ae á^Á áae
 á^ |aeaeE [Á ~ ^Áae | |^ • cae { ae EÁÁ • cae aeaeA^ • aeae { ae • aeÁ { ~ { ^ } eÁ Á
 ^aeÁ [|Á c^ } o |á Á | |^ • caeÁ^Á ae&|ae Á ~ ^Ác { Á^ • Á [á^ | |^ • cae } [|ae • Á
] aeae [Á ae ae @ Á aeÁ] ae&|ae { ^áaeÁ Uaeae ae } aeÁ^ • cae |á aeae [Á] ae
 & { } |^ caaA^Á^Á | |^ • cae Ác [] aeae Á ae caeÁ ae • cae aeaeA^Á q { ae • aeÁ • eÁ
 d aeae @ Á c^Á& { [Á á^ cae EÁ • cae aeÁae q { ae • aeÁaeaeÁ aeÁ Á [| EÁ cae ae á [Á
 aeÁc & } aeaeA^Áae [|ae ^ } d ÁaeÁ& | aeÁaeÁ |c | |^ • Á { Á } c^ } • ÁaeÁ [] d • ÁLight
 Detection and Ranging . ÁŠÖÜEÁ | d ae • [| caa [• EUaeae • [EÁ ~ ae [Á | ae Áae
 |^* ae [Á | | |^ • cae Á Á • caa [Á [ÁT ae ÁÖ| •• [LÁ { aeA^* |aeaeaeÁ | Á [* [EÁ ae Á
 á^* |aeaeae Á [| Á& |c Á^Á^Ác | ÁÁ | d ae } e | Áae^* |aeaeaeÁ | ae Áae ae ae EÁÁ
 c & } aeaeA^Áae [• d ae ^ { Á cae aeae } ^ • cae Á | ae Á | aeÁaeÁ^c & e [ÁaeÁ |c | |^ • Á
 q áaeae ae Á Individual Tree DetectionÁÜÖDae ae • Á • ae [|ae [• Á^ÁÖae [] eÁ
 ÖEÁ DÁ ÁÁÁUaeaeÁ^ÁÖEÁ DÁ^ • eÁ |c | EÁ |ae Áae ae ae • Á • Á aeé ^ d [• ÁÁ
 á^ q ae • Áae ae @ • ÁaeÁ q^ |ÁaeÁEÁ Á Á aeae Áae ~ q | Á aeaeÁaeÁ ÁT [á^ | ÁaeÁ
 Öc |aeÁÁÖ|] aeÁ Canopy Height ModelÁ ÁÖPT DÁ ~ ^Á | ae ~ ae ae Á& { Áae [ÁaeÁ
 ae |aeÁÁÁÁÁ q^ |EUÁae^* | |ae [Á^ÁÖae [] eÁ ÖEÁ DÁae } caeÁÁaeae @ Á& { Á
] aeé ^ d [• Á cae ae [Á { Á^* ae [ÁaeÁ | |^ • caeÁc [] aeÁ EÁ^ • cae } ae áaeÁ |ae Á
 ~ cae ae [Á • Á] aeé ^ d [• Á] ae / ^ • EÁÖ 5 • Áae q ae ae Áae Á&] ae EÁ |ae Á^ cae ae Á
 { ..d ae Áae } c^ { ÁaeÁ [] d • Á | |^ • cae } ae ae ÁaeÁaeaeÁ |c | |^ EÁ • cae Á ..d ae Á
 ae |^ • cae } ae ae ÁaeÁ& ||^ |aeE [ÁaeÁUaeae •] Á } d Á • aeUaeaeÁ • cae EÁ |ae cae ae aeÁ
 • ^ |^ 8e [Áae Á ..d ae Á ^ } • Á& ||^ |ae } ae ae Á& { Áae á Áae ae^ • ÁEÁ ÁEÁ EÁÖ Á
 { ..d ae Á^ • cae eÁ |^ • cae } ae ae Áae | |^ • Áae & ^ } ae eÁÁU ae • caa [] aeae |^ áae |Á
 { [á^ | |^ • ÁaeÁae q { ae • aeÁaeaeÁ aeÁ Á [| ÁAbove Ground BiomassÁ ÁÖÖDÁ
 caeae á [ÁÁEÁ JÁEÁEÁ | EÁ^ q á [Á ~ ^Á Áae [ÁÁÁ] ae d Á | ae [Á | ae | |^ • cae Á
 [Áae [|ae [Á cae ae [Á ^ ^ } & ae Á [Á ~ & •• [ÁaeÁ • cae aeaeÁÁÖÖEÁ cae ae á [Á
 } ^ c^ } • ÁaeÁ [] d • Á cae ae Á | aeÁ^c & e [ÁaeÁ |c | |^ • Á q áaeae ae ÁÜÖDÁ

Á

Uaeae ae EÁÖ { ae • aeÁaeaeÁ aeÁ Á [| EÁ
 q áaeae ae EÁÖ { ae • aeÁaeaeÁ aeÁ Á [| EÁ

Á

LISTA DE FIGURAS

Figura 2.1 - Ciclo do CO ₂	8
Figura 2.2 - Mapa de corte seletivo no “arco do desmatamento”.	11
Figura 2.3 - Comparação de diferentes sensores em áreas de corte seletivo.	12
Figura 2.4 - Princípios e Componentes de Um Sistema LiDAR Aerotransportado.....	14
Figura 2.5 - Representação da nuvem de pontos e imagens LiDAR de uma parcela do Projeto Paisagens Sustentável (<i>Sustainable Landscape – SL</i>).	16
Figura 3.1 - Áreas de estudo.	21
Figura 3.2 – Modelo de alocação das parcelas.	24
Figura 3.3 - Coleta de ponto georreferenciado com o GPS.	26
Figura 3.4 - Mensuração de indivíduos dentro das parcelas.	27
Figura 3.5 – Área T.	28
Figura 3.6 - Áreas A, B e C.	29
Figura 3.7 – Fluxograma de trabalho.	30
Figura 3.8 – Demonstração de integração da linguagem R e o método FUSION.	31
Figura 3.9 - Densidade de pontos LiDAR nas parcelas mensuradas na área T.	32
Figura 3.10 - Densidade de pontos LiDAR nas parcelas mensuradas nas áreas A, B e C.	32
Figura 3.11 - Janela de suavização.....	34
Figura 4.1 - <i>Box plot</i> e distribuição das alturas das árvores presentes no transecto 2, da área T.	41
Figura 4.2 - Histograma da densidade de pontos em relação à altura da nuvem utilizada para demonstrar o tamanho de pixel do CHM.....	43
Figura 4.3 - CHMs não suavizados.	44
Figura 4.4 - CHMs não suavizados.	45
Figura 4.5 - Demonstração da suavização das bordas e propagação de valores nulos.....	46
Figura 4.6 - <i>Boxplot</i> das alturas encontradas no transecto 2 da área T.	47
Figura 4.7 - Comparação das bordas encontradas pelos algoritmos.	48
Figura 4.8 - Demonstração de isolamento de árvores no transecto 1 da área T.	49
Figura 4.9 - Demonstração do isolamento de árvores nas parcelas das áreas de FN.	50
Figura 4.10 - Histograma, correlação de Pearson e comparação entre valores observados e estimados para a altura das árvores em cada área e em cada algoritmo.....	51

Figura 4.11 - Correlação das alturas encontradas pelo algoritmo Dalponte (2018). Cada área está com uma coloração, em azul está a área A, em amarelo a B, em vermelho a C e em verde a T.....	53
Figura 4.12 - Correlação das alturas encontradas pelo algoritmo de Silva et al. (2017). Cada área está com uma coloração, em azul está a área A, em amarelo a B, em vermelho a C e em verde a T.....	54
Figura 4.13 – Representação da nuvem de pontos do isolamento de um isolamento de copa e o histograma da dispersão vertical.....	55
Figura 4.14 - Correlação das métricas das nuvens de pontos, recortadas por meio das copas isoladas.	56
Figura 4.15 - Correlação de Pearson das métricas selecionadas, utilizando o recorte da nuvem com o algoritmo de Dalponte (2018).	58
Figura 4.16 - Correlação de Pearson das métricas selecionadas, utilizando o recorte da nuvem com o algoritmo de Silva et al. (2017).	59
Figura 4.17 - Correlações das métricas utilizando as nuvens de pontos recortados pelo isolamento de copa pelo algoritmo de Dalponte (2018).....	60
Figura 4.18 - Correlações das métricas utilizando as nuvens de pontos recortados pelo isolamento de copa pelo algoritmo de Silva et al. (2017).	61
Figura 4.19 - Métricas e valores de $R^2_{ajustados}$ para área B, com isolamento de copa com o algoritmo de Dalponte (2018).	63
Figura 4.20 - Métricas e valores de $R^2_{ajustados}$ para todas as áreas, com isolamento de copa com o algoritmo de Dalponte (2018).	64
Figura 4.21 - Tabela com métricas e valores de $R^2_{ajustados}$ para todas as áreas, com isolamento de copa com o algoritmo de Silva et al. (2017).	65
Figura 4.22 - Gráficos de resíduos dos modelos gerados.....	66

LISTA DE TABELAS

Tabela 3.1 - Dados das Varreduras LiDAR.....	23
Tabela 3.2 - Parâmetros utilizados no algoritmo de Dalponte (2018).....	36
Tabela 4.1 - Tabela ANOVA, apresentando a soma dos quadrados, erro quadrático, valor F, p value e sua significância.	42
Tabela 4.2 - Tabela de comparação de árvores observadas em campo em comparação a copas encontradas pelos algoritmos na nuvem de pontos.	48
Tabela 4.3 - Valores de $R^2_{ajustados}$ e quantidade de métricas para o conjunto de métricas de cada algoritmo utilizado para isolamento de copas e limiares.	62

1 INTRODUÇÃO

As florestas tropicais estocam de 40% a 50% do carbono (C) florestal do mundo (WATSON et al., 2000; KINDERMANN et al., 2008). A principal fixação do C nas florestas é por meio da fotossíntese, com maior predominância em espécies arbóreas (NASCIMENTO; AURENCE, 2002). A respiração de plantas e queima de combustíveis fósseis ou vegetais são alguns dos fatores que proporcionam o aumento de C carbono na atmosfera. Este, interage com o oxigênio (O) e gera o dióxido de carbono (CO₂) que é o principal gás responsável pelo efeito estufa, o que ocasiona o aumento da temperatura na superfície terrestre (MARTINS et al., 2003). Este aumento influencia o ambiente e a vida na Terra quando interage com a radiação eletromagnética e armazena maior quantidade de energia, proporcionando ambientes ideais para a vida no planeta. Porém, estudos da Organização Mundial de Meteorologia (2016) sugerem que desde a revolução industrial, a temperatura média do planeta aumentou aproximadamente 1° C devido a intensificação do efeito estufa, causando mudanças significativas em nossos ecossistemas em um curto espaço de tempo. Este fato aflora uma condição ambiental negativa à estabilidade dos ecossistemas habitados pelos seres humanos.

As florestas são fixadoras de carbono em sua biomassa, um fator que desestabiliza esta fixação é a degradação florestal que atinge aproximadamente 100 milhões de ha por ano em todo nosso planeta (NABUURS et al., 2007). Na floresta amazônica brasileira, uma das regiões que apresenta maior taxa de degradação florestal se encontra no estado do Mato Grosso (MT) (DETER, 2015; ALVES et al., 2016).

Empoderando diretrizes para reduzir o aumento de CO₂ houveram e ainda há iniciativas tanto nacionais como internacionais, como por exemplo, o programa de Reduções de Emissões do Desmatamento e Degradação Florestal (*Reducing Emissions from Deforestation and Forest Degradation – REDD+*), desenvolvido pela Organização das Nações Unidas para diminuir a degradação florestal no planeta e mitigar a inserção de gases que intensificam o efeito estufa (*Food and Agriculture Organization of the United Nations – FAO*, 2010).

Este programa busca o gerenciamento sustentável, conservação e conhecimento de estoques de C presente em florestas, desenvolvido no âmbito da Convenção-Quadro das Nações Unidas sobre Mudança do Clima (UNFCCC) e recompensa financeiramente países em desenvolvimento por seus resultados (UNFCCC, 2011). Para monitoramento dos resultados de programas como REDD+ e dos gases do efeito estufa, uma etapa fundamental é o inventário da biomassa acima do solo (*Above Ground Biomass* - AGB em inglês) (ANDERSSON et al., 2009).

Na atual conjuntura técnico científica que paira sobre as certezas e incertezas do C em florestas, tem-se a convicção da necessidade de melhora na exatidão e precisão de inventários de biomassa florestal, onde é importante estratificar as amostras para diminuir o erro devido as variabilidades de sítios e de espécies que se estuda. Desse modo, a estratificação proporciona extrapolações mais confiáveis. A estratificação consiste em inventariar áreas ou elementos similares, onde as amostras são representadas por valores estatísticos de tendência central ou de dispersão das parcelas ou indivíduos dessas parcelas (FIGUEIREDO et al., 2014). Após realizado o inventário, a variável de interesse é extrapolada proporcionalmente para toda a área similar. Estas amostragens são necessárias pois é inviável analisar grandes áreas florestais mensurando cada indivíduo vegetal presente nelas. Neste escopo, nas últimas décadas, técnicas e produtos de Sensoriamento Remoto – SR emergiram proporcionando melhores análises em escalas regionais, nacionais e mundiais (PONZONI E SHIMABUKURO, 2010).

Além de imagens orbitais de alta resolução que possibilitam analisar a floresta em 2 dimensões, dados *Light Detection and Ranging* – LiDAR vem se destacando no setor florestal de forma incisiva para monitorar a floresta de forma tridimensional (d'OLIVEIRA et al., 2014). O produto resultante dessa tecnologia, é uma nuvem densa de pontos com coordenadas de dispersões horizontais e verticais de coordenadas geodésicas (GIONGO et al., 2010). As nuvens de pontos possibilitam identificar árvores em meio à floresta e analisar a composição vegetal em diferentes estratos, para extrair variáveis quantitativas e prever variáveis qualitativas do sítio analisado (ELLIS, 2016).

Utilizando a nuvem de pontos LiDAR juntamente com dados de campo, é possível gerar modelos matemáticos que, por meio de técnica de regressão, possibilitem estimar variáveis não mensuradas diretamente (FERRAZ et al., 2016). Um exemplo de variável não mesurada diretamente é a biomassa, ela é uma variável de difícil acesso, custosa para grandes áreas e apresenta relação com as métricas extraídas da nuvem de pontos LiDAR (FIGUEIREDO FILHO et al., 2014; MCGAUGHEY, 2015).

Em consonância com o exposto, este trabalho buscou gerir uma alternativa metodológica nas estimativas de biomassa de floresta tropical a partir de dados LiDAR, definindo a árvore como objeto de estudo. Dessa maneira, a hipótese do trabalho é que a estimativa de biomassa, a partir da individualização das árvores, é uma alternativa metodológica flexível e eficiente, uma vez que as extrapolações dos modelos gerados não seriam limitadas pelas dimensões das parcelas que são comumente realizadas.

1.1 Objetivo geral

Estimar biomassa viva acima do solo, utilizando a técnica de isolamento de copas em nuvens de pontos LiDAR aerotransportado em quatro áreas da região nordeste do estado do Mato Grosso.

1.2 Objetivos específicos

- a) Isolar copas de árvores utilizando algoritmos propostos por Silva et al. (2017) e Dalponte (2018);
- b) Analisar os resultados da aplicação dos algoritmos descritos no item anterior;
- c) Analisar a relação entre as métricas do LiDAR e a biomassa;
- d) Gerar modelos para prever biomassa pela individualização das copas das árvores, tendo como variáveis independentes métricas da nuvem de pontos LiDAR.

2 REVISÃO BIBLIOGRÁFICA

Sendo um dos países emergentes no contexto global e com vasta cobertura florestal, que busca um desenvolvimento sustentável, o Brasil tem importância direta em reduzir as emissões dos gases que contribuem para intensificar o aumento do efeito estufa no planeta. Desde o ano de 1992 em que sediou o evento das Nações Unidas – ONU a ECO-92, o Brasil é um dos 195 países que assinaram o tratado para combater o aumento da temperatura mundial (MMA, 2017). Um dos tópicos deste acordo visa a preservação da cobertura florestal do planeta. Contudo, a cobertura arbórea não garante que a floresta esteja desenvolvendo seu papel ecológico e não emita elevadas taxas de gases como o CO₂ (HOLTUM; WINTER, 2010).

O acompanhamento da mudança da cobertura florestal amazônica tem sido o foco de projetos e estudos em escalas nacionais e mundiais. Essas utilizam imagens ópticas orbitais com resolução espacial que variam de 30 a 250 m (PRODES, 2017; MILODOWSKI, et al. 2017; TYUKAVINA et al. 2017). A divisão política da floresta amazônica brasileira é Amazônia Legal Brasileira (AML), a maioria dos esforços nessa área são para mitigar o desmatamento que tem oscilado nos últimos anos com tendência de redução (INPE, 2017; FONSECA, 2017). Apesar disso, as degradações florestais causadas pelo fogo, corte seletivo e fragmentação cresceram consideravelmente (BARLOW; PERES, 2008).

Uma forma de atenuar altas emissões de gases indesejados de florestas é por meio das diretrizes do programa de redução de emissões causadas pelo desmatamento e degradação florestal do REDD+. Estas diretrizes são adotadas diretamente pelo Ministério do Meio Ambiente – MMA (2016), que utiliza como principal variável de controle o estoque de biomassa presente nas florestas dentro das fronteiras nacionais.

2.1 Biomassa

Para estudar a biomassa florestal, é necessário estimar todos os componentes bióticos, incluindo massas vivas aéreas e subterrâneas de árvores, arbustos, palmeiras, mudas e outros elementos do sub-bosque, epífitas e também massa de plantas mortas como gravetos e madeira (BROWN, 1997). Esses componentes representam a maior fração da biomassa total em uma floresta (FEARNSIDE, 1994). Sucintamente, a biomassa é definida como a quantidade total de matéria orgânica, expressa em toneladas (T) secas por unidade de área (BROWN, 1997).

Com vasta biodiversidade, as Florestas Amazônicas comportam grande quantidade de biomassa. Utilizando 2.954 hectares (ha) inventariados, distribuídos em toda AML, em 1994 foi estimada uma biomassa média de 463 megagramas por hectare (Mg ha^{-1}), equivalente a T, para as florestas primárias, incluindo os componentes mortos e sob o solo (FEARNSIDE, 2000). Em experimentos realizados por Benítez et al. (2016) na floresta amazônica do Equador, foi encontrada uma variação de AGB entre 17,48 e 464,90 Mg ha^{-1} , com desvio padrão de 195,80 Mg ha^{-1} e média de 118,96 Mg ha^{-1} . Os autores descreveram uma heterogeneidade na biomassa das áreas observadas, com uma distribuição normal de seu histograma.

Fearnside (2003) descreve que em parcelas estudadas em regiões da AML, foi observado o valor médio de 354 Mg ha^{-1} de AGB. Destas, 28 Mg ha^{-1} são de indivíduos mortos. No estado do Pará (PA), Gerwing (2002) encontrou um valor médio de biomassa de 309 Mg ha^{-1} . Na Amazônia Central, foi observado uma AGB média de 397,7 Mg ha^{-1} com *Root-mean-square error* (RMSE) de 30 Mg ha^{-1} , desta 81,9% é proveniente de espécies arbóreas, 7% de troncos derrubados, 5,3% de pequenos arbustos, 2,1% de lianas, 1,9% de liteira, 1,5% de troncos morrendo ou mortos e as palmáceas representando 0,3% (NASCIMENTO; LAURENCE, 2002).

Para realizar o cálculo de biomassa, uma variável importante coletada em campo é o Diâmetro a Altura do Peito (DAP), esta variável é o diâmetro a 1,3 m de altura de uma árvore, por convenções hipsometrias são mensurados os

elementos DAP's superiores a 0,1 m. Este diâmetro junto com a altura são as variáveis mais importantes para estimar a biomassa de uma árvore viva em meio à floresta. Segundo Nascimento e Laurence (2002), os indivíduos com DAPs entre 0,2 e 0,5 m, representaram 46,7% da AGB viva de uma região florestal no estado do PA, DAPs superiores a 0,6 m, representam 13,4% da AGB.

Nas estimativas de árvores tropicais vivas, Chave et al. (2005) ajustaram um modelo que é aceito amplamente na área acadêmica denominado de modelo de Biomassa Acima do Solo (AGB_{arv}) (Equação 2.1). Este modelo foi desenvolvido a partir da análise de mais de 2.400 árvores, algumas com DAP's superiores a 0,05 m, existentes em 17 países. Os autores obtiveram um R^2 de 0,957 em áreas de florestas tropicais secas, úmidas e mistas.

$$AGB_{arv} = 0,0509 * D * DAP^2 * Htot \quad (2.1)$$

em que a AGB_{arv} é a biomassa viva acima do solo, expressa em megagrama (Mg), D é densidade do indivíduo e $Htot$ é a altura total do indivíduo.

Para calcular a biomassa de árvores mortas, Palace et al. (2007) utilizaram o volume morto do indivíduo multiplicado por sua densidade. Por não possuírem material lenhoso, a composição físico-química dos vegetais do gênero palmáceas possuem uma equação diferente na estimativa de sua biomassa, tanto para as mortas quanto as vivas. Suas AGBs podem ser estimadas (AGB_{pal}) por meio da Equação 2.2 (NASCIMENTO; LAURENCE, 2002):

$$AGB_{pal} = \frac{(exp^{0,9285 \ln(DAP^2)+5,7236} * 1,05001)}{10^3} \quad (2.2)$$

Outro gênero que contribui para diversidade florestal e sua dinâmica é a o das plantas lianas, comumente encontradas em florestas tropicais. Utilizando 424 indivíduos, Schnitzer et al. (2006) ajustaram um modelo (Equação 2.3) para o cálculo de biomassa (AGB_{lia}) desse gênero.

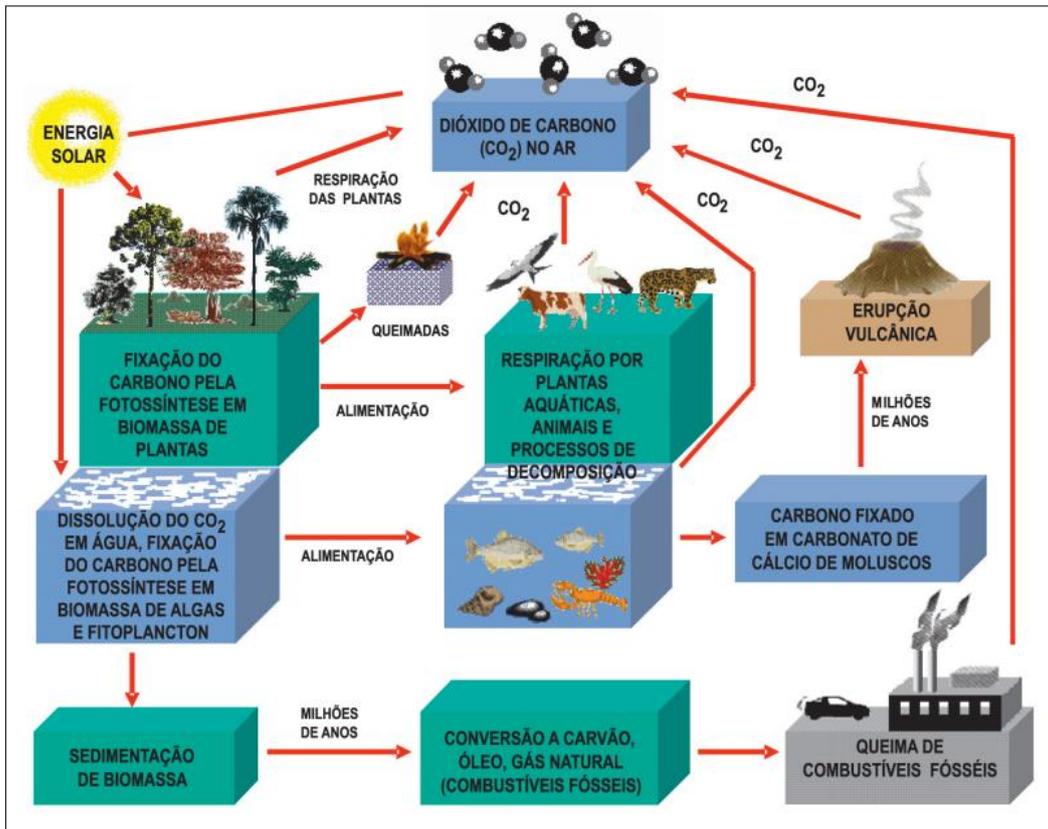
$$AGB_{lia} = \exp(-1,784+2,657 \ln(D)) \quad (2.3)$$

Estes modelos para estimar biomassa, auxiliam no estudo da magnitude e emissão de elementos que, por ventura, sejam liberados pelo desmatamento ou degradação florestal.

2.2 Ciclo do carbono

O C é o elemento químico mais presente na biomassa, variando de 40 a 50% de sua composição (SCHLESINGER, 1995). A interação de C e O formam um dos principais gases que contribuem para o efeito estufa, o dióxido de carbono CO₂. Este é fixado na biosfera terrestre principalmente por meio da fotossíntese e respiração das plantas (Figura 2.1). Assim, uma fração do CO₂ é reemitida à atmosfera, através da respiração e queima e outra, é fixada nos órgãos das plantas, processo denominado Produção Primária Líquida (PPL) ou *Net Primary Production* (NPP) (MARTINS et al., 2003).

Figura 2.1 - Ciclo do CO₂.



Fonte: Martins et al. (2003).

O carbono fixado é consumido por organismos heterotróficos e gradativamente liberado por meio da respiração na forma de CO₂, podendo ser também liberado pelo processo de decomposição da matéria orgânica ou ataque de microrganismos (MARTINS et al., 2003). A dinâmica e evolução da biosfera é a base para descrever o ciclo do C, sendo notório que o CO₂ no planeta está estreitamente ligado aos biomas da Terra e seus climas.

