


UNIVERSIDADE FEDERAL DO PARANÁ

FRANCIEL EDUARDO REX

ESTIMATIVAS DO ESTOQUE E DINÂMICA DE BIOMASSA ACIMA DO SOLO  
UTILIZANDO DIFERENTES ABORDAGENS ESTATÍSTICAS E DADOS LiDAR EM  
FLORESTA TROPICAL



CURITIBA

2019

FRANCIEL EDUARDO REX

ESTIMATIVAS DO ESTOQUE E DINÂMICA DE BIOMASSA ACIMA DO SOLO  
UTILIZANDO DIFERENTES ABORDAGENS ESTATÍSTICAS E DADOS LiDAR EM  
FLORESTA TROPICAL

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Florestal, Setor de Ciências Agrárias, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Mestre em Engenharia Florestal, Área de Concentração em Manejo Florestal.

Orientadora: Prof.<sup>a</sup> Dr.<sup>a</sup> Ana Paula Dalla Corte

Coorientadores: Dr. Carlos Alberto Silva; Prof. Dr. Carlos Roberto Sanquetta; Prof. Dr. Sebastião do Amaral Machado.

CURITIBA

2019

Ficha catalográfica elaborada pela  
Biblioteca de Ciências Florestais e da Madeira - UFPR

Rex, Franciel Eduardo

Estimativas do estoque e dinâmica de biomassa acima do solo utilizando diferentes abordagens estatísticas e dados LiDAR em floresta tropical / Franciel Eduardo Rex. – Curitiba, 2019.  
121 f. : il.

Orientadora: Profa. Dra. Ana Paula Dalla Corte


Coorientadores: Dr. Carlos Alberto Silva; Prof. Dr. Carlos R. Sanquetta  
Prof. Dr. Sebastião do Amaral Machado

Dissertação (Mestrado) - Universidade Federal do Paraná, Setor de Ciências Agrárias, Programa de Pós-Graduação em Engenharia Florestal. Defesa: Curitiba, 25/02/2019. Área de concentração: Manejo Florestal.

1. Biomassa vegetal - Medição - Amazônia. 2. Biomassa vegetal - Métodos estatísticos. 3. Sensoriamento remoto. 4. Levantamentos florestais. 5. Teses. I. Dalla Corte, Ana Paula. II. Silva, Carlos Alberto. III. Sanquetta, Carlos Roberto. IV. Machado, Sebastião do Amaral. V. Universidade Federal do Paraná, Setor de Ciências Agrárias. VI. Título.

CDD – 634.9

CDU – 634.0.548(811)



MINISTÉRIO DA EDUCAÇÃO  
SETOR SETOR DE CIÊNCIAS AGRARIAS  
UNIVERSIDADE FEDERAL DO PARANÁ  
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO ENGENHARIA  
FLORESTAL - 40001016015P0

## TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em ENGENHARIA FLORESTAL da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de **FRANCIEL EDUARDO REX** intitulada: **ESTIMATIVAS DO ESTOQUE E DINÂMICA DE BIOMASSA ACIMA DO SOLO UTILIZANDO DIFERENTES ABORDAGENS ESTATÍSTICAS E DADOS LiDAR EM FLORESTA TROPICAL**, após terem inquirido o aluno e realizado a avaliação do trabalho, são de parecer pela sua Aprovação no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 25 de Fevereiro de 2019.

ANA PAULA DALLA CORTE

Presidente da Banca Examinadora (UFPR)

CARINE KLAUBERG SILVA

Avaliador Externo (UFSJ)

ALLAN LIBANIO PELISSARI

Avaliador Interno (UFPR)

“Dedico esse trabalho aos meus pais Rosani e Dilmar Rex, e também aos meus amados avós Olga e Roque Ziembowicz. A minha luta, sempre foi a de vocês. A minha vitória, será eternamente nossa!”

## AGRADECIMENTOS

Aos meus pais Rosani e Dilmar, por serem minha base, pelo apoio incondicional em todos os momentos, e também por acreditarem nos meus sonhos. Amo muito vocês.

Aos meus avós Olga e Roque, pelo o carinho, confiança e força que sempre me transmitiram. Obrigado também por entenderem que eu precisaria mais uma vez estar longe de casa.

À minha Orientadora Prof.<sup>a</sup> Dr.<sup>a</sup> Ana Paula Dalla Corte, que é admirável como profissional e como pessoa, sempre me inspirou muito em ir busca de mais conhecimento. Agradeço pela orientação, dedicação, confiança em mim e por todos os ensinamentos durante o curso. Com certeza aprendi muito com você. Além do mais, tenho uma imensa admiração pela profissional que és e pela forma que conduz o trabalho. Meu sinceros agradecimentos.

Ao pesquisador e também co-orientador deste trabalho, Carlos Alberto Silva por todo suporte, esforços e contribuições para a melhoria desta pesquisa, e também pelo seu tempo e disposição em sempre ajudar. Também agradeço ao Carlos por toda ajuda com o intercâmbio para os Estados Unidos, com certeza foi um grande facilitador desse processo. Sou extremamente grato pela oportunidade de ter trabalhado com você.

Aos Co-orientadores Prof.<sup>o</sup> Dr. Carlos Roberto Sanquetta e Prof.<sup>o</sup> Dr. Sebastião do Amaral Machado, pelas valiosas colaborações e sugestões para a melhoria do trabalho.

Ao Pesquisador Dr. Andrew Thomas Hudak pela oportunidade na realização do intercâmbio no Serviço Florestal Americano em Moscow, Idaho e também por todos os ensinamentos e conhecimentos passados durante este tempo. Além do mais, agradeço também pela oportunidade cultural que pude vivenciar durante o tempo que residi nos Estados Unidos. Com certeza foi uma ótima oportunidade de crescimento pessoal e profissional.

Aos demais pesquisadores do Serviço Florestal Americano por serem tão amigáveis e hospitaleiros comigo durante o período que estive realizando meu intercâmbio

As minhas amigas de longa data Fernanda e Pâmela que mesmo de longe estiveram tão próximas de mim durante essa fase importante da minha vida.

As minhas amigas e companherias de apartamento Franciele e Cristine, pela boa amizade, pelos ótimos momentos que compartilhamos e claro, por me aguentarem.

À Bruna que foi uma das grandes amigas que começou no mestrado. Nossa amizade rendeu muitas histórias e sou extremamente grato por todos os ensinamentos e por os momentos que compartilhamos.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela bolsa de estudos

À EMBRAPA e também ao Projeto Paisagens Sustentáveis, pela disponibilidade dos dados LiDAR.

E a todos que contribuíram de alguma forma para a realização deste trabalho.

## RESUMO

As florestas tropicais são consideradas como os ecossistemas vegetais que mais estocam carbono, devido ao acúmulo de biomassa em seus tecidos durante seu desenvolvimento. A floresta Amazônica se destaca pela sua extensão, sendo considerada a maior floresta tropical do mundo. Assim, frente às principais discussões de mudanças climáticas globais, a floresta Amazônica tem sido apontada como umas das alternativas para redução de gases do efeito estufa, principais responsáveis pelas mudanças climáticas globais. Nesse sentido, esta pesquisa foi dividida em duas etapas: A primeira etapa objetivou realizar uma análise da dinâmica da biomassa acima do solo (AGB) em floresta tropical através de dados de LiDAR aerotransportado, relacionando com mudanças estruturais identificadas automaticamente. A segunda etapa teve como objetivo comparar diferentes abordagens para a estimativa de AGB em floresta tropical, bem como analisar a dinâmica da AGB em uma floresta tropical que foi seletivamente explorada. O primeiro estudo foi conduzido na Floresta Nacional (FLONA) do Jamari, em Rondônia – Brasil. Neste estudo, foram utilizados dados de LiDAR e de inventário florestal. A metodologia foi constituída de processamento dos dados LiDAR para obtenção do modelo de altura de copa (CHM) e das métricas para estimativa de AGB. Dois modelos disponíveis na literatura foram utilizados para as estimativas de AGB de campo e via métricas LiDAR. Após este procedimento, uma análise das mudanças dos estoques de AGB em nível de paisagem e também das mudanças estruturais identificadas foi realizada. O segundo estudo foi conduzido em uma floresta tropical seletivamente explorada no leste da Amazônia. Os dados de campo foram constituídos de 85 parcelas, enquanto que os dados LiDAR foram obtidos em 2012, 2014 e 2017. Modelos no nível da parcela foram primeiramente desenvolvidos usando 6 métricas baseadas na análise de PCA e quatro abordagens de aprendizado de máquina foram implementados e comparados com o modelo de regressão linear (OLS). Os resultados de ambos os capítulos mostraram que o LiDAR é uma ferramenta de grande potencial para a estimativa do estoque e da dinâmica de AGB em florestas tropicais, permitindo desta forma que diferentes análises sejam desenvolvidas. Foram mensuradas de forma automática 40 copas para cada ano no estrato superior da floresta, e com estas, observou-se que houve acréscimos estruturais positivos que não influenciaram nas estimativas dos estoques de AGB. Os resultados do segundo capítulo mostraram que entre as abordagens utilizadas, o método de regressão linear foi superior às demais abordagem, entretanto, abordagens não paramétricas como *Random Forest* e *Support Vector Machine* também mostraram potencial para estimativas de AGB e podem ser utilizadas quando necessário. Os resultados do segundo capítulo também revelaram que era possível mapear os estoques de AGB com uma precisão aceitável (RMSE <20%), dessa forma, foi possível analisar com precisão as mudanças ao longo do tempo dos estoques de biomassa em uma floresta seletivamente explorada.

Palavras-chave: Amazônia, sensoriamento remoto, predição de biomassa, métodos de estimação.

## ABSTRACT

Tropical forests are considered the most carbon-storing plant ecosystems due to the accumulation of biomass in their tissues during their development. The Amazon rainforest stands out for its extension, being considered the largest tropical forest in the world. Faced with the main discussions of global climate change, the Amazon rainforest has been identified as an alternative to reduce greenhouse gases, which are the main cause of global climate change. Thereby, this research was divided into two stages. The first stage was to perform an analysis of the aboveground biomass (AGB) dynamics in tropical forest from airborne LiDAR data, relating them to the structural changes identified automatically. The second stage was aimed at comparing different approaches to estimate AGB in tropical forest, as well as to analyze the dynamics of AGB in a tropical forest that was selectively explored. The first study was conducted in the Jamari National Forest (FLONA), in Rondônia - Brazil. Airborne LiDAR and forest inventory were used and the methodology was consisted of processing the LiDAR data to obtain Canopy Height Models (CHM) and also the metrics for estimating AGB at plot and landscape level. Two allometric models available in the literature were used for AGB estimates. The first was used to estimate the AGB from the field and the other was used for the estimations via LiDAR metrics. After this, an analysis was made of the changes in AGB stocks at the landscape level and also of the structural changes identified. The second study was conducted in a selectively exploited tropical forest in eastern Amazonia. The field data were composed of 85 plots. LiDAR data were obtained in 2012, 2014 and 2017. Plot-level models were first developed using 6 metrics based on PCA analysis and four machine learning approaches were implemented and compared with the linear regression model (OLS). The results of both chapters showed that the LiDAR is a tool with great potential for the estimation of the stock and the dynamics of AGB in tropical forests, thus allowing different analyzes to be developed. From two LiDAR surveys (2011-2013), 40 crowns were automatically measured for each year in the superior stratum of the forest, and with these, it was observed that there were positive structural increases that did not influence of AGB stocks. The results of the second chapter showed that among the approaches used, the linear regression method was superior to the other approaches, however, non-parametric approaches such as Random Forest and Support Vector Machine also shown potential for AGB estimates and may be used when required. The results of the second chapter also revealed that it was possible to map AGB stocks with acceptable accuracy (RMSE <20%), so it was possible to safely analyze the changes over time in biomass stocks in a forest that was selectively exploited.

Keywords: Amazon, remote sensing, biomass prediction, methods.

## LISTA DE ILUSTRAÇÕES

FIGURA 1 - PRINCÍPIOS E COMPONENTES DE UM SISTEMA ALS.....	28
FIGURA 2 - ESQUEMA DE CLASSIFICAÇÃO POR MEIO DO SVM, EM QUE OS PONTOS E QUADRADOS REPRESENTAM DUAS CLASSES NO ESPAÇO DE ATRIBUTOS.....	32
FIGURA 3- CLASSIFICAÇÃO DE OBJETOS UTILIZANDO O KNN COM K = 3. CADA COR REPRESENTA UMA CLASSE E OS CÍRCULOS MARCADOS COM UM P REPRESENTAM OBJETOS DESCONHECIDOS A SEREM ROTULADOS. ....	34
FIGURA 4 - EXEMPLO DE UM MODELO DE UM NEURÔNIO. ....	36
FIGURA 5 - EXEMPLO DE UM CLASSIFICADOR BASEADO EM UMA ÁRVORE DE DECISÃO NO QUAL SÃO TESTADOS ATRIBUTOS CATEGÓRICOS E QUANTITATIVOS.....	38
FIGURA 6 - MAPA DE LOCALIZAÇÃO DA ÁREA DE ESTUDO NA FLORESTAL NACIONAL DO JAMARI.....	52
FIGURA 7 - RELAÇÕES ENCONTRADAS PARA AS ESTIMATIVAS DE AGB. AGB 2011) RELAÇÕES DAS ESTIMATIVAS REFERENTE AOS TRANSECTOS DO ANO DE 2011; AGB 2013) RELAÇÕES DAS ESTIMATIVAS REFERENTE AS PARCELAS DO ANO DE 2013.....	58
FIGURA 8 - QUALIDADE DO RESULTADO DA SEGMENTAÇÃO DAS COPAS DOS MODELOS DE ALTURA DE COPAS GERADOS PELO PROCESSAMENTO DE DADOS LIDAR.....	59
FIGURA 9 - RELAÇÕES ENCONTRADAS PARA OS PARÂMETROS OBTIDOS COM A DETECÇÃO DAS COPAS. A) ALTURAS DAS ÁRVORES EXTRAÍDAS DO CHM PARA OS ANOS DE 2011 E 2013. B) AC DAS ÁRVORES EXTRAÍDAS DO CHM PARA OS ANOS DE 2011 E 2013. ....	60
FIGURA 10 - DISTRIBUIÇÃO DOS VALORES ENCONTRADOS PARA AS ESTIMATIVAS DE BIOMASSA ACIMA DO SOLO DA AMOSTRA DE FLORESTA PARA OS ANOS DE 2011 E 2013.....	61
FIGURA 11 - MAPA DE LOCALIZAÇÃO DA ÁREA DE ESTUDO NA FAZENDA CAUAXI LOCALIZADA NO LESTE DA AMAZÔNIA.....	77
FIGURA 12 - (A) A PORCENTAGEM DE VARIAÇÃO EXPLICADA PELOS SEIS PCS. (B) PROJEÇÃO DAS DUAS PRIMEIRAS PONTUAÇÕES DE PC DAS MÉTRICAS DE LIDAR SELECIONADAS.....	84

FIGURA 13 - VALORES PREVISTOS E OBSERVADOS PARA BIOMASSA ACIMA DO SOLO PARA OS MODELOS TESTADOS USANDO VARIÁVEIS SELECIONADAS A PARTIR DE MÉTRICAS DE LIDAR.....	87
FIGURA 14 - BOXPLOT DAS ESTIMATIVAS DE ESTOQUES DA AGB NO NÍVEL DA PARCELA PARA 2012, 2014 E 2017.....	88
FIGURA 15 - MAPA DOS ESTOQUES DE AGB EM 2012 (A), 2014 (B) E 2017 (C). ZOOM DOS MAPAS DE AGB EM UMA UNIDADE NÃO REGISTRADA DE 2012 (D) REGISTRADA EM 2012 (E), SEM REGISTRO EM 2014 (F), UNIDADE REGISTRADA EM 2014 (G), SEM REGISTRO EM 2017 (H) E UNIDADE REGISTRADA EM 2017 (I).	90
FIGURA 16 - BOXPLOT DAS ESTIMATIVAS DE MUDANÇA DA AGB AO NÍVEL DA PARCELA PARA 2012, 2014 E 2017.....	91
FIGURA 17 - MAPA DA MUDANÇA DA AGB EM 2012 (A), 2014 (B) E 2017 (C). ZOOM DOS MAPAS DE MUDANÇA DE AGB EM UMA UNIDADE NÃO REGISTRADA DE 2012 (D) REGISTRADA EM 2012 (E), SEM REGISTRO EM 2014 (F), UNIDADE REGISTRADA EM 2014 (G), SEM REGISTRO EM 2017 (H) E UNIDADE REGISTRADA EM 2017 (I).	93

## LISTA DE TABELAS

TABELA 1 - APLICAÇÕES FLORESTAIS DE DADOS LIDAR. ....	30
TABELA 2 - ESPECIFICAÇÕES REFERENTES AOS SOBREVOOS PARA A COLETA DAS NUVENS LIDAR DOS ANOS DE 2011 E 2013. ....	54
TABELA 3 - ESPECIFICAÇÕES DOS CONJUNTOS DE DADOS LIDAR AEROTRANSPORTADO. ....	79
TABELA 4 - MÉTRICAS DE ESTRUTURA DERIVADA DE LIDAR CONSIDERADAS COMO VARIÁVEIS PREDITORAS CANDIDATAS. ....	80
TABELA 5 - CÁLCULOS DE AUTOVALORES E AUTOVETORES PARA OS PRIMEIROS CINCO PCS. ....	85
TABELA 6 - MODELOS DE REGRESSÃO E DE AM PARA ESTIMATIVA DE AGB BASEADOS EM MÉTRICAS LIDAR UTILIZANDO PARCELAS DE CAMPO (N = 85). ....	86
TABELA 7 - MÉDIA E DESVIO PADRÃO (SD) PARA O MODELO DE AGB BASEADO EM MÉTRICAS LIDAR EM 2014. STD ERROR É O ERRO PADRÃO ESTIMADO DERIVADO DA ANÁLISE DE INCERTEZA. ....	89
TABELA 8 - MÉDIA E DESVIO PADRÃO (SD) PARA O MODELO DE AGB BASEADO EM MÉTRICAS LIDAR EM 2014. STD ERROR É O ERRO PADRÃO ESTIMADO DERIVADO DA ANÁLISE DE INCERTEZA. ....	92

## SUMÁRIO

<b>1. CAPÍTULO I: ASPECTOS GERAIS .....</b>	<b>14</b>
1.1. INTRODUÇÃO GERAL.....	14
1.1. ORGANIZAÇÃO DO TRABALHO.....	17
<b>2. REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>18</b>
<b>3. CAPÍTULO II: REVISÃO DE LITERATURA.....</b>	<b>21</b>
3.1. FLORESTA AMAZÔNICA.....	21
3.2. BIOMASSA E CARBONO.....	22
3.3. INVENTÁRIO FLORESTAL .....	24
3.4. SENSORIAMENTO REMOTO.....	25
3.5. LiDAR .....	26
3.6. APRENDIZADO DE MÁQUINA .....	30
3.7. <i>Support Vector Machine (SVM)</i> .....	32
3.8. <i>k-Nearest Neighbors (k-NN)</i> .....	33
3.9. <i>Artificial Neural Network (Redes Neurais Artificiais – RNA)</i> .....	35
3.10. <i>Random Forest (RF)</i> .....	36
<b>4. REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>39</b>
<b>5. CAPÍTULO III: MUDANÇA NO ESTOQUE DE BIOMASSA ACIMA DO SOLO EM FLORESTA TROPICAL VIA DADOS LIDAR.....</b>	<b>48</b>
5.1. INTRODUÇÃO .....	50
5.2. OBJETIVOS .....	51
5.3. MATERIAL E MÉTODOS .....	52
5.3.1. Área de Estudo .....	52
5.3.2. Dados Utilizados .....	53
5.3.3. Processamento dos Dados de LiDAR.....	54
5.3.4. Individualização de árvores.....	55

5.3.5.	Estimativas de AGB .....	56
5.3.6.	Estimativa de AGB via métricas LiDAR .....	56
5.3.7.	Mudança da AGB e na estrutura das copas .....	57
5.3.8.	Avaliações estatísticas .....	57
5.4.	RESULTADOS .....	57
5.4.1.	Processamento e Estimativas LiDAR versus Inventário Florestal .....	57
5.4.2.	Segmentação de copas .....	59
5.4.3.	Mudanças estruturais .....	60
5.4.4.	Dinâmica da AGB da área de estudo .....	61
5.5.	DISCUSSÃO .....	62
5.6.	CONCLUSÕES .....	65
<b>6.</b>	<b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>66</b>
<b>7.</b>	<b>CAPÍTULO IV: COMPARAÇÃO ENTRE ABORDAGENS DE MODELAGEM ESTATÍSTICA PARA ESTOQUE DE BIOMASSA ACIMA DO SOLO E ESTIMATIVA DA DINÂMICA EM FLORESTA TROPICAL SELETIVAMENTE EXPLORADA A PARTIR DE DADOS LIDAR .....</b>	<b>72</b>
7.1.	INTRODUÇÃO .....	74
7.2.	OBJETIVOS .....	76
7.3.	MATERIAL E MÉTODOS .....	76
7.3.1.	Área de estudo .....	76
7.3.2.	Dados de campo .....	78
7.3.3.	Dados LiDAR e processamento .....	78
7.3.4.	Desenvolvimento e Avaliação de Modelagem .....	80
7.3.5.	Abordagens de modelagem .....	80
7.3.6.	Estimativa e mapeamento de alterações da AGB .....	81
7.4.	RESULTADOS .....	84
7.4.1.	PCA e seleção de variáveis .....	84
7.4.2.	Modelagem e Avaliação .....	85

7.4.3. Mapeamento e incerteza da mudança de biomassa acima do solo .....	87
7.5. DISCUSSÃO .....	93
7.6. CONCLUSÕES .....	98
<b>8. REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>99</b>

## 1. CAPÍTULO I: ASPECTOS GERAIS

### 1.1. INTRODUÇÃO GERAL

Os ecossistemas tropicais ocupam uma grande extensão do planeta e apresentam alta diversidade de fatores ambientais, tais como, clima, geologia, relevo, solo, vegetação e animais (MAYAUX et al., 2005; BOHLMAN et al., 2008; LAURANCE et al., 2010). A floresta Amazônica é um exemplo de um ecossistema de alta diversidade, pois apresenta a maior extensão de floresta tropical do mundo (PEREIRA et al., 2010), sendo também considerada a maior floresta tropical do mundo em estoque de carbono (BACCINI et al., 2012).

Todavia, áreas florestais são globalmente ameaçadas pelas atividades humanas, como o desmatamento, que é causado principalmente pela maior pressão populacional, especialmente nos países tropicais (OCHOA-CUEVA et al., 2015). Além do mais, desmatamento e também a degradação nos trópicos são uma grande fonte de emissão de carbono (C) na atmosfera, contribuindo com cerca de 7–15% do total de emissões antropogênicas de carbono desde o início dos anos 2000 (HARRIS et al., 2012). Nesse sentido, a floresta Amazônica influencia no envio de Dióxido de Carbono (CO<sub>2</sub>) para a atmosfera por meio de desmatamento e degradação florestal (HOUGHTON, 2013), sendo necessárias ferramentas eficazes para monitorar estas paisagens ao longo do tempo, uma vez que o monitoramento da biomassa pode fornecer informações do sequestro, armazenamento e / ou emissão de carbono na atmosfera (GOETZ et al., 2011; BARBOSA et al., 2014; ZHAO et al., 2018).

A biomassa acima do solo (AGB – *Aboveground Biomass*) definida como toda a biomassa viva acima do solo, incluindo tronco, cepo, galhos, casca, sementes e folhagem (IPCC, 2006), é usada para estimar os reservatórios de carbono terrestre e o sequestro de carbono da atmosfera (GOETZ et al., 2011; BARBOSA et al., 2014). A estimativa precisa dessa variável, particularmente em escala de mudanças no uso da terra, é de extrema importância para monitorar a dinâmica do carbono em regiões tropicais (CLARK et al., 2011). Além do mais, essas estimativas podem contribuir para a eficácia das políticas ambientais, como, por exemplo, REDD ++ que visa reduzir as emissões do desmatamento e da degradação florestal e tem papel de conservação, manejo sustentável das florestas e aumento dos estoques de carbono florestal (CAMPBELL, 2009).

Para estimar a AGB, diferentes técnicas podem ser aplicadas. Medições tradicionais baseadas em campo fornecem os valores de AGB mais precisos, mas são destrutivas e

espacialmente limitadas (ENE et al., 2013; WU et al., 2016). A tecnologia de sensoriamento remoto pode ser usada para fornecer informações quantitativas, espacialmente explícitas, de maneira oportuna e econômica para o monitoramento e mapeamento do estoque de carbono florestal (GIBBS et al., 2007). Dados provenientes de sensores remotos são amplamente utilizados, em especial, LiDAR (*Light Detection and Ranging*) vem se destacando na obtenção de informações como a AGB, devido ao potencial de penetrar no dossel da floresta (LEFSKY et al., 2002) e de ser um instrumento poderoso em florestas de alta biomassa onde os sensores ópticos passivos ou de sensores RADAR têm problemas de saturação (CHEN et al., 2015).

Desse modo, através de uma plataforma aerotransportada, o sistema ALS obtém medidas diretas da vegetação, como altura do dossel (DUBAYAH et al., 2000; POPESCU et al., 2011; SATO et al., 2015), sendo essas informações fortemente relacionadas à AGB. Além do mais, uma das principais vantagens do LiDAR está na capacidade de penetrar nas pequenas aberturas da cobertura para detectar a estrutura vertical e extrair a elevação do solo. A capacidade para estimar a AGB a partir de observações de detecção remota tem avançado consideravelmente, em grande parte devido ao aumento da disponibilidade das medições diretas tridimensional (3D) de estrutura da vegetação fornecidas por LiDAR (LEFSKY et al., 2002), e um grande número de estudos tem relatado o uso do equipamento aerotransportado para mapear a AGB em ambientes tropicais (por exemplo, ASNER et al., 2012; D'OLIVEIRA et al., 2012; ANDERSEN et al., 2014; CHEN et al., 2015; SILVA et al., 2017). No entanto, vale ressaltar que nenhum instrumento de sensoriamento remoto pode medir diretamente a AGB. Dessa forma, medições de inventário de campo são obrigatórias para calibrar e validar as estimativas (GOETZ; DUBAYAH, 2011).

Apesar dos avanços em pesquisas referentes à estimativa de biomassa utilizando a tecnologia LiDAR, muitas abordagens foram e continuam sendo testadas; entretanto ainda não está claro o impacto de diferentes abordagens na predição de AGB em florestas tropicais. Geralmente, regressão por mínimos quadrados ordinários com seleção de variáveis passo a passo tem sido usada com mais frequência para construir modelos entre medições de campo e métricas de ALS (GARCIA-GUTIERREZ et al., 2014). A principal vantagem de utilizar este tipo de metodologia é a simplicidade e clareza dos modelos resultantes (GARCIA-GUTIERREZ et al., 2015), especialmente quando a relação entre a AGB e as métricas de ALS é quase linear (MUAYA et al., 2015). Entretanto, abordagens não-paramétricas oferecem um método de modelagem e predição que é muito eficaz e que podem ser

considerados como uma alternativa à regressão, uma vez que não se baseiam em quaisquer suposições de distribuição dos dados (PACKALÉN; MALTAMO, 2007).

Nesse sentido, a presente pesquisa teve como motivação principal a utilização de dados LiDAR e aplicação de diferentes abordagens estatísticas para estimativas de AGB em florestas tropicais. Além do mais, também fez parte da motivação desta pesquisa, realizar análises da dinâmica dessa variável em nível de paisagem para entender a dinâmica do esoque de AGB, uma vez que estes são de extrema importância frente às principais discussões de mudanças climáticas globais.

## 1.1. ORGANIZAÇÃO DO TRABALHO

Este trabalho foi desenvolvido em 4 capítulos, sendo que o primeiro capítulo, “Aspectos Gerais (I)” trata-se de uma introdução geral dos assuntos que fazem parte do escopo desta pesquisa; o segundo capítulo “Revisão Bibliográfica (II)” faz uma breve revisão dos principais temas, enquanto que os capítulos (III) e (IV) apresentam métodos de pesquisa e resultados. O trabalho então é composto pelos capítulos que se seguem:

- I. Aspectos Gerais;
- II. Revisão Bibliográfica;
- III. Dinâmica da biomassa acima do solo em floresta tropical via dados LiDAR;
- IV. Comparação entre abordagens de modelagem estatística para estoque de biomassa acima do solo e estimativa da dinâmica em floresta tropical seletivamente explorada a partir de dados LiDAR.

## 2. REFERÊNCIAS BIBLIOGRÁFICAS

ANDERSEN, H. et al. Monitoring selective logging in western Amazonia with repeat lidar flights. **Remote Sensing of Environment**, v. 151, p. 157-165, 2014.

ASNER, G. P. et al. High-resolution mapping of forest carbon stocks in the Colombian Amazon. **Biogeosciences**, v. 9, n. 7, p. 2683-2696, 2012.

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

BARBOSA, J. M.; BROADBENT, E. N.; BITENCOURT, M. D. Remote sensing of aboveground biomass in tropical secondary forests: A review. **International Journal of Forestry Research**, v. 2014, 2014.

BOHLMAN, S. A. et al. Importance of soils, topography and geographic distance in structuring central Amazonian tree communities. **Journal of Vegetation Science**, v. 19, n. 6, p. 863-874, 2008.

BOJINSKI, S. et al. The concept of essential climate variables in support of climate research, applications, and policy. **Bulletin of the American Meteorological Society**, v. 95, n. 9, p. 1431-1443, 2014.

CAMPBELL, Bruce M. Beyond Copenhagen: REDD +, agriculture, adaptation strategies and poverty. **Global Environmental Change**. V. 19, n. 4, p. 397-399, 2009.

CHEN, Q; LAURIN, G. V; VALENTINI, R. Uncertainty of remotely sensed aboveground biomass over an African tropical forest: Propagating errors from trees to plots to pixels. **Remote Sensing of Environment**, v. 160, p. 134-143, 2015.

CLARK, M. L. et al. Estimation of tropical rain forest aboveground biomass with small-footprint lidar and hyperspectral sensors. **Remote Sensing of Environment**, v. 115, n. 11, p. 2931-2942, 2011.

D'OLIVEIRA, M. VN. et al. Estimating forest biomass and identifying low-intensity logging areas using airborne scanning lidar in Antimary State Forest, Acre State, Western Brazilian Amazon. **Remote Sensing of Environment**, v. 124, p. 479-491, 2012.

DUBAYAH, R. et al. Land surface characterization using lidar remote sensing. **Spatial information for land use management**, p. 25-38, 2000.

ENE, L. T. et al. A simulation approach for accuracy assessment of two-phase post-stratified estimation in large-area LiDAR biomass surveys. **Remote Sensing of Environment**, v. 133, p. 210-224, 2013.

GARCÍA-GUTIÉRREZ, J. et al. A comparison of machine learning regression techniques for LiDAR-derived estimation of forest variables. **Neurocomputing**, v. 167, p. 24-31, 2015.

GARCIA-GUTIERREZ, J. et al. Evolutionary feature selection to estimate forest stand variables using LiDAR. **International Journal of Applied Earth Observation and Geoinformation**, v. 26, p. 119-131, 2014.

GARCÍA-MARTÍN, A. et al. Using remote sensing to estimate a renewable resource: forest residual biomass. In: **Remote Sensing of Biomass-Principles and Applications**. InTech, p.297-322, 2012.

GIBBS, H K. et al. Monitoring and estimating tropical forest carbon stocks: making REDD a reality. **Environmental Research Letters**, v. 2, n. 4, p. 045023, 2007.

GOETZ, S; DUBAYAH, R. Advances in remote sensing technology and implications for measuring and monitoring forest carbon stocks and change. **Carbon Management**, v. 2, n. 3, p. 231-244, 2011.

HARRIS, N. L. et al. Baseline map of carbon emissions from deforestation in tropical regions. **Science**, v. 336, n. 6088, p. 1573-1576, 2012.

HOUGHTON, R. A. The emissions of carbon from deforestation and degradation in the tropics: past trends and future potential. **Carbon Management**, v. 4, n. 5, p. 539-546, 2013.

IPCC - Intergovernmental Panel on Climate Change. 2006 IPCC **Guidelines for National Greenhouse Gas Inventories**. In *National Greenhouse Gas Inventories Programme*; IGES: Tsukuba, Japan, 2006; p. 673

LAURANCE, S. G.W et al. Influence of soils and topography on Amazonian tree diversity: a landscape-scale study. **Journal of Vegetation Science**, v. 21, n. 1, p. 96-106, 2010.

LEFSKY, M. A. et al. Lidar remote sensing for ecosystem studies: Lidar, an emerging remote sensing technology that directly measures the three-dimensional distribution of plant canopies, can accurately estimate vegetation structural attributes and should be of particular interest to forest, landscape, and global ecologists. **BioScience**, v. 52, n. 1, p. 19-30, 2002.

MAIN-KNORN, M. et al. Evaluating the remote sensing and inventory-based estimation of biomass in the Western Carpathians. **Remote Sensing**, v. 3, n. 7, p. 1427-1446, 2011.

MAUYA, E. W. et al. Modelling aboveground forest biomass using airborne laser scanner data in the miombo woodlands of Tanzania. **Carbon balance and management**, v. 10, n. 1, p. 28, 2015.

MAYAUX, P. et al. Tropical forest cover change in the 1990s and options for future monitoring. **Philosophical Transactions of the Royal Society of London B: Biological Sciences**, v. 360, n. 1454, p. 373-384, 2005.

OCHOA-CUEVA, P. et al. Spatial estimation of soil erosion risk by land-cover change in the Andes of southern Ecuador. **Land degradation & development**, v. 26, n. 6, p. 565-573, 2015.

PACKALÉN, P; MALTAMO, M. The k-MSN method for the prediction of species-specific stand attributes using airborne laser scanning and aerial photographs. **Remote sensing of Environment**, v. 109, n. 3, p. 328-341, 2007.

PAN, Y. et al. A large and persistent carbon sink in the world's forests. **Science**, p. 1201609, 2011.

PEREIRA, D. et al. Fatos Florestais. **Imazon, Belém, PA**, 2010.

POPESCU, S. C. et al. 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.

SATO, L Y. et al. Análise da relação entre dados de LiDAR e de biomassa florestal no sudoeste da Amazônia. In: **Embrapa Monitoramento por Satélite-Artigo em anais de congresso (ALICE)**. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17., 2015, João Pessoa. Anais... São José dos Campos: INPE, 2015.

SILVA, C. A. et al. Impacts of airborne lidar pulse density on estimating biomass stocks and changes in a selectively logged tropical forest. **Remote Sensing**, v. 9, n. 10, p. 1068, 2017

THURNER, M. et al. Evaluation of climate-related carbon turnover processes in global vegetation models for boreal and temperate forests. **Global change biology**, v. 23, n. 8, p. 3076-3091, 2017.

WU, C. et al. Comparison of machine-learning methods for above-ground biomass estimation based on Landsat imagery. **Journal of Applied Remote Sensing**, v. 10, n. 3, p. 035010, 2016.

ZHAO, K. et al. Utility of multitemporal lidar for forest and carbon monitoring: Tree growth, biomass dynamics, and carbon flux. **Remote Sensing of Environment**, v. 204, p. 883-897, 2018.

### 3. CAPÍTULO II: REVISÃO DE LITERATURA

#### 3.1. FLORESTA AMAZÔNICA

Segundo dados da Organização das Nações Unidas para Agricultura e Alimentação (FAO, 2015) a área com cobertura arbórea no Brasil é de 493,5 milhões hectares, de florestas naturais e plantadas, o que representa a segunda maior área florestal do mundo, atrás apenas da Rússia. As florestas naturais somam cerca de 485,7 milhões de hectares, cobrindo aproximadamente 57% da superfície terrestre brasileira (FAO, 2015) sendo que a área estimada de floresta no bioma Amazônia foi de 342 milhões hectares para o ano de 2015 (FAO, 2014).

No que se refere à floresta Amazônica, esse ecossistema se destaca entre os mais importantes ecossistemas tropicais do mundo, não apenas por sua grande extensão territorial, mas também por sua rica biodiversidade e pelo importante papel que desempenha nos ciclos biológicos do planeta em nível regional e mundial (BORGES, 2017). Além do mais, essa alta diversidade de espécies, muitas vezes endêmicas (OLIVEIRA; AMARAL, 2004), evidencia a importância do uso dos recursos florestais de forma racional, visando preservar as espécies para futuras gerações (IFT, 2012).

De acordo com Veríssimo e Pereira (2015), no Brasil há duas definições para a Amazônia: o bioma e Amazônia Legal. Bioma Amazônia corresponde à cobertura florestal original e ocupa uma área de 410 milhões de hectares quadrados. Enquanto que a Amazônia Legal soma cerca de 500 milhões de hectares incluindo também áreas de vegetação não florestal (cerrados e campos naturais). Aproximadamente 63% da Amazônia Legal é coberta por florestas densas, abertas e estacionais e 22% são cobertos por vegetação nativa não florestal, composta por cerrado, campos naturais e campinaranas. Além do mais, em torno de 15% da cobertura vegetal da Amazônia Legal foi desmatada até 2009.

