



**ANA CAROLINA MAGALHÃES NUNES**

**ESTIMATIVA DO ESTOQUE DE CARBONO EM  
PLANTIOS DE *Eucalyptus* spp. A PARTIR DE  
MÉTRICAS LiDAR**

**LAVRAS-MG**

**2015**

**ANA CAROLINA MAGALHÃES NUNES**

**ESTIMATIVA DO ESTOQUE DE CARBONO EM PLANTIOS DE  
*Eucalyptus* spp. A PARTIR DE MÉTRICAS LiDAR**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia Florestal, área de concentração em Manejo Florestal, para a obtenção do título de Mestre.

Orientador

Dr. Luis Marcelo Tavares de Carvalho

**LAVRAS-MG**

**2015**

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca  
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).**

Nunes, Ana Carolina Magalhães.

Estimativa do estoque de carbono em plantios de *Eucalyptus* spp. a partir de métricas LiDAR / Ana Carolina Magalhães Nunes. –  
Lavras : UFLA, 2015.  
70 p. : il.

Dissertação (mestrado acadêmico)–Universidade Federal de  
Lavras, 2015.

Orientador: Luis Marcelo Tavares de Carvalho.

Bibliografia.

1. Biomassa Florestal. 2. Tecnologia Laser Aerotransportada. 3.  
Random Forest. I. Universidade Federal de Lavras. II. Título.

**ANA CAROLINA MAGALHÃES NUNES**

**ESTIMATIVA DO ESTOQUE DE CARBONO EM PLANTIOS DE  
*Eucalyptus* spp. A PARTIR DE MÉTRICAS LiDAR**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia Florestal, área de concentração em Manejo Florestal, para a obtenção do título de Mestre.

APROVADA em 07 de julho de 2015.

Dra. Margarete Marin Lordelo Volpato

EPAMIG

Dr. Antonio Carlos Ferraz Filho

UFLA

Dr. Luis Marcelo Tavares de Carvalho  
Orientador

**LAVRAS - MG**

**2015**

À Floripes, minha mãe.

DEDICO.

## AGRADECIMENTOS

A Deus que iluminou meu caminho durante esta caminhada.

À Universidade Federal de Lavras (UFLA), ao Departamento de Ciências Florestais (DCF) e ao Laboratório de estudos e projetos em Manejo Florestal (LEMAF), pela oportunidade concedida para realização do mestrado.

Agradeço ao Programa de Pós-Graduação em Engenharia Florestal pela oportunidade concedida.

À CAPES pela concessão da bolsa de estudos.

Ao professor Dr. Luis Marcelo Tavares de Carvalho, pela orientação.

À minha família, Roldão, Helena, Floramelha, Maria Helena, Fernando, Zinho, Nelsinho, Yara, Clarisse por todo apoio, incentivo e amor que me ajudaram a vencer cada obstáculo desta caminhada.

Ao meu amor, Paulo Pigozzo, pelo amor, paciência e companheirismo em todos os momentos de alegrias e desesperos.

À minha amiga irmã, Lidy, pela amizade, apoio, carinho e amor durante graduação e mestrado.

Aos meus amigos, por cada experiência vivida ao longo desses anos.