As florestas são os mais importantes repositórios terrestres de C, o que as tornam fundamentais para analisar as incertezas sobre o ciclo deste elemento (LE TOAN et al., 2011). Desde o início da revolução industrial até o ano de 2010, estima-se que foram lançados 49 (± 4,5) Pg CO₂ ano⁻¹ na atmosfera terrestre de maneira antrópica, representando 76% do total dessas emissões. A agricultura, floresta e outros usos e ocupações do solo, representam de 20 a 25% dessas emissões (SMITH et al., 2014). Em áreas florestais degradadas, a

quantificação de CO₂ emitido por consequências de impactos depende de fatores como a intensidade, magnitude e o tipo de degradação que a área sofre (BROWN, 1997).

2.3 Degradação florestal

A degradação tem influência sobre as funções sociais, culturais e ecológicas de uma floresta, sendo um detrimento silencioso no desenvolvimento sustentável. Suas consequências são, na maioria das vezes, sutis e se mostram latentes quando a floresta perde a própria capacidade de manter suas funções ecológicas básicas. Diferente de uma floresta não degradada, que possui todas suas interações ecológicas funcionando (SCHOENE et al., 2007).

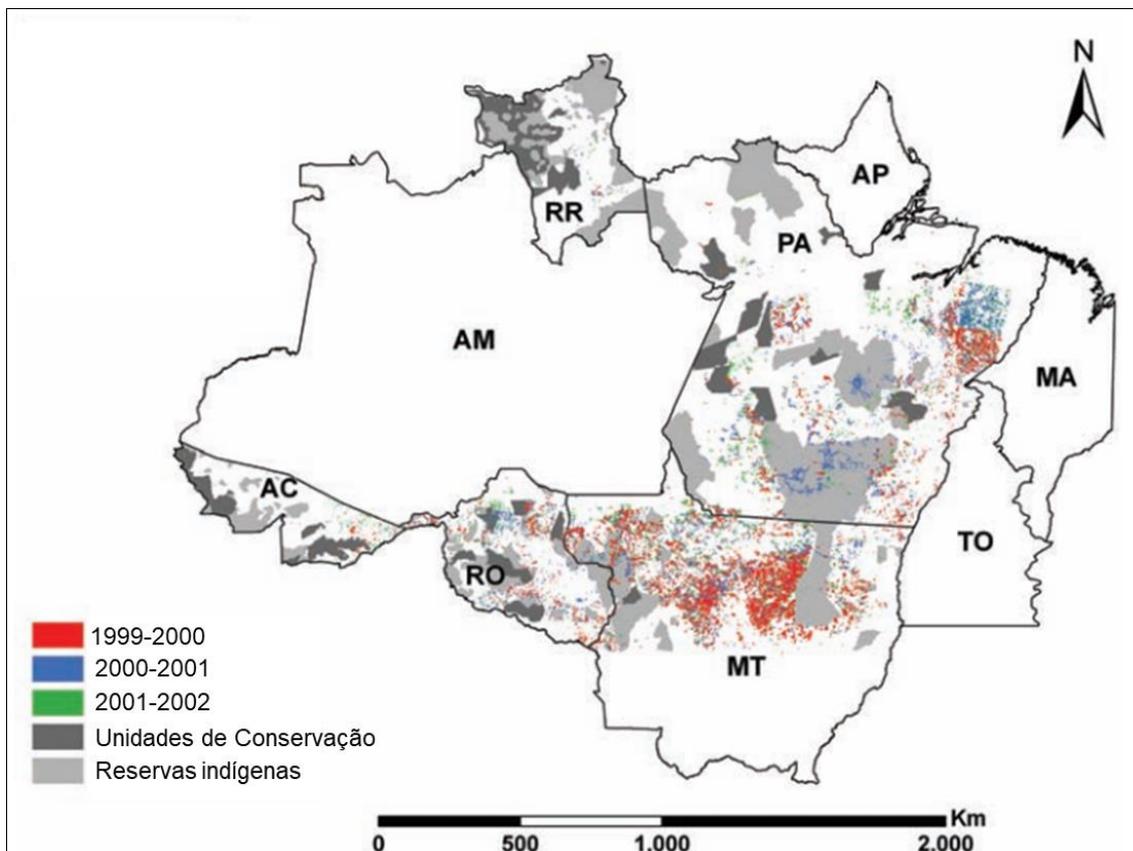
A degradação florestal é um processo distinto do desmatamento, enquanto que o desmatamento consiste na supressão de toda a vegetação presente na área. Na degradação, mantem a cobertura florestal, perdendo a capacidade de fornecer serviços ecossistêmicos. Este fator faz com que ocorra grandes mudanças na composição de espécies endêmicas, invasão de outras exóticas ou poluição (DURAIAPPAH et al., 2005) Dentre os estados brasileiros com altas taxas de degradação, o Mato Grosso apresentou um Índice de Degradação Ambiental (IDA) de 0,149 em 2016, maior índice para os estados que compõem o Brasil Central. Este índice leva em consideração fatores como queimadas, áreas florestais nativas com manejos e valores econômicos (ALVES et al., 2016). O estado do MT, apresentou no ano de 2015 a segunda maior área degradada dos estados representantes da ALB, com estimativas de 1.479,1 km² degradados pro fogo ou corte seletivo (DETER, 2015).

A região norte do estado do Mato Grosso teve o início de sua colonização na década de 80, época que surgiu o projeto fomentado pela empresa Colonizadora Paralelo 16 Ltda, o que ocasionou mudanças de uso e ocupação da terra (IBGE, 2017), iniciando nesta época as degradações intensas na região. Dentre essas degradações está o corte seletivo. Segundo Asner et al. (2004), o corte seletivo trata-se da exploração de madeira presente em áreas florestais, provocando uma degradação que varia de acordo com a intensidade

deste impacto, que pode chegar a retirar de 25 a 50% do dossel florestal, danificando até 30 árvores ao se retirar a árvore de interesse. Nos estados do Acre (AC), Roraima (RR), Mato Grosso (MT), Pará (PA), Amapá (AM) e Rondônia (RO), as taxas de degradação florestal por corte seletivo entre os anos de 1999 a 2002 variaram de 60 a 123% em comparação ao desmatamento. Nestes estados, os cortes seletivos concentram-se no Acre e Mato Grosso, onde foram extraídos de 27 a 50 milhões de m³ de madeira e um fluxo de 0,1 bilhão de Mg de C foram emitidos para a atmosfera (ASNER et al., 2006). Em impactos por queimadas, Morton et al. (2013) estimaram que entre os anos de 1999 e 2010, cerca de 85.500 km² da região oriental da Amazônia sofreram por esta degradação, concentradas no estado do Mato Grosso e sul do Pará.

Sato et al. (2016) utilizaram dados LiDAR para quantificar as mudanças pós incêndios nas alturas das árvores e na biomassa florestal na região ocidental da Amazônia Brasileira. Em dez anos, não houve recuperação total das alturas, e a biomassa foi inferior nas áreas degradadas variando de -6,71 a -22,69% em relação às áreas de florestas intactas. Ao comparar o impacto do fogo e do corte seletivo no estado do Pará, constatou-se que em cortes seletivos moderados houve uma perda de 20% (35 m³ ha⁻¹) de madeira, na extração intensa ocorreu uma redução de 48% (69 m³ ha⁻¹). Para queima moderada da floresta, a perda de madeira foi igual a encontrada no corte seletivo intenso, enquanto que na queima intensa houve uma redução de 83% da madeira (GERWING, 2002). Mesmo com menor intensidade de impacto, o corte seletivo abrange vastas áreas da floresta amazônica, principalmente no “arco do desmatamento”, região em que está inserida a área de estudo deste trabalho (Figura 2.2).

Figura 2.2 - Mapa de corte seletivo no “arco do desmatamento”.

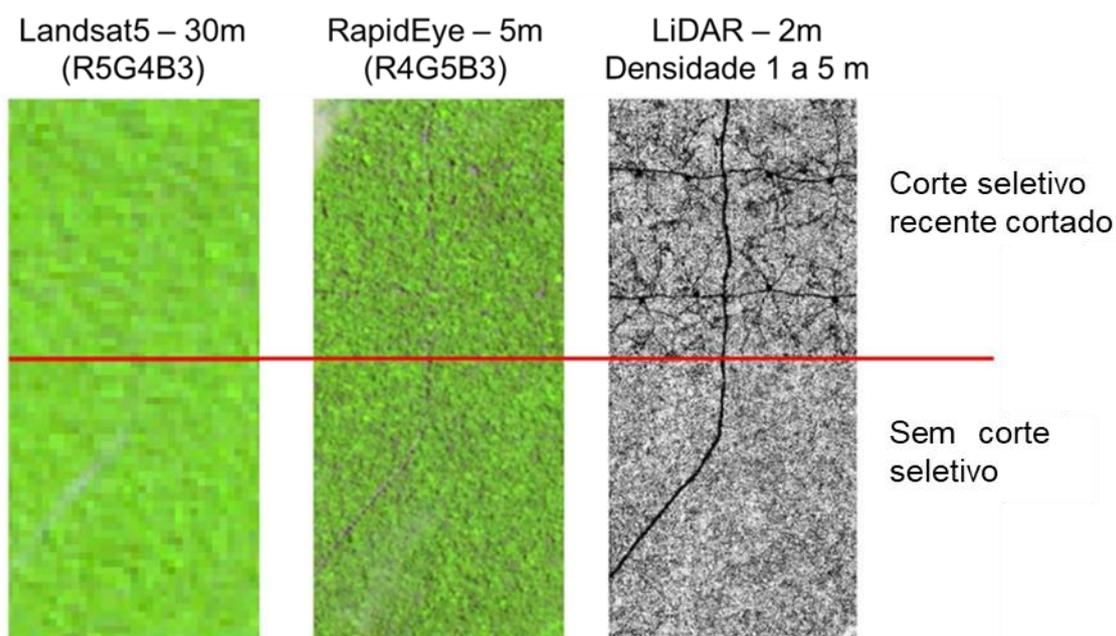


Mapa de áreas com corte seletivo no “cinturão do desmatamento” entre os anos de 1999 e 2002.

Fonte: Adaptada de Asner et al. (2006).

Normalmente as árvores que são retiradas da floresta, pelo corte seletivo, são as que compõem o dossel ou são emergentes por possuírem maior volume e comprimento de toras e agregarem maior valor ao produto de madeira serrada (d'OLIVEIRA et al., 2012). Por este motivo, o órgão que fornece concessão ao plano de manejo do corte seletivo, vem utilizando monitoramentos das áreas afetadas com corte seletivo, utilizando a análise da nuvem de pontos antes e depois da extração da madeira *Light Detection and Ranging* (LiDAR) (Figura 2.3).

Figura 2.3 - Comparação de diferentes sensores em áreas de corte seletivo.



Comparação entre imagens orbitais do Landsat5 e RapidEye, com a imagem de densidade de nuvem de pontos LiDAR entre 1 e 5 metros de altura.
 Fonte: Serviço Florestal Brasileiro (2016).

Com estes procedimentos, a tecnologia LiDAR vem se consolidando como aliada no monitoramento de áreas com corte seletivo na região da Amazônia, utilizando repetidos voos antes e pós corte seletivo (ANDERSEN et al., 2013)

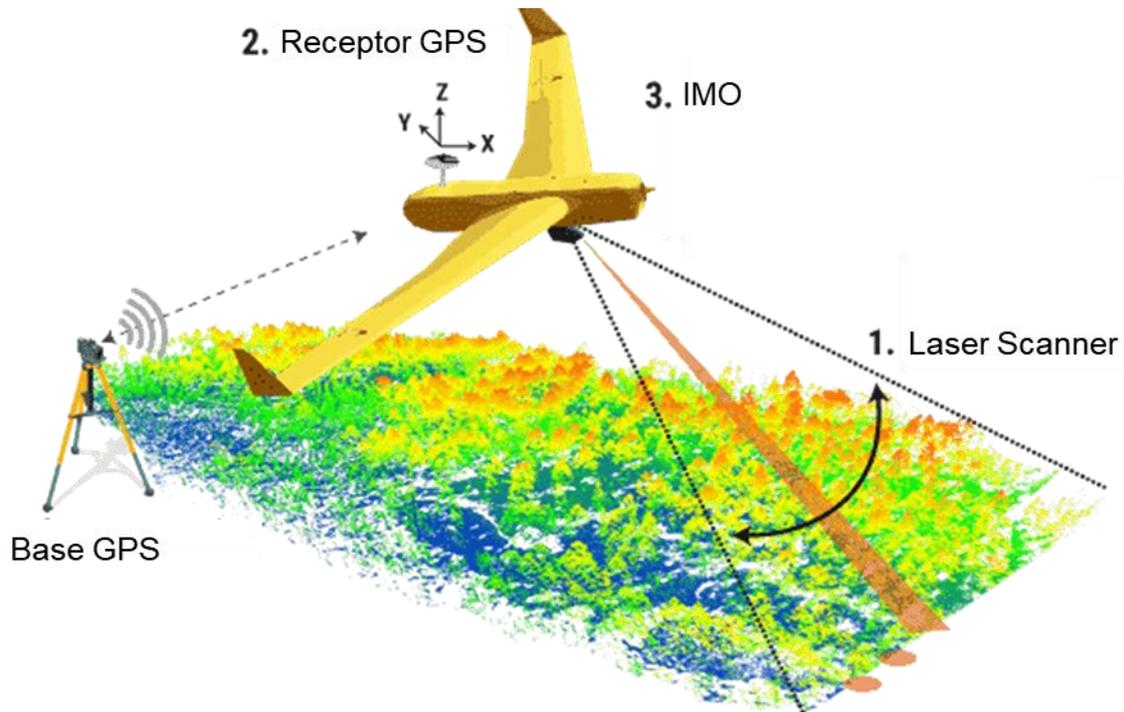
2.4 Sistema LiDAR

Os equipamentos *Light Detection and Ranging* (LiDAR) permitem inúmeras aplicações em diversas áreas da engenharia pela altíssima precisão e detalhamento no imageamento dos objetos em estudo. Em português, também é comum utilizar o termo Sistema de Varredura a *LASER* (GIONDO et al., 2010). O sistema *LiDAR* possibilita obter distâncias com altíssima precisão em relação a objetos, resultando em uma nuvem tridimensional de pontos bastante densa podendo facilmente ultrapassar milhões de pontos com apenas alguns minutos de coleta. Este potencial pode ser explorado para captura rápida e exata de dados extremamente detalhados (LICHTI et al., 2008).

2.4.1 Funcionamento do sistema LiDAR

O equipamento LiDAR pode ser utilizado de maneira terrestre (*Terrestrial Laser Scanner* (TLS)), aérea (*Airborne Laser Scanner* (ALS)) (Figura 2.4) ou orbital, sendo projetado para a obtenção de coordenadas tridimensionais de pontos em uma superfície, registrando a localização espacial e as intensidades dos raios *LASER* que são refletidos por milhares de pontos a cada segundo (RIBEIRO JÚNIOR, 2011; SILVA, 2011). Essa tecnologia apresenta a vantagem de ser um sistema ativo de captação, ou seja, não depende da iluminação solar (GIONDO et al., 2010). O equipamento ALS é composto basicamente por três elementos: *LASER*, INS e GPS.

Figura 2.4 - Princípios e Componentes de Um Sistema LiDAR Aerotransportado.



Sistema de varredura LiDAR aéreo transportado.

Fonte: Adaptada de Santana (2018).

A partir da década de 80, iniciou a utilização do *LASER* para mensurar distâncias e, desde então, foram criados sensores para realizar varreduras da superfície terrestre. Alguns programas a nível mundial são o *NASA's Atmospheric Oceanographic LiDAR (AOL)* (FLOOD, 2001), *Airborne Topographic Mapper (ATM)* (ABSHIRE et al., 2000), *Shuttle Laser Altimeter (SLA)* (BUFTON et al., 1995) e *Mars Observer Laser Altimeter (MOLA)* (ZUBER et al., 1992). O equipamento *Laser* amplifica a luz por emissão estimulada de radiação, sendo um dispositivo eletro-óptico, emitindo a radiação de forma coerente (YEN et al., 2011) e utilizando pulsos disparados na direção dos objetos e na captação dos pulsos refletidos destes, sem a necessidade de refletores (RIBEIRO JÚNIOR, 2011).

A mensuração da distância de cada ponto pode ocorrer por três maneiras: tempo de voo do sinal (*Time of Flight*), diferença de fase (*Phase-difference*) e triangulação (*Triangulated Scanner*) (LICHTI et al., 2008). Para Buck et al.

(2012), a diferença entre esses princípios reside na velocidade de coleta de dados e na distância fixada para determinada precisão. Os equipamentos mais comuns realizam a medição das distâncias a partir da medida do tempo entre a emissão e a recepção do pulso sobre o alvo, medindo ângulos de emissão do feixe *LASER* para posicioná-los no espaço (RATCLIFFE e MYERS, 2006; MÁRQUEZ, 2010).

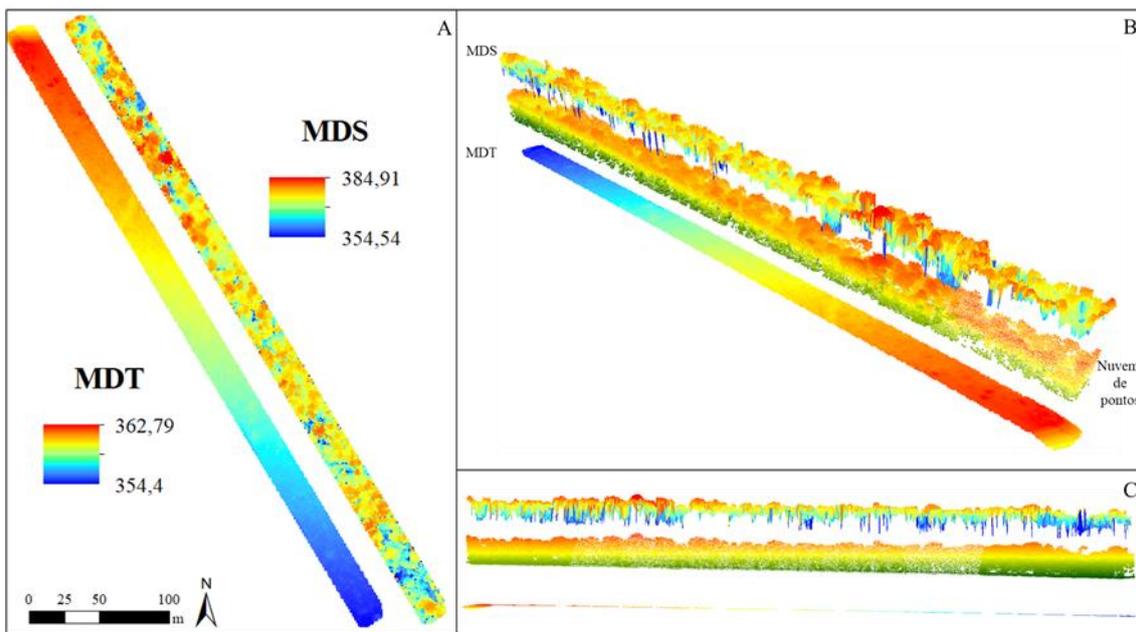
Outro elemento fundamental para o sistema ALS é o *Inertia Navigation System* (INS) ou Sistema de Navegação Inercial (INS). Basicamente, este componente é utilizado para estabelecer orientação da antena do sistema ALS enquanto este realiza a coleta de dados por meio de uma Unidade de Mediação Inercial (IMU) (GIONGO et al., 2010). O IMU é integrado por acelerômetros, giroscópios e uma unidade de controle. Esta última tem a função de controlar os sinais emitidos pelos demais componentes. Os dados do IMU auxiliam o INS para calcular tempo de voo e sua orientação, que registra informações para repassar um índice ao tempo obtido pelo GPS (JENSEN, 2009). O georreferenciamento da nuvem de pontos coletados pelo *LASER* é feito através de um equipamento que utiliza sinal da constelação de satélites *Global Positioning System* (GPS), tendo uma base fixa no solo para acurar o posicionamento do receptor que fica na aeronave, atribuindo uma localização geográfica a cada ponto coletado (JENSEN, 2009). Os dados coletados pelos componentes são pós processados separadamente, para ser realizado suas junções criando as nuvens de pontos corrigidas (GIONGO et al., 2010).

2.5 Algumas aplicações de LiDAR em florestas

No campo florestal, as nuvens de pontos LiDAR têm sido bastante utilizadas, havendo *softwares* que possibilitam extrair informações da floresta. Um exemplo destes *softwares* é o FUSION, que dentre suas ferramentas possui uma que retorna até 100 métricas da nuvem de pontos. As métricas são dados quantitativos e estatísticos da dispersão vertical da nuvem de pontos coletados na floresta (MCGAUGHEY, 2015).

Dados LiDAR, por proporcionarem resoluções espaciais finas, podem identificar atributos de árvores individuais em regiões tropicais, tais como ponto central, forma da copa e altura. Para realizar estes cálculos, pode-se desenvolver métodos de processamentos das imagens geradas a partir da nuvem de pontos; dentre essas imagens estão as do Modelo Digital do Terreno – MDT, Modelo Digital de Elevação – MDE e o Modelo de Altura de Copa (*Canopy Height Models* – CHM) (Figura 2.5), o CHM é a diferença entre o MDE e o MDT da floresta (d’OLIVEIRA et al., 2014).

Figura 2.5 - Representação da nuvem de pontos e imagens LiDAR de uma parcela do Projeto Paisagens Sustentável (*Sustainable Landscape* – SL).



A – Representa o Modelo Digital do Terreno – MDT e Modelo Digital de Superfície – MDS, as imagens possuem resolução espacial de 0,5 m; B – Visualização 3D da nuvem de pontos, MDT e MDS; e C – Visualização transversal 3D dos produtos mostrados no painel B.

d'Oliveira et al. (2012) utilizaram métricas de nuvens de pontos coletadas em áreas florestais do estado do Acre (AC) para realizar a mensuração de biomassa em três locais, duas áreas não degradadas e uma degradada por corte seletivo. As métricas escolhidas para compor um modelo de predição de biomassa foram os totais de retornos do primeiro quartil acima do solo e a variância de todos os retornos acima do solo. O resultado do modelo

extrapolado para todas as áreas foi uma média de biomassa de 231,6 Mg ha⁻¹. A área degradada apresentou biomassa estatisticamente menor do que as áreas não degradadas, ao nível de 0,01% de probabilidade estatística.

Longo et al. (2016) avaliaram a Densidade de Carbono Acima do Solo (DCA) em 359 parcelas espalhadas em florestas nativas da Amazônia brasileira, utilizando varreduras LiDAR. Destas varreduras, 48 possuíam inventários de campo. As áreas inventariadas foram distintas em 6 classes: floresta intacta, duas classes de cortes seletivos com intensidades diferentes (queimada uma vez, queimada mais de uma vez e queimada com corte seletivo). Nesta pesquisa, as métricas selecionadas foram: altura média dos retornos, curtose da dispersão dos pontos, total de retornos a 10% e 100% da altura e interquartil da altura. Para selecionar estas métricas, inicialmente foi aplicado o logaritmo da biomassa observada das árvores (variável dependente) e nas métricas coletadas (variáveis independentes). Com a intenção de eliminar as métricas que tinham relação entre si, foi realizada a seleção *stepwise*, por meio da função *stepAIC* do pacote *MASS* presente no software estatístico R. Realizando-se posteriormente a seleção de subconjunto de variáveis, utilizando a função *regsubsets*, do pacote *leaps*. Tendo o número máximo de métricas, foram ajustados os coeficientes utilizando o método dos mínimos quadrados, com uma heterocedástica distribuição dos resíduos. Para finalizar, foi calculada a *Bayesian Information Criterion* (BIC) e selecionado o modelo com menor estatística BIC. Os autores constataram que o LiDAR possui um excelente potencial para caracterizar a variabilidade do estoque de carbono em florestas degradadas e não degradadas. As estimativas por meio da nuvem de pontos, foram significativamente menores em áreas degradadas recentemente (LONGO et al., 2016).

Quando dados LiDAR são utilizados para analisar áreas com estruturas com menor complexidade, como florestas plantadas, apresentam erros não significativos na identificação de árvores, omitindo em 0,37 indivíduos/ha. Ocorre também, a diminuição do erro na análise de atributos individuais, como exemplo do volume, se combinados os dados LiDAR e as imagens aéreas. Os dados LiDAR tendem a subestimar variáveis individuais de árvores, diminuindo

o volume em 2,98% (SHINZATO et al., 2016), este fator também subestima a biomassa de áreas estudadas, pois estas variáveis são altamente correlacionadas. Para estimar o volume de plantios comerciais, Silva et al. (2016) utilizaram a técnica de componentes principais para selecionar métricas de parcelas e por meio de regressão múltipla estimar seus volumes de madeira (m^3), obtendo um coeficiente de determinação do modelo de 0,87 (R^2_{adj}) e um RMSE de $27,60 m^3 ha^{-1}$. Ainda sobre a complexidade estrutural de florestas nativas, valores de modelos de ajustes (R^2) com dados ópticos de médias resoluções espaciais são superiores em florestas boreais, onde a quantidade, densidade e dispersão de espécies são diferentes das encontradas em florestas tropicais. Por isso, nesse tipo de vegetação, deve-se utilizar dados com resoluções mais finas (PAN et al., 2013).

2.6 Individualização de árvores

O objetivo da Detecção Individual de Árvores (*Individual Tree Detection* ITD) por meio de imagens orbitais é localizar o ponto central da árvore e a forma de sua copa. Isso permite extrair informações horizontais das árvores e suas dispersões e, conseqüentemente, do ambiente em que estão alocadas. Essas informações são necessárias para diversas atividades de manejo e planejamento florestal (d'OLIVEIRA et al., 2014). Shinzato et al. (2016) fizeram uso de imagens ópticas tradicionais e imagens LiDAR para realizar a ITD e estimar volume de plantios comerciais de *Eucalyptus urograndis*, conseguindo um R_2 de 0,84 para plantios de até 3 anos.

Para realizar a ITD, Pitkanen e Maltamo (2004) utilizaram o CHM com tamanho de $0,5 \times 0,5 m$ de *pixel*. Os *pixel* foram calculados usando o primeiro retorno dos pontos, ou seja, o ponto com maior altura, segmentando então as imagens para obter as áreas das copas das árvores. Outra técnica de segmentação que pode ser utilizada para a ITD em imagens CHM é o algoritmo *watershed*, mostrando bons resultados em árvores espaçadas (ENE et al., 2012; REITBERGER et al., 2009). Trabalhando em regiões de coníferas, Lee et al. (2010) utilizaram o algoritmo de crescimento de região para isolar árvores em

imagens LiDAR CHM de plantios comerciais, sendo satisfatório nas estimativas das alturas das árvores, porém, insatisfatório na detecção da forma das copas.