A Floresta Amazônica também cumpre com funções ecológicas, culturais e econômicas de importância incalculável. Ela sustenta a economia de regiões inteiras, abriga sociedades tradicionais e também tem um papel central no equilíbrio do clima do planeta, além de ajudar a manter a qualidade das águas e a estabilidade do solo (ROTH, 2009). A região é detentora de uma grande diversidade étnico-cultural com uma população de aproximadamente 24 milhões de habitantes, dos quais mais de 450 mil são indígenas distribuídos em mais de 173 povos reconhecidos (VERÍSSIMO et al., 2011).

A Floresta Amazônica também é o maior reservatório natural de diversidade do planeta, onde cada um de seus diferentes ambientes florestais possui um contingente florístico rico e variado, muitas vezes exclusivo de determinado ambiente (OLIVEIRA; AMARAL, 2004). A região florística Amazônica é composta principalmente por formações de Floresta Ombrófila Densa, Floresta Ombrófila Aberta, Floresta Estacional Sempre Verde e Campinarana, é caracterizada por apresentar vegetação com predomínio de famílias de dispersão pantropical, como *Sapotaceae*, *Fabaceae*, *Lecythydaceae*, *Vochysiaceae*, *Caricaceae* e *Humiriaceae* (IBGE, 2012). A precipitação média do bioma Amazônia é de 2.300mm por ano, sendo que o mês de janeiro é o mais seco, enquanto que o mês de julho corresponde ao período mais quente (MARENGO; NOBRE, 2009).

Por ser considerada a maior floresta tropical do mundo, a floresta Amazônica estoca um quinto do carbono total da vegetação terrestre global, atuando como sumidouro, responsável pelo processamento de três vezes mais carbono por meio da fotossíntese e da respiração do que o carbono liberado para a atmosfera pela queima de combustíveis fósseis (MALHI et al., 2008), representando assim o maior reservatório de carbono na forma de biomassa do planeta (MALHI et al., 2008; BETTS, 2006). Entretanto, nas últimas décadas, a ação humana, em grande parte dos ecossistemas naturais da Terra, acelerou grandemente e o século XXI anunciará profundas mudanças no uso da terra, particularmente nos países tropicais em desenvolvimento (LEE; JETZ, 2008).

O INPE (Instituto Nacional de Pesquisas Espaciais) pelo Projeto de Monitoramento do Desmatamento na Amazônia Legal por Satélite (PRODES), estima que 790 mil hectares foram desmatados na Amazônia por corte raso no período de agosto de 2017 a julho de 2018 (INPE, 2018), o que se releva de extrema preocupação devido a emissões de gases de efeito estufa por mudança no uso e cobertura da terra, uma vez que os principais vetores de emissões de gases do efeito estufa são desmatamento, exploração madeireira, incêndios florestais, secas (ARAGÃO et al., 2014) e barragens hidroelétricas (FEARNSIDE, 1995; FEARNSIDE, 2015).

### 3.2. BIOMASSA E CARBONO

De acordo com o Guia de Inventário Nacional de Gases de Efeito Estufa do IPCC (2006), a biomassa florestal é definida pelo peso da árvore, em quilos (kg) ou toneladas (t), sendo que a primeira é utilizada para o peso individual e a segunda quando se refere a estoques, e ainda está relacionada à produtividade primária líquida que um ecossistema tem

a capacidade de produzir (ZHAO; RUNNING, 2010). O termo biomassa florestal também pode significar toda a biomassa existente na floresta ou apenas a fração arbórea da mesma, podendo-se também utilizar o termo fitomassa florestal ou fitomassa arbórea (SANQUETTA; BALBINOT, 2002).

Na literatura também é possível encontrar termos como biomassa total, que é a soma de: biomassa viva horizontal acima do solo (árvores e arbustos), biomassa morta acima do solo (serapilheira e troncos caídos) e biomassa abaixo do solo (raízes) (MARTINELLI et al., 1994). No entanto, a biomassa florestal normalmente é dividida em dois grandes grupos, denominados de biomassa acima do solo (*Aboveground Biomass* - AGB) e biomassa abaixo do solo (*Belowground Biomass* - BGB). Em florestas tropicais, a maior parte dessa biomassa total se encontra em árvores, principalmente na biomassa viva acima do solo, sob forma de madeira fresca (cerca de 70% da biomassa total) com significativa presença de água (cerca de 15% a 20%) (BAIS, 2008).

Em uma floresta, a biomassa viva é composta por troncos, galhos, raízes, cascas, sementes e folhagens, enquanto que a biomassa morta é composta por serapilheira, galhos e troncos caídos e pela biomassa morta abaixo do solo (HIGA *et al.*, 2014). É uma variável ecológica crucial, que deve ser estimada com precisão para reduzir as incertezas nas estimativas do orçamento de carbono florestal e entender possíveis mudanças no sistema climático (SRINIVASAN et al., 2014). Além disso, metade da biomassa é considerada como responsável pelo carbono, que é de grande interesse científico para entender o ciclo do carbono (HOUGHTON et al., 2009, LIN et al., 2010, ZOLKOS et al., 2013). Uma vez que, os reservatórios de carbono na Terra encontram-se na atmosfera, nos oceanos, nas reservas de combustíveis fósseis, nos solos e na vegetação, a qual é responsável pelo fluxo mais intenso no ciclo de carbono global (MOURA-COSTA, 1996).

A quantificação da AGB dentro de um estande é necessária para que os manejadores tomem decisões informadas sobre o valor e o uso de suas terras florestais (HE et al., 2013). Nos dias de hoje, há um grande interesse em estudos que abordam, em seu escopo, o termo biomassa florestal, uma vez que, esse parâmetro apresenta relações diretas com CO<sub>2</sub> atmosférico, e deste com as mudanças climáticas. Com efeito, a AGB, incluindo as partes acima e abaixo do solo, é a principal via para remoção de CO<sub>2</sub> da atmosfera através dos processos da fotossíntese e respiração (IPCC, 2006). Entretanto, mensurar a biomassa de árvores é um processo laborioso e de alto custo em relação às outras variáveis biométricas da floresta, tais como o DAP (diâmetro altura do peito) e a altura. Devido a isso, tem sido usual o emprego de modelos empíricos que possibilitam estimar a biomassa a

partir de variáveis dendrométricas, que são determinadas com simplicidade via inventário florestal. Assim, a aplicação da modelagem viabiliza os inventários florestais de biomassa em grande escala espacial, uma vez que reduz essencialmente os custos (BEHLING, 2016).

### 3.3. INVENTÁRIO FLORESTAL

O Inventário Florestal é o uso de fundamentos de amostragem e mensuração para a determinação ou estimativa das características quantitativas ou qualitativas da floresta, com finalidade de se conhecer o estoque de madeira presente na floresta e seu potencial produtivo, além de ser possível o desenvolvimento de estudos de crescimento e conhecer a estrutura da floresta (SCOLFORO; MELLO, 2006). De acordo com Soares et al. (2006) o Inventário Florestal consiste em uma técnica de estimação da produção florestal e de outras características dos recursos florestais, que pode ser realizada sob diferentes níveis de detalhamento e em diferentes momentos (SOARES et al., 2006). Enquanto que, Péllico Netto e Brena (1997) definem o inventário florestal como uma atividade que visa obter informações qualitativas e quantitativas dos recursos florestais existentes em uma área pré-especificada.

Nas atividades florestais e nas avaliações ambientais relativas aos recursos florestais, o inventário florestal é sempre uma técnica importante, talvez até mesmo imprescindível ao perfeito conhecimento do potencial dos recursos existentes em uma determinada área, sendo a validade estatística e representatividade amostral marcas registradas do inventário florestal (SANQUETTA et al., 2009). Uma vez que o inventário florestal utiliza como ferramenta principal a teoria da amostragem, dois conceitos devem ser levados em consideração: população e amostra. O primeiro termo refere-se ao conjunto de valores unitários sobre os quais se faz observações, totalizando todos os indivíduos. Já a amostra é uma rede de unidades amostrais com as quais se faz uma inferência para o restante da população por meio de estimativa de parâmetros (SCOLFORO; MELLO, 2006).

Na Amazônia, as estimativas de biomassa podem ser realizadas pelos métodos diretos e indiretos. Pelo método direto, as árvores são cortadas e seus componentes separados e pesados (SANQUETTA; BALBINOT, 2002). De acordo com Silva Junior (2018) os métodos diretos trazem consigo limitação quando da realização de levantamentos em áreas de grande extensão (exemplo, toda a floresta Amazônica), que tornam o processo oneroso e lento. Enquanto que os métodos indiretos se baseiam em dados amostrados de inventários florestais, tais como diâmetro, altura e densidade da madeira, os quais são

posteriormente utilizados para o desenvolvimento de modelos estatísticos alométricos de estimativa de biomassa por meio de análise de regressão (HIGUCHI et al., 1982), e ainda por meio de imagens de satélite (SILVA et al., 2015) uso de inteligência artificial (SCHOENINGER et al., 2008) e de fatores de expansão (SILVEIRA, 2010).

### 3.4. SENSORIAMENTO REMOTO

A definição de Sensoriamento Remoto (SR) é abordada na literatura por diversos autores: Florenzano (2007) afirma que, o termo Sensoriamento refere-se à obtenção de dados, e Remoto, que significa distante, é utilizado porque a obtenção é feita a distância, ou seja, sem contato físico entre o sensor e a superfície terrestre. Para Meneses et al. (2012) o Sensoriamento Remoto é uma técnica de obtenção de imagens dos objetos da superfície terrestre sem que haja contato físico entre o sensor e o objeto. Enquanto que Liu (2015) define o SR como uma técnica de aquisição e de aplicação das informações sobre um objeto sem nenhum contato físico com ele.

Novo (2010) apresenta uma definição mais completa sobre SR, como sendo a utilização conjunta de sensores, equipamentos para processamento de dados, equipamentos de transmissão de dados colocados a bordo de aeronaves, espaçonaves, ou outras plataformas, com o objetivo de estudar eventos, fenômenos e processos que ocorrem na superfície do planeta Terra a partir do registro e da análise das interações entre a radiação eletromagnética (REM) e as substâncias que o compõem em suas mais diversas manifestações.

Em síntese, todas definições de SR culminam para um mesmo fim, a obtenção de informações da superfície terrestre sem contato físico entre o sensor e o objeto. Além do mais, adicionando a teoria, Meneses et al. (2012) comentam que nenhum outro tipo de sensor que obtenha imagens que não seja pela detecção da radiação eletromagnética deve ser classificado como sensoriamento remoto. A radiação eletromagnética desempenha papel fundamental no processo de obtenção de informação via sensoriamento remoto, a quantidade e qualidade da energia eletromagnética refletida e emitida pelos objetos terrestres resultam das interações entre a energia eletromagnética e estes objetos, interações estas que são determinadas pelas propriedades físico-químicas e biológicas desses objetos e podem ser identificadas nas imagens e nos dados de sensores remotos.

O sensor como retratado anteriormente é um dispositivo capaz de responder à radiação eletromagnética em determinada faixa do espectro eletromagnético, registrá-la e

gerar um produto numa forma adequada para ser interpretada pelo usuário. Sendo constituído basicamente por um coletor, que pode ser uma lente, espelho ou antena e um sistema de registro, que pode ser um detector ou filme (ROSA, 2011).

Os sensores podem ser classificados em função da fonte de energia ou em função do tipo de produto que produz. Em função da fonte de energia, os sensores podem ser classificados em passivos, quando não possuem fonte própria de radiação. Ex.: Sistemas fotográficos e satélites. E, ativos, quando possuem sua própria fonte de radiação eletromagnética, trabalhando em faixas restritas do espectro. Ex.: Radares e LiDAR. (INPE, 2006).

Com estas definições de sensoriamento remoto, é explícita em afirmar que o objeto imageado é registrado pelo sensor por meio de medições da radiação eletromagnética, tal como a luz solar refletida da superfície de qualquer objeto. Nenhum outro tipo de sensor que obtenha imagens que não seja pela detecção da radiação eletromagnética deve ser classificado como sensoriamento remoto (MENESES et al., 2012).

Para Ferreira et al. (2008) a análise integrada de dados de sensoriamento remoto e outras informações temáticas têm possibilitado, entre outros, melhor representação, à escala (e unidades) da paisagem, das distribuições e variações fitofisionômicas. As tecnologias que envolvem o sensoriamento remoto e a obtenção de dados sem o seu contato direto, refletem diretamente na economia de tempo.

### 3.5. LiDAR

O termo LiDAR (*Light Detection and Ranging*), é utilizado para designar uma tecnologia de sensoriamento remoto que utiliza pulso *laser* para caracterizar alvos de interesse em três dimensões (WEVER; LINDENBERGER, 1999; GIONGO et al., 2010). Essa tecnologia também é conhecida como Sistema de Varredura, Rastreamento ou Perfilamento a *Laser*. O LiDAR combina medições de luz de *laser* e posicionamento para realizar levantamentos e mapeamentos com alta acurácia de objetos presentes na superfície e criar uma nuvem de pontos tridimensional (3D) (NOAA, 2012)

A tecnologia LiDAR não é recente, foi inventada na década de 1960 por Theodore H. Maiman, cujos principais precedentes para o desenvolvimento foram a emissão estimulada de radiação luminosa, cujo estudo previa a possibilidade de estimular um corpo a liberar energia com características constantes e uniformes em forma de radiação eletromagnética (GONÇALES, 2007, SILVA et al., 2013), porém sua utilização na aquisição de dados geográficos pode ser considerada recente.

O Sistema LiDAR é uma tecnologia que emprega um equipamento de sensoriamento remoto ativo (*scanner*), que transmite a radiação eletromagnética e mede a radiação que é retroespalhada para um receptor depois de interagir com a atmosfera da terra ou com objetos (LONGLEY et al., 2009). Essa tecnologia é baseada nos mesmos princípios utilizados no sistema de RADAR, com a diferença de que, ao invés do uso de ondas de rádio para localizar os objetos de interesse, o sistema LiDAR utiliza pulsos *laser* (GIONGO et al., 2010).

Como retratado anteriormente, o sistema LiDAR é uma tecnologia de sensoriamento remoto ativo, ou seja, apresenta sua própria fonte de energia, neste caso, uma fonte de luz, o *laser*, a qual emite radiação eletromagnética em ondas curtas (1-10  $\mu\text{m}$ ) sendo sensível às perturbações atmosféricas (ANDERSEN et al., 2006) e, assim, é considerado um método direto na captura de dados. Uma vantagem dos sensores de varredura a *laser* em relação aos clássicos sensores passivos (fotografias aéreas e imagens de satélite) é que os scanners a *laser* não dependem do sol como uma fonte de iluminação (GIONGO et al., 2010).

A luz *laser* possui características únicas, tais como: monocromaticidade, alta intensidade, direção e coerência, que o tornam um excelente instrumento de uso científico e tecnológico (BAGNATO, 2001). A coerência é a propriedade mais importante da luz emitida por um laser, isto é, todos os raios de luz individuais possuem mesmo comprimento de onda e estão todos alinhados. Isto se deve ao fato de que a energia emitida não se dissipa a medida que estes raios se propagam, o que permite concentrá-la em um ponto finamente definido e aumentar significativamente o seu alcance (CARROLL, 1978; BRANDALIZE; PHILIPS, 2002).


O equipamento que realiza o escaneamento é chamado de *Laser Scanner* e pode ser do tipo móvel ou fixo, aerotransportado ou terrestre. De acordo com Popescu (2011), não há grandes diferenças entre os princípios ópticos e mecânicos dos sistemas LiDAR de escaneamento aéreo, espacial e terrestre. As distinções ocorrem na montagem das plataformas e na complexidade das tecnologias adicionais usadas para determinar a orientação e a posição do sensor.

Outros autores como Pereira (2014) e Martins Neto, (2016) defendem a ideia de que há dois tipos de sistemas de varredura *laser*: sistema estático e dinâmico. O sistema estático consiste de uma base fixa no terreno que emite pulsos *laser* para o objeto (alvo). Já o sistema dinâmico consiste da utilização de um feixe óptico de alta potência em uma plataforma móvel (avião ou helicóptero), coerente no espaço e no tempo, para garantir a

qualidade da medição da distância. Atualmente a plataforma mais utilizada para levantamentos e estudos da vegetação com LiDAR é a plataforma aérea (SILVA, 2013).

De acordo com Giongo et al. (2010) os sistemas LiDAR aerotransportado (*Airborne Laser Scanner - ALS*) são compostos por um sensor laser que essencialmente registra o tempo entre o sinal emitido e recebido de um determinado ponto, um Sistema Inercial de Navegação (INS – *Inertial Navigation System*) e um receptor GPS em uma plataforma aerotransportada. Em terra, é necessária uma rede de GPS que trabalhe de forma conjunta ao GPS instalado na plataforma (FIGURA 1).

FIGURA 1 - PRINCÍPIOS E COMPONENTES DE UM SISTEMA ALS.



FONTE: GIONGO ET AL. (2010).

De acordo com Giongo (2010) o princípio de funcionamento da tecnologia LiDAR consiste na emissão de um pulso *laser* de uma plataforma (aérea, terrestre ou orbital) com uma elevada frequência de repetição. O tempo de retorno dos pulsos *laser* entre a plataforma e os alvos é medido pelo sensor, permitindo a estimativa destas distâncias (BALTSAVIAS, 1999b; WAGNER et al., 2004) à distância ( $D$ ), e pode ser obtida pela equação (1) (BALTSAVIAS, 1999a).

$$D = c\left(\frac{t}{2}\right) \quad eq.1$$

Onde,

$c$  = velocidade da luz  $\approx 300.000$  km/s

$t$  = tempo de emissão e recepção de um pulso (ns)

O conjunto total de informações é armazenado e processado, e isso resulta em pontos com extrema exatidão (X, Y e Z), que correspondem a superfícies e objetos (vegetação, construções e outros) presentes no terreno (GIONGO et al., 2010). O potencial desta tecnologia está na alta precisão dos sensores, os quais permitem detectar a altitude do terreno e extrair as informações de altura da copa das árvores. Além disso, o levantamento poderá ser feito com agilidade em áreas extensas e de difícil acesso, conferindo grande vantagem ao método (NELSON et al., 1988).

Outra característica deste sistema é a relação direta entre o grau de detalhamento que se deseja da superfície e a densidade de pulsos emitidos, que é o número destes por unidade de área, sendo mais detalhados os modelos digital de elevação (MDE) quanto maior a densidade de pulsos (WEHR; LOHR, 1999; GIONGO et al., 2010). Da mesma forma, quanto maior a densidade, mais exato e preciso será o dimensionamento das árvores pois maiores serão as chances de os pulsos luminosos penetrarem pela copa das árvores e no sub-bosque para atingirem a superfície do terreno (JAKUBOWSKI et al., 2013; HANSEN et al., 2015).

Nos últimos anos, o uso da tecnologia de transmissão aérea para medir as características biofísicas da floresta tem aumentado rapidamente. Na TABELA 1 é apresentado algumas das aplicações já testadas.

TABELA 1 - APLICAÇÕES FLORESTAIS DE DADOS LIDAR.

<b>PARÂMETROS FLORESTAIS</b>	<b>FORMA DE OBTENÇÃO DE DADOS ALS</b>	<b>EXEMPLO DE APLICAÇÃO DE LITERATURA</b>
<b>ALTURA DO DOSSEL</b>	Medida direta	Næsset (1997)
<b>VOLUME DE COPA</b>	Medida direta	Coops et al. (2007)
<b>DIÂMETRO DE COPA</b>	Medida direta	Roberts et al. (2005)
<b>Nº DE INDIVÍDUOS</b>	Medida direta	Hirata et al. (2009)
<b>VOLUME</b>	Modelagem	Ioki et al. (2010)
<b>BIOMASSA</b>	Modelagem	Damilin e Medvedev (2004)
<b>CARBONO</b>	Modelagem	Balzter et al (2007)
<b>ÁREA BASAL</b>	Modelagem	Silva et al (2017)
<b>DIÂMETRO À ALTURA DO PEITO</b>	Modelagem	Ibanez et al (2016)
<b>COBERTURA DE COPA</b>	Fusão com outros sensores	Andersen et al (2005)
<b>IDENTIFICAÇÃO DE ESPÉCIES</b>	Fusão com outros sensores	Kim (2007)

FONTE: GIONGO ET AL. (2010)

Com aplicações recentes no Brasil, essa tecnologia vem substituindo os levantamentos topográficos tradicionais e as restituições por fotogrametria em algumas situações (RIBAS et al., 2015). Além do mais, na área florestal, a tecnologia LiDAR é de ampla aplicação para geração de modelos digitais de terreno (MDT), modelos digitais de superfície (MDS) e modelos digitais normalizados (MDSn). Com a utilização destes modelos é possível extrair declividade de terreno, informações de árvores isoladas, quantificação de biomassa e carbono, análise de extratos florestais, modelagem 3D de copas, dentre outros (PEREIRA, 2014).

### 3.6. APRENDIZADO DE MÁQUINA

A área de Aprendizado de Máquina (AM) é considerada um ramo da área de Inteligência Artificial (IA), sendo uma área especializada no estudo e construção de sistemas que sejam capazes de aprender de forma automatizada a partir de dados (BRINK et al, 2017). Uma das definições mais adequadas foi proposta por Tom Mitchell em seu livro “*Machine Learning*” (MITCHELL, 1997). O autor define como “A capacidade de melhorar

o desempenho na realização de alguma tarefa por meio da experiência” ou seja, os computadores são programados para aprender com a experiência passada, e empregando o princípio da inferência chamado indução, obtêm-se conclusões genéricas a partir de um conjunto particular de exemplos.

Em outras palavras o Aprendizado de Máquina (AM) é uma ramificação da IA, em que consiste no processo de indução de uma hipótese ou aproximação de função a partir da experiência passada (FACELI et al., 2011). Além do mais, AM tem uma grande sobreposição com estatística, uma vez que ambas as áreas estudam análises de dados. No entanto, diferente da estatística, que foca principalmente em modelos teóricos bem definidos e ajustamento de parâmetros a esses modelos, aprendizado de máquina tem um foco mais algorítmico, utilizando representações de modelos mais flexíveis e heurísticas para a realização de busca (PRATI, 2006).

Recentemente, técnicas de AM tem ganhado destaque na geração de modelos em diversas áreas do conhecimento científico como: agronomia, economia, engenharia, fisiologia, matemática, meteorologia, neurologia e outros (ZANETTI et al., 2008; ALVAREZ, 2009; KUMAR et al., 2015).

Segundo Russell e Norvig (2010), os tipos de aprendizagem podem ser classificados de acordo com o tipo de *feedback* que recebem do ambiente:

- Aprendizagem não-supervisionada: o agente aprende padrões na entrada, embora não seja fornecido nenhum *feedback* explícito. A tarefa mais comum de aprendizagem não-supervisionada é o agrupamento, ou seja, a detecção de grupos de exemplos de entrada potencialmente úteis.
- Aprendizagem por reforço: também conhecida como aprendizagem semi-supervisionada. O agente aprende a partir de uma série de reforços - recompensas ou punições.
- Aprendizagem supervisionada: o agente observa alguns exemplos de pares de entrada e saída, e aprende uma função que faz o mapeamento da entrada para a saída.


Os algoritmos de aprendizado de máquina geralmente são capazes de modelar assinaturas de classe complexa, podem aceitar uma variedade de dados de previsão de entrada e não fazem suposições sobre a distribuição de dados (ou seja, não-paramétricos) (MAXWELL et al., 2018). Desta forma, a seguir são apresentadas as variedades de algoritmos utilizados nesta pesquisa:

### 3.7. Support Vector Machine (SVM)

A Máquina de Vetores de Suporte (SVM - *Support Vector Machine*) é uma técnica de aprendizado de máquina que é baseada na discriminação de classes em um espaço de características de alta dimensão que é gerado através de transformações não-lineares dos preditores (VAPNIK, 1998). Nesse espaço de alta dimensão, um hiperplano de decisão é calculado para separar as classes de previsão (GOETZ et al., 2015), ou seja, a ideia básica consiste em transformar os dados de entrada em um recurso dimensional de maior espaço, onde o problema pode ser tratado de maneira linear (NEUMANN et al., 2012).

O bom desempenho em conjuntos de dados que possuem muitos atributos, mesmo quando há poucas amostras de treino é a principal vantagem do classificador SVM. Entretanto, suas desvantagens são a baixa velocidade e alto consumo de recursos durante as fases de treinamento, assim como a complexidade de parametrização de suas funções *kernel*. O SVM assume como base uma superfície de decisão que separa as classes, maximizando os limites de separação entre elas, sendo este conhecido como hiperplano ideal (FIGURA 2). Os pontos localizados próximos a essa superfície são definidos como vetores de suporte (*support vectors*), encontrados durante a fase de treinamento (BURGES, 1998).

FIGURA 2 - ESQUEMA DE CLASSIFICAÇÃO POR MEIO DO SVM, EM QUE OS PONTOS E QUADRADOS REPRESENTAM DUAS CLASSES NO ESPAÇO DE ATRIBUTOS.



FONTE: NASCIMENTO *ET AL.*, 2009 MODIFICADO DE HUANG *ET AL.* (2002) E MELGANI E BRUZZONE (2004).

Uma característica importante para uma boa Máquina de Vetores de Suporte é a capacidade de lidar com dados imperfeitos, também chamados de ruídos; e de minimizar os *outliers*, ou seja, exemplos isolados que destoam dos demais e que podem ocorrer devido a


presença de ruídos (LORENA, 2006). A máquina deve idealmente ser robusta aos ruídos e *outliers* presentes nos dados, não obtendo os classificadores sobre estes tipos de informações (CORTES; VAPNIK, 1995).

O SVM possui quatro funções, sendo elas (i) linear, (ii) quadrática, (iii) polinomial e (iv) função de base radial (FBR). Segundo Brown et al. (2000), Huang et al. (2002), Melgani e Bruzzone (2004) o FBR apresenta os melhores resultados na separação ótima de classes e todas as outras três funções são variações da FBR.

### 3.8. *k-Nearest Neighbors (k-NN)*

O algoritmo *k-NN* (*k-Nearest Neighbours*, ou *k-vizinhos mais próximos*) (COVER; HART, 1967) é um método de classificação baseado na proximidade de amostras de treino no espaço de características. É considerado um dos mais simples algoritmos de aprendizagem de máquina, sendo também conhecido como preguiçoso (*lazy*), no sentido que não há fase de aprendizagem com a construção de modelo e posterior generalização para todos os dados, mas sim a memorização dos dados de treinamento (FACELI et al., 2011; WITTEN et al., 2011). A ideia por trás do algoritmo *k-NN* é que se a amostra apresentada não é conhecida, a melhor coisa a fazer é analisar os exemplos similares a nova amostra para determinar a qual classe ela pertence (MARSLAND, 2008). De acordo com Mitchel (1997) *k-NN* é um classificador em que o aprendizado é baseado na analogia. O conjunto de treinamento é formado por vetores *n*-dimensionais e cada elemento deste conjunto representa um ponto no espaço *n*-dimensional (DUDA et al., 2001) (FIGURA 3).

FIGURA 3- CLASSIFICAÇÃO DE OBJETOS UTILIZANDO O KNN COM  $K = 3$ . CADA COR REPRESENTA UMA CLASSE E OS CÍRCULOS MARCADOS COM UM P REPRESENTAM OBJETOS DESCONHECIDOS A SEREM ROTULADOS.



FONTE: ADAPTADO DE SANTOS (2010).

De acordo com da Penha Neto (2012) existem três parâmetros principais que devem ser utilizados pelo algoritmo  $k$ -NN: Um conjunto de objetos já rotulados, ou seja, um grupo conhecido de objetos, uma métrica de similaridade para se obter a distância entre os objetos e o valor de  $k$ , que corresponde ao número de vizinhos próximos considerados para o cálculo da distância e classificação. Ainda, conforme o autor, o valor de  $k$  é um ponto importante a ser considerado. Se o valor de  $k$  for pequeno demais, o resultado do algoritmo pode ficar sensível a *outliers*. Todavia, se o valor de  $k$  for grande demais, então a vizinhança pode incluir muitos pontos pertencentes a classes distintas.

Uma diferença chave entre esta técnica e outros métodos é que nesta abordagem uma função de aproximação, para determinar a que classe o vetor de características pertence, é gerada para cada nova amostra apresentada ao algoritmo. Este comportamento proporciona uma vantagem significativa a esta técnica quando a função discriminante é muito complexa, mas pode ser descrita por um conjunto de funções de aproximação de complexidade reduzida. No entanto, o aprendizado baseado em instâncias pode ter um custo computacional elevado para classificar novas amostras. Isto ocorre devido ao fato de que todos os cálculos ocorrem no momento da classificação e não quando os exemplos de treinamento são armazenados. Outra desvantagem deste tipo de abordagem é o fato de que todos os exemplos armazenados na memória são utilizados nos cálculos de aproximação para cada nova amostra, quando somente os mais próximos seriam o bastante para realizar a classificação (MITCHELL, 1997).

### 3.9. *Artificial Neural Network* (Redes Neurais Artificiais – RNA)

A aprendizagem por Redes Neurais Artificiais (RNA) é um dos principais métodos de aprendizagem de máquina (HAYKIN, 2008). Os primeiros trabalhos desenvolvidos na área datam de 1943, quando o neurofisiologista, filósofo e poeta americano Warren McCulloch, e o lógico Walter Pitts desenvolveram o primeiro modelo matemático de um Neurônio, e mostraram que a combinação de vários neurônios aumenta o poder de processamento do conjunto como um todo, mas estas redes iniciais não tinham capacidade de aprendizado (BITTENCOURT, 2001)

RNAs são modelos computacionais inspirados no sistema nervoso humano, os quais adquirem conhecimento através de um processo de aprendizagem, e se assemelha ao cérebro em dois aspectos: o conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem e as forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido (HAYKIN, 2001).

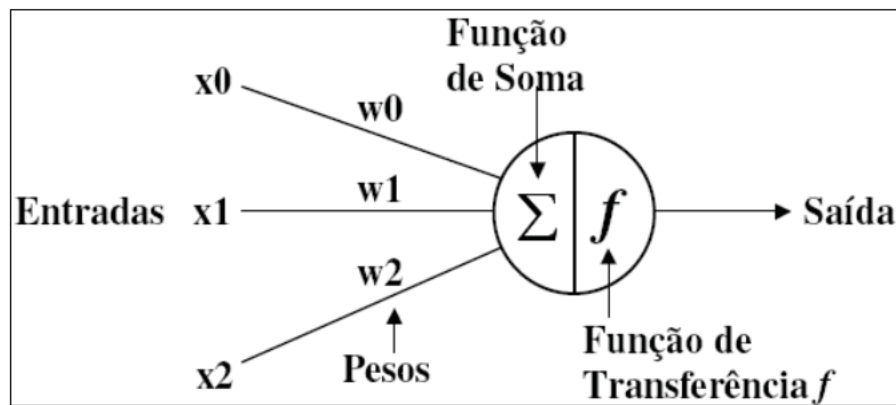
As redes neurais artificiais usam um grande número de neurônios artificiais interconectados, alguns desses neurônios recebem excitações do exterior e são chamados neurônios de entrada. Outros têm suas respostas usadas para alterar, de alguma forma, o mundo exterior, sendo chamados neurônios de saída. Há ainda os neurônios que não são nem entrada nem de saída, os quais são conhecidos como neurônios internos. Estes neurônios internos à rede têm grande importância, conhecidos na literatura como “*hidden*”, fazendo com que alguns traduzam como “escondidos” (BARRETO, 2002).

Um neurônio artificial compreende a unidade básica de processamento de uma RNA, a qual apresenta duas facetas elementares: a arquitetura e o algoritmo de aprendizagem. Essa divisão surge naturalmente pelo paradigma de como a rede é treinada. Os dados de entrada denominados de neurônios de entrada, são captados de outro neurônio ou do ambiente, em seguida são processados e assim geram um resultado (HAYKIN, 2001). Em outras palavras, o elemento mais básico de uma rede neural é um neurônio, uma unidade de processamento completa que atua em paralelo com outros neurônios na rede (FERREIRA et al., 2011). Sua principal desvantagem é que o modelo construído funciona como uma caixa preta, ou seja, é muito difícil compreender/interpretar o modelo (OLIVEIRA, 2016).

De acordo com Ferreira et al. (2011) os três elementos básicos são descritos a seguir, e ilustrados na FIGURA 4:

1. Um conjunto de conexões de entrada, cada uma delas possuindo um peso associado, dessa forma, cada entrada  $x$  que está ligada a um dado neurônio deve ser multiplicada pelo seu respectivo peso  $w$ ;
2. Um somador, para realizar a soma da multiplicação dos sinais de entrada pelos seus respectivos pesos, considerando todas as conexões que chegam ao neurônio;
3. Uma função de ativação para gerar uma saída, a qual é enviada ao próximo nó do sistema. O objetivo da função de ativação é limitar a amplitude da saída do neurônio. Algumas funções de ativação mais utilizadas estão as funções sigmóide, linear, passo e a logística.

FIGURA 4 - EXEMPLO DE UM MODELO DE UM NEURÔNIO.



FONTE: FERREIRA *et al.* (2011).

### 3.10. *Random Forest (RF)*

Floresta Aleatória (RF, do inglês - *Random Forest*) é uma técnica de aprendizado desenvolvida por Breiman (2001) baseada na combinação de um grande conjunto de árvores de decisão. RF tem sido considerado como um dos métodos de previsão mais precisos para classificação e regressão, pois pode modelar interações complexas entre variáveis de entrada e é relativamente robusto em relação à *outliers* (WANG *et al.*, 2016). É uma técnica estatística não-paramétrica que é capaz de sintetizar funções de regressão ou classificação baseadas em conjuntos de dados discretos ou contínuos (MUTANGA *et al.*, 2012; HUDAK *et al.*, 2012).

Outros autores também definem RF como modelos do tipo *ensemble methods*, que combinam a predição de um conjunto de árvores de decisão, para obter uma única resposta

como saída, que tende a apresentar melhor desempenho que as obtidas com cada árvore do modelo em separado, devido à redução de variância (ALVARENGA JÚNIOR, 2018).

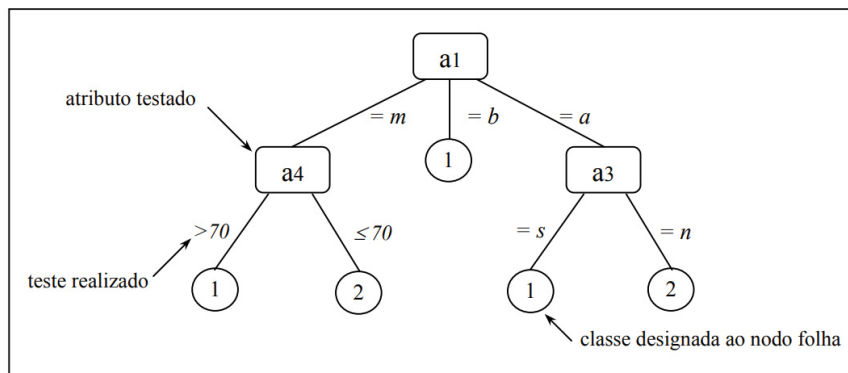
De acordo com Sá Lucas (2011), esta técnica consiste essencialmente em três partes:

- *Bagging*: gerar, através de reamostragem, um conjunto de sub-amostras provenientes da amostra original, selecionadas de maneira aleatória simples com reposição;
- *Boosting*: construir, para cada subamostra, um modelo de árvore de decisão, aumentando a ponderação das observações incorretamente classificadas com base nos modelos criados para as outras subamostras; e
- *Randomizing*: desenvolver os modelos de árvore de decisão utilizando, em cada nó, um conjunto de variáveis selecionadas aleatoriamente, diferente para cada nó.

O RF começa com muitas amostras de *bootstrap* que são sorteadas aleatoriamente com a substituição do conjunto de dados de treinamento original, então uma árvore de regressão é ajustada a cada uma das amostras de *bootstrap*. Para cada nó por árvore, um pequeno conjunto de variáveis de entradas selecionadas do conjunto total é considerado aleatoriamente para o particionamento binário (WANG et al., 2016). A utilização de várias árvores de decisão é utilizada para estabilizar as previsões do modelo (BREIMAN, 2001), essas árvores são montadas em reamostras das observações selecionadas aleatoriamente com substituição (reamostragem de *bootstrap*). Cada decisão da árvore é, além disso, baseada em preditores selecionados aleatoriamente (GOETZ et al., 2015).

