

UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE CIÊNCIAS RURAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA FLORESTAL

José Augusto Spiazzi Favarin

**DADOS DE SENSOR LIDAR NA IDENTIFICAÇÃO E
CARACTERIZAÇÃO DE CLAREIRAS E ESTRADAS
NA FLORESTA AMAZÔNICA**

Santa Maria, RS
2019

José Augusto Spiazzi Favarin

**DADOS DE SENSOR LIDAR NA IDENTIFICAÇÃO E CARACTERIZAÇÃO DE
CLAREIRAS E ESTRADAS NA FLORESTA AMAZÔNICA**

Dissertação de mestrado apresentado ao Programa de Pós-Graduação em Engenharia Florestal da Universidade Federal de Santa Maria (UFSM), como requisito parcial para a obtenção do título de **Mestre em Engenharia Florestal**.

Orientador: Prof. Dr. Rudiney Soares Pereira

Santa Maria, RS

2019

Ficha gerada com os dados fornecidos pelo autor

Spiazzi Favarin, José Augusto
Dados de Sensor LiDAR na Identificação e Caracterização de Clareiras e Estradas na
Floresta Amazônica / José Augusto Spiazzi Favarin.-2019.
65 p.; 30cm

Orientador: Rudiney Soares Pereira
Dissertação (mestrado) – Universidade Federal de Santa Maria, Centro de Ciências
Rurais, Programa de Pós-graduação em Engenharia Florestal, Santa Maria, RS, 2019.

1. Floresta Amazônica 2. Escaneamento laser 3. Clareiras 4. Estradas I.Pereira, Rudiney
Soares II. Spiazzi Favarin, José Augusto .III. Título

José Augusto Spiazzi Favarin

**DADOS DE SENSOR LIDAR NA IDENTIFICAÇÃO E CARACTERIZAÇÃO DE
CLAREIRAS E ESTRADAS NA FLORESTA AMAZÔNICA**

Dissertação de mestrado apresentado ao Programa de Pós-Graduação em Engenharia Florestal da Universidade Federal de Santa Maria (UFSM), como requisito parcial para a obtenção do título de **Mestre em Engenharia Florestal**.

Aprovado em 30 de janeiro de 2019:

Rudiney Soares Pereira, Dr. (UFSM)
(Presidente/Orientador)

Emanuel Araújo Silva, Dr. (UFRPE)

Elvis Rabuske Hendges, Dr. (UNIOESTE)

Santa Maria, RS
2019

DEDICATÓRIA

À memória dos meus queridos avós, Vô Luiz Spiazzi e Vó Christina Spiazzi, que me passaram a paixão que tinham pela natureza e o respeito e cuidado que devemos ter por ela.

AGRADECIMENTOS

Inicialmente, agradeço à minha mãe Maria Cristina e à minha irmã Simone, por todo o suporte e incentivo para que eu alcançasse mais esse objetivo na minha vida. Também, pela compreensão nos momentos em que não me fiz presente em alguns momentos nossos.

À Universidade Federal de Santa Maria, a qual tenho uma forte ligação, não apenas por ter proporcionado boa parte da minha formação acadêmica, mas por meu pai José Alberto ter sido um dos primeiros radialistas da Rádio Universidade.

Ao Programa de Pós-Graduação em Engenharia Florestal por ter possibilitado que eu pudesse me aperfeiçoar nas Ciências Florestais.

Ao Prof. Rudiney por ter incentivado e aceitado me orientar no mestrado, pelos ensinamentos e conselhos em momentos profissionais complicados por qual passei.

Ao Prof. Emanuel Araujo Silva e ao Prof. Elvis Rabuske Hendges por terem aceito fazer parte da banca examinadora do meu trabalho de mestrado.

À Família Labsere: Alessandra Marasciulo (Leka), Bruna Simões, Dionatas Hoeneff (Dioninha), Elisiane Alba (Lisi), Fábio Batista, Helena Oliveira, Juliana Marchesan, Mateus Schuh, Matheus Frigo (Frigo) e Tiago Badin (Badin, afinal, quem é Tiago?); os “anexos” Janderson (Jandinho), Luciana e Pabulo; os “discidentes” Lizi, Robson, Rodrigo e Zimba. Todos, de um jeito ou de outro, contribuíram para que eu alcançasse esse objetivo e proporcionaram discussões técnicas, científicas e filosóficas. Pela união ao passarmos por momentos apreensivos e por tornarem esses dois anos mais leves e divertidos com muito companheirismo.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior pela concessão de bolsa para que eu pudesse me dedicar à pesquisa.

Às felinas Mel e Tina, afinal também são parte da minha família, pela companhia e brincadeiras que me distraiam e ajudavam a aliviar o estresse.

“ninguém ganha o mínimo de sucesso ao menos que exista alguém para ajuda-lo”

Jesse Owens (1913 – 1980)

Resumo

DADOS DE SENSOR LIDAR NA IDENTIFICAÇÃO E CARACTERIZAÇÃO DE CLAREIRAS E ESTRADAS NA FLORESTA AMAZÔNICA

AUTOR: José Augusto Spiazzi Favarin
ORIENTADOR: Rudiney Soares Pereira

As florestas tropicais possuem grande importância na manutenção da biodiversidade, contudo sofrem com a exploração ilegal de madeira e o desmatamento. Por outro lado, práticas de manejo florestal sustentável contribuem para o uso racional dos recursos florestais. Dessa forma, é salutar que se empregue novas tecnologias e métodos para o acompanhamento dessas atividades. Este estudo objetivou identificar e delimitar clareiras em floresta tropical a partir de dados LiDAR com o emprego de diferentes densidades de retornos. A área de estudo se localiza na Fazenda Cauaxi, município de Paragominas-PA, na qual é desempenhada a atividade de manejo florestal. Foram obtidos dados de inventário florestal a partir de 22 parcelas de 20 x 500m, sendo medidas as árvores com DAP maior ou igual a 35cm. Os dados LiDAR foram obtidos em um voo que cobriu uma área de 1.216ha composta por 20 cenas constituídas de uma nuvem de pontos. Foi definida uma área mínima de clareira de 34m², baseada nos raios das copas medidas no inventário florestal. A nuvem de pontos foi processada no FUSION/LDV e obteve-se um *raster* segmentado em áreas de clareiras para cada uma das densidades de retornos testadas (37, 28, 18, 9, 4 e 1ppm², correspondendo aos tratamentos desse estudo). As áreas foram agrupadas em três classes de tamanhos, Classe 1, Classe 2 e Classe 3 (34 – 149, 150 – 399 e maior ou igual a 400m², respectivamente). As estradas foram identificadas pelo padrão da distribuição espacial na área com o auxílio do DTM. A análise estatística foi realizada no R utilizando-se o teste de Kruskal-Wallis para avaliar se houve diferença entre os tratamentos avaliados, o qual não acusou significância ao nível de 0,05, portanto as densidades não diferiram entre si. Devido à identificação das estradas, as áreas foram reclassificadas em Clareiras pequenas, Clareiras grandes e Estradas. O número de áreas em Clareiras pequenas variou entre os tratamentos de 80,7 a 87,4% do total de clareiras, o que é esperado para áreas menores que 150m², em relação à área, a variação foi de 50,4 a 62,3%. Contabilizando áreas de clareiras e estradas, a classe Estrada foi a que teve maior cobertura na área de estudo, variando entre os tratamentos de 68,3 a 55,5%. Foi possível inferir que determinadas clareiras foram abertas pela atividade de extração seletiva de madeira devido ao arranjo espacial das áreas. Não foram identificadas clareiras raras, áreas superiores a 400m². Portanto, trabalhar com a redução da densidade de pontos não prejudicou a identificação e delimitação de clareiras em floresta tropical. A tecnologia LiDAR se mostrou uma eficiente ferramenta para monitorar distúrbios no dossel florestal. Assim, podendo abranger sua aplicação ao monitoramento da atividade de manejo florestal, do desmatamento e exploração ilegal de madeira na Amazônia.

Palavras-chave: Abertura em dossel florestal. Escaneamento laser. Floresta tropical. Densidade de pontos

Abstract

SENSOR LIDAR DATA IN THE IDENTIFICATION AND CHARACTERIZATION OF GAPS AND ROADS IN THE AMAZON FOREST

AUTHOR: José Augusto Spiazzi Favarin

ADVISOR: Rudiney Soares Pereira

Tropical forests have great importance in maintaining biodiversity, yet suffer from illegal logging and deforestation. On the other hand, sustainable forest management practices contribute to the rational use of forest resources. In this way, it is salutary that new technologies and methods are used to follow these activities. This study aimed to identify and delimit gaps in tropical forest from LiDAR data with the use of different density of returns. The study area is located in Fazenda Cauaxi, municipality of Paragominas-PA, in which the forest management activity is carried out. Forest data were obtained from forest inventory from 22 plots of 20 x 500m, and trees with DBH greater than or equal to 35cm were measured. LiDAR data were obtained on a flight that covered an area of 1.216ha composed of 20 scenes consisting of a cloud of points. A minimum gap area of 34m² was defined, based on the canopy rays measured in the forest inventory. The cloud of points was processed in the FUSION/LDV and a segmented raster was obtained in gap areas for each of the density of returns tested (37, 28, 18, 9, 4 and 1ppm², corresponding to the treatments of that study). The areas were grouped into three size classes, Class 1, Class 2 and Class 3 (34 – 149, 150 – 399 and greater than or equal 400m², respectively). The roads were identified by the spatial distribution pattern in the area with the aid of the DTM. The statistical analysis as performed in the R and the Kruskal-Wallis test was used to evaluated if there was a difference between the evaluated treatments, which did not show any significance at the 0.05 level, so the densities did not differ. Due to the identification of roads, the areas were reclassified into Small gaps, Large gaps and Roads. The number of areas in small gaps varied between treatments from 80.7 to 87.4% of total gaps, which is expected for areas smaller than 150m², in relation to the area, the variation was from 50.4 to 62,3%. By accounting for areas of gaps and roads, the Roads had the greatest coverage in the study area, varying between treatments from 68.3 to 55.5%. It was possible to infer that some gaps were opened by the activity of selective extraction of wood due to the spatial arrangement of the areas. Rare gaps were not identified, areas greater than 400m². Therefore, working with the reduction of the density of points did not affect the identification and delimitation of gaps in tropical forest. LiDAR technology has proven to be an effective tool for monitoring forest canopy disturbances. Thus, it can cover its application to the monitoring of the activity of forest management, deforestation and illegal logging in the Amazon.

Keywords: Forest canopy opening. Laser scanning. Tropical forest. Point density.

LISTA DE FIGURAS

Figura 1 – Localização da Amazônia Legal.	18
Figura 2 – Comparação dos métodos de Brokaw e Runkle envolvendo clareiras.	20
Figura 3 – Características espectrais da vegetação verde sadia.....	22
Figura 4 – Aquisição de dados LiDAR aerotransportado e componentes do sistema.....	23
Figura 5 – Representação em 3D de um dossel florestal a partir de dados LiDAR.	24
Figura 7 – Localização da área de estudo na Fazenda Cauaxi, Paragominas – PA.....	28
Figura 6 – Janela do <i>WebGIS</i> do Projeto Paisagens Sustentáveis.	30
Figura 8 – Croqui da parcela de inventário florestal.	31
Figura 9 – Conjunto de cenas LiDAR sobre a área de estudo.....	32
Figura 10 – <i>Raster</i> resultante da segmentação do CHM com pixels agrupados.	39
Figura 11 – Comparativo das clareiras identificadas na Classe 1.	42
Figura 12 – Comparativo das clareiras identificadas na Classe 2.	43
Figura 13 – Comparativo das clareiras identificadas na Classe 3.	44
Figura 14 – Distribuição dos dados por classe no gráfico <i>BoxPlot</i>	45
Figura 15 – Análise dos resíduos através do gráfico <i>QQ-plot</i>	46
Figura 16 – Estradas identificadas a partir da segmentação baseada no CHM.	49
Figura 17 – Segmentação das áreas de estradas nos tratamentos T1D37 e T6D01.....	50
Figura 18 – Identificação de estradas sobre o DTM.....	51
Figura 19 – Mapa de classificação das áreas em clareiras e estradas.....	54

LISTA DE TABELAS

Tabela 1 – Informações técnicas do voo.....	32
Tabela 2 – Classes de tamanho de áreas de clareiras.....	35
Tabela 3 – Estatística descritiva das áreas de copa.....	37
Tabela 4 – Valores do DTM e do CHM por tratamento.	38
Tabela 5 – Estatística descritiva dos tratamentos por classe de área de clareira.	40
Tabela 6 – Resultados dos testes de normalidade e homocedasticidade.	47
Tabela 7 – Resultado do teste de <i>Kruskal-Wallis</i>	47
Tabela 8 – Classificação das áreas em clareiras e estradas.....	52

LISTA DE ABREVIATURAS E SIGLAS

ASPRS	American Society for Photogrametry and Remote Sensing
CHM	Canopy Heigh Model
DAP	Diâmetro à Altura do Peito
DEM	Digital Elevation Model
DETER	Sistema de Detecção do Desmatamento em Tempo Real na Amazônia
DSM	Digital Surface Model
DTM	Digital Terrain Model
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
GNSS	Global Navigation Satelite System
INPE	Instituto Nacional de Pesquisas Espaciais
IDE	Integrated Development Environment
IMU	Inertial Measurement Unit
INS	Inertial Navigation System
LiDAR	Light Detection and Ranging
PPCDAm	Plano de Ações para a Prevenção e Controle do Desmatamento da Amazônia Legal
PRODES	Projeto de Monitoramento do Desmatamento na Amazônia Legal
SIG	Sistemas de Informações Georeferenciadas
SIRGAS	Sistema de Referência Geocêntrico das Américas
USGS	United States Geological Survey
UTM	Universal Transversa de Mercator

SUMÁRIO

1 INTRODUÇÃO	14
1.1 OBJETIVOS	16
1.1.1 Objetivo geral	16
1.1.2 Objetivos específicos	16
1.2 JUSTIFICATIVA	17
2 FUNDAMENTAÇÃO TEÓRICA	18
2.1 FLORESTA AMAZÔNICA	18
2.1.1 Floresta Ombrófila Densa	19
2.2 CLAREIRAS	20
2.3 SENSORIAMENTO REMOTO.....	21
2.3.1 LiDAR	23
2.4 ESTRADAS FLORESTAIS	26
3 MATERIAIS E MÉTODOS	28
3.1 ÁREA DE ESTUDO	28
3.1.1 Localização	28
3.1.2 Caracterização da área de estudo	28
3.1.2.1 <i>Vegetação</i>	29
3.2 AQUISIÇÃO DOS DADOS.....	29
3.2.1 Projeto Paisagens Sustentáveis Brasil	29
3.2.2 Dados de Inventário Florestal	30
3.2.3 Dados LiDAR	31
3.3 IDENTIFICAÇÃO DE CLAREIRAS.....	33
3.3.1 Definição da área mínima de clareira	33
3.3.2 Processamento da nuvem de pontos LiDAR	33
3.3.3 Identificação das áreas de clareiras e estradas	35
3.3.4 Análise Estatística	36
4 RESULTADOS E DISCUSSÃO	37
4.1 DEFINIÇÃO DA ÁREA MÍNIMA	37
4.2 PROCESSAMENTO DA NUVEM DE PONTOS LIDAR.....	37
4.3 IDENTIFICAÇÃO DAS ÁREAS DE CLAREIRAS.....	39
4.3.1 Identificação de estradas	49
4.3.2 Classificação das clareiras	52

5 CONCLUSÃO.....	56
REFERÊNCIAS BIBLIOGRÁFICAS	57

1 INTRODUÇÃO

As florestas são ecossistemas que ao longo dos anos mantêm um equilíbrio entre animais e plantas. Mesmo florestas em equilíbrio (chamadas de climáticas) passam por distúrbios periódicos (como incêndios, ventos fortes, tempestades intensas, ou simplesmente senescência e queda de grandes árvores) que abrem clareiras de diferentes tamanhos na floresta, reiniciando nestes trechos pontuais um novo processo de sucessão florestal secundária (GANDOLFI, 2007). As florestas tropicais estão naturalmente submetidas a distúrbios de intensidade, duração e frequência variáveis, fazendo com que esses ecossistemas estejam sempre em fluxo. (CHAZDON, 2016).

Estes distúrbios, além de ocorrerem naturalmente, podem ser decorrentes do aquecimento global, incêndios florestais e desmatamento (NOBRE, 2007), este último sendo amplamente usado para a conversão de terras para a produção de culturas alimentares e ou pastagens, constituindo-se na maior força destrutiva nas florestas tropicais (ASNER et al., 2005). Como consequência, estas ações deixam para trás amplas áreas sem cobertura florestal e também aberturas no interior das florestas. Outra ação antrópica que ocasiona a abertura de clareiras, é a atividade de exploração florestal realizada de modo sustentável.

O conhecimento das características físicas, florísticas e estruturais das clareiras é essencial em estudos de dinâmica de clareiras, considerando a inter-relação existente entre estas características e o processo de regeneração natural que ocorre nestes distúrbios (MARTINS e RODRIGUES, 2002). Nas clareiras a sucessão ecológica inicia com o aumento da radiação solar na floresta, provocando a germinação de sementes no solo (GOMES et al., 2010). Dessa forma, desempenham um papel importante na regeneração florestal, rotatividade de espécies e na dinâmica geral dos ecossistemas florestais (St-ONGE et al., 2014).

Devido a essa importância ecológica é necessária a quantificação desses distúrbios. Assim como em levantamentos florestais, a atividade de coleta de dados em campo é o método mais convencional, portanto o mais utilizado. Conforme Lima (2005), existem três métodos básicos para medir a área de clareira, o de Brokaw, que consiste na medição de até oito coordenadas de direção e distância até o limite da clareira, a partir de um ponto central; o de Green, que se assemelha ao de Brokaw, com a adição de oito medições e o de Runkle, que realiza um ajuste da largura e comprimento da clareira a uma fórmula de elipse.

Outro distúrbio antrópico de grande importância é a abertura de estradas, o qual tem como consequência a supressão da vegetação. A operação de desmatamento de uma estrada florestal principal necessita de se desmatar 20 m de largura, considerando-se o eixo da estrada

a ser construída (COSTA FILHO e DA COSTA, 1980). Conforme Aricak (2015), anualmente são gastos milhões de dólares para a construção de estradas e vias de acesso para a atividade florestal.

De acordo com White et al. (2010), as estradas florestais são importantes no manejo florestal e são indispensáveis para ter um mapa detalhado de cada estrada para fins de infraestrutura para proteção contra incêndios e transporte de produtos florestais. Além disso, conforme Azizi et al. (2014), a extração automática de estradas usando o sensoriamento remoto pode poupar tempo e custos de trabalho na atualização da base de dados de estradas florestais.

Métodos de mensuração e monitoramento das florestas vão surgindo à medida que se desenvolvem novas tecnologias. A mais difundida, especialmente em nível regional, é o uso de imagens obtidas por sensores embarcados em plataformas orbitais. Nos últimos anos houve grandes avanços na documentação de perdas históricas e anuais de florestas tropicais com o uso de satélites (HANSEN et al., 2013).

No Brasil, por exemplo, pode-se citar dois programas que monitoram o desmatamento na Floresta Amazônica operados pelo INPE (Instituto Nacional de Pesquisas Espaciais), o sistema DETER, que utiliza imagens do sensor MODIS com resolução espacial de 250 m, que visa detectar alterações na cobertura florestal (INPE, 2008) e o projeto PRODES, que mapeia a dinâmica do desmatamento por corte raso através dos satélites da série Landsat com resolução espacial de 30 m (INPE, 2013). No entanto, segundo Hunter et al. (2015) as imagens óticas passivas precisam lidar com os problemas apresentados pelas nuvens, que são predominantes nos trópicos úmidos.

Assim, a solução é a utilização de um sensor que possa obter dados da floresta abaixo da cobertura de nuvens. Este é o caso do sensor LiDAR (*Light Detection and Ranging*, em tradução livre, detecção de luz e alcance), que é um sensor ativo, ou seja, tem sua própria fonte de energia eletromagnética, e pode ser transportado em aeronaves. Pode-se considerar também como vantagens, a realização do voo em locais específicos e em diferentes resoluções, bastando alterar a altura de voo da aeronave. Para Popescu (2007), o LiDAR apresenta vantagem aos métodos de sensoriamento remoto óptico na obtenção de características da vegetação, desde árvores individuais até extensões regionais, pois possui alta intensidade amostral, medições diretas, geolocalização precisa e processamento autônomo.