Utilizando seis tipos de áreas diferentes na França, Suécia e Dinamarca, foram comparados seis algoritmos para isolar árvores aplicados em imagens CHM. Os algoritmos utilizados foram: detecção de máximos locais; seguimento do vale; correspondência de modelos; teoria do espaço-escala; campos aleatórios de Markov e processos de pontos marcados (LARSEN et al., 2011). O resultado do trabalho mostrou que nenhum dos algoritmos utilizados foi satisfatório para todas as áreas, salientando que as características diferentes de cada área interferem na individualização das árvores.

Féret e Asner (2012), trabalharam em uma região tropical havaiana na identificação de espécies. Além da segmentação da imagem CHM do dado LiDAR, foram utilizadas imagens multiespectrais classificadas pelo algoritmo *Supporte Vector Machine*. Resultados mostraram que a segmentação da imagem LiDAR foi superior para a ITD. Ferraz et al. (2016) realizaram a ITD e a estimativa de biomassa individual em uma floresta tropical da região do Panamá, utilizando imagens CHM segmentadas e o algoritmo nomeado *3D Adaptive Mean Shift (AMS3D)*. A metodologia obteve melhor resultado em árvores emergentes e dominantes e mostrou-se satisfatória na aquisição de métricas individuais, densidade, altura e tamanho de copa. No estudo, foram ajustados quatro modelos de biomassa, obtendo erros entre 27,13 a 32,62 Mg ha⁻¹.

O Grupo de Pesquisa *Quantitative Ecology*, da *School of Forestry at Northern Arizona University* disponibiliza um algoritmo¹ para isolar árvores em nuvens de pontos LiDAR. Este algoritmo é desenvolvido na linguagem R e utiliza métodos do *software* FUSION (MCGAUGHEY, 2015), sendo transposto totalmente para linguagem R por Silva et al. (2017). Como parâmetro ao algoritmo, utilizando imagens CHM, são utilizadas as alturas mínimas das árvores a serem filtradas

¹ <http://quantitativeecology.org/using-r-lidar-and-fusion-to-delineate-individual-trees-through-canopy-height-model-segmentation/>

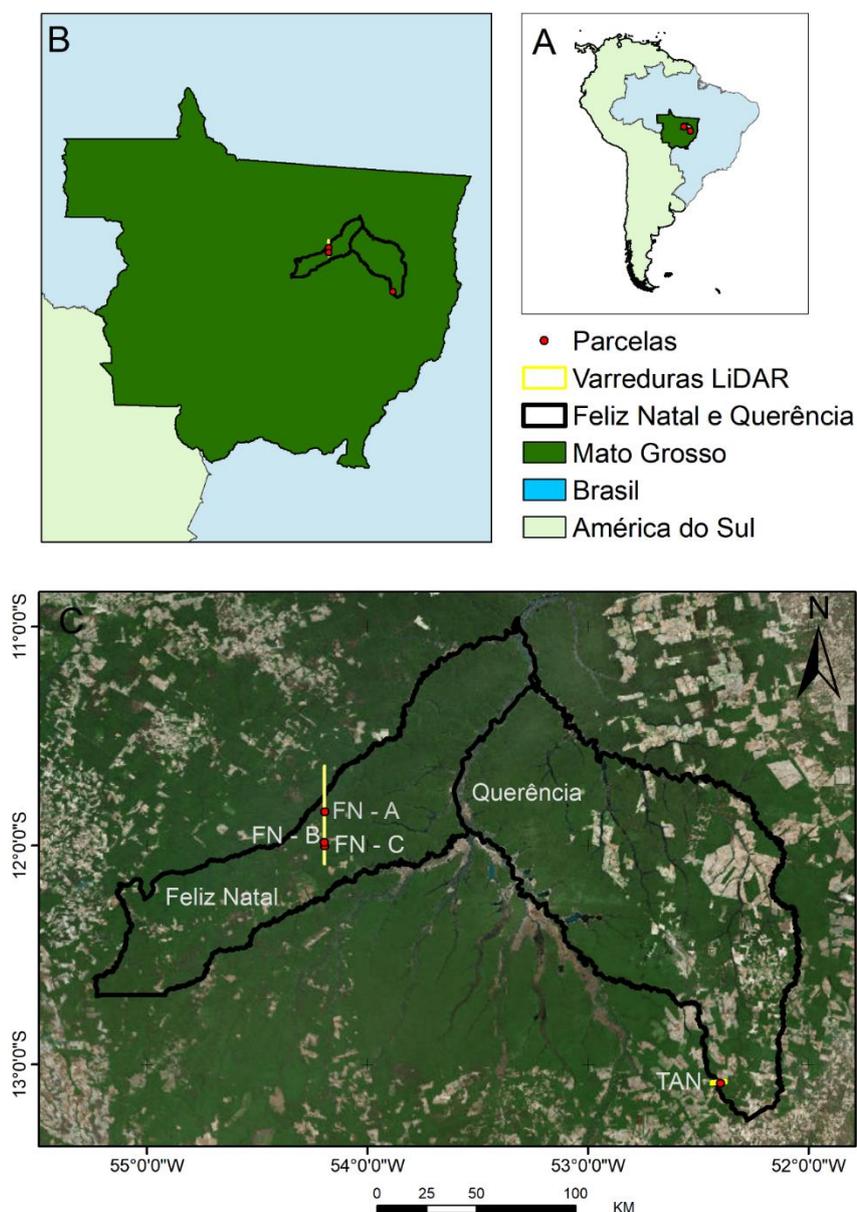
e o raio máximo das suas copas. Este algoritmo retorna uma imagem com o ponto central da árvore e sua delimitação (QUANTITATIVE ECOLOGY, 2017). Outro algoritmo utilizado para realizar a individualização de copas foi desenvolvido por Dalponte (2018), este utiliza a nuvem de pontos como entrada para realizar individualização das árvores.

3 MATERIAIS E MÉTODOS

3.1 Áreas de estudo

As áreas escolhidas para realizar o trabalho estão localizadas em 2 municípios da região norte mato-grossense (Figura 3.1), Feliz Natal (11.462,464 km²) e Querência (17.786,195 km²). Apesar das varreduras LiDAR sobreporem mais municípios, as parcelas de campo analisadas não abrangem todos eles.

Figura 3.1 - Áreas de estudo.



Estas áreas fazem parte do projeto Paisagens Sustentáveis (*Sustainable Landscapes – SL*), uma cooperação entre o Serviço Florestal dos Estados Unidos (*United States Forest Service*) e a Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA). Este projeto tem o objetivo de desenvolver novas metodologias e conhecimentos para a estimativa de carbono dentro das diretrizes de REDD+. O projeto disponibiliza as varreduras LiDAR e os dados de campo correspondentes (KELLER, 2017). Seguindo a nomenclatura do SL, a varredura no município de Querência é caracterizada como TAN e a de Feliz Natal como FN.

3.1.1 Histórico da área de estudo Querência

A área localiza-se na Fazenda Tanguro (TAN) e possui aproximadamente 150 ha. Em parte da área da varredura LiDAR, foram realizados experimentos para avaliar a regeneração florestal com sucessivas queimadas controladas por Balch et al. (2008) e Brando et al. (2014). Os pesquisadores realizaram queimadas anuais e tri anuais no período de 2004 a 2010, exceto no ano de 2008.

3.1.2 Histórico da área de estudo Feliz Natal

Esta área se estende desde o centro do município de Feliz Natal até a região sul do município de União do Sul. Devido ao seu tamanho, apresenta locais que tem sofrido diferentes impactos como: corte seletivo, desmatamento e fogo. As parcelas presentes nesta área foram divididas em 3 subáreas: FN – A, mais ao norte; FN – B, na região sul da varredura e FN – C, mais ao sul que a anterior. Nas parcelas FN – A e FN -C, houveram cortes seletivos (LONGO et al., 2016), ambas as áreas possuem 4 parcelas com área sob a varredura LiDAR. As duas parcelas FN – B estão localizadas em uma faixa fina de floresta remanescente.

3.2 Dados LiDAR

Apesar das varreduras dos dados LiDAR terem sido similares, elas apresentam algumas singularidades conforme descritas na Tabela 3.1.

Tabela 3.1 - Dados das Varreduras LiDAR

Variável	Área de Estudo	
	FN	TAN
Data de Aquisição (dd/mm/aaaa)	31/03/2016	04/08/2012
Zona UTM	21S	22S
Número de Tiles	61	21
Área Total de Varredura (ha)	995	1005
Média de densidade de retornos (pontos/m ²)	32,44	13,7
Média de densidade dos primeiros retornos (pontos/m ²)	23,28	7,05
Altitude média de voo	850	850
Ângulo de visada (graus)	15	11
Especificações do Scanner	OPTECH/ ALTM 3100/ 05SEN171	Altm 3100 / Optech inc
Frequência do Scanner (Hz)	40	59,8

Informações técnicas sobre a aquisição e pré-processamento das nuvens de pontos fornecidas pelo projeto Paisagens Sustentáveis, que serão utilizadas neste trabalho.

Fonte: Adaptada de Keller (2017).

Todos os pontos das varreduras foram georreferenciados em projeção UTM com o DATUM Sirgas 2000 por meio do equipamento APPLANIX, com frequência de 5 Hz. Outro fator pertinente a todas as varreduras são as sobreposições de voo de 65%, permitindo assim, quantidade suficiente de pontos por m² (ppm²) para análise deste trabalho.

3.3 Dados de campo

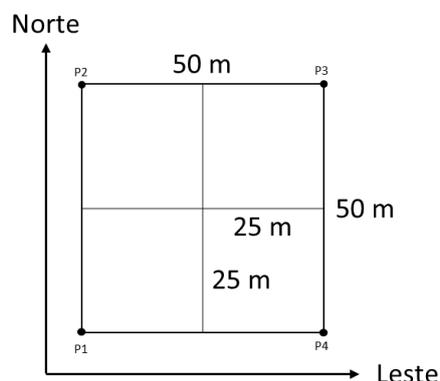
Os dados de campo das áreas TAN, FN – A e C foram obtidos do banco de dados do projeto Paisagens Sustentáveis, que disponibiliza por meio de planilha eletrônica 24 atributos de cada indivíduo vivo (árvore, palmácea e lianas), com Circunferência a Altura do Peito (CAP) superior a 0,1 m, mensurados dentro dos vértices das parcelas. Alguns destes são: transecto em

que a árvore se encontra, número da árvore, densidade, biomassa acima do solo, gênero da espécie, forma da copa, altura comercial, altura total, raio norte, raio sul, raio leste, raio oeste e as coordenadas UTM (KELLER, 2017).

As biomassas das espécies foram calculadas pelos modelos descritos por Chave et al. (2005) para árvores vivas, Nascimento e Laurence (2002) para palmáceas e Schnitzer et al. (2006) para lianas. Estes modelos foram descritos anteriormente na fundamentação deste trabalho. Todos os indivíduos mensurados foram georreferenciados de acordo com suas posições nas parcelas.

A partir deste ponto, as áreas serão descritas como A, B, C e T para as áreas FN – A, FN – B, FN – C e TAN, respectivamente. Foram instaladas duas novas parcelas na área B, para aumentar amostragem das árvores utilizadas no trabalho. A alocação da parcela ocorreu primeiramente pelo vértice inicial, o ponto inferior esquerdo (P01), a partir deste, com o auxílio de uma bússola, tentou-se manter a direção dos pontos cardeais e mediu-se 50 m para Norte, o qual seria o vértice 2 (P02) e 50 m para Leste formando o vértice 4 (P04). A partir do P02 mediu-se 50 m para Leste para obter o ponto vértice 3 (P03). No final, caso a medida entre P03 e P04 não fosse de 50m, significava que a parcela não estava bem enquadrada. Então corrigia-se a posição dos vértices 3 e 4 (Figura 3.2).

Figura 3.2 – Modelo de alocação das parcelas.



Em cada parcela coletou-se as seguintes informações dos indivíduos arbóreos com DAP \geq 30 cm: circunferência a altura do peito (CAP), altura total (Htot), altura comercial (Hcom), raio da copa nas orientações norte (RN), sul (RS), leste (RL) e oeste (RO), nome científico da espécie, a posição relativa em relação ao dossel (Emergente, Dominante ou Dominada), se a árvore estava Viva ou Morta, a localização das árvores com GPS de navegação, bem como a localização X e Y de cada árvore na parcela, além disso, os pontos dos quatro vértices das parcelas foram coletados com sistema GPS (Figura 3.3). O sistema GPS foi de fundamental importância para obter precisamente a localização das parcelas e, posteriormente, ser comparada com as informações espaciais obtidas do LiDAR.

Os GPS utilizados para realizar o georreferenciamento das parcelas foram 2 *Sokkia Radian IS L1* e um *Topcon HIPER*, este último foi utilizado como base. Era fixado o ponto com um pedaço de madeira para que o mesmo ponto pudesse ser utilizado novamente, se necessário. Para aumentar a recepção dos aparelhos em meio a vegetação, foi utilizado bastões de suspensão e, para cada coleta, foi anotada a altura do aparelho para posterior correção de altitude. Também foram anotadas data e hora de início e término da coleta de cada vértice da parcela. O pós processamento dos dados foi realizado no programa *topcon tools*, utilizando a Rede Brasileira de Monitoramento Contínuo dos Sistemas GNSS – RBMC da cidade de Sorriso – MT para melhorar a geolocalização do instrumento que foi utilizado como base.

Figura 3.3 - Coleta de ponto georreferenciado com o GPS.



Aquisição de ponto no vértice da parcela com sistema GPS, detalhe em caixa vermelha o aparelho posicionado o mais alto possível para facilitar aquisição do ponto.

Fonte: Kaio Allan Cruz Gasparini (2017).

Após o pós processamento, o erro médio de deslocamento horizontal entre os pontos coletados não foi superior a 1 m, erro aceitável para fins de utilização. Possivelmente, este erro é decorrente da vegetação densa, que em alguns casos, não foi possível instalar a base em locais sem interferência de sinal, devido a questões de segurança do aparelho ou logística.

Ao realizar as medições nas parcelas da área B, procurou-se manter os padrões utilizados pelo projeto Paisagens Sustentáveis. A partir do vértice inferior esquerdo, convencionalmente adotado com as coordenadas de origem, ou seja (0, 0), se obteve o X e Y de cada árvore. O DAP foi obtido com a mensuração do CAP dos indivíduos a campo e este foi então dividido por π . A altura total (Htot), altura comercial (Hcom), raios de copa e posição relativa da

copa foram mensuradas por meio de estimativa visual devido a experiência do identificador a campo (Figura 3.4).

Figura 3.4 - Mensuração de indivíduos dentro das parcelas.



Mensuração de atributos físicos das árvores (CAP, Htot, Hcom, raios de copa) e marcação de pontos com GPS de navegação.

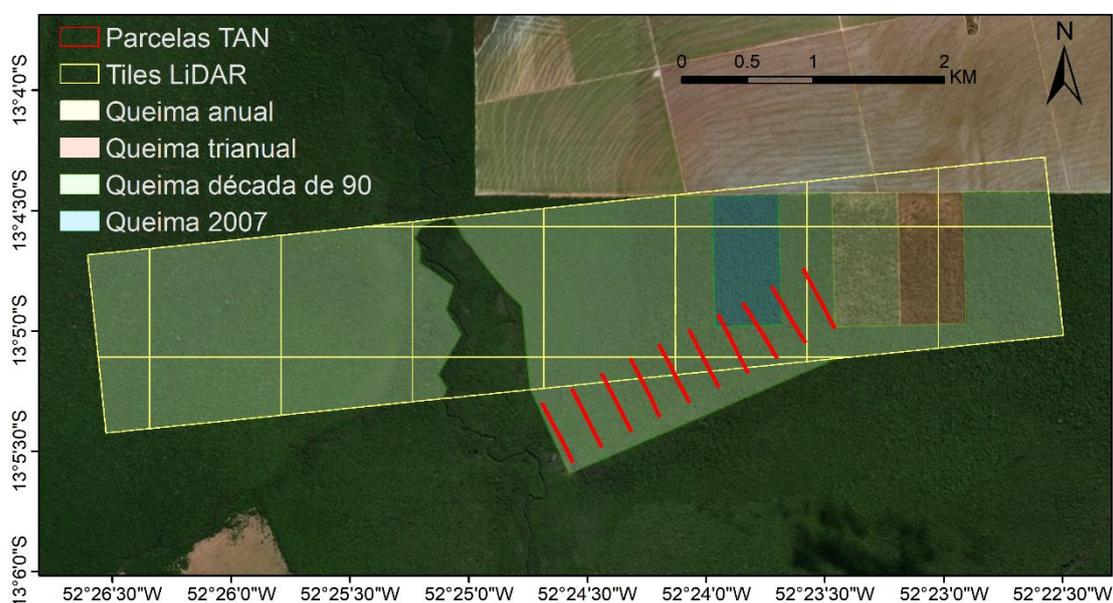
Fonte: Kaio Allan Cruz Gasparini (2017).

Os dados mensurados em campo (Figura 3.4) foram organizados em planilhas eletrônicas. Para cada espécie identificada durante o inventário, foi obtida a Densidade Básica da Madeira - DBM (ρ) em g/cm^3 a partir do banco global desenvolvido por Chave et al. (2009) e Zanne et al. (2009). A união da tabela das informações da DBM com as respectivas espécies identificadas em campo, foi feita em função do nome científico de cada indivíduo, utilizando a função merge, nativa da linguagem R.

3.4 Dados de Querência

Pelo projeto SL, no município de Querência, foram instalados 10 transectos com dimensões de 20 x 500 m (1 ha)(Figura 3.5), medindo todos os indivíduos com Diâmetro a Altura do Peito (DAP) superiores ou iguais a 0,35 m. No centro dos maiores transectos, foram alocadas subparcelas com vértices de 2 x 500 m (0,1 ha), nos quais foram mensurados os elementos com DAPs superiores a 0,1 m.

Figura 3.5 – Área T.



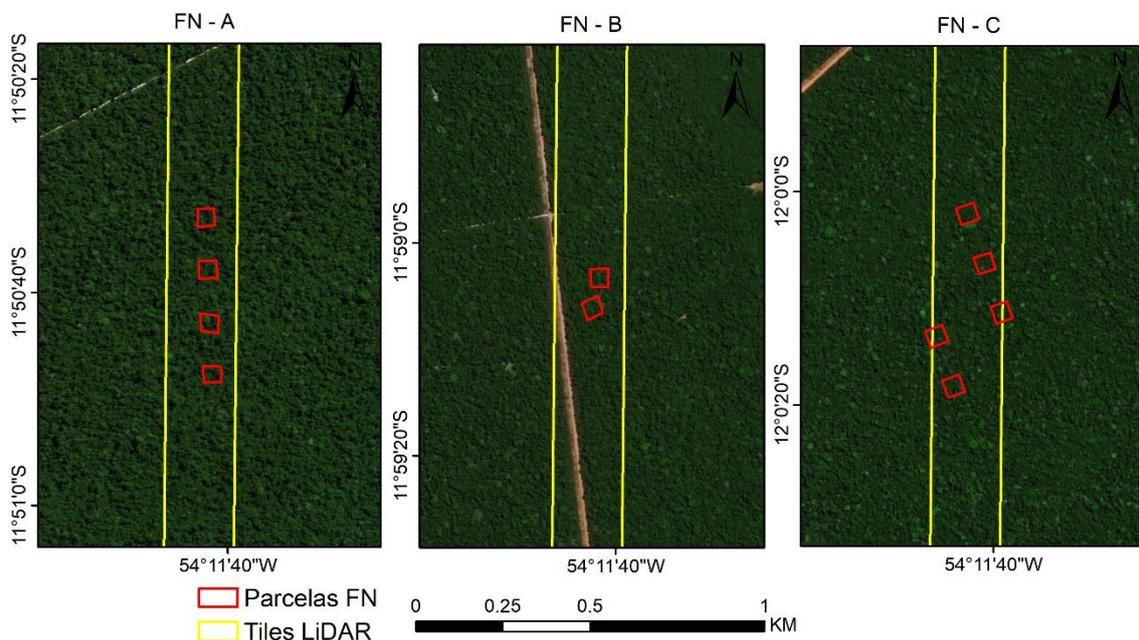
Disposição dos *tiles* da Varredura LiDAR (linhas amarelas) e parcelas instaladas (linhas vermelhas) pelo projeto PS. Área atingida por fogo durante a década de 90 (verde claro) e no ano de 2007 (azul claro), segundo Longo et al. (2016). Queimadas realizadas anualmente (amarelo claro) e trianualmente (vermelho claro) nos experimentos de Balch et al. (2008) e Brando et al. (2014). A imagem utilizada é da GeoEye do ano de 2016.

A varredura LiDAR na área TAN, foi realizada em um transecto de 1373 x 7316 m que não sobrepõem todas as parcelas de campo que foram mensuradas. Três parcelas foram totalmente sobrepostas pela varredura e quatro parcialmente.

3.5 Dados de Feliz Natal (FN)

O transecto da nuvem de pontos coletadas em FN possui medidas de 200 x 5000 m. As parcelas dessa área têm medidas de 50 x 50 m (Figura 3.6), as mesmas se localizam ao norte e sul do transecto LiDAR. As parcelas A e C estão distanciadas 100 m entre si, e todos os indivíduos acima de 0,35 m foram mensurados. As parcelas da área B estão distantes 25 m entre si e todos os indivíduos acima de 0,1 m foram mensurados.

Figura 3.6 - Áreas A, B e C.

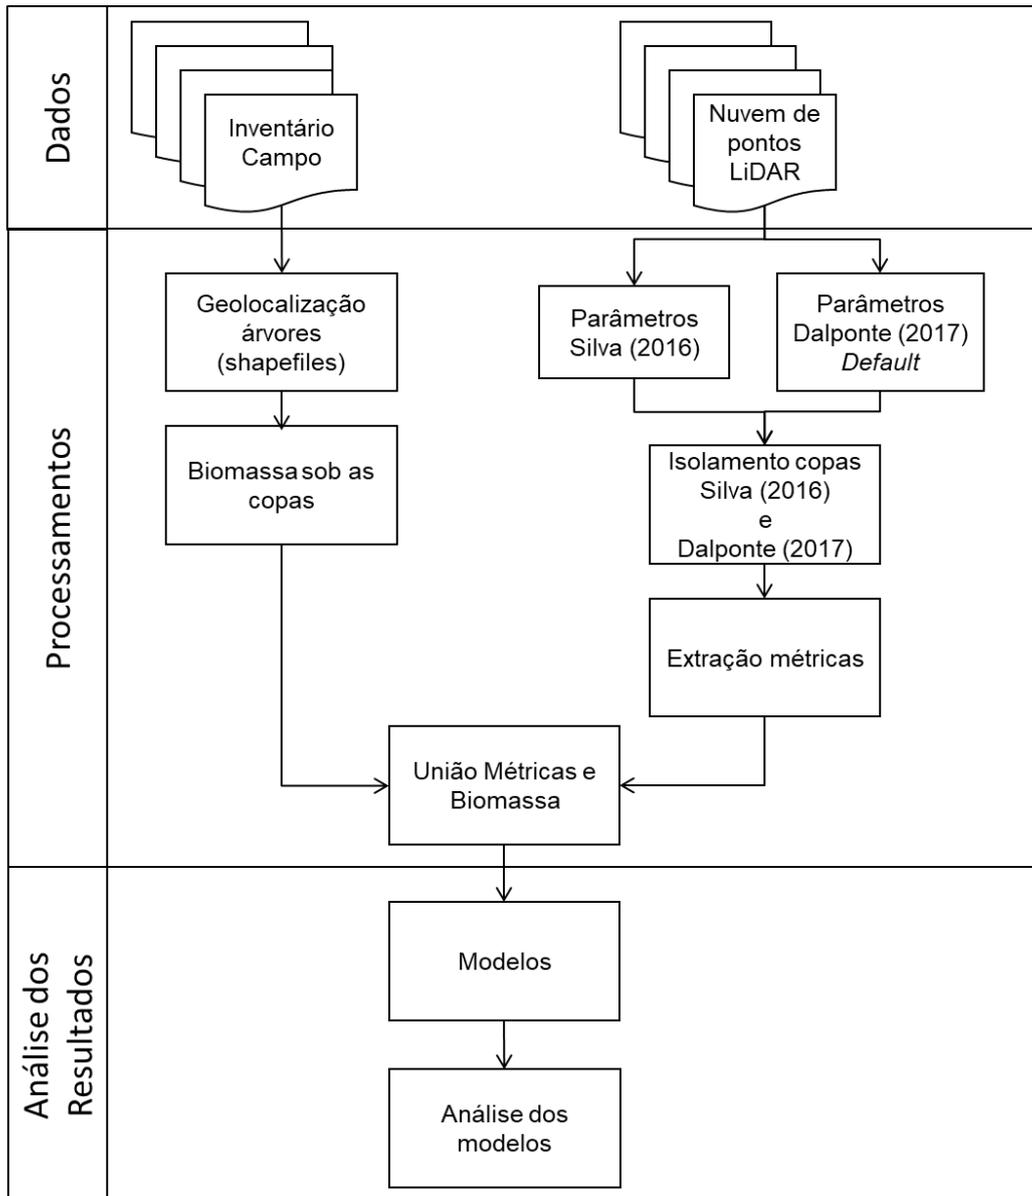


Projeção das três áreas com parcelas utilizadas no trabalho que estão no município de Feliz Natal. Em amarelo está o sobrevoo LiDAR e em vermelho a localização das parcelas. A imagem utilizada é da GeoEye do ano de 2016.

3.6 Abordagem metodológica

O fluxograma (Figura 3.7) representa basicamente os passos que foram desenvolvidos no trabalho. Estes passos foram divididos em três funcionalidades principais: dados, processamento dos dados e análise dos resultados.

Figura 3.7 – Fluxograma de trabalho.



Em seguida serão esmiuçados os processos e ferramentas contidos no fluxograma.