De acordo com Fonseca (1994), a teoria de funcionamento de qualquer algoritmo baseado em árvores de decisão é bastante simples, e embora algoritmos baseados em árvores de decisão possam apresentar diferenças na forma de agir em um determinado passo, todos se baseiam na estratégia de dividir para conquistar. De modo geral, a filosofia baseia-se na sucessiva divisão do problema em vários subproblemas de menores dimensões, até que uma solução para cada um dos problemas mais simples possa ser encontrada. Deste modo, os classificadores baseados em árvores de decisão procuram encontrar formas de dividir sucessivamente o universo em vários subconjuntos, até que cada um deles contemple apenas uma classe ou até que uma das classes demonstre uma clara maioria não justificando posteriores divisões. Assim, a classificação consiste apenas em seguir o caminho ditado pelos sucessivos testes colocados ao longo da árvore até que seja encontrada uma folha que conterà a classe a atribuir ao novo exemplo. A FIGURA 5 mostra um exemplo de uma árvore de decisão.

FIGURA 5 - EXEMPLO DE UM CLASSIFICADOR BASEADO EM UMA ÁRVORE DE DECISÃO NO QUAL SÃO TESTADOS ATRIBUTOS CATEGÓRICOS E QUANTITATIVOS.



FONTE: GARCIA (2003).

De acordo com Ferreira et al. (2001), o uso de RF pode ser utilizado como alternativa a regressão linear, principalmente quando ocorrem relações complexas e não lineares entre as variáveis (STROBL et al., 2009). Além do mais, estudos tem demonstrado que a abordagem de RF tem produzido geralmente melhores resultados de predição em comparação com uma variedade de outros métodos (ESKELSON et al., 2009; HUDAK et al., 2008). Guo et al. (2011) ainda mencionam algumas vantagens desse classificador, tais como uma rápida execução, o fato de não sofrer com *overfitting* e também de ser geralmente eficiente, mesmo com grandes bases de dados, como, por exemplo, dados de LIDAR. Ele não requer suposições sobre a distribuição dos dados, o que é interessante quando se utilizam características de diferentes tipos ou escalas.

#### 4. REFERÊNCIAS BIBLIOGRÁFICAS

ALVARENGA JÚNIOR, W. J. **Métodos de otimização hiperparamétrica: um estudo comparativo utilizando árvores de decisão e florestas aleatórias na classificação binária.** 60 f. Dissertação (Mestrado em Engenharia Elétrica) - Pós-Graduação em Engenharia Elétrica da Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte.2018

ALVAREZ, R. Predicting average regional yield and production of wheat in the Argentine Pampas by an artificial neural network approach. **European Journal of Agronomy**, v. 30, n. 2, p. 70-77, 2009.

ANDERSEN, H; REUTEBUCH, S. E.; MCGAUGHEY, R J. A rigorous assessment of tree height measurements obtained using airborne lidar and conventional field methods. **Canadian Journal of Remote Sensing**, v. 32, n. 5, p. 355-366, 2006.

ARAGAO, L. EOC et al. Environmental change and the carbon balance of Amazonian forests. **Biological Reviews**, v. 89, n. 4, p. 913-931, 2014.

BAGNATO, V. S. **Os fundamentos da luz LASER. Física na Escola**, São Carlos, v. 2, n. 2, p. 4-9, 2001.

BAIS, C, R. **Tamanho de parcelas para quantificação de biomassa e carbono em uma floresta ombrófila densa na Mata Atlântica.** 74 f. Dissertação (Mestrado em Recursos Florestais). Universidade de São Paulo, Piracicaba 2008

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

BALTSAVIAS, E. P. A comparison between photogrammetry and laser scanning. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 54, n. 2-3, p. 83-94. 1999b

BARRETO, J. M. Introdução as redes neurais artificiais. **V Escola Regional de Informática. Sociedade Brasileira de Computação, Regional Sul, Santa Maria, Florianópolis, Maringá**, p. 5-10, 2002.

BEHLING, A. **Modelagem da biomassa de árvores para assegurar aditividade dos seus componentes.** 117 f. Tese (Doutorado em Engenharia Florestal) – Setor de Ciências Florestais – Universidade Federal do Paraná, Curitiba, 2016.

BETTS, R. A. Forcings and feedbacks by land ecosystem changes on climate change. In: **Journal de Physique IV (Proceedings)**. EDP sciences, 2006. p. 119-142.

BITTENCOURT, G. **Inteligência Artificial Ferramentas e Teorias.** 2a. edição Campus Universitário, Trindade-Florianópolis, Editora da UFSC, 2001. 362p.

BORGES, J. B. **Avaliação de Ciclo de Vida (ACV) comparativa da exploração autorizada e da exploração não autorizada em Floresta Amazônica.** 2016. xi, 48 f., il.

Monografia (Bacharelado em Engenharia Florestal)—Universidade de Brasília, Brasília, 2016.

BRANDALIZE, M. C. B.; PHILIPS, J. W. Padrões de classificação de equipamentos laser utilizados em levantamentos terrestres e aéreos. **Geodésia Online-Revista da Comissão Brasileira de Geodésia**, Florianópolis, v. 1, p. 1, 2002.

BREIMAN, L. Random forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001.

BRINK, H; RICHARDS, J. W.; FETHEROLF, M. Real-world machine learning. **Manning**, 400p. 2017.

BROWN, M; LEWIS, H G.; GUNN, S. R. Linear spectral mixture models and support vector machines for remote sensing. **IEEE Transactions on geoscience and remote sensing**, v. 38, n. 5, p. 2346-2360, 2000.

BURGES, C. JC. A tutorial on support vector machines for pattern recognition. **Data mining and knowledge discovery**, v. 2, n. 2, p. 121-167, 1998.

CARROLL, J. M. **Fundamentos y aplicaciones del láser** Johna Millar Carroll, traducción de Luis Ibáñez Morlán y Mariano Velasco Duránte. Marcombo, 154 p. 1978.

CORTES, C; VAPNIK, V. Support-vector networks. **Machine learning**, v. 20, n. 3, p. 273-297, 1995.

COVER, T; HART, P. Nearest neighbor pattern classification. **IEEE transactions on information theory**, v. 13, n. 1, p. 21-27, 1967.

DA PENHA NETO, G. **Uso de algoritmos de mineracao de dados para agrupamento e busca de erros em séries temporais coletadas a partir de geossensores: um estudo de caso na mata atlântica**. Dissertação (Mestrado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 49 p. 2012.

DUDA, R.; HART, P.; STORK, D. **Pattern classification and scene analysis**. 2. ed. New York: John Wiley & Sons, 654p. 2001.

ESKELSON, B NI; BARRETT, T M.; TEMESGEN, H. Imputing mean annual change to estimate current forest attributes. **Silva Fennica**. 43 (4): 649-658, v. 43, n. 4, p. 649-658, 2009.

FACELI, K et al. Inteligência artificial: uma abordagem de aprendizado de máquina. **Rio de Janeiro: LTC.**, 378p. 2011.

FAO – **Food and Agriculture Organization of the United Nations**. 2014. FRA2015 Brazil, Country Report. Rome: FAO. Disponível em: <http://www.fao.org/3/aaz172e.pdf>

FAO - **Food and Agriculture Organization of the United Nations**. Global Forest Resources Assessment 2015: How have the world’s forests changed? Rome 2015

FEARNSIDE, P. M. Emissions from tropical hydropower and the IPCC. **Environmental Science & Policy**, v. 50, p. 225-239, 2015.

FEARNSIDE, P. M. Hydroelectric dams in the Brazilian Amazon as sources of 'greenhouse' gases. **Environmental conservation**, v. 22, n. 1, p. 7-19, 1995.

FERREIRA, C. A.; SOARES, J. F.; CRUZ, F. RB. Reconhecimento de padrões em Estatística: Uma abordagem Comparativa. In: **V Congresso Brasileiro de Redes Neurais**. p. 409-414, 2001.

FERREIRA, L. et al. Utilização de redes neurais artificiais como estratégia de previsão de preços no contexto de agronegócio. **RAI Revista de Administração e Inovação**, v. 8, n. 4, p. 6-26, 2011.

FERREIRA, L. G; FERREIRA, N. C; FERREIRA, M E. Sensoriamento remoto da vegetação: evolução e estado-da-arte. **Acta Scientiarum Biological Sciences**, v. 30, n. 4, p. 379-390, 2008.

FLORENZANO, T. G. **Iniciação em sensoriamento remoto**. Oficina de Textos, p. 123. 2007.

GARCIA, S. C. **O uso de árvores de decisão na descoberta de conhecimento na área da saúde**. 87 f. 2003. Dissertação de Mestrado em Ciências da Computação. Universidade Federal do Rio Grande do Sul, Porto Alegre. 2003.

GIONGO, M. et al. LiDAR: princípios e aplicações florestais. **Pesquisa Florestal Brasileira**, v. 30, n. 63, p. 231, 2010.

GOETZ, J. N. et al. Evaluating machine learning and statistical prediction techniques for landslide susceptibility modeling. **Computers & geosciences**, v. 81, p. 1-11, 2015.

GONÇALES, R.. **Dispositivo de varredura LASER 3D terrestre e suas aplicações na Engenharia, com ênfase em túneis**. 2007. 103 f. Dissertação (Mestrado em Engenharia) – Departamento de Engenharia de Transportes, Universidade de São Paulo, São Paulo, 2007

GUO, L. et al. Relevance of airborne lidar and multispectral image data for urban scene classification using Random Forests. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 1, p. 56-66, 2011.

HANSEN, E H; GOBAKKEN, T; NÆSSET, E. Effects of pulse density on digital terrain models and canopy metrics using airborne laser scanning in a tropical rainforest. **Remote Sensing**, v. 7, n. 7, p. 8453-8468, 2015.

HAYKIN, S. **Neural Networks and Learning Machines**, 3a edição. 906p. 2008.

HAYKIN, S. **Redes neurais: princípios e prática**. 2.ed. Porto Alegre: Bookman, 2001. 900p

HE, Q. et al. Above-ground biomass and biomass components estimation using LiDAR data in a coniferous forest. **Forests**, v. 4, n. 4, p. 984-1002, 2013.

HERNÁNDEZ, L. et al. Towards complete and harmonized assessment of soil carbon stocks and balance in forests: The ability of the Yasso07 model across a wide gradient of climatic and forest conditions in Europe. **Science of The Total Environment**, v. 599, p. 1171-1180, 2017.

HIGA, R. C. V. et al. Protocolo de medição e estimativa de biomassa e carbono florestal. **Colombo: Embrapa Florestas**, p. 72, 2014.

HIGUCHI, N; SANTOS, J dos; JARDIM, F. Tamanho de parcela amostral para inventários florestais. **Acta amazônica**, v. 12, n. 1, p. 91-103, 1982.

HOUGHTON, R. A.; HALL, F; GOETZ, S. J. Importance of biomass in the global carbon cycle. **Journal of Geophysical Research: Biogeosciences**, v. 114, n. G2, 2009.

HUANG, C; DAVIS, L. S.; TOWNSHEND, J. R. G. An assessment of support vector machines for land cover classification. **International Journal of remote sensing**, v. 23, n. 4, p. 725-749, 2002.

HUDAK, A. T. et al. Nearest neighbor imputation of species-level, plot-scale forest structure attributes from LiDAR data. **Remote Sensing of Environment**, v. 112, n. 5, p. 2232-2245, 2008.

HUDAK, A. T. et al. Quantifying aboveground forest carbon pools and fluxes from repeat LiDAR surveys. **Remote Sensing of Environment**, v. 123, p. 25-40, 2012.

IBGE – Instituto Brasileiro de Geografia e Estatística. Manual Técnico da Vegetação Brasileira. **Série Manuais Técnicos em Geociências 1**, 2º edição revista e ampliada. IBGE, Rio de Janeiro. 2012. 271p.

IBANEZ, C. A. G. et al. Estimating dbh of trees employing multiple linear regression of the best lidar-derived parameter combination automated in python in a natural broadleaf forest in the philippines. **International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences**, v. 41, pp.657-662. 2016.

INPE - Instituto Nacional de Pesquisas Espaciais. **SPRING: Tutorial de Geoprocessamento**. 2006. Disponível em: [http://www.dpi.inpe.br/spring/portugues/tutorial/introducao\\_sen.html](http://www.dpi.inpe.br/spring/portugues/tutorial/introducao_sen.html).

INPE - Instituto Nacional de Pesquisas Espaciais. Coordenação Geral de Observação da Terra - OBT. Projeto PRODES: monitoramento da floresta amazônica brasileira por satélite, 2018. Disponível em: <<http://www.obt.inpe.br/prodes/>>. Acesso em: 18 jun. 2018.

INSTITUTO FLORESTA TROPICAL - IFT. **Manejo florestal e exploração de impacto reduzido em florestas naturais de produção da Amazônia**. Informativo Técnico do IFT 1. Belém: IFT, 2012. Disponível em <[www.ift.org.br](http://www.ift.org.br)>.

Intergovernmental Panel on Climate Change. IPCC 2006 **IPCC Guidelines for National Greenhouse Gas Inventories**. In *National Greenhouse Gas Inventories Programme*; IGES: Tsukuba, Japan, 2006; p. 673

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.

KUMAR, R; AGGARWAL, R. K.; SHARMA, J. D. Comparison of regression and artificial neural network models for estimation of global solar radiations. **Renewable and Sustainable Energy Reviews**, v. 52, p. 1294-1299, 2015.

LEE, T. M; JETZ, W. Future battlegrounds for conservation under global change. **Proceedings of the Royal Society of London B: Biological Sciences**, v. 275, n. 1640, p. 1261-1270, 2008.

LIN, Y. et al. From TLS to VLS: Biomass estimation at individual tree level. **Remote Sensing**, v. 2, n. 8, p. 1864-1879, 2010.

LIU, W.T.H. **Aplicações de Sensoriamento Remoto**. Campo Grande: Editora UNIDERP, 2007. 908p.

LONGLEY, P. A. et al. **Sistemas e ciência da informação geográfica**. Bookman Editora, 2009.

LORENA, A.C. **Investigação de estratégias para a geração de máquinas de vetores de suporte multiclasses**. 2006. 203 f. Tese (Doutorado em Ciências da Computação e Matemática Computacional). Universidade de São Paulo, São Carlos. 2006

MALHI, Y. et al. Climate change, deforestation, and the fate of the Amazon. **Science**, v. 319, n. 5860, p. 169-172, 2008.

MARENGO, J. A.; NOBRE, C. **Clima da região Amazônica. Tempo e Clima no Brasil**, editado por: Fonseca de Albuquerque Cavalcanti, I., Ferreira, N., Justi da Silva, M., Faus da Silva Dias, M., Oficina de Textos, p. 179-212, 2009.

MARSLAND, S; **Machine Learning: An Algorithmic Perspective**. 1. ed. Chapman & Hall/CRC Press, 457p. 2008

MARTINELLI, L. A. et al. Incertezas associadas às estimativas de biomassa em florestas tropicais: o exemplo de uma floresta situada no estado de Rondônia. In: **Anais do Seminário**

**de Emissão x Sequestro de CO<sub>2</sub>: uma nova oportunidade de negócios para o Brasil**; Rio de Janeiro. Rio de Janeiro: CVRD; p. 221, 1994.

MARTINS NETO, R. P. **Extração de variáveis dendrométricas em árvores de *Pinus Taeda* l. A partir de dados TLS e ALS**. 2016 187 f. Dissertação (Mestrado em Engenharia Florestal) Centro de Ciências Agroveterinárias, da Universidade do Estado de Santa Catarina, Universidade do Estado de Santa Catarina, Lajes. 2016.

MAXWELL, A E.; WARNER, T A.; FANG, F. Implementation of machine-learning classification in remote sensing: An applied review. **International journal of remote sensing**, v. 39, n. 9, p. 2784-2817, 2018.

MELGANI, F; BRUZZONE, L. Classification of hyperspectral remote sensing images with support vector machines. **IEEE Transactions on geoscience and remote sensing**, v. 42, n. 8, p. 1778-1790, 2004.

MENESES, P. R. et al. **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília: UnB, p. 01-33, 2012.

MITCHELL, T, M. **Machine Learning**. 1.ed. McGraw-Hill. 414p. 1997.

MOURA-COSTA, P. Tropical forestry practices for carbon sequestration. **Dipterocarp Forest Ecosystems: Towards Sustainable Management, World Scientific: Singapore**, p. 308-334, 1996.

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

NELSON, R; KRABILL, W; TONELLI, J. Estimating forest biomass and volume using airborne laser data. **Remote sensing of environment**, v. 24, n. 2, p. 247-267, 1988.

NEUMANN, M et al. Assessing performance of L-and P-band polarimetric interferometric SAR data in estimating boreal forest above-ground biomass. **IEEE Transactions on Geoscience and Remote Sensing**, v. 50, n. 3, p. 714-726, 2012.

NOAA, CSC. **Lidar 101: an introduction to lidar technology, data, and applications**. NOAA Coastal Services Center, 72 p. 2012.

NOVO, E.M.L.M. **Sensoriamento Remoto: Princípios e Aplicações**. Editora Edgard Blucher Ltda.388 p. ISBN: 978-85-2120-540-1. 2010

OLIVEIRA, A. N de; AMARAL, L. L. do. Florística e fitossociologia de uma floresta de vertente na Amazônia Central, Amazonas, Brasil. **Acta Amazonica**, 2004.

OLIVERA, A. R. **Comparação de algoritmos de aprendizagem de máquina para construção de modelos preditivos de diabetes não diagnosticado**. 2016. 88 f. Dissertação (Mestrado em Ciência da Computação) - Programa de Pós-Graduação em Computação. Porto Alegre, BR – RS, 2016.

PÉLLICO NETTO, S.; BRENA, D. **Inventário florestal**. Curitiba: Universidade Federal do Paraná,. 316 p. 1997

PEREIRA, J. P. **Mensuração automática de copas de Araucaria angustifolia (Bertol.) Kuntze a partir de dados LiDAR para estimativa de variáveis dendrométricas**. 140 f. Dissertação (Mestrado) - Programa de PósGraduação em Engenharia Florestal, CAV - UDESC. Lages, 2014.

PINHEIRO RIBAS, R et al. Proposição metodológica de extração da altimetria em edificações utilizando dados LIDAR com vista a estudos volumétricos de coeficientes de aproveitamento. **UD y la GEOMÁTICA**, v. 10, n. 1, 2015.

POPESCU, S. C. et al. 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.

PRATI, R. C. **Novas abordagens em aprendizado de máquina para a geração de regras, classes desbalanceadas e ordenação de casos**. 155 f. 2006. Tese (Doutorado em Ciências da Computação e Matemática Computacional) - Instituto de Ciências Matemáticas e de Computação. Universidade de São Paulo, São Carlos. 2006.

ROSA, R. Geotecnologias na geografia aplicada. **Revista do Departamento de Geografia**, v. 16, p. 81-90, 2011.

ROTH, P. et al. Manual do Técnico Florestal. **Rio Branco: Design gráfico Guilherme K. Noronha**. 2009. 260p.

RUSSELL, S; NORVIG, P; INTELLIGENCE, Artificial. A modern approach. **Artificial Intelligence. Prentice-Hall, Egnlewood Cliffs**, v. 25, n. 27, p. 79-80, 1995.

SÁ LUCAS, L. Árvore, florestas e sua função como preditores: uma aplicação na avaliação do grau de maturidade de empresas. **PMKT – Revista Brasileira de Pesquisas de Marketing, Opinião e Mídia**, Número 6, p. 6-11, 2011.

SANQUETTA, C. R. et al. Inventários florestais: planejamento e execução. **Curitiba: Multi-Graphic**, v. 2, 2009. 316p.

SANQUETTA, C. R; BALBINOT, R. Métodos de determinação de biomassa florestal. **As florestas e o carbono**. Curitiba, p. 119-140, 2002.

SANTOS, R. **Princípios e Aplicações de Mineração de Dados**. São José dos Campos: INPE, 2010. Disponível em: <<http://www.lac.inpe.br/~rafael.santos/cap359.jsp>>. Acesso em: 10 Julho 2018.

SCHOENINGER, Emerson Roberto et al. Uso de redes neurais artificiais como uma alternativa para mapeamento de biomassa e carbono orgânico no componente arbóreo de florestas naturais. **Ambiência**, v. 4, n. 3, p. 529-549, 2008.

SCOLFORO, J.R.S.; MELLO, J.M. Inventário florestal. **Lavras: UFLA/FAEPE**, 561p. 2006

SILVA JUNIOR, C. H. L. **Dinâmica da formação de bordas florestais e seu impacto nos estoques de carbono na Bacia Amazônica utilizando sensoriamento remoto.** 2018 183 f. Dissertação (Mestrado em Sensoriamento Remoto ) Instituto Nacional de Pesquisas Espaciais – INPE, São José dos Campos - SP – Brasil. 2018

SILVA, C. A. **Carbono na parte aérea de plantios de Eucalyptus spp.-em nível de árvore por amostragem destrutiva e para talhões inteiros após o ajuste de métricas LiDAR.** 152 f. 2013. Dissertação (Mestrado em Ciências) Departamento de Recursos Florestais, Universidade de São Paulo, Piracicaba. 2013

SILVA, C. A. et al. Modeling and mapping basal area of Pinus taeda L. plantation using airborne LiDAR data. **Anais da Academia Brasileira de Ciências**, v. 89, n. 3, p. 1895-1905, 2017.

SILVA, H.F., et al. Estimativa do estoque de carbono por métodos indiretos em área de restauração florestal em Minas Gerais. **Scientia Forestalis**, Piracicaba, v. 43, n. 108, p. 943-953, dez..2015

SILVEIRA, P. Estimativa da biomassa e carbono acima do solo em um fragmento de floresta ombrófila densa utilizando o método da derivação do volume comercial. **Floresta**, v. 40, n. 4, 2010.

SOARES, C. P. B; DE PAULA NETO, F; DE SOUZA, A. L. Dendrometria e inventário florestal. **UFV**, 276p. 2006.

SRINIVASAN, S. et al. Multi-temporal terrestrial laser scanning for modeling tree biomass change. **Forest Ecology and Management**, v. 318, p. 304-317, 2014.

VAPNIK, V. **Statistical learning theory.** 1998. Wiley, New York, 1998.

VERÍSSIMO, A. et al. **Áreas Protegidas Na Amazônia Brasileira: Avanços E Desafios**© IMAZON/ISA, 88p. 2011.

VERÍSSIMO, A; PEREIRA, D. Produção na Amazônia Florestal: características, desafios e oportunidades. **Parcerias Estratégicas**, v. 19, n. 38, p. 13-44, 2015.

WAGNER, W. et al. **From single-pulse to full-waveform airborne laser scanners: potential and practical challenges.** na, 2004.

WANG, L et al. Estimation of biomass in wheat using random forest regression algorithm and remote sensing data. **The Crop Journal**, v. 4, n. 3, p. 212-219, 2016.

WEHR, A; LOHR, U. Airborne laser scanning—an introduction and overview. **ISPRS Journal of photogrammetry and remote sensing**, v. 54, n. 2-3, p. 68-82, 1999.

WEVER, C; LINDENBERGER, J. Experiences of 10 years laser scanning. In: **Photogrammetric Week 99.** 1999.

WITTEN, I. H. et al. **Data Mining: Practical machine learning tools and techniques**. Morgan Kaufmann, 2016.

ZANETTI, S. S. et al. Estimação da evapotranspiração de referência no Estado do Rio de Janeiro usando redes neurais artificiais. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 12, n. 2, p. 174-180, 2008.

ZHAO, M; RUNNING, S. W. Drought-induced reduction in global terrestrial net primary production from 2000 through 2009. **science**, v. 329, n. 5994, p. 940-943, 2010.

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

## 5. CAPÍTULO III: MUDANÇA NO ESTOQUE DE BIOMASSA ACIMA DO SOLO EM FLORESTA TROPICAL VIA DADOS LIDAR

### RESUMO

Florestas tropicais armazenam grande parte do estoque global de carbono na forma de biomassa, variável esta que é de fundamental importância frente às principais discussões de mudanças climáticas globais. Todavia, por parte do desmatamento e degradação ocorrida de forma descontrolada nos últimos anos houve um comprometimento considerável de CO<sub>2</sub> para atmosfera, agravando os efeitos do aquecimento global. Nesse sentido, o objetivo deste estudo foi avaliar a mudança dos estoques de biomassa acima do solo (AGB) em uma floresta tropical, utilizando dados LiDAR (*Light Detection and Ranging*), em um período de dois anos (2011-2013). Técnicas automáticas de detecção de copas foram utilizadas de forma complementar para observar se mudanças estruturais poderiam influir na dinâmica da AGB. Este estudo foi conduzido na Floresta Nacional (FLONA) do Jamari, localizada em Rondônia – Brasil. Foram utilizados dados de sobrevoos de LiDAR e dados de inventário de campo. A metodologia foi constituída em: organização dos dados, obtenção dos relatórios descritivos das nuvens, filtragem de pontos e geração dos modelos digitais. Também foi realizada a normalização das alturas e geração do modelo de altura de copa (CHM), para segmentação das copas. Em seguida foram realizados os recortes das parcelas e obtenção das relações entre as estimativas LiDAR *versus* Inventário de Campo. Foi utilizada uma abordagem orientada a objeto, sendo testado uma série de valores para a segmentação das copas. Após este procedimento, realizou-se as estimativas de AGB para toda amostra de LiDAR. Foram geradas estimativas de AGB via LiDAR para as parcelas do inventário florestal e para a amostra da área de estudo. Fortes correlações foram observadas entre as estimativas de AGB ( $r > 0,88$ ). Apesar das mudanças negativas de AGB ocorridas, não houve diferença significativa no período avaliado nos estoques de AGB ( $p > 0,05$ ; teste Tukey). Os resultados deste capítulo confirmam que o LiDAR é uma tecnologia que pode ser utilizado com segurança para a estimativa do estoque e da dinâmica de AGB em florestas tropicais, permitindo desta forma que diferentes análises sejam desenvolvidas. Além do mais, o LiDAR é uma ferramenta estratégica, a partir de seus sub-produtos (modelos digitais) e com técnicas de sensoriamento remoto, foi possível obter com facilidade informações dendrométricas, que comumente são de difícil obtenção em campo. A partir de dois levantamentos de LiDAR (2011-2013) foram mensuradas de forma automática 40 copas para cada ano no estrato superior da floresta, e com estas, observou-se que houveram acréscimos estruturais positivos que não influenciaram nas estimativas dos estoques de AGB.

Palavras-Chaves: Amazônia; inventário, laser, detecção, estoque de AGB.

### CHAPTER III: CHANGING IN ABOVEGROUND BIOMASS STOCK IN THE RAINFOREST VIA LIDAR DATA

#### ABSTRACT

Tropical forests store much of the global carbon stock in the form of biomass, a variable that is of fundamental importance in the face of the main discussions of global climate change. However, due to the deforestation and degradation that occurred in an uncontrolled way in recent years, there has been a considerable commitment of CO<sub>2</sub> to the atmosphere, aggravating the global warming effects. The objective of this study was to evaluate the change of aboveground biomass (AGB) stocks in a tropical forest using LiDAR (Light Detection and Ranging) data over a period of two years (2011-2013). Automatic crown detection techniques were used in a complementary way to observe whether structural changes may influence the AGB dynamics. This study was conducted in Jamari National Forest in Rondonia State - Brazil. LiDAR overfly data and field inventory data were used. The methodology was constituted in: organization of the data, obtaining the descriptive reports of the clouds, filtering of points and generation of the digital models. It was also performed the heights normalization and generation of the crown height model (CHM) for crown segmentation. Then, the plots were cut out and the relationships between the LiDAR estimates versus Field Inventory were obtained. An object-oriented approach was used, and a series of values were tested for the segmentation of the canopies. After this procedure, AGB estimates were performed for the entire LiDAR sample. Estimates of AGB were generated via LiDAR for the forest inventory plots and for the sample of the study area. Strong correlations were observed between estimates of AGB ( $r > 0,88$ ). Despite the negative changes in AGB occurred, there was no significant difference in the period evaluated ( $p > 0.05$ ; t test). The results of this chapter confirm that LiDAR is a technology that can be used safely for the estimation of the stock and the dynamics of AGB in tropical forests, thus allowing different analyzes to be developed. In addition, LiDAR is a strategic tool, based on its by-products (digital models) and remote sensing techniques, it was possible to easily obtain information of great importance of the forest, which are commonly difficult to obtain in the field. From two LiDAR surveys (2011-2013), 40 cups were automatically measured for each year in the upper stratum of the forest, and with these, it was observed that there were positive structural increases that did not influence the estimates of AGB stocks

Keywords: Amazon; detections, disturbances, inventory, laser.

## 5.1. INTRODUÇÃO

Nos últimos anos, a detecção remota da AGB da floresta vem recebendo atenção crescente devido à sua relevância para a modelagem do ciclo do carbono global e para programas internacionais destinados a reduzir as emissões de gases de efeito estufa (GEE) em áreas tropicais, como o programa de colaboração das Nações Unidas para a Redução das Emissões pelo Desmatamento e Degradação Florestal (REDD+) (LAURIN et al., 2014).

Considerada a maior floresta tropical do mundo, a Floresta Amazônica ocupa 5,4 milhões de km<sup>2</sup> e apresenta papel fundamental na ciclagem da água, armazenamento de carbono e na regulação do clima local e regional (CLEMENT; HIGUCHI, 2006; NOBRE et al., 2007). Contudo, devido ao aumento das taxas de mortalidade referente à elevação da temperatura e secas severas (principalmente causadas pelo *El Niño*) as florestas podem atuar como fonte de emissão de carbono (CLARK, 2004). De forma particular, florestas tropicais são sensíveis aos distúrbios antropogênicos, como o desmatamento ou a exploração madeireira, que causa degradação florestal em larga escala (VAN DER WERF et al., 2009), sendo esta, outra forma de atuar como fonte de carbono, emitindo GEE em proporções significantes para a atmosfera (FEARNSIDE, 1997; HOUGHTON et al., 2000)

Nesse sentido, observar a dinâmica da biomassa terrestre torna-se um grande desafio e uma das principais fontes de incertezas no ciclo global do carbono (QUÉRÉ et al., 2016). No gerenciamento de florestas tropicais se requer ferramentas efetivas para monitorar paisagens ao longo do tempo. Ferramentas baseadas em dados decampo são valiosas, porém, especialmente limitadas (WEST; WEST, 2009). Nesse meio, entre as tecnologias de mapeamentos atuais, o LiDAR é considerada a tecnologia de detecção remota mais precisa para o mapeamento de biomassa (ZOLKOS et al., 2013) e possui uma posição proeminente, devido à sua capacidade superior de resolver a estrutura da vegetação 3D (VIERLING et al., 2008).

Considerado uma tecnologia promissora para quantificar e monitorar a AGB nos ecossistemas florestais, o LiDAR fornece informações essenciais para quantificar sua dinâmica (LIM et al., 2003; WULDER et al., 2012). A utilização de dados de *laser* aerotransportado (ALS - *Airborne Laser Scanning*) contribui com o aumento da área amostrada (ASNER et al., 2012; ASNER; MASCARO, 2014), e tem sido largamente utilizada para estimar parâmetros florestais em florestas tropicais (ex. DRAKE et al., 2002; D'OLIVEIRA et al., 2012; ANDERSEN et al., 2014; ASNER, 2014; SAATCHI et al., 2007). Além do mais, possibilita gerar um modelo de altura de copa (CHM) que pode ser usado para

a detecção individual de árvores, delineamento de copas, e posteriormente na estimativa de parâmetros biométricos, como volume e biomassa (POPESCU 2007; FALKOWSKI et al., 2009; VAUHKONEN et al., 2012; HU et al., 2014; DUNCANSON et al., 2015; KANKARE et al., 2015).

O delineamento de árvores, conforme Pereira (2014) tem sua aplicação elementar no inventário e manejo florestal, e tem sido muito explorado, existindo uma série de métodos diferentes para a detecção e medição de árvores individuais por sensoriamento remoto (por exemplo, LI et al., 2012; PITKÄNEN et al., 2004; BRANDTBERG et al., 2003; WEINACKER et al., 2004; HEINZEL et al., 2008). Além de que é uma importante etapa de estudos que objetivam extrações de informações dendrométricas (SUÁREZ et al., 2005). A utilização de técnicas de segmentação de imagens com uma abordagem orientada a objeto é de grande auxílio para a classificação e segmentação das imagens laser (MIQUELES; CENTENO, 2003) e são primordiais frente aos avanços no meio científico para obtenção de informações cada vez mais precisas.

## HIPÓTESE

Dados LiDAR aerotransportado podem ser utilizados para obter e avaliar informações estruturais da floresta e também dos estoques de AGB.

## 5.2. OBJETIVOS

O objetivo deste trabalho foi estimar e avaliar as mudanças nos estoques de biomassa acima do solo (AGB) em uma floresta tropical via dados de LiDAR aerotransportado.

Para tanto, os objetivos específicos foram:

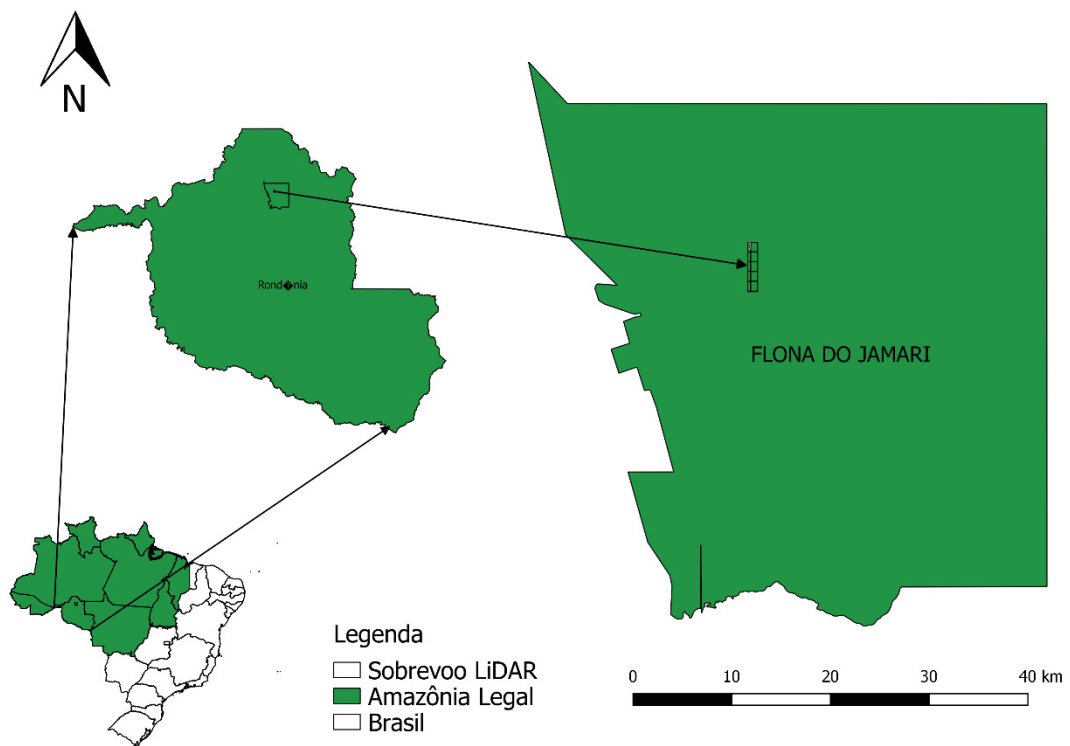
- (i) Identificar e individualizar, por meio de processos automáticos as copas dos indivíduos no dossel superior da floresta.
- (ii) Estimar o estoque de AGB via LiDAR e comparar com as estimativas de inventário florestal;
- (iii) Avaliar se os estoques de AGB e as mudanças ocorridas no intervalo de tempo apresentam diferenças significativas.

### 5.3. MATERIAL E MÉTODOS

#### 5.3.1. Área de Estudo

A área de estudo trata-se da Floresta Nacional (Flona) do Jamari, que está localizada no estado de Rondônia e que se apresenta em regime de concessão florestal do Serviço Florestal Brasileiro (FIGURA 6).

FIGURA 6 - MAPA DE LOCALIZAÇÃO DA ÁREA DE ESTUDO NA FLORESTAL NACIONAL DO JAMARI.



FONTE: O AUTOR (2018).

A Flona do Jamari foi criada em 1984 e está situada nos municípios de Itapuã do Oeste, Cujubim e Candeias do Jamari, abrangendo uma área total de 220 mil hectares. Segundo a classificação fisionômica-ecológica do IBGE (2012), é predominantemente coberta por Floresta Ombrófila Densa, com algumas porções de Floresta Ombrófila Aberta, com predominância de palmeiras ou com cipós. Em 2008, o Serviço Florestal Brasileiro concedeu 96 mil hectares da Flona do Jamari para exploração florestal por meio de concessão, divididos em três Unidades de Manejo Florestal (UMF). No mês de setembro de 2010 foi iniciada a exploração nas primeiras Unidades de Produção Anual (UPA).