O equipamento, tem potencial para a obtenção de medidas diretas tri dimensionais do dossel florestal que são usadas para estimar parâmetros de inventário florestal, como a altura das árvores, volume e biomassa (POPESCU et al., 2011). De acordo com Lin et al. (2016), enquanto parâmetros ao nível de árvore, como altura e diâmetro são obtidos no campo para, a

partir de modelos, estimar o volume, com o LiDAR a altura é obtida diretamente pelo sensor e o diâmetro é calculado a partir de métricas derivadas.

A viabilidade de dados LiDAR temporais proporciona uma estrutura espaço temporal para estudos sobre distúrbios e regeneração a fim de melhorar nosso entendimento destes processos dentro dos ecossistemas florestais (BLACKBURN et al., 2014). Assim, Melendy et al. (2018) recomendam o uso do LiDAR para monitorar e mensurar o impacto causado pela extração seletiva de madeira (abertura de clareiras, estradas e linhas de arraste), seja realizada legalmente ou até mesmo ilegalmente.

Como os produtos obtidos pelo processamento dos dados são oriundos de uma nuvem de pontos, a acurácia das métricas da estrutura florestal vai depender da densidade de pontos (JAKUBOWSKI et al., 2013). Por essa razão, de acordo com Yoga et al. (2017), é preciso investigar se fatores como a distribuição espacial dos retornos pode influenciar a predição ou a incerteza de modelos de atributos florestais.

1.1 OBJETIVOS

1.1.1 Objetivo geral

Este estudo teve como objetivo geral realizar a identificação e a delimitação das áreas de clareiras e estradas em floresta tropical empregando técnicas de processamento aplicadas a dados de sensoriamento remoto ativo obtidos por sensor LiDAR aerotransportado.

1.1.2 Objetivos específicos

- a) Identificar áreas de clareiras abertas em uma área de exploração florestal sustentável localizada na Amazônia;
- b) Quantificar as áreas de clareiras abertas em uma área de exploração florestal sustentável localizada na Amazônia;
- c) Verificar se há influência na detecção de clareiras à adoção de diferentes densidades de retornos registrados dos pulsos oriundos do sensor;
- d) Identificar e quantificar as aberturas correspondentes às estradas florestais.
- e) Verificar se há influência da densidade de retornos na identificação do traçado de estradas.

1.2 JUSTIFICATIVA

A Floresta Amazônica é a maior floresta tropical do mundo e abriga vasta biodiversidade de plantas e animais, atraindo, assim, as atenções da comunidade científica nacional e internacional para questões que envolvem sua proteção, conservação e uso sustentável de seus recursos naturais. O uso sustentável da floresta deve considerar a dinâmica de crescimento e desenvolvimento, conhecendo sua estrutura, regeneração e relações autoecológicas.

Distúrbios que afetam o equilíbrio da floresta como a formação de clareiras e a construção de estradas, precisam ser constantemente monitorados. Este acompanhamento já é realizado com o uso das geotecnologias, como é o caso do sensoriamento remoto orbital, que emprega sensores sensíveis à região do visível e do infravermelho do espectro eletromagnético. Porém, o nível de detalhe deste monitoramento varia dependendo da resolução espacial do sensor utilizado, além do mais, sobre a Floresta Amazônica há uma grande cobertura de nuvens, o que prejudica a aquisição de imagens por sensores óticos.

A alternativa encontrada dentro das geotecnologias é utilizar um sensor ativo, o qual possui sua própria fonte de radiação eletromagnética, que possa obter dados da floresta abaixo da cobertura de nuvens. É o caso do sensor LiDAR, que pode ser transportado em um avião e realizar voos sobre a floresta. Este sensor se destaca pela precisão dos dados adquiridos, inclusive medidas em três dimensões do terreno e vegetação.

Estes dados consistem em uma nuvem de pontos das quais se extraem produtos derivados. A precisão desses produtos está ligada à densidade de pontos dessa nuvem, que por sua vez vai depender do sensor. Outro fator que pode influenciar na densidade de pontos é o custo de aquisição, que será maior quanto for a densidade.

Deste modo, considerando que a densidade de pontos pode influenciar nos produtos gerados a partir da nuvem de pontos, este estudo se justifica por avaliar se a redução da densidade de pontos irá influenciar na identificação de distúrbios como clareiras e aberturas de estradas em um dossel florestal.

Assim, foram elaboradas as seguintes hipóteses:

- a) a redução na densidade de retornos influi na detecção das áreas de clareiras;
- b) o método de delimitação de clareiras permite identificar padrões na disposição das áreas detectadas e inferir sobre a possível origem do distúrbio.

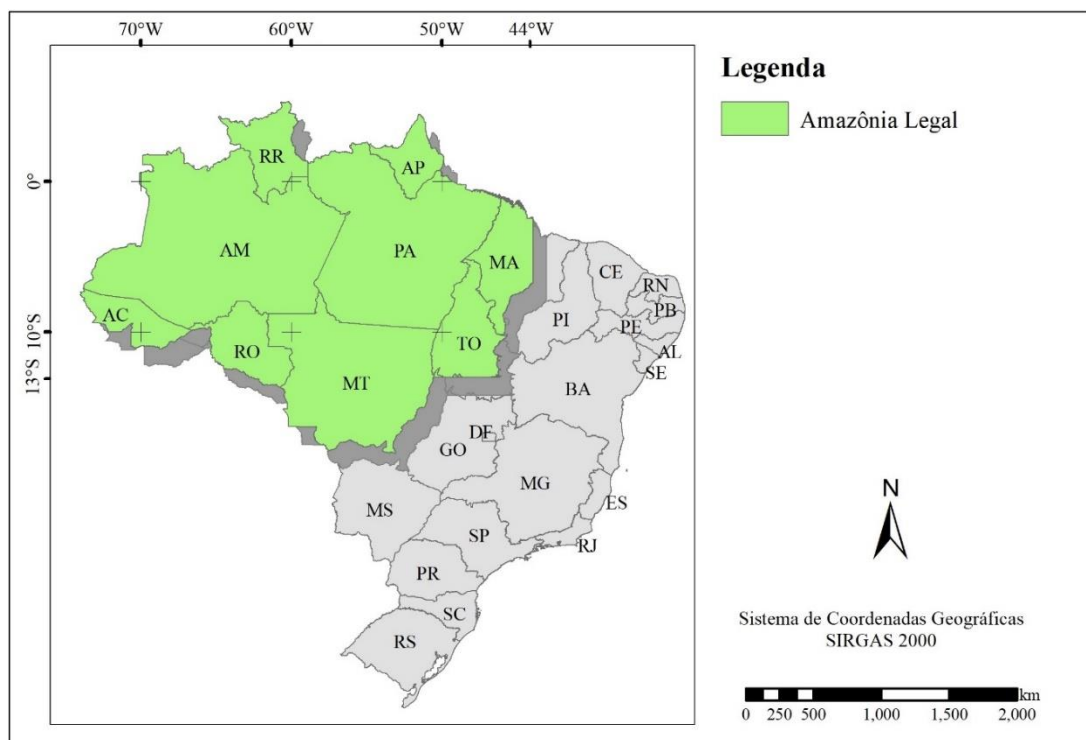
2 FUNDAMENTAÇÃO TEÓRICA

2.1 FLORESTA AMAZÔNICA

As florestas ocupam 30,6% da área coberta por terra do planeta, desta área 93% são de florestas naturais, classificadas em tropicais, subtropicais, temperadas e boreais (FAO, 2015). A Floresta Amazônica é a maior floresta tropical do mundo, sendo que 426,5 milhões de ha estão em território brasileiro (CLEMENT e HIGUCHI, 2006), caracterizando-se por uma enorme diversidade de ambientes, com mais de 600 tipos diferentes de habitats terrestres e de água doce, que abriga rica biodiversidade: cerca de 45 mil espécies de plantas e vertebrados conhecidos (BRASIL 2013). De acordo com Haddad et al. (2015), é o principal remanescente de floresta tropical do mundo, mas o progressivo desmatamento ameaça suas contribuições para o equilíbrio ambiental global.

No Brasil, a Floresta Amazônica está compreendida dentro da Amazônia Legal, a qual ocupa 59% do território brasileiro (PENNA FILHO, 2013). Corresponde aos territórios dos estados do Acre, Amazonas, Amapá, Mato Grosso, Pará, Rondônia, Roraima e parte do Maranhão e do Tocantins (Figura 1).

Figura 1 – Localização da Amazônia Legal.



Fonte: O autor.

Florestas tropicais são criticamente importantes para a subsistência humana, estabilidade climática e conservação da biodiversidade, porém estão sob constante ameaça (BARLOW et al., 2016). A maior parte da área desmatada é destinada à pecuária e, em menor proporção, à agricultura, inclusive grãos (SCHNEIDER et al, 2000). A fim de realizar ações de combate ao desmatamento o governo brasileiro atua através de programas como, o Projeto de Monitoramento do Desmatamento na Amazônia Legal por Satélite (PRODES) (INPE, 2013) e o Plano de Ações para a Prevenção e Controle do Desmatamento da Amazônia Legal (PPCDAm) (MMA, 2013)

A região amazônica é vista como prioridade mundial devido a sua importância na manutenção dos estoques de carbono e a sua contribuição em outros serviços ambientais valiosos (FEARNSIDE, 2016). Por isso, deve-se adotar práticas de manejo florestal sustentáveis para atividades de exploração da floresta.

De acordo com Pereira et al. (2010), a extração seletiva de madeira na Amazônia ocorre há mais de 30 anos, tendo na indústria madeireira a maior atividade econômica na região, destacando-se os estados do Mato Grosso, Rondônia e Pará. A exploração de impacto reduzido permite que a floresta se recupere até a próxima colheita, uma vez que são deixadas árvores em pé e é realizado o planejamento dos danos à toda a vegetação, inclusive à regeneração natural (HIRAI et al., 2012).

Um planejamento mal feito, ou a falta dele pode acarretar sérias consequências para a floresta. Segundo Braz (2010), são observadas na floresta densidades inadequadas de estradas de acesso para áreas com baixo potencial madeireiro, isto, além de acarretar no aumento dos custos de construção e manutenção de estradas, danifica a floresta desnecessariamente acelerando as modificações na sua composição e estrutura, reduzindo o estoque de madeira comercial para o próximo ciclo.

2.1.1 Floresta Ombrófila Densa


Conforme IBGE (2012), este tipo de vegetação é caracterizado por fanerófitos - subformas de vida macro e mesofanerófitos, além de lianas lenhosas e epífitas em abundância, que o diferenciam das outras classes de formações. No entanto, sua característica ecológica principal reside nos ambientes ombrófilos que marcam muito a “região florística florestal”.

De tal modo, a característica ombrotérmica da Floresta Ombrófila Densa está presa a fatores climáticos tropicais de elevadas temperaturas (médias de 25° C) e de alta precipitação, bem-distribuída durante o ano (de 0 a 60 dias secos), o que determina uma situação bioecológica praticamente sem período biologicamente seco (IBGE, 2012).

2.2 CLAREIRAS

Clareiras podem ser definidas, segundo Brokaw (1982), como uma abertura no dossel que se estende verticalmente para o solo, através de todos os níveis da vegetação, devendo ser definida a uma altura média de dois metros acima do solo. Para Runkle (1982), é uma área do solo sob a abertura do dossel, delimitada pelas bases das árvores de dossel que circundam a abertura do mesmo. A Figura 2 ilustra a definição de clareiras adotada por cada um dos autores.

Figura 2 – Comparação dos métodos de Brokaw e Runkle envolvendo clareiras.



Em que: As quedas das árvores A e B danificam as árvores C, D e E.

Fonte: Adaptado de van der Meer et al. (1994).

Segundo Frelich (2002), ao nível de árvore individual, em muitas florestas as clareiras abertas pela morte de árvores são o distúrbio natural dominante que afeta o crescimento da vegetação vizinha. São ambientes nos quais as condições de luz promovem alta taxa de

crescimento, mas não alteram apenas o seu próprio ambiente pois promovem mudanças na floresta ao seu redor (HUNTER et al., 2015)

Conforme Lima (2005), as clareiras podem ser formadas devido à queda de galhos, morte de árvores em pé que vão tendo suas copas fragmentadas e até mesmo desenraizamento das árvores, de qualquer forma, causam danos ao sub-bosque, variando a intensidade do dano. Para McCarthy (2001), as clareiras também podem ser abertas a partir de fenômenos meteorológicos, ataques de insetos e doenças.

Grandes clareiras são formadas quando o dossel é composto de grandes árvores, as quais são capazes de produzir grandes aberturas quando caem (MARTINS e RODRIGUES, 2002). A um dado tempo, a variabilidade das clareiras expressa padrões de mortalidade e danos físicos, além do preenchimento da clareira que ocorre via rebrota e sucessão secundária (ASNER et al., 2013). Vepakomma et al. (2018) não consideram clareiras outros tipos de aberturas como corpos de água, estradas e afloramentos rochosos.


A rotatividade da comunidade de árvores em florestas tropicais mistas é altamente dependente das aberturas do dossel, as quais são resultantes de quedas de árvores (CARVALHO et al., 2000), pois, conforme Carvalho et al. (2000), logo após a abertura do dossel há o aumento dos níveis de luz, que favorecem plantas já estabelecidas, as quais sobreviveram ao distúrbio de queda de árvores, incluindo, além de árvores imaturas e tolerantes à sombra do dossel, também árvores do sub-bosque e outras formas como ervas, bambus e lianas. Dessa forma, de acordo com Whitmore (1990), as clareiras, entre outros aspectos, contribuem para a diversidade, a qual se relaciona ao número ou riqueza de espécies pioneiras, por exemplo, as que dependem desse tipo de sítio para que possam regenerar com êxito.

2.3 SENSORIAMENTO REMOTO

O sensoriamento remoto, segundo Jensen (2011), consiste em instrumentos, tais como câmeras, escâneres, lasers, dispositivos lineares e/ou matriciais localizados em plataformas como aeronaves ou satélites, os quais registram informações de objetos sem contato físico, nas regiões do ultravioleta, visível, infravermelho e micro-ondas do espectro eletromagnético. Baseia-se na interação da radiação eletromagnética com os objetos da superfície terrestre como a vegetação, a água e o solo, estes objetos refletem, absorvem e transmitem radiação eletromagnética em porções que variam com o comprimento de onda, de acordo com suas características bio-físicas-químicas (FLORENZANO, 2011).

Conforme Rosette et al. (2012), o sensoriamento remoto ótico proporciona uma representação bidimensional da vegetação presente na superfície e sua reflectância pode ser relacionada indiretamente com parâmetros biofísicos como os índices de vegetação e índice de área foliar. De acordo com Ponzoni e Shimabukuro (2009), a reflectância é dada pela razão entre a quantidade de energia refletida e a energia que incide na superfície das folhas ou do dossel, enquanto que a transmitância é a razão entre o fluxo transmitido através do dossel e das camadas que constituem a folha pelo fluxo incidente. Uma folha verde sadia possui picos de reflexão nos comprimentos de onda nas faixas do visível (0,4 a 0,72 μm), infravermelho próximo (0,72 a 1,1 μm) e infravermelho médio (1,1 a 3,2 μm) (PONZONI et al., 2007). Essa interação da radiação eletromagnética com a vegetação pode ser conferida na Figura 3.

Figura 3 – Características espectrais da vegetação verde sadia.



Fonte: Adaptado de Jensen (2011).

Devido a essas interações da radiação eletromagnética com a vegetação, o sensoriamento remoto desenvolveu-se como uma técnica de grande importância para os estudos em florestas, possuindo diversas aplicações. Entre elas, estão a exploração seletiva de madeira (ASNER et al., 2005), incêndios florestais (KAZMIERCZAK, 2015), monitoramento florestal (JUCKER et al., 2016) e identificação de desmatamento (MILODOWSKI, et al., 2017). Em um

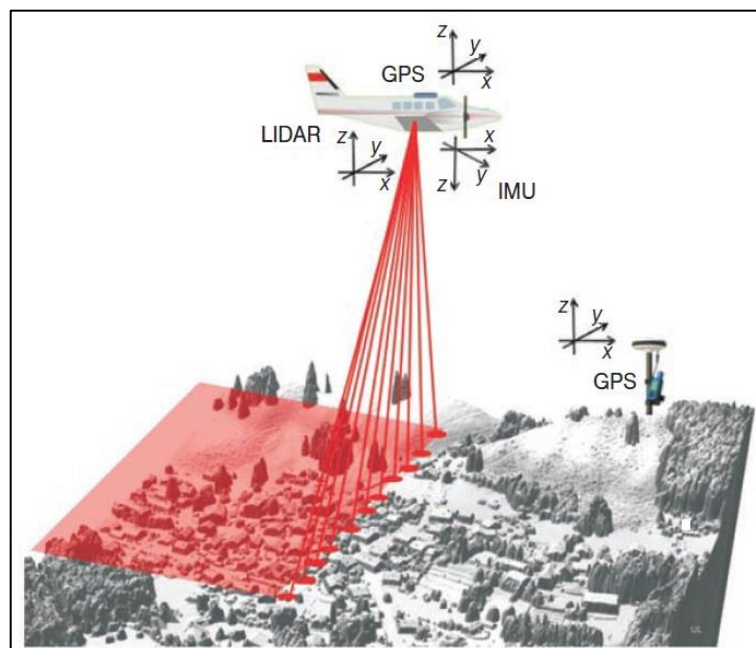
estudo em floresta tropical, Pithon et al. (2012) detectaram clareiras em dossel florestal a partir do sensoriamento remoto ótico de alta resolução.

2.3.1 LiDAR

O sistema LiDAR é um dispositivo de sensoriamento remoto ativo que mede o tempo de viagem necessária para um pulso de energia laser enviado do sistema sensor aerotransportado até o alcance do solo e refletir de volta ao sensor (POPESCU, 2007). Ainda, de acordo com o autor, o tempo medido é convertido em uma medida de distância que é usada para uma precisa caracterização da superfície refletida, incluindo a vegetação florestal.

Conforme Maltamo et al. (2014), a precisão dos dados é conferida devido à integração da tecnologia de posicionamento global por satélite (GNSS – *Global Navigation Satellite System*) com o sistema de navegação inercial (INS – *Inertial Navigation System*), que posicionam o sensor de forma acurada e, do mesmo modo, os dados registrados denominados retornos. Os retornos são pulsos refletidos nos alvos na superfície, constituindo-se em uma coleção de pontos distribuídos espacialmente, com coordenadas x , y e z , cada ponto representando um alvo interceptado ao longo do caminho iluminado pelo pulso laser (ZHAO et al., 2009). A Figura 4 apresenta um esquema de como é realizada a aquisição dos dados LiDAR e os componentes do sistema.

Figura 4 – Aquisição de dados LiDAR aerotransportado e componentes do sistema.




Fonte: Beraldin et al. (2010).

Os pulsos emitidos pelo sensor LiDAR penetram no dossel florestal e oferecem informações tridimensionais sobre a estrutura do dossel e a topografia abaixo dele, o que não é possível de se obter usando outras técnicas de sensoriamento remoto (HEISKANEN et al., 2015). Em áreas com cobertura de vegetação densa, os pulsos podem refletir principalmente do topo e entre o dossel vegetal, com alguns pulsos penetrando até o nível do solo e, assim, proporcionando uma acurada elevação do terreno (POPESCU, 2007).

Muitos sistemas LiDAR usam para a análise da vegetação o comprimento de onda do pulso na região do infravermelho próximo do espectro eletromagnético (ROSETTE et al., 2012). No entanto, segundo Karila et al. (2017), há sensores como o Opitech Titan que possuem pulsos com diferentes comprimentos de onda, no infravermelho (1550 nm), infravermelho próximo (1064 nm) e no verde (532 nm). O dossel representado em três dimensões pode ser conferido na Figura 5.

Figura 5 – Representação em 3D de um dossel florestal a partir de dados LiDAR.



Fonte: Adaptado de Roncat et al. (2014).

Conforme Zhao et al. (2009), é possível extrair um número infinito de possíveis métricas derivadas de dados LiDAR, as quais dependerão das características dos dados, número de retornos gravados por pulso e se há ou não informações auxiliares como a intensidade e o ângulo de escaneamento. O número de retornos por pulso varia de acordo com o sensor utilizado, como o caso de Jakubowski et al. (2013), que utilizou um sensor que registra até quatro retornos por pulso, chegando a uma densidade superior a 20 ppm², enquanto que Kukunda et al. (2018) utilizou um que registra até sete retornos por pulso, resultando em uma densidade de 160 ppm².