3.7 Processamento dos dados

Para o processamento das nuvens de pontos LiDAR utilizou-se linguagem R, com códigos adaptados do software FUSION. Este programa foi desenvolvido no Departamento de Agricultura e Serviço Florestal Estado Unidense (US

Department of Agriculture Forest Service - USDA Forest Service, no *Northwest Research Station*) por um funcionário do Governo Federal. De acordo com o Título 17, Seção 105 do Código dos Estados Unidos, o *software* não está sujeito à proteção de direitos autorais e é de domínio público, sendo principalmente uma ferramenta de pesquisa. As funções do FUSION são documentadas² pelo manual do usuário e podem ser executadas no *prompt* de comando (CMD) do sistema operacional Windows. Assim, estes comandos foram integrados com a linguagem R para otimizar suas tarefas, utilizando a função `system` (Figura 3.8).

Figura 3.8 – Demonstração de integração da linguagem R e o método FUSION.

```
1 #Recorte Nuvem de pontos
2 system(paste(file.path("C:", "Fusion", "Polyclipdata.exe"),
3               "/multifile /shape:5,*",
4               "C:/shape.shp" #Caminho de caminho de corte
5               "C:/pastaSaida", #Saida dos arquivos recortados
6               "C:/nuvemDePontos.las", #Nuvem de pontos a ser recortadas
7               sep=" "))
```

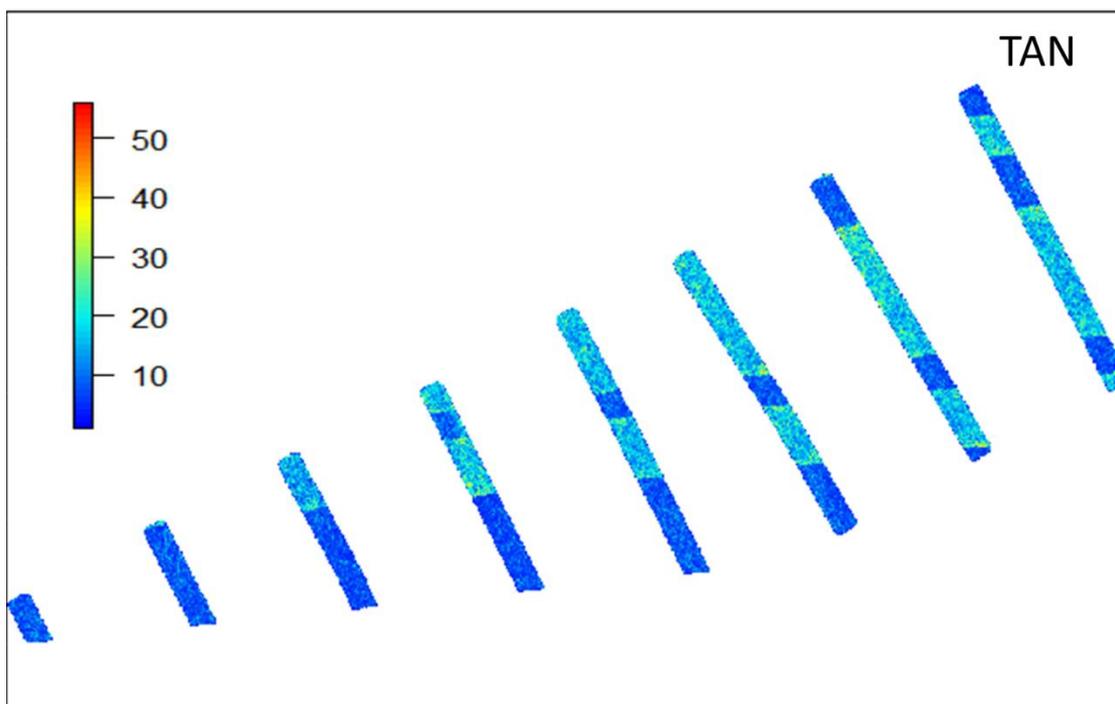
Neste caso é apresentada a ferramenta de corte da nuvem de pontos em função de um arquivo *spatial polygon shapefile*.

3.7.1 PROCESSAMENTO DOS DADOS LiDAR

Inicialmente, as nuvens de pontos LiDAR foram recortadas, utilizando-se o arquivo vetorial das parcelas com um buffer de 10 m (Figuras 3.9 e 3.10), para que árvores de bordadura não tivessem suas copas parcialmente analisadas.

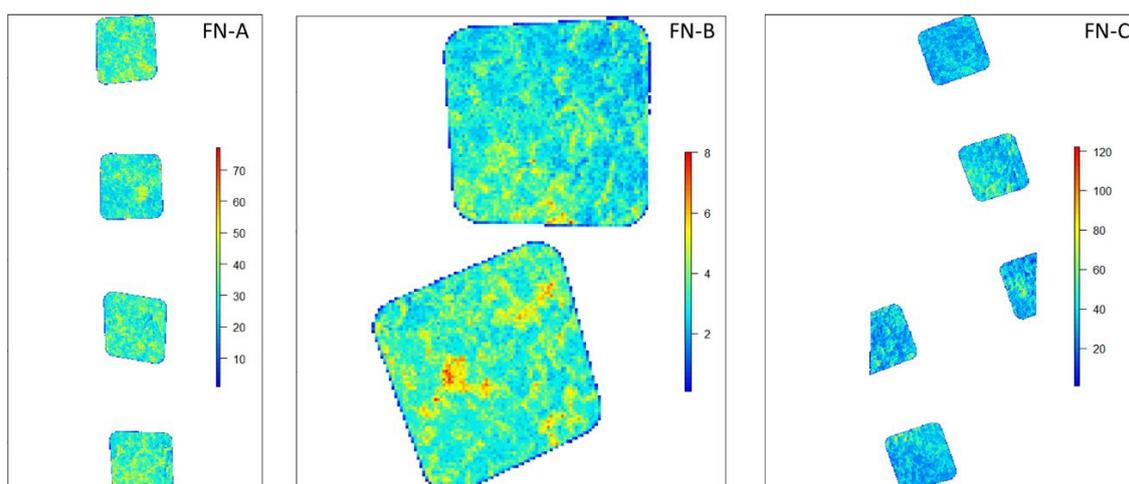
² http://forsys.cfr.washington.edu/fusion/FUSION_manual.pdf

Figura 3.9 - Densidade de pontos LiDAR nas parcelas mensuradas na área T.



A densidade está em pontos por m².

Figura 3.10 - Densidade de pontos LiDAR nas parcelas mensuradas nas áreas A, B e C.



A densidade está em pontos por m².

A densidade de pontos por m² demonstrou-se satisfatória para obtenção de biomassa (SILVA et al., 2018). A nuvens de pontos foram normalizadas,

visando transformar as coordenadas Z's da nuvem de pontos de altitude para altura. A maneira escolhida para realizar este procedimento foi subtraindo a nuvem de pontos pelo Modelo Digital do Terreno – MDT. Para isso, inicialmente são filtrados os pontos referentes ao solo e estes são interpolados para formar o arquivo *raster* MDT. O método de média ponderada foi escolhido para gerar o arquivo matricial, utilizando a altitude dos 10 pontos mais próximos ao centro do pixel para atribuir a altitude da célula (Equação 3.1).

$$a_p = \frac{a_1 * d_1 + a_2 * d_2 + \dots a_n * d_n}{n} \quad 3.1$$

Onde a_p é a altitude do pixel a ser definido, a_n a altitude dos pontos que serão usados para realizar a interpolação, e d_n é a distância do centro do pixel aos pontos (YAMAMOTO e LANDIM, 2013).

Com as parcelas normalizadas, aplicou-se dois algoritmos para isolamento de copas, um desenvolvido por Silva et al. (2017) e outro por Dalponte (2018), disponibilizados pelas bibliotecas rLiDAR e itcSegment respectivamente, ambas em linguagem R. Os parâmetros do algoritmo de Silva et al. (2017) variam de acordo com cada área estudada e sofrem influência da densidade da nuvem de pontos (pontos/m²), topologia do terreno e tipo de floresta estudada. Da nuvem de pontos é necessário obter *Canopy Height Models* (CHM), que o algoritmo utiliza a máxima altura para localizar o centroide da copa da árvore. Além do arquivo *raster* CHM, o algoritmo recebe como parâmetros a altura mínima de identificação de árvores e a janela de identificação de pontos máximos, este deve ser um valor inteiro ímpar que corresponde a n pixel observados para identificação do máximo local (Figura 3.11).

Figura 3.11 - Janela de suavização.

4,5	4,7	4,7
4,7	4,8	4,85
4,73	4,8	4,9*

Exemplo de janela 3x3 utilizada para identificação da maior altura de árvores por meio do CHM, neste caso, seria escolhido o pixel com valor 4,9, representando que nesta janela há uma árvore com ponto central de altura de 4,9 metros.

Para sanar dúvidas não encontradas na literatura, referentes ao tamanho de pixel da CHM, diferença entre um CHM suavizado ou não, e o tamanho da janela no encontro do ponto máximo para identificação das alturas das árvores, foi escolhida uma parcela aleatória, que foi o transecto 2 da área T para o teste desses parâmetros. Os parâmetros compuseram uma análise em Delineamento de Blocos Casualizados – DBC utilizando as alturas das árvores. O arranjo do experimento é exemplificado na Figura 3.12.

Tabela 3.2 - Delineamento de Blocos Casualizados.

		0,5		1		1,5		2		2,5		3		3,5		4		4,5		5	
		S	N	S	N	S	N	S	N	S	N	S	N	S	N	S	N	S	N	S	N
3	J3	J3	J3	J3	J3																
	P0,5	P0,5	P1	P1	P1,5	P1,5	P2	P2	P2,5	P2,5	P3	P3	P3,5	P3,5	P4	P4	P4,5	P4,5	P5	P5	P5
	S	N	S	N	S	N	S	N	S	N	S	N	S	N	S	N	S	N	S	N	S
5	J5	J5	J5	J5	J5																
	P0,5	P0,5	P1	P1	P1,5	P1,5	P2	P2	P2,5	P2,5	P3	P3	P3,5	P3,5	P4	P4	P4,5	P4,5	P5	P5	P5
	S	N	S	N	S	N	S	N	S	N	S	N	S	N	S	N	S	N	S	N	S
7	J7	J7	J7	J7	J7																
	P0,5	P0,5	P1	P1	P1,5	P1,5	P2	P2	P2,5	P2,5	P3	P3	P3,5	P3,5	P4	P4	P4,5	P4,5	P5	P5	P5
	S	N	S	N	S	N	S	N	S	N	S	N	S	N	S	N	S	N	S	N	S
9	J9	J9	J9	J9	J9																
	P0,5	P0,5	P1	P1	P1,5	P1,5	P2	P2	P2,5	P2,5	P3	P3	P3,5	P3,5	P4	P4	P4,5	P4,5	P5	P5	P5
	S	N	S	N	S	N	S	N	S	N	S	N	S	N	S	N	S	N	S	N	S
11	J11	J11	J11	J11	J11																
	P0,5	P0,5	P1	P1	P1,5	P1,5	P2	P2	P2,5	P2,5	P3	P3	P3,5	P3,5	P4	P4	P4,5	P4,5	P5	P5	P5
	S	N	N	N	S	N	S	N	S	N	S	N	S	N	S	N	S	N	S	N	S

Demonstração do Delineamento de Blocos Casualizados utilizado para analisar os parâmetros utilizados no transecto 2, da área T. Azul – Tamanho da janela de máximo ponto, verde – Tamanho do pixel do CHM e amarelo se o CHM é suavizado (S) ou não (N).

Foram analisados tamanhos de pixel de 0,5 a 5 metros, em um intervalo de 0,5 m, e janelas com arestas de varreduras de 3, 5, 7, 9 e 11 pixel. Para cada uma dessas variáveis foram gerados CHM's suavizados e outros não.

O algoritmo de Dalponte (2018) recebe como parâmetros os vetores das coordenadas X, Y e Z de cada ponto da nuvem de pontos; o número *European Petroleum Survey Group* (EPSG) do Sistemas de Referência de Coordenadas (SRC) em que se encontra a nuvem de pontos LiDAR; a resolução do *raster* que será utilizado para encontrar os máximos valores no CHM (*resolution*), mínimo e máximo tamanho da janela usada para detectar o local máximo (*MinSearchFilSize* e *MaxSearchFilSize*) pois é uma janela móvel, sendo que o mínimo deve ser um valor maior que 3 e o máximo deve ser um valor maior ou igual o mínimo valor. O parâmetro denominado *TRESHSeed* representa a porcentagem da máxima altura que não serão considerados árvores, este valor varia 0 a 1, que representam a porcentagem da altura das árvores; o *TRESHCrown* assim como o parâmetro anterior é relativo em função da altura, mas determina o máximo diâmetro de copa; há também um parâmetro para determinar o máximo e mínimo diâmetro (*minDIST* e *maxDIS*); a altura mínima para ser considerado árvore (*HeightThreshold*) e um parâmetro exponencial de ponderação usado para aumentar o contraste no CHM para detectar os máximos locais (*cw*). Estes parâmetros não foram testados como no algoritmo anterior, pois o algoritmo foi utilizado em floresta tropical semelhante ao sítio de estudo deste trabalho e mostrou resultados satisfatórios (Coomes et al., 2017), por isso, foram usados os parâmetros padrões do algoritmo (Tabela 3.3).

Tabela 3.3 - Parâmetros utilizados no algoritmo de Dalponte (2018).

Parâmetro	Valores
EPSG	31982 e 31981
Resolution	0,5 m
MinSearchFilSize	3 pixel
MaxSearchFilSize	7 pixel
TRESHSeed	0,55
TRESHCrown	0,6
minDIST	5 m
maxDIST	40 m
HeightThreshold	2 m
cw	1

A abordagem desenvolvida por Dalponte (2018), encontra máximos locais sobre o CHM, então, designa-se estes como topos de árvores, em seguida, usa um método de árvore de decisão para crescer coroas individuais em torno dos máximos locais. O processo passa pelas seguintes etapas: (1) um filtro passa-baixa é aplicado no arquivo *raster* CHM, para suavizar a superfície e reduzir o número de máximos locais; (2) máximos locais são localizados usando uma janela móvel com tamanho que se adapta dentro de um intervalo definido pelo usuário (mínimo e tamanho máximo) de acordo com a altura do pixel; um pixel do CHM é rotulado como máximo local se o seu valor z é maior que todos os outros valores z na janela, e com z maior que alguns valores mínimos de altura acima do solo; (3) cada máximo local é rotulado como uma "região inicial" em torno da qual a copa de uma árvore pode ser definida; as alturas dos quatro pixel vizinhos são extraídos do CHM e estes pixel são adicionados à região se a sua distância vertical do máximo local é menor do que certa porcentagem, definida pelo usuário, da altura máxima local. Este procedimento é repetido para todos os vizinhos de células que estão incluídos na região, e assim por diante iterativamente até que nenhum outro pixel seja adicionado à região; (4) cada região é formada pelos pontos de primeiro retorno da nuvem de pontos

LiDAR, estes são extraídos não levando em consideração os pontos abaixo da mínima altura de árvore fornecida pelo usuário, (5) são vetorizados as copas e estas são definidas como polígonos e pontos.

A nuvem de pontos de cada área foi utilizada como parâmetro de entrada para cada algoritmo, o resultado é o arquivo *shapefile* da copa de cada árvore. Após isoladas as copas das árvores, se identificou qual dos indivíduos mensurados em campo estavam sob a copa destas. Para isso, utilizou-se a técnica de identificar pontos, neste caso os arquivos *shapefile* das árvores dentro dos polígonos (copas das árvores). A ferramenta utilizada foi o método *point.in.poly* do pacote *spatialEco*, que atribui ao arquivo de pontos os identificadores dos polígonos que os abrangem, para então selecionar apenas as copas que continham árvores inventariadas sob suas áreas definidas. Cada copa gerada serviu de parâmetro para recortar a nuvem de pontos, gerando uma nova nuvem que representa o perfil vertical da copa isolada em questão, este novo arquivo tem um valor de identificação das árvores.

Tendo cada nuvem de pontos representando uma copa, foram extraídas métricas de cada uma utilizando a função *getMetrics*, do pacote rLiDAR. As métricas são parâmetros estatísticos que descrevem um conjunto de dados LiDAR, sendo calculadas pela elevação dos pontos e intensidades, se forem disponíveis. O produto deste método gera uma tabela com as métricas calculadas, em que cada linha da tabela representa um arquivo e cada coluna uma métrica, a primeira coluna possui o nome do arquivo em que as métricas foram extraídas. Por meio desta primeira coluna, é realizada a junção dos dados de campo de cada árvore, que estavam nos atributos dos arquivos *shapefile* das árvores de campo e as métricas extraídas de altura e de intensidade, que são:

- Número total de retornos
- Número total de 1º aos 9º retornos
- Mínimo
- Máximo
- Média
- Mediana

- Moda
- Desvio Padrão
- Variância
- Coeficiente de variação
- Distância Interquartil
- Assimetria
- Curtose
- DAM (Desvio Absoluto Médio)
- MADMedian (Mediana dos desvios absolutos)
- MADMode (Moda dos desvios absolutos)
- Momentos-L
- Assimetria do momento L
- Curtose de momento L
- Valores percentuais (1, 5, 10, 20, 25, 30, 40, 50, 60, 70, 75, 80, 90, 95, 99)

Com as métricas acima é possível calcular razões, que acentuam a dispersão dos valores da dispersão vertical dos pontos coletados da nuvem de pontos (MCGAUGHEY, 2015):

- Porcentagem dos primeiros retornos / moda da altura
- Porcentagem de todos os retornos / altura
- Número total de retornos / total primeiros retornos * 100

A métrica de máxima altura foi considerada a altura total da árvore em questão e foi correlacionada com as árvores que estavam sob a copa, mensurada em campo. Após as métricas extraídas, estas foram analisadas por meio da correlação de Pearson, que mede o grau da relação linear entre variáveis quantitativas, que representa a intensidade de uma relação. Estas podem ser inversamente proporcionais ou diretamente proporcionais, com valores de -1 a 1 (PORTAL ACTION, 2018).

As métricas foram utilizadas para formar um modelo de regressão linear com a biomassa viva acima do solo (AGB). Quando se tem apenas um parâmetro de

entrada, há uma Regressão Simples e quando há mais de um parâmetro de entrada se tem uma Regressão Multivariada (PORTAL ACTION, 2018). A técnica de regressão linear auxilia o campo da engenharia florestal, estudando a relação entre uma variável dependente (Y) e variáveis independentes (X_1, \dots, X_p) (RODRIGUES, 2012). Em estudos florestais que relacionam dados LiDAR e biomassa, a biomassa pode ser considerada a variável dependente e as variáveis independentes podem ser as métricas obtidas da nuvem de pontos LiDAR (FERRAZ et al., 2016). A regressão é feita a fim de encontrar os coeficientes do modelo que são representados pela letra grega beta (β) que descrevem matematicamente a relação das variáveis independentes pela variável dependente, como é descrito na Equação 3.2 (MACHADO e FIGUEIREDO FILHO, 2003).

$$Y_i = \beta_0 + \beta_1 X_i + \dots + e_i \quad 3.2$$

Em que Y_i é a variável de interesse, β_0 é uma constante que representa a interceptação da reta com o eixo vertical, β_1 é a constante que representa a inclinação da reta, X_i é a variável independente que define o fator de inclinação da equação e e_i inclui os possíveis erros residuais do ajuste (MACHADO e FIGUEIREDO FILHO, 2003).

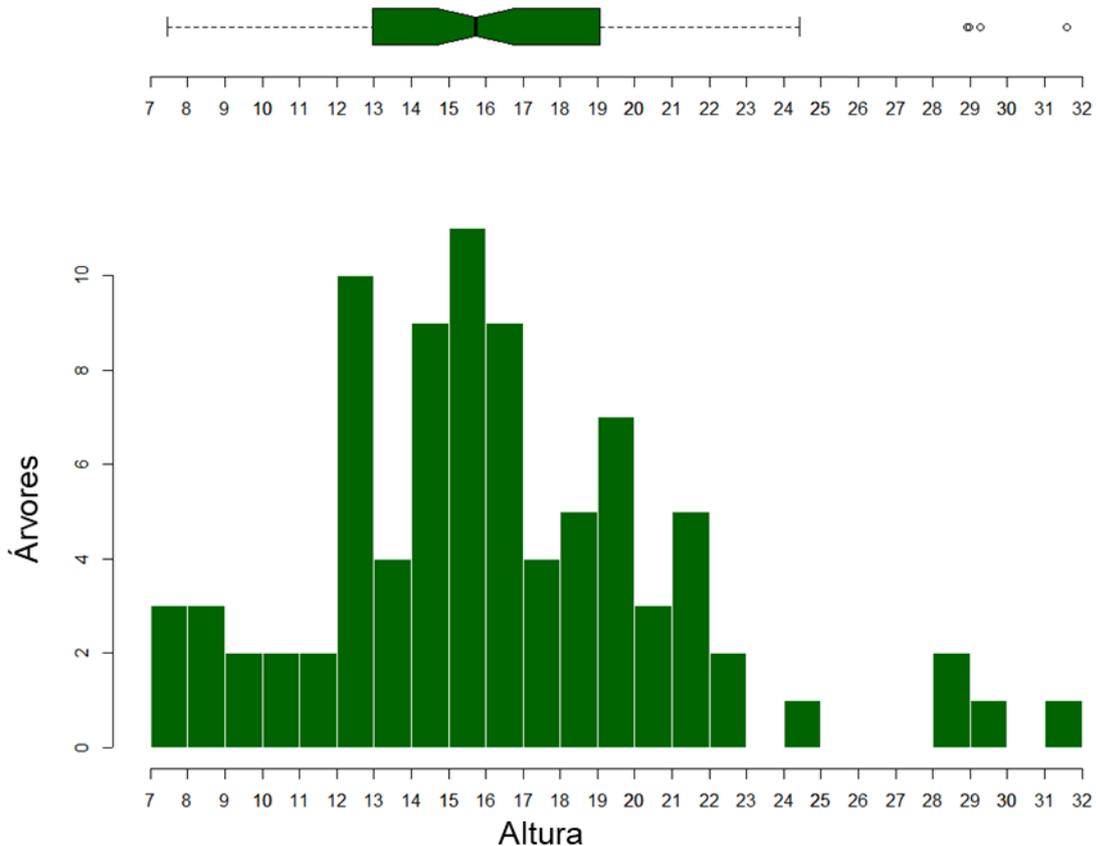
Como há várias métricas, se faz necessário averiguar se estas são correlacionadas, o desejado é que não sejam, para serem consideradas ortogonais. Dificilmente há total individualidade entre as métricas, porém, se houver intensa correlação, a regressão não pode ser considerada confiável (HOERL et al., 1975), por isso, foram utilizados dois limiares de corte 0,5 e 0,8. Métricas com correlações superiores a estes valores foram eliminadas, tanto diretas ou inversamente proporcionais. Para realizar a eliminação das métricas, foi utilizada a função *findCorrelation*, do pacote *caret*, que pesquisa por meio de uma matriz de correlação e retorna um vetor de números inteiros correspondentes às colunas a serem removidas para reduzir as correlações de pares. Neste caso, os valores absolutos de correlações de pares são considerados em duas variáveis que têm uma alta ligação.

Após eliminadas as métricas, as restantes foram utilizadas como parâmetro no método em um modelo de busca exaustiva, avanço ou retrocesso gradual ou de substituição sequencial, que retorna os melhores modelos separados com diferentes critérios de seleção de modelo como AIC, BIC, CIC, DIC e R^2_{adj} (WOLFINGER, 1993). Neste trabalho foi utilizado o Coeficiente de Determinação Ajustado - R^2_{adj} . O Coeficiente de Determinação Ajustado - R^2_{adj} define quanto as métricas selecionadas para o modelo de regressão linear conseguirão explicar a variável dependente, no caso deste trabalho, a biomassa arbórea viva da floresta tropical. Na prática, o R^2_{adj} é a medida descritiva de ajuste do modelo que está ligado intimamente do valor de observações, que neste caso são as árvores isoladas. Mesmo não havendo um consenso estatístico sobre a quantidade exata de amostras que devem ser usadas em um modelo, tem-se que o R^2_{adj} tende a se estabilizar com 6% de amostragem da área total observada para florestas nativas (FIGUEIREDO FILHO et al., 2014).

4 RESULTADOS

Para iniciar as análises dos parâmetros de algoritmos utilizados pelo algoritmo de Silva et al. (2017), foi escolhida uma parcela aleatória na identificação das árvores, o transecto 2 da área TAN. Foram 86 árvores vivas com alturas totais superiores a 7 m mensuradas nesta parcela, este parâmetro foi escolhido após análise do histograma das alturas das árvores coletadas na parcela (Figura 4.1).

Figura 4.1 - *Box plot* e distribuição das alturas das árvores presentes no transecto 2, da área T.



O parâmetro de altura mínima foi utilizado para definir a altura das árvores presentes na parcela e então foram utilizados os diferentes tamanhos de janelas e pixel em arquivos com dados suavizados e não suavizados. Estatisticamente, o tamanho do pixel utilizado para encontrar a altura das árvores não apresentou diferença pois, o *p value* foi igual a 1. Ressaltando

fortemente que este parâmetro não interferiu na média das alturas estimadas por meio da nuvem de pontos. Em oposto, o parâmetro de altura e suavização do CHM apresentaram valores inferiores a 2^{-16} (Tabela 4.1).

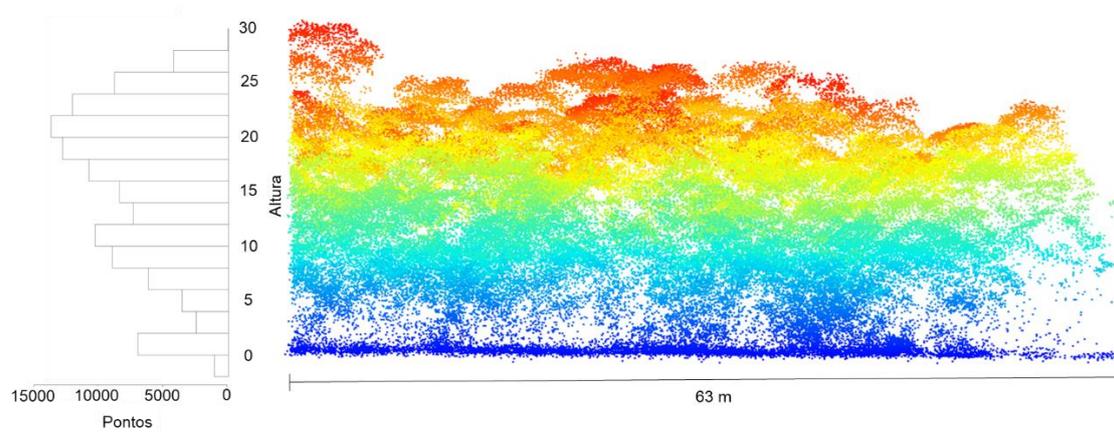
Tabela 4.1 - Tabela ANOVA, apresentando a soma dos quadrados, erro quadrático, valor F, p value e sua significância.