### 5.3.2. Dados Utilizados

Os dados utilizados nesta pesquisa foram adquiridos do domínio do Projeto Paisagens Sustentáveis Brasil, apoiado pela Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA), pelo Serviço Florestal dos Estados Unidos (USFS), pela Agência dos Estados Unidos para o Desenvolvimento Internacional (USAID) e pelo Departamento de Estado dos EUA. O projeto foi criado para o desenvolvimento de novas metodologias e expansão do conhecimento através de técnicas de contabilização de carbono no âmbito do REDD+, entre eles o uso de dados LiDAR, tecnologia que permite avaliar detalhadamente áreas de estudos, fornecendo informações sobre a superfície do terreno e da estrutura da vegetação, parâmetros estes relacionados ao estoque de carbono (EMBRAPA, 2014).

Os dados do inventário florestal foram coletados no mês de dezembro de 2011 e 2013, sendo instaladas 6 transectos para a coleta do ano de 2011 e 24 parcelas para o ano de 2013. Em 2011 seis transectos de 500 m de comprimento por 20 m de largura foram instalados para mensuração florestal baseado em uma amostra ponderada de área basal com uma proporção de 1:10 para árvores maiores que 5 cm. O inventário florestal referente ao ano de 2013, totalizou em 24 parcelas de 50 m x 50 m dispostas sistematicamente ao longo de 6 linhas de referência (transectos). Cada parcela instalada apresenta um tamanho de 50 m x 50 m. Dentro das parcelas, foram alocadas sub-parcelas de 10 m x 50 m.

Para cada árvore foram registradas e coletadas: nome comum, da família e da espécie, densidade da madeira, área basal, diâmetro à altura do peito, biomassa acima do solo, altura comercial e total, raios cartesianos, coordenadas UTM e a data da coleta.

Os dados LiDAR referem-se a sobrevoos realizados nos mesmos anos da coleta dos dados de campo (2011-2013). A área abrangida em cada sobrevoo foi de 500 ha. A TABELA 2 apresenta os parâmetros do sobrevoo dos dois anos.

TABELA 2 - ESPECIFICAÇÕES REFERENTES AOS SOBREVOS PARA A COLETA DAS NUVENS LIDAR DOS ANOS DE 2011 E 2013.

<b>Especificações</b>	<b>2011</b>	<b>2013</b>
Data de aquisição	17/11/2011	20/09/2013
Datum	Sirgas 2000	Sirgas 2000
Sistema de coordenadas da UTM:	20S	20S
Área total	500ha	500ha
Média de densidade de pulsos/m <sup>2</sup>	15,43 ppm <sup>2</sup>	15,48 ppm <sup>2</sup>
Altitude média do voo	850 m	853 m
Campo de visão	11,1 °	11,1 °
Frequência de varredura	59,8 Hz	67,5 Hz
Porcentagem de sobreposição	65%	65%

FONTE: O AUTOR (2018).

### 5.3.3. Processamento dos Dados de LiDAR

O processamento dos dados LiDAR deu-se com auxílio do *software* FUSION versão 3.60 (MCGAUGHEY, 2016), que foi desenvolvido pelo Serviço Florestal Norte Americano. Este *software* permite analisar e visualizar os dados de LiDAR, além de ser uma eficiente ferramenta de processamento (MCGAUGHEY, 2014).

Primeiramente, os dados LiDAR em formato “laz” foram selecionados, e o ambiente M-DOS do sistema *Windows* foi preparado para o processamento. Em seguida o comando *catalog* foi utilizado para produzir o relatório descritivo do conjunto de dados LiDAR. Posteriormente, foi utilizado o comando *groundfilter* para classificar os pontos de solo, o qual é baseado no algoritmo de filtragem, fundamentado em Kraus e Pfeifer (1998). Então, foram gerados os Modelos Digitais de Terreno (MDT) usando o produto do passo anterior, ou seja, os pontos classificados de solo. Neste procedimento foi utilizado o comando *gridsurfacecreate*.

Para a normalização das alturas da área de estudo, foi utilizado o comando *ClipData*, e gerado o CHM com o comando *canopymodel*. O comando *PolyClipdata* foi utilizado para realizar o recorte das parcelas medidas em campo, bem como, os indivíduos arbóreos delineados pelo processo de segmentação, que é explanado em seguida. Com o comando *CloudMetrics* foram extraídas as métricas derivadas de LiDAR das parcelas. Enquanto o comando *GridMetrics* foi utilizado para produzir as mesmas métricas LiDAR, conforme

calculado com o *CloudMetrics*, porém, agora dentro de células de grade de resolução espacial de 50X50m em toda a paisagem conforme metodologia apresentada em Longo et al. (2016) e Silva et al. (2017).

Ao realizar o processamento dos dados LiDAR, notou-se que não seria possível utilizar todo o conjunto de dados, pois algumas parcelas do inventário florestal ficaram parcialmente fora do sobrevoo LiDAR. Desta forma, para o ano de 2011 foram mantidas 5 transectos e 18 parcelas foram mantidas para o ano de 2013, assim, justificando o fato da não utilização de todas as parcelas.

#### 5.3.4. Individualização de árvores

Para a individualização das árvores, utilizou-se o CHM como modelo de entrada para segmentar as copas da área de estudo. Para este procedimento, foi utilizado o algoritmo de segmentação por crescimento de regiões implementado no *software* eCognition, que possui como principal característica uma abordagem orientada a objeto, que é de grande auxílio para a classificação e segmentação das imagens do laser (MIQUELES; CENTENO, 2003). O *software* eCognition foi utilizado nesta pesquisa por apresentar uma abordagem de classificação automática e também por permitir que o usuário realize o processo de classificação visual, sendo assim possível aplicar a fotointerpretação considerando a resposta espectral dos alvos (TRIMBLE, 2014). Além do mais, este *software* tem apresentado bons resultados em trabalhos semelhantes (por exemplo, REX et al., 2018; PANDE-CHHETRI et al., 2017).

Por se tratar de uma floresta tropical com grande heterogeneidade de espécies e grande variação de alturas e dimensão de copas, foi testada uma série de valores para a segmentação do CHM. A segmentação de copas de árvores foi constituída por combinações de valores de escala (*Scale Parameter*) e também dos parâmetros de forma e compacidade, traduzidos do inglês em *Shape* e *Compactness*, respectivamente. Os valores testados foram: *Scale Parameter* - SP variando de 10 a 50 com intervalo de 5. Enquanto que para os parâmetros (*Shape* - forma e *Compactness*) foram testados valores que variaram entre 0,1 e 0,9 com intervalo de 0,1 entre os parâmetros.

Após o procedimento de segmentação, os resultados foram exportados para o *software* Arcgis 10.4 e sobre o CHM foram selecionadas copas homólogas entre os anos avaliados. Posteriormente, foram extraídos os valores correspondentes de altura total dos indivíduos via nuvem LiDAR, bem como a área de copa (AC), em metros quadrados (m<sup>2</sup>).

### 5.3.5. Estimativas de AGB

Como o conjunto de dados do inventário florestal possuía dados de diâmetro à altura do peito e a identificação de espécies, foi aplicada a Equação 2 desenvolvida para estimação de biomassa em função do diâmetro e densidade, proposta por Chave et al. (2005) que tem como variáveis independentes o DAP e a densidade básica da madeira.

$$AGB = \rho * \exp(-1,499 + 2,148 \ln(DAP) + 0,207 (\ln(DAP))^2 - 0,0281 (\ln(DAP))^3)$$

Eq. 2

Em que:

AGB é a biomassa acima do solo (kg),  $\rho$  é a densidade da madeira ( $\text{g.cm}^3$ ) e DAP é diâmetro à altura do peito (1,30 m).

### 5.3.6. Estimativa de AGB via métricas LiDAR

A estimativa da AGB via métricas LiDAR foi obtida em momentos distintos, e considerou a Equação 3 desenvolvida por d'Oliveira et al., 2012. Esses autores calibraram o modelo com base em dados de parcelas de campo de 50 m x 50 m. Para evitar inconsistências na aplicação da equação no presente conjunto de dados, foi gerado um *grid* com resolução de 50m para o ano de 2011, e posteriormente a estimativa e extração da AGB dos transectos de 500x20m. Já para o conjunto de dados referente ao ano de 2013, foram geradas as métricas para estimativa da AGB diretamente nas parcelas (50 m x 50 m). Em um segundo momento, foram obtidas as estimativas para toda a área de estudo de LiDAR, levando em consideração o *grid* com resolução de 50m.

$$AGB = (3,119 + 0,564 PS5 + 0,062 Var)^2 + 1,74$$

Eq.3

Em que:

AGB = biomassa acima do solo ( $\text{Mg.ha}^{-1}$  árvores  $\text{DAP} \geq 10$  cm);

P25 = equivale aos retornos do primeiro quartil ou 25% percentil;

Var = variação da elevação.

( $R^2$  adj = 0,72; Erro padrão = 40,2).

### 5.3.7. Mudança da AGB e na estrutura das copas

A dinâmica da AGB na área de estudo foi avaliada com base nos *grids* de resolução de 50 m, gerados para ambos os anos. O delineamento das copas serviu como avaliação complementar para observar se possíveis alterações estruturais das copas e alturas dos indivíduos arbóreos pode influir na dinâmica da AGB.

### 5.3.8. Avaliações estatísticas

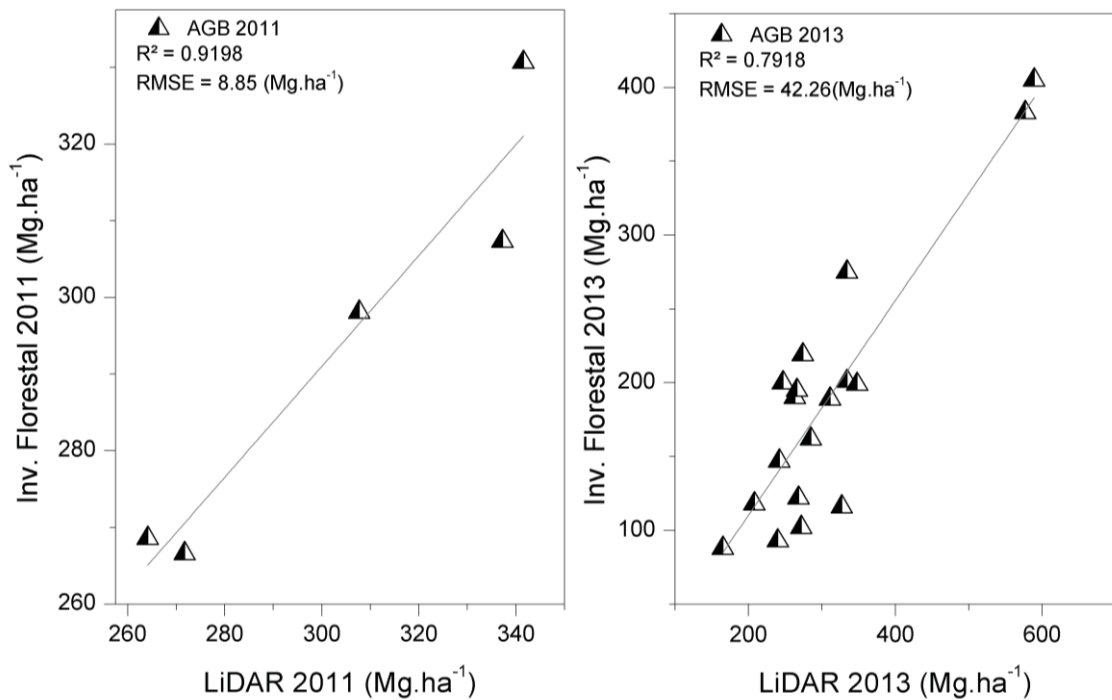
As relações entre as estimativas geradas de biomassa das parcelas foram avaliadas pelo coeficiente de determinação ( $R^2$ ); pelo coeficiente de correlação de Pearson ( $r$ ) e erro médio quadrático (RMSE). Já as mudanças da biomassa estimada via LiDAR no período entre 2011 e 2013 foram analisadas em termos de valores estimados, os quais foram submetidos ao teste t de *student*, a 5% de probabilidade.

## 5.4. RESULTADOS

### 5.4.1. Processamento e Estimativas LiDAR versus Inventário Florestal

Foram gerados modelos digitais de terreno, superfície e de copas para os dois anos, sendo os valores máximos encontrados para os CHM de 55m e 52,57m, para o ano de 2013 e 2011, respectivamente. A relação entre as estimativas da AGB via LiDAR versus Inventário Florestal, apresentaram fortes relações, com valores de coeficiente de determinação  $R^2$  de 0,9198 e de 0,7918, para o ano de 2011 e 2013, respectivamente (FIGURA 7).

FIGURA 7 - RELAÇÕES ENCONTRADAS PARA AS ESTIMATIVAS DE AGB. AGB 2011) RELAÇÕES DAS ESTIMATIVAS REFERENTE AOS TRANSECTOS DO ANO DE 2011; AGB 2013) RELAÇÕES DAS ESTIMATIVAS REFERENTE AS PARCELAS DO ANO DE 2013.



FONTE: O AUTOR (2018).

Os valores encontrados para o coeficiente de correlação de Pearson foram de 0,9590 para o ano de 2011 e 0,8891 para o ano de 2013. A redução do coeficiente de determinação  $R^2$  nas estimativas do ano de 2013, tem relação com o tamanho da parcela, uma vez que para o ano de 2011 a amostragem utilizada foi realizada em transectos de 1ha, e para o ano de 2013, a amostragem foi realizada em parcelas quadradas de 0,25ha.

As estimativas de AGB através de dados LiDAR se apresentam próximas às estimativas a partir dos dados de inventário florestal. A AGB estimada via dados LiDAR para o ano de 2011 apresentou em média  $287,14 \pm 46,77 \text{ Mg.ha}^{-1}$ , enquanto a média de AGB via dados de inventário florestal foi de  $321,98 \pm 39,86 \text{ Mg.ha}^{-1}$ .

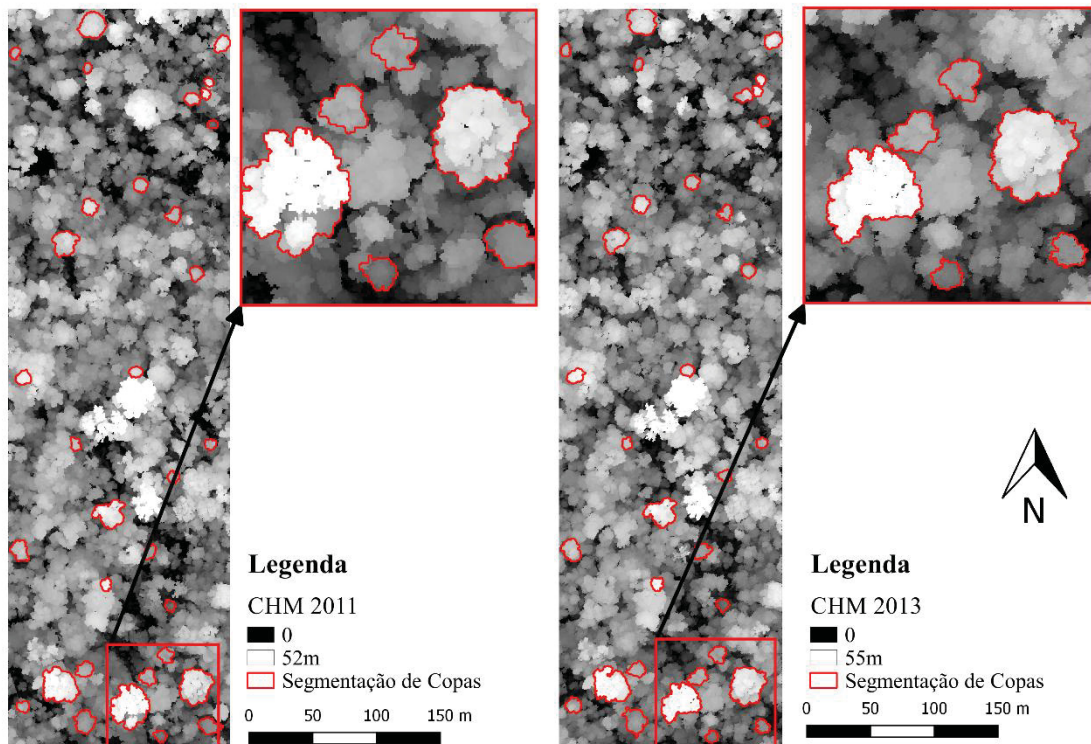
A AGB estimada para o ano de 2013 apresentou maiores variações; em média a estimativa via LiDAR foi de  $308,47 \text{ Mg.ha}^{-1}$ , enquanto a estimativa via inventário de campo foi de  $189,19 \text{ Mg.ha}^{-1}$ . Para estas estimativas também foram observados maiores valores de desvio padrão, tais como  $110,13 \text{ Mg.ha}^{-1}$  e  $89,97 \text{ Mg.ha}^{-1}$  para as estimativas via LiDAR e Inventário de campo, respectivamente.

#### 5.4.2. Segmentação de copas

O processo de segmentação das copas para a individualização das árvores considerou um resultado complementar, em que foram obtidos mais valores, ou seja, não apenas um resultado. Os valores de segmentação que proporcionaram os melhores resultados para a extração das copas do ano de 2011 foram: *Scale Parameter* (15 e 35), sendo os valores que melhor se ajustaram de *shape* e *compactness* 0,60 e 0,30, respectivamente. Já para o ano de 2013 foram obtidos os seguintes valores, três resultados de *Scale Parameter* (45; 35 e 25), e os seus respectivos valores de *shape* e *compactness* os de (0,30 - 0,60; 0,60 - 0,10 e 0,2 - 0,8). Esses valores compuseram 40 copas para cada ano.

Com o processo de delimitação das copas, foi possível observar que, entre o período de dois anos, houve alterações no dossel da floresta (FIGURA 8). A alternativa de uma segmentação com mais de um resultado, permitiu a extração de formas variadas de copas de árvores, uma vez que, devido à heterogeneidade da floresta analisada, torna-se complexo obter bons resultados definindo apenas um parâmetro para este procedimento.

FIGURA 8 - QUALIDADE DO RESULTADO DA SEGMENTAÇÃO DAS COPAS DOS MODELOS DE ALTURA DE COPAS GERADOS PELO PROCESSAMENTO DE DADOS LIDAR.

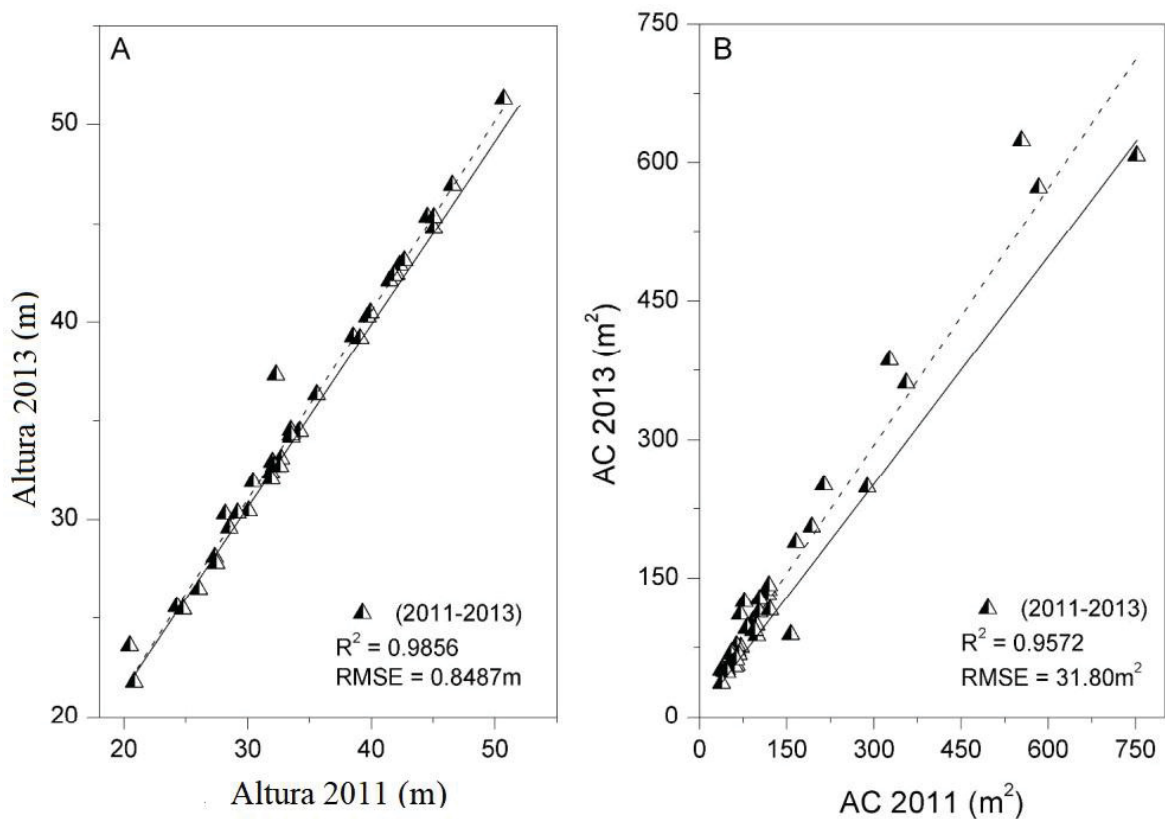


FONTE: O AUTOR (2018).

### 5.4.3. Mudanças estruturais

As mudanças estruturais observadas das AC e das alturas no período de 2011-2013 apresentaram altos valores de coeficiente de determinação (FIGURA 9), para o parâmetro AC foi observado  $R^2 = 0,9572$ , e para as alturas  $R^2 = 0,9856$ . De modo geral, esses parâmetros apresentaram regularidade em termos de valores, havendo acréscimos de valores no período de 2 anos, uma vez que, o coeficiente angular da regressão linear se apresentou significativamente maior que 1.

FIGURA 9 - RELAÇÕES ENCONTRADAS PARA OS PARÂMETROS OBTIDOS COM A DETECÇÃO DAS COPAS. A) ALTURAS DAS ÁRVORES EXTRAÍDAS DO CHM PARA OS ANOS DE 2011 E 2013. B) AC DAS ÁRVORES EXTRAÍDAS DO CHM PARA OS ANOS DE 2011 E 2013.



FONTE: O AUTOR (2018).

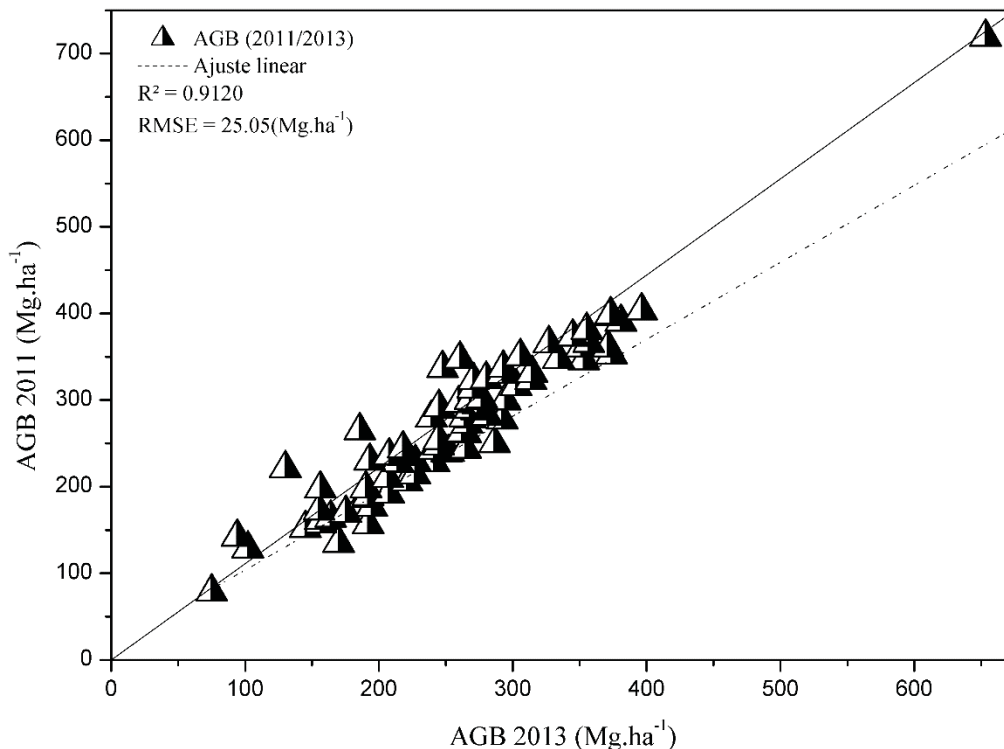
O padrão observado de distribuição das AC extraídas apresenta uma grande maioria de indivíduos com copas menores ( $36,9 - 180,3\text{m}^2$ ) e posteriormente uma significativa redução de indivíduos com o aumento da área de copa ( $\geq 180,3\text{m}^2$ ). Em questão de valores, a média de AC das árvores delineadas foram de  $145,81\text{ m}^2$  e  $151,53\text{ m}^2$ , para os anos de 2011 e 2013, respectivamente, e o total de AC para o ano de 2011 foi de  $5.832,39\text{ m}^2$  e de

6.061,52m<sup>2</sup> para o ano de 2013. Esses valores representam aproximadamente 4% de aumento de AC entre o período avaliado.

#### 5.4.4. Dinâmica da AGB da área de estudo

Os valores estimados de AGB para a floresta (FIGURA 10) apresentam regularidade assim como os valores de AC, entretanto, o padrão para a amostra de LiDAR da floresta apresenta redução da AGB entre os anos avaliados (coeficiente angular menor que 1). Percebe-se que houve uma aproximação no ângulo da reta do ajuste linear aos 45 graus, o que caracteriza a região de coincidência da estimativa. Em questão de valores, há uma perda de 1.220,28 Mg.ha<sup>-1</sup> de AGB entre 2011 e 2013, representando assim, redução de 5,64% em aproximadamente dois anos.

FIGURA 10 - DISTRIBUIÇÃO DOS VALORES ENCONTRADOS PARA AS ESTIMATIVAS DE BIOMASSA ACIMA DO SOLO DA AMOSTRA DE FLORESTA PARA OS ANOS DE 2011 E 2013.



FONTE: O AUTOR (2018).

O estoque total de AGB para os aproximadamente 15ha de floresta avaliada no ano de 2011 apresentou o valor de 21.636,15 Mg.ha<sup>-1</sup>, enquanto que para o ano de 2013 o estoque encontrado foi de 20.415,87 Mg.ha<sup>-1</sup>. Em média, a floresta apresentou valores de 270,45 ±

90,26 Mg.ha<sup>-1</sup> para o ano de 2011 e para o ano de 2013 os valores foram de 255,19 ± 83,92 Mg.ha<sup>-1</sup>. O teste T de *student* revelou que não há mudanças significativas no período avaliado (2011-2013) em nível de 5% de probabilidade.

## 5.5. DISCUSSÃO

Os valores dos modelos de altura de copa representam as maiores alturas da floresta, além do que, a utilização de modelos de altura de copas de uma grande floresta se torna uma alternativa viável em relação ao tempo e recurso investidos (CUNHA; CENTENO, 2005) uma vez que a alta resolução dos dados do CHM oferece a possibilidade de detectar as medidas de árvores individuais (PERSSON et al., 2002).

Em relação aos tamanhos e formatos das parcelas Melo (2017) observou que houve subestimava com 0,25 ha por não representar a distribuição diamétrica da floresta de forma eficaz. De modo geral, parcelas pequenas (0,25 ha) não calibrar biomassa estimada com dados LiDAR (MASCARO et al., 2011; LONGO et al., 2016). A precisão das estimativas de biomassa baseadas em dados LiDAR, aumenta à medida que o tamanho das parcelas de calibração de campo aumenta (ASNER; MASCARO, 2014; MAUYA et al., 2015). O tamanho e a forma das parcelas interferem na probabilidade de amostragem de árvores com grandes diâmetros (HIGUCHI, SANTOS; JARDIM, 1982; BROWN, GILLESPIE; LUGO, 1989), bem como na intensidade do efeito de borda, que leva ao aumento da variância com parcelas de 50 m x 50 m (0,25 ha) (MELO, 2017).

A AGB média via LiDAR das parcelas analisadas neste estudo (287,14 ± 46,77 Mg.ha<sup>-1</sup>) foi próxima a biomassa média das florestas amazônicas (SAATCHI et al., 2011; BACCINI 2012). Uma série de pesquisas mostra boas relações entre as estimativas geradas via dados LiDAR e dados de inventário de campo, por exemplo, autores como Sato et al. (2015), Figueiredo et al. 2016, Santos et al. (2017) obtiveram resultados pertinentes em seus trabalhos utilizando dados de LiDAR em floresta tropical.

A heterogeneidade do ambiente nativo apresenta várias formas de copas, bem como grande variação nas alturas dos indivíduos arbóreos, assim, no processo de segmentação foi observado que algumas copas eram mais bem segmentadas com valores mais baixos para o parâmetro escala, enquanto que outras copas ficavam mais bem ajustadas com valores mais altos. Resultado similar foi observado por Ribas e Elmiro (2013) em que, os autores encontraram mais do que um valor na segmentação de modelos digitais gerados por LiDAR em ambiente nativo.

O padrão encontrado de área de copa assemelha-se com o J-invertido, o qual é típico de florestas naturais onde há um grande número de árvores que povoam as classes de menor diâmetro, seguindo uma diminuição exponencial do número de árvores com diâmetros maiores (ODUM, 2001). Esse padrão também foi encontrado por Sato et al. (2016) ao quantificar os impactos de fogo na altura e biomassa da floresta no sudoeste da Amazônia brasileira usando a tecnologia LiDAR. Em relação as mudanças estruturais positivas das áreas de copas, estas podem ter relação com o aumento da disponibilidade de recursos, que aumenta a PPL (Produtividade Primária Líquida), e assim, aumenta as taxas de crescimento dos indivíduos (PHILLIPS et al., 2009).

A obtenção das alturas via LiDAR resultou em valores acurados, uma vez que foi observado regularidade nas medidas obtidas no período avaliado. De acordo com Giongo et al. (2010), a obtenção das alturas das árvores via LiDAR se apresenta de grande potencial, pois essa informação é obtida de forma direta, diferente de outras características estruturais da floresta, como a AGB, área basal, diâmetro, que são obtidas por técnicas de modelagem e/ou estimadas a partir de medições diretas (DUBAYAH et al., 2000). A capacidade de mensurar diretamente a altura e derivar outras medidas a partir desta é uma grande vantagem em relação a outras formas de sensoriamento remoto (RIBAS; ELMIRO, 2013), e principalmente em relação aos métodos tradicionais de coleta desta variável em florestas tropicais, um vez que nos inventários florestais a altura das árvores é atribuída de maneira visual, o que é extremamente tendencioso, pois a noção de espaço pode variar entre um observador treinado e um não treinado (KITAHARA et al., 2010; SILVA et al., 2012).

O aumento da altura da espécie Castanheira-do-Brasil (*Bertholletia excelsa* H.B.K), que é típica da floresta Amazônica não é acompanhado proporcionalmente pelo aumento do diâmetro de copa (TONINI; ARCO-VERDE, 2005; DIONÍSIO et al., 2017), o que corrobora com Hess et al. (2014) que relataram que de modo geral espécies nativas apresentam fustes tortuosos, que acabam gerando uma maior discrepância na relação h/d, isto é, diâmetros elevados e alturas pequenas, ou alturas elevadas com diâmetro menor, gerando assim, uma baixa correlação dessas duas variáveis.

Em valores médios de AGB da área analisada, foi encontrado valores semelhantes ao de Silva et al. 2017, que utilizaram a mesma abordagem para predição de estoques de AGB em uma floresta no estado do Pará, apesar que, no estudo desses autores não houveram mudanças negativas em um período de dois anos. Estudos semelhantes ao escopo dessa pesquisa relatam sobre impactos ocorridos em florestas que causaram redução dos valores de AGB. Silva (2014) analisando impactos após exploração da FLONA do Jamari apontou

redução de 23,5% de AGB. Já Mazzei et al. (2010), encontraram redução de 10 a 40% pós-exploração, representada por árvores abatidas e danificadas, enquanto que Gerwing (2002) observou redução de biomassa aérea de 20% em locais que sofreram extração moderada ( $35 \text{ m}^3 \cdot \text{ha}^{-1}$ ) e 48% sob exploração intensa ( $69 \text{ m}^3 \cdot \text{ha}^{-1}$ ). A redução de 5,64% de AGB encontrada nessa pesquisa pode ser considerada baixa em relação aos 23,5% de redução de AGB encontrada por Silva (2014), e de Asner et al. (2005), o qual estimaram perda de carbono pós manejo em torno dos 15%.

Nesse sentido, é possível perceber o potencial da tecnologia LiDAR como ferramenta para gerar informações precisas sobre o ambiente. Pelo bioma Amazônia apresentar grandes extensões, já era esperado encontrar divergências na literatura. De acordo com Andersen et al. (2014) dados de lidar multitemporais podem ser usados para detectar e quantificar as alterações de AGB, mesmo quando o nível de mudança de AGB é baixo ( $10\text{-}20 \text{ Mg} \cdot \text{ha}^{-1}$ ), o que corrobora com os resultados deste trabalho para o período avaliado.

Mesmo como resultados que não diferiram significativamente, não podem descartar o fato de que mudanças negativas estão acontecendo nos estoques de AGB da floresta, sendo necessário um período de tempo maior para uma avaliação de mudanças em uma floresta sem indícios de eventos de grandes dimensões, como observado por Sato et al. (2016), que detectaram mudanças na biomassa e altura da floresta por um período equivalente a pelo menos 10 anos após a ocorrência de um evento de incêndio no sub-bosque. Esses autores ainda comentam que esse tipo de distúrbio pode causar perda persistente de AGB e redução subsequente dos estoques de carbono florestal, e ainda, que o LiDAR é uma tecnologia poderosa para explorar esses impactos.

Com as estimativas de AGB para todo o local de estudo foi possível identificar as mudanças ocorridas entre o período avaliado, além de que, as mudanças estruturais observadas nas copas e nas alturas dos indivíduos arbóreos não foram suficientes para influir sobre a paisagem avaliada. Não obstante, é importante ressaltar que, variações na estrutura das florestas podem ter causas relacionadas à fenologia da vegetação e às condições climáticas locais, devendo ser consideradas repetições de observações para estudos de dinâmica (CASTILLO et al., 2012).

## 5.6. CONCLUSÕES

As estimativas geradas via dados LiDAR apresentam fortes correlações com as obtidas via inventário florestal. A melhor relação entre os dados foi obtida para o ano de 2011, cuja amostragem utilizada em campo foi realizada em faixas de 1ha.

Os resultados encontrados neste capítulo mostram que é possível estimar os estoques de AGB e também obter informações estruturais da floresta com precisão. Assim, pode-se concluir que a tecnologia LiDAR é uma ferramenta de grande potencial para auxiliar em estimativas regionais dos estoques de AGB em florestais tropicais, bem como para detecção de mudanças em ampla escala, em que medições baseadas em campo demandariam tempo e onerosos custos.

Além do mais, a metodologia de individualização de copas de árvores possibilita identificar alterações positivas na paisagem, as quais não são refletidas nas estimativas de AGB da amostra de floresta avaliada. Nesse sentido, essa abordagem pode gerar informações detalhadas sobre o ambiente, além do que, esse enfoque pode potencializar a avaliação de mudanças temporais nos estoques de biomassa e, conseqüentemente, de carbono.

## 6. REFERÊNCIAS BIBLIOGRÁFICAS

- ANDERSEN, H. et al. Monitoring selective logging in western Amazonia with repeat lidar flights. **Remote Sensing of Environment**, v. 151, p. 157-165, 2014.
- ASNER, G. P. et al. High-resolution mapping of forest carbon stocks in the Colombian Amazon. **Biogeosciences**, v. 9, n. 7, p. 2683, 2012.
- ASNER, G. P.; MASCARO, J. Mapping tropical forest carbon: Calibrating plot estimates to a simple LiDAR metric. **Remote Sensing of Environment**, v. 140, p. 614-624, 2014.
- ASNER, Gregory P. et al. Selective logging in the Brazilian Amazon. **Science**, v. 310, n. 5747, p. 480-482, 2005.
- BACCINI, A. G. S. J. et al. Estimated carbon dioxide emissions from tropical deforestation improved by carbon-density maps. **Nature climate change**, v. 2, n. 3, p. 182, 2012.
- BRANDTBERG, T. et al. Detection and analysis of individual leaf-off tree crowns in small footprint, high sampling density lidar data from the eastern deciduous forest in North America. **Remote sensing of Environment**, v. 85, n. 3, p. 290-303, 2003.
- BROWN, S; GILLESPIE, A. JR; LUGO, A. E. Biomass estimation methods for tropical forests with applications to forest inventory data. **Forest science**, v. 35, n. 4, p. 881-902, 1989.
- CASTILLO, Mauricio et al. LIDAR remote sensing for secondary Tropical Dry Forest identification. **Remote sensing of environment**, v. 121, p. 132-143, 2012.
- CHAVE, J. et al. Tree allometry and improved estimation of carbon stocks and balance in tropical forests. **Oecologia**, v. 145, n. 1, p. 87-99, 2005.
- CLARK, D. A. Sources or sinks? The responses of tropical forests to current and future climate and atmospheric composition. **Philosophical Transactions of the Royal Society of London B: Biological Sciences**, v. 359, n. 1443, p. 477-491, 2004.
- CLEMENT, C. R.; HIGUCHI, N. A floresta amazônica e o futuro do Brasil. **Ciência e Cultura**, v. 58, n. 3, p. 44-49, 2006.
- CUNHA, F; CENTENO, C. T. M. Segmentação de imagens geradas por perfilamento a laser para delimitação de árvores individuais em uma área de reflorestamento de eucaliptos. In: **Simpósio Brasileiro de Sensoriamento Remoto**, 12. (SBSR), Goiânia. Anais. São José dos Campos: INPE. p. 737-744. ISBN 85-17-00018-8, 2005.
- DIONISIO, L. F. S; CONDÉ, T. M; GOMES, J. P; MARTINS, W. B. R; SILVA, M. T; SILVA, M. W. Caracterização morfométrica de árvores solitárias de *Bertholletia excelsa* HBK no sudeste de Roraima. **Revista Agro@mbiente On-line**, v. 11, n. 2, p. 163-173, 2017.
- D'OLIVEIRA, M VN et al. Estimating forest biomass and identifying low-intensity logging areas using airborne scanning lidar in Antimary State Forest, Acre State, Western Brazilian Amazon. **Remote Sensing of Environment**, v. 124, p. 479-491, 2012.