Os custos de aquisição dos dados, assim como a performance de processamento dos mesmos, são influenciados pela densidade de pontos (ANDERSON et al., 2005; TESFAMICHAEL et al., 2014). Devido a essas condições, estudos sobre redução da densidade de pontos foram realizados a fim de verificar o impacto dessa redução nas variáveis obtidas por dados LiDAR (JAKUBOWSKI et al., 2013; LI et al., 2013; TREITZ et al., 2012; MANURI et al., 2017; YOGA et al., 2017). Apesar da redução substancial da densidade de pontos, os dados LiDAR ainda possuem um número maior de pontos de referência de elevação que os modelos digitais de elevação (DEM – *Digital Elevation Model*) derivados de fotogrametria do Serviço Geológico dos Estados Unidos (USGS – *United States Geological Survey*) (ANDERSON et al., 2005).

Os retornos constituem uma nuvem de pontos que, segundo Rosette et al. (2012), proporciona a geração de dois produtos cartográficos, o modelo digital do terreno (DTM – *Digital Terrain Model*) e o modelo digital de superfície (DSM – *Digital Surface Model*), os quais são usados para descrever o terreno e o topo da superfície florestal, respectivamente. A partir do DTM e do DSM é gerado o modelo de alturas do dossel (CHM – *Canopy Height Model*), o qual proporciona estimativas acuradas de importantes parâmetros florestais como a altura do dossel, volume e a estrutura vertical do dossel.

Com estes parâmetros oriundos do processamento dos dados LiDAR, é possível desenvolver aplicações voltadas para a vegetação, como biomassa (LEITOLD et al., 2015; SATO et al., 2016; CHEN et al., 2016), carbono, (LONGO et al., 2016; LIN et al., 2016), efeitos da seca na Amazônia (MOURA et al., 2015) e exploração seletiva (ANDERSEN et al., 2014).

Para estudos florestais em particular, o LiDAR é capaz de caracterizar efetivamente tanto o terreno quanto a estrutura da vegetação (LEITOLD et al., 2015). Segundo Kaartinen et al. (2012), em países nórdicos a obtenção de características como altura média, altura dominante, diâmetro médio, número de fustes, área basal e volume do fuste, as quais são necessárias no planejamento do manejo florestal, estão sendo substituídas por métodos de inventário baseados em LiDAR.

Além do mais, em conformidade com Duncanson et al. (2015), o LiDAR abre a possibilidade para medidas rápidas e acuradas da altura e dimensão de copa de milhões de árvores. Segundo Kaartinen et al. (2012), os dados lidar podem ser processados ao nível de povoamento (ou parcela), no qual relacionam-se as métricas extraídas das parcelas com os atributos do povoamento como altura dominante, altura total, diâmetro médio, área basal e volume, e também ao nível de indivíduo, em que após a identificação das árvores, atributos como altura e diâmetro de copa são extraídos dos retornos LiDAR e correlacionados com atributos dendrométricos medidos no campo.

Para Yang et al. (2015), que integraram imagens suborbitais com dados LiDAR, o sensoriamento remoto proporcionou uma eficiente e acurada ferramenta para a identificação automática de clareiras, quando comparada à interpretação manual, não se limitando apenas a melhorar a identificação, mas também subsidiar o manejo de ecossistemas florestais em se tratando de dinâmica de clareiras. Blackburn et al. (2014) estudaram o mapeamento de mudanças em clareiras e propriedades do dossel de uma floresta decidual de folhas largas a partir de dados LiDAR multi temporais.

O LiDAR é um método de sensoriamento remoto ativo promissor para a análise tanto da frequência, quanto da distribuição do tamanho das clareiras, pois proporciona informação acurada de altura, muitas vezes a partir de múltiplas medidas por metro quadrado (HUNTER et al., 2015). O uso de dados LiDAR proporciona uma alta acurácia na detecção de clareiras, sugerindo que esta técnica é uma excelente ferramenta para a delimitação e mapeamento contínuo de clareiras (St.-ONGE e VEPAKOMMA, 2012; VEPAKOMMA et al., 2008).

De acordo com Azizi et al. (2014), as estradas são importantes para o manejo florestal e podem ser obtidas de forma acurada e eficiente usando dados LiDAR de alta resolução, o qual reduz a necessidade de ir a campo coletar informações desse parâmetro básico. Dados de estradas derivados de LiDAR podem preencher lacunas existentes nas fontes de dados especialmente em áreas florestadas, representando uma valiosa ferramenta para acessar estradas florestais não previstas (WHITE et al., 2010).

2.4 ESTRADAS FLORESTAIS

De acordo com Costa Filho e Da Costa (1980), existem três classes de estradas florestais para a Amazônia: Estrada Permanente Principal, a qual possui pista dupla e largura de no mínimo 8m, revestida de piçarra ou material equivalente sendo destinada para o tráfego em velocidades altas (50 a 60 km/h); Estrada Permanente Secundária, a qual se constitui em pista

única de 4 m de largura com o mesmo revestimento da Principal, porém a velocidade de tráfego é baixa (20 a 30 km/h); Estrada Temporária para verão, conta com pista única com largura de 4 m sem revestimento especial e utilizada em épocas secas.

Segundo Kiss et al. (2015), as estradas florestais desempenham um importante papel nas operações florestais, permitindo o manejo florestal e acesso fácil aos locais de colheita pelo maquinário, aumentando a disponibilidade de recursos florestais e permitindo o transporte aos locais de processamento da madeira. Oferecem, também, possibilidades às operações de silvicultura mecanizada, recreação, coleta de produtos não madeireiros e acesso a serviços protetivos como o combate ao fogo e operações de resgate (KISS et al., 2016).

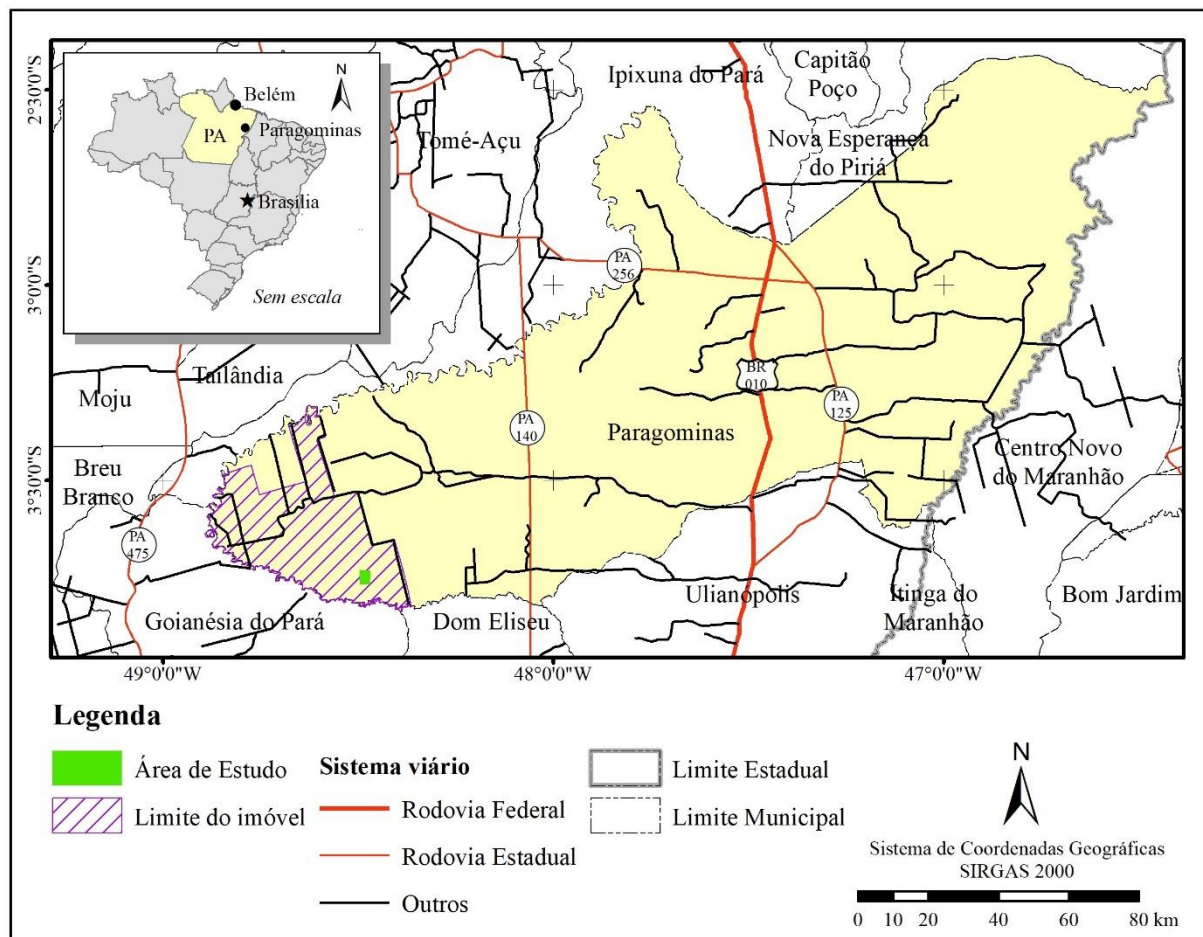
3 MATERIAIS E MÉTODOS

3.1 ÁREA DE ESTUDO

3.1.1 Localização

A área de estudo está localizada a $3^{\circ}44'59''$ de latitude sul e $48^{\circ}28'51''$ de longitude oeste, na Fazenda Cauaxi. A fazenda pertence ao complexo de fazendas Rio Capim, situada no município de Paragominas, a qual está inserida na área de domínio do Grupo Cikel (Figura 7).

Figura 7 – Localização da área de estudo na Fazenda Cauaxi, Paragominas – PA.



Fonte: O autor.

3.1.2 Caracterização da área de estudo

O complexo Rio Capim é composto por 6 propriedades com área total de 209.248,6185 hectares, localizadas no município de Paragominas, denominadas Rio Capim, Sumal, Poty, Caculé, Cauaxi I e Cauaxi II. Estas fazendas pertencem ao Grupo CIKEL, e atualmente estão sob gestão da empresa CKBV FLORESTAL LTDA do mesmo Grupo, onde executa a atividade de manejo florestal (CIKEL, 2018).

A classificação climática para a região, segundo Köppen, é do tipo “Awi”, isto é, tropical chuvoso com estação seca bem definida. A precipitação média anual está em torno de 1.800 mm com temperatura média anual de 26,3 °C e umidade relativa do ar de 81% (ALVARES et al. 2013).

A área apresenta uma topografia que vai de plana a suavemente ondulada, sendo identificada como pertencente à Região Geomorfológica Planalto Setentrional Pará-Maranhão (Brasil, 1973). A área é banhada pelas bacias dos rios Capim, que limita a área ao noroeste, e o do Surubijú, que faz limite ao sul (CARDONA, 2012). Conforme Radambrasil (1983), os solos são classificados como Latossolo Amarelo Distrófico.

3.1.2.1 Vegetação

A vegetação originária do município é representada pela floresta densa da sub-região dos altos platôs do Pará-Maranhão, pela floresta densa de planície aluvial e dos terraços. Entretanto, os constantes desmatamentos, provocados pelo avanço da agropecuária na região, reduziram, drasticamente, as grandes áreas cobertas pela floresta original, dominadas, hoje, por extensas áreas de mata secundária, caracterizadas por capoeira nos seus diversos estágios de desenvolvimento (CARDONA, 2012)

As principais espécies exploradas na área são *Manilkara huberi* (Ducke) A.Chev., *Hymenaea courbaril* L., *Astronium lecointei* Ducke, *Parkia pendula* (Wild.) Benth. ex Walp., *Couratari oblongifolia* Ducke & Knuth e *Pouteria bilocularis* (Winkler) Baehni (MAZZEI et al. 2010).

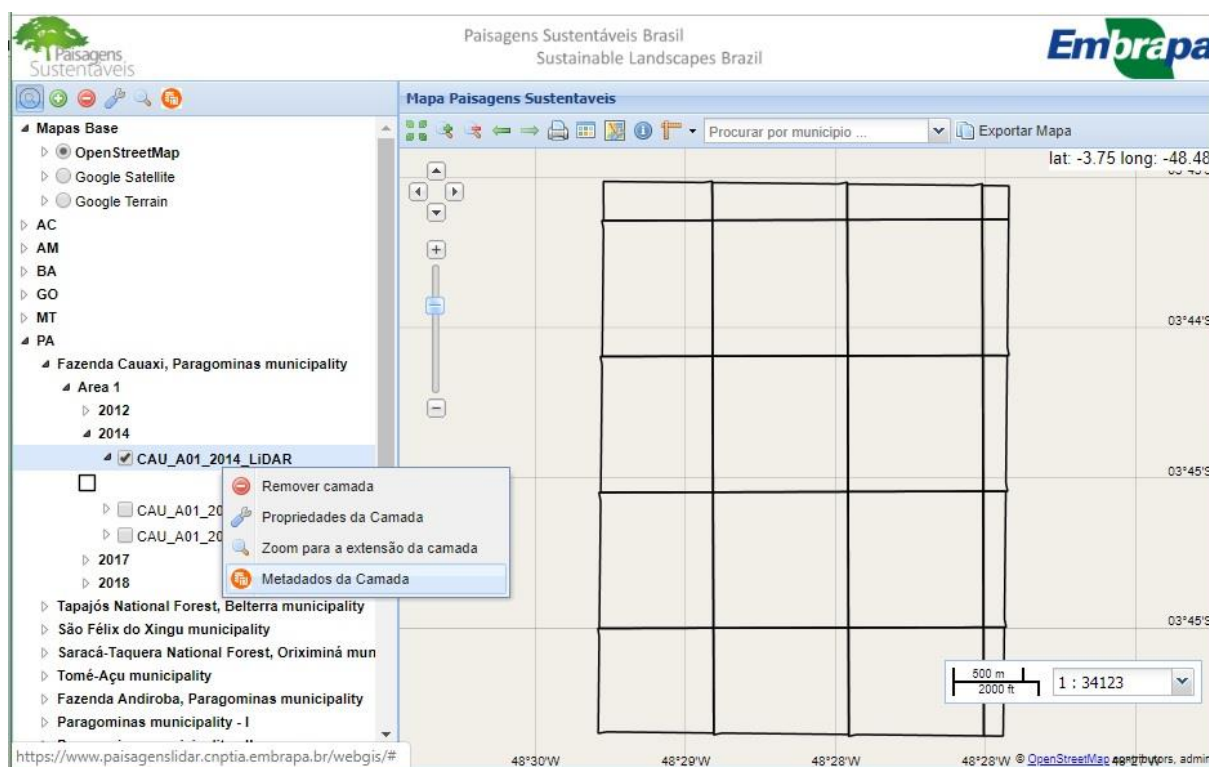
3.2 AQUISIÇÃO DOS DADOS

3.2.1 Projeto Paisagens Sustentáveis Brasil

O Projeto Paisagens Sustentáveis Brasil é um projeto de cooperação técnica e financiado pela Agência dos Estados Unidos para o Desenvolvimento Internacional e o Departamento de

Estado dos Estados Unidos (EMBRAPA, 2014). De acordo com Embrapa (2016), o projeto conta com um WebGIS onde disponibiliza os dados adquiridos com o sensor LiDAR e a base de dados de inventários florestais em áreas dos biomas Amazônia, Cerrado e Mata Atlântica (Figura 6).

Figura 6 – Janela do *WebGIS* do Projeto Paisagens Sustentáveis.



Fonte: Adaptado de Embrapa (2018).


O projeto, de acordo com Embrapa (2014), conta com a participação do Serviço Florestal Americano e a Empresa Brasileira de Pesquisa Agropecuária (Embrapa) e visa gerar informações detalhadas da superfície do terreno e da vegetação, assim, contribuindo para o desenvolvimento de técnicas de medição e mitigação dos efeitos do dióxido de carbono e outros gases de efeito estufa.

3.2.2 Dados de Inventário Florestal

O inventário florestal foi realizado pelo Instituto Floresta Tropical entre os dias 18 de fevereiro e 25 de abril de 2014. Foram distribuídas na área 22 parcelas com dimensões de 20 m

x 500 m, compreendendo uma área de 10.000 m² totalizando uma área de 22 ha, igualmente 22 sub-parcelas de 2 x 500 m (Figura 8), porém os dados dessas não foram utilizados nesse trabalho. As árvores com diâmetro à altura do peito (DAP) superior ou igual a 35 cm foram medidas.

Figura 8 – Croqui da parcela de inventário florestal.



Fonte: Adaptado de Embrapa (2014).

Entre as variáveis obtidas estão o número da árvore, nome comum, nome científico, família botânica, DAP, altura comercial, altura total, raio de copa norte, raio de copa sul, raio de copa leste, raio de copa oeste, coordenada UTM E e coordenada UTM N. As coordenadas foram adquiridas no *datum* SIRGAS 2000, fuso 22 Sul.

3.2.3 Dados LiDAR

O sensor LiDAR utilizado para a aquisição dos dados foi o *scanner* da fabricante Optech, modelo Orion M300, 09SEN243. Outros sensores fazem parte do conjunto de equipamentos embarcados com o LiDAR, como a Unidade de Medição Inercial (IMU – *Inertial Measurement Unit*) Litton, 413996 e o Sistema de Navegação Global por Satélite (GNSS – *Global Navigation Satellite System*) Applanix, 09SEN243. Os dados foram obtidos no *datum* SIRGAS 2000 com o sistema de projeção cartográfica Universal Transversa de Mercator (UTM), fuso 22 Sul.

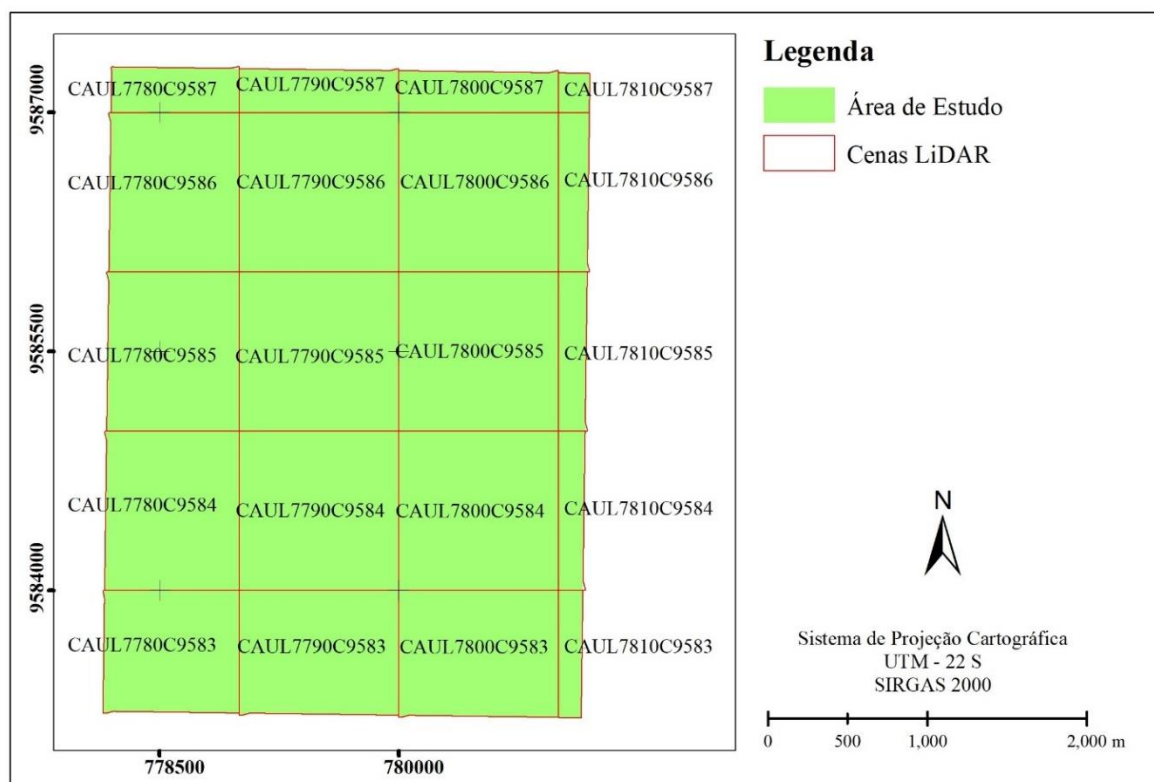
Os dados foram adquiridos em dois dias consecutivos, 26 e 27 de dezembro de 2014, por meio do voo realizado pela empresa Geóid Aerolevantamento Ltda. As informações técnicas do voo estão disponíveis na Tabela 1.

Tabela 1 – Informações técnicas do voo.