## RESUMO

Atualmente o destaque dado às questões climáticas se deve ao aumento acentuado das concentrações de dióxido de carbono na atmosfera e seu efeito sobre o ambiente. Dentre os diversos serviços ambientais prestados pelas florestas, destacam-se o sequestro e estocagem de carbono. Plantios florestais com espécies de eucalipto no Brasil representam 5,5 milhões de hectares. Essas espécies se caracterizam pelo rápido crescimento e consequente rapidez em absorver e capturar carbono disponível na atmosfera em biomassa. A quantificação do estoque de carbono na biomassa florestal é uma atividade trabalhosa, demorada e onerosa e novas tecnologias vêm sendo desenvolvidas a fim de sanar tais limitações, dentre estas, a tecnologia LiDAR (Light Detection and Ranging). A precisão dos levantamentos, utilizando LiDAR, depende das características intrínsecas ao sistema (sensor, densidade de pontos, altitude da plataforma de voo, frequência dos pulsos, footprint, ângulo de varredura, entre outros). Estimativas da biomassa e estoque de carbono, com base nos dados LiDAR, ocorrem via modelagem por métodos paramétricos (regressão linear múltipla) ou não paramétricos (*Random Forest*). Neste contexto, objetivou-se neste trabalho avaliar o uso das métricas LiDAR na estimativa do estoque de carbono em plantios de *Eucalyptus* spp, bem como o estudo das influências das características do voo e do tipo de modelagem. Foram realizados dois voos LiDAR em oito fazendas da empresa Fibria. A partir da nuvem de pontos, provenientes de cada voo, obtiveram-se as métricas LiDAR que foram pré-selecionadas quanto à correlação com o estoque de carbono e multicolinearidade entre elas, resultando em seis variáveis independentes que compuseram o modelo. A variável dependente estoque de carbono foi obtida por intermédio do modelo logaritmizado de Schumacher e Hall (1993) adaptado para a área de estudo. Ajustaram-se modelos com base no voo 1 via regressão linear múltipla (1), voo 2 via regressão linear múltipla (2), voo 1 via *Random Forest* (3) e voo 2 via *Random Forest* (4). Os melhores modelos de 1, 2, 3 e 4 obtiveram  $R^2_{ajd}$  83%, 84%, 82% e 79% e RMSE 7,82; 7,71; 8,02; 8,72 Mg ha<sup>-1</sup>, respectivamente. Em todos os casos, as variáveis independentes que compuseram os modelos finais foram *hp50* e *stratum VI*. Portanto, a partir das métricas LiDAR é possível se obter estimativas acuradas do estoque de carbono em florestas plantadas de eucalipto. Não houve diferenças significativas entre as estimativas do estoque de carbono provenientes dos voos 1 e 2, bem como entre as estimativas do estoque de carbono obtidas por modelagem via regressão linear múltipla e *random forest*.

Palavras-chave: Biomassa florestal. Tecnologia laser aerotransportada. Regressão linear múltipla. *Random forest*.

## ABSTRACT

Currently, the emphasis given to the climatic issues is due to the pronounced increase in the concentrations of carbon dioxide in the atmosphere and its effects over the environment. Among the many environmental services provided by forests, we highlight the sequestering and stocking of carbon. Forest plantations with eucalyptus species represent 5.5 million hectares in Brazil. These species are characterized by the rapid growth and consequent speed in absorbing and capturing carbon available in the atmosphere. The quantification of the carbon stock in the forest biomass is a laborious, time-consuming and onerous activity. New technologies have been developed in order to remedy such limitations, among which is the LiDAR (Light Direction and Ranging) technology. The precision of the surveys using LiDAR depends on the traits intrinsic to the system (sensor, point density, flight platform altitude, pulse frequency, footprint, scanning angle, among others). The estimation of biomass and carbon stock obtained from the LiDAR occur via modeling by means of parametric (multiple linear regression) or non-parametric (Random Forest) methods. In this context, the objective of this work was to evaluate the use of LiDAR metrics in the estimation of the carbon stock of *Eucalyptus* spp plantations, as well as to study the influence of the flight traits and type of modeling. We conducted two LiDAR flights over eight farms owned by the Fibria company. With the cloud of points derived from each flight, we obtained the LiDAR metrics, which were pre-selected according to the correlation with the carbon stock and multicollinearity between them, resulting in six independent variables that comprised the model. The dependent variable of carbon stock was obtained by means of the Schumacher & Hall logarithm model (1993) adapted for the study area. We adjusted models from flight 1 via multiple linear regression (1), flight 2 via multiple regression (2), flight 1 via Random Forest (3) and flight 2 via Random Forest (4). The best models of 1, 2, 3 and 4 obtained  $R^2_{adj}$  of 83%, 84%, 82% and 79%, and RMSE of 7.82, 7.71, 8.02 and 8.72 Mg ha<sup>-1</sup>, respectively. In all cases, the independent variables comprising the final models were hp50 and stratum VI. Therefore, with the LiDAR metrics, it is possible to obtain accurate estimates of the carbon stocks in Eucalyptus planted forests. There was no significant difference between the carbon stock estimates obtained from flights 1 and 2, as well as between those obtained from modeling via multiple linear regression and Random Forest.