		Soma dos Quadrados	Erro quadrático	F	p value	
Pixel	8	0	0.05	0.0065	1	
Janela	4	3712	927.97	128.8324	$< 2^{-16}$	***
Suavizado	1	1559	1558.61	216.386	$< 2^{-16}$	***
Resíduo	9180	66123	7.2			

Nível de significância: 0^{***} 0.001^{***} 0.01^{**} 0.05^{*} 0.1['] 1

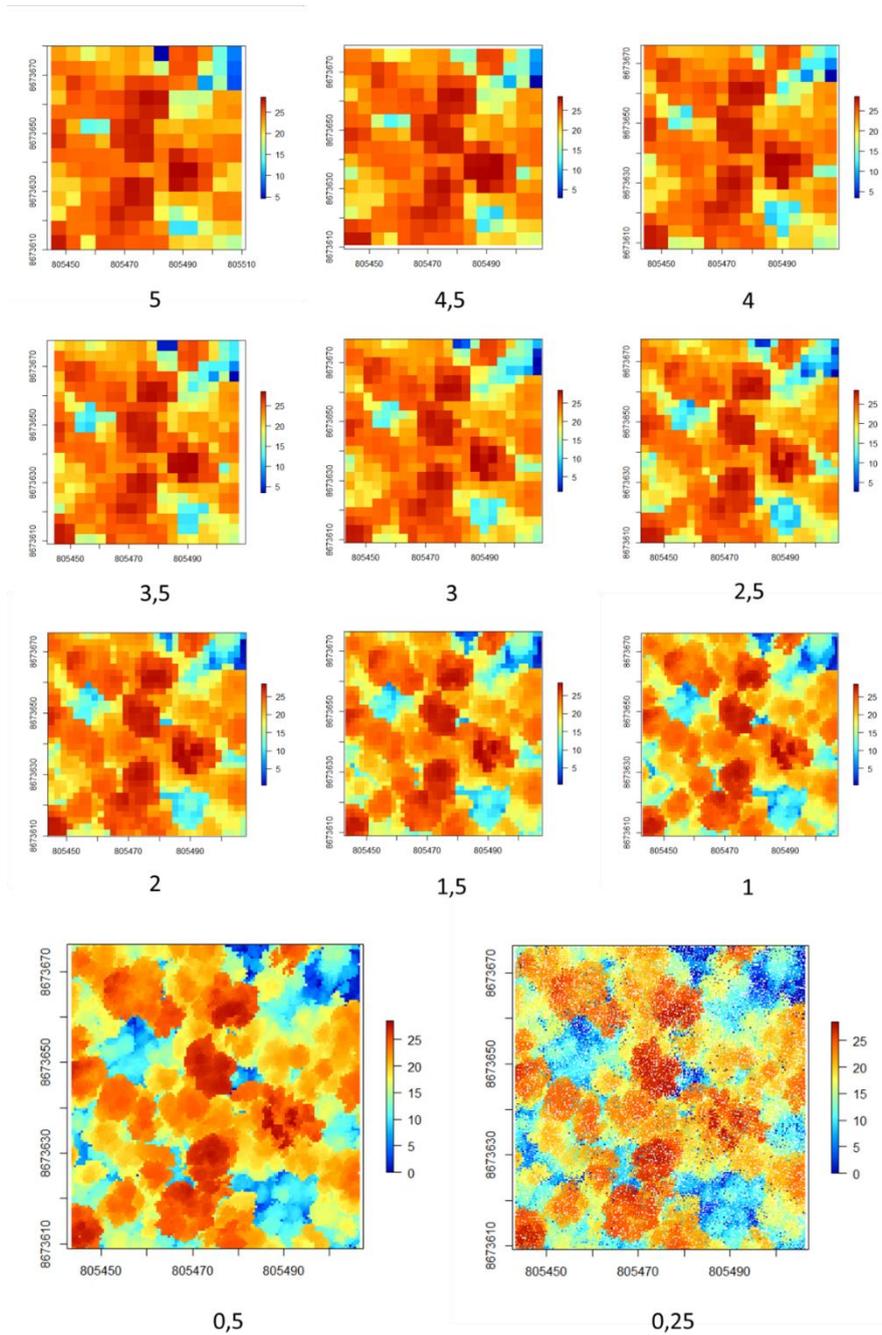
Foi necessário realizar a suavização do CHM, para eliminar pixel que não eram representativos, dependendo da escala em que foram utilizados, e também eliminar possíveis ruídos que possam ocorrer, mesmo que isso acarrete em perda de informação geométrica da altura (BALTSAVIAS et al., 1999). Foram analisados pixel de até 0,25 m para observar a influência da densidade de pontos (Figura 4.2).

Figura 4.2 - Histograma da densidade de pontos em relação à altura da nuvem utilizada para demonstrar o tamanho de pixel do CHM.



Observando os CHMs suavizados (Figura 4.4) e não suavizados (Figura 4.3), percebeu-se que os *rasters* suavizados apresentam menor ruído de pixel e bordas mais arredondadas.

Figura 4.3 - CHMs não suavizados.

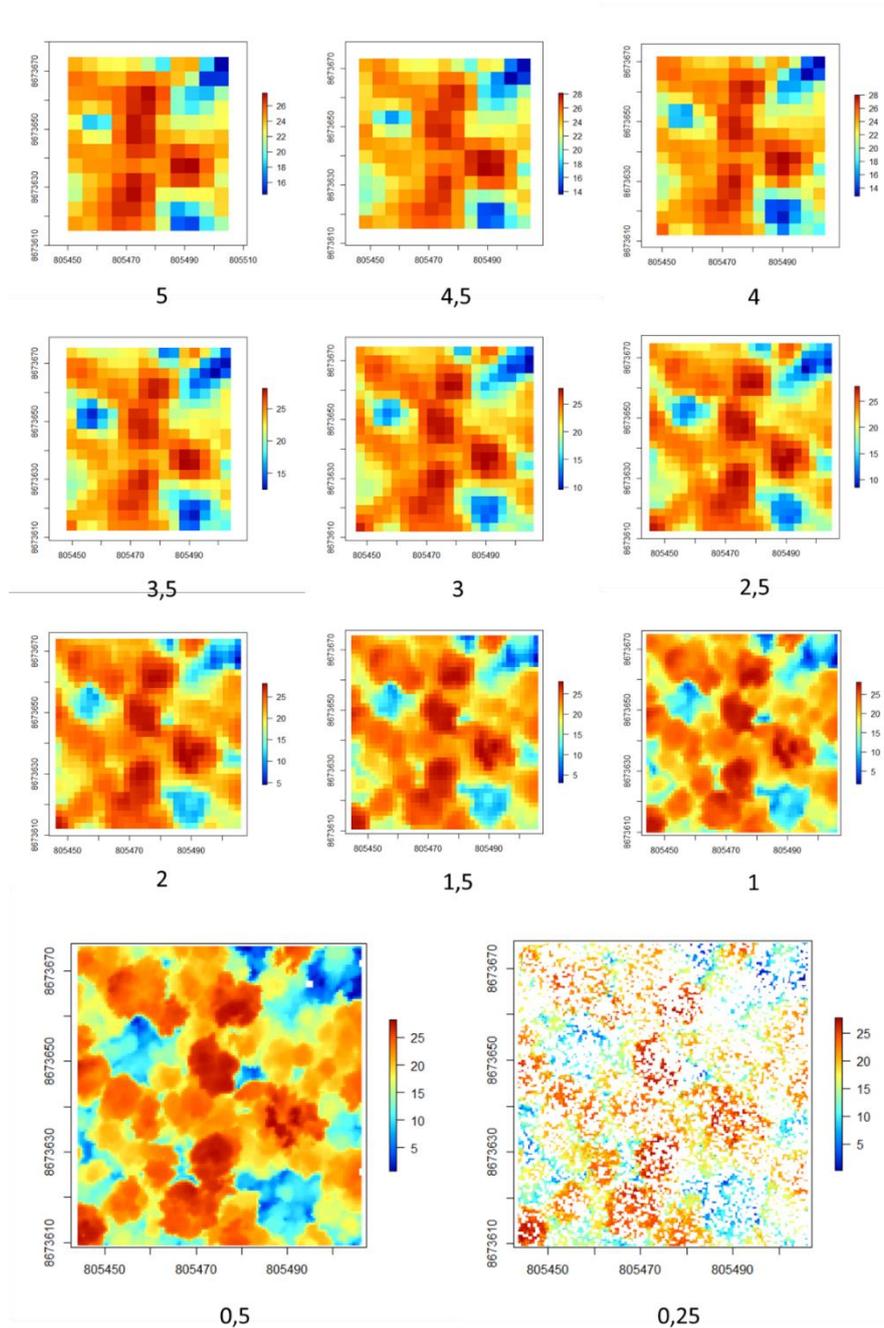


Demonstrando a silhueta das copas das árvores em função do tamanho de pixel utilizado, gerado a partir da nuvem de pontos LiDAR.

Ao utilizar o tamanho de pixel de 0,25 ocorreram diversos pixel que não foram contemplados, possivelmente devido à densidade de pontos. Em todos *rasters*

suavizados ocorreu a diminuição da extensão dos mesmos, eliminando-se a coluna de pixel de bordas.

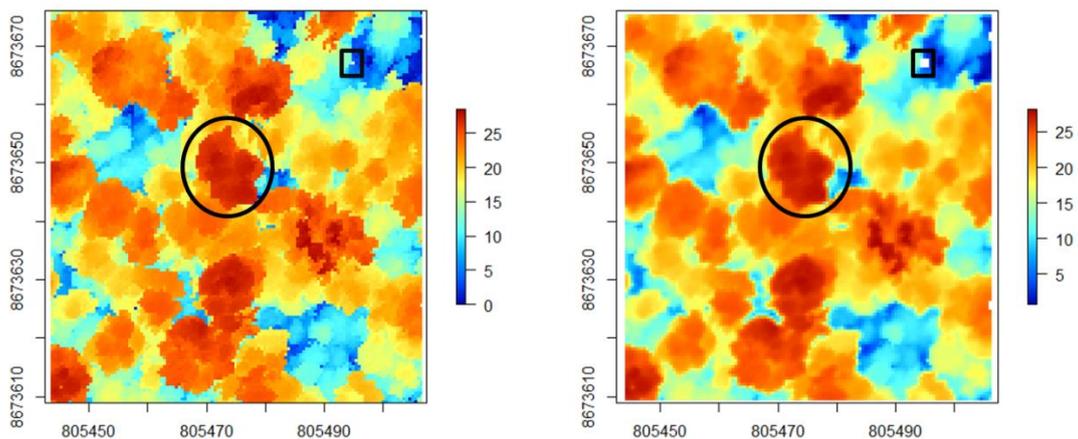
Figura 4.4 - CHMs não suavizados.



Demonstrando a silhueta das copas das árvores em função do tamanho de pixel utilizado, gerado a partir da nuvem de pontos LiDAR.

O menor arredondamento das bordas das árvores foi suavizado nas imagens em que foram aplicados o filtro, porém, valores nulos foram propagados para toda a janela de suavização, de 3 por 3 pixel (Figura 4.5).

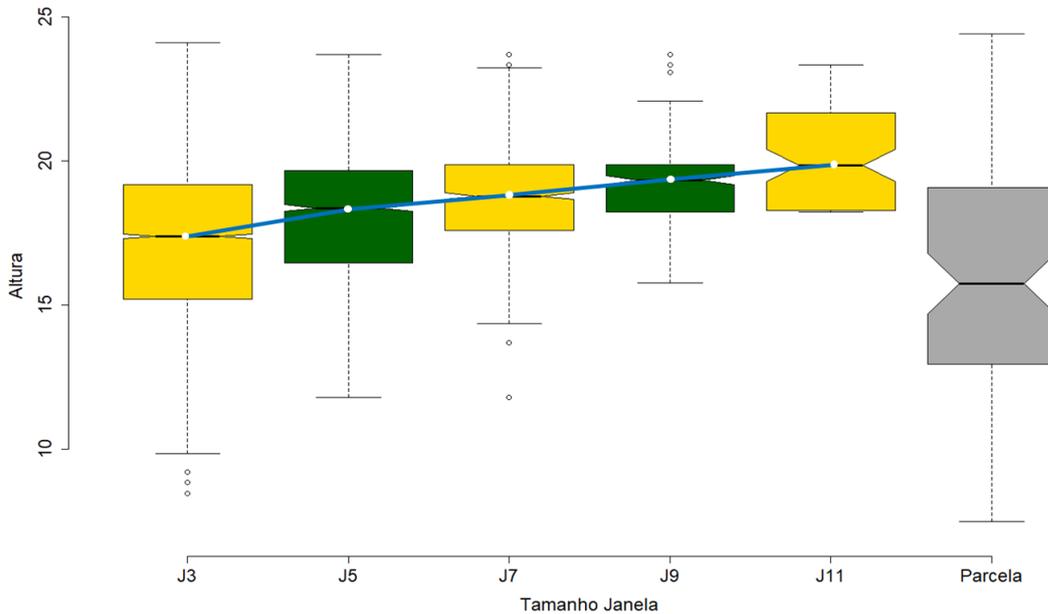
Figura 4.5 - Demonstração da suavização das bordas e propagação de valores nulos.



Comparação da resolução de 0,5 m do CHM, utilizada para segmentação de copas no algoritmo de Silva et al. (2017). O círculo destaca a suavização na borda em uma das árvores e o retângulo ressalta os valores nulos que foram gerados ao se passar o filtro de suavização.

Ao utilizar o algoritmo focal sobre a imagem CHM com resolução de pixel de 0,25, foram gerados vários valores nulos no *raster* de saída, por isto, utilizou-se a resolução de 0,5 m para realizar o isolamento das copas. Os valores nulos que poderiam interferir nas estimativas da suavização das imagens foram interpolados, utilizando os valores dos 8 pixel adjacentes. Com o aumento do tamanho da janela, há incremento nas alturas das árvores que são encontradas, contudo, diminui a quantidade de árvores estimadas (Figura 4.6 – Linha azul). Ao comparar as alturas encontradas em cada tamanho de copa, com as alturas do transecto (Figura 4.6), de maneira subjetiva, decidiu-se utilizar 3 pixel como o tamanho de janela para encontrar o ponto máximo da altura.

Figura 4.6 - *Boxplot* das alturas encontradas no transecto 2 da área T.



Boxplot das alturas encontradas com janelas 3, 5, 7, 9 e 11 pixel, nas cores amarelos e verdes, em comparação às alturas das árvores mensuradas no transecto da área T. O traço horizontal no interior do *boxplot* define a mediana dos dados observados e seus limites inferiores e superiores, são os interquartis das alturas de cada janela, abrangendo 50% dos dados. As linhas pontilhadas indicam aproximadamente dois desvios padrões, os pontos que estão fora destas linhas são considerados outliers. A abertura lateral dos *boxplots*, se coincidirem uma com a outra, indicam que a média dos valores são estatisticamente iguais ao nível de 95%. A linha azul liga a mediana da altura de cada janela.

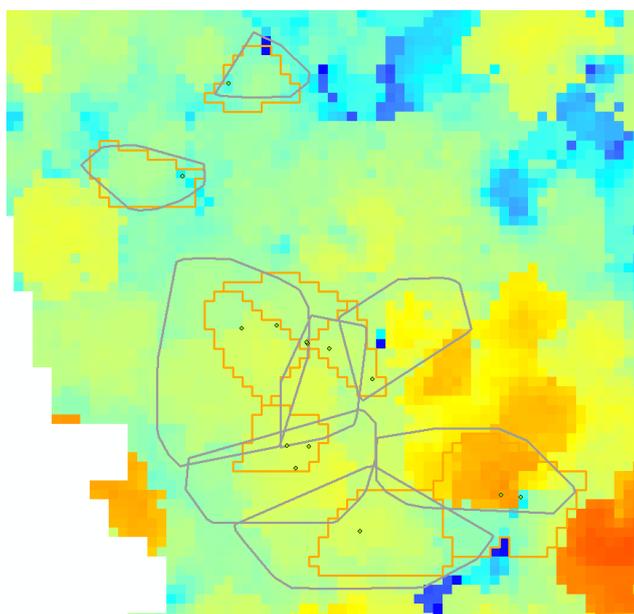
Após estes parâmetros definidos, foram isoladas as copas de cada área separadamente. Pela posição geográfica, não houve omissão para encontrar copas de árvores, porém, houve inclusão, em que uma copa definida pelo algoritmo sobrepôs mais de uma árvore (Tabela 4.2). Nestes casos, as biomassas das árvores foram somadas, para que as métricas extraídas representassem todos indivíduos sob a copa.

Tabela 4.2 - Tabela de comparação de árvores observadas em campo em comparação a copas encontradas pelos algoritmos.

Área	Árvores		
	Campo	Silva et al. (2017)	Dalponte (2018)
A	84	70	61
B	237	161	133
C	69	57	57
T	442	275	369

Os algoritmos utilizados para isolamento de copas, não apresentaram discrepância no número de copas isoladas, inclusive na área C, os mesmos números de árvores foram encontrados por ambos. O algoritmo de Dalponte (2018) demonstrou uma maior suavização nas bordas das árvores, enquanto o algoritmo de Silva et al. (2017), mantém as bordas serrilhadas (Figura 4.7).

Figura 4.7 - Comparação das bordas encontradas pelos algoritmos.



Demonstração do isolamento de copas pelos algoritmos de Silva et al. (2017) em laranja e Dalponte (2018), em cinza. Os pontos são as árvores mensuradas em campo e sob esta, está o CHM (0,5 m de resolução) utilizado para isolar as copas.

Utilizando o Algoritmo de Silva et al. (2017) não ocorre a sobreposição de copas igual ao algoritmo de Dalponte (2018). Neste último caso, as biomassas foram somadas para ambas as árvores. Nas áreas A, C e T a concentração de árvores foi superior nas sub-parcelas do projeto *Paisagens Sustentáveis*, em que as árvores com menor diâmetro foram mesuradas (Figuras 4.8 e 4.9).

Figura 4.8 - Demonstração de isolamento de árvores no transecto 1 da área T.

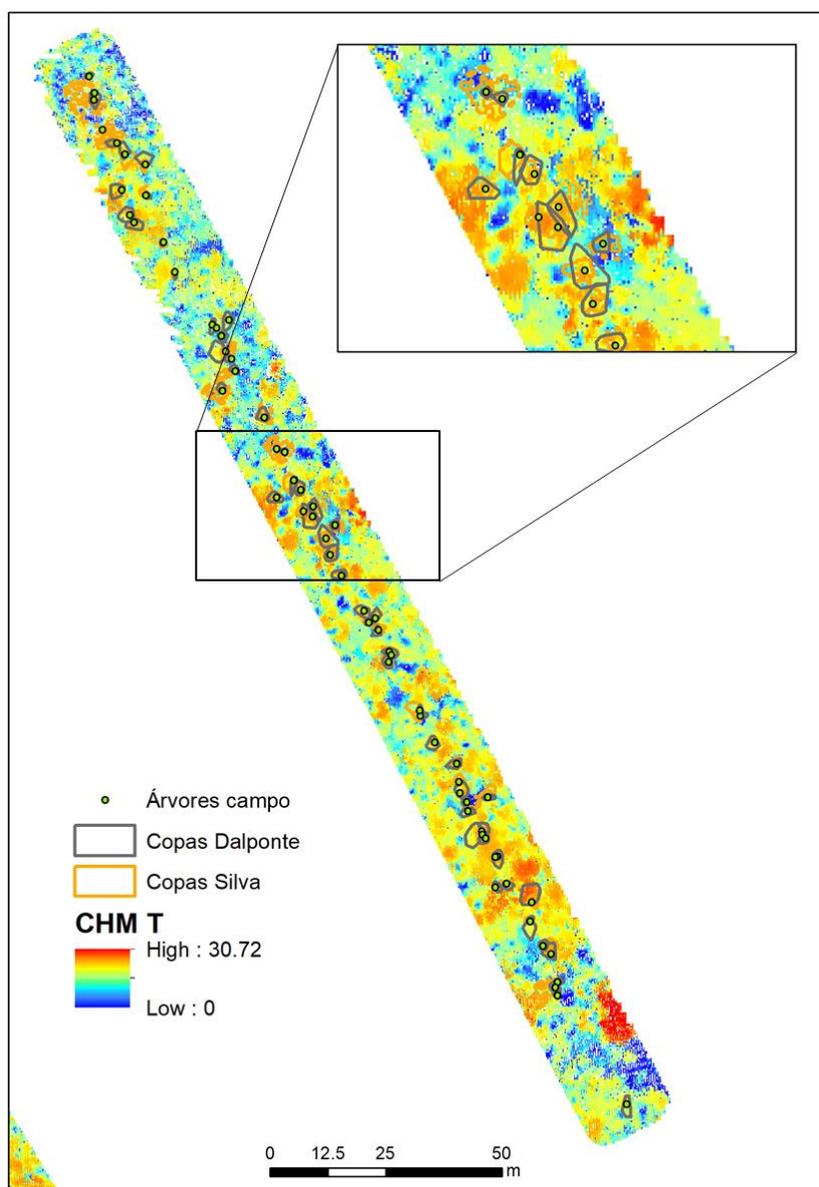
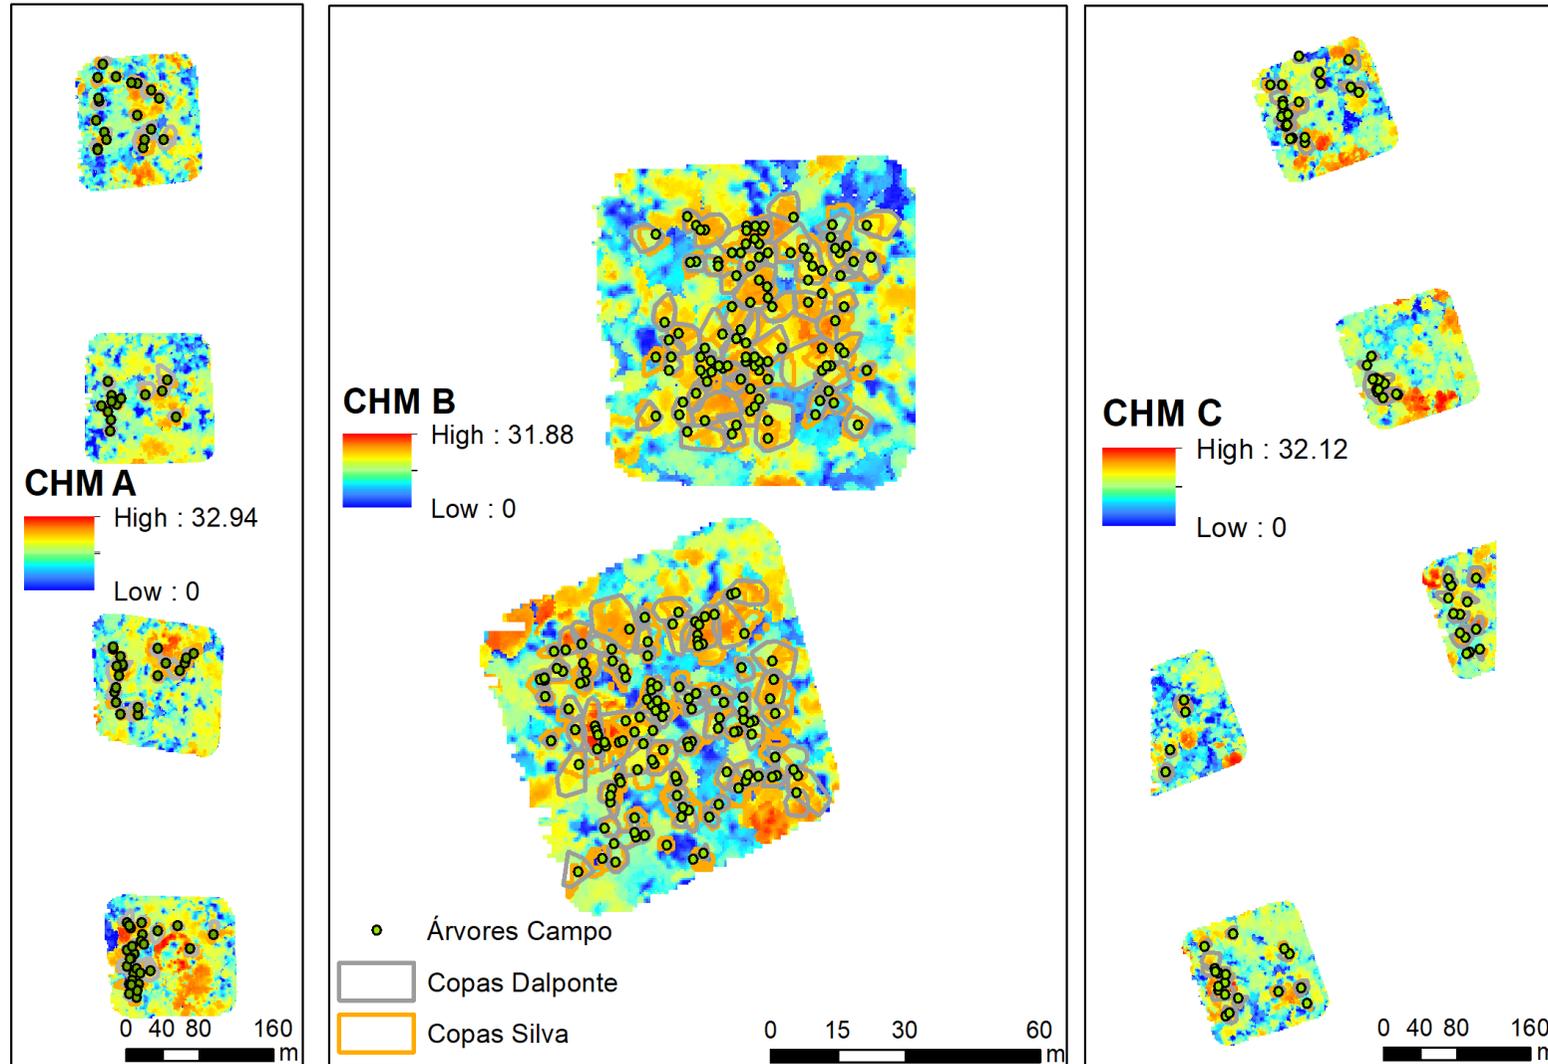
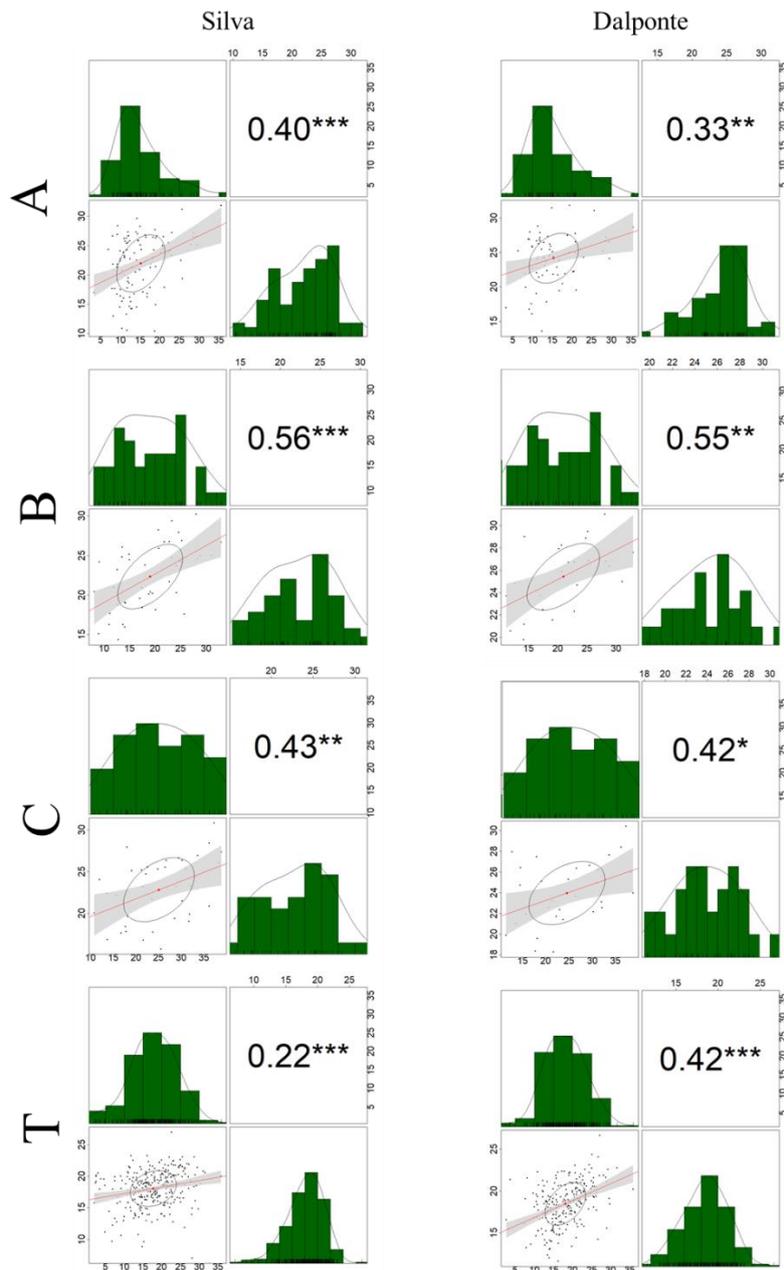


Figura 4.9 - Demonstração do isolamento de árvores nas parcelas das áreas de FN.