Informação	Valor
Área recoberta	1.216ha
Número de cenas	20
Sobreposição das faixas	65%
Campo de visada	12°
Altitude média de voo	850m
Densidade média de retornos	61,38ppm ²
Densidade média de primeiros retornos	37,5ppm ²
Frequência de escaneamento	83Hz
Frequência do GNSS	5Hz
Frequência da IMU	100kHz

As cenas adquiridas por este voo foram compostas por uma nuvem de pontos no formato *.las. A Figura 9 mostra as cenas das nuvens de pontos sobre a área de estudo.

Figura 9 – Conjunto de cenas LiDAR sobre a área de estudo.



Fonte: O autor.

O formato **.las* é o padrão da nuvem de pontos, de acordo com Goergens et al. (2014), foi criado pela Sociedade Americana de Fotogrametria e Sensoriamento Remoto (ASPRS – *American Society for Photogrammetry and Remote Sensing*) a fim de padronizar e facilitar a troca de arquivos entre provedores de serviço, desenvolvedores de *software* e usuários. Outro formato usual é o **.laz*, uma versão compactada possuindo de 7 a 25 % do tamanho original do arquivo **.las* (ISENBURG, 2012).

3.3 IDENTIFICAÇÃO DE CLAREIRAS

3.3.1 Definição da área mínima de clareira

A área mínima para ser considerada uma clareira foi definida adaptando-se o método de Hunter et al. (2015), considerando uma clareira a área ocupada pela copa de uma árvore caso esta tenha sido removida. A partir dos raios das copas medidos no inventário florestal, calculou-se o raio médio de cada árvore fazendo a média das quatro direções medidas (norte, sul, leste e oeste). Posteriormente, a partir do raio médio, calculou-se as áreas das copas. As áreas menores que 1 m² foram excluídas por serem menores que a resolução de 1m dos arquivos *raster* gerados.

A partir da estatística descritiva do conjunto das áreas das copas, definiu-se como parâmetro a mediana. A mediana é indicada quando o conjunto de dados possui valores extremos discrepantes dos demais, o que pode comprometer a discussão dos dados baseados simplesmente na média (MELLO e PETERNELLI, 2013).

3.3.2 Processamento da nuvem de pontos LiDAR

A nuvem de pontos foi processada no *software* FUSION/LDV. Este *software*, de distribuição gratuita e desenvolvido pelo *Silviculture and Forest Models Team, Research Branch of the US Forest Service*, é uma eficiente ferramenta que permite analisar e visualizar os dados de LiDAR (MCGAUGHEY, 2016).

O FUSION/LDV dispõe de uma série de ferramentas, as quais foram utilizadas neste estudo. Foram as seguintes:

- a) *ThinData* – equaliza a densidade de retornos, criando um mosaico caso haja mais de uma cena compondo a nuvem de pontos (extensão *.las). Tem a densidade de retornos para a qual será equalizada a nuvem como um parâmetro de entrada;
- b) *Catalog* – resumo descritivo da nuvem de pontos. Tem como entrada a nuvem de pontos (extensão *.las), podendo ser composta por uma ou mais cenas ou o produto da ferramenta *ThinData*;
- c) *groundFilter* – filtra os retornos que foram refletidos ao nível do solo. Tem como entrada o produto da ferramenta *ThinData*;
- d) *GridSurfaceCreate* – gera o DTM. Tem como entrada o produto da ferramenta *groundFilter*;
- e) *ClipData* – normaliza e gera o DSM. Tem como entrada os produtos das ferramentas *ThinData* e *GridSurfaceCreate*;
- f) *canopymodel* – gera o CHM;
- g) *TreeSeg* – segmenta as copas das árvores individualmente. Tem como entrada o CHM.

Anteriormente à execução do código com as ferramentas que fizeram o processamento da nuvem, foi executado o *Catalog*, sem a equalização de pulsos, a fim de se obter um relatório sobre a nuvem, o qual informa, entre outros parâmetros, a densidade média de retornos em pontos por metro quadrado (ppm²) de toda a nuvem e, também, de cada cena. Obteve-se, assim, a informação da menor densidade entre as cenas, ou seja, a densidade mínima, partiu-se, então, desse valor para equalizar a densidade de pulsos.

Dessa forma, executou-se o código com a densidade mínima calculada e posteriormente frações dessa densidade, 75%, 50%, 25%, 10% e 2%. Do mesmo modo, Almeida et al. (2019) utilizaram frações de densidade de retornos, porém com valores absolutos definidos a priori (30, 25, 20, 15, 10, 5 e 2 ppm²), em um estudo envolvendo índice de área foliar e perfil de densidade de área foliar.

A ferramenta *TreeSeg*, que realiza a segmentação das copas, foi utilizada para realizar a segmentação das clareiras, para tanto foi necessário ajustar seus parâmetros. O limiar de altura foi ajustado para 2 m, conforme a definição de clareiras de Brokaw (1982). Dessa forma, as células do CHM pertencentes ao dossel acima desse limiar foram segmentadas, pertencendo a uma única classe.

Outro parâmetro ajustado foi a altura máxima, 2 m, o que significa que apenas os retornos abaixo dessa altura foram segmentados. Assim, o produto gerado consiste em um *raster* segmentado em área de dossel e áreas de clareiras. No caso da segmentação para a

identificação das estradas, os parâmetros utilizados foram de 0,1 m para o limiar de altura bem como para a altura máxima, logo, apenas os pontos próximos ao nível do solo foram utilizados na segmentação.

Juntamente com as ferramentas que geraram os arquivos *raster*, *GridSurfaceCreate*, *canopymodel* e *TreeSeg*, foi adicionado ao código a ferramenta *dtm2ascii*, a qual transformou a extensão **.dtm* do *raster* para a extensão **.asc*, isto permitiu que os arquivos com esta extensão fossem carregados, visualizados e manipulados nos ambientes dos programas de geoprocessamento.

3.3.3 Identificação das áreas de clareiras e estradas

Os arquivos *raster* na extensão **.asc*, resultantes da ferramenta *TreeSeg*, foram adicionados ao ambiente do QGIS 2.14, *software* livre de geoprocessamento, para a transformação dos dados em extensão **.tif*, viabilizando as operações geoespaciais sobre os mesmos. A fim de eliminar células espúrias das bordas, foi definido um retângulo envolvente, o qual foi usado para recortar os arquivos *raster*.

Foi realizada uma operação de agrupamento de células contíguas do *raster*, dessa forma cada área de clareira assumiu um valor identificador próprio, o que permitiu que fossem analisadas individualmente cada clareira. Adicionou-se à tabela de atributos o campo *area_m2*, área em metros quadrados, no qual foi calculado a área de cada clareira e também do dossel, adicionando-se o campo “*Classe*” para inserir o nome da classe.

As clareiras foram classificadas conforme a área, obedecendo critérios adaptados da literatura. Três classes foram estabelecidas, conforme a Tabela 2.

Tabela 2 – Classes de tamanho de áreas de clareiras.

Área (m ²)	Classe	Codinome	Referencia
a.min – 149	Clareiras pequenas	Classe 1	Tabarelli e Mantovani (2000)
150 – 399	Clareiras grandes	Classe 2	Brokaw (1985); Tabarelli e Mantovani (2000)
≥ 400	Clareiras grandes e raras	Classe 3	Brokaw (1985); Lima (2005)

Em que: a.min = área mínima de clareira encontrada.

As estradas foram identificadas com a análise do *raster* segmentado, não sendo realizada nenhuma classificação nas áreas. Com o objetivo de identificar o traçado das estradas presentes abaixo do dossel, foram analisadas as diferentes densidades utilizadas na identificação das clareiras. Dessa forma realizou-se uma análise visual das áreas segmentadas e que permitissem uma vetorização do traçado sobre o *raster*.

Foram criados *shapefiles* para cada densidade e adicionado o campo *compr_m*, a fim de se calcular o comprimento dos segmentos. Adicionalmente, foi utilizado o DTM gerado sob as áreas, assim, verificou o traçado aparente, analisando sua posição em relação às maiores altitudes ou em altitudes menores, o que poderia caracterizar um curso de água.

3.3.4 Análise Estatística

Os procedimentos estatísticos foram realizados por meio do desenvolvimento de códigos na linguagem de programação científica R, usando o ambiente de desenvolvimento integrado (*Integrated Development Environment* – IDE) RStudio. R é uma linguagem e ambiente *open source* para computação que proporciona uma vasta variedade de análise estatística (modelamento linear e não linear, testes estatísticos clássicos, análise de series temporais, classificação, agrupamento, etc.) e técnicas gráficas, sendo altamente extensível por pacotes (R CORE TEAM, 2017).

A fim de se determinar qual o teste estatístico mais apropriado, paramétrico ou não-paramétrico, para avaliar se houve diferença entre as densidades de retornos para a identificação de clareiras, adotou-se um teste para verificar o preceito de normalidade do conjunto de dados. Para tal, foi utilizado o teste de *Kolmogorov-Smirnov*, que admite a normalidade dos resíduos caso seja aceita a hipótese nula.

Outro preceito para a definição de qual teste utilizar é o da homocedasticidade das variâncias. Para isso, foi utilizado o teste de *Bartlet*, desse modo, caso a hipótese nula seja aceita, admite-se a homocedasticidade das variâncias. A fim de avaliar se houve diferença significativa entre os tratamentos, adotou-se um teste não-paramétrico, o teste de *Kruskal-Wallis*.

4 RESULTADOS E DISCUSSÃO

4.1 DEFINIÇÃO DA ÁREA MÍNIMA

A estatística descritiva do conjunto de áreas de copa das árvores está demonstrada na Tabela 3. A média das áreas de copa das árvores para a área de estudo foi de 55,40m², associada a um desvio padrão de 64,88m², o que indicou a existência de uma grande variabilidade no conjunto de dados.

Tabela 3 – Estatística descritiva das áreas de copa.

Medida estatística	Área (m²)
Média	55,404
Mediana	34,732
Moda	28,274
Desvio padrão	64,878
Mínimo	1,039
Máximo	1.069,406
Contagem	2.215 (árvores)

Dessa forma, adotou-se a mediana, a qual apresentou o valor de 34 m² como sendo a área mínima de clareira, o que ficou dentro do intervalo recomendado por Brokaw (1985) de 20 a 40m² a partir de estudos de campo. Esse estudo utilizou área semelhante à definida por Blackburn et al. (2014) de 30m² em um estudo no sul da Inglaterra em floresta temperada decidual de folhas largas, do mesmo modo, similar à menor clareira, 35m², estudada por Martins et al. (2004) em floresta semidecidual mesofítica no sudeste do Brasil e Tabarelli e Mantovani (2000) de 30,3m² em estudo na Floresta Atlântica na Serra do Mar, Brasil.

4.2 PROCESSAMENTO DA NUVEM DE PONTOS LIDAR

O processamento inicial da nuvem de pontos no FUSION/LDV com a ferramenta *Catalog* retornou uma densidade média de retornos de 61,38 ppm², enquanto que a cena com a menor densidade média de retornos foi de 37,55 ppm². Portanto, a densidade inicial de retornos adotada foi de 37 ppm², a fim de que houvesse homogeneidade na densidade de retornos em toda a área de estudo, sendo usada como referência para as demais densidades de retornos analisadas.

As densidades de retornos usadas foram 37, 28, 18, 9, 4 e 1 ppm² (100%, 75%, 50%, 25%, 10% e 2%, respectivamente). Estes valores foram inseridos como parâmetro da ferramenta *ThinData*, que equalizou a densidade de retornos em toda a área, sendo realizada uma rotina de processamento separadamente para cada uma das densidades. Os tratamentos foram, codificados com a inclusão da densidade correspondente: T1D37, T2D28, T3D18, T4D09, T5D04 e T6D01, respectivamente, as densidades de 37, 28, 18, 9, 4 e 1 ppm².

Os produtos intermediários gerados pela rotina de processamento foram o DTM e o CHM com 1 metro de resolução espacial. Os valores de altitude do DTM e de altura do CHM podem ser conferidos na Tabela 4.

Tabela 4 – Valores do DTM e do CHM por tratamento.

Tratamento	DTM (m)		CHM (m)
	Mínimo	Máximo	
T1D37	73,89	161,71	78,36
T2D28	73,89	165,98	75,15
T3D18	73,89	175,84	69,52
T4D09	73,89	175,84	75,15
T5D04	73,89	178,95	69,36
T6D01	74,26	179,65	69,57

Observou-se que a altitude mínima do DTM permaneceu a mesma com a diminuição da densidade, 73,89 m, exceto T6D01 que registrou altitude mínima de 74,26 m. Ao passo que os valores máximos aumentaram conforme a densidade foi diminuindo, indicando que as altitudes máximas são mais sensíveis à redução da densidade de pontos. Conforme Leitold et al. (2015), uma baixa densidade de pontos ocasiona em uma menor acurácia do DTM, os autores compararam pontos de controle de GNSS com o DTM e verificaram que os erros do DTM aumentam conforme a densidade de pontos diminui.

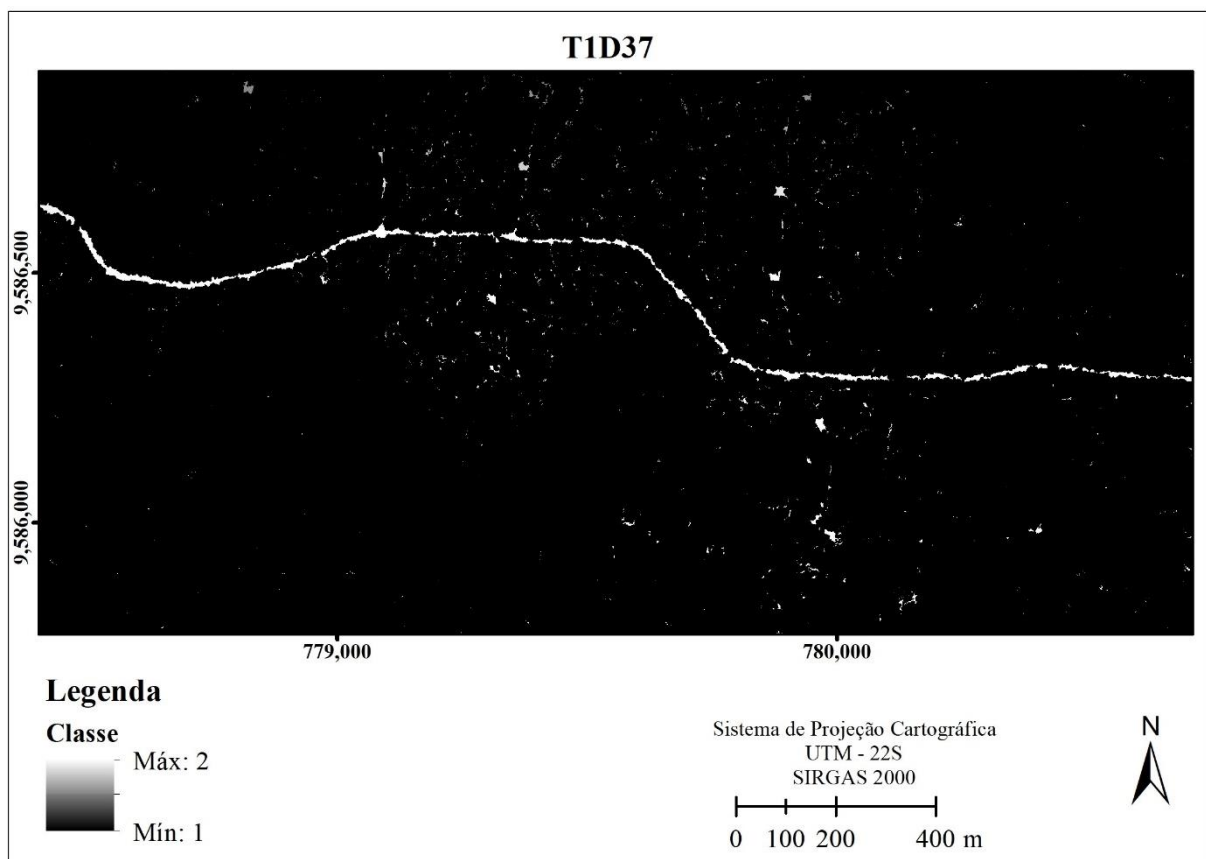
Anderson et al (2005) também encontraram a indicação do aumento do erro à medida que a densidade diminuiu, os autores explicam que é uma tendência esperada, já que baixas densidades proporcionam maiores espaços entre os pontos, como foi observado por Hruza et al. (2018), que utilizaram baixa densidade de pontos (1,13 ppm²) e obtiveram um DTM de baixa precisão. A variabilidade da acurácia do DTM introduz erros nos cálculos da altura do dossel, geralmente levando a estimativas errôneas das métricas relacionadas à floresta (LEITOLD et al., 2015). As alturas do CHM também variaram, onde a maior altura foi encontrada em T1D37 (78,36 m), enquanto que a menor em T5D04 (69,36 m).

O produto final, gerado pela ferramenta *TreeSeg* (baseado no CHM) foi um arquivo *raster* com a extensão *.asc* contendo a segmentação das áreas de clareiras, correspondendo ao conjunto de *pixels* abaixo de 2m e *pixels* acima deste limiar, neste caso, a área de dossel.

4.3 IDENTIFICAÇÃO DAS ÁREAS DE CLAREIRAS

Com o recorte do *raster*, já em formato *.tif*, a partir do retângulo envolvente, a área de estudo passou de 1.216 ha para 1.174 ha, uma diferença de apenas 3,45%. Os *pixels* foram agrupados de acordo com o limiar de altura de 2 m, dessa forma, o arquivo *raster* resultante passou a ter apenas duas classes e cada um dos polígonos segmentados, ou seja, as áreas de clareiras, possuindo um identificador (ID) próprio (Figura 10).

Figura 10 – *Raster* resultante da segmentação do CHM com *pixels* agrupados.



Fonte: O autor.

Após o cálculo das áreas, as clareiras maiores ou iguais a 34 m² foram classificadas conforme as classes previamente definidas (Tabela 5), enquanto que as áreas menores que 34 m² foram removidas, assim como em Blackburn et al. (2014), e incorporadas à classe Dossel, no caso deste estudo.

Tabela 5 – Estatística descritiva dos tratamentos por classe de área de clareira.

Classe	PD	T1D37	T2D28	T3D18	T4D09	T5D04	T6D01
Classe 1	A.tot	9.742,00	10.267,00	11.738,00	10.167,00	19.130,00	17.379,00
	A.min	34,00	34,00	34,00	34,00	34,00	34,00
	A.max	147,00	147,00	147,00	147,00	146,00	149,00
	A.med	62,85	63,38	62,44	63,54	61,51	63,66
	var	810,92	876,91	888,96	881,36	791,55	775,43
	sd	28,48	29,61	29,82	29,69	28,13	27,85
	N	155,00	162,00	188,00	160,00	311,00	273,00
Classe 2	A.tot	9.084,00	8.800,00	9.063,00	8.797,00	12.220,00	12.046,00
	A.min	151,00	153,00	151,00	153,00	151,00	150,00
	A.max	397,00	386,00	396,00	386,00	392,00	382,00
	A.med	232,92	231,58	232,38	231,50	244,40	231,65
	var	5.492,44	5.013,44	4.755,45	4.997,28	5.477,59	3.852,94
	sd	74,11	70,81	68,96	70,69	74,01	52,07
	N	39,00	38,00	39,00	38,00	50,00	52,00
Classe 3	A.tot	17.665,00	18.213,00	18.979,00	18.221,00	20.939,00	12.911,00
	A.min	419,00	403,00	414,00	403,00	405,00	401,00
	A.max	3.391,00	3.398,00	3.802,00	3.399,00	3.708,00	3.297,00
	A.med	929,74	910,65	948,95	910,55	1.046,95	860,73
	var	496.073,90	485.124,70	598.175,70	485.133,10	587.919,00	542.360,10
	sd	704,33	696,51	773,42	696,52	766,76	736,45
	N	19,00	20,00	20,00	20,00	20,00	15,00
Clareiras (ha)		3,65	3,73	3,98	3,72	5,23	4,23
Dossel (ha)		1.170,35	1.170,27	1.170,02	1.170,28	1.168,77	1.169,77
Área total (ha)		1.174,00	1.174,00	1.174,00	1.174,00	1.174,00	1.174,00

Em que: PD = parâmetro descritivo, A.tot = área total (m²), A.min = área mínima (m²), A.max = área máxima (m²) e A.med = área média (m²), var = variância, sd = desvio padrão e N = número de clareiras.