DRAKE, J. B. et al. Estimation of tropical forest structural characteristics using large-footprint lidar. **Remote Sensing of Environment**, v. 79, n. 2-3, p. 305-319, 2002.

DUBAYAH, R.; KNOX, R.; HOFTON, M.; BLAIR, J. B.; DRAKE, J. Land surface characterization using LiDAR remote sensing. In: HILL, M. e ASPINALL, R. (Ed.). **Spatial Information for Land Use Management**. Singapore: International Publishers Direct, p. 25-38. 2000.

DUNCANSON, L. I. et al. An efficient, multi-layered crown delineation algorithm for mapping individual tree structure across multiple ecosystems. **Remote Sensing of Environment**, v. 154, p. 378-386, 2014.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (EMBRAPA). **Soluções Tecnológicas**. Disponível em: <https://www.embrapa.br/busca-de-solucoes-tecnologicas/-/produto-servico/3862/paisagens-sustentaveis>, 2014.

FALKOWSKI, M. J. et al. Characterizing forest succession with lidar data: An evaluation for the Inland Northwest, USA. **Remote Sensing of Environment**, v. 113, n. 5, p. 946-956, 2009.

FEARNSIDE, P. M. Roraima e o aquecimento global: balanço anual das emissões de gases do efeito estufa provenientes da mudança de uso da terra. **Homem, Ambiente e Ecologia no Estado de Roraima**. Instituto Nacional de Pesquisas da Amazonia (INPA), Manaus, Amazonas, p. 337-359, 1997.

FIGUEIREDO, E O. et al. LIDAR-based estimation of bole biomass for precision management of an Amazonian forest: Comparisons of ground-based and remotely sensed estimates. **Remote Sensing of Environment**, v. 187, p. 281-293, 2016.

GERWING, J. J. Degradation of forests through logging and fire in the eastern Brazilian Amazon. **Forest ecology and management**, v. 157, n. 1-3, p. 131-141, 2002.

HEINZEL, J. N. et al. Full automatic detection of tree species based on delineated single tree crowns—a data fusion approach for airborne laser scanning data and aerial photographs. **Proceedings of SilviLaser**, v. 2008, n. 8th, 2008.

HESS, A. F.; BRZ, E. M.; THAINES, T.; MATOS, P. P. Ajuste de relação hipsométrica para espécies da Floresta Amazônica. **Ambiência** - Revista do Setor de Ciências Agrárias e Ambientais, v.10, n.1, 2014.

HIGUCHI, N; SANTOS, J dos; JARDIM, F. Tamanho de parcela amostral para inventários florestais. **Acta amazônica**, v. 12, n. 1, p. 91-103, 1982.

HOUGHTON, Richard A. et al. Annual fluxes of carbon from deforestation and regrowth in the Brazilian Amazon. **Nature**, v. 403, n. 6767, p. 301, 2000.

HU, B. et al. Improving the efficiency and accuracy of individual tree crown delineation from high-density LiDAR data. **International Journal of Applied Earth Observation and Geoinformation**, v. 26, p. 145-155, 2014.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. **Manual técnico da vegetação brasileira**: sistema fitogeográfico, inventário das formações florestais e campestres, técnicas e manejo de coleções botânicas, procedimentos para mapeamentos. Rio de Janeiro: IBGE- Diretoria de Geociências, 2012. 271p. (Manuais Técnicos de Geociências, 1).

GIONGO, M., KOEHLER, H. S., do AMARAL MACHADO, S., KIRCHNER, F. F., MARCHETTI, M. (2010). LiDAR: princípios e aplicações florestais. **Pesquisa Florestal Brasileira**, 30(63), 231.

KANKARE, V. et al. Diameter distribution estimation with laser scanning based multisource single tree inventory. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 108, p. 161-171, 2015.

KITAHARA, F. et al. Effects of training for inexperienced surveyors on data quality of tree diameter and height measurements. **Silva Fennica**, v. 44, n. 4, p. 657-667, 2010.

KRAUS, K.; PFEIFER, N. Determination of terrain models in wooded areas with airborne laser scanner data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 53, n. 4, p. 193-203, Aug 1998. ISSN 0924- 2716.

LAURIN, G. V. et al. Above ground biomass estimation in an African tropical forest with lidar and hyperspectral data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 89, p. 49-58, 2014.

LI, W et al. A new method for segmenting individual trees from the lidar point cloud. **Photogrammetric Engineering & Remote Sensing**, v. 78, n. 1, p. 75-84, 2012.

LIM, K. et al. LiDAR remote sensing of forest structure. **Progress in physical geography**, v. 27, n. 1, p. 88-106, 2003.

LONGO, M. et al. Aboveground biomass variability across intact and degraded forests in the Brazilian Amazon. **Global Biogeochemical Cycles**, v. 30, n. 11, p. 1639-1660, 2016.

MASCARO, J. et al. Evaluating uncertainty in mapping forest carbon with airborne LiDAR. **Remote Sensing of Environment**, v. 115, n. 12, p. 3770-3774, 2011.

MAUYA, E. W et al. Modelling aboveground forest biomass using airborne laser scanner data in the miombo woodlands of Tanzania. **Carbon balance and management**, v. 10, n. 1, p. 28, 2015.

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.

MCGAUGHEY RJ (2014) **FUSION/LDV**: Software for LIDAR data analysis and visualization, Version 3.42. USDA Forest Service, Pacific Northwest Research Station (Seattle, WA)

MCGAUGHEY, R.J. **FUSION / LDV**: software para análise e visualização de dados LIDAR. Seattle, WA, USFS, p.11, 2016.

MELO, AWF. **Alometria de Árvores e Biomassa Florestal na Amazônia Sul-Ocidental**, 2017. Tese (Doutorado em Ciências de Florestas Tropicais), Instituto Nacional de Pesquisas da Amazônia Programa de Pós-Graduação em Ciências de Florestas Tropicais, 154 f. 2017

MIQUELES, M. A.; CENTENO, J. AS. Detecção e caracterização de vegetação usando dados do laser scanner aerotransportado. **COLÓQUIO BRASILEIRO DE CIÊNCIAS GEODÉSICAS**, v. 3, p. 1-12, 2003.

NOBRE, C. A.; SAMPAIO, G.; SALAZAR, L. Mudanças climáticas e Amazônia. **Ciência e Cultura**, v. 59, n. 3, p. 22-27, 2007.

ODUM, E.P. **Fundamentos de Ecologia**, 6ed.; Fundação Calouste Gulbenkian: Lisboa, Portugal, 927p. 2001.

PANDE-CHHETRI, R., ABD-ELRAHMAN, A., LIU, T., MORTON, J., & WILHELM, V. L. Object-based classification of wetland vegetation using very high-resolution unmanned air system imagery. **European Journal of Remote Sensing**, 50(1), 564-576. 2017.

PEREIRA, J. P. **Mensuração automática de copas de Araucaria angustifolia (Bertol.) Kuntze a partir de dados LiDAR para estimativa de variáveis dendrométricas**. 140 f. Dissertação (Mestrado) - Programa de PósGraduação em Engenharia Florestal, CAV - UDESC. Lages, 2014.

PERSSON, A; HOLMGREN, J; SODERMAN, U. Detecting and measuring individual trees using an airborne laser scanner. **Photogrammetric Engineering and Remote Sensing**, v. 68, n. 9, p. 925-932, 2002.

PHILLIPS, O. L. et al. The changing Amazon forest. **Philosophical Transactions of the Royal Society of London B: Biological Sciences**, v. 363, n. 1498, p. 1819-1827, 2008.

PITKÄNEN, J. et al. Adaptive methods for individual tree detection on airborne laser based canopy height model. **International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 36, n. 8, p. 187-191, 2004.

POPESCU, S. C. Estimating biomass of individual pine trees using airborne lidar. **Biomass and Bioenergy**, v. 31, n. 9, p. 646-655, 2007.

QUÉRÉ, C. L. et al. Global carbon budget 2016. **Earth System Science Data**, v. 8, n. 2, p. 605-649, 2016.

REX, F.E., DALLA CORTE, A.P., MACHADO, S.A., SANQUETTA, C.R. Identificação e extração de copas de Araucaria angustifolia (Bertol.) Kuntze a partir de dados lidar. **Advances in Forestry Science**, 5(2), 319-323. 2018.

RIBAS, R.P., ELMIRO, M.A.T. Individualização de árvores em ambiente florestal nativo utilizando métodos de segmentação em modelos digitais produzidos a partir da tecnologia LIDAR. **Revista Brasileira de Cartografia**, 65, 719-729, 2013.

SAATCHI, S. S. et al. Benchmark map of forest carbon stocks in tropical regions across three continents. **Proceedings of the National Academy of Sciences**, v. 108, n. 24, p. 9899-9904, 2011.

SAATCHI, S. S. et al. Distribution of aboveground live biomass in the Amazon basin. **Global Change Biology**, v. 13, n. 4, p. 816-837, 2007.

SANTOS, E.; JORGE, A.; SHIMABUKURO, Y. E.; GONCALVES, F. G. Estimativa de biomassa acima do solo para uma área queimada e uma área de corte seletivo no município de Feliz Natal - MT por meio de dados LiDAR. In: **XVIII Simpósio Brasileiro de Sensoriamento Remoto**, 2017, Santos. Anais do XVIII Simpósio Brasileiro de Sensoriamento Remoto - SBSR, 2017.

SATO, L. Y. et al. Análise da relação entre dados de LiDAR e de biomassa florestal no sudoeste da Amazônia. In: **Embrapa Monitoramento por Satélite-Artigo em anais de congresso (ALICE)**. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17., 2015, João Pessoa. Anais... São José dos Campos: INPE, 2015.

SATO, L. Y. et al. Post-Fire Changes in Forest Biomass Retrieved by Airborne LiDAR in Amazonia. **Remote Sensing**, v. 8, n. 10, p. 839, 2016.

SILVA, C. A. et al. Impacts of airborne lidar pulse density on estimating biomass stocks and changes in a selectively logged tropical forest. **Remote Sensing**, v. 9, n. 10, p. 1068, 2017.

SILVA, G.F. et al. Avaliação de métodos de medição de altura em florestas naturais. **Revista Árvore**, v. 36, n. 2, 2012.

SILVA, J. L. **Danos florestais e estimativa da redução no estoque de carbono em áreas de manejo florestal sob concessão pública: floresta nacional do Jamari – RO, Brasil**. Manaus: [s.n.], 2014. xiii, 97p. Dissertação( Ciências de Florestas Tropicais (CFT)) - Instituto Nacional de Pesquisas da Amazônia.

SUÁREZ, J. C. et al. Use of airborne LiDAR and aerial photography in the estimation of individual tree heights in forestry. **Computers & Geosciences**, v. 31, n. 2, p. 253-262, 2005.

TONINI, H.; ARCO-VERDE, M.F. Morfologia da copa para avaliar o espaço vital de quatro espécies nativas da Amazônia. **Pesquisa agropecuária brasileira**, Brasília, v.40, n.7, p.633-638, 2005.

TRIMBLE, **Ecognition Developer Reference Book 9.0**. Trimble Documentation München, Germany, 14p. 2014.

VAN DER WERF, G. R. et al. CO<sub>2</sub> emissions from forest loss. **Nature geoscience**, v. 2, n. 11, p. 737, 2009.

VAUHKONEN, J. et al. Comparative testing of single-tree detection algorithms under different types of forest. **Forestry**, v. 85, n. 1, p. 27-40, 2011.

VIERLING, K. T. et al. Lidar: shedding new light on habitat characterization and modeling. **Frontiers in Ecology and the Environment**, v. 6, n. 2, p. 90-98, 2008.

WEINACKER, H. et al. Development of filtering, segmentation and modelling modules for lidar and multispectral data as a fundament of an automatic forest inventory system. **International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 36, n. Part 8, p. W2, 2004.

WEST, P. W.; WEST, P. W. **Tree and forest measurement**. Heidelberg: Springer, 192p. 2009.

WULDER, M. A. et al. Lidar sampling for large-area forest characterization: A review. **Remote Sensing of Environment**, v. 121, p. 196-209, 2012.

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

## 7. CAPÍTULO IV: COMPARAÇÃO ENTRE ABORDAGENS DE MODELAGEM ESTATÍSTICA PARA ESTOQUE DE BIOMASSA ACIMA DO SOLO E ESTIMATIVA DA DINÂMICA EM FLORESTA TROPICAL SELETIVAMENTE EXPLORADA A PARTIR DE DADOS LIDAR

### RESUMO

A estimativa da biomassa acima do solo (AGB) tem sido um dos maiores desafios da ciência de sensoriamento remoto para observações de mudanças no armazenamento de carbono nos últimos anos. Os impactos de diferentes técnicas de modelagem na estimativa de estoques e mudanças da AGB usando dados de campo e de LiDAR aerotransportado em uma floresta tropical seletivamente explorada no leste da Amazônia foram avaliadas. A AGB derivada de campo foi calculada a partir de 85 parcelas de 50 m × 50 m em 2014. Os dados LiDAR foram obtidos em 2012, 2014 e 2017. Os modelos no nível da parcela foram primeiramente desenvolvidos usando 6 métricas baseadas na análise de PCA e quatro abordagens de aprendizado de máquina foram implementados: Floresta Aleatória (RF), Máquina de Vetores de Suporte (SVM), Rede Neural Artificial (RNA) e algumas variações de *k*-Vizinhos Mais Próximos (k-NN) e seu desempenho foi comparado a um modelo de regressão linear (OLS). Os resultados mostraram que o OLS apresentou o melhor desempenho entre os algoritmos tendo apresentado RMSE na validação cruzada *leave-one-out* (LOOCV) de 46,94 Mg.ha<sup>-1</sup>. Porém, RF e SVM também tiveram bons desempenhos e apresentaram RMSE de 55,80 e 56,24 Mg.ha<sup>-1</sup>, respectivamente. As variações de RNA e KNN apresentaram valores maiores de RMSE que as demais, maior que 64 Mg.ha<sup>-1</sup>. O melhor modelo permitiu a obtenção de mapas de estoques de AGB e mudanças em uma floresta tropical seletivamente explorada com RMSE inferior a 50 Mg.ha<sup>-1</sup> e R<sup>2</sup> adj. = 0,70 em um tamanho de pixel de 50 m x 50 m. A média de AGB para toda a área em 2012 foi de 244,16 Mg.ha<sup>-1</sup>, enquanto em 2014 e 2017, a média prevista foi de 263,22 e 250,84 Mg.ha<sup>-1</sup>, respectivamente. Com a realização deste estudo foi modelar a AGB em uma floresta seletivamente explorada a partir de dados de inventários florestal e de métricas LiDAR. No total, apenas seis métricas foram necessárias para a modelagem, e a métrica Altura Média foi a que apresentou maior contribuição para o modelo. Entre as abordagens estatísticas testadas, melhores estimativas de biomassa foram obtidas em OLS, com este foi possível gerar mapas dos estoques de AGB com precisão. Assim, os resultados deste capítulo indicam que este estudo pode servir de base para programas como o REDD+, além de ajudar a entender as mudanças causadas por atividades de exploração seletiva.

Palavras-chaves: Amazônia, Aprendizado de Máquina, Mapeamento.

## CHAPTER IV: COMPARISON OF STATISTICAL MODELLING APPROACHES FOR ABOVEGROUND BIOMASS STOCK AND DYNAMICS ESTIMATION FROM LIDAR DATA IN SELECTIVELY LOGGED TROPICAL FOREST

### ABSTRACT

The estimation of aboveground biomass (AGB) has been one of the major challenges of remote sensing science for monitoring changes in carbon storage in recent years. The impacts of different modeling techniques on the estimation of AGB stocks and changes using field data and airborne LiDAR in a selectively logged tropical forest in eastern Amazonia were evaluated. Field-derived AGB was estimated from 85 square plots of  $50 \times 50$  m in 2014. The LiDAR data were obtained in 2012, 2014 and 2017. Models at plot level were first developed using 6 descriptive statistics based on PCA analysis and four machine learning approaches were implemented: random forest (RF), support vector machine (SVM), artificial neural networks (ANN), and some variations of k-nearest neighbors (k-NN); their performance was compared to that of a linear regression model (OLS). The results showed that OLS had the best performance among the algorithms with an RMSE of  $46,94 \text{ Mg}\cdot\text{ha}^{-1}$  in the leave-one-out cross-validation (LOOCV). RF and SVM also performed moderately well and showed an RMSE in the LOOCV of  $55,80$  and  $56,24 \text{ Mg}\cdot\text{ha}^{-1}$ , respectively. NNA and KNN variations produced higher RMSE than the others - greater than  $64 \text{ Mg}\cdot\text{ha}^{-1}$ . The best model was used to map AGB stocks and changes in a selectively logged tropical forest at a grid size of  $50\text{m} \times 50\text{m}$  with a RMSE of less than  $50 \text{ Mg}\cdot\text{ha}^{-1}$  and  $R^2 \text{ adj} = 0,70$ . The AGB mean for the entire area in 2012 was  $244,16 \text{ Mg}\cdot\text{ha}^{-1}$ , while in 2014 and 2017 the mean values predicted were  $263,22$  and  $250,84 \text{ Mg}\cdot\text{ha}^{-1}$ , respectively. This study showed that it was possible modeling the AGB in a forest selectively exploited using forest inventory data and of LiDAR metrics. In total, only six metrics were required for the modeling, and the Height Mean metric showed the greatest contribution to the model. Among the statistical approaches tested, better estimates of biomass were obtained in OLS, using this it was possible to generate maps of AGB stocks accurately. Thus, the results of this chapter show that this study can serve as a basis for programs such as REDD +, as well as help in understanding changes caused by selective logging activities.

Keywords: Amazon, Machine Learning, Mapping.

## 7.1. INTRODUÇÃO

Entre os ecossistemas terrestres, as florestas agem como "freios" naturais na mudança climática global, pois sequestram e armazenam mais carbono do que outros ecossistemas (GIBBS et al., 2007; THOMSON et al., 2010). Pesquisadores têm dado cada vez mais atenção às florestas tropicais devido à sua importância relativa no ciclo global de carbono (MOORE et al., 2018). A floresta amazônica se destaca como a maior área contínua de floresta tropical (HIGUCHI et al., 2006), cobrindo cerca de 4 milhões de km<sup>2</sup> (PEREIRA et al., 2010). Sua grande extensão é extremamente importante, pois pode emitir ou sequestrar volumes significativos de dióxido de carbono (PHILLIPS et al., 2008, LINDSELL; KLOP, 2013). Florestas tropicais são conhecidas como grandes sumidouros de carbono (HOOIJER et al., 2010), entre essas, reservas florestais amazônicas estocam um quinto do carbono total da vegetação terrestre global (MALHI et al., 2008), representando assim o maior reservatório de carbono na forma de biomassa no planeta (MALHI et al., 2008; BETTS, 2006).

A exploração seletiva é uma técnica florestal que é realizada em floresta tropical e tem sido uma atividade importante que afeta o uso e cobertura da terra (ASNER et al., 2005; VIDAL et al., 2016; SILVA et al., 2017) modificando substancialmente os fluxos de carbono (HANSEN et al., 2013). Além disso, a extração seletiva de madeira ou outras práticas de colheita podem degradar o ambiente florestal se excederem o rendimento florestal sustentável (PEARSON et al., 2014). No entanto, o uso correto de técnicas florestais, como a extração seletiva de árvores, não precisa constituir uma fonte de degradação florestal (FERREIRA et al., 2015). Alguns estudos científicos mostraram que a extração de madeira bem planejada pode permitir a recuperação total dos estoques de carbono (MAZZEI et al., 2010; RUTISHAUSER et al., 2015), que podem ser monitorados estimando estoques e mudanças na biomassa acima do solo (AGB).

O crescimento das árvores, a mortalidade e as perturbações florestais alteram os fluxos de carbono ao longo do tempo, influenciados por perturbações naturais e antropogênicas (CHAZDON, 2003). Além disso, incentivos econômicos foram criados para favorecer o sequestro de carbono nas florestas, comumente referido como REDD + (Redução de Emissões por Desmatamento e Degradação Florestal) (MILES; KAPOS, 2008; AGRAWAL et al., 2011), embora sua implementação dependa criticamente da confiabilidade de protocolos de monitoramento de carbono baseados em terra, relatórios e verificação (MRV) do armazenamento de carbono (CHAVE et al., 2014). Neste sentido, devido ao alto potencial de crescimento das florestas tropicais na conversão de carbono atmosférico em

biomassa, especialmente em comparação com outros ecossistemas terrestres, uma estimativa precisa da estrutura da floresta e da biomassa é essencial para a compreensão e gestão do ciclo global de carbono (MARVIN et al., 2014, MOLINA et al., 2016). O monitoramento de florestas em regiões tropicais é um desafio, e os levantamentos de campo demandam muitos recursos e são muito limitados em extensão e frequência (LAURIN et al., 2014).

Estimativas precisas de parâmetros estruturais da floresta e monitoramento de suas mudanças ao longo do tempo são essenciais para os inventários florestais e modelos de crescimento, bem como modelagem do ciclo de carbono e sistemas de manejo florestal (NÆSSET et al., 2004). O uso de dados de LiDAR aerotransportado ganhou destaque na estimativa de características biofísicas da floresta, como a altura do dossel e a área basal (HUDAK et al. 2009, ASNER et al., 2009). Além disso, LiDAR aerotransportado e técnicas de sensoriamento remoto foram usadas com sucesso para estimar a biomassa acima do solo em vários ecossistemas florestais (NÆSSET et al., 2011; ASNER et al., 2009; ZOLKOS et al., 2013; CLARK et al., 2011) e têm imenso potencial para melhorar a compreensão da magnitude da mudança de carbono da biomassa em múltiplas escalas (HOUGHTON, 2005), incluindo a exploração seletiva (ANDERSEN et al., 2014; SILVA et al., 2017; LEI et al., 2018). Além disso, os métodos de sensoriamento remoto podem ser aplicados até mesmo em áreas florestais remotas, onde o monitoramento baseado em dados de campo dos estoques de carbono florestal é caro e difícil.

Atualmente, existem vários métodos de modelagem estatística usados para estimar a AGB a partir de dados LiDAR, que são variados em suas suposições e complexidade (KOCH, 2010; GLEASON; IM, 2012). Alguns autores utilizaram técnicas de regressão linear para prever a AGB (ENGLHART et al., 2013; ANDERSEN et al., 2014; RÉJOU-MÉCHAIN et al., 2015), enquanto outros autores utilizaram métodos não-paramétricos, como Floresta Aleatória (RF), k-vizinho mais próximo (kNN) e Máquina Vetorial de Suporte (SVM) (PFLUGMACHER et al., 2014; ESKELSON et al., 2009). Embora modelos derivados de LiDAR sejam geralmente desenvolvidos com base em regressão linear para a estimativa de parâmetros estruturais de floresta regredidos a partir de métricas LiDAR (GARCÍA-GUTIÉRREZ et al., 2015), faltam estudos que compararam métodos de modelagem para estimativa de mudança de AGB em floresta tropical seletivamente explorada, assim, preencher esse vazio é crucial não apenas para estimar os estoques da AGB, mas também para monitorar as mudanças da AGB ao longo do tempo (KOCH, 2010). Métodos de aprendizado de máquina são comumente usados para identificar estruturas em dados complexos, muitas vezes não-lineares (OLDEN et al., 2008), e podem ser mais eficazes do que a regressão

tradicional, entretanto poucos estudos compararam a acurácia e a precisão de múltiplas abordagens de aprendizado de máquina à regressão linear. Embora o LiDAR aerotransportado possa facilitar estimativas oportunas e espacialmente explícitas da estrutura da floresta na floresta tropical, ainda existem conflitos entre as técnicas de modelagem.

## HIPÓTESE

Modelos podem ser simplificados e ainda manter um nível adequado de precisão para a estimativa de mudanças da AGB em florestas tropicais.

## 7.2. OBJETIVOS

Este estudo objetivou modelar a AGB em nível de parcela para uma floresta tropical usando dados LiDAR aerotransportados, para então estimar e mapear em nível de paisagem a dinâmica da AGB. Para isso, foram comparadas quatro abordagens de aprendizado de máquina com o método tradicional de regressão linear.

Os seguintes objetivos foram incluídos no escopo do estudo:

(i) Avaliar o desempenho de algoritmos de aprendizado de máquina, Floresta Aleatória (RF), Máquina Vetorial de Suporte (SVM), Redes Neurais Artificiais (RNA) e algumas variações de  $k$  Vizinhos mais Próximos ( $k$ -NN) com o modelo de regressão linear (OLS);

(ii) Estimar o estoque de AGB no nível da paisagem usando o melhor modelo da etapa anterior; e

(iii) Avaliar como o Manejo de exploração madeireira de impacto reduzido, pode afetar a dinâmica da biomassa das florestas tropicais.

## 7.3. MATERIAL E MÉTODOS

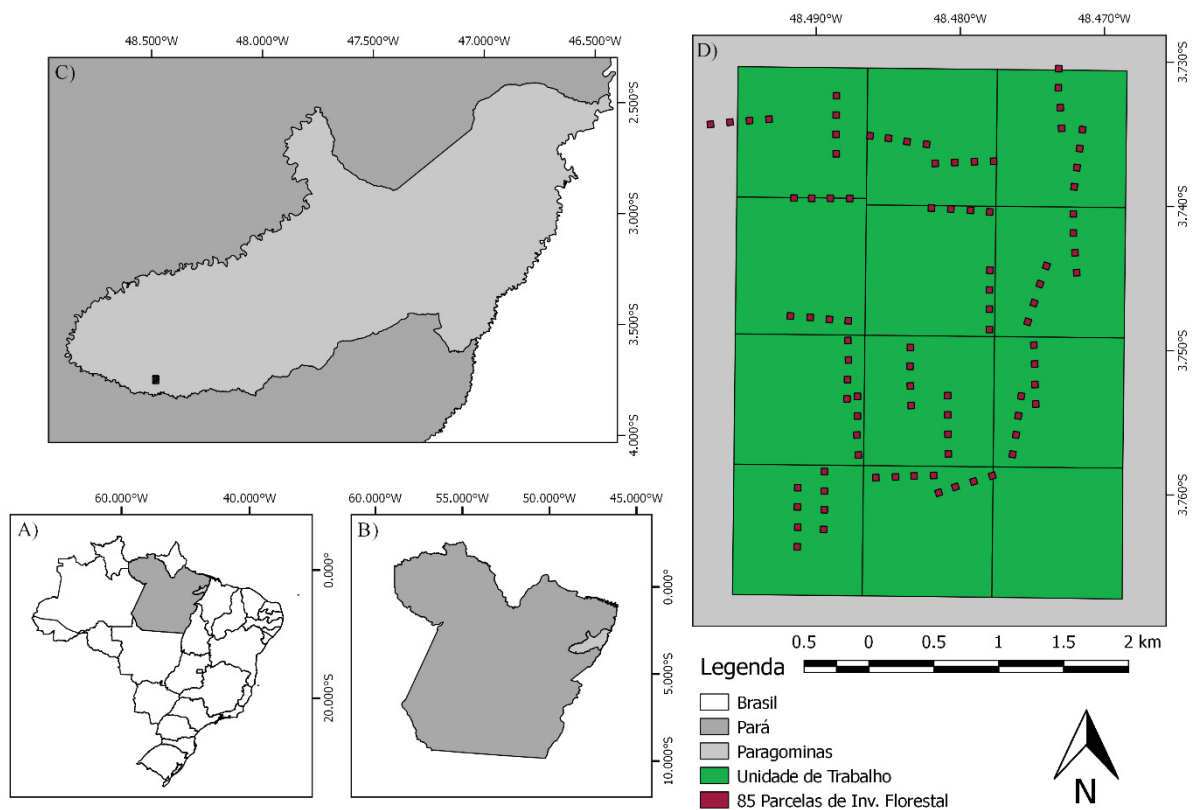
### 7.3.1. Área de estudo

Para o desenvolvimento deste estudo sentiu-se a necessidade de alterar a área de estudo em relação à área do capítulo anterior. Essa alteração se justifica pelo fato dos impasses previamente encontrados no capítulo III, onde a base de dados apresentava um conjunto limitado de informações e com diferenças entre os mesmos, o que seria impraticável e insuficiente para a abordagem deste capítulo. Assim, este estudo foi realizado na Fazenda

Cauaxi, no Município de Paragominas, estado do Pará, Brasil (FIGURA 11). O estado do Pará está localizado no Leste da Amazônia, onde o desmatamento e a exploração madeireira são partes integrantes da economia há décadas (FEARNSIDE, 2005; FEARNSIDE, 2007). O clima na Fazenda Cauaxi é tropical úmido, e a média anual total de precipitação é de 2200 mm (COSTA; FOLEY, 1998; IBGE, 1988).

Na Fazenda Cauaxi encontra-se sediado o Centro de Manejo Florestal Roberto Bauch, onde o Instituto Floresta Tropical (IFT) desenvolve atividades de treinamento e pesquisa em manejo florestal desde o ano 1995. Em total são 5.000 ha que administra o IFT entre as Fazendas Cauaxi e Rio Capim, cumprindo com os princípios e critérios estabelecidos pelo FSC, que conciliam interesse e viabilidade ambiental com benefícios sociais. Por ser uma área particular não existem pressões de populações humanas locais, e atividades de caça e pescas estão proibidas; Desta maneira, a retirada de madeira é a única atividade antrópica (CARDONA, 2012).

FIGURA 11 - MAPA DE LOCALIZAÇÃO DA ÁREA DE ESTUDO NA FAZENDA CAUAXI LOCALIZADA NO LESTE DA AMAZÔNIA.



FONTE: O AUTOR (2018).

### 7.3.2. Dados de campo

Os dados do inventário florestal utilizado no estudo foram coletados no ano de 2014. Um total de 85 parcelas de 50 m × 50 m (0,25 ha) foram espaçadas em intervalos de 100 m ao longo dos transectos. Para cada parcela, uma sub-parcela ao longo de um dos lados da parcela com dimensões de 5 m × 50 m (250 m<sup>2</sup>) foram demarcadas. Dois métodos de amostragem foram usados para coletar os dados da pesquisa: no nível da parcela, todas as árvores com diâmetro à altura do peito (DAP = 1,30 m) igual ou maior que 35 cm foram medidas, enquanto árvores com DAP igual ou maior que 10 cm foram medidos apenas na área das sub-parcelas. A biomassa acima do solo (AGB) das parcelas e sub-parcelas foi obtida pela agregação dos valores individuais de biomassa das árvores e conversão para Mg.ha<sup>-1</sup>. A árvore individual AGB foi estimada para cada árvore usando uma equação alométrica desenvolvida por (CHAVE et al., 2014) (eq.4):

$$AGB(kg) = \exp[-1,803 - 0,976E + 0,976\ln(\rho) + 2,673\ln(dap) - 0,0299[\ln(dap)]^2] \text{ Eq.4}$$

Onde:

AGB (kg) é a biomassa acima do solo em kg; dap é o diâmetro na altura do peito (1,30 m) e  $\rho$  é a densidade da madeira. A variável E é uma medida do estresse ambiental, que relaciona informações de sazonalidade da temperatura, déficit hídrico climático e sazonalidade da precipitação. Nesta área de estudo,  $E = -0,103815$ .

### 7.3.3. Dados LiDAR e processamento

Os dados LiDAR aerotransportados utilizados neste estudo foram adquiridos em 2012, 2014 e 2017, e também fazem parte do projeto Paisagens Sustentáveis, o qual foi descrito com maiores informações no capítulo anterior. A TABELA 3 apresenta os atributos de dados do sensor de LiDAR e características de voo.

TABELA 3 - ESPECIFICAÇÕES DOS CONJUNTOS DE DADOS LIDAR AEROTRANSPORTADO.

Especificações	2012	2014	2017
Data de aquisição	27–29 Julho	26–27 Dezembro	12 de Dezembro
Datum	Sirgas 2000	Sirgas 2000	Sirgas 2000
Densidade média	13,89 ppm <sup>2</sup>	37,5 ppm <sup>2</sup>	22,61 ppm <sup>2</sup>
Altura do voo	850 m	850 m	850 m
Campo de visão	11 °	12 °	15°
Frequência	59,8 Hz	83,0 Hz	40 Hz
Porcentagem de cobertura	65%	65%	70%

FONTE: O AUTOR (2018).

O processamento dos dados LiDAR foi realizado utilizando o *software* FUSION / LDV toolkit versão 3,60 (MCGAUGHEY, 2016) e Lastools (ISENBURG, 2018). Primeiro, a densidade de pulso de LiDAR foi reduzida para 12 pulsos / m<sup>2</sup> e a ferramenta de *catalog* foi utilizada para produzir o relatório descritivo do conjunto de dados LiDAR. Em seguida, os retornos de solo foram classificados usando o algoritmo de densificação da *Progressive Triangulated Irregular Network* (TIN) implementado em Lasground (ISENBURG, 2018) (configurações: step = 10 m, bulge = 0,5 m, spike = 1 m, offset = 0,05 m) DTMs de 1 m foram criados para cada um dos conjuntos de dados de densidade de pulso reduzido usando o utilitário *blast2dem* em Lastools (ISENBURG, 2018).

A normalização das alturas foi realizada com o comando *ClipData*, enquanto o comando *PolyClipdata* foi utilizado para realizar o corte das parcelas medidas no campo. A partir do comando *CloudMetrics*, as métricas LiDAR derivadas dos gráficos foram extraídas. Foram selecionadas algumas métricas para a modelagem; essas métricas são mostradas na TABELA 4.

TABELA 4 - MÉTRICAS DE ESTRUTURA DERIVADA DE LIDAR CONSIDERADAS COMO VARIÁVEIS PREDITORAS CANDIDATAS.

Variável	Descrição	Variável	Descrição
HMAX	Altura Máxima	HP40	Percentil 40 da altura
HMEAN	Altura Média	HP50	Percentil 50 da altura
HMODE	Moda da Altura	HP60	Percentil 60 da altura
HSD	Desvio padrão da altura	HP70	Percentil 70 da altura
HVAR	Variância da altura	HP75	Percentil 75 da altura
HCV	Coeficiente de variação	HP80	Percentil 80 da altura
HIQ	Distância interquartil da altura acima do solo	HP90	Percentil 90 da altura
HSKEW	Assimetria da altura	HP95	Percentil 95 da altura
HKURT	Curtose da altura	HP99	Percentil 99 da altura
HP20	Percentil 20 da altura	CRR	Canopy relief ratio ((HMEAN - HMIN)/(HMAX - HMIN))
HP25	Percentil 25 da altura	COV	Cobertura de copa (Porcentagem de primeiro retorno acima de 2.00m)
HP30	Percentil 30 da altura		

FONTE: O AUTOR (2018).

#### 7.3.4. Desenvolvimento e Avaliação de Modelagem

Como etapa preliminar da modelagem de AGB, foi realizada a análise de componentes principais (PCA) para seleção de variáveis (WOLD et al., 1987). A PCA foi aplicada sob as métricas LiDAR para selecionar as melhores métricas de previsão, bem como as métricas com maior probabilidade de contribuir para o desenvolvimento do modelo. Na PCA autovetores foram identificados e inspecionados em cada PC (por exemplo, SILVA et al., 2016). Foi aplicada a função *prcomp* de função em ambiente R (R DEVELOPMENT CORE TEAM, 2018) para conduzir a análise de componentes principais nas métricas de LiDAR.