Após isoladas as copas, foram comparadas as alturas das árvores mensuradas em campo e as encontradas pelo algoritmo. Nos casos em que haviam mais de uma árvore sob a copa, utilizou-se a maior copa.

Figura 4.10 - Histograma, correlação de Pearson e comparação entre valores observados e estimados para a altura das árvores em cada área e em cada algoritmo.

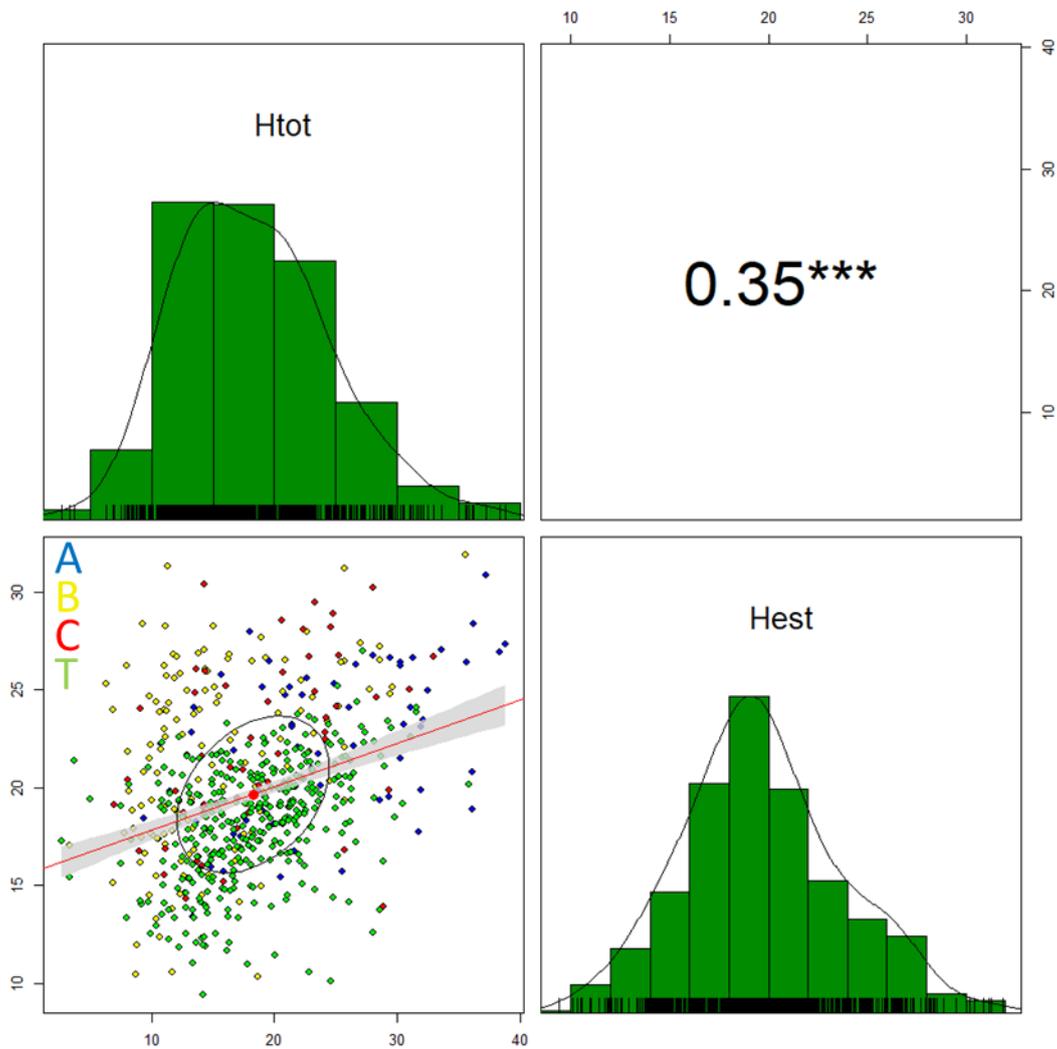


Para cada área estudada, a imagem acima mostra um gráfico de dispersão (quadrados inferiores esquerdo), a linha vermelha representa a regressão linear, os ajustes são mostrados para y por x e x por y, o ponto vermelho

representa a média. Elipses de correlação (em preto) e intervalo de confiança de um modelo são demonstrados (cinzas). As distribuições univariadas são representadas como histogramas e gráficos de densidade de *kernel*, os quadrados superiores esquerdos representam as árvores observadas e os quadrados inferiores direitos representam as alturas estimadas pelos algoritmos. Os valores de correlações de Pearson são descritos nos quadrados superiores direitos, com estrelas que descrevem os níveis de significância (‘ ’ > 0.05, ‘*’ ≤ 0.05, ‘**’ ≤ 0.01, ‘***’ ≤ 0.001 e ‘****’ ≤ 0.0001). A área que apresentou melhor correlação com as alturas foi a área B, mas ao analisar o intervalo de confiança ocorreram diversos pontos discrepantes, em todos os estratos de alturas.

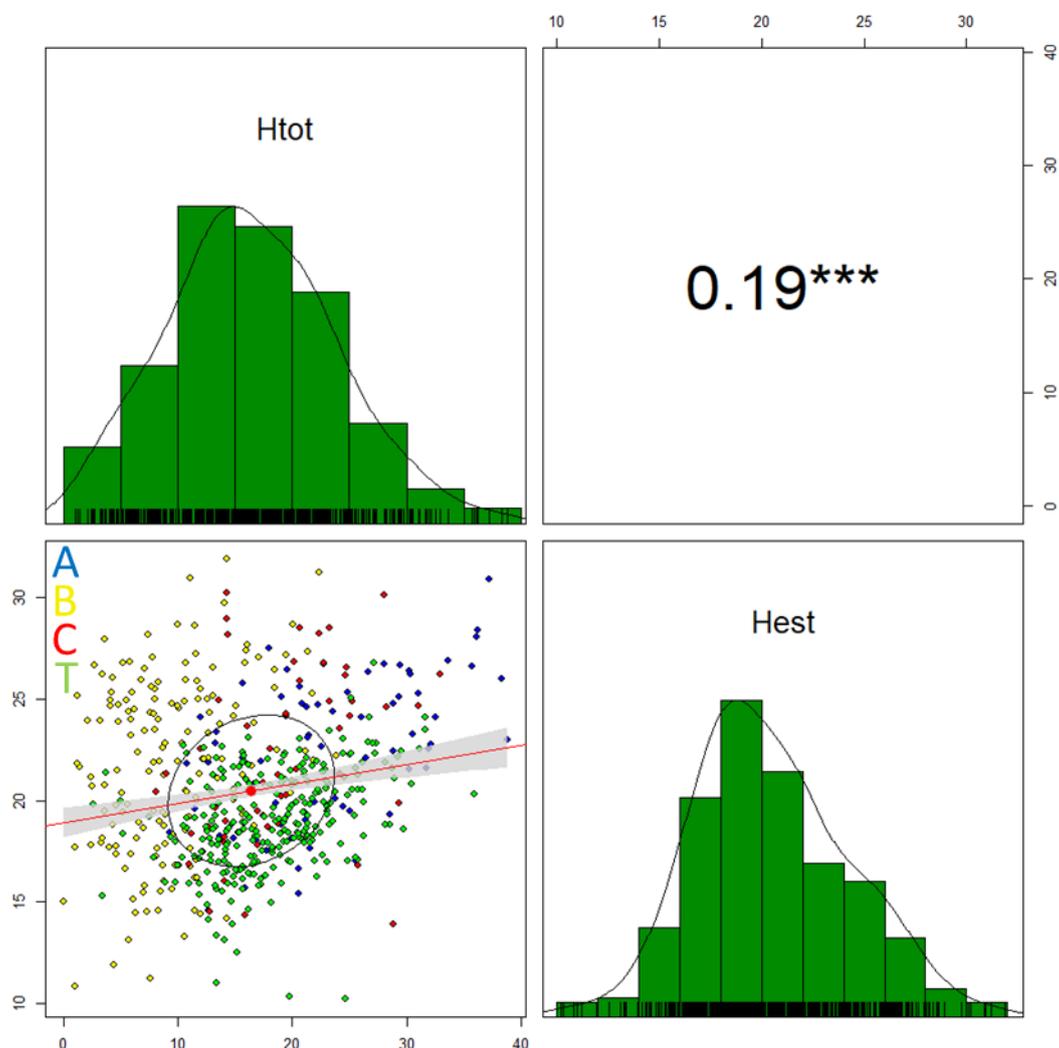
O ajuste da área T apresentou um modelo com menor amplitude de erro (Figura 4.10 – T), possivelmente por apresentar maior quantidade de amostras. Nesta área, o algoritmo desenvolvido por Silva et al. (2017) apresentou melhor angulação, se comparado ao de Dalponte (2018), demonstrando menor correlação. As áreas A e B apresentaram intervalos em seus histogramas em que não houve altura de árvores observadas, reforçando o corte seletivo recente nestas áreas.

Figura 4.11 - Correlação das alturas encontradas pelo algoritmo Dalponte (2018). Cada área está com uma coloração, em azul está a área A, em amarelo a B, em vermelho a C e em verde a T.



O algoritmo de Dalponte (2018) apresentou uma correlação de Pearson de 0,35, com um nível de significância inferior a 1%, utilizando todas as árvores. Apresentou um histograma similar ao encontrado com as árvores mensuradas em campo.

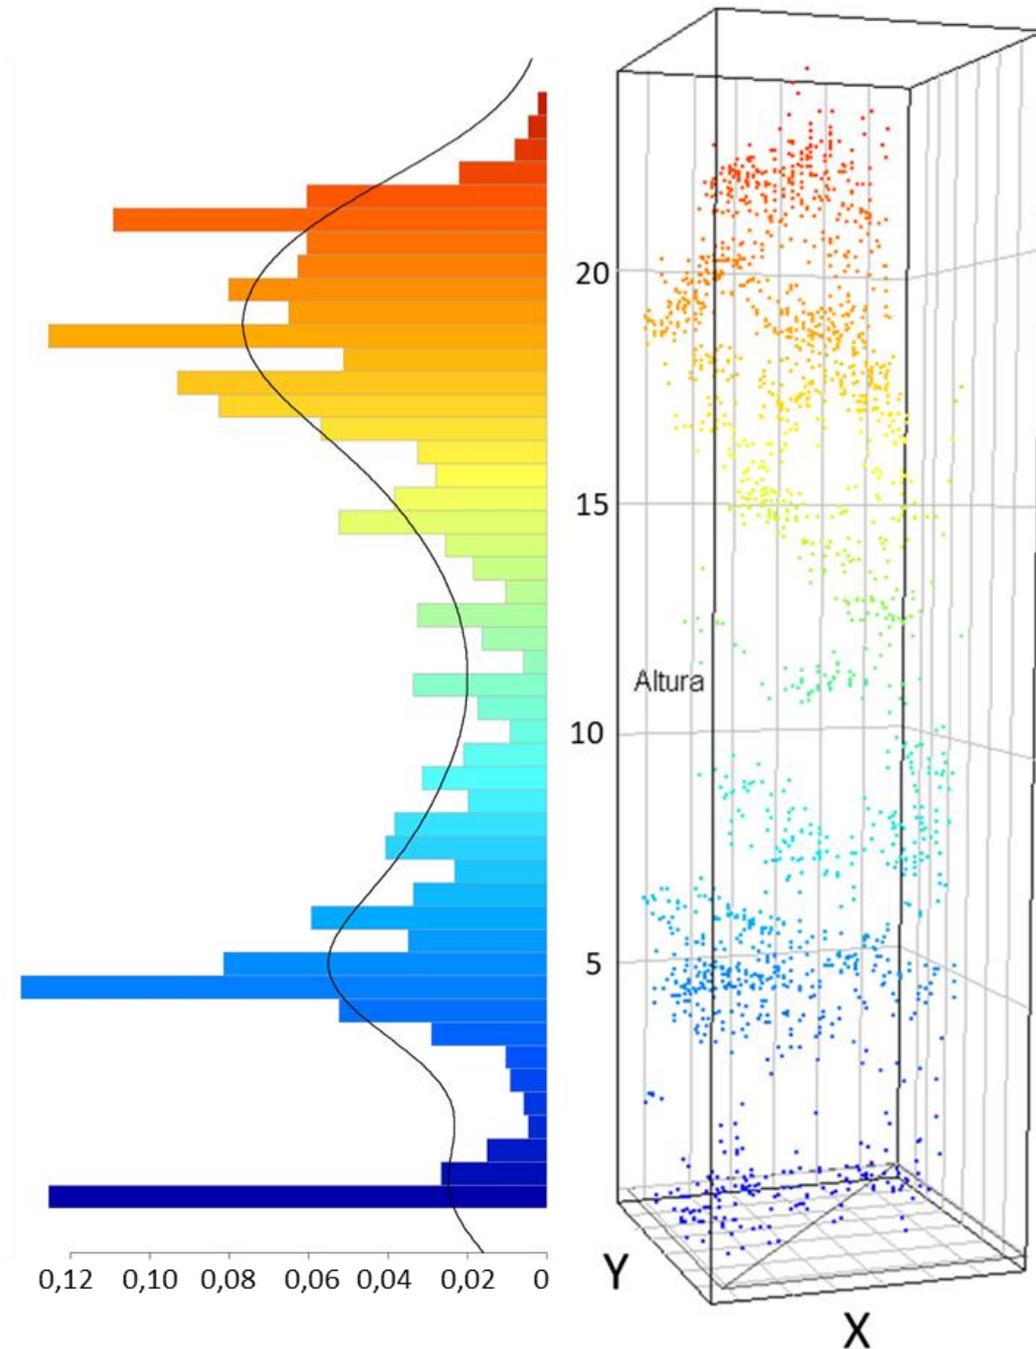
Figura 4.12 - Correlação das alturas encontradas pelo algoritmo de Silva et al. (2017). Cada área está com uma coloração, em azul está a área A, em amarelo a B, em vermelho a C e em verde a T.



Assim como no algoritmo anterior, o desenvolvido por Silva et al. (2017), demonstrou um histograma similar com o das árvores mensuradas em campo, com uma distribuição quase sobreposta, porém, sua correlação de Pearson foi inferior, 0,19 ao nível de significância de 1%.

Após o isolamento das copas das árvores, estas foram usadas para recortar a nuvem de pontos na posição X e Y, gerando novas nuvens (Figura 4.13). Estas novas nuvens representaram árvores individuais ou árvores do dossel e de sub-bosque que estejam sob as árvores dominantes.

Figura 4.13 – Representação da nuvem de pontos do isolamento de um isolamento de copa e o histograma da dispersão vertical.

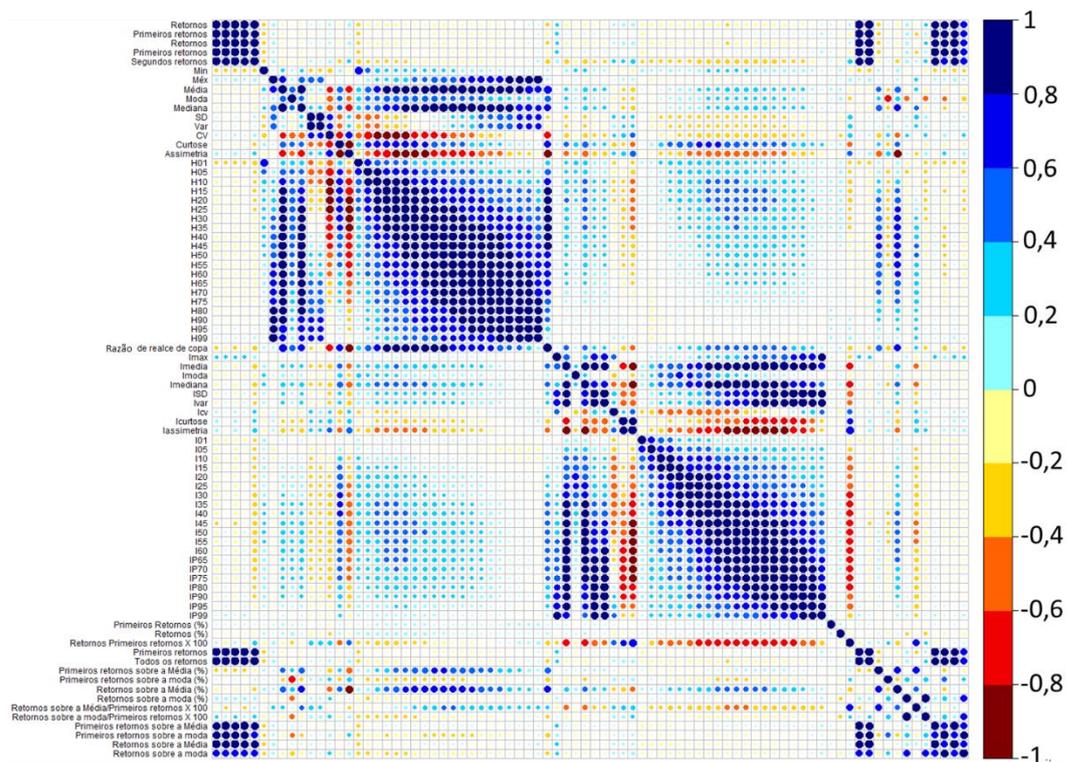


Ao lado direito está a nuvem de pontos tridimensional em um plano cartesiano 3D, os *grids* de altura possuem intervalos de 5 m no eixo Z e 1 m nos demais. O *grid* de solo possui arestas de 1 m. Ao lado esquerdo, o histograma dos valores das alturas coletadas pelo sistema LiDAR e a curva do histograma suavizada, com a densidade de pontos média por estrato.

No exemplo da Figura 4.13, os dois algoritmos utilizados encontraram apenas uma copa, porém, ao analisar o histograma percebe-se que na altura de 5 metros há outra árvore pela densidade de pontos do histograma. A medição em campo desta árvore apresentou 6,10 m de altura e a árvore do dossel possui 26,50 m. A análise deste tipo de histograma foi utilizada por Ferraz et al. (2016) para isolar árvores do sub dossel.

Após todas as nuvens de pontos serem recortadas por cada copa isolada em cada algoritmo, foi realizada a análise de correlação das métricas (Figura 4.14) para ajuste do modelo de biomassa.

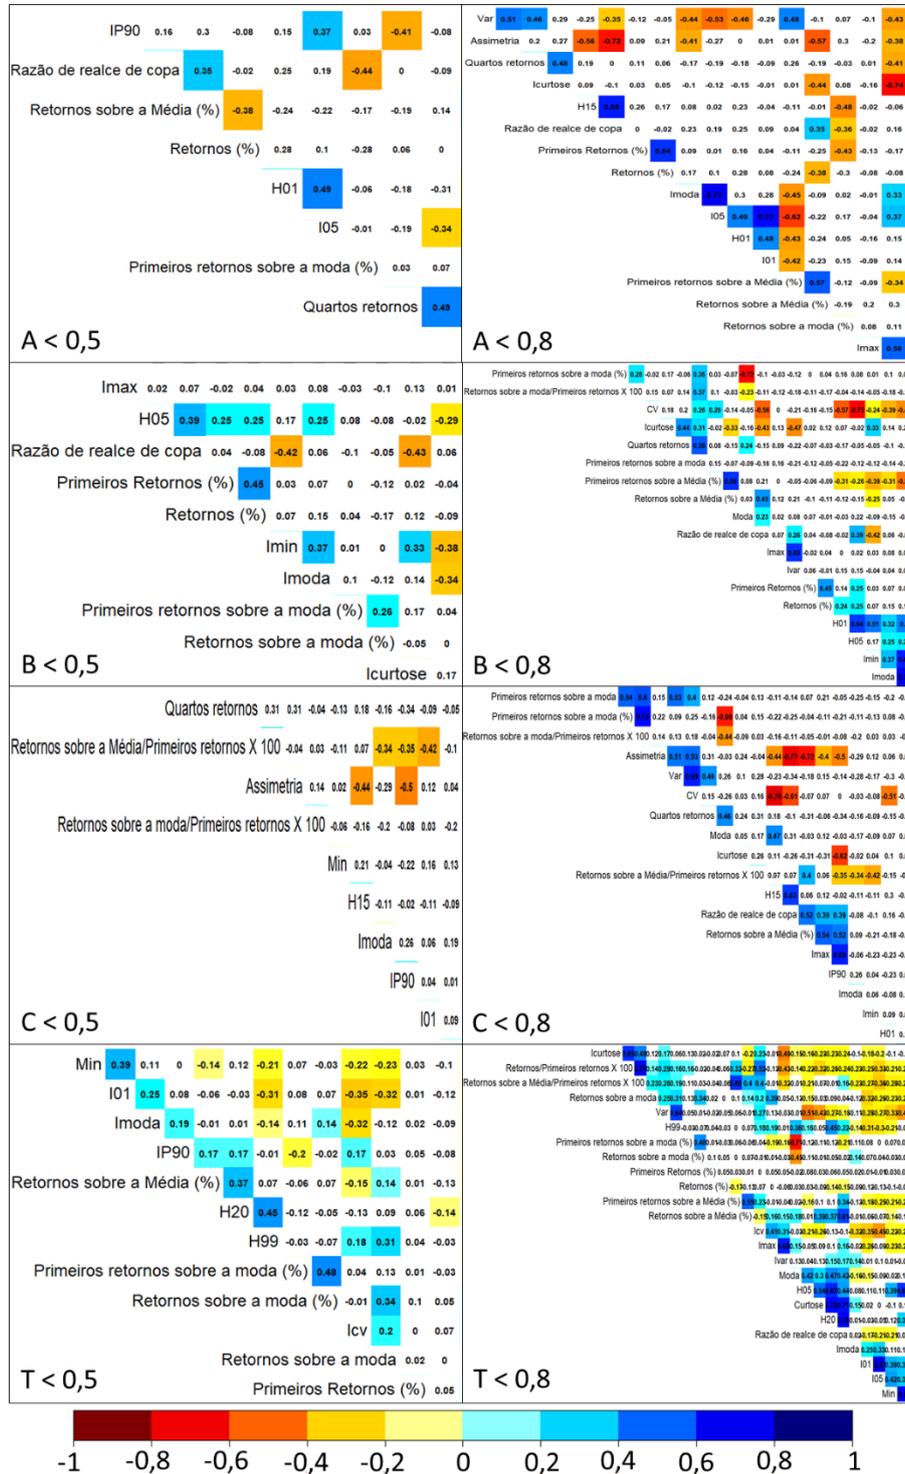
Figura 4.14 - Correlação das métricas das nuvens de pontos, recortadas por meio das copas isoladas.



A esquerda, o nome de cada métrica e a direita estão as correlações, em que o azul escuro representa a correlação diretamente proporcional e o vermelho escuro a inversamente proporcional.