Posteriormente à análise, observou-se que as diferentes densidades apresentaram áreas distintas para uma mesma classe de clareira, assim como a contagem de clareiras. Percebeu-se, então que, conforme a classe de área aumentou, essas diferenças diminuíram, especialmente no número de clareiras identificadas. Na Classe 2 os tratamentos T1D37 e T3D18 tiveram 39 clareiras identificadas e os tratamentos T2D28 e T4D09 tiveram 38, uma diferença de apenas

uma clareira, ao passo que os tratamentos T5D04 e T6D01 tiveram um número maior de clareiras identificadas, 50 e 52, respectivamente.

Já na Classe 3 houve maior semelhança entre os tratamentos quanto ao número de clareiras, 20 foram identificadas nos tratamentos T2D28, T3D18, T4D09 e T5D04. Nessa classe o tratamento T1D37 teve uma clareira a menos identificada, enquanto que o tratamento T6D01 identificou 15 clareiras.

Dessa forma, o número total de clareiras foi influenciado pelo número de clareiras da Classe 1, que, quando esta foi excluída da contagem, o número de clareiras se aproximou entre as densidades, exceto o T5D04 e T6D01 que apresentaram um número maior de clareiras. Em todos os tratamentos, a Classe 1 foi a que apresentou o maior número de clareiras, o que também foi encontrado por Martins e Rodrigues (2002) e Martins et al. (2004) em Floresta Semidecidual Mesofítica no sudeste do Brasil em que a maioria das clareiras possuíam menos de 100 m².

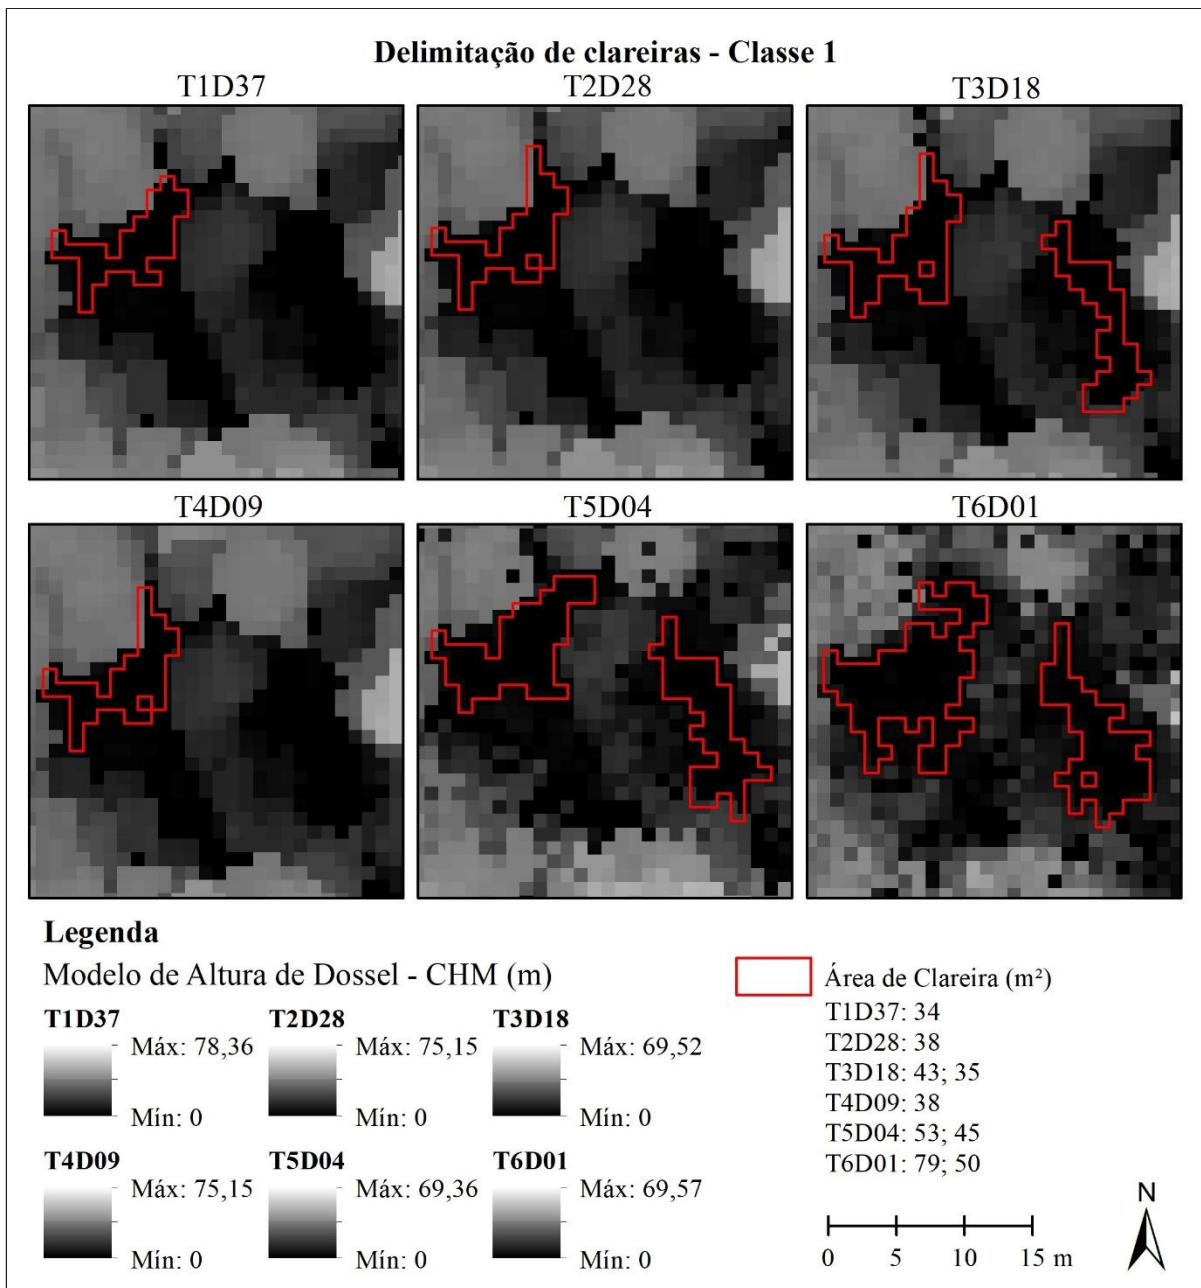
Quanto às áreas, da mesma forma que o número de clareiras, há uma indicação de que a área total seja influenciada mais pelas áreas menores de clareiras, visto que, quando se contabilizaram apenas a Classe 2 e a Classe 3, as áreas totais se aproximaram, sendo essas de 2,67 ha para T1D37 e 2,70 ha para T2D28 e T4D09, enquanto que T3D18 e T5D04 tiveram uma área maior (2,80 ha e 3,32 ha, respectivamente) e T6D01 uma área total menor, de 2,50 ha.

Em um estudo realizado por Brokaw (1985) em floresta tropical no Panamá, foram encontradas clareiras com áreas entre 20 e 705 m², com métodos de medição no campo. Para Martins e Rodrigues (2002), as clareiras descobertas variaram em área entre 20 e 468 m² medidas com fotografias hemisféricas (olho de peixe), em Floresta Semidecidual Mesofítica no sudeste do Brasil.

A partir da detecção por LiDAR, St. Onge e Vepakoma (2012) encontraram uma área média de clareiras de 79,4 m² e as maiores áreas detectadas chegaram a 1.743, 1.721 e 798 m², em uma floresta em Quebec, Canadá. Vepakoma et al. (2008) localizaram clareiras entre 5 e 2.180 m² a partir do CHM, em estudo em reserva florestal no Canadá. Segundo Carvalho et al. (2000), o tamanho das clareiras não afeta apenas os níveis de luz e o microclima, mas também um complexo gradiente do ambiente.

Analisando-se os resultados por classe de tamanho, foram escolhidas clareiras aleatoriamente para a comparação visual entre as áreas nos seis tratamentos testados. As áreas identificadas foram dispostas sobre o respectivo CHM de cada tratamento. As clareiras da Classe 1 podem ser visualizadas na Figura 11.

Figura 11 – Comparativo das clareiras identificadas na Classe 1.



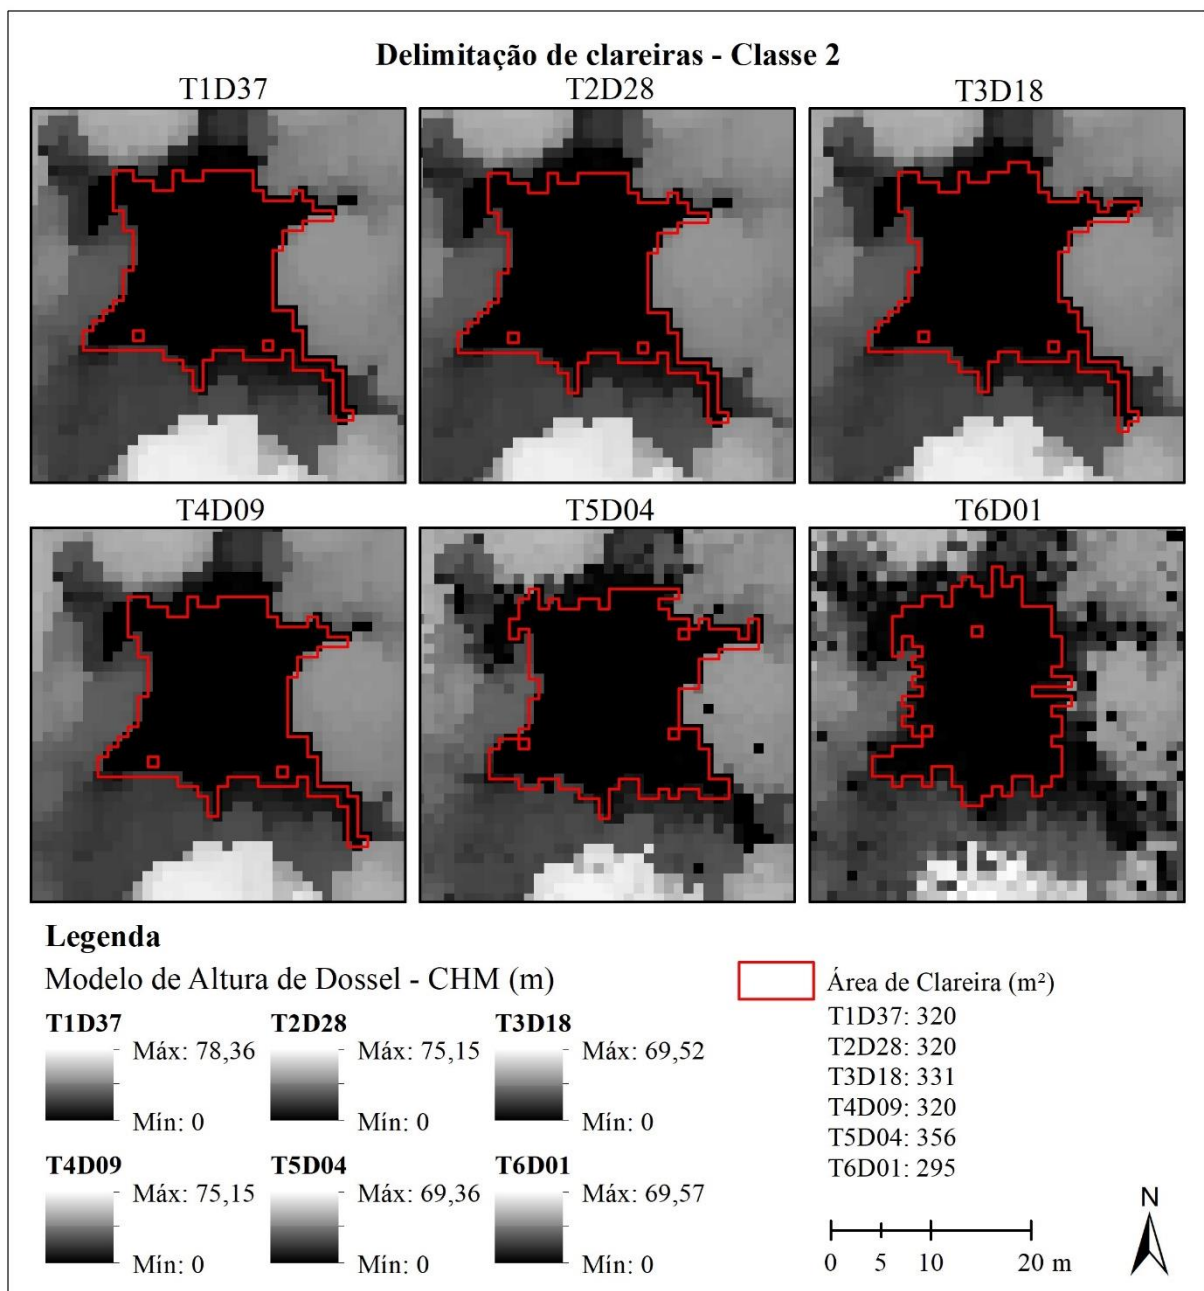
Fonte: O autor.

Notou-se que, em uma mesma região, houve diferença nos resultados apresentados pelos tratamentos nas áreas identificadas na Classe 1, assim como, também, o número de clareiras identificadas. Os tratamentos T1D37, com 34 m², T2D28 e T4D09, ambos com 38 m², apresentaram áreas semelhantes, enquanto que os tratamentos T3D18, T5D04 e T6D01

apresentaram áreas maiores, 43, 53 e 79 m², respectivamente, inclusive uma segunda área identificada com áreas de 35, 45 e 50 m², respectivamente.

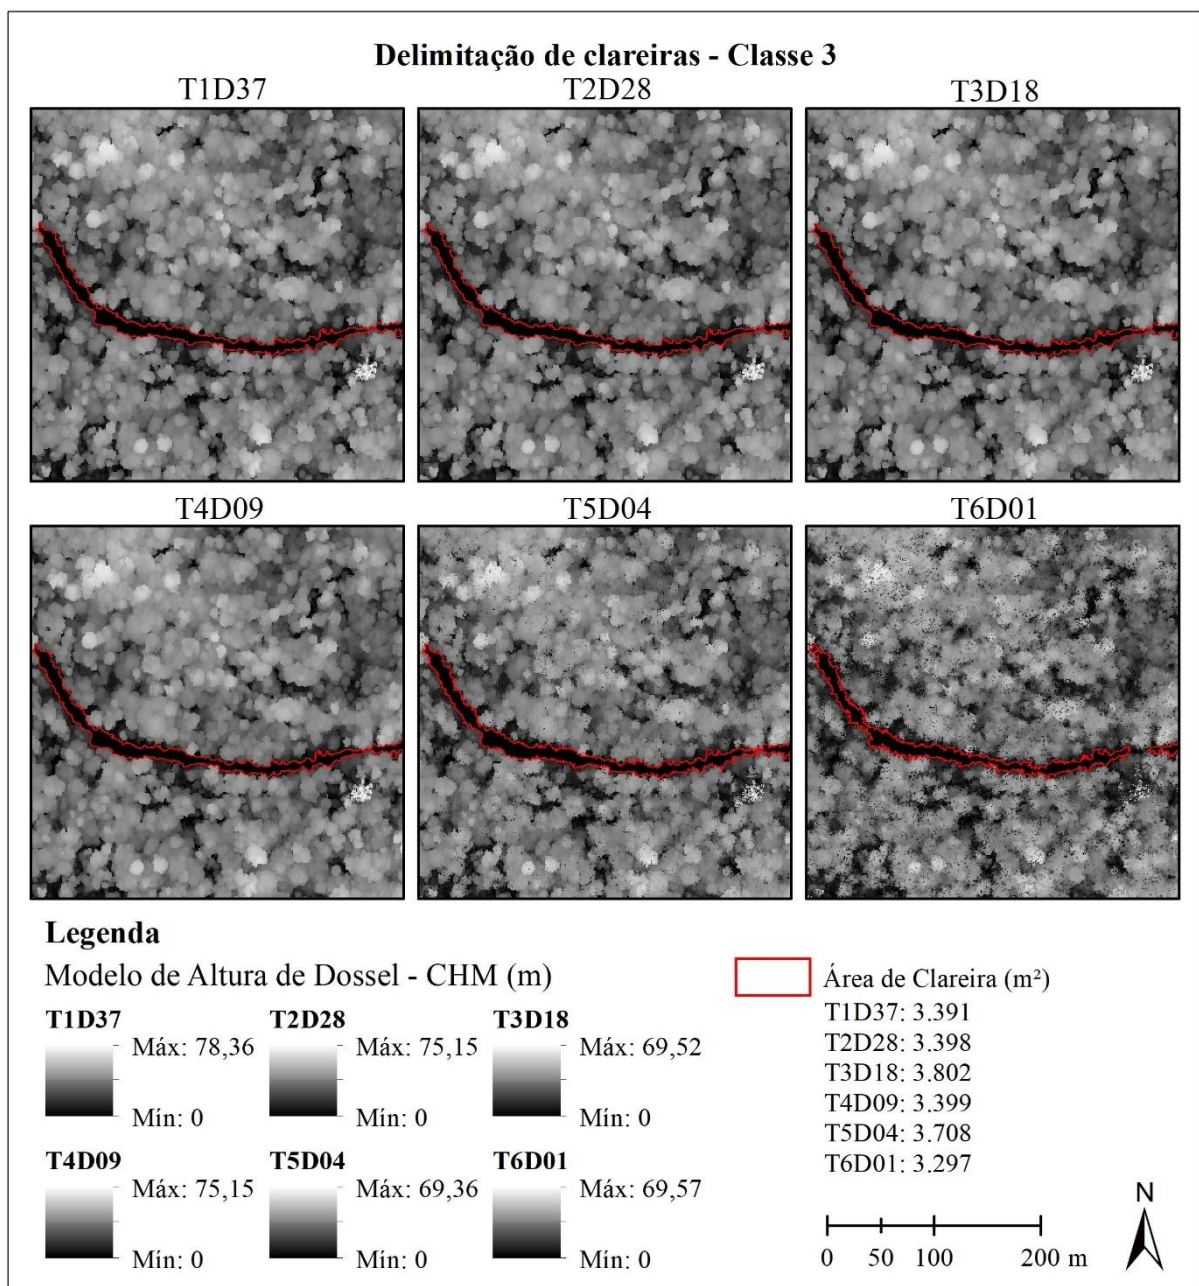
A Figura 12 demonstra áreas de clareiras de cada um dos tratamentos identificadas na Classe 2, localizadas na mesma região dos seus respectivos CHM.

Figura 12 – Comparativo das clareiras identificadas na Classe 2.



Observou-se que na Classe 2 os tratamentos T1D37, T2D28 e T4D09 apresentaram a mesma área, 320 m², enquanto que os tratamentos T3D18 e T5D04, com áreas de 331 e 356 m², respectivamente, apresentaram áreas maiores que os demais tratamentos. O tratamento com a menor área identificada foi o T6D01.

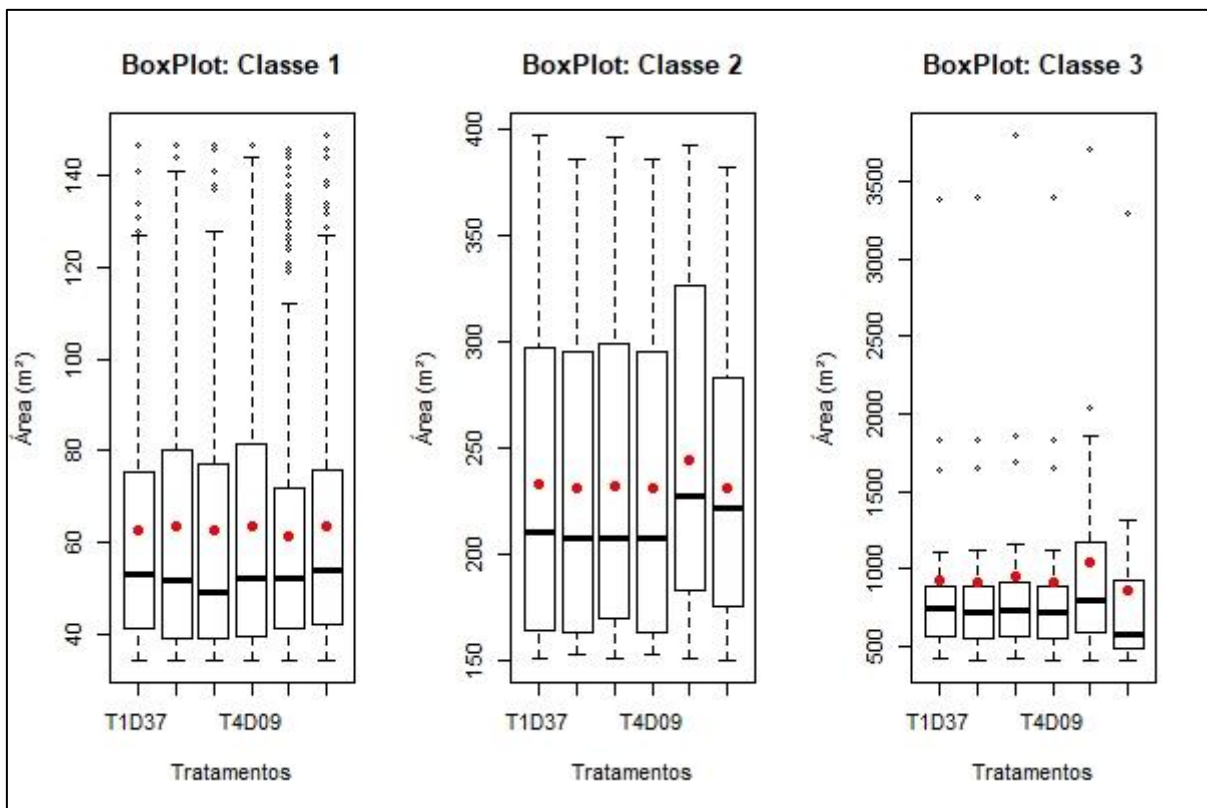
Figura 13 – Comparativo das clareiras identificadas na Classe 3.