#### 7.3.5. Abordagens de modelagem

Após a seleção das variáveis, foram testadas cinco abordagens de modelos estatísticos para estimar e mapear os estoques e as mudanças de AGB em floresta tropical da seguinte forma:

i) Mínimos quadrados ordinários (OLS - *Ordinary least-squares*). Este é o método mais comum para modelar e prever a AGB a partir de dados baseados em LiDAR. O modelo OLS foi implementado na linguagem R e usamos o pacote “*lm*”.

ii) Floresta Aleatória (RF - *Random Forest*). O algoritmo RF foi implementado no *software* estatístico R, usando o pacote *randomForest* (LIAW; WIENER, 2002). Em RF, a *n*tree foi definida como 1000 e os outros parâmetros (por exemplo, *mtry*) foram deixados no modo padrão de RF.

iii) k-Vizinhos Mais Próximos (k-NN). O método k-NN é um método não-paramétrico usado para classificação e regressão (ALTAMAN, 1992). Neste estudo, k-NN foi carregado com o pacote *yaImpute* (CROOKSTON; FINLEY, 2008) no *software* estatístico R. Para cada imputação, foi definido k = 1 vizinhos para manter a variação original nos dados (HUDAK et al., 2008). Os métodos de imputação utilizados foram: *Euclidean*, *Mahalanobis*, *Most Similar Neighbor* (MSN), *Independent Component Analysis* (ICA), *Random Forest* (RF), and RAW (sem peso) (CROOKSTON; FINLEY, 2008).

iv) Máquina de vetores de suporte (SVM). Esta é uma técnica de aprendizagem estatística não-paramétrica supervisionada (MOUNTRAKIS et al., 2011). O algoritmo SVM foi carregado usando o pacote (*e1071*) (DIMITRIADOU et al., 2008). A Função de Base Radial para a função Kernel foi selecionada.

v) Rede Neural Artificial (RNA). Este é um modelo matemático que simula o sistema de redes neurais biológicas (KOHONEN, 1988). Normalmente, uma rede neural consiste em três camadas de neurônios: camada de entrada, camada oculta e camada de saída. A RNA foi executada em ambiente R usando os pacotes *nnt* (VENABLES; RIPLEY, 2002).

### 7.3.6. Estimativa e mapeamento de alterações da AGB

Diferentes abordagens de aprendizados de máquina foram testadas para modelar a AGB em 2014, entretanto, o melhor desempenho entre os métodos foi utilizado para prever e mapear os estoques da AGB em 2012, 2014 e 2017 nos níveis de parcela e de paisagem. A estimativa da mudança da AGB foi então calculada como a diferença na previsão da AGB de 2012 a 2014, 2012 a 2017 e 2014 a 2017.

$AGB_{2012}(\text{Mg/ha}) = f$  (métricas LiDAR 2012; parâmetros do modelo baseado em 2014).

$AGB_{2014}(\text{Mg/ha}) = f$  (métricas LiDAR 2014; parâmetros do modelo baseado em 2014).

$AGB_{2017}(\text{Mg/ha}) = f$  (métricas LiDAR 2017; parâmetros do modelo baseado em 2014).

$$\Delta AGB_{(2014-2012)} = AGB_{2014} - AGB_{2012}$$

$$\Delta AGB_{(2017-2012)} = AGB_{2017} - AGB_{2012}$$

$$\Delta AGB_{(2017-2014)} = AGB_{2017} - AGB_{2014}$$

onde:

AGB é o estoque de AGB (Mg / ha) e  $\Delta AGB$  é a mudança de AGB (Mg / ha). A validação cruzada *leave-one-out* (LOOCV) foi desenvolvida, (por exemplo, SILVA et al., 2016; SILVA et al., 2017), e a precisão de predição dos modelos LOOCV foi avaliada em termos de coeficiente de determinação ( $R^2$ ), erro médio quadrático absoluto e relativo (RMSE) e o desvio absoluto e relativo da relação linear entre os valores observados e os valores esperados de AGB da LOOCV:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}}$$

Eq. 5

$$Bias = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)$$

Eq. 6

onde  $n$  é o número de parcelas,  $y_i$  é o valor observado para a parcela  $i$  e  $\hat{y}_i$  é o valor previsto para a parcela  $i$ . Além disso, o RMSE e o viés relativos foram calculados dividindo o RMSE absoluto e o viés (Equações (5) e (6)) pela média observada da AGB. Para ter uma precisão de previsão igual ou superior a um inventário florestal convencional na floresta tropical, definiu-se acurácia do modelo aceito como RMSE e viés relativos de  $\leq 20\%$  (SILVA et al., 2017). Para verificar a normalidade dos dados foi utilizado o teste de Shapiro-Wilk.

Uma análise de incerteza do nível de paisagem para os estoques de  $\widehat{AGB}_{2012}$ ,  $\widehat{AGB}_{2014}$  e  $\widehat{AGB}_{2017}$  também foi realizada integrando os erros de nível de pixel e representando a

autocorrelação espacial dos erros da seguinte forma (MCROBERTS, 2006; WEISBIN et al., 2014; GARCIA et al; 2017 SILVA et al., 2017).

$$\widehat{\sigma^2_{AGB}} = \frac{1}{m^2} \sum_{i=1}^m \sum_{i<j}^m cov(\sigma_i, \sigma_j) = \frac{1}{m^2} \left( \sum_{i=1}^m \sigma^2 + 2 \sum_{i=1}^m \sum_{i<j}^m \rho(d) \sigma_i \sigma_j \right)$$

onde:

$\widehat{\sigma^2_{AGB}}$  é a variância do estimador para o estoque médio de AGB para toda a área de estudo;  $m$  é o número de pixels na área;  $\rho(d)$  é a função de autocorrelação espacial da distância,  $d$ , baseada em um modelo exponencial de semi-variograma; e  $\sigma_i$  é o erro padrão estimado dos valores de estoque da AGB no  $i$ -ésimo pixel.

Por fim, os estoques da AGB em 2012, 2014 e 2017 e as mudanças da AGB dos mapas finais foram os descritos em McRoberts et al. (2014):

$$\Delta_{AGB_0} = \frac{1}{N} \sum_{i=1}^N (\widehat{AGB}_i^{t2} - \widehat{AGB}_i^{t1}) - \frac{1}{n} \sum_{p_i \in S} [(\widehat{AGB}_i^{t2} - \widehat{AGB}_i^{t1}) - (AGB_i^{t2} - AGB_i^{t1})]$$

onde:

$N$  é o tamanho da população,  $n$  é o tamanho da amostra,  $\widehat{AGB}_i^t$  é a previsão do modelo em momentos diferentes, e  $AGB_i^{t2}$  representa a biomassa observada em cada momento. O segundo elemento da equação representa o viés do estimador inicial de mudança de biomassa.

A variância do estimador foi calculada como:

$$\widehat{var}(\widehat{\Delta}) = \frac{1}{n(n-1)} \sum_{p_i \in S} [\varepsilon_i - \bar{\varepsilon}],$$

onde:

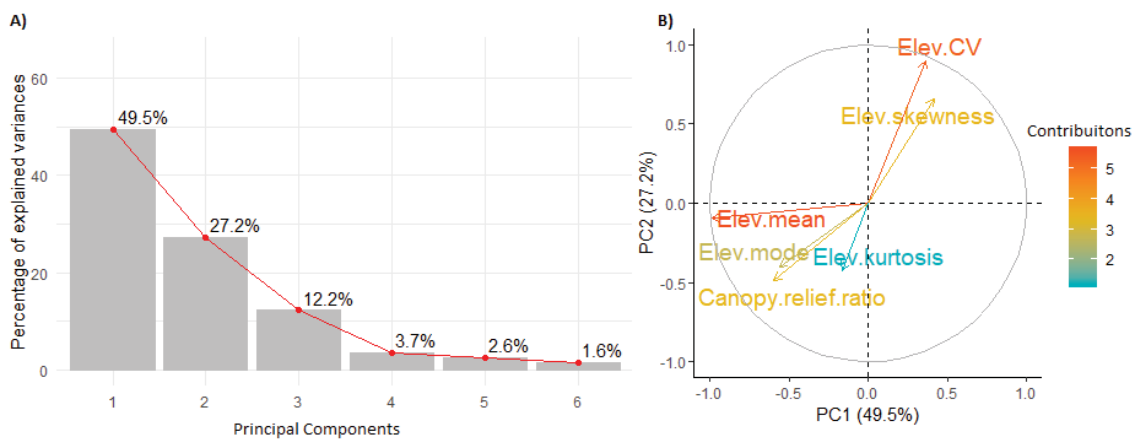
$\varepsilon_i$  é o erro de previsão do modelo e  $\bar{\varepsilon}$  é o erro médio do modelo.

## 7.4. RESULTADOS

### 7.4.1. PCA e seleção de variáveis

A PCA indicou que a primeira componente principal é responsável por 49,5% da variação em todo o conjunto de dados LiDAR. Além disso, os primeiros seis componentes que foram utilizados para a modelagem representam mais de 97% da variância total das 23 métricas LiDAR, uma vez que os três primeiros componentes principais apresentaram cerca de 90% da variação total contida nas métricas LiDAR selecionadas. Para cada componente principal, foi selecionada uma métrica, baseada no maior valor contido dos autovetores; neste sentido, foram selecionadas as seguintes métricas: PC1 representada por Altura Média; PC2: Coeficiente de Variação da Altura; PC3: Curtose da altura; PC4: Cobertura de copa; PC5: Moda da Altura; PC6: Assimetria da Altura. Os primeiros seis componentes principais podem substituir as métricas originais de LiDAR, reduzindo o tamanho do conjunto de dados e a redundância. O resultado da contribuição de cada PC e a projeção de cada métrica são mostrados na FIGURA 12. A TABELA 5 representa os autovalores e os autovetores de cada componente principal.

FIGURA 12 - (A) A PORCENTAGEM DE VARIAÇÃO EXPLICADA PELOS SEIS PCS. (B) PROJEÇÃO DAS DUAS PRIMEIRAS PONTUAÇÕES DE PC DAS MÉTRICAS DE LIDAR SELECIONADAS.



FONTE: O AUTOR (2018).

TABELA 5 - CÁLCULOS DE AUTOVALORES E AUTOVETORES PARA OS PRIMEIROS CINCO PCS

PCs	Ev	Eigenvectors (Eg)					
		HMEAN	HCV	HKUR	COV	HMOD	HSKEW
PC1	3,37	<b>-0,29</b>	0,10	-0,04	-0,17	-0,16	0,12
PC2	2,49	-0,03	<b>0,36</b>	-0,16	-0,19	-0,16	0,26
PC3	1,67	0,04	-0,08	<b>0,44</b>	-0,32	0,01	0,31
PC4	0,91	0,01	-0,04	-0,37	<b>0,79</b>	0,04	0,09
PC5	0,77	-0,07	0,08	-0,08	-0,17	<b>0,88</b>	-0,06
PC6	0,60	-0,02	0,10	0,25	-0,15	-0,31	<b>-0,37</b>

FONTE: O AUTOR (2018).

#### 7.4.2. Modelagem e Avaliação

O desempenho dos métodos de aprendizado de máquina é apresentado na TABELA 6, que apresenta todas as estatísticas que foram produzidas pelo processo de validação, e por questões visuais, apenas os dois melhores métodos foram expostos em forma de figura e podem ser visualizados na FIGURA 13.

Os métodos utilizados neste estudo apresentaram valores de  $R^2$  adj próximo a 70% através do processo de validação (LOOCV). O melhor desempenho foi verificado para o OLS, que produziu valores melhores que os demais métodos em relação a  $R^2$  adj e RMSE e RMSE%, sendo respectivamente, os valores 0,70, 46,94 Mg.ha<sup>-1</sup> e 19,72%. O algoritmo RF apresentou um desempenho semelhante ao OLS, porém, o desempenho foi inferior em termos de  $R^2$  adj, RMSE% e RMSE. A maior diferença entre OLS e RF é encontrada em  $R^2$  adj, onde o RF produziu um valor próximo a 0,60%, enquanto o OLS produziu um valor de 70%. Embora o OLS tenha produzido o melhor desempenho, os valores de RMSE e viés para os dois algoritmos demonstraram desempenho semelhante.

O algoritmo SVM pode ser classificado como o terceiro melhor desempenho. Este algoritmo apresentou desempenho semelhante ao algoritmo RF, porém com valores menores em todos os parâmetros avaliados. Em geral, o algoritmo apresentou valores de 0,58 de  $R^2$  adj, 23,62 Mg.ha<sup>-1</sup> de RMSE e 0,67 Mg.ha<sup>-1</sup> de viés. As seis derivações do algoritmo  $k$ -NN que foram testadas, apresentaram valores de  $R^2$  adj variando de 0,35 a 0,53. Os valores de RMSE, variaram de 64,52 a 75,90 Mg.ha<sup>-1</sup> e os valores de RMSE % variaram de 27,10 a 31,88%. Já os valores de viés e viés % variaram respectivamente de -1,55 a -4,44 Mg.ha<sup>-1</sup> e de

-0,65 a 1,85%. Para as variações deste algoritmo, pode-se dizer que o melhor desempenho foi verificado no algoritmo *k*-NN MSN, que produziu os melhores valores dos parâmetros estatísticos avaliados, enquanto o pior desempenho foi para o algoritmo *k*-NN.raw, que apresentou os menores valores. Apesar do pior desempenho do *k*-NN.raw, este algoritmo produziu melhores valores de viés entre os as imputações de *k*-NN.

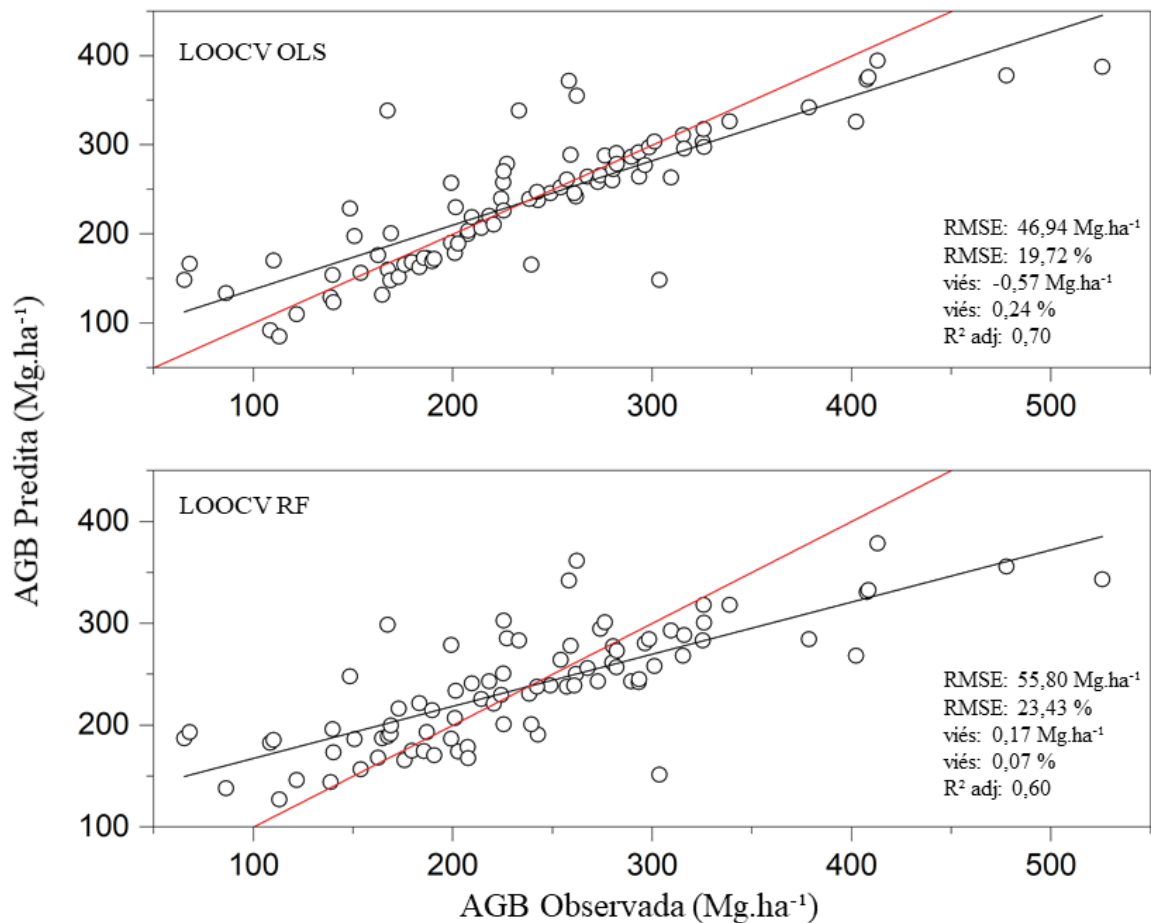
Por fim, o RNA apresentou o pior desempenho entre os algoritmos de aprendizado de máquina. As estatísticas encontradas para o RNA mostraram que esse algoritmo não conseguiu modelar a AGB usando as métricas selecionadas. Resumindo, o RNA apresentou os maiores valores de RMSE absoluto e relativo, bem como maiores valores de viés, embora tenha apresentado um valor intermediário de  $R^2$  adj (0.55). A estimativa da AGB com as métricas LiDAR foi realizada usando o melhor modelo de todas as abordagens testadas. O melhor modelo para estimar a biomassa usando métricas de LiDAR foi o OLS (TABELA 6, FIGURA 13:  $R^2$  adj = 0,70, RMSE = 44,94 Mg.ha<sup>-1</sup>, viés = -0,57 Mg.ha<sup>-1</sup>).

TABELA 6 - MODELOS DE REGRESSÃO E DE AM PARA ESTIMATIVA DE AGB BASEADOS EM MÉTRICAS LIDAR UTILIZANDO PARCELAS DE CAMPO (N = 85).

Métodos	Métricas LiDAR	$R^2$ adj.	RMSE		viés	
			Mg.ha <sup>-1</sup>	%	Mg.ha <sup>-1</sup>	%
OLS		0,70	46,94	19,72	-0,57	0,24
RF		0,60	55,80	23,43	0,17	0,07
SVM		0,58	56,24	23,62	1,59	0,67
RNA		0,55	124,7	52,76	110,6	46,78
<i>k</i> -NN mahalanobis	H.Mean + H.CV + H.Kurt + COV +	0,39	73,02	30,67	-4,67	-1,96
<i>k</i> -NN msn	H.Mode + H.Skew	0,53	64,52	27,10	-4,40	-1,85
<i>k</i> -NN ica		0,39	73,02	30,67	-4,67	-1,96
<i>k</i> -NN rf		0,43	71,02	29,83	-4,39	1,84
<i>k</i> -NN raw		0,35	75,90	31,88	-1,55	-0,65
<i>k</i> -NN euclidean		0,48	66,90	28,10	-4,10	-1,72

FONTE: O AUTOR (2018).

FIGURA 13 - VALORES PREVISTOS E OBSERVADOS PARA BIOMASSA ACIMA DO SOLO PARA OS MODELOS TESTADOS USANDO VARIÁVEIS SELECIONADAS A PARTIR DE MÉTRICAS DE LIDAR.



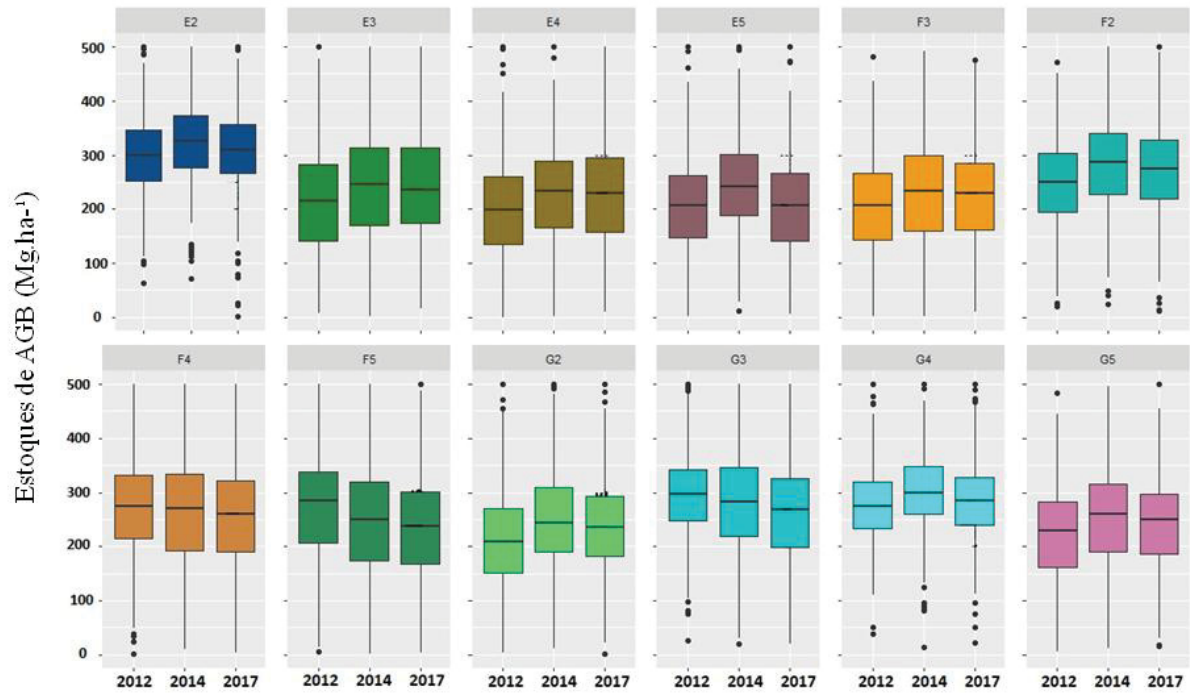
FONTE: O AUTOR (2018).

#### 7.4.3. Mapeamento e incerteza da mudança de biomassa acima do solo

Em relação à incerteza da AGB para toda a área, em 2012 a média prevista foi de 244,16 Mg.ha<sup>-1</sup>, enquanto em 2014 e 2017 a média prevista foi de 263,22 e 250,84 Mg.ha<sup>-1</sup>, respectivamente. Para as unidades de trabalho, em 2012, foram encontrados valores médios variando de 200 ( $\pm 91,21$ ) a 296 ( $\pm 74,71$ ) Mg.ha<sup>-1</sup>. Já em 2014 e 2017 foram encontrados valores médios de 228,56 ( $\pm 95,87$ ) a 324,20 ( $\pm 77,90$ ) Mg.ha<sup>-1</sup> e 210,51 ( $\pm 89,88$ ) a 303,81 ( $\pm 78,77$ ) Mg.ha<sup>-1</sup>, respectivamente. As estimativas de estoques da AGB no nível da parcela são mostradas na FIGURA 14 e também descritas na TABELA 7. Em geral, as unidades de trabalho apresentaram valores próximos e semelhantes, dentre as 12 unidades de trabalho, 5 delas apresentaram valores menores de 220,00 Mg.ha<sup>-1</sup> de estoque de AGB em 2012, enquanto que em 2014, todas as unidades de trabalho apresentaram valores superiores a 220

Mg.ha<sup>-1</sup>, representando um aumento dos estoques da AGB. No entanto, em 2017 todas as unidades de trabalho tiveram perda de AGB em relação a 2014.

FIGURA 14 - BOXPLOT DAS ESTIMATIVAS DE ESTOQUES DA AGB NO NÍVEL DA PARCELA PARA 2012, 2014 E 2017.



FONTE: O AUTOR (2018).

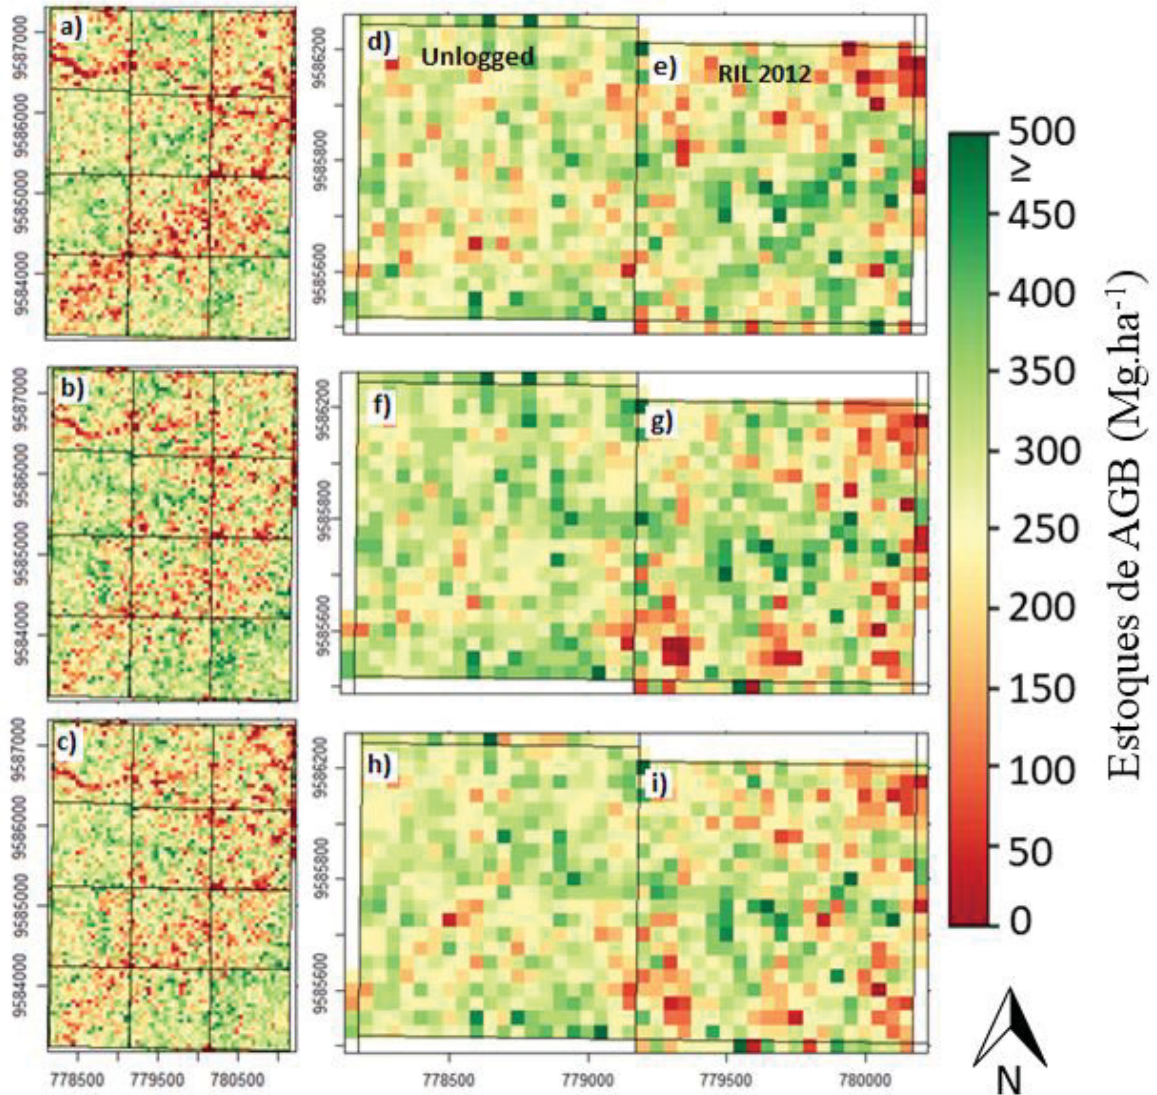
TABELA 7 - MÉDIA E DESVIO PADRÃO (SD) PARA O MODELO DE AGB BASEADO EM MÉTRICAS LIDAR EM 2014. STD ERROR É O ERRO PADRÃO ESTIMADO DERIVADO DA ANÁLISE DE INCERTEZA.

UT	AGB 2012 (Mg.ha <sup>-1</sup> )			AGB 2014 (Mg.ha <sup>-1</sup> )			AGB 2017 (Mg.ha <sup>-1</sup> )		
	Média	sd	Std Error	Média	sd	Std Error	Média	sd	Std Error
<b>E2</b>	296,59	74,71	3,66	324,21	77,90	3,80	303,81	78,78	3,87
<b>E3</b>	217,48	100,63	5,14	249,84	103,69	5,26	244,87	99,01	4,99
<b>E4</b>	200,24	91,21	4,94	228,56	95,87	5,04	226,65	94,54	5,07
<b>E5</b>	210,32	87,83	4,34	246,66	88,36	4,33	210,51	89,89	4,45
<b>F2</b>	249,82	81,86	4,21	286,04	86,13	4,40	274,85	84,71	4,31
<b>F3</b>	203,07	88,58	4,74	231,27	97,66	5,05	226,49	93,21	4,81
<b>F4</b>	279,31	90,97	4,57	267,57	103,72	5,28	257,08	98,79	4,94
<b>F5</b>	273,54	93,87	4,63	246,66	105,92	5,20	233,96	92,71	4,55
<b>G2</b>	205,56	89,18	4,55	245,20	88,02	4,49	238,06	86,07	4,36
<b>G3</b>	292,39	77,41	3,92	276,79	93,37	4,75	261,80	90,10	4,58
<b>G4</b>	272,78	66,15	3,22	300,20	69,22	3,37	284,95	68,34	3,33
<b>G5</b>	218,73	88,15	4,66	251,07	87,72	4,57	243,30	83,47	4,43

FONTE: O AUTOR (2018).

Duas unidades de trabalho foram destacadas para analisar os valores de AGB, uma que foi explorada seletivamente (F4) e uma intacta (G4). Percebeu-se que a unidade que foi explorada seletivamente ao longo dos anos mostrou constante queda nos valores de AGB, enquanto, a unidade que não foi explorada seletivamente inicialmente apresentou um aumento e, em seguida apresentou valores menores de AGB. Ainda com base no melhor modelo resultante dos valores médios de LOOCV, a biomassa acima do solo foi utilizada para criar mapas AGB com resolução de 50 m x 50 m pixels em 2012, 2014 e 2017 (FIGURA 15). As FIGURAS 15D, 15F E 15H mostram a unidade de trabalho intacta para os anos de 2012, 2014 e 2017, respectivamente, enquanto as FIGURAS 15E, 15G e 15I representam a unidade que foi explorada seletivamente.

FIGURA 15 - MAPA DOS ESTOQUES DE AGB EM 2012 (A), 2014 (B) E 2017 (C). ZOOM DOS MAPAS DE AGB EM UMA UNIDADE NÃO REGISTRADA DE 2012 (D) REGISTRADA EM 2012 (E), SEM REGISTRO EM 2014 (F), UNIDADE REGISTRADA EM 2014 (G), SEM REGISTRO EM 2017 (H) E UNIDADE REGISTRADA EM 2017 (I).



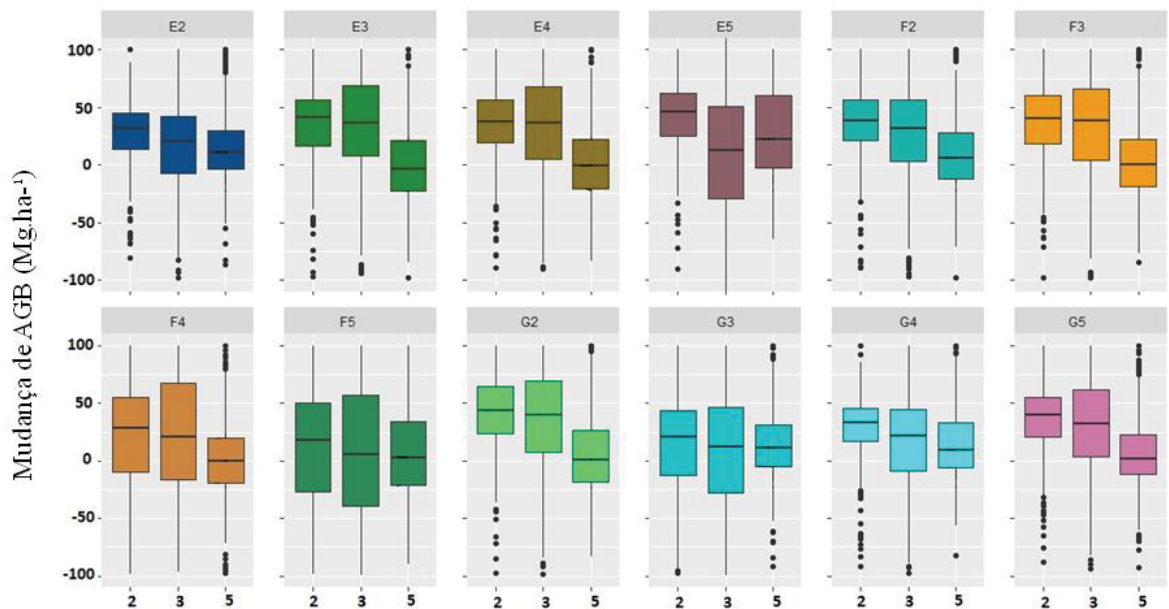
FONTE: O AUTOR (2018).

A estimativa da mudança da AGB no nível da paisagem mostra que no período de 2012-2014 a mudança média prevista foi de  $22,28 \text{ Mg.ha}^{-1}$ , enquanto nos intervalos 2014-2017 e 2012-2017 os valores encontrados foram de  $-12,17$  e  $9,54 \text{ Mg.ha}^{-1}$ , respectivamente. As estimativas de mudança da AGB no nível da parcela são mostradas na FIGURA 16 e detalhadas em valores na TABELA 8. No nível da parcela para o período de 2012 a 2014, encontraram-se valores variando de  $-23,61$  a  $43,75 \text{ Mg.ha}^{-1}$  e no período de 2014 a 2017, mudança média prevista de  $-36,85$  a  $-3,59 \text{ Mg.ha}^{-1}$ , enquanto no período de 2012-2017, os valores variaram de  $-35,89$  a  $36,61 \text{ Mg.ha}^{-1}$ .

Em resumo, percebeu-se que entre 2012-2014 houveram aumentos nos valores de AGB acima de  $40 \text{ Mg}\cdot\text{ha}^{-1}$ , o qual foi encontrado na unidade de trabalho (G2), e em geral, a maioria das unidades de trabalho apresentaram aumentos na AGB de aproximadamente  $30 \text{ Mg}\cdot\text{ha}^{-1}$  entre 2012-2014, porém apenas 3 unidades apresentaram valores negativos, ou seja, perda da AGB no período. No entanto, entre 2014 e 2017, percebeu-se que todas as unidades de trabalho apresentaram perda de AGB, e que uma delas apresentou aproximadamente  $-37 \text{ Mg}\cdot\text{ha}^{-1}$  entre o período avaliado. Embora as perdas de AGB tenham ocorrido entre 2014 e 2017, notou-se que entre 2012 e 2017 quase todas as unidades apresentaram valores incrementais.

Em relação às mudanças de AGB nas duas unidades que foram escolhidas destacadas neste trabalho, notou-se que a unidade seletivamente explorada (F4) apresenta um padrão de perda de AGB, enquanto, a unidade intacta (G4) apresenta inicialmente um ingresso de biomassa no período (2012-2014) e, em seguida, perda de aproximadamente  $-15 \text{ Mg}\cdot\text{ha}^{-1}$  de AGB. A média da paisagem da mudança estimada de AGB também foi mapeada em uma resolução de *grid* de  $50 \text{ m} \times 50 \text{ m}$  (FIGURA 17).

FIGURA 16 - BOXPLOT DAS ESTIMATIVAS DE MUDANÇA DA AGB AO NÍVEL DA PARCELA PARA 2012, 2014 E 2017.