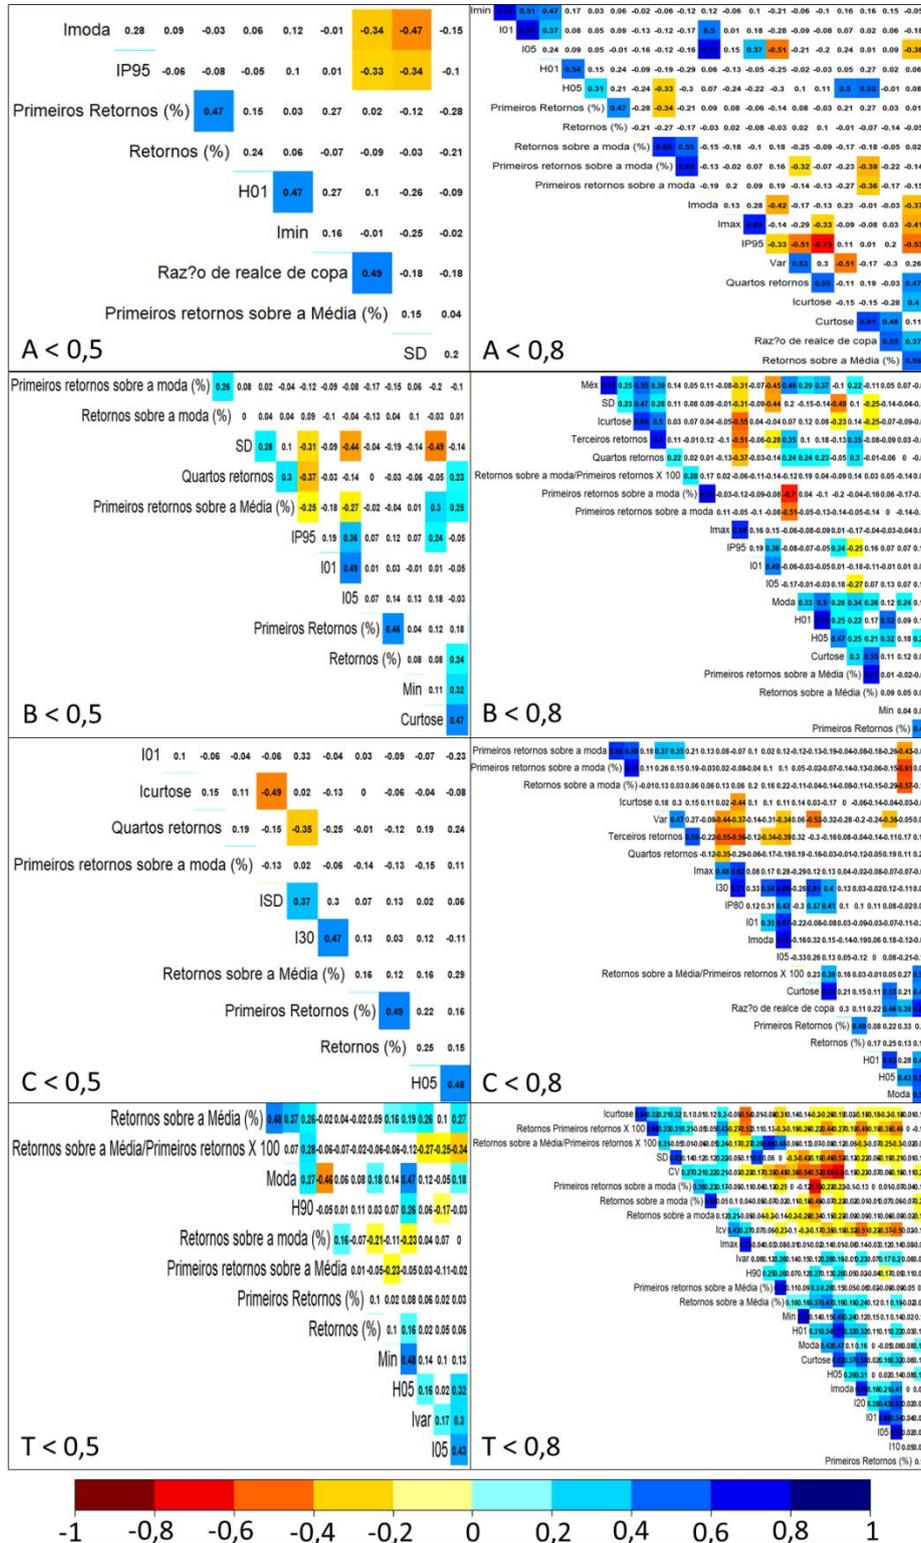
É possível perceber quatro grupos altamente correlacionados: os retornos com valores absolutos, os retornos com valores relativos de altura e intensidade, as estatísticas descritivas e as razões com os valores absolutos e relativos. Como o *range* de coleta dos sistemas LiDAR utilizados são iguais, os retornos subsequentes ao primeiro dependem do tipo de sub bosque que há nas áreas observadas, que não se modificam significativamente nas parcelas estudadas, este fato pode ter ocasionado a alta correlação nos dois primeiros grupos. As demais correlações são influência da distribuição dos pontos no perfil florestal, que não segue uma distribuição normal, contudo, demonstrou um padrão de distribuição, como mostrado na figura 4.13. A análise apresentou algumas tênues correlações, como a mínima altura (Min), a razão de copa (Razão de realce de copa), intensidade média (Imedia), assimetria da intensidade (assimetria) e porcentagem dos primeiros retornos sobre a moda (Primeiros retornos sobre a moda (%)). Entretanto, ao analisar as métricas de cada área, não foi perceptível tendências com o algoritmo utilizado ou o limiar de corte da correlação (Figuras 4.15 e 4.16)

Figura 4.15 - Correlação de Pearson das métricas selecionadas, utilizando o recorte da nuvem com o algoritmo de Dalponte (2018).



Métricas com correlações de Pearson $< 0,5$ e $< 0,8$, feitas após o recorte da nuvem de pontos utilizando o algoritmo de Dalponte (2018). Os valores próximos a 0 não apresentam coloração.

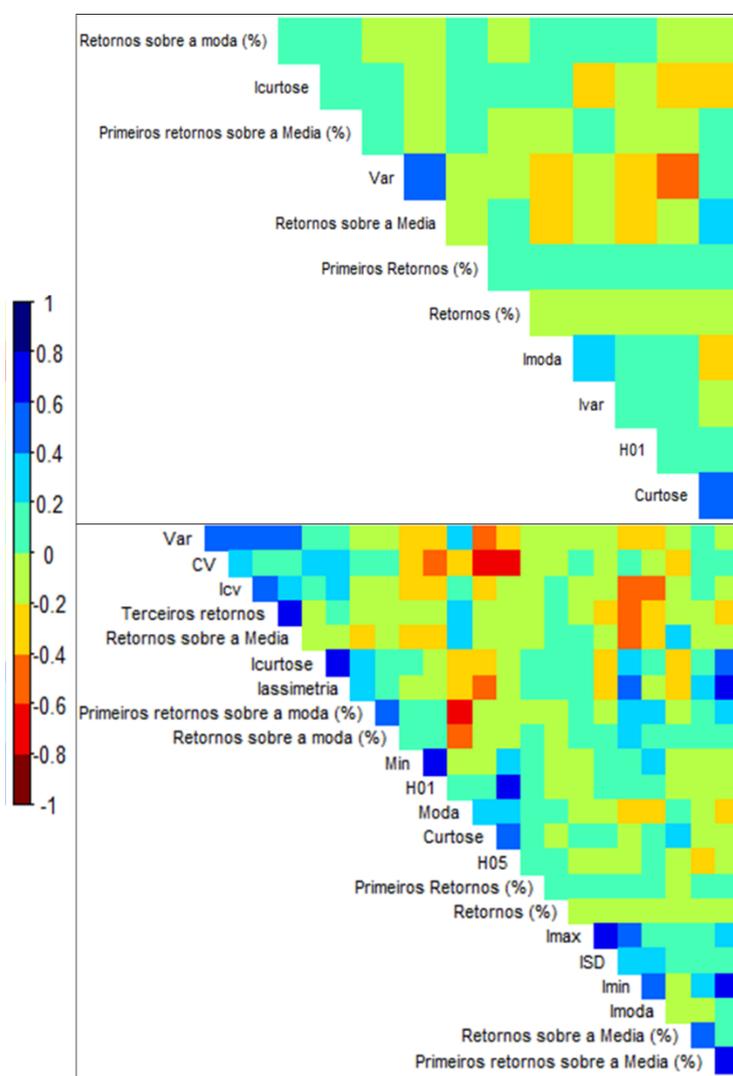
Figura 4.16 - Correlação de Pearson das métricas selecionadas, utilizando o recorte da nuvem com o algoritmo de Silva et al. (2017).



Métricas com correlações de Pearson $<0,5$ e $<0,8$; feitas após o recorte da nuvem de pontos utilizando o algoritmo de Silva et al. (2017). Os valores próximos a 0 não apresentam coloração.

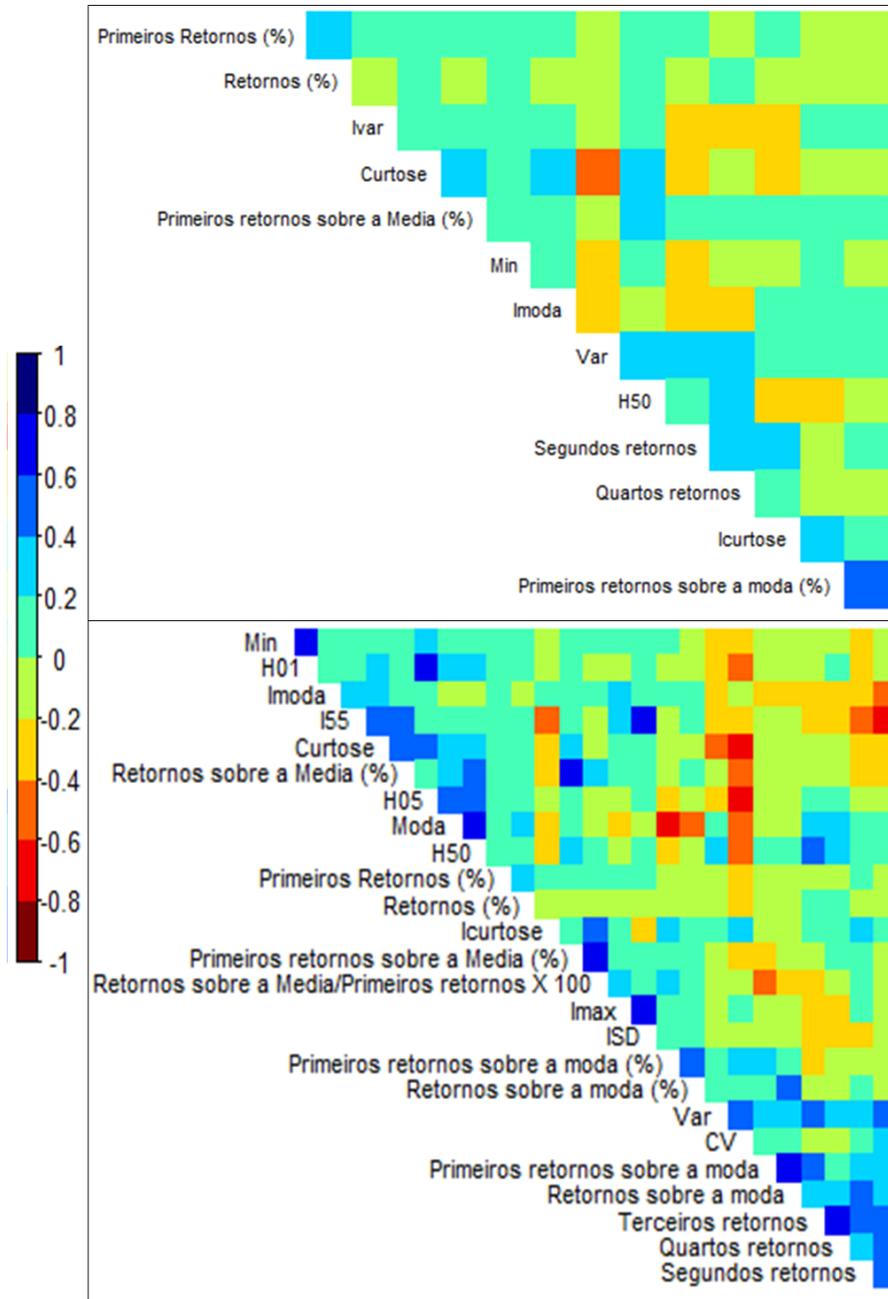
Os limiares de corte de 0,5 de correlação de Pearson, apresentaram menor quantidade de pontos se comparado ao limiar de 0.8. Houve também, diferença em quantidade de métricas encontradas entre as áreas e entre os algoritmos (Figura 4.17).

Figura 4.17 - Correlações das métricas utilizando as nuvens de pontos recortados pelo isolamento de copa pelo algoritmo de Dalponte (2018).



No quadro superior estão as métricas com limiares de corte de correlação de 0,5 e na inferior de 0,8.

Figura 4.18 - Correlações das métricas utilizando as nuvens de pontos recortados pelo isolamento de copa pelo algoritmo de Silva et al. (2017).



No quadro superior estão as métricas com limiares de corte de correlação de 0,5 e na inferior de 0,8.

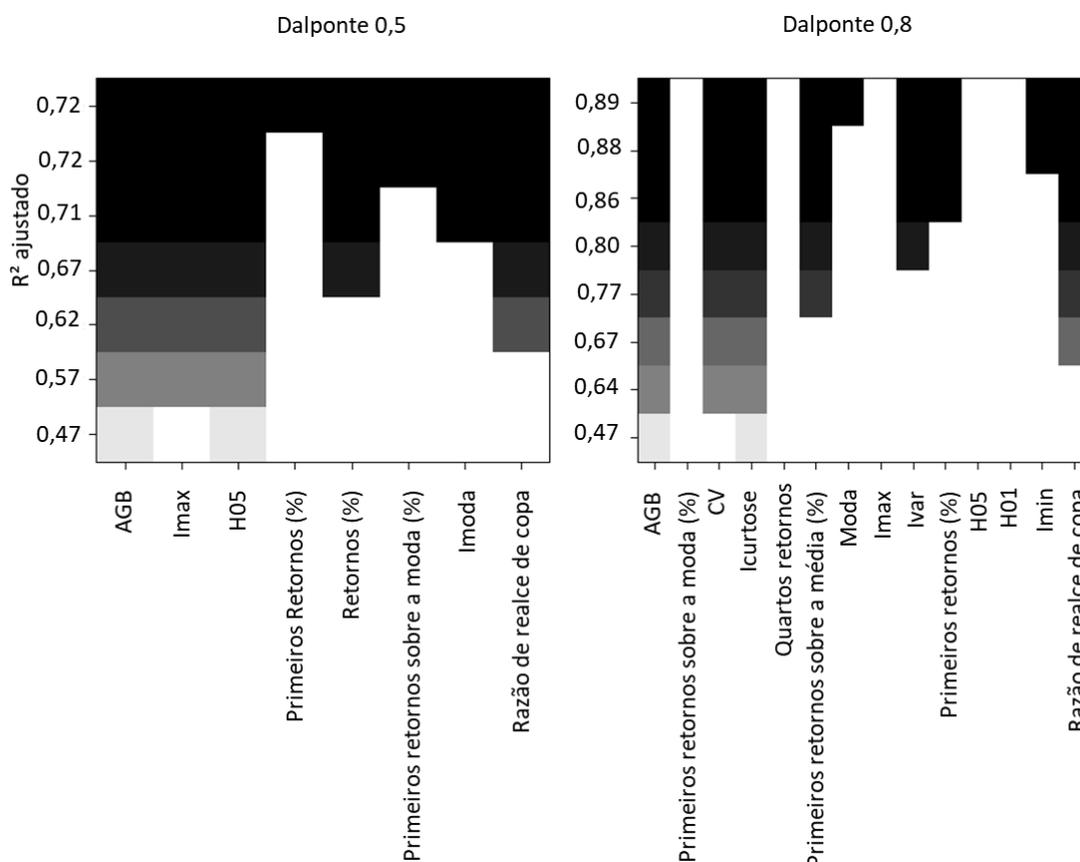
O método *regsubset* apresentou resultados de métricas que descrevem a biomassa para cada área (Tabela 4.2). Estes resultados foram discrepantes, em que o $R^2_{ajustado}$ sofreu visível variância.

Tabela 4.3 - Valores de $R^2_{ajustados}$ e quantidade de métricas para o conjunto de métricas de cada algoritmo utilizado para isolamento de copas e limiares.

Limiar	Dalponte				Silva			
	0.5		0.8		0.5		0.8	
Área	$R^2_{ajustado}$	Métricas	$R^2_{ajustado}$	Métricas	$R^2_{ajustado}$	Métricas	$R^2_{ajustado}$	Métricas
A	0.15	2	0.14	4	0.56	5	0.79	4
B	0.72	7	0.89	8	0.088	2	0.18	8
C	0.15	2	0.18	5	0.081	2	0.55	8
T	0.57	5	0.055	6	0.16	6	0.2	8

A área que apresentou melhor R^2_{adj} em que as métricas explicam a variação de AGB, foi a B, utilizando o algoritmo de Dalponte (2018). As métricas com correlação de Pearson Menores que 0,8 foram: Primeiros retornos, Primeiros retornos sobre a moda, coeficiente de variação, curtose da intensidade, quartos retornos, primeiros retornos sobre a média, moda, intensidade máxima, variância da intensidade, porcentagem dos primeiros retornos, altura a 5% da altura máxima, altura a 1% da altura máxima, intensidade mínima e a razão do realce de copa (Figura 4.19). Percebe-se que as métricas abrangem vários extratos verticais da floresta e contemplam todos os grupos de métricas.

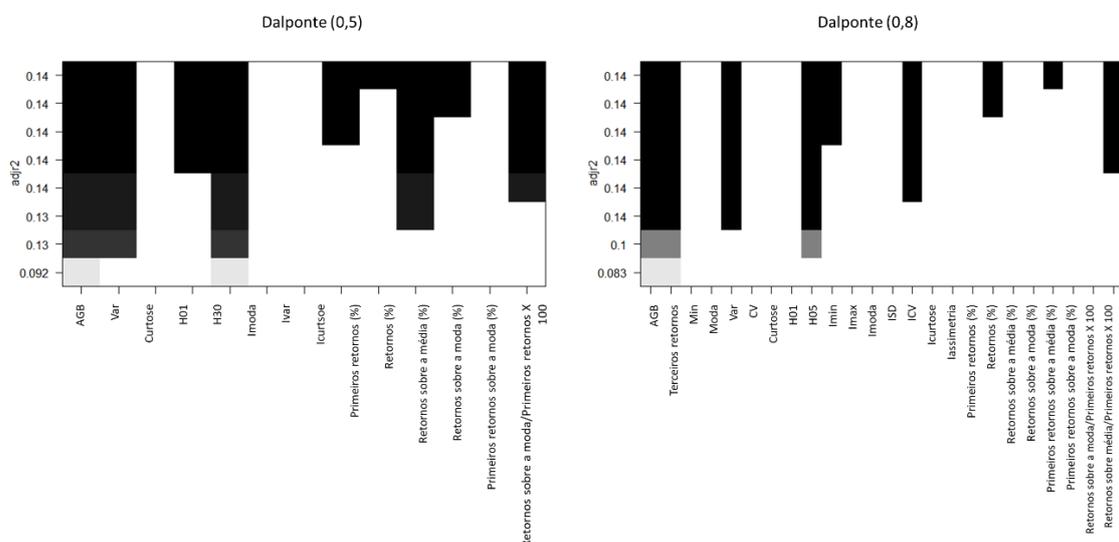
Figura 4.19 - Métricas e valores de $R^2_{ajustados}$ para área B, com isolamento de copa com o algoritmo de Dalponte (2018).



Possíveis modelos lineares para utilização na estimativa de AGB, encontrados pelo algoritmo de Dalponte (2018), para a área B. Os valores na coluna da esquerda representam os valores de $R^2_{ajustados}$ e os valores no eixo X representam cada variável para compor o modelo.

A correlação para as métricas com limiar menor que 0,5 foram: intensidade máxima, altura a 5% da altura máxima, primeiros retornos, primeiros retornos sobre a moda, moda da intensidade e razão de realce de copa. Nestas métricas, ficou perceptível que houve maior quantidade de métricas de porcentagem. Estas métricas se adaptam melhor a região de floresta, pois atenuam o efeito da densidade de pontos, já que não tem uma distribuição homogênea (MCGAUGHEY, 2015). Os possíveis modelos ajustados pelas métricas isoladas pelo algoritmo Dalponte (2018) para todas as áreas apresentaram um $R^2_{ajustados}$ inferiores aos da área B (Figura 4.21).

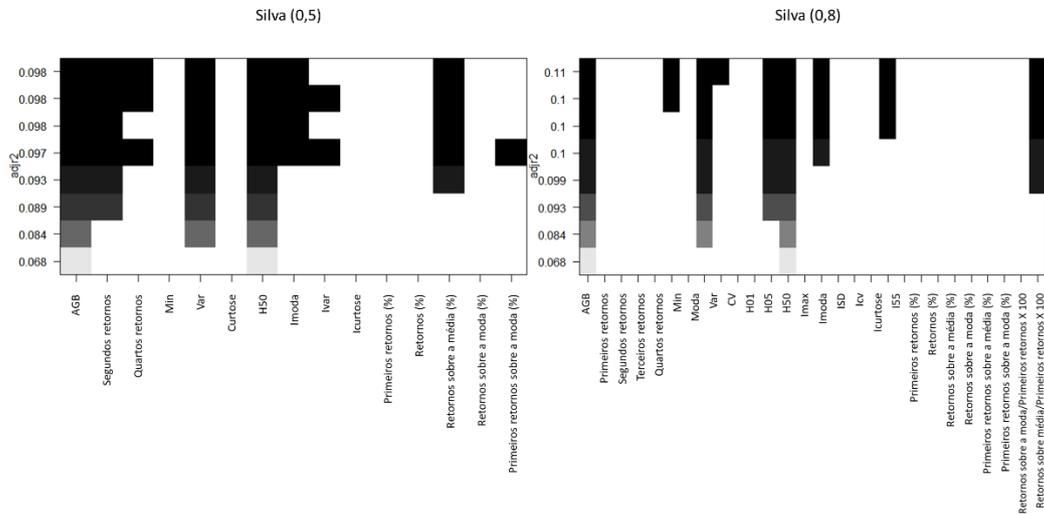
Figura 4.20 - Métricas e valores de $R^2_{ajustados}$ para todas as áreas, com isolamento de copa com o algoritmo de Dalponte (2018).



Possíveis modelos lineares para utilização na estimativa de AGB, encontrados pelo algoritmo de Dalponte (2018), para todas as áreas. Os valores na coluna da esquerda representam os valores de $R^2_{ajustados}$ e os valores no eixo X representam cada variável para compor o modelo.

O mesmo foi observado as métricas isoladas pelo algoritmo de Silva et al. (2017), que apresentaram resultados inferiores que o outro utilizado (Figura 4.21).

Figura 4.21 - Tabela com métricas e valores de $R^2_{ajustados}$ para todas as áreas, com isolamento de copa com o algoritmo de Silva et al. (2017).



Possíveis modelos lineares para utilização na estimativa de AGB, encontrados pelo algoritmo de Silva (2016), para todas as áreas. Os valores na coluna da esquerda representam os valores de $R^2_{ajustados}$ e os valores no eixo X representam cada variável para compor o modelo.

Métricas similares foram encontrados no isolamento, entre elas algumas relativas a dispersão vertical da floresta, altura mínima, variância e número de retornos. As métricas relativas podem descrever com melhor abrangência cada árvore e normalizar os valores discrepantes. As métricas de alturas central do interior da floresta podem descrever árvores de sub dossel, que as métricas de dossel não descrevem. As alturas mínimas podem descrever se há influência arbustiva para cada área e o número de retornos dependerá fortemente da densidade de copa sob a floresta (MCGAUGHEY, 2015). Mesmo com baixa robustez, os modelos gerais para todas as áreas são descritos nas Equações 4.1 e 4.2, para as métricas encontradas pela nuvem de pontos com isolamento de copas de Silva et al. (2017) e Dalponte (2018), respectivamente:

$$AGB_{silva} = -3.205429062 + 0.05325577 * \text{Min} - 0.044349312 * \text{Moda} + 0.138263422 * \text{H05} + 0.000803138 * \text{Imoda} + 0.065717024 * \text{I55} + 0.073825143 * \text{Retornos sobre a média/Primeiros retornos} * 100$$

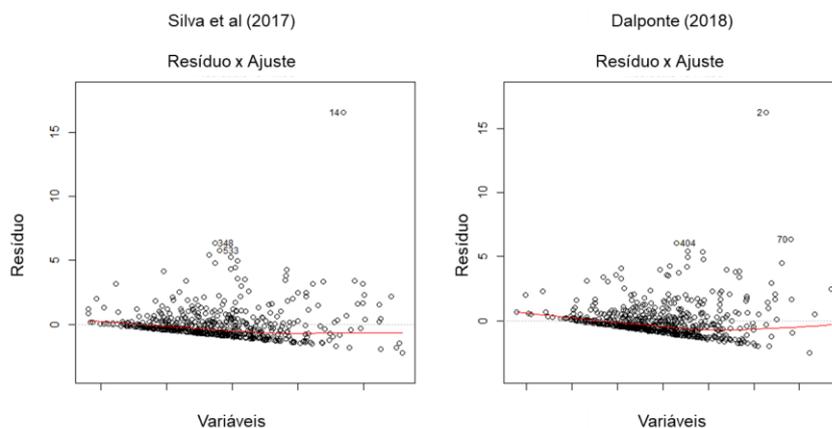
$$\begin{aligned}
 AGB_{dalponte} = & -0.874411839 - 0.012099121 * Var + 0.023977575 * H01 + 0.007890493 \\
 & * H30 + 0.034006669 * Primeiros\ retornos\ (\%) + 0.20782558 \\
 & * Retornos\ sobre\ a\ média\ (\%) - 0.06316948 \\
 & * Retornos\ sobre\ a\ média/Primeiros\ retornos * 100
 \end{aligned}$$

4.2

Os modelos gerais foram feitos com os maiores valores de R^2 ajustados, que no caso de Silva et al. (2017) foram as métricas com limiar de corte de 0,8 e para as métricas isoladas pelo algoritmo de Dalponte (2018) ambos os limiares obtiveram o mesmo valor máximo de R^2 ajustados, então, optou-se pelo limiar de 0,5. Retornos acima da média sobre os primeiros retornos vezes 100, foi uma métrica similar a ambas. Em trabalho de Andersen et al. (2014) a razão de métricas foi utilizada para identificar áreas sem biomassa em que houve arraste de toras de corte seletivo. Possivelmente, a métrica comum aos dois modelos deve descrever estruturas sob cada copa de árvore.