Fonte: O autor.

Na Classe 3 observou-se que, assim como nas Classes 1 e 2, os tratamentos T1D37, T2D28 e T4D09 apresentaram áreas de clareiras próximas, 3.391, 3.398 e 3.399 m², respectivamente. Ao passo que os tratamentos T3D18 e T5D04, com áreas de clareiras de 3.802 e 3.708 m², respectivamente, apresentaram áreas maiores que os demais tratamentos enquanto que o tratamento T6D01 apresentou a menor área entre os tratamentos, com área de 3.297 m². A distribuição das áreas pode ser observada na Figura 14.

Figura 14 – Distribuição dos dados por classe no gráfico *BoxPlot*.



Fonte: O autor.

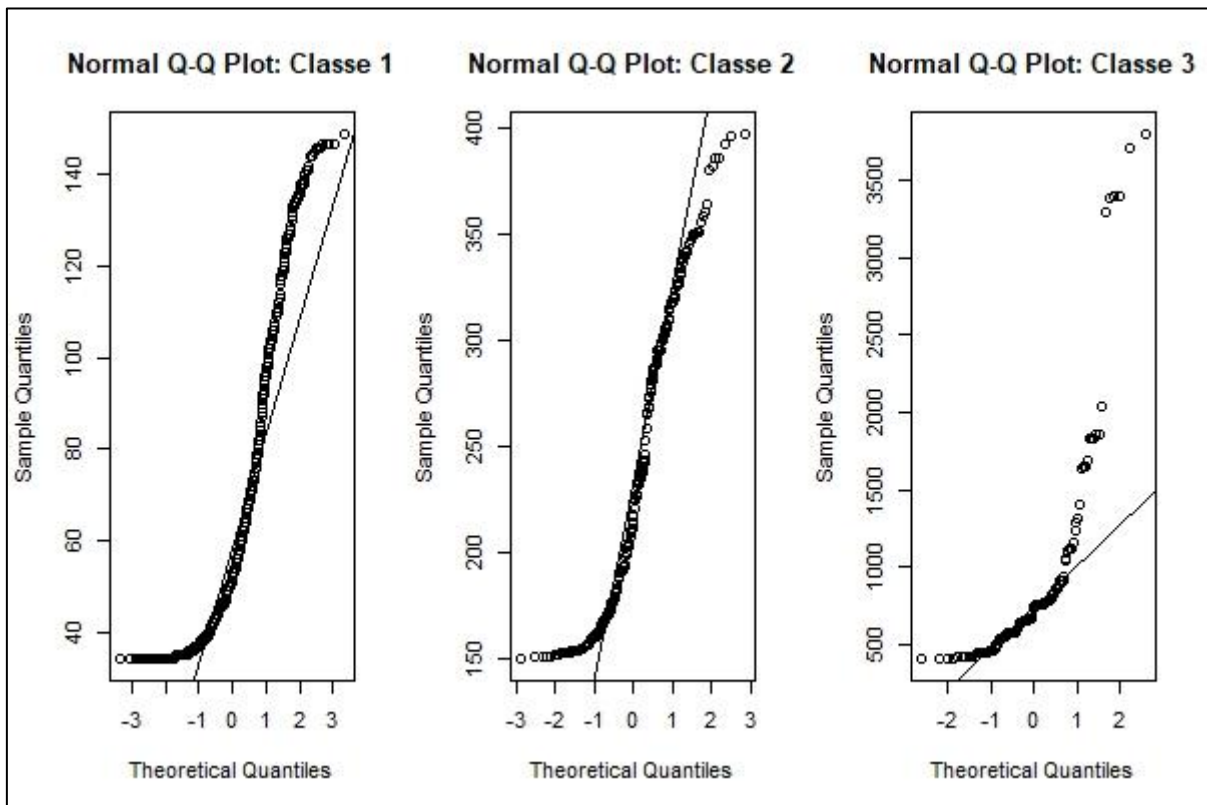
Em que: O ponto vermelho representa a média. Os tratamentos seguem a partir do T1D37 até o T6D01, da esquerda para a direita.

Após análise dos gráficos, percebeu-se que na Classe 1 as áreas medianas dos tratamentos se assemelham, com a área mediana do tratamento T3D18 abaixo dos demais e a variação das áreas se assemelhou nos tratamentos T2D28 e T4D09. Nas Classes 2 e 3 as áreas medianas se assemelham do tratamento T1D37 ao T4D09, assim como a variação das áreas, enquanto que os tratamentos T5D04 e T6D01 possuem áreas medianas maiores e variação das áreas distinta. Nas Classes 1 e 3 notou-se a presença de valores extremos, os quais não foram

considerados *outliers* pois fazem parte do conjunto de dados e a supressão desses valores interfeririam na análise dos dados.

Como houve diferença nas áreas detectadas pelos diferentes tratamentos nas três classes de áreas de clareiras, embora alguns tenham detectados áreas similares ou próximas, é preciso aplicar testes estatísticos a fim de saber se essas diferenças entre os tratamentos são significativas. Para se determinar qual o teste estatístico mais apropriado para ser utilizado, deve-se atender a algumas premissas, como a normalidade dos resíduos e a homocedasticidade das variâncias. A priori, foi feita a análise dos resíduos a partir de um gráfico *QQ-plot*, assim, verificou-se se os resíduos estavam distribuídos normalmente (Figura 15).

Figura 15 – Análise dos resíduos através do gráfico *QQ-plot*.



Fonte: O autor.

Verificando as distribuições dos resíduos, notou-se que não houve normalidade. Nas três classes percebe-se que houve assimetria na distribuição indicado pela disposição em “S” em torno da reta. Mesmo na Classe 2 onde os resíduos se distribuem mais sobre a reta e apenas

próximos aos extremos se distribuem em curva, não há como verificar apenas com o gráfico se isso influencia para que a distribuição seja normal ou não.

Portanto, houve a necessidade de se aplicar um teste estatístico para a verificação da normalidade, dessa forma, o teste selecionado foi o de *Kolmogorov-Smirnov*. A premissa da homocedasticidade foi testada aplicando-se o teste de *Bartlet*. Os resultados obtidos para ambos foram dispostos na Tabela 6.

Tabela 6 – Resultados dos testes de normalidade e homocedasticidade.

Classe	Kolmogorov-Smirnov		Bartlet	
	D	p-valor*	χ^2	p-valor*
Classe 1	0,1581	2,2e-16	1,9812	0,8517
Classe 2	0,13271	0,0002427	1,9507	0,8559
Classe 3	0,26658	1,837e-7	0,42698	0,9946

* nível de significância de 0,05.

O teste de *Kolmogorov-Smirnov* retornou um p-valor menor que o nível de significância de 0,05, assim, rejeitou a hipótese de nulidade, ou seja, desse modo os resíduos das três classes não seguem a distribuição normal, confirmando o que foi sugerido pelo gráfico *QQ-plot*. Quanto à homocedasticidade, o teste de *Bartlet* retornou um p-valor maior que o nível de significância de 0,05, aceitando a hipótese de nulidade, o que demonstrou que há homogeneidade de variâncias nas três classes.

Conforme os testes realizados, não houve atendimento às duas premissas (normalidade e homocedasticidade), o que permitiria a realização de um teste paramétrico. Assim, foi adotado um teste não paramétrico para avaliar se houve diferença significativa entre os tratamentos utilizados, o teste de *Kruskal-Wallis*. Lima (2005) também adotou um método não paramétrico para avaliar os tratamentos de seu estudo em clareiras, o teste de *Friedman ANOVA*. Diante disso, os resultados do teste podem ser verificados na Tabela 7.

Tabela 7 – Resultado do teste de *Kruskal-Wallis*.

Classe	χ^2	p-valor*
Classe 1.	2,1751	0,8244
Classe 2	1,4967	0,9135
Classe 3	3,2096	0,6677

* nível de significância de 0,05.

Após apreciação da tabela, verificou-se que as classes apresentaram um p-valor maior que o nível de significância de 0,05, desse modo, não houve diferença significativa entre os tratamentos, logo, qualquer um dos seis tratamentos poderia ser utilizado para realizar a identificação de clareiras em dosséis de floresta tropical a partir de dados de sensor LiDAR, sem prejuízo na quantificação das áreas de clareiras. Resultados obtidos por St. Onge e Vepakoma (2012) a partir de um estudo de clareiras em floresta boreal mista, sugerem a tecnologia LiDAR como uma excelente ferramenta para mapear clareiras, usando uma densidade de retornos de 3 ppm², a qual é similar à densidade de retornos do tratamento T5D04 desse estudo, possuindo uma densidade de retornos de 4 ppm².

Treitz et al (2012) realizaram um estudo ao nível de parcela com diferentes densidades de pulsos, e a redução da densidade não ocasionou a redução da precisão da predição de variáveis de inventário florestal. Da mesma forma, um estudo realizado por Jakubowski et al. (2013), indicou que não é necessária alta densidade de pulsos para predizer métricas de estruturas florestais ao nível de parcela (pixel de aproximadamente 24 m), no entanto, ao nível de árvores individuais, inclusive na acurácia da identificação de espécies de árvores (KAARTINEN et al., 2012), é preciso densidade alta, já que, conforme os autores, a acurácia das métricas diminuíram conforme a densidade diminuiu.

A densidade de retornos a ser utilizada vai depender do objetivo a ser alcançado, assim como para determinadas variáveis o decréscimo da densidade não interfere, para outras, podem ocorrer perda de acurácia. Com maior densidade de pulsos, há mais pulsos por unidade de área que potencialmente interagirão com mais feições sobre e próximas ao solo, proporcionando mais detalhes da superfície (CAMPBELL et al., 2018).

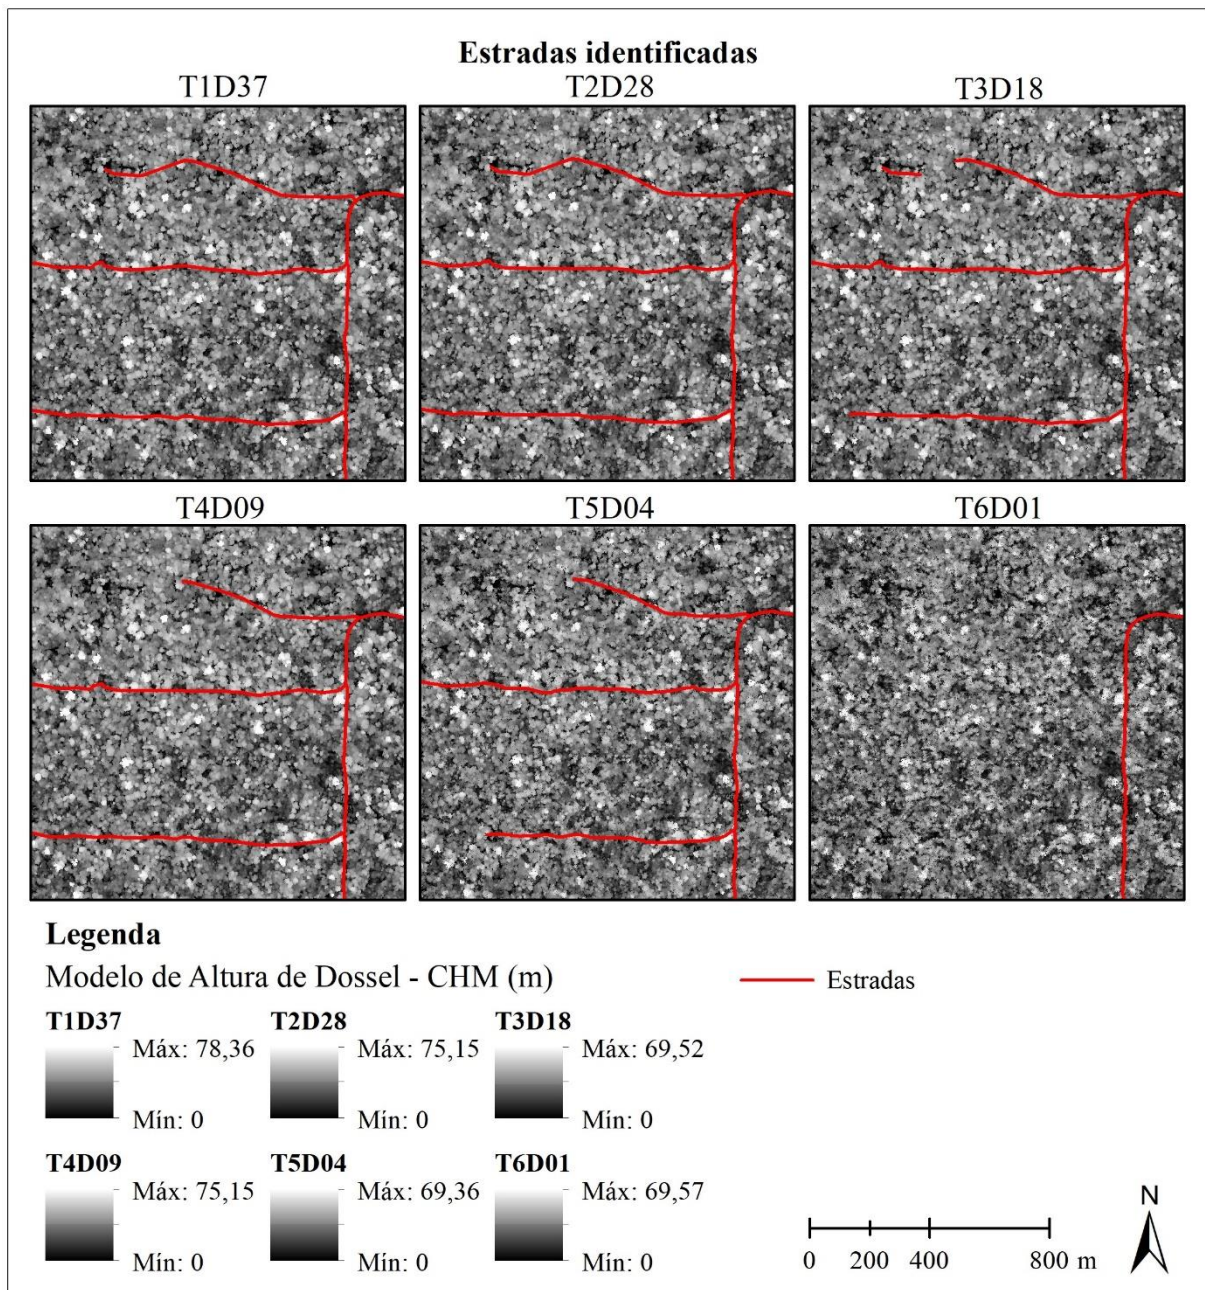
De acordo com um trabalho de estimativa de biomassa realizado por Silva et al. (2017), conforme a densidade de pulsos diminuiu, a acurácia do estoque de biomassa também diminuiu. Li et al. (2013) investigaram os efeitos da densidade de pontos na classificação de espécies, como resultado, os autores obtiveram um aumento da acurácia da classificação com o aumento da densidade de pontos, não sendo adequada baixas densidades de pontos para caracterização de estrutura de copas.

No entanto, é importante ressaltar, que métodos estatísticos não paramétricos são menos precisos que métodos paramétricos, pois estes utilizam a mediana como medida de tendência central em vez da média e do desvio padrão.

4.3.1 Identificação de estradas

As estradas foram analisadas qualitativamente, de modo que pudessem ser identificadas sobre o *raster* resultante da segmentação. A Figura 16 mostra as estradas sobre o CHM gerado para cada um dos tratamentos.

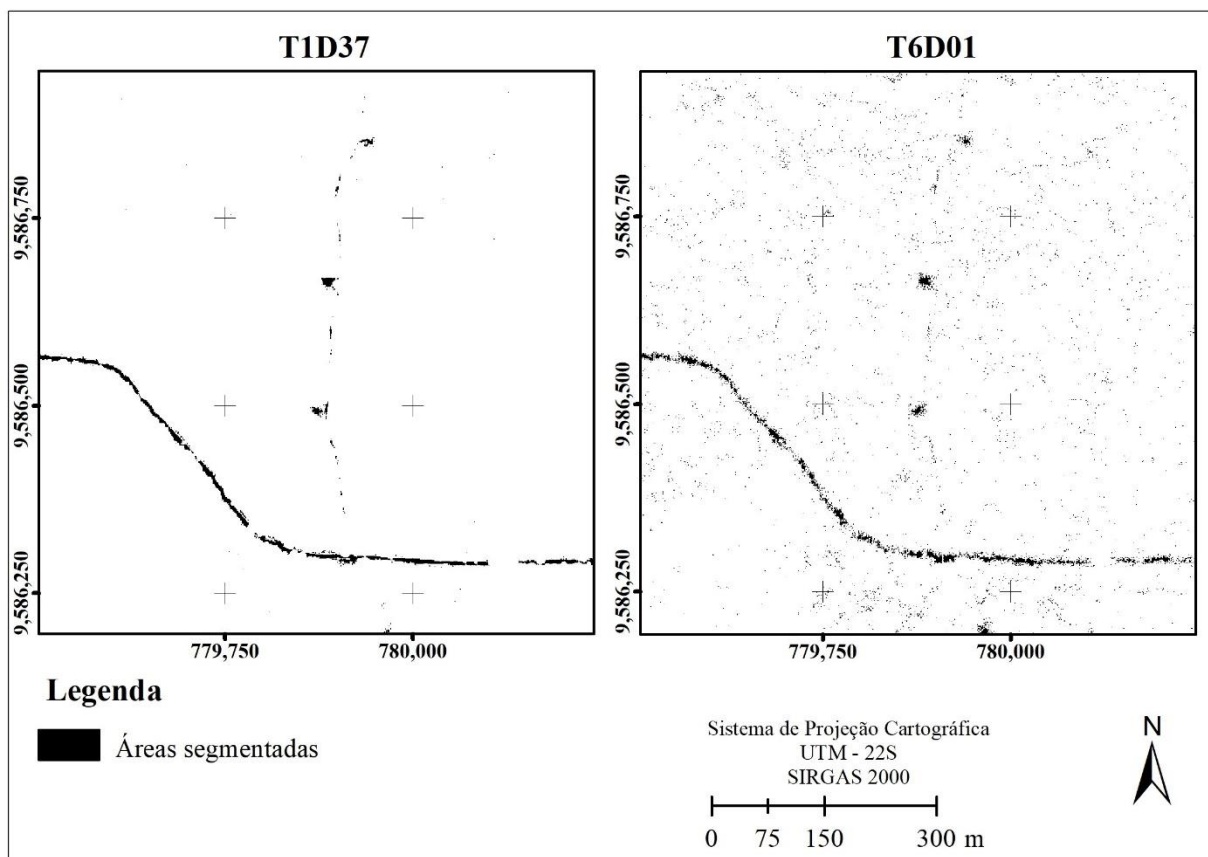
Figura 16 – Estradas identificadas a partir da segmentação baseada no CHM.



Pôde-se observar na Figura 16 que, conforme a densidade de retornos foi diminuindo, com ela também diminuiu a capacidade de identificar segmentos que sugerissem um traçado de estradas. Apenas as estradas principais, as quais inclusive podem ser observadas no próprio CHM, puderam ser identificadas nas menores densidades, prejudicando a identificação de estradas presentes abaixo do dossel florestal.