Keywords: Forest biomass. Airborne laser technology. Multiple linear regression. Random forest.



## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	9
<b>1.1</b>	<b>Objetivo Geral</b> .....	12
<b>1.2</b>	<b>Perguntas Científicas</b> .....	12
<b>2</b>	<b>REFERENCIAL TEÓRICO</b> .....	13
<b>2.1</b>	<b>Estoque de carbono e as mudanças climáticas</b> .....	13
<b>2.2</b>	<b>Quantificação do estoque de carbono</b> .....	16
<b>2.3</b>	<b>LiDAR ( Light Detectition and Ranging)</b> .....	18
<b>2.3.1</b>	<b>Características do LiDAR</b> .....	19
<b>2.3.2</b>	<b>Componentes do LiDAR</b> .....	20
<b>2.3.2.1</b>	<b>Sensor laser</b> .....	20
<b>2.3.2.2</b>	<b>Sistema de posicionamento global (GPS)</b> .....	22
<b>2.3.2.3</b>	<b>Sistema de navegação inercial (INS)</b> .....	22
<b>2.3.3</b>	<b>Fundamentos do LiDAR</b> .....	23
<b>2.4</b>	<b>Estudo da biomassa e do estoque de carbono utilizando LiDAR</b> ...	25
<b>2.5</b>	<b>Modelagem das Métricas LiDAR</b> .....	29
<b>2.5.1</b>	<b>Modelo de regressão linear múltipla</b> .....	29
<b>2.5.2</b>	<b>Random Forest</b> .....	32
<b>3</b>	<b>MATERIAL E MÉTODOS</b> .....	35
<b>3.1</b>	<b>Caracterização da área de estudo</b> .....	35
<b>3.2</b>	<b>Estimativa do Estoque de Carbono via inventário</b> .....	37
<b>3.3</b>	<b>Estimativa do estoque de carbono via LiDAR</b> .....	39
<b>3.3.1</b>	<b>Aquisição dos dados LiDAR</b> .....	39
<b>3.3.2</b>	<b>Processamento dos dados</b> .....	40
<b>3.4</b>	<b>Modelagem do estoque de carbono por meio das variáveis LiDAR</b> .....	46
<b>3.4.1</b>	<b>Regressão Linear Múltipla</b> .....	46
<b>3.4.1.1</b>	<b>Avaliação dos modelos construídos</b> .....	47
<b>3.4.2</b>	<b>Random Forest</b> .....	48
<b>3.5</b>	<b>Análise estatística</b> .....	49
<b>4</b>	<b>RESULTADOS E DISCUSSÕES</b> .....	50
<b>4.1</b>	<b>Estoque de carbono via inventário</b> .....	50
<b>4.2</b>	<b>Estoque de carbono via métricas LiDAR</b> .....	50
<b>4.2.1</b>	<b>Produtos do processamento do voo LiDAR</b> .....	50
<b>4.2.2</b>	<b>Modelagem do estoque de carbono via LiDAR</b> .....	51
<b>4.2.2.1</b>	<b>Regressão linear múltipla</b> .....	51
<b>4.2.2.2</b>	<b>Random Forest</b> .....	55
<b>4.3</b>	<b>Análise estatística</b> .....	58
<b>5</b>	<b>CONCLUSÕES</b> .....	61
	<b>REFERÊNCIAS</b> .....	62

## 1 INTRODUÇÃO

O aumento desproporcional da concentração de gases efeito estufa (GEEs) na atmosfera e o conseqüente aquecimento do sistema climático da terra têm levado a comunidade internacional a criar e estabelecer instituições e mecanismos voltados para a gestão deste problema (MÜLLER et al., 2009; RIBEIRO, 2011).

Uma das medidas criadas para redução das emissões de gases de efeito estufa foi o Protocolo de Quioto, em 1997. O Protocolo estabeleceu três mecanismos de flexibilização (comércio de emissões, implementação conjunta e mecanismo de desenvolvimento limpo), a fim de tornar viável a redução de emissões de GEEs dos países desenvolvidos e industrializados (MÜLLER et al., 2009; RIBEIRO, 2011; SILVA et al., 2014).