Os resíduos dos ajustes dos modelos apresentados apresentaram *outliers* (Figura 4.22)

Figura 4.22 – Gráficos de resíduos dos modelos gerados.



A distribuição dos erros dos modelos apresentou similaridade, principalmente subestimando valores de biomassa, com maior concentração de resíduos até 5 mg. A superestimava de resíduo de biomassa apresentou uma constância linear. Ambos os erros podem decorrer de erros em campo associados a limitações do modelo, seria coerente para trabalhos futuros ajustar modelos biométricos, já que o a curva média apresenta ponto de inflexão.

5 CONCLUSÕES

O algoritmo de Silva et al. (2017), utilizado para isolar copas em áreas de florestas nativas na região nordeste do estado do Mato Grosso, sofre fortes influências de seus parâmetros. Para este, o tamanho de pixel que apresentou maior detalhamento de copa, sem conter valores nulos, nas áreas das parcelas estudadas foi de 0,5 m. Com pixel de 0,25 m apresentou valores nulos. A suavização do *Canopy Height Model* - CHM homogeneiza as copas das árvores e também as suas bordas, que não apresentam um dégradé até serem interrompidas abruptamente no estrato inferior da floresta. Ao aumentar o tamanho da janela utilizada para o algoritmo em questão, diminui-se o número de árvores encontradas, contudo, as médias aumentam.

Ambos os algoritmos não encontraram quantidade de árvores iguais aquelas mensuradas em campo. Tampouco apresentaram similaridade no número de árvores encontradas, exceto na área C, que teve impacto de corte seletivo. Os algoritmos não apresentaram similaridade na forma da copa das árvores, enquanto o algoritmo de Silva et al. (2017) serrilha a borda em função da aresta do pixel, mas não sobrepõe suas copas, o algoritmo de Dalponte (2018), ao contrário, suaviza as copas, sobrepondo-as.

As alturas das árvores foram aproximadas principalmente na área B, para esta área, os histogramas de árvores encontradas por meio da nuvem de pontos LiDAR apresentou intervalos sem indivíduos encontrados, corroborando com o campo. Todos os gráficos de correlações foram dispersos e mesmo nas árvores com maior altura apresentaram erros, em sua maioria, fora do intervalo de confiança.

As métricas isoladas por meio das copas de ambos os algoritmos apresentaram alta correlação entre si. Ao isolar métricas com correlação de Pearson menores que 0,5 e 0,8 não houve métricas similares para todas as áreas. Então, a degradação florestal pode influenciar nas métricas extraídas. Ao agrupar a correlação de Pearson para todas as áreas, por algoritmo utilizado, foram selecionadas métricas de alturas, porcentagem de altura e intensidade.

O melhor resultado foi pelo algoritmo de Dalponte (2018), na área B, chegando a um $R^2_{ajustado}$ 0,89, utilizando 8 métricas. Porém, houve ampla variância entre os valores de $R^2_{ajustado}$ entre as áreas. O modelo geral de análise não atingiu resultados satisfatórios, um modelo robusto que conseguisse abranger todas as áreas degradadas não pôde ser consolidado, porém, algumas áreas mostraram-se com potencial para utilizarem a individualização de copa na predição de biomassa.

A metodologia proposta mostrou forte possibilidade de ser aplicada, sendo uma alternativa para suprimir métodos convencionais até então utilizados.

6. REFERÊNCIAS BIBLIOGRÁFICAS

- ABSHIRE, J. B.; SUN, X.; AFZAL, R. S. Mars orbiter laser altimeter: receiver model and performance analysis. **Applied Optics**, v. 39, n. 15, p. 2449–2460, 2000.
- ALVES, L. B.; MARQUES, D. M. F.; LIMA, A. F. R.; FONSECA JÚNIOR, S. B. Degradação ambiental: diagnóstico e análise para o Brasil central. **Conjuntura Econômica Goiana**, v. 36, p. 59–80, 2016.
- ANDERSEN, H. E.; REUTEBUCH, S. E.; MCGAUGHEY, R. J.; D'OLIVEIRA, M. V. N.; KELLER, M. Monitoring selective logging in western Amazonia with repeat LiDAR flights. **Remote Sensing of Environment**, v. 151, p. 157–165, 2013.
- ANDERSEN, H. E.; REUTEBUCH, S. E.; MCGAUGHEY, R. J.; D'OLIVEIRA, M. V. N.; KELLER, M. Monitoring selective logging in western Amazonia with repeat LiDAR flights. **Remote Sensing of Environment**, v. 151, p. 157–165, 2014.
- ANDERSSON, K.; EVANS, T. P.; RICHARDS, K. R. National forest carbon inventories: policy needs and assessment capacity. **Climatic Change**, v. 93, n. 1–2, p. 69–101, 2009.
- ASNER, G. P.; KNAPP, D.; BROADBENT, E.; OLIVEIRA, P.; KELLER, M.; SILVA, J. Selective logging in the Brazilian Amazon. **Science**, v. 310, n. 2005, p. 483, 2006.
- ASNER, G. P.; NEPSTAD, D.; CARDINOT, G.; RAY, D. Drought stress and carbon uptake in an Amazon forest measured with spaceborne imaging spectroscopy. **Proceedings of National Academy of Sciences of the United States of America**, v. 101, n. 16, p. 6039–6044, 2004.
- BALCH, J. R. K.; NEPSTAD, D. C.; BRANDO, P. M.; CURRAN, L. M.; PORTELA, O.; CARVALHO, O.; LEFEBVRE, P. Negative fire feedback in a transitional forest of southeastern Amazonia. **Global Change Biology**, v. 14, n. 10, p. 2276–2287, 2008.
- BARLOW, J.; PERES, C. A. Fire-mediated dieback and compositional cascade in an Amazonian forest. **Philosophical Transactions of the Royal Society: Biological Sciences**, v. 363, n. 1498, p. 1787–1794, 2008.
- BENÍTEZ, F. L.; ANDERSON, L. O.; FORMAGGIO, A. R. Evaluation of geostatistical techniques to estimate the spatial distribution of aboveground biomass in the Amazon rainforest using high-resolution remote sensing data. **Acta Amazonica**, v. 46, n. 2, p. 151–160, 2016.
- BRANDO, P. M.; BALCH, J. K.; NEPSTAD, D. C.; MORTON, D. C.; PUTZ, F. E.; COE, M. T.; SILVERIO, D.; MACEDO, M. N.; DAVIDSON, E. A.; NOBREGA, C. C.; ALENCAR, A.; SOARES-FILHO, B. S. Abrupt increases in

amazonian tree mortality due to drought-fire interactions. **Proceedings of the National Academy of Sciences**, v. 111, n. 17, p. 6347–6352, 2014.

BRASIL. MINISTÉRIO DO MEIO AMBIENTE - MMA. **Agenda 21 global**. 2017. Disponível em: <<http://www.mma.gov.br/responsabilidade-socioambiental/agenda-21/agenda-21-global>>. Acesso em: 24 fev. 2018.

BROWN, S. Estimating biomass and biomass change of tropical forests: a primer. **FAO Forestry Paper**, v. 134, n.8, p. 1–42, 1997.

BUCK, A. L. B.; SILVA, M. N.; LINGNAU, C.; MACHADO, Á. M. L.; MARTINS NETO, R. P.; PESCK, V. A. Avaliação da modelagem tridimensional do tronco de pinus elliottii a partir de dados laser terrestre. **Ambiência**, v. 8, n. esp., p. 549–557, 2012.

BUFTON, J.; BLAIR, J.; CAVANAUGH, J.; GARVIN, D.; HARDING, D.; HOPF, D.; KIRKS, K.; RABINE, D.; WALSH, N (1995). **Shuttle laser altimeter (SLA): a pathfinder for space-based laser altimetry and LiDAR**. Disponível em: <<https://www.researchgate.net/publication/234428552>>. Acesso em: 8 fev. 2018.

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

COOMES, D. A.; DALPONTE, M.; JUCKER, T.; ASNER, G. P.; BANIN, L. F.; BURSLEM, D. F. R. P.; LEWIS, S. L.; NILUS, R.; PHILLIPS, O. L.; PHUA, M. H.; QIE, L. Area-based vs tree-centric approaches to mapping forest carbon in southeast asian forests from airborne laser scanning data. **Remote Sensing of Environment**, v. 194, p. 77–88, 2017.

D'OLIVEIRA, M. V. N.; FIGUEIREDO, E. O.; PAPA, D. DE A. **Uso do LiDAR como ferramenta para o manejo de precisão em florestas tropicais**. 2014. Disponível em: <<https://www.embrapa.br/acre/busca-de-publicacoes/-/publicacao/1029435/uso-do-LiDAR-como-ferramenta-para-o-manejo-de-precisao-em-florestas-tropicais>>. Acesso em: 5 jan. 2018.

D'OLIVEIRA, M. V. N.; REUTEBUCH, S. E.; MCGAUGHEY, R. J.; ANDERSEN, H. E. Estimating forest biomass and identifying low-intensity logging areas using airborne scanning LiDAR in antimary state forest, acre state, western brazilian amazon. **Remote Sensing of Environment**, v. 124, p. 479–491, 2012.

DALPONTE, M. **itcSegment: Individual Tree Crowns Segmentation**. R package version 0.8. Disponível em: <<https://CRAN.R-project.org/package=itcSegment>>. Acesso em: 8 fev. 2017.

DETECÇÃO DO DESMATAMENTO EM TEMPO REAL - DETER. **Relatório de avaliação do ano de 2015**. São José dos Campos: INPE, 2015. p. 2–9.

DURAIAPPAH, A. K. et al. **Ecosystems and human well-being**. Washington: Island Press, 2005. v. 5. Disponível em: <<http://www.who.int/entity/globalchange/ecosystems/ecosys.pdf%5Cnhttp://www.loc.gov/catdir/toc/ecip0512/2005013229.html>>.

ELLIS, P.; GRISCOM, B.; WALKER, W.; GONÇALVES, F.; CORMIER, T. Mapping selective logging impacts in borneo with gps and airborne LiDAR. **Forest Ecology and Management**, v. 365, p. 184–196, 2016.

ENE, L.; NÆSSET, E.; GOBAKKEN, T. Single tree detection in heterogeneous boreal forests using airborne laser scanning and area-based stem number estimates. **International Journal of Remote Sensing**, v. 33, n. 16, p. 5171–5193, 2012.

FOOD AND AGRICULTURE ORGANIZATION - FAO. **Global forest resources assessment 2010**. Rome: FAO, 2010. 27p.

FEARNSIDE, P. M. Deforestation control in Mato Grosso: a new model for slowing the loss of Brazil's Amazon forest. **Ambio**, v. 32, n. 5, p. 343–345, 2003.

FEARNSIDE, P. M. Global warming and tropical land-use change: greenhouse gas emissions from biomass burning, decomposition and soils in forest conversion, shifting cultivation and secondary vegetation. **Climatic Change**, v. 46, n. 1/2, p. 115–158, 2000.

FÉRET, J. B.; ASNER, G. P. Semi-supervised methods to identify individual crowns of lowland tropical canopy species using imaging spectroscopy and LiDAR. **Remote Sensing**, v. 4, n. 8, p. 2457–2476, 2012.

FERRAZ, A.; SAATCHI, S.; MALLET, C.; JACQUEMOUD, S.; GONÇALVES, G.; SILVA, C. A.; SOARES, P.; TOMÉ, M.; PEREIRA, L. Airborne LiDAR estimation of aboveground forest biomass in the absence of field inventory. **Remote Sensing**, v. 8, n. 8, p. 1–18, 2016.

FERRAZ, A.; SAATCHI, S.; MALLET, C.; MEYER, V. LiDAR detection of individual tree size in tropical forests. **Remote Sensing of Environment**, v. 183, p. 318–333, 2016.

FIGUEIREDO FILHO, A.; MACHADO, S. A.; MIRANDA, R. O. V.; RETSLAFF, F. A. S. **Compêndio de equações de volume e de afilamento de espécies florestais plantadas e nativas para as regiões fitogeográficas do Brasil**. Curitiba: Os Autores, 2014.

FLOOD, M. LiDAR activities and research priorities in the commercial sector. International archives of photogrammetry, remote sensing and spatial information. **Sciences**, v. 34, n. 3, p. 22–24, 2001.

FONSECA, A.; JUSTINO, M.; CARDOSO, D.; RIBEIRO, J.; SOUZA JUNIOR, C.; VERISSÍMO, A. **Sistema de alerta de desmatamento (SAD): junho de 2017**. Belém: Imazon, 2017.

GERWING, J. J. Degradation of forests through logging and fire in the eastern brazilian amazon. **Forest Ecology and Management**, v. 157, n. 1/3, p. 131–141, 2002.

GIONGO, M.; KOEHLER, H. S.; MACHADO, S. A.; KIRCHNER, F. F.; MARCHETTI, M. LiDAR: princípios e aplicações florestais. **Pesquisa Florestal Brasileira**, v. 30, n. 63, p. 231–244, 2010.

HOERL, A. E.; KANNARD, R. W.; BALDWIN, K. F. Ridge regression: some simulations. **Communications in Statistics**, v. 4, n. 2, p. 105–123, 1975.

HOLTUM, J. A. M.; WINTER, K. Elevated CO₂ and forest vegetation: more a water issue than a carbon issue? **Functional Plant Biology**, v. 37, n. 8, p. 694–702, 2010.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. **Cidades**. Disponível em: <<https://cidades.ibge.gov.br/brasil/mt/feliz-natal/panorama>>. Acesso em: 22 set. 2017.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS - INPE. **INPE estima 6.624 km² de desmatamento por corte raso na Amazônia em 2017**. 2017. Disponível em: <<http://www.obt.inpe.br/OBT/noticias/INPE-estima-desmatamento-por-corte-raso-na-Amazonia-em-2017>>. Acesso em: 5 jan. 2018.

JENSEN, J. R. **Remote sensing of the environment: an earth resource perspective**. 2. ed. New Delhi: Pearson Education, 2009.

KELLER, M. **Paisagens sustentáveis: cooperação entre o serviço florestal americano e a Embrapa**. 2017. Disponível em: <<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/122974/1/4454.pdf>>. Acesso em: 4 ago. 2017.

KINDERMANN, G.; MCCALLUM, I.; FRITZ, S.; OBERSTEINER, M. A global forest growing stock, biomass and carbon map based on FAO statistics. **International Institute for Applied Systems Analysis**, v. 42, n. 3, p. 387–396, 2008.

LARSEN, M.; ERIKSSON, M.; DESCOMBES, X.; PERRIN, G.; BRANDTBERG, T.; GOUGEON, F. A. Comparison of six individual tree crown detection algorithms evaluated under varying forest conditions. **International Journal of Remote Sensing**, v. 32, n. 20, p. 143–1161, 2011.

LE TOAN, T.; QUEGAN, S.; DAVIDSON, M. W. J.; BALZTER, H.; PAILLOU, P.; PAPATHANASSIOU, K.; PLUMMER, S.; ROCCA, F.; SAATCHI, S.; SHUGART, H.; ULANDER, L. The biomass mission: mapping global forest

biomass to better understand the terrestrial carbon cycle. **Remote Sensing of Environment**, v. 115, n. 11, p. 2850–2860, 2011.

LEE, H.; SLATTON, K. C.; ROTH, B. E.; CROPPER, W. P. Adaptive clustering of airborne LiDAR data to segment individual tree crowns in managed pine forests. **International Journal of Remote Sensing**, v. 31, p. 117–139, 2010.

LICHTI, D.; PFEIFER, N.; MAAS, H. G. Terrestrial laser scanning. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 63, n. 1, p. 1–3, 2008.

LONGO, M.; KELLER, M.; DOS-SANTOS, M. N.; LEITOLD, V.; PINAGÉ, E. R.; BACCINI, A.; SAATCHI, S.; NOGUEIRA, E. M.; BATISTELLA, M.; MORTON, D. C. Aboveground biomass variability across intact and degraded forests in the Brazilian Amazon. **Global Biogeochemical Cycles**, v. 30, n. 11, p. 1639–1660, 2016.

MACHADO, S. A. FIGUEIREDO FILHO, A. **Dendometria**. Curitiba: Ed. dos Autores, 2003.

MALTAMO, M.; EERIKÄINEN, K.; PITKÄNEN, J.; HYYPPÄ, J.; VEHMAS, M. Estimation of timber volume and stem density based on scanning laser altimetry and expected tree size distribution functions. **Remote Sensing of Environment**, v. 90, n. 3, p. 319–330, 2004.

MÁRQUEZ, A. **Un tratado sobre el escaner terrestre tls**. 2010. Disponível em: <<http://mecinca.net/papers/EscanerTLS.pdf>>. Acesso em: 19 ago. 2017.

MARTINS, C. R.; PEREIRA, P. A. P.; LOPES, W. A.; ANDRADE, J. B. Ciclos globais de carbono, nitrogênio e enxofre: a importância na química da atmosfera. **Caderno Temáticos de Química Nova na Escola**, v. 5, p. 28–41, 2003.

MCGAUGHEY, R. J. **FUSION/ldv**: software for LiDAR data analysis and visualization. Washington: USDA, 2015. 154p.

ORGANIZAÇÃO MUNDIAL DE METEOROLOGIA. **METEOWORLD**. Disponível em: <public.wmo.int/en/resources/meteoworld>. Acesso em: 24 fev. 2017.

MILODOWSKI, D. T.; MITCHARD, E. T. A.; WILLIAMS, M. Forest loss maps from regional satellite monitoring systematically underestimate deforestation in two rapidly changing parts of the Amazon. **Environmental Research Letters**, v. 12, n. 9, 2017.

MORTON, D. C.; LE PAGE, Y.; DEFRIES, R.; COLLATZ, G. J.; HURTT, G. C. Understorey fire frequency and the fate of burned forests in southern Amazonia. **Philosophical Transactions of the Royal Society: Biological Sciences**, v. 368, n. 1619, p. 1–5, 2013.

NASCIMENTO, H. E. M.; LAURANCE, W. F. Total aboveground biomass in central amazonian rainforests: a landscape scale study. **Forest Ecology and Management**, v. 168, n. 1/3, p. 311–321, 2002.

PALACE, M.; KELLER, M.; ASNER, G. P.; SILVA, J. N. M.; PASSOS, C. Necromass in undisturbed and logged forests in the brazilian Amazon. **Forest Ecology and Management**, v. 238, n. 1/3, p. 309–318, 2007.

PAN, Y.; BIRDSEY, R. A.; PHILLIPS, O. L.; JACKSON, R. B. The structure, distribution, and biomass of the world's forests. **Annual Review of Ecology, Evolution, and Systematics**, v. 44, n. 1, p. 593–622, 2013.

PARRY, M.; PARRY, M. L.; CANZIANI, O.; PALUTIKOF, J.; VAN DER LINDEN, P. HANSON, C. **Climate change 2007-impacts, adaptation and vulnerability: working group II contribution to the fourth assessment report of the IPCC**. England: Cambridge University Press, 2007.

PITKÄNEN, J.; MALTAMO, M. Adaptive methods for individual tree detection on airborne laser based canopy height model. **International Archives of the Photogrammetry Remote Sensing and Spatial Information Sciences**, v. 36, p. 187–191, 2004.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento remoto no estudo da vegetação**. São José dos Campos: Parentese, 2010.

PORTAL ACTION. **Matriz de correlação**. Disponível em: <<http://www.portalaction.com.br/en/node/1724>>. Acesso em: 16 mar. 2018.

PRODES SISTEMA DE MONITORAMENTO DO DESMATAMENTO NA AMAZÔNIA LEGAL. **Monitoramento da floresta amazônica brasileira por satélite**. 2017. Disponível em: <<http://www.obt.inpe.br/prodes/14>>. Acesso em: 24 fev. 2017.

RATCLIFFE, S.; MYERS, A. **Laser scanning in the open pit mining environment: a comparison with photogrammetry**. 2006. Disponível em: <http://gim-international.e-activesites.nl/download/whitepaper_uploadfile_2.pdf>. Acesso em: 02 fev. 2017.

REITBERGER, J.; SCHNÖRR, C.; KRZYSZEK, P.; STILLA, U. 3D segmentation of single trees exploiting full waveform LiDAR data. **ISPRS journal of Photogrammetry and Remote Sensing**, v. 64, n. 6, p. 561–574, 2009.

RIBEIRO JÚNIOR, S. Determinação de volumes em atividades de mineração utilizando ferramentas do sensoriamento remoto. 2011. 161p. Tese (Doutorado em Engenharia Civil) – Universidade Federal de Viçosa, Viçosa, 2011.

RODRIGUES, S. C. A. **Modelo de regressão linear e suas aplicações**. 2012. 94p. Dissertação (Mestrado em Matemática) - Universidade da Beira Interior, Covilhã, 2012.

SANTANA, H. **Sistema LiDAR para drones - sensores LiDAR**. Disponível em: <<http://www.xdrones.es/sistema-LiDAR-para-drones/>>. Acesso em: 8 fev. 2018.

SATO, L.; GOMES, V.; SHIMABUKURO, Y.; KELLER, M.; ARAI, E.; DOS-SANTOS, M.; BROWN, I.; ARAGÃO, L. Post-fire changes in forest biomass retrieved by airborne LiDAR in Amazonia. **Remote Sensing**, v. 8, n. 10, p. 839, 2016.

SCHLESINGER, W. H. An overview of the carbon cycle. In: LAL, R.; KIMBLE, J.; LEVINE, E.; STEWART, B. A. (Orgs.). **Soils and global change**. London: Lewis, 1995. p.9-26.

SCHNITZER, S. A.; DEWALT, S. J.; CHAVE, J.; SCHNITZER, S. A. Comparison lianas: censusing and measuring of the common a quantitative method. **Biotropica**, v. 38, n. 5, p. 581–591, 2006.

SCHOENE, D.; KILLMANN, W.; VON LÜPKE, H.; LOYCHEWILKIE, M. **Definitional issues related to reducing emissions from deforestation in developing countries**. Rome: FAO, 2007.

SERVIÇO FLORESTAL BRASILEIRO. **Monitoramento das concessões florestais**. Disponível em: <<http://www.florestal.gov.br/monitoramento>>. Acesso em: 2 jun. 2018.

SHINZATO, E.; SHIMABUKURO, Y.; COOPS, N.; TOMPALSKI, P.; GASPAROTO, E. Integrating area-based and individual tree detection approaches for estimating tree volume in plantation inventory using aerial image and airborne laser scanning data. **IForest - Biogeosciences and Forestry**, v. 9, p. e1–e7, 2016.

SILVA, C. A.; SAATCHI, S.; GARCIA, M.; LABRIERE, N.; KLAUBERG, C.; FERRAZ, A.; ZHAO, K. Comparison of small-and large-footprint LiDAR characterization of tropical forest aboveground structure and biomass: a case study from central gabon. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 99, 1–15, 2018.

SILVA, C. A.; CROOKSTON, N. L.; HUDAK, A. T.; VIERLING, L. A.; KLAUBERG, C.; CARDIL A. **rLiDAR: LiDAR data processing and visualization**. R package version 0.1.1. Disponível em: <<https://CRAN.R-project.org/package=rLiDAR>>. Acesso em: 03 jan. 2017.

SILVA, C. A.; KLAUBERG, C.; HUDAK, A. T.; VIERLING, L. A.; LIESENBERG, V.; CARVALHO, S. P. C. E.; RODRIGUEZ, L. C. E. A principal component

approach for predicting the stem volume in eucalyptus plantations in Brazil using airborne LiDAR data. **Forestry**, v. 89, n. 4, p. 422–433, 2016.

SILVA, M. N. **Aplicação de laser scanner terrestre para determinação de variáveis dendrométricas em Pinus SPP**. Dissertação (Mestrado em Engenharia florestal) - Universidade Federal do Paraná, Curitiba, 2011.

SMITH, P.; BUSTAMANTE, M.; UK, P. S.; BRAZIL, M. B. Agriculture, forestry and other land use (AFOLU). In: EDENHOFER, O. et al. **Climate change 2014: mitigation of climate change**. Cambridge: Cambridge University Press, 2014. p. 811–922.

TYUKAVINA, A.; HANSEN, M. C.; POTAPOV, P. V.; STEHMAN, S. V.; SMITH-RODRIGUEZ, K.; OKPA, C.; AGUILAR, R. Types and rates of forest disturbance in brazilian legal amazon, 2000–2013. **Science Advances**, v. 3, n. 4, p. 1–16, 2017.

UNITED NATIONS FRAMEWORK CONVENTION ON CLIMATE CHANGE - UNFCCC. The marrakesh accords & the marrakesh declaration. **Refocus**, v. 3, n. 1, p. 20–23, 2001.

WATSON, R. T.; NOBLE, I. R.; BOLIN, B.; RAVINDRANATH, N. H.; VERARDO, D. J.; DOKKEN, D. J. **Land use, land use change, and forestry**. Geneva: UNFCCC, 2010.

WOLFINGER, R. Covariance structure selection in general mixed models. **Communications in Statistics - Simulation and Computation**, v. 22, n. 4, p. 1079–1106, 1993.

YEN, K. S.; RAVANI, B.; LASKY, T.; BROOKS, R. **Technology LiDAR for Data Efficiency Washington State Department of Transportation**. 2011. Disponível em: < <http://ahmct.ucdavis.edu/pdf/UCD-ARR-10-11-30-01.pdf> >. Acesso em: 2 jun. 2018.

ZUBER, M. T.; SMITH, D. E.; SOLOMON, S. C.; MUHLEMAN, D. O.; HEAD, J. W.; GARVIN, J. B.; ABSHIRE, J. B.; BUFTON, J. L. The mars-observer laser altimeter investigation. **Journal of Geophysical Research: Planets**, v. 97, n. E5, p. 7781–7797, 1992.