A partir do T3D18 passou-se a haver mais dificuldade em definir um traçado aparente de estrada, pois muitos segmentos ficaram descontínuos e, devido a menor densidade de retornos, foram gerados muitos segmentos com áreas pequenas. A Figura 17 demonstra a diferença de segmentação no tratamento T1D37, com a maior densidade de retornos, e o tratamento T6D01, com a menor densidade de retornos.

Figura 17 – Segmentação das áreas de estradas nos tratamentos T1D37 e T6D01.



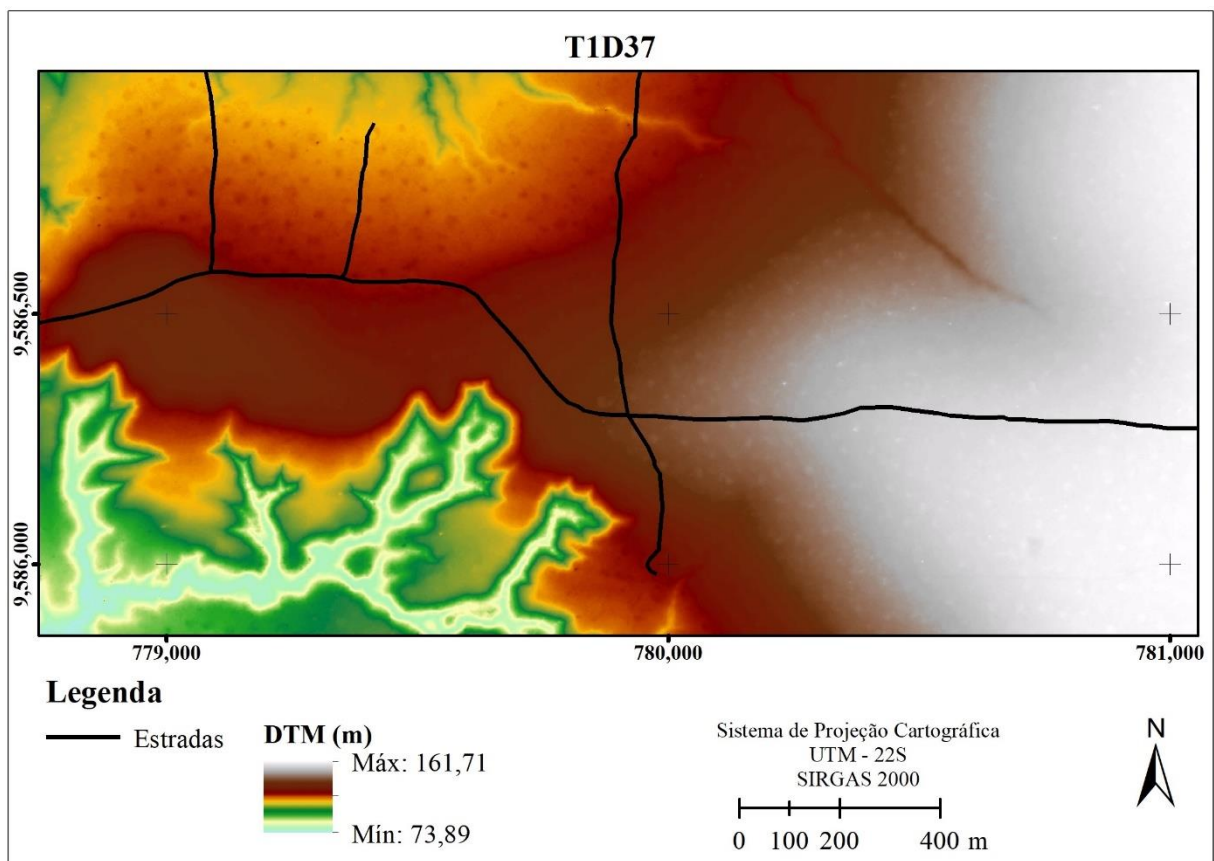
Fonte: O autor.

No tratamento T1D37 percebeu-se uma segmentação mais restrita em áreas, o que permitiu que se identificasse um traçado alinhado a uma única direção. Já no tratamento T6D01,

as áreas segmentadas ficaram mais difusas, o que, no caso da vetorização sobre o *raster*, os segmentos possibilitavam mais de uma direção a ser tomada para o traçado da estrada. Da mesma forma, outras áreas que poderiam ser de espaços entre as copas das árvores, poderiam acabar causando confusão na identificação do traçado.

Os traçados das estradas também foram colocados sobre o DTM a fim de conferir que estivessem sobre o divisor de águas e não em altitudes baixas, o que poderia também caracterizar, pela configuração linear, um curso de água. A Figura 18 exemplifica as estradas e o DTM gerados a partir da densidade de retornos de 37 ppm².

Figura 18 – Identificação de estradas sobre o DTM.



Fonte: O autor

Observou-se na Figura 18 que as estradas identificadas seguem, portanto, as maiores altitudes do DTM. Assim, além da identificação de clareiras a partir de dados LiDAR, também foi possível identificar estradas abertas no dossel florestal.

Já foram realizados trabalhos abordando a identificação de estradas, como o de Azizi et al. (2014), que realizaram um estudo para determinar a aptidão do LiDAR para a extração de estradas florestais, o qual mostrou que as características das estradas medidas usando LiDAR foram altamente acuradas. Do mesmo modo, Matinnia et al. (2018) extraíram seções longitudinais acuradas de estradas oriundas de DTM gerado a partir de dados LiDAR.

Quanto à densidade de pontos, Kiss et al. (2016), avaliaram as condições de estradas florestais quanto às condições estruturais e a superfície e puderam detectar a qualidade da superfície com uma densidade alta. Os resultados de uma pesquisa realizada por Matinnia et al. (2017) indicaram que as propriedades geométricas de estradas florestais existentes podem ser monitoradas sob denso dossel usando dados lidar.

O LiDAR aerotransportado é amplamente aplicado às florestas, mas é relativamente novo o campo de estudo para estradas e estradas florestais não pavimentadas (KISS et al, 2016), portanto, a identificação de estradas é uma área com potencial para ser explorada.

4.3.2 Classificação das clareiras

Com a identificação das estradas, foi necessário refazer a classificação das áreas de clareiras, pois polígonos das Classes 1 e 2, por estarem sob o traçado de estradas, foram incorporados às áreas correspondentes às estradas. A quantificação final das classes de clareiras, incluindo agora uma classe para estradas, pode ser conferida na Tabela 8.

Tabela 8 – Classificação das áreas em clareiras e estradas.

Classe		T1D37	T2D28	T3D18	T4D09	T5D04	T6D01
Clareiras pequenas	A.tot	5.827,00	6.157,00	7.477,00	6.134,00	14.043,00	10.753,00
	N	97	102	126	101	242	185
Clareiras grandes	A.tot	5.735,00	5.802,00	6.111,00	5.797,00	8.512,00	6.741,00
	N	24	24	25	24	35	31
Estradas	A.tot	24.936,00	25.321,00	26.192,00	25.244,00	29.734,00	21.828,00
	N	92	94	96	93	104	94
Clareiras (ha)		1,16	1,20	1,36	1,19	2,26	1,75
Dossel (ha)		1.172,84	1.172,80	1.172,64	1.172,81	1.171,74	1.172,25
Área total (ha)		1.174,00	1.174,00	1.174,00	1.174,00	1.174,00	1.174,00

Em que: A.tot = área total (m²) e N = número de áreas.

Observou-se nos dados que, as quantidades de clareiras nos tratamentos T1D37, T2D28 e T4D09 tiveram números próximos para Clareiras pequenas (Classe 1), variando de 97 à 102, enquanto que na classe Clareiras grandes (Classe 2) a quantidade foi semelhante nos tratamentos T1D37, T2D28, T3D18 e T4D09. Os tratamentos T5D04 e T6D01 apresentaram números superiores em ambas as classes.

Em relação ao número total de clareiras, a classe Clareiras pequenas foi representada por 80,7% em T1D37, 80,8% em T4D09, 81,0% em T2D28, 83,4% em T3D18, 85,6% em T6D01 e 87,4% em T5D04. Estes valores foram acima do encontrado por Tabarelli e Mantovani (1999) em uma floresta na Serra do Mar, estado de São Paulo, de 73,3% de clareiras com áreas menores que 150 m², todavia, dentro do esperado para florestas tropicais em que a frequência de clareiras pequenas é maior que a de clareiras de maiores dimensões (BROKAW, 1985; MARTINS e RODRIGUES, 2002).

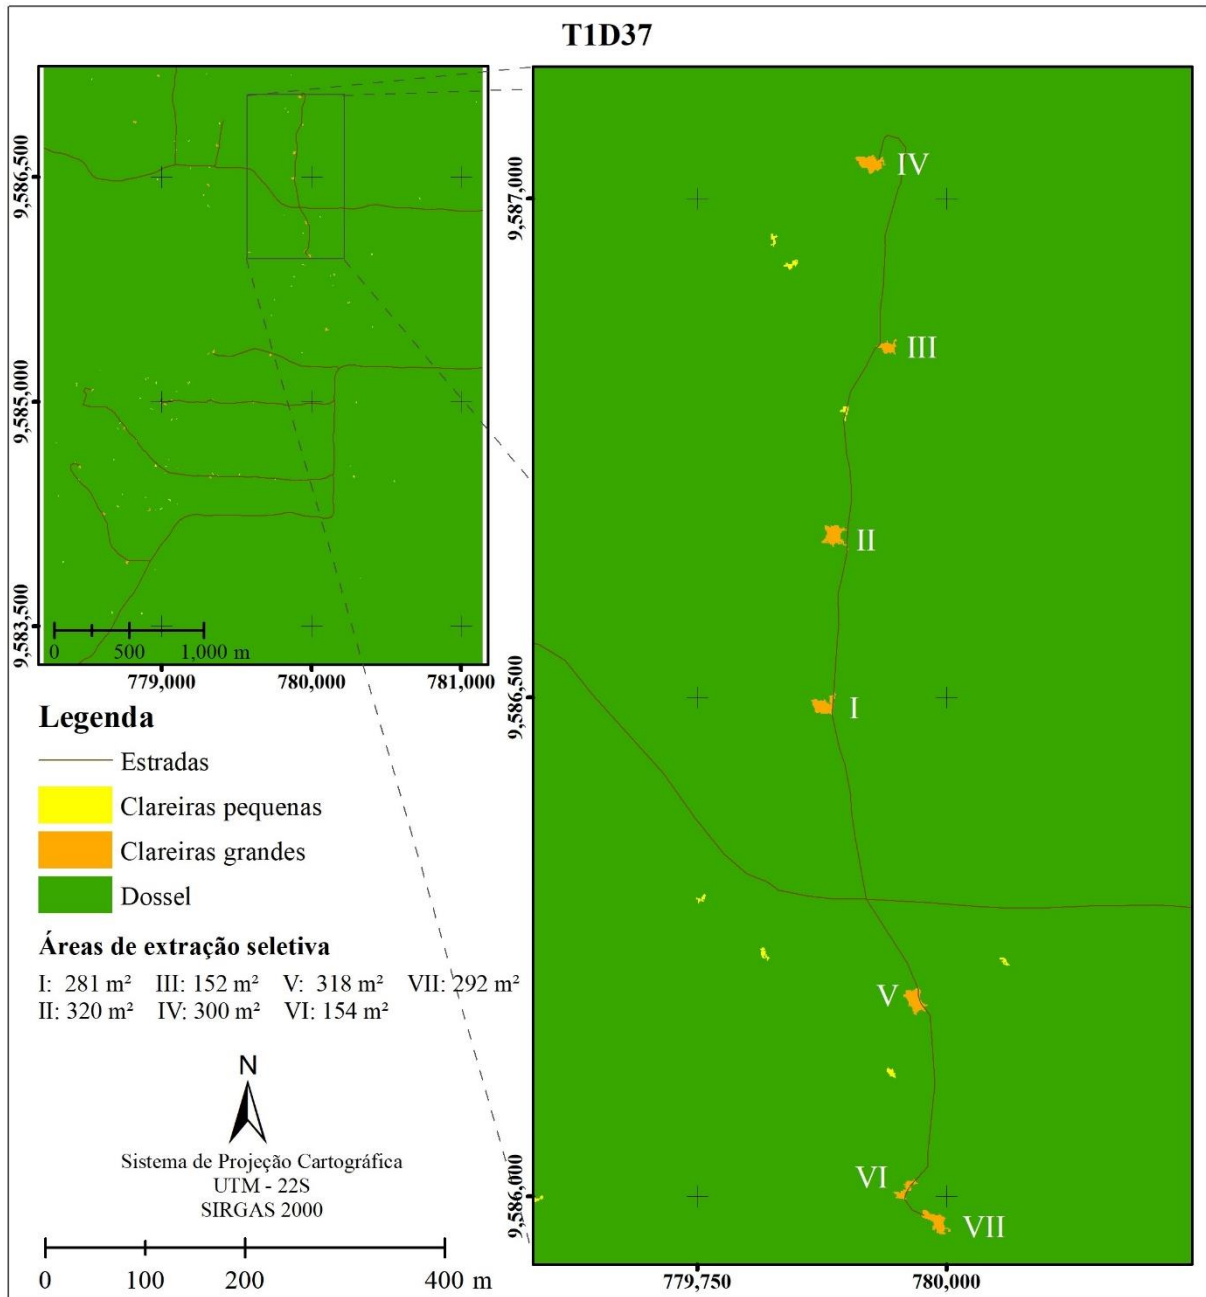
A Classe 3, Clareiras grandes e raras, deixou de figurar entre as classes de clareiras, isso porque essas áreas foram, em sua totalidade, identificadas como sendo áreas pertencentes à Estradas. Da mesma forma, as outras classes também tiveram áreas que foram identificadas como Estradas. A redução de área mais expressiva da classe de Clareiras pequenas foi no tratamento T1D37, com uma redução de 40,19% enquanto que a menor redução foi no tratamento T5D04, 26,59%. Na classe das Clareiras grandes o tratamento com maior redução de área foi o T6D01, com 44,04%, ao passo que o tratamento que teve menor redução foi o T5D04, 30,34%.

Os tratamentos T1D37, T2D28 e T4D09 representaram áreas similares em Clareiras pequenas (50,4, 51,5 e 51,4%, respectivamente), enquanto que T3D18, T5D04 e T6D01 representaram 55,0, 62,3 e 61,5%, respectivamente, da área total de clareiras. Em relação às áreas totais identificadas, ou seja, contabilizando clareiras e estradas, estas últimas tiveram uma representação maior que as clareiras. Assim, representaram com 68,3, 67,9, 65,8, 67,9, 56,9 e 55,5% a partir dos tratamentos T1D37, T2D28, T3D18, T4D09, T5D04 e T6D01, respectivamente.

As áreas totais das classes relativas à área de estudo foram pequenas. As clareiras representaram 0,10% nos tratamentos T1D37, T2D28 e T4D09, 0,12% no T3D18, 0,15% no T6D01 e 0,19% no tratamento T5D04. Enquanto que as áreas de estradas representaram 0,19% no tratamento T6D01, 0,21% no T1D37, 0,22% nos tratamentos T2D28, T3D18 e T4D09 e 0,25% no T5D04.

A Figura 19 mostra o mapa de classificação das áreas identificadas, utilizando o tratamento T1D37 como referência para a representação.

Figura 19 – Mapa de classificação das áreas em clareiras e estradas.



Fonte: O autor.

Analisando a Figura 19 percebeu-se que as clareiras seguem um padrão de alinhamento. Esta disposição das clareiras sugere que não foram abertas naturalmente, mas sim por ação antrópica. Além da disposição, possuem áreas próximas umas das outras, exceto as áreas III e VI que possuem, respectivamente, 152 e 154 m², as outras possuem 281, 320, 300, 318 e 292

m², respectivamente áreas I, II, IV, V e VII, pertencendo, assim, à classe das Clareiras grandes. As áreas da classe Clareiras pequenas variaram de 34 a 66 m². As estradas identificadas, conectando as clareiras, reforçaram a suposição de que foram abertas por ação antrópica.

Como a área de estudo se localiza dentro da propriedade de uma empresa de base florestal, pode-se inferir que estas áreas foram resultantes da extração de indivíduos de espécies de interesse comercial. De acordo com estudo realizado por Weishampel et al (2012), o LiDAR pode ser usado como uma ferramenta para monitorar mudanças no dossel em áreas afetadas por extração seletiva de madeira. Um trabalho conduzido por Andersen et al. (2014) demonstrou o potencial do LiDAR aerotransportado para quantificar mudanças estruturais, ao nível do solo e também do dossel, em exploração seletiva de madeira em florestas tropicais, inclusive em exploração com intensidade muito baixa. d'Oliveira et al. (2012) mapearam com sucesso estradas, linhas de extração e clareiras sob o dossel a partir de dados LiDAR com retornos próximos ao nível do solo.

Além da aplicação na exploração florestal de baixo impacto, a identificação de clareiras e estradas realizadas a partir de dados LiDAR pode ser uma aliada no monitoramento do desmatamento e extração ilegal de madeira. Da mesma forma, quando se considera o aspecto ecológico, estes distúrbios influenciam diretamente na composição e na regeneração de espécies em seu interior e na estrutura da vegetação adjacente.

5 CONCLUSÃO

A identificação de áreas de clareiras em um dossel de floresta tropical não sofreu influência da redução da densidade de retornos LiDAR utilizada. Portanto, a aquisição de dados com uma baixa densidade de pulsos, que entre outros fatores influenciam na densidade de retornos, seria viável, o que, conseqüentemente, reduziria os custos de aquisição e melhoraria a performance de processamento.

Confirmou-se o que é esperado para áreas menores de 150 m², as quais possuem maior frequência. Da mesma forma, com a identificação das estradas e eliminando-se as áreas segmentadas sob os traçados, não foram registradas clareiras maiores que 400 m², o que corroborou com a literatura que considera raras clareiras com áreas superiores a essa.

A identificação das estradas, ao contrário da identificação das clareiras, teve influência da redução da densidade de retornos. Assim, para os traçados de estradas recomenda-se não reduzir a densidade de retornos.

A partir do reconhecimento de padrões da disposição espacial das áreas de clareiras identificadas no dossel, pode-se inferir que algumas foram abertas por ação antrópica, sugerindo a atividade de extração seletiva de madeira na floresta.

A tecnologia LiDAR se mostrou uma eficiente ferramenta para a identificação de aberturas no dossel florestal, portanto, tem um grande potencial para o monitoramento e planejamento da exploração florestal sustentável. Do mesmo modo, pode ser aplicado ao monitoramento do desmatamento e retirada ilegal de madeira em floresta tropical, a qual desempenha importantes funções ecossistêmicas de interesse global.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALMEIDA, D. R. A. et al. Optimizing the Remote Detection of Tropical Rainforest Structure with Airborne Lidar: Leaf Area Profile Sensitivity to Pulse Density and Spatial Sampling. **Remote Sensing**. v. 11, n. 92, 2019.
- ALVARES, C. A et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v.22, p. 711-728. 2013.
- ANDERSEN, H. E. et al. Monitoring selective logging in western Amazonia with repeat lidar flights. **Remote Sensing of Environment**. v. 151, p. 157 – 165, 2014.
- ANDERSON, E. S.; THOMPSON, J. A.; AUSTIN, R. E. LIDAR density and linear interpolator effects on elevation estimates. **International Journal of Remote Sensing**. v. 26, n. 18, p. 3889 – 3900, 2005.
- ARICAK, B. Using remote sensing data to predict road fill areas and areas affected by fill erosion with planned forest road construction: a case study in Kastamonu Regional Forest Directorate (Turkey). **Environ. Monit. Assess.** v. 187, n. 417, p. 1 – 10. 2015.
- ASNER, G. P. et al. Selective Logging in the Brazilian Amazon. **Science**. v. 310, n. 5747, p. 480 – 482, 2005.
- ASNER, G. P et al. Forest Canopy Gap Distributions in the Southern Peruvian Amazon. **Plos One**. v. 8, n. 4, p. 1 – 10. 2013.
- AZIZI, Z.; NAJAFI, A.; SADEGHIAN, S. Forest Road Detection Using LiDAR Data. **Journal of Forestry Research**. v. 25, n. 4, p. 975 – 980, 2014.
- BARLOW, J. et al. Anthropogenic disturbance in tropical forests can double biodiversity loss from deforestation. **Nature**. v.535, n.7610, p.144-147, Jul. 2016
- BERALDIN, J. A.; BLAIS, F.; LOHR, U. Laser Scanning Technology. In: VOSELMAN, G.; MASS, H. G (Coord.). **Airborne and terrestrial laser scanning**. Escócia, UK: Whittles Publishing. 2010.
- BLACKBURN, G. A.; ABD LATIF, Z.; BOYD, D. S. Forest disturbance and regeneration: a mosaic of discrete gap dynamics and open matrix regimes? **Journal of Vegetation Science**. n.25, p.1341–1354. 2014.
- BRASIL. Ministério do Meio Ambiente – MMA & Serviço Florestal Brasileiro – SFB. **Florestas do Brasil em resumo** (Relatório). Dados de 2007-2012. Brasília, DF: MMA e SFB, 2013, p. 50
- BRASIL. Departamento Nacional de Produção Mineral. **Levantamento de recursos minerais**. Folha SA.23 – São Luís e parte da folha SA.24 – Fortaleza. Geologia, geomorfologia, solos, vegetação e uso potencial da terra. Vol.3. Ministério de Minas e Energia, Rio de Janeiro, 1973.