Dentre estes mecanismos, destaca-se o Mecanismo de Desenvolvimento Limpo (MDL), que permite aos países desenvolvidos financiarem projetos de redução de emissões ou sequestro de carbono em países em desenvolvimento. Estes projetos são relacionados ao Uso da Terra e Mudança no Uso da Terra e Floresta (*Land use, land use change and forestry – LULUCF*), atividades de florestamento e reflorestamento.

O crescente aumento da demanda de projetos de MDL, em virtude da ascensão do mercado de crédito de carbono somado aos serviços ambientais prestados pelas florestas como sequestro e a estocagem de carbono na biomassa, torna a quantificação do carbono estocado na biomassa florestal ferramenta fundamental para a sustentabilidade das florestas (RIBEIRO, 2011).

De acordo com a Associação Brasileira de Papel e Celulose (BRACELPA), o sequestro de carbono é mais intenso, durante a fase de crescimento da árvore, o que explica o grande volume de absorção do carbono em florestas plantadas. No Brasil, o ciclo do eucalipto é um dos mais curtos (seis

a sete anos) e produtivos do mundo. Dessa forma, as florestas dessas espécies plantadas para fins industriais são altamente eficientes na captura de carbono, além disso, em florestas plantadas, à medida que se colhe uma árvore, outra muda é plantada em seu lugar, dando início a novo ciclo de absorção de CO<sub>2</sub>.

De acordo com relatório de árvores plantadas da Indústria Brasileira de Árvores (INSTITUTO BRASILEIRO DE ÁRVORES - IBA, 2013), a área plantada com árvores atingiu 7,6 milhões de hectares. Destes, 72% são plantios de árvores de eucalipto.

Neste contexto, a motivação para o presente estudo está na importância em se desenvolver novas técnicas para quantificação de carbono em florestas plantadas em virtude do grande potencial do setor florestal brasileiro visando agregar valor às florestas plantadas com o mercado de crédito de carbono e de contribuir para redução nas emissões de CO<sub>2</sub>.

De acordo com Watzlawick (2003), estudos de quantificação do estoque de carbono na biomassa florestal são trabalhosos, demorados e muito onerosos, podendo os mesmos ser realizados por meio de métodos diretos e indiretos. Pelo método direto, as árvores são cortadas e seus componentes separados e pesados, e pelo método indireto são utilizadas equações alométricas e/ou produtos de sensoriamento remoto.

O mesmo autor ressalta, ainda, a importância da utilização das técnicas de sensoriamento remoto e SIG nas estimativas de biomassa e estoque de carbono, visto que as mesmas possibilitam realizar quantificações, utilizando métodos não destrutivos, bem como realizar a espacialização das informações, tornando-se uma ferramenta útil, também, com finalidade de monitoramento.

Silva (2013) destaca como alternativas, para mensurar o estoque de carbono presente na biomassa florestal, o sensoriamento remoto e, mais recentemente, o uso do laser aerotransportado (ALS) com a tecnologia LiDAR ((Light Detection and Ranging).

A tecnologia LiDAR está sendo amplamente utilizada no setor florestal, principalmente, na estimativa da biomassa e estoque de carbono em razão da rapidez da coleta dos dados, possibilitando o início do seu processamento imediatamente após o voo e a sua natureza 3D. Além disso, a utilização desta tecnologia fornece informações precisas de variáveis como, por exemplo, a altura das árvores e o mapeamento do terreno embaixo delas (em ambientes abertos ou adensados) que, com a utilização de técnicas convencionais, seriam difíceis de obter (ALVES, 2010; DANILIN; MEDVEDEV, 2009; ZONETE; RODRIGUEZ; PACKALÉN, 2010).

A precisão dos levantamentos, utilizando LiDAR, depende das características intrínsecas ao sistema (GOODWIN; COOPS; CULVENOR, 2006), tais como sensor utilizado, densidade de pontos, altitude da plataforma de voo, frequência dos pulsos, footprint, ângulo de varredura, entre outros. Estudos envolvendo essas características visam entender a influência destas na estimativa de determinadas variáveis florestais (NAESSET, 2009; NAESSET; GOBAKKEN, 2008).