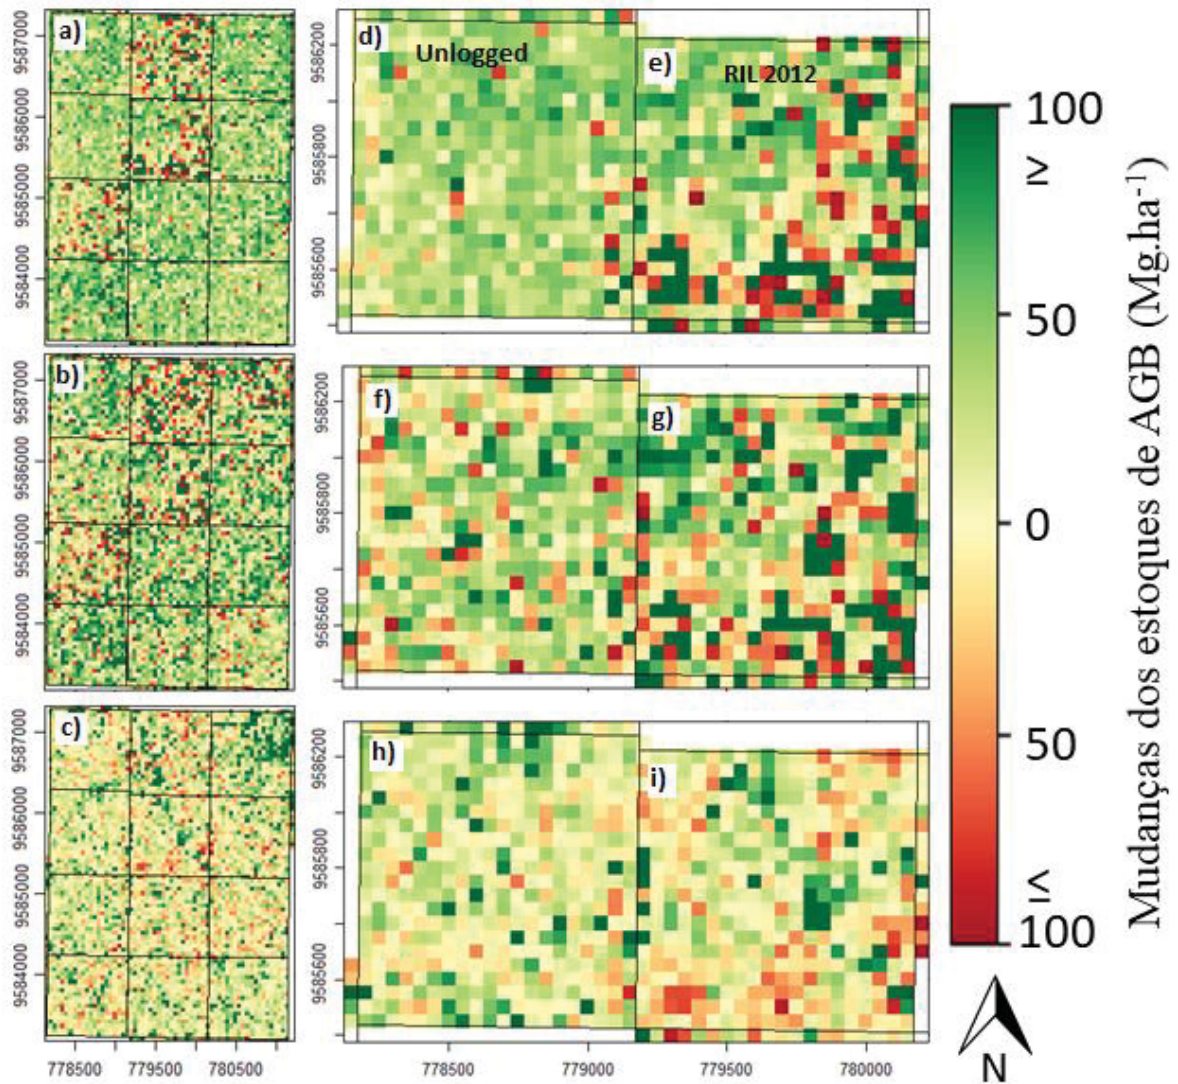
FONTE: O AUTOR (2018).

TABELA 8 - MÉDIA E DESVIO PADRÃO (SD) PARA O MODELO DE AGB BASEADO EM MÉTRICAS LIDAR EM 2014. STD ERROR É O ERRO PADRÃO ESTIMADO DERIVADO DA ANÁLISE DE INCERTEZA.

UT	$\Delta 2012-2014$ (Mg.ha <sup>-1</sup> )		$\Delta 2014-2017$ (Mg.ha <sup>-1</sup> )		$\Delta 2012-2017$ (Mg.ha <sup>-1</sup> )	
	Média	Std Error	Média	Std Error	Média	Std Error
<b>E2</b>	27,61	1,53	-20,40	1,97	7,22	2,35
<b>E3</b>	34,58	1,89	-3,60	2,05	30,85	2,72
<b>E4</b>	33,49	2,38	-4,04	1,88	29,91	2,90
<b>E5</b>	39,70	1,83	-36,85	2,85	2,02	3,36
<b>F2</b>	38,10	1,57	-11,18	2,01	26,92	2,57
<b>F3</b>	36,15	1,95	-4,38	1,96	31,31	2,63
<b>F4</b>	-10,62	3,63	-7,14	2,59	-21,43	3,99
<b>F5</b>	-23,61	3,82	-12,03	2,60	-35,90	3,71
<b>G2</b>	43,76	1,86	-7,14	2,07	36,62	2,75
<b>G3</b>	-14,42	3,53	-15,32	1,90	-30,21	3,48
<b>G4</b>	27,41	1,62	-15,25	1,75	12,16	2,23
<b>G5</b>	36,51	1,55	-7,02	1,77	28,76	2,42

FONTE: O AUTOR (2018).

FIGURA 17 - MAPA DA MUDANÇA DA AGB EM 2012 (A), 2014 (B) E 2017 (C). ZOOM DOS MAPAS DE MUDANÇA DE AGB EM UMA UNIDADE NÃO REGISTRADA DE 2012 (D) REGISTRADA EM 2012 (E), SEM REGISTRO EM 2014 (F), UNIDADE REGISTRADA EM 2014 (G), SEM REGISTRO EM 2017 (H) E UNIDADE REGISTRADA EM 2017 (I).



FONTE: O AUTOR (2018).

## 7.5. DISCUSSÃO

Acompanhar as mudanças dos estoques de AGB é vital para o MRV em apoio ao REDD+ bem como para estimativas precisas e satisfatórias, assim, técnicas de modelagem apropriadas e procedimentos de aquisição de dados são de suma importância. Além do mais, conhecer a quantidade e a distribuição espacial detalhada da biomassa acima do solo é de

primordial importância para o cálculo de fontes e sumidouros de carbono ao longo do tempo (LEITOLD et al, 2015).

Neste estudo, foram desenvolvidos mapas referentes aos estoques de AGB usando dados multitemporais e técnicas avançadas de modelagem, mostrando a variação dos estoques de AGB ao longo dos anos para florestas exploradas na Amazônia oriental. Como as florestas exploradas são um dos ecossistemas mais difíceis de detectar mudanças, devido às mudanças sutis e de curto prazo, os resultados deste estudo destacam ao potencial de dados LiDAR e a importância de técnicas apropriadas de modelagem no suporte à iniciativas de mitigação das mudanças climáticas. Ao comparar as mudanças de AGB entre áreas de floresta intactas e exploradas, foi possível obter informações sobre a resiliência das florestas tropicais à distúrbios. Especificamente, os resultados desta pesquisa, mostraram que as florestas tropicais têm grande potencial para a recuperação da AGB, mesmo após uma perturbação, como a extração seletiva de madeira.

Métricas LiDAR que são derivadas de nuvens de pontos brutas podem ser utilizadas em modelos empíricos para prever atributos florestais biofisiologicamente importantes como área basal, diâmetro médio do caule e biomassa acima do solo (LEFSKY et al., 1999; NAESSET, 2002). Neste estudo, as métricas selecionadas para compor os modelos estão de acordo com estudos anteriores (CLARK et al., 2012; LATIFI et al., 2012; FASSNACHT et al., 2014; LOPATIN et al., 2016). Em geral, a grande maioria destes estudos para estimativa dos estoques de AGB indicam que a métrica de Altura Média é a mais significativa, o que corrobora com o resultado da PCA deste estudo, no entanto, a contribuição de outras métricas na construção de modelos preditivos deve ser levada em conta. Métricas como a Altura Média, Percentil 50 e 90 da altura são de grande importância pois podem descrever diretamente a distribuição vertical da altura do dossel nos níveis médio e superior do dossel, enquanto métricas como, Desvio padrão e Coeficiente de variação da altura podem fornecer informações sobre a complexidade vertical e a heterogeneidade dos componentes do dossel (LI et al., 2008; LI et al., 2014 ).

Meyer et al. (2013) também encontraram que a Altura Média foi a métrica mais importante na modelagem, e comentaram que seria possível estimar a AGB usando um modelo com apenas esta métrica, entretanto, os resultados em escala da paisagem sugerem que tal modelo não detectaria tanta mudança de AGB quanto um modelo que possui a contribuição de outras métricas. Os autores ainda enfatizaram que a contribuição de outras métricas pode ser de grande utilidade, por exemplo, métricas de alturas intermediárias como Percentil 25 e 50 da altura podem ajudar a detectar áreas de regeneração, enquanto que a

altura média e altura máxima são bons indicadores de perda de AGB no caso de queda de árvores.

Outras métricas utilizadas no desenvolvimento dos modelos apresentados aqui também são importantes e encontradas como potenciais indicadores preditivos em outros estudos. Métricas do perfil vertical do dossel, tais como percentis de altura e variância de alturas têm sido mais frequentemente utilizadas e corroboram com os resultados aqui encontrados (NI-MEISTER et al., 2010; d'OLIVEIRA et al., 2012). No entanto, outros estudos têm procurado também avaliar o potencial de métricas baseadas em pontos dos dados LiDAR para descrever parâmetros biofísicos da floresta, e alguns resultados encorajadores foram obtidos usando densidade de pontos, a razão do número de retornos de laser (IOKI et al., 2010; ZHAO et al., 2011) e a métrica Cobertura de Copa (*Canopy Cover*), que é representado pela distribuição espacial dos pontos (VAN AARDT et al., 2008; FRAZER et al., 2011).

Entre os fatores de estimativa de AGB, o método de abordagem é um dos mais importantes na maioria dos casos (FASSNACHT et al., 2014). Neste estudo, o OLS teve melhor desempenho que as abordagens não-paramétricas. O desempenho inferior das abordagens não-paramétricas em relação ao método OLS tem sido relatado em vários estudos que tentaram comparar métodos paramétricos e não-paramétricos na previsão de vários atributos da floresta (FEHRMANN et al., 2008; HAARA et al., 2012; PENNER et al., 2013). No entanto, métodos como RF e SVM que se aproximaram do OLS podem ser usados para estimar e fazer inferências quando considerado necessário, ou seja, em situações onde existam relações não lineares e / ou possivelmente diversas entre variáveis independentes e dependentes (MAUYA et al., 2015). Além disso, métodos como RF têm o potencial de ser usado para modelagem de regressão, assim como para finalidades de classificação, o que pode se provar mais vantajoso ao trabalhar com múltiplos fluxos de dados remotamente detectados ao mesmo tempo. Nesta pesquisa, o desempenho de RF e SVM que tiveram os melhores desempenhos entre as abordagens não-paramétricas pode ter sido influenciado não apenas pelo número de parcelas de campo, mas também por outros fatores, como um *bootstrapping* robusto de dados para evitar valores  $R^2$  excessivamente otimistas. (FASSNACHT et al., 2014), bem como características ambientais e físicas, como número de árvores, uniformidade no diâmetro do caule, tipos de vegetação, etc .; estes afetam a precisão dos modelos de ALS e, portanto, estimativas de AGB.

Integrando dados aéreos de LiDAR e ópticos Cao et al. (2018), compararam as precisões de modelos não-paramétricos de AGB em uma floresta na parte superior da bacia do

rio Heihe, no noroeste da China, e descobriram que a RF teve o melhor desempenho entre as abordagens não-paramétricas, seguido por RNA e (SVR - *Support Vector Machine for Regression*). Os resultados de Cao et al. (2018) revelam melhorias nas estimativas de AGB integrando dados LiDAR e ópticos, e apresentam um padrão semelhante ao deste estudo, abrindo novas oportunidades para a realização de estudos que têm como objetivo auxiliar a reduzir as incertezas nas estimativas de AGB. O estudo dirigido por Görgens et al. (2015), se revela muito próximo aos resultados encontrados neste estudo, no qual os autores encontraram desempenho superior de RF em relação a outras abordagens de aprendizado de máquina como RNA e SVR. Görgens et al. (2015), avaliaram o desempenho de três ferramentas de aprendizado de máquina para prever o volume de plantios de florestas de crescimento rápido, com base em métricas estatísticas de vegetação extraídas de LiDAR ALS.

Hudak et al. (2008) compararam diferentes variações de  $k$ -NN para imputar simultaneamente a área basal e a densidade de árvores em nível de parcela por espécie a partir de variáveis topográficas e da estrutura do dossel derivadas de dados de LiDAR, e descobriram que RF produziu os melhores resultados gerais, e também concluíram que RF foi a mais robusta e flexível abordagem entre variações testadas. Os resultados dos autores são próximos aos resultados encontrados neste trabalho no que diz respeito as versões de  $k$ -NN, no entanto, o melhor desempenho entre as imputação de  $k$ -NN neste trabalho foi verificado em (MSN), seguido da distância euclidiana e então RF. Da mesma forma que para a área basal e a densidade de árvores, as imputações  $k$ -NN raw e ICA apresentaram os piores desempenhos na modelagem da AGB. Além do mais, Maltamo et al. (2006) demonstraram bons resultados com o algoritmo MSN para a predição do volume do caule (RMSE: 5,88 % e Viés: 0,28 %) em uma floresta na Finlândia utilizando dados de LiDAR e informações de textura de fotografias aéreas, e ainda, os autores também conseguiram reduziu o erro das previsões de volume em 23%, comparado com as previsões obtidas usando apenas a textura da fotografia aérea.

Em comparação com outros estudos, os resultados encontrados neste estudo em termos de  $R^2$  para estimativas de AGB estão dentro dos limites do que foi encontrado em áreas de florestas tropicais (ASNER et al., 2010; ASNER et al., 2012; ASNER et al., 2009). Asner et al. (2012) em quatro regiões tropicais do Panamá, Peru, Madagascar e Havaí relataram  $R^2$  variando de 0,68 a 0,85. Um estudo também realizado em floresta tropical seletivamente explorada d'OLIVEIRA et al., (2012) encontrou valores de  $R^2$  variando de 0,63 a 0,72 para modelos de regressão linear; os autores também comentaram que os resultados encontrados não surpreenderam, pois estavam limitados a uma única equação alométrica da

AGB baseada apenas no diâmetro de todas as espécies, semelhante a este estudo. Alguns estudos recomendaram o aumentar o tamanho da parcela em possíveis casos para aumentar a precisão da previsão (MAUYA et al., 2015), uma vez que pequenas parcelas terão uma proporção maior de indivíduos em que a amostragem baseada no inventário florestal e métricas LiDAR não coincide, porque indivíduos com hastes dentro de parcelas têm copas localizadas parcialmente ou totalmente fora dos limites das parcelas ou vice-versa (FRAZER et al., 2011).

No que diz respeito aos valores médios de AGB  $\text{Mg}\cdot\text{ha}^{-1}$ , os valores encontrados neste estudo também condizem com estudos semelhantes realizados também em florestas tropicais. Autores como d'Oliveira et al., (2012) também utilizaram dados de LiDAR aerotransportado para estimar a biomassa acima do solo e identificar áreas perturbadas por corte seletivo em uma floresta tropical na Amazônia brasileira ocidental, e a média da AGB encontrada pelos autores foi de  $231,6 \text{ Mg}\cdot\text{ha}^{-1}$ . Andersen et al. 2014 estimaram a biomassa acima do solo para dois anos (2010 e 2011) e obtiveram os valores médios de 232.1 e 223.0  $\text{Mg}\cdot\text{ha}^{-1}$ , respectivamente e uma diferença de  $- 9.1 \text{ Mg}\cdot\text{ha}^{-1}$  para o período avaliado. A mudança média dos estoques de AGB verificada em Andersen et al. (2014) se mostra semelhante aos valores encontrados nesta pesquisa, entretanto, os valores estimados neste estudo foram maiores, uma vez que o intervalos de análise também eram maiores, o que justifica este fato.

Estudos como este que comparam e especificam a aplicabilidade de técnicas de modelagem para estimativa da AGB são muito úteis para melhorar a precisão da AGB e do inventário florestal de LiDAR com sistemas MRV regionais / nacionais para programas de redução de emissões de REDD + para florestas tropicais (ENGLHART et al., 2013). Uma interpretação comum das diretrizes de mensuração e relato do IPCC (MRV) é que a incerteza da AGB não deve ser maior que 20% da média (ZOLKOS et al., 2013). Os resultados deste estudo mostram que o OLS pode ser usado para estimar a AGB com exatidão satisfatória e que as medidas de dados LiDAR são capazes de estimar mudanças ao longo dos anos nos níveis da paisagem. Caso houvesse dados de campo para 2012 e 2017, poderia ter sido avaliado se os mesmos parâmetros e modelos funcionam melhor para todos os casos, no entanto, como os dados de campo são caros e difíceis de obter, com mais frequência, essa expedição é considerada impraticável e, portanto, pode ser vista como uma das maiores desvantagens, ao mesmo tempo em que se conta com a tecnologia LiDAR. Mesmo assim, as fontes de dados de código aberto disponíveis globalmente como a NASA *Global Ecosystem Dynamics Investigation* podem abrir novas possibilidades de pesquisa relacionada às florestas

tropicais exploradas, bem como para monitorar e identificar atividades madeireiras ilegais (DUBAYAH, 2017; SILVA et al., 2017).

Pesquisas sobre a aplicação de métodos de modelagem para identificar o registro de baixa intensidade usando o LiDAR livremente disponível estão atualmente em um estágio inicial, embora tenham ganhado impulso (HETHCOAT et al., 2018). As abordagens baseadas em dados LiDAR permitiram navegar com facilidade entre a maior parte dos obstáculos mencionados neste estudo, e assim, mostraram que o LiDAR tem a capacidade de detectar até mesmo as diferenças de pequena escala que ocorrem em florestas seletivamente exploradas com precisão satisfatória. Estudos futuros também podem comparar quanta diferença está acontecendo na previsão da mudança da AGB ao longo dos anos com base em diferentes técnicas de modelagem para áreas florestais queimadas e exploradas, bem como para detectar padrões espaciais de resíduos, incluindo as árvores circundantes danificadas em áreas seletivamente exploradas.

## 7.6. CONCLUSÕES

Dentre as métricas originais do conjunto de dados LiDAR, apenas seis são necessárias para a modelagem, em que a Altura Média prova ser a métrica mais importante.

Na comparação dos métodos de predição, OLS se apresenta como o método mais apropriado para predição de AGB usando dados de ALS, como indicado por  $R^2$ , RMSE e viés. Embora outros métodos, como RF e SVM, também apresentampotencial para predição de AGB, eles podem ser usados quando há necessidade de aplicar método não-paramétrico.

Com os resultados da presente pesquisa foi possível avaliar e monitorar a AGB em áreas de perturbação florestal de pequena escala, como a extração seletiva de madeira com exatidão satisfatória. Assim, esses resultados podem servir como informações importantes para os programas de inventário de carbono relacionados às iniciativas de REDD ++.

## REFERÊNCIAS BIBLIOGRÁFICAS

- AGRAWAL, A; NEPSTAD, D; CHHATRE, A. Reducing emissions from deforestation and forest degradation. **Annual Review of Environment and Resources**, v. 36, p. 373-396, 2011.
- ALTMAN, N. S. An introduction to kernel and nearest-neighbor nonparametric regression. **The American Statistician**, v. 46, n. 3, p. 175-185, 1992.
- ALVARENGA JÚNIOR, W. J. **Métodos de otimização hiperparamétrica: um estudo comparativo utilizando árvores de decisão e florestas aleatórias na classificação binária**. 60 f. Dissertação (Mestrado em Engenharia Elétrica) - Pós-Graduação em Engenharia Elétrica da Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte.2018
- ALVAREZ, R. Predicting average regional yield and production of wheat in the Argentine Pampas by an artificial neural network approach. **European Journal of Agronomy**, v. 30, n. 2, p. 70-77, 2009.
- ANDERSEN, H. et al. Monitoring selective logging in western Amazonia with repeat lidar flights. **Remote Sensing of Environment**, v. 151, p. 157-165, 2014.
- ANDERSEN, H; REUTEBUCH, S. E.; MCGAUGHEY, R J. A rigorous assessment of tree height measurements obtained using airborne lidar and conventional field methods. **Canadian Journal of Remote Sensing**, v. 32, n. 5, p. 355-366, 2006.
- ARAGAO, L. EOC et al. Environmental change and the carbon balance of Amazonian forests. **Biological Reviews**, v. 89, n. 4, p. 913-931, 2014.
- ASNER, G. P. et al. High-resolution mapping of forest carbon stocks in the Colombian Amazon. **Biogeosciences**, v. 9, n. 7, p. 2683-2696, 2012.
- ASNER, G. P. et al. Selective logging in the Brazilian Amazon. **science**, v. 310, n. 5747, p. 480-482, 2005.
- ASNER, G. P. Tropical forest carbon assessment: integrating satellite and airborne mapping approaches. **Environmental Research Letters**, v. 4, n. 3, p. 034009, 2009.
- ASNER, G. P.; MASCARO, J. Mapping tropical forest carbon: Calibrating plot estimates to a simple LiDAR metric. **Remote Sensing of Environment**, v. 140, p. 614-624, 2014.
- ASNER, Gregory P. et al. A universal airborne LiDAR approach for tropical forest carbon mapping. **Oecologia**, v. 168, n. 4, p. 1147-1160, 2012.
- ASNER, Gregory P. et al. High-resolution forest carbon stocks and emissions in the Amazon. **Proceedings of the National Academy of Sciences**, v. 107, n. 38, p. 16738-16742, 2010.

ASNER, Gregory P. et al. Selective logging in the Brazilian Amazon. **Science**, v. 310, n. 5747, p. 480-482, 2005.

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

BAGNATO, V. S. **Os fundamentos da luz LASER. Física na Escola**, São Carlos, v. 2, n. 2, p. 4-9, 2001.

BAIS, C. R. **Tamanho de parcelas para quantificação de biomassa e carbono em uma floresta ombrófila densa na Mata Atlântica**. 74 f. Dissertação (Mestrado em Recursos Florestais). Universidade de São Paulo, Piracicaba 2008

BALTSAVIAS, E. P. A comparison between photogrammetry and laser scanning. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 54, n. 2-3, p. 83-94. 1999b

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

BARBOSA, J. M.; BROADBENT, E. N.; BITENCOURT, M. D. Remote sensing of aboveground biomass in tropical secondary forests: A review. **International Journal of Forestry Research**, v. 2014, 2014.

BARRETO, J. M. Introdução as redes neurais artificiais. **V Escola Regional de Informática. Sociedade Brasileira de Computação, Regional Sul, Santa Maria, Florianópolis, Maringá**, p. 5-10, 2002.

BEHLING, A. **Modelagem da biomassa de árvores para assegurar aditividade dos seus componentes**. 117 f. Tese (Doutorado em Engenharia Florestal) – Setor de Ciências Florestais – Universidade Federal do Paraná, Curitiba, 2016.

BETTS, R. A. Forcings and feedbacks by land ecosystem changes on climate change. In: **Journal de Physique IV (Proceedings)**. EDP sciences. p. 119-142. 2006.

BITTENCOURT, G. **Inteligência Artificial Ferramentas e Teorias**. 2a. edição Campus Universitário, Trindade-Florianópolis, Editora da UFSC, 2001. 362p.

BOHLMAN, S. A. et al. Importance of soils, topography and geographic distance in structuring central Amazonian tree communities. **Journal of Vegetation Science**, v. 19, n. 6, p. 863-874, 2008.

BOJINSKI, S. et al. The concept of essential climate variables in support of climate research, applications, and policy. **Bulletin of the American Meteorological Society**, v. 95, n. 9, p. 1431-1443, 2014.

BORGES, J. B. **Avaliação de Ciclo de Vida (ACV) comparativa da exploração autorizada e da exploração não autorizada em Floresta Amazônica**. 2016. xi, 48 f., il. Monografia (Bacharelado em Engenharia Florestal)—Universidade de Brasília, Brasília, 2016.

BRANDALIZE, M. C. B.; PHILIPS, J. W. Padrões de classificação de equipamentos laser utilizados em levantamentos terrestres e aéreos. **Geodésia Online-Revista da Comissão Brasileira de Geodésia**, Florianópolis, v. 1, p. 1, 2002.

BRANDTBERG, T. et al. Detection and analysis of individual leaf-off tree crowns in small footprint, high sampling density lidar data from the eastern deciduous forest in North America. **Remote sensing of Environment**, v. 85, n. 3, p. 290-303, 2003.

BREIMAN, L. Random forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001.

BRINK, H; RICHARDS, J. W.; FETHEROLF, M. Real-world machine learning. **Manning**, 400p. 2017.

BROWN, M; LEWIS, H G.; GUNN, S. R. Linear spectral mixture models and support vector machines for remote sensing. **IEEE Transactions on geoscience and remote sensing**, v. 38, n. 5, p. 2346-2360, 2000.

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

BURGES, C. JC. A tutorial on support vector machines for pattern recognition. **Data mining and knowledge discovery**, v. 2, n. 2, p. 121-167, 1998.

CAMPBELL, Bruce M. Beyond Copenhagen: REDD +, agriculture, adaptation strategies and poverty. **Global Environmental Change**. V. 19, n. 4, p. 397-399, 2009.

CAO, L., PAN, J., LI, R., LI, J., & LI, Z. Integrating airborne LiDAR and optical data to estimate forest aboveground biomass in arid and semi-arid regions of China. **Remote Sensing**, 10(4), 532. 2018.

CARDONA, M. A. Q. **Efeitos do manejo florestal na estrutura da avifauna na floresta Amazônica de Paragominas (Pará)**. 2012. Tese de Doutorado. Escola Superior de Agricultura “Luiz de Queiroz”, Piracicaba, São Paulo. 107p. 2012.

CARROLL, J. M. **Fundamentos y aplicaciones del láser** Johna Millar Carroll, traducción de Luis Ibáñez Morlán y Mariano Velasco Duránte. Marcombo, 154 p. 1978.

CASTILLO, Mauricio et al. LIDAR remote sensing for secondary Tropical Dry Forest identification. **Remote sensing of environment**, v. 121, p. 132-143, 2012.

CHAVE, J. et al. Improved allometric models to estimate the aboveground biomass of tropical trees. **Global change biology**, v. 20, n. 10, p. 3177-3190, 2014.

CHAVE, J. et al. Tree allometry and improved estimation of carbon stocks and balance in tropical forests. **Oecologia**, v. 145, n. 1, p. 87-99, 2005.

CHAZDON, R. L. Tropical forest recovery: legacies of human impact and natural disturbances. **Perspectives in Plant Ecology, evolution and systematics**, v. 6, n. 1-2, p. 51-71, 2003.

CHEN, Q; LAURIN, G. V; VALENTINI, R. Uncertainty of remotely sensed aboveground biomass over an African tropical forest: Propagating errors from trees to plots to pixels. **Remote Sensing of Environment**, v. 160, p. 134-143, 2015.

CLARK, D. A. Sources or sinks? The responses of tropical forests to current and future climate and atmospheric composition. **Philosophical Transactions of the Royal Society of London B: Biological Sciences**, v. 359, n. 1443, p. 477-491, 2004.

CLARK, D. B., & KELLNER, J. R. Tropical forest biomass estimation and the fallacy of misplaced concreteness. **Journal of Vegetation Science**, 23(6), 1191-1196. 2012.

CLARK, M. L. et al. Estimation of tropical rain forest aboveground biomass with small-footprint lidar and hyperspectral sensors. **Remote Sensing of Environment**, v. 115, n. 11, p. 2931-2942, 2011.

CLEMENT, C. R.; HIGUCHI, N. A floresta amazônica e o futuro do Brasil. **Ciência e Cultura**, v. 58, n. 3, p. 44-49, 2006.

CORTES, C; VAPNIK, V. Support-vector networks. **Machine learning**, v. 20, n. 3, p. 273-297, 1995.

COSTA, M. H.; FOLEY, J A. A comparison of precipitation datasets for the Amazon basin. **Geophysical research letters**, v. 25, n. 2, p. 155-158, 1998.

COVER, T; HART, P. Nearest neighbor pattern classification. **IEEE transactions on information theory**, v. 13, n. 1, p. 21-27, 1967.

CROOKSTON, N. L.; FINLEY, A. O. yaImpute: an R package for kNN imputation. **Journal of Statistical Software**. 23 (10). 16 p., 2008.

CUNHA, F; CENTENO, C. T. M. Segmentação de imagens geradas por perfilamento a laser para delimitação de árvores individuais em uma área de reflorestamento de eucaliptos. In: **Simpósio Brasileiro de Sensoriamento Remoto**, 12. (SBSR), Goiânia. Anais. São José dos Campos: INPE. p. 737-744. ISBN 85-17-00018-8, 2005.

DA PENHA NETO, G. **Uso de algoritmos de mineracao de dados para agrupamento e busca de erros em séries temporais coletadas a partir de geossensores: um estudo de caso na mata atlântica**. Dissertação (Mestrado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 49 p. 2012.

DIMITRIADOU, E. et al. Misc functions of the Department of Statistics (e1071), TU Wien. **R package**, v. 1, p. 5-24, 2008.

DIONISIO, L. F. S; CONDÉ, T. M; GOMES, J. P; MARTINS, W. B. R; SILVA, M. T; SILVA, M. W. Caracterização morfométrica de árvores solitárias de *Bertholletia excelsa* HBK no sudeste de Roraima. **Revista Agro@mbiente On-line**, v. 11, n. 2, p. 163-173, 2017.

D'OLIVEIRA, M. VN et al. Estimating forest biomass and identifying low-intensity logging areas using airborne scanning lidar in Antimary State Forest, Acre State, Western Brazilian Amazon. **Remote Sensing of Environment**, v. 124, p. 479-491, 2012.

D'OLIVEIRA, M. VN. et al. Estimating forest biomass and identifying low-intensity logging areas using airborne scanning lidar in Antimary State Forest, Acre State, Western Brazilian Amazon. **Remote Sensing of Environment**, v. 124, p. 479-491, 2012.

DRAKE, J. B. et al. Estimation of tropical forest structural characteristics using large-footprint lidar. **Remote Sensing of Environment**, v. 79, n. 2-3, p. 305-319, 2002.

DUBAYAH, R. et al. Land surface characterization using lidar remote sensing. **Spatial information for land use management**, p. 25-38, 2000.

DUBAYAH, R. O. et al. **CMS: LiDAR-derived Biomass, Canopy Height and Cover**, Sonoma County, California, 2013. ORNL DAAC, Oak Ridge, Tennessee, USA. 2017.

DUBAYAH, R.; KNOX, R.; HOFTON, M.; BLAIR, J. B.; DRAKE, J. Land surface characterization using LiDAR remote sensing. In: HILL, M. e ASPINALL, R. (Ed.). **Spatial Information for Land Use Management**. Singapore: International Publishers Direct, p. 25-38. 2000.

DUDA, R.; HART, P.; STORK, D. **Pattern classification and scene analysis**. 2. ed. New York: John Wiley & Sons, 654p. 2001.

DUNCANSON, L. I. et al. An efficient, multi-layered crown delineation algorithm for mapping individual tree structure across multiple ecosystems. **Remote Sensing of Environment**, v. 154, p. 378-386, 2014.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (EMBRAPA). **Soluções Tecnológicas**. Disponível em: <https://www.embrapa.br/busca-de-solucoes-tecnologicas/-/produto-servico/3862/paisagens-sustentaveis>, 2014.

ENE, L. T. et al. A simulation approach for accuracy assessment of two-phase post-stratified estimation in large-area LiDAR biomass surveys. **Remote Sensing of Environment**, v. 133, p. 210-224, 2013.

ENGLHART, S; JUBANSKI, J; SIEGERT, F. Quantifying dynamics in tropical peat swamp forest biomass with multi-temporal LiDAR datasets. **Remote Sensing**, v. 5, n. 5, p. 2368-2388, 2013.

ESKELSON, B NI; BARRETT, T M.; TEMESGEN, H. Imputing mean annual change to estimate current forest attributes. **Silva Fennica**. 43 (4): 649-658, v. 43, n. 4, p. 649-658, 2009.

FACELI, K et al. Inteligência artificial: uma abordagem de aprendizado de máquina. **Rio de Janeiro: LTC**,. 378p. 2011.

FALKOWSKI, M. J. et al. Characterizing forest succession with lidar data: An evaluation for the Inland Northwest, USA. **Remote Sensing of Environment**, v. 113, n. 5, p. 946-956, 2009.

FAO – **Food and Agriculture Organization of the United Nations**. 2014. FRA2015 Brazil, Country Report. Rome: FAO. Disponível em: <http://www.fao.org/3/aaz172e.pdf>

FAO - **Food and Agriculture Organization of the United Nations**. Global Forest Resources Assessment 2015: How have the world's forests changed? Rome 2015

FASSNACHT, F. E. et al. Importance of sample size, data type and prediction method for remote sensing-based estimations of aboveground forest biomass. **Remote Sensing of Environment**, v. 154, p. 102-114, 2014.

FEARNSIDE, P. M. **Deforestation in Amazonia Encyclopedia of Earth** ed CJ Cleveland (Washington, DC: Environmental Information Coalition, National Council of Science and the Environment). pp. 395-400. 2007.

FEARNSIDE, P. M. Deforestation in Brazilian Amazonia: history, rates, and consequences. **Conservation biology**, v. 19, n. 3, p. 680-688, 2005.

FEARNSIDE, P. M. Emissions from tropical hydropower and the IPCC. **Environmental Science & Policy**, v. 50, p. 225-239, 2015.

FEARNSIDE, P. M. Hydroelectric dams in the Brazilian Amazon as sources of 'greenhouse' gases. **Environmental conservation**, v. 22, n. 1, p. 7-19, 1995.

FEARNSIDE, P. M. Roraima e o aquecimento global: balanço anual das emissões de gases do efeito estufa provenientes da mudança de uso da terra. **Homem, Ambiente e Ecologia no Estado de Roraima**. Instituto Nacional de Pesquisas da Amazonia (INPA), Manaus, Amazonas, p. 337-359, 1997.

FEHRMANN, L. et al. Comparison of linear and mixed-effect regression models and ak-nearest neighbour approach for estimation of single-tree biomass. **Canadian Journal of Forest Research**, v. 38, n. 1, p. 1-9, 2008.

FERREIRA et al, J. **Degradação florestal na Amazônia: como ultrapassar os limites conceituais, científicos e técnicos para mudar esse cenário**. Belém: Embrapa Amazônia Oriental,. 29p. Documentos 413 ISSN (1983-0513). 2015.

FERREIRA, C. A.; SOARES, J. F.; CRUZ, F. RB. Reconhecimento de padrões em Estatística: Uma abordagem Comparativa. In: **V Congresso Brasileiro de Redes Neurais**. p. 409-414, 2001.

FERREIRA, L. et al. Utilização de redes neurais artificiais como estratégia de previsão de preços no contexto de agronegócio. **RAI Revista de Administração e Inovação**, v. 8, n. 4, p. 6-26, 2011.

FERREIRA, L. G; FERREIRA, N. C; FERREIRA, M E. Sensoriamento remoto da vegetação: evolução e estado-da-arte. **Acta Scientiarum Biological Sciences**, v. 30, n. 4, p. 379-390, 2008.

FIGUEIREDO, E O. et al. LIDAR-based estimation of bole biomass for precision management of an Amazonian forest: Comparisons of ground-based and remotely sensed estimates. **Remote Sensing of Environment**, v. 187, p. 281-293, 2016.

FLORENZANO, T. G. **Iniciação em sensoriamento remoto**. Oficina de Textos, p. 123. 2007.

FRAZER, G. W. et al. Simulated impact of sample plot size and co-registration error on the accuracy and uncertainty of LiDAR-derived estimates of forest stand biomass. **Remote Sensing of Environment**, v. 115, n. 2, p. 636-649, 2011.

GARCIA, M. et al. Quantifying biomass consumption and carbon release from the California Rim fire by integrating airborne LiDAR and Landsat OLI data. **Journal of Geophysical Research: Biogeosciences**, v. 122, n. 2, p. 340-353, 2017.

GARCIA, S. C. **O uso de árvores de decisão na descoberta de conhecimento na área da saúde**. 87 f. 2003. Dissertação de Mestrado em Ciências da Computação. Universidade Federal do Rio Grande do Sul, Porto Alegre. 2003.

GARCÍA-GUTIÉRREZ, J. et al. A comparison of machine learning regression techniques for LiDAR-derived estimation of forest variables. **Neurocomputing**, v. 167, p. 24-31, 2015.

GARCIA-GUTIERREZ, J. et al. Evolutionary feature selection to estimate forest stand variables using LiDAR. **International Journal of Applied Earth Observation and Geoinformation**, v. 26, p. 119-131, 2014.

GARCÍA-MARTÍN, A. et al. Using remote sensing to estimate a renewable resource: forest residual biomass. In: **Remote Sensing of Biomass-Principles and Applications**. InTech, p.297-322, 2012.

GERWING, J. J. Degradation of forests through logging and fire in the eastern Brazilian Amazon. **Forest ecology and management**, v. 157, n. 1-3, p. 131-141, 2002.

GIBBS, H. K. et al. Monitoring and estimating tropical forest carbon stocks: making REDD a reality. **Environmental Research Letters**, v. 2, n. 4, p. 045023, 2007.

GIONGO, M. et al. LiDAR: princípios e aplicações florestais. **Pesquisa Florestal Brasileira**, v. 30, n. 63, p. 231, 2010.

GLEASON, C.J.; IM, J. Forest biomass estimation from airborne LiDAR data using machine learning approaches. **Remote Sensing of Environment**, v. 125, pp.80-91, 2012.

GOETZ, J. N. et al. Evaluating machine learning and statistical prediction techniques for landslide susceptibility modeling. **Computers & geosciences**, v. 81, p. 1-11, 2015.

GOETZ, S; DUBAYAH, R. Advances in remote sensing technology and implications for measuring and monitoring forest carbon stocks and change. **Carbon Management**, v. 2, n. 3, p. 231-244, 2011.