BRAZ, E. M. **Subsídios para o planejamento do manejo De florestas tropicais da Amazônia**. 2010. 237 f. Tese (Doutorado em Engenharia Florestal) – Universidade Federal de Santa Maria, Santa Maria, 2010.

BROKAW, N. V. L. Treefalls: frequency, time, and consequences. In: E. G. LEIGHT, JR.; A. S. RAND; D. M. WINDSOR (Ed.). **The Ecology of a Tropical Forest: Seasonal Rythms and Long-Term Changes**. Washington, D.C., U.S.A: Smith. Inst. Press, 1982. p.101-108.

BROKAW, N. V. L. Gap-Phase Regeneration in a Tropical Forest. **Ecology**. v. 66, n. 3, p. 682 – 687, Jun., 1985.

CAMPBELL, M. J. et al. Quantifying understory vegetation density using small-footprint airborne lidar. **Remote Sensing of Environment**. v. 215, p. 330 – 342, 2018.

CARDONA, M. A. Q. **Efeitos do manejo florestal na estrutura da avifauna na floresta Amazônica de Paragominas (Pará)**. 2012. 108 f. Tese (Doutorado em Recursos Florestais) – Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba, 2012.

CARVALHO, L. M. T. de; FONTES, M. A. L.; OLIVEIRA-FILHO, A. T. de. Tree species distribution in canopy gaps and mature forest in na área of cloud forest of the Itibioca Range, South-eastern Brazil. **Plant Ecology**. v. 149, p. 9 – 22, 2000.

CHAZDON, R. L. **Renascimento de florestas: regeneração da era do desmatamento**. Tradução de AMAZONAS, N.; CESAR, R. São Paulo: Oficina de Textos. 2016. 430 p. Original em Inglês.

CHEN, Q. et al. Modeling and Mapping Agroforestry Aboveground Biomass in the Brazilian Amazon Using Airborne Lidar Data. **Remote Sens**. v. 8, n. 21, 2016.

CIKEL. **Resumo Público Plano de Manejo Florestal Sustentável – UMF Rio Capim**. Paragominas: CKBV Florestal Ltda., 2018. 5 p.

CLEMENT, C. R.; HIGUCHI, N. A floresta amazônica e o futuro do Brasil. **Ciência e Cultura**. v. 58, p. 44–49, 2006.

COLWELL, R. N. **Manual of Remote Sensing**. 2nd Ed. Falls Church: ASP & RS. 1983.

COSTA FILHO, P. P.; DA COSTA, H. B. Construção de estradas florestais e transporte florestal rodoviário na região amazônica. **Circular Técnica 6**. Belém: EMBRAPA/CPATU, 1980. 30 p.

D’OLIVEIRA, M. V. N., RIBAS, L. A. Forest regeneration in artificial gaps twelve years after canopy opening in Acre State Western Amazon. **Forest Ecology and Management**. v. 261, p. 1722 – 1731, 2011.

DUNCANSON L, ROURKE O, DUBAYAH R (2015) Small sample sizes yield biased allometric equations in temperate forests. **Scientific Reports**. v. 5, n. 17153, 2015.

EMBRAPA. Empresa Brasileira de Pesquisa Agropecuária. **Programa internacional reúne cientistas em evento sobre uso de dados LiDAR e inventários florestais**. Brasília, 2014. Disponível em: < <https://www.embrapa.br/busca-de-noticias/-/noticia/1671905/programa->

internacional-reune-cientistas-em-evento-sobre-uso-de-dados-lidar-e-inventarios-florestais>. Acessado em: 23 out. 2018.

EMBRAPA. Empresa Brasileira de Pesquisa Agropecuária. **Paisagens Sustentáveis**. Brasília, 2016. Disponível em: < <https://www.embrapa.br/busca-de-solucoes-tecnologicas/-/produto-servico/3862/paisagens-sustentaveis>>. Acessado em: 23 out. 2018.

EMBRAPA. Empresa Brasileira de Pesquisa Agropecuária. **WebGIS Paisagens Sustentáveis Brasil**. Brasília, 2018. Disponível em: < <http://www.paisagenslidar.cnptia.embrapa.br/webgis/>>. Acessado em: 23 out. 2018.

FAO. Food And Agriculture Organization Of The United Nations. **Global Forest Resources Assessment 2015: How are the world's forests changing?** 2.ed. Roma: 54 p. 2015.

FEARNSIDE, P.M. Brazil's Amazonian forest carbon: the key to Southern Amazonia's significance for global climate. **Reg Environ Change**. v. 18, n. 1, 2016.

FLORENZANO, T. G. **Imagens de satélite para estudos ambientais**. 3 ed. São Paulo: Oficina de Textos, 2011.

FRELICH, L.E. **Forest Dynamics and Disturbance Regimes: Studies from Temperate Evergreen–Deciduous Forests**. Cambridge, UK: Cambridge University Press. 2002. p. 266.

GANDOLFI, S. Sucessão florestal e as florestas brasileiras: Conceitos e problemas. In: VIII Congresso de Ecologia do Brasil. Caxambu, Minas Gerais. **Anais...** 2007.

GOMES, J. M. et al. Sobrevivência de espécies arbóreas plantadas em clareiras causadas pela colheita de madeira em uma floresta de terra firme no município de Paragominas na Amazônia brasileira. **Acta Amazonica**. v. 40, n. 1, p. 171 – 178, 2010.

GORGENS, E. B.; SILVA, A. G. P.; RODRIGUEZ, L. C. E. **LiDAR: Aplicações Florestais**. Curitiba: CRV, 2014, p. 131.

HADDAD, N. M. et al. Habitat fragmentation and its lasting impact on Earth's ecosystems. **Science Advances**, v. 1, n. 2, 2015.

HANSEN, M. et al. High-Resolution Global Maps of 21st-Century Forest Cover Change. **Science**. v. 342, n. 6160, 850 – 853, 2013.

HEISKANEN, J. et al. Use of airborne lidar for estimating canopy gap fraction and leaf area index of tropical montane forests. **International Journal of Remote Sensing**. v. 36, n. 10, p. 2569 – 2583, 2015.

HIRAI, E. H. et al. Efeito da exploração florestal de impacto reduzido sobre a regeneração natural em uma floresta densa de terra firme no município de Paragominas na Amazônia brasileira. **Sci. For**. v. 40, n. 95, p. 306 – 315, 2012.

HRUZA, P. et al. Detecting Forest Road Wearing Course Damage Using Different Methods of Remote Sensing. **Remote Sens**. v. 10, n. 492, 2018.

HUNTER, M. O. et al. Tree height and tropical forest biomass estimation. **Biogeosciences**. v. 10, p. 8385–8399, 2013.

HUNTER, M. O. et al. Structural Dynamics of Tropical Moist Forest Gaps. **Plos One**. v. 10, n. 7, Jul. 2015.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Manual Técnico da Vegetação Brasileira**. 2 ed. Resvista e ampliada. 2012

INPE. Instituto Nacional de Pesquisas Espaciais. **Sistema de Detecção do Desmatamento em Tempo Real na Amazônia – DETER: aspectos gerais, Metodológicos e plano de desenvolvimento**. Monitoramento da cobertura florestal da Amazônia por satélites. São José dos Campos: INPE, 2008, p. 16.

INPE. Instituto Nacional de Pesquisas Espaciais. **Metodologia para o Cálculo da Taxa Anual de Desmatamento na Amazônia Legal**. Programa Amazônia – Projeto PRODES. São José dos Campos: INPE, 2013, p. 37.

ISENBURG, M. **LASzip: lossless compression of LiDAR data**. 2012.

JAKUBOWSKI, M. K.; GUO, Q.; KELLY, M. Tradeoffs between lidar pulse density and forest measurement accuracy. **Remote Sensing of Environment**. v. 130, p. 245 – 253, 2013.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: uma perspectiva em recursos terrestres**. Tradução de: EIPHANIO, J. C. N. (coordenador)... [et al.]. 2ed. São José dos Campos, SP: Parêntese, 2011. Original em inglês.

JUCKER, T. Allometric equations for integrating remote sensing imagery into forest monitoring programmes. **Global Change Biology**. 2016.

KAARTINEN, H. et al. An international comparison of individual tree detection and extraction using airborne laser scanning. **Remote Sensing**, Basel, v. 4, n. 4, p. 950-974, Mar. 2012.

KARILA, K. et al. Feasibility of Multispectral Airborne Laser Scanning Data for Road Mapping. **IEEE Geoscience and Remote Sensing Letters**. v. 14, n. 3, p. 294 – 298, Mar. 2017.

KAZMIERCZAK, M. L. Sensoriamento remoto para incêndios florestais. P.175-211. In: SAUSEN, T. M.; LACRUZ, M. S. P. (Coord.). **Sensoriamento remoto para desastres**. São Paulo: Oficina de Textos. 285p. 2015.

KISS, K.; MALINEN, J.; TOKOLA, T. Forest road quality control using ALS data. **Can. J. For. Res.** v. 45, p. 1636 – 1642, 2015.

KISS, K.; MALINEN, J.; TOKOLA, T. Comparison of high and low density airborne lidar data for forest road quality assessment. In: ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences. Volume III-8, 2016, Prague, Czech Republic, **Anais...** 2016. p. 167 – 172.

KOCH, B. Status and future of laser scanning, synthetic aperture radar and hyperspectral remote sensing data for forest biomass assessment. **ISPRS Journal of Photogrammetry and Remote Sensing**. v. 65, n. 6, 581–590, 2010.

KUKUNDA, C. B. et al. Ensemble classification of individual Pinus crowns from multispectral satellite imagery and airborne LiDAR. **Int J Appl Earth Obs Geoinformation**. v. 65, p. 12 – 23, 2018.

LEITOLD, V. et al. Airborne lidar-based estimates of tropical forest structure in complex terrain: opportunities and trade-offs for REDD+. **Carbon Balance and Management**. v. 10, n. 3, 2015.

LI, J.; HU, B.; NOLAND, T. Classification of tree species based on structural features derived from high density LiDAR data. **Agricultural and Forest Meteorology**. v. 171, n. 172, p. 104 – 114, 2013.

LIMA, R. A. F. Gap size measurement: The proposal of a new field method. **Forest Ecology and Management**. v. 214, p. 413 – 419, 2005.

LIN, Y.; THOMSON, G.; POPESCU, S. C. An IPCC-Compliant Technique for Forest Carbon Stock Assessment Using Airborne LiDAR-Derived Tree Metrics and Competition Index. **Remote Sens**. v. 8, n. 528, 2016.

LONGO, M. et al. Aboveground biomass variability across intact and degraded forests in the Brazilian Amazon. **Global Biogeochem. Cycles**. v. 30, 2016.

MALTAMO, M.; NAESSET, E.; VAUHKONEN. **Forestry Applications of Airborne Laser Scanning: Concepts and Case Studies**. London: Springer. 2014.

MANURI, S. et al. Assessing the influence of return density on estimation of lidar-based aboveground biomass in tropical peat swamp forests of Kalimantan, Indonesia. **International Journal of Applied Earth Observation and Geoinformation**. v. 56, p. 24 – 35, 2017.

MARTINS, S. V.; RODRIGUES, R. R. Gap-phase regeneration in a semideciduous mesophytic forest, South-eastern Brazil. **Plant Ecology**. v. 00, p. 1 -12. 2002.

MARTINS, S. V. et al. Colonization of gaps produced by death of bamboo clumps in a semideciduous mesophytic forest in South-eastern Brazil. **Plant Ecology**. v. 172, p. 121 – 131. 2004.

MATINNIA, B. et al. Monitoring geometric properties of an existing forest road using airborne Lidar data. **J. For. Sci**. v. 63, n. 11, p. 490 – 495, 2017.

MATINNIA, B. et al. Study of the LiDAR accuracy in mapping forest road alignments and estimating the earthwork volume. **J. For. Sci**. v. 64, n. 11, p. 469 – 477, 2018.

MAZZEI, L. et al.. Above-ground biomass dynamics after reduced-impact logging in the Eastern Amazon. **Forest Ecology and Management**, v.259, n.3, p.367-373, 2010.

MCCARTHY, J. Gap dynamics of forest trees: with particular attention to boreal forests. **Environmental Reviews**. n.9, p.1–59. 2001.

MCGAUGHEY, R. J. **FUSION/LDV: Software for LIDAR Data Analysis and Visualization**. Washington D. C: USDA Forest Service. 2016.

MELENDY, L. et al. Automated method for measuring the extent of selective logging damage with airborne LiDAR data. **ISPRS Journal of Photogrammetry and Remote Sensing**. v. 139, p. 228 – 240, 2018.

MELLO, M. P.; PETERNELLI, L. A. **Conhecendo o R – Uma visão mais que Estatística**. Viçosa: UFV, 2013, p. 222.

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. **Environ. Res. Lett.** v. 12. 2017.

MINISTÉRIO DO MEIO AMBIENTE - MMA. **Plano de ação para prevenção e controle do desmatamento na Amazônia Legal (PPCDAm): 3ª fase (2012-2015) pelo uso sustentável e conservação da floresta**. Brasília: MMA, 2013.

MOURA, Y. M. M. et al. Seasonality and drought effects of Amazonian forests observed from multi-angle satellite data. **Remote Sensing of Environment**. v. 171, p. 278 – 290, 2015.

NOBRE, C. A.; SAMPAIO, G.; SALAZAR, L. Mudanças climáticas e Amazônia. **Ciência e Cultura**. v. 59, p. 22–27. 2007.

PENNA FILHO, P. Reflexões sobre o Brasil e os desafios Pan-Amazônicos. **Rev. Bras. Polít. Int.** v. 56, n. 2, p. 94 – 111, 2013.

PEREIRA, D. A. **Fatos Florestais da Amazônia**. IMAZON – Belém, PA. 2010

PITHON, S. et al. A statistical method for detecting logging-related canopy gaps using high-resolution optical remote sensing. **International Journal of Remote Sensing**. v. 34, n. 2, p. 700 – 711, 2012.

PONZONI, F. J. et al. **Calibração absoluta de sensores orbitais: conceituação, principais procedimentos e aplicação**. São José dos Campos, SP: Parentese. 2007, 72p.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento remoto no estudo da vegetação**. São José dos Campos: Parentese. 2009.

POPESCU, S. C. Estimating biomass of individual pine trees using airborne lidar. **Biomass & Bioenergy**, v. 31, p. 646–655. 2007.

POPESCU, S. C.; ZHAO, K.; NEUENSCHWANDER, A.; LIN, C. Satellite lidar vs. small footprint airborne lidar: Comparing the accuracy of aboveground biomass estimates and forest structure metrics at footprint level. **Remote Sensing of Environment**, v. 115, n. 11, p. 2786 – 2797, 2011

RADAMBRASIL: **Levantamento de Recursos Naturais**. Rio de Janeiro/Vitória: geologia, geomorfologia, pedologia, vegetação e uso potencial da terra, Ministério de Minas e Energia, folhas SF., 1983.

R CORE TEAM. R: A Language and Environment for Statistical Computing; **R Foundation for Statistical Computing**: Vienna, Austria, 2017. Disponível em: <<http://www.R-project.org>>. Acesso em: 10 out. 2018.

RONCAT, A. et al. Laser Pulse Interaction with Forest Canopy: Geometric and Radiometric Issues. In: MALTAMO, M.; NAESSET, E.; VAUHKONEN, J. **Forestry Applications of Airborne Laser Scanning – Concepts and Case Studies**. London: Springer. 2014.

ROSETTE, J. et al. Lidar Remote Sensing for Biomass Assessment. In: FATOYINBO, L. (Ed.) **Remote Sensing of Biomass – Principles and Applications**. Rijeka, Croatia: Intech. 2012. p. 322.

RUNKLE, J. R. Patterns of Disturbance in Some Old-Growth Mesic Forests of Eastern North America. **Ecology**. v. 63, n. 5, p. 1533 – 1546, Out. 1982.

SATO, L. Y. et al. Post-Fire Changes in Forest Biomass Retrieved by Airborne LiDAR in Amazonia. **Remote Sens**. v. 8, n. 839, 2016.

SCHNEIDER, R. et al. **Amazônia sustentável: limites e oportunidades para o desenvolvimento rural**. Brasília: Imazon e Banco Mundial. 77p. 2000.

SILVA, C. A. et al. Impacts of Airborne Lidar Pulse Density on Estimating Biomass Stocks and Changes in a Selectively Logged Tropical Forest. **Remote Sens**. v. 9, n. 1068, 2017.

St-ONGE, B.; VEPAKOMMA, U. Assessing forest gap dynamics and growth using multi-temporal laser-scanner data. **International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**. v.XXXVI, n. 8-W2. p.173-178. 2012.

St-ONGE, B. et al. Canopy gap detection and analysis with airborne laser scanning. In **Forestry Applications of Airborne Laser Scanning**; Maltamo, M., Næsset, E., Vauhkonen, J., Eds.; Springer Netherlands: Dordrecht, The Netherlands, v. 27, p. 419–437, 2014.

TABARELLI, M.; MANTOVANI, W. Clareiras naturais e a riqueza de espécies pioneiras em uma floresta atlântica montana. **Ver. Brasil. Biol**. v. 59, n. 2, p. 251 – 261. 1999.

TABARELLI, M.; MANTOVANI, W. Gap-phase regeneration in a tropical montane forest: the effects of gap structure and bamboo species. **Plant Ecology**. v. 148, p. 149 – 155. 2000.

TESFAMICHAEL, S. G.; AHMED, F. B.; VAN AARRDT, J. A. N. Investigating the impact of discrete-return lidar point density on estimations of mean and dominant plot-level tree height in *Eucalyptus grandis* plantations. **International Journal of Remote Sensing**. v. 31, n. 11, p. 2925 – 2940, Jun. 2010.

TREITZ, P. et al. LiDAR Sampling Density for Forest Resource Inventories in Ontario, Canada. **Remote Sens**. v. 4, p. 830 – 848, 2012.

Van der MEER, P. J. et al. Defining canopy gaps in a tropical rain forest: effects on gap size and turnover time. **Acta Ecológica**. v. 15, n. 6, p. 701 – 714. 1994.

VEPAKOMMA, U.; ST-ONGE, B.; KNEESHAW, D. Spatially explicit characterization of boreal forest gap dynamics using multi-temporal lidar data. **Remote Sensing of Environment** v.112, n. 5, p.2326–2340. 2008.

VEPAKOMMA, U.; KNEESHAW, D. D.; GRANDPRÉ, L. D. Influence of Natural and Anthropogenic Linear Canopy Openings on Forest Structural Patterns Investigated Using LiDAR. **Forests**. v. 9, n. 540, 2018.

WEISHAMPEL, J. F. et al. Use of airborne LiDAR to delineate canopy degradation and encroachment along the Guatemala–Belize border. **Tropical Conservation Science**. v. 5, n. 1, p. 12 –24, 2012.

WHITE, R. A. Forest roads mapped using LiDAR in steep forested terrain. **Remote Sensing**. v. 2, p. 1120–1141, 2010.

WHITMORE, T. C. **An introduction to tropical rain forests**. Blackwell, London. 1990. 296 p.

YANG, J.; JONES, T.; CASPERSEN, J.; HE, Y. Object-Based Canopy Gap Segmentation and Classification: Quantifying the Pros and Cons of Integrating Optical and LiDAR Data. **Remote Sens**. v. 7, n. 12, p.15971-15982. 2015

YOGA, S. et al. Modeling the Effect of the Spatial Pattern of Airborne Lidar Returns on the Prediction and the Uncertainty of Timber Merchantable Volume. **Remote Sens**. v. 9, n. 808, 2017.

ZHAO, K.; POPESCU, S.; NELSON, R. Lidar remote sensing of forest biomass: A scaleinvariant estimation approach using airborne lasers. **Remote Sensing of Environment**. v. 133, p. 182–196, 2009.