GONÇALES, R.. **Dispositivo de varredura LASER 3D terrestre e suas aplicações na Engenharia, com ênfase em túneis**. 2007. 103 f. Dissertação (Mestrado em Engenharia) – Departamento de Engenharia de Transportes, Universidade de São Paulo, São Paulo, 2007

GÖRGENS, E. B; MONTAGHI, A; RODRIGUEZ, L. C. E. A performance comparison of machine learning methods to estimate the fast-growing forest plantation yield based on laser scanning metrics. **Computers and Electronics in Agriculture**, v. 116, p. 221-227, 2015.

GUO, L. et al. Relevance of airborne lidar and multispectral image data for urban scene classification using Random Forests. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 1, p. 56-66, 2011.

HAARA, A; KANGAS, A. Comparing K nearest neighbours methods and linear regression—is there reason to select one over the other?. **Mathematical and Computational Forestry & Natural-Resource Sciences (MCFNS)**, v. 4, n. 1, p. 50-65 (16), 2012.

HANSEN, E H; GOBAKKEN, T; NÆSSET, E. Effects of pulse density on digital terrain models and canopy metrics using airborne laser scanning in a tropical rainforest. **Remote Sensing**, v. 7, n. 7, p. 8453-8468, 2015.

HANSEN, M. C. et al. High-resolution global maps of 21st-century forest cover change. **science**, v. 342, n. 6160, p. 850-853, 2013.

HARRIS, N. L. et al. Baseline map of carbon emissions from deforestation in tropical regions. **Science**, v. 336, n. 6088, p. 1573-1576, 2012.

HAYKIN, S. **Neural Networks and Learning Machines**, 3a edição. 906p. 2008.

HAYKIN, S. **Redes neurais: princípios e prática**. 2.ed. Porto Alegre: Bookman, 2001. 900p

HE, Q. et al. Above-ground biomass and biomass components estimation using LiDAR data in a coniferous forest. **Forests**, v. 4, n. 4, p. 984-1002, 2013.

HEINZEL, J. N. et al. Full automatic detection of tree species based on delineated single tree crowns—a data fusion approach for airborne laser scanning data and aerial photographs. **Proceedings of SilviLaser**, v. 2008, n. 8th, 2008.

HERNÁNDEZ, L. et al. Towards complete and harmonized assessment of soil carbon stocks and balance in forests: The ability of the Yasso07 model across a wide gradient of climatic and forest conditions in Europe. **Science of The Total Environment**, v. 599, p. 1171-1180, 2017.

HESS, A. F.; BRZ, E. M.; THAINES, T.; MATOS, P. P. Ajuste de relação hipsométrica para espécies da Floresta Amazônica. **Ambiência** - Revista do Setor de Ciências Agrárias e Ambientais, v.10, n.1, 2014.

HETHCOAT, M. G. et al. A machine learning approach to map tropical selective logging. **Remote Sensing of Environment**, v. 221, p. 569-582, 2019.

HIGA, R. C. V. et al. Protocolo de medição e estimativa de biomassa e carbono florestal. **Colombo: Embrapa Florestas**, p. 72, 2014.

HIGUCHI, N. O desmatamento insustentável na Amazônia. **Ciência Hoje**, v. 39, n. 232, p. 67-71, 2006.

HIGUCHI, N; SANTOS, J dos; JARDIM, F. Tamanho de parcela amostral para inventários florestais. **Acta amazônica**, v. 12, n. 1, p. 91-103, 1982.

HOOIJER, A. et al. Current and future CO<sub>2</sub> emissions from drained peatlands in Southeast Asia. **Biogeosciences**, p. 1505–1514. 2010.

HOUGHTON, R. A. The emissions of carbon from deforestation and degradation in the tropics: past trends and future potential. **Carbon Management**, v. 4, n. 5, p. 539-546, 2013.

HOUGHTON, R. A.; HALL, F; GOETZ, S. J. Importance of biomass in the global carbon cycle. **Journal of Geophysical Research: Biogeosciences**, v. 114, n. G2, 2009.

HOUGHTON, Richard A. et al. Annual fluxes of carbon from deforestation and regrowth in the Brazilian Amazon. **Nature**, v. 403, n. 6767, p. 301, 2000.

HU, B. et al. Improving the efficiency and accuracy of individual tree crown delineation from high-density LiDAR data. **International Journal of Applied Earth Observation and Geoinformation**, v. 26, p. 145-155, 2014.

HUANG, C; DAVIS, L. S.; TOWNSHEND, J. R. G. An assessment of support vector machines for land cover classification. **International Journal of remote sensing**, v. 23, n. 4, p. 725-749, 2002.

HUDAK, A. T. et al. LiDAR utility for natural resource managers. **Remote Sensing**, v. 1, n. 4, p. 934-951, 2009.

HUDAK, A. T. et al. Nearest neighbor imputation of species-level, plot-scale forest structure attributes from LiDAR data. **Remote Sensing of Environment**, v. 112, n. 5, p. 2232-2245, 2008.

HUDAK, A. T. et al. Quantifying aboveground forest carbon pools and fluxes from repeat LiDAR surveys. **Remote Sensing of Environment**, v. 123, p. 25-40, 2012.

IBANEZ, C. A. G. et al. Estimating dbh of trees employing multiple linear regression of the best lidar-derived parameter combination automated in python in a natural broadleaf forest in

the philippines. **International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences**, v. 41, pp.657-662. 2016.

IBGE – Instituto Brasileiro De Geografia E Estatística. 1988. Mapa de Vegetação do Brasil. Ministério da Agricultura, Brasília, Brasil.

IBGE – Instituto Brasileiro de Geografia e Estatística. Manual Técnico da Vegetação Brasileira. **Série Manuais Técnicos em Geociências** 1, 2º edição revista e ampliada. IBGE, Rio de Janeiro. 2012. 271p.

INPE - Instituto Nacional de Pesquisas Espaciais. Coordenação Geral de Observação da Terra - OBT. Projeto PRODES: monitoramento da floresta amazônica brasileira por satélite, 2018. Disponível em: <<http://www.obt.inpe.br/prodes/>>. Acesso em: 18 jun. 2018.

INPE - Instituto Nacional de Pesquisas Espaciais. **SPRING: Tutorial de Geoprocessamento**. 2006. Disponível em: [http://www.dpi.inpe.br/spring/portugues/tutorial/introducao\\_sen.html](http://www.dpi.inpe.br/spring/portugues/tutorial/introducao_sen.html).

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. **Manual técnico da vegetação brasileira**: sistema fitogeográfico, inventário das formações florestais e campestres, técnicas e manejo de coleções botânicas, procedimentos para mapeamentos. Rio de Janeiro: IBGE- Diretoria de Geociências, 2012. 271p. (Manuais Técnicos de Geociências, 1).

INSTITUTO FLORESTA TROPICAL - IFT. **Manejo florestal e exploração de impacto reduzido em florestas naturais de produção da Amazônia**. Informativo Técnico do IFT 1. Belém: IFT, 2012. Disponível em <[www.ift.org.br](http://www.ift.org.br)>.

IPCC - Intergovernmental Panel on Climate Change. 2006 **IPCC Guidelines for National Greenhouse Gas Inventories**. In *National Greenhouse Gas Inventories Programme*; IGES: Tsukuba, Japan, 2006; p. 673

IOKI, K., IMANISHI, J., SASAKI, T., MORIMOTO, Y., KITADA, K. Estimating stand volume in broad-leaved forest using discrete-return LiDAR: plot-based approach. **Landscape and Ecological Engineering**, 6(1), 29. 2010

IPCC - Intergovernmental Panel on Climate Change. 2006 **IPCC Guidelines for National Greenhouse Gas Inventories**. In *National Greenhouse Gas Inventories Programme*; IGES: Tsukuba, Japan, 2006; p. 673

ISENBURG, M. **Rapidlasso GmbH**—Fast Tools to Catch Reality. Available online: <https://rapidlasso.com/lastools/> (accessed on 8 March 2018).

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.

KANKARE, V. et al. Diameter distribution estimation with laser scanning based multisource single tree inventory. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 108, p. 161-171, 2015.

KITAHARA, F. et al. Effects of training for inexperienced surveyors on data quality of tree diameter and height measurements. **Silva Fennica**, v. 44, n. 4, p. 657-667, 2010.

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

KOHONEN, T. An introduction to neural computing. **Neural networks**, v. 1, n. 1, p. 3-16, 1988.

KRAUS, K.; PFEIFER, N. Determination of terrain models in wooded areas with airborne laser scanner data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 53, n. 4, p. 193-203, Aug 1998. ISSN 0924- 2716.

KUMAR, R; AGGARWAL, R. K.; SHARMA, J. D. Comparison of regression and artificial neural network models for estimation of global solar radiations. **Renewable and Sustainable Energy Reviews**, v. 52, p. 1294-1299, 2015.

LATIFI, H; FASSNACHT, F; KOCH, B. Forest structure modeling with combined airborne hyperspectral and LiDAR data. **Remote Sensing of Environment**, v. 121, p. 10-25, 2012.

LAURANCE, S. G.W et al. Influence of soils and topography on Amazonian tree diversity: a landscape-scale study. **Journal of Vegetation Science**, v. 21, n. 1, p. 96-106, 2010.

LAURIN, G. V. et al. Above ground biomass estimation in an African tropical forest with lidar and hyperspectral data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 89, p. 49-58, 2014.

LEE, T. M; JETZ, W. Future battlegrounds for conservation under global change. **Proceedings of the Royal Society of London B: Biological Sciences**, v. 275, n. 1640, p. 1261-1270, 2008.

LEFSKY, M. A. et al. Lidar remote sensing for ecosystem studies: Lidar, an emerging remote sensing technology that directly measures the three-dimensional distribution of plant canopies, can accurately estimate vegetation structural attributes and should be of particular interest to forest, landscape, and global ecologists. **BioScience**, v. 52, n. 1, p. 19-30, 2002.

LEFSKY, M. A.; COHEN, W. B.; ACKER, S. A.; PARKER, G. G.; SPIES, T. A.; HARDING, D. Lidar remote sensing of the canopy structure and biophysical properties of Douglas-fir western hemlock forests. **Remote Sensing of Environment**, v. 70, p. 339-361, 1999

LEI, Y. et al. Quantification of selective logging in tropical forest with spaceborne SAR interferometry. **Remote Sensing of Environment**, v. 211, p. 167-183, 2018.

LEITOLD, V., KELLER, M., MORTON, D. C., COOK, B. D., SHIMABUKURO, Y. E.. Airborne lidar-based estimates of tropical forest structure in complex terrain: opportunities and trade-offs for REDD+. **Carbon balance and management**, 10(1), 3. 2015.

LI, W et al. A new method for segmenting individual trees from the lidar point cloud. **Photogrammetric Engineering & Remote Sensing**, v. 78, n. 1, p. 75-84, 2012.

LI, W. et al. Correlating the horizontal and vertical distribution of lidar point clouds with components of biomass in a picea crassifolia forest. **Forests**, v. 5, n. 8, p. 1910-1930, 2014.

LI, Y; ANDERSEN, A; MCGAUGHEY, R. A comparison of statistical methods for estimating forest biomass from light detection and ranging data. **Western Journal of Applied Forestry**, v. 23, n. 4, p. 223-231, 2008.

LIAW, A. et al. Classification and regression by randomForest. **R news**, v. 2, n. 3, p. 18-22, 2002.

LIM, K. et al. LiDAR remote sensing of forest structure. **Progress in physical geography**, v. 27, n. 1, p. 88-106, 2003.

LIN, Y. et al. From TLS to VLS: Biomass estimation at individual tree level. **Remote Sensing**, v. 2, n. 8, p. 1864-1879, 2010.

LINDSELL, J. A.; KLOP, E. Spatial and temporal variation of carbon stocks in a lowland tropical forest in West Africa. **Forest Ecology and Management**, v. 289, p. 10-17, 2013.

LIU, W.T.H. **Aplicações de Sensoriamento Remoto**. Campo Grande: Editora UNIDERP, 2007. 908p.

LONGLEY, P. A. et al. **Sistemas e ciência da informação geográfica**. Bookman Editora, 2009.

LONGO, M. et al. Aboveground biomass variability across intact and degraded forests in the Brazilian Amazon. **Global Biogeochemical Cycles**, v. 30, n. 11, p. 1639-1660, 2016.

LOPATIN, J. et al. Comparing generalized linear models and random forest to model vascular plant species richness using LiDAR data in a natural forest in central Chile. **Remote sensing of environment**, v. 173, p. 200-210, 2016.

LORENA, A.C. **Investigação de estratégias para a geração de máquinas de vetores de suporte multiclases**. 2006. 203 f. Tese (Doutorado em Ciências da Computação e Matemática Computacional). Universidade de São Paulo, São Carlos. 2006

MAIN-KNORN, M. et al. Evaluating the remote sensing and inventory-based estimation of biomass in the Western Carpathians. **Remote Sensing**, v. 3, n. 7, p. 1427-1446, 2011.

MALHI, Y. et al. Climate change, deforestation, and the fate of the Amazon. **science**, v. 319, n. 5860, p. 169-172, 2008.

MALTAMO, M. et al. Nonparametric estimation of stem volume using airborne laser scanning, aerial photography, and stand-register data. **Canadian Journal of Forest Research**, v. 36, n. 2, p. 426-436, 2006.

MARENGO, J. A.; NOBRE, C. **Clima da região Amazônica. Tempo e Clima no Brasil**, editado por: Fonseca de Albuquerque Cavalcanti, I., Ferreira, N., Justi da Silva, M., Faus da Silva Dias, M., Oficina de Textos, p. 179-212, 2009.

MARSLAND, S; **Machine Learning: An Algorithmic Perspective**. 1. ed. Chapman & Hall/CRC Press, 457p. 2008

MARTINELLI, L. A. et al. Incertezas associadas às estimativas de biomassa em florestas tropicais: o exemplo de uma floresta situada no estado de Rondônia. In: **Anais do Seminário de Emissão x Sequestro de CO<sub>2</sub>: uma nova oportunidade de negócios para o Brasil**; Rio de Janeiro. Rio de Janeiro: CVRD; p. 221, 1994.

MARTINS NETO, R. P. **Extração de variáveis dendrométricas em árvores de *Pinus Taeda* l. A partir de dados TLS e ALS**. 2016 187 f. Dissertação (Mestrado em Engenharia Florestal) Centro de Ciências Agroveterinárias, da Universidade do Estado de Santa Catarina, Universidade do Estado de Santa Catarina, Lajes. 2016.

MARVIN, D. C. et al. Amazonian landscapes and the bias in field studies of forest structure and biomass. **Proceedings of the National Academy of Sciences**, v. 111, n. 48, p. E5224-E5232, 2014.

MASCARO, J. et al. Evaluating uncertainty in mapping forest carbon with airborne LiDAR. **Remote Sensing of Environment**, v. 115, n. 12, p. 3770-3774, 2011.

MAUYA, E. W. et al. Modelling aboveground forest biomass using airborne laser scanner data in the miombo woodlands of Tanzania. **Carbon balance and management**, v. 10, n. 1, p. 28, 2015.

MAXWELL, A E.; WARNER, T A.; FANG, F. Implementation of machine-learning classification in remote sensing: An applied review. **International journal of remote sensing**, v. 39, n. 9, p. 2784-2817, 2018.

MAYAUX, P. et al. Tropical forest cover change in the 1990s and options for future monitoring. **Philosophical Transactions of the Royal Society of London B: Biological Sciences**, v. 360, n. 1454, p. 373-384, 2005.

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.

MCGAUGHEY RJ (2014) **FUSION/LDV**: Software for LIDAR data analysis and visualization, Version 3.42. USDA Forest Service, Pacific Northwest Research Station (Seattle, WA)

MCGAUGHEY, R. J. M. **FUSION/LDV**: software for LiDAR data analysis and visualization (version 3.60). Seattle, WA. 2016. Disponível

em:<[http://forsys.cfr.washington.edu/fusion/FUSION\\_manual.pdf](http://forsys.cfr.washington.edu/fusion/FUSION_manual.pdf)>

MCROBERTS, D.E.; BOLLANDSÅS, O.M.; NÆSSET, E. Modeling and estimating change. **In Forestry Applications of Airborne Laser Scanning; Concepts and Case Studies**; Maltamo, M., Naesset, E., Vauhkonen, J., Eds.; Springer: Dordrecht, The Netherlands,; pp. 293–313. 2014.

MCROBERTS, R. E. A model-based approach to estimating forest area. **Remote Sensing of Environment**, v. 103, n. 1, p. 56-66, 2006.

MELGANI, F; BRUZZONE, L. Classification of hyperspectral remote sensing images with support vector machines. **IEEE Transactions on geoscience and remote sensing**, v. 42, n. 8, p. 1778-1790, 2004.

MELO, AWF. **Alometria de Árvores e Biomassa Florestal na Amazônia Sul-Ocidental**, 2017. Tese (Doutorado em Ciências de Florestas Tropicais), Instituto Nacional de Pesquisas da Amazônia Programa de Pós-Graduação em Ciências de Florestas Tropicais, 154 f. 2017

MENESES, P. R. et al. **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília: UnB, p. 01-33, 2012.

MEYER, V. et al. Detecting tropical forest biomass dynamics from repeated airborne lidar measurements. **Biogeosciences**, v. 10, n. 8, p. 5421-5438, 2013.

MILES, L; KAPOV, V. Reducing greenhouse gas emissions from deforestation and forest degradation: global land-use implications. **science**, v. 320, n. 5882, p. 1454-1455, 2008.

MIQUELES, M. A.; CENTENO, J. AS. Detecção e caracterização de vegetação usando dados do laser scanner aerotransportado. **COLÓQUIO BRASILEIRO DE CIÊNCIAS GEODÉSICAS**, v. 3, p. 1-12, 2003.

MITCHELL, T, M. **Machine Learning**. 1.ed. McGraw-Hill. 414p. 1997.

MOLINA, P. et al. Spatially-explicit testing of a general aboveground carbon density estimation model in a western Amazonian forest using airborne LiDAR. **Remote Sensing**, v. 8, n. 1, p. 9, 2016.

MOORE, J. K. et al. Sustained climate warming drives declining marine biological productivity. **Science**, v. 359, n. 6380, p. 1139-1143, 2018.

MOUNTRAKIS, G., IM, J., OGOLE, C., Support vector machines in remote sensing – A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, 66, p. 247-259, 2011.

MOURA-COSTA, P. Tropical forestry practices for carbon sequestration. **Dipterocarp Forest Ecosystems: Towards Sustainable Management, World Scientific: Singapore**, p. 308-334, 1996.

MUTANGA, O; ADAM, E; CHO, M A. High density biomass estimation for wetland vegetation using WorldView-2 imagery and random forest regression algorithm.

**International Journal of Applied Earth Observation and Geoinformation**, v. 18, p. 399-406, 2012.

NÆSSET, E. et al. Laser scanning of forest resources: the Nordic experience. **Scandinavian Journal of Forest Research**, v. 19, n. 6, p. 482-499, 2004.

NÆSSET, E. et al. Model-assisted regional forest biomass estimation using LiDAR and InSAR as auxiliary data: a case study from a boreal forest area. **Remote Sensing of Environment**, v. 115, n. 12, p. 3599-3614, 2011.

NÆSSET, E. Predicting forest stand characteristics with airborne scanning laser using a practical two-stage procedure and field data. **Remote Sensing of Environment**, v. 80, p. 88-99, 2002.

NELSON, R; KRABILL, W; TONELLI, J. Estimating forest biomass and volume using airborne laser data. **Remote sensing of environment**, v. 24, n. 2, p. 247-267, 1988.

NEUMANN, M et al. Assessing performance of L-and P-band polarimetric interferometric SAR data in estimating boreal forest above-ground biomass. **IEEE Transactions on Geoscience and Remote Sensing**, v. 50, n. 3, p. 714-726, 2012.

NI-MEISTER, W. et al. Assessing general relationships between aboveground biomass and vegetation structure parameters for improved carbon estimate from lidar remote sensing. **Journal of Geophysical Research**, v. 115, G00E11, 2010.

NOAA, CSC. **Lidar 101: an introduction to lidar technology, data, and applications**. NOAA Coastal Services Center, 72 p. 2012.

NOBRE, C. A.; SAMPAIO, G.; SALAZAR, L. Mudanças climáticas e Amazônia. **Ciência e Cultura**, v. 59, n. 3, p. 22-27, 2007.

NOVO, E.M.L.M. **Sensoriamento Remoto: Princípios e Aplicações**. Editora Edgard Blucher Ltda. 388 p. ISBN: 978-85-2120-540-1. 2010

OCHOA-CUEVA, P. et al. Spatial estimation of soil erosion risk by land-cover change in the Andes of southern Ecuador. **Land degradation & development**, v. 26, n. 6, p. 565-573, 2015.

ODUM, E.P. **Fundamentos de Ecologia**, 6ed.; Fundação Calouste Gulbenkian: Lisboa, Portugal, 927p. 2001.

OLDEN, J. D.; LAWLER, J. J.; POFF, N. L. Machine learning methods without tears: a primer for ecologists. **The Quarterly review of biology**, v. 83, n. 2, p. 171-193, 2008.

OLIVEIRA, A. N de; AMARAL, L. L. do. Florística e fitossociologia de uma floresta de vertente na Amazônia Central, Amazonas, Brasil. **Acta Amazonica**, 2004.

OLIVERA, A. R. **Comparação de algoritmos de aprendizagem de máquina para construção de modelos preditivos de diabetes não diagnosticado**. 2016. 88 f. Dissertação

(Mestrado em Ciência da Computação) - Programa de Pós-Graduação em Computação. Porto Alegre, BR – RS, 2016.

PACKALÉN, P; MALTAMO, M. The k-MSN method for the prediction of species-specific stand attributes using airborne laser scanning and aerial photographs. **Remote sensing of Environment**, v. 109, n. 3, p. 328-341, 2007.

PAN, Y. et al. A large and persistent carbon sink in the world's forests. **Science**, p. 1201609, 2011.

PANDE-CHHETRI, R., ABD-ELRAHMAN, A., LIU, T., MORTON, J., & WILHELM, V. L. Object-based classification of wetland vegetation using very high-resolution unmanned air system imagery. **European Journal of Remote Sensing**, 50(1), 564-576. 2017.

PEARSON, T. RH; BROWN, S; CASARIM, F. M. Carbon emissions from tropical forest degradation caused by logging. **Environmental Research Letters**, v. 9, n. 3, p. 034017, 2014.

PÉLLICO NETTO, S.; BRENA, D. **Inventário florestal**. Curitiba: Universidade Federal do Paraná,. 316 p. 1997

PENNER, M.; PITT, D. G.; WOODS, M. E. Parametric vs. nonparametric LiDAR models for operational forest inventory in boreal Ontario. **Canadian Journal of Remote Sensing**, v. 39, n. 5, p. 426-443, 2013.

PEREIRA, D. et al. Fatos Florestais. **Imazon, Belém, PA**, pp. 1-126. 2010.

PEREIRA, J. P. **Mensuração automática de copas de Araucaria angustifolia (Bertol.) Kuntze a partir de dados LiDAR para estimativa de variáveis dendrométricas**. 140 f. Dissertação (Mestrado) - Programa de PósGraduação em Engenharia Florestal, CAV - UDESC. Lages, 2014.

PERSSON, A; HOLMGREN, J; SODERMAN, U. Detecting and measuring individual trees using an airborne laser scanner. **Photogrammetric Engineering and Remote Sensing**, v. 68, n. 9, p. 925-932, 2002.

PFLUGMACHER, D. et al. Using Landsat-derived disturbance and recovery history and lidar to map forest biomass dynamics. **Remote Sensing of Environment**, v. 151, p. 124-137, 2014.

PHILLIPS, O. L. et al. The changing Amazon forest. **Philosophical Transactions of the Royal Society of London B: Biological Sciences**, v. 363, n. 1498, p. 1819-1827, 2008.

PINHEIRO RIBAS, R et al. Proposição metodológica de extração da altimetria em edificações utilizando dados LIDAR com vista a estudos volumétricos de coeficientes de aproveitamento. **UD y la GEOMÁTICA**, v. 10, n. 1, 2015.

PITKÄNEN, J. et al. Adaptive methods for individual tree detection on airborne laser based canopy height model. **International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 36, n. 8, p. 187-191, 2004.

POPESCU, S. C. Estimating biomass of individual pine trees using airborne lidar. **Biomass and Bioenergy**, v. 31, n. 9, p. 646-655, 2007.

POPESCU, S. C. et al. 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.

PRATI, R. C. **Novas abordagens em aprendizado de máquina para a geração de regras, classes desbalanceadas e ordenação de casos**. 155 f. 2006. Tese (Doutorado em Ciências da Computação e Matemática Computacional) - Instituto de Ciências Matemáticas e de Computação. Universidade de São Paulo, São Carlos. 2006.

QUÉRÉ, C. L. et al. Global carbon budget 2016. **Earth System Science Data**, v. 8, n. 2, p. 605-649, 2016.

R CORE TEAM. **R: A Language and Environment for Statistical Computing**. R Foundation for Statistical Computing, Vienna. <https://www.R-project.org>. 2018

RÉJOU-MÉCHAIN, Maxime et al. Using repeated small-footprint LiDAR acquisitions to infer spatial and temporal variations of a high-biomass Neotropical forest. **Remote Sensing of Environment**, v. 169, p. 93-101, 2015.

REX, F.E., DALLA CORTE, A.P., MACHADO, S.A., SANQUETTA, C.R. Identificação e extração de copas de *Araucaria angustifolia* (Bertol.) Kuntze a partir de dados lidar. **Advances in Forestry Science**, 5(2), 319-323. 2018.

RIBAS, R.P., ELMIRO, M.A.T. Individualização de árvores em ambiente florestal nativo utilizando métodos de segmentação em modelos digitais produzidos a partir da tecnologia LIDAR. **Revista Brasileira de Cartografia**, 65, 719-729, 2013.

ROSA, R. Geotecnologias na geografia aplicada. **Revista do Departamento de Geografia**, v. 16, p. 81-90, 2011.

ROTH, P. et al. Manual do Técnico Florestal. **Rio Branco: Design gráfico Guilherme K. Noronha**. 2009. 260p.

RUSSELL, S; NORVIG, P; INTELLIGENCE, Artificial. A modern approach. **Artificial Intelligence**. Prentice-Hall, Egnlewood Cliffs, v. 25, n. 27, p. 79-80, 1995.

RUTISHAUSER, E. et al. Rapid tree carbon stock recovery in managed Amazonian forests. **Current Biology**, v. 25, n. 18, p. R787-R788, 2015.

SÁ LUCAS, L. Árvore, florestas e sua função como preditores: uma aplicação na avaliação do grau de maturidade de empresas. **PMKT – Revista Brasileira de Pesquisas de Marketing, Opinião e Mídia**, Número 6, p. 6-11, 2011.

SAATCHI, S. S. et al. Benchmark map of forest carbon stocks in tropical regions across three continents. **Proceedings of the National Academy of Sciences**, v. 108, n. 24, p. 9899-9904, 2011.

SAATCHI, S. S. et al. Distribution of aboveground live biomass in the Amazon basin. **Global Change Biology**, v. 13, n. 4, p. 816-837, 2007.

SANQUETTA, C. R. et al. Inventários florestais: planejamento e execução. **Curitiba: Multi-Graphic**, v. 2, 2009. 316p.

SANQUETTA, C. R.; BALBINOT, R. Métodos de determinação de biomassa florestal. **As florestas e o carbono. Curitiba**, p. 119-140, 2002.

SANTOS, E.; JORGE, A.; SHIMABUKURO, Y. E.; GONCALVES, F. G. Estimativa de biomassa acima do solo para uma área queimada e uma área de corte seletivo no município de Feliz Natal - MT por meio de dados LiDAR. In: **XVIII Simpósio Brasileiro de Sensoriamento Remoto**, 2017, Santos. Anais do XVIII Simpósio Brasileiro de Sensoriamento Remoto - SBSR, 2017.

SANTOS, R. **Princípios e Aplicações de Mineração de Dados**. São José dos Campos: INPE, 2010. Disponível em: <<http://www.lac.inpe.br/~rafael.santos/cap359.jsp>>. Acesso em: 10 Julho 2018.

SATO, L Y. et al. Análise da relação entre dados de LiDAR e de biomassa florestal no sudoeste da Amazônia. In: **Embrapa Monitoramento por Satélite-Artigo em anais de congresso (ALICE)**. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17., 2015, João Pessoa. Anais... São José dos Campos: INPE, 2015.

SATO, L. Y. et al. Post-Fire Changes in Forest Biomass Retrieved by Airborne LiDAR in Amazonia. **Remote Sensing**, v. 8, n. 10, p. 839, 2016.

SCHOENINGER, Emerson Roberto et al. Uso de redes neurais artificiais como uma alternativa para mapeamento de biomassa e carbono orgânico no componente arbóreo de florestas naturais. **Ambiência**, v. 4, n. 3, p. 529-549, 2008.

SCOLFORO, J.R.S.; MELLO, J.M. Inventário florestal. **Lavras: UFLA/FAEPE**, 561p. 2006

SILVA JUNIOR, C. H. L. **Dinâmica da formação de bordas florestais e seu impacto nos estoques de carbono na Bacia Amazônica utilizando sensoriamento remoto**. 2018 183 f. Dissertação (Mestrado em Sensoriamento Remoto) Instituto Nacional de Pesquisas Espaciais – INPE, São José dos Campos - SP – Brasil. 2018

SILVA, C. A. **Carbono na parte aérea de plantios de Eucalyptus spp.-em nível de árvore por amostragem destrutiva e para talhões inteiros após o ajuste de métricas LiDAR**. 152 f. 2013. Dissertação (Mestrado em Ciências) Departamento de Recursos Florestais, Universidade de São Paulo, Piracicaba. 2013

SILVA, C. A. et al. A principal component approach for predicting the stem volume in Eucalyptus plantations in Brazil using airborne LiDAR data. **Forestry: An International Journal of Forest Research**, v. 89, n. 4, p. 422-433, 2016.

SILVA, C. A. et al. Impacts of airborne lidar pulse density on estimating biomass stocks and changes in a selectively logged tropical forest. **Remote Sensing**, v. 9, n. 10, p. 1068, 2017.

SILVA, C. A. et al. Modeling and mapping basal area of *Pinus taeda* L. plantation using airborne LiDAR data. **Anais da Academia Brasileira de Ciências**, v. 89, n. 3, p. 1895-1905, 2017.

SILVA, G.F. et al. Avaliação de métodos de medição de altura em florestas naturais. **Revista Árvore**, v. 36, n. 2, 2012.

SILVA, H.F., et al. Estimativa do estoque de carbono por métodos indiretos em área de restauração florestal em Minas Gerais. **Scientia Forestalis**, Piracicaba, v. 43, n. 108, p. 943-953, dez..2015

SILVA, J. L. **Danos florestais e estimativa da redução no estoque de carbono em áreas de manejo florestal sob concessão pública: floresta nacional do Jamari – RO**, Brasil. Manaus: [s.n.], 2014. xiii, 97p. Dissertação(Ciências de Florestas Tropicais (CFT)) - Instituto Nacional de Pesquisas da Amazônia.

SILVEIRA, P. Estimativa da biomassa e carbono acima do solo em um fragmento de floresta ombrófila densa utilizando o método da derivação do volume comercial. **Floresta**, v. 40, n. 4, 2010.

SOARES, C. P. B; DE PAULA NETO, F; DE SOUZA, A. L. Dendrometria e inventário florestal. **UFV**, 276p. 2006.

SRINIVASAN, S. et al. Multi-temporal terrestrial laser scanning for modeling tree biomass change. **Forest Ecology and Management**, v. 318, p. 304-317, 2014.

SUÁREZ, J. C. et al. Use of airborne LiDAR and aerial photography in the estimation of individual tree heights in forestry. **Computers & Geosciences**, v. 31, n. 2, p. 253-262, 2005.

THOMSON, A. M. et al. Climate mitigation and the future of tropical landscapes. **Proceedings of the National Academy of Sciences**, v. 107, n. 46, p. 19633-19638, 2010.

THURNER, M. et al. Evaluation of climate-related carbon turnover processes in global vegetation models for boreal and temperate forests. **Global change biology**, v. 23, n. 8, p. 3076-3091, 2017.

TONINI, H.; ARCO-VERDE, M.F. Morfologia da copa para avaliar o espaço vital de quatro espécies nativas da Amazônia. **Pesquisa agropecuária brasileira**, Brasília, v.40, n.7, p.633-638, 2005.

TRIMBLE., **Ecognition Developer Reference Book 9.0**. Trimble Documentation München, Germany, 14p. 2014.

VAN AARDT, J. A., WYNNE, R. H., & SCRIVANI, J. A. Lidar-based mapping of forest volume and biomass by taxonomic group using structurally homogenous segments. **Photogrammetric Engineering & Remote Sensing**, 74(8), 1033-1044. 2008.

VAN DER WERF, G. R. et al. CO<sub>2</sub> emissions from forest loss. **Nature geoscience**, v. 2, n. 11, p. 737, 2009.

VAPNIK, V. **Statistical learning theory**. 1998. Wiley, New York, 1998.

VAUHKONEN, J. et al. Comparative testing of single-tree detection algorithms under different types of forest. **Forestry**, v. 85, n. 1, p. 27-40, 2011.

VENABLES, W. N.; RIPLEY, B. D. Tree-based methods. In: **Modern Applied Statistics with S**. Springer, New York, NY, p. 251-269. 2002.

VERÍSSIMO, A. et al. **Áreas Protegidas Na Amazônia Brasileira: Avanços E Desafios**© IMAZON/ISA, 88p. 2011.

VERÍSSIMO, A; PEREIRA, D. Produção na Amazônia Florestal: características, desafios e oportunidades. **Parcerias Estratégicas**, v. 19, n. 38, p. 13-44, 2015.

VIDAL, E; WEST, T. AP; PUTZ, F. E. Recovery of biomass and merchantable timber volumes twenty years after conventional and reduced-impact logging in Amazonian Brazil. **Forest Ecology and Management**, v. 376, p. 1-8, 2016.

VIERLING, K. T. et al. Lidar: shedding new light on habitat characterization and modeling. **Frontiers in Ecology and the Environment**, v. 6, n. 2, p. 90-98, 2008.

WAGNER, W. et al. **From single-pulse to full-waveform airborne laser scanners: potential and practical challenges**. na, 2004.

WANG, L et al. Estimation of biomass in wheat using random forest regression algorithm and remote sensing data. **The Crop Journal**, v. 4, n. 3, p. 212-219, 2016.

WEHR, A; LOHR, U. Airborne laser scanning—an introduction and overview. **ISPRS Journal of photogrammetry and remote sensing**, v. 54, n. 2-3, p. 68-82, 1999.

WEINACKER, H. et al. Development of filtering, segmentation and modelling modules for lidar and multispectral data as a fundament of an automatic forest inventory system. **International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 36, n. Part 8, p. W2, 2004.

WEISBIN, C. R.; LINCOLN, W; SAATCHI, S. A systems engineering approach to estimating uncertainty in above-ground biomass (AGB) derived from remote-sensing data. **Systems Engineering**, v. 17, n. 3, p. 361-373, 2014.

WEST, P. W.; WEST, P. W. **Tree and forest measurement**. Heidelberg: Springer, 192p. 2009.

WEVER, C; LINDENBERGER, J. Experiences of 10 years laser scanning. In: **Photogrammetric Week 99**. 1999.

WITTEN, I. H. et al. **Data Mining: Practical machine learning tools and techniques**. Morgan Kaufmann, 2016.

WOLD, S; ESBENSEN, K; GELADI, P. Principal component analysis. **Chemometrics and intelligent laboratory systems**, v. 2, n. 1-3, p. 37-52, 1987.

WU, C. et al. Comparison of machine-learning methods for above-ground biomass estimation based on Landsat imagery. **Journal of Applied Remote Sensing**, v. 10, n. 3, p. 035010, 2016.

WULDER, M. A. et al. Lidar sampling for large-area forest characterization: A review. **Remote Sensing of Environment**, v. 121, p. 196-209, 2012.

ZANETTI, S. S. et al. Estimaco da evapotranspirao de referncia no Estado do Rio de Janeiro usando redes neurais artificiais. **Revista Brasileira de Engenharia Agrcola e Ambiental**, v. 12, n. 2, p. 174-180, 2008.

ZHAO, F., YANG, X., SCHULL, M. A., ROMN-COLN, M. O., YAO, T., WANG, Z., ... & NEWNHAM, G. J. Measuring effective leaf area index, foliage profile, and stand height in New England forest stands using a full-waveform ground-based lidar. **Remote Sensing of Environment**, 115(11), 2954-2964. 2011.

ZHAO, K. et al. Utility of multitemporal lidar for forest and carbon monitoring: Tree growth, biomass dynamics, and carbon flux. **Remote Sensing of Environment**, v. 204, p. 883-897, 2018.

ZHAO, M; RUNNING, S. W. Drought-induced reduction in global terrestrial net primary production from 2000 through 2009. **Science**, v. 329, n. 5994, p. 940-943, 2010.

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