A determinação do estoque de carbono, considerando os dados LiDAR, ocorre por meio da modelagem destes dados (ALVES, 2010). A regressão linear múltipla é a análise de regressão mais utilizada nestes estudos (GOODWIN; COOPS; CULVENOR, 2006; NAESSET, 2002; NAESSET; GOBAKKEN, 2008; STEPHENS et al., 2012), porém, com aumento do uso de técnicas não paramétricas no processo de modelagem, estudos têm sido desenvolvidos utilizando estes algoritmos, em especial o *Random Forest* (HUDAK, 2012). Por se tratar de uma metodologia nova estudos mais aprofundados devem ocorrer.

## 1.1 Objetivo Geral

O presente trabalho objetiva avaliar o uso das métricas LiDAR na estimativa do estoque de carbono em plantios de *Eucalyptus* spp. da empresa Fibria.

## 1.2 Perguntas Científicas

- a) Dentre as métricas LiDAR qual a mais correlacionada com o estoque de carbono?
- b) Há diferença na estimativa do estoque de carbono utilizando-se voos com características técnicas diferentes?
- c) Há diferença entre os métodos de modelagem regressão linear múltipla e *Random Forest* para o estudo do estoque de carbono com base nas métricas LiDAR?

## **2 REFERENCIAL TEÓRICO**

### **2.1 Estoque de carbono e as mudanças climáticas**

As questões ambientais têm sido amplamente discutidas nos últimos anos, sendo um dos temas mais abordados o efeito estufa. Entende-se por efeito estufa o processo natural de absorção de grande parte da radiação emitida pela superfície da terra, realizada por determinados gases presentes na atmosfera, os chamados gases de efeito estufa (GEES) (dióxido de carbono, metano, óxido nítrico e os perfluorcarbonetos) (XAVIER; KERR, 2004).

Estes gases são essenciais para a vida na Terra, pois mantêm a temperatura, bem como nos protege dos raios solares. Porém, o seu excesso tem aumentado a temperatura da Terra, causando o chamado aquecimento global (FERNANDES et al., 2007; RIBEIRO, 2011; ROCHA, 2003).

A primeira tentativa de lidar com a questão climática em nível internacional aconteceu em 1988, com o estabelecimento do Painel Intergovernamental sobre mudança climática (IPCC), com o objetivo de revisar e reunir informações científicas sobre o clima. Em 1990, o IPCC lançou o primeiro relatório de avaliação, concluindo que a mudança climática era assunto premente e pedindo a criação de uma convenção que estabelecesse a base para cooperação internacional em questões relacionadas ao aquecimento global (FERNANDES et al., 2007).

Em 1992, no Rio de Janeiro, durante a Rio-92, foi estabelecida a Convenção Quadro das Nações Unidas sobre Mudanças Climáticas (em inglês, United Nations Framework Convention on Climate Change – UNFCCC), que teve como objetivo a estabilização da concentração dos GEEs na atmosfera em um nível que impeça que as atividades antrópicas levem a uma “interferência perigosa” no clima do planeta (RIBEIRO, 2011; ROCHA, 2003).

Por intermédio da UNFCCC, representantes dos países signatários passaram a se reunir anualmente para discutir o progresso de sua implementação e dar continuidades às discussões nas chamadas Conferência das Partes (COPs) (FERNANDES et al., 2007).

A conferência das partes, realizada em Quioto em 1997, destaca-se, segundo Rocha (2003), como uma das mais importantes, uma vez que foram definidas metas de redução das emissões do GEE, além de critérios e diretrizes para utilização dos mecanismos de mercado, como por exemplo, o Mecanismo de Desenvolvimento Limpo (MDL). Este acordo ficou conhecido como Protocolo de Quioto e estabeleceu que países industrializados devessem reduzir suas emissões de gases do efeito estufa em 5,2% abaixo dos níveis observados em 1990, no período entre 2008-2012. Este protocolo entrou oficialmente em vigor em fevereiro de 2005.

A proposta do MDL consiste em que cada tonelada de CO<sub>2</sub> que deixar de ser emitida ou retirada da atmosfera por um país em desenvolvimento poderá ser negociada no mercado mundial, criando um novo atrativo para a redução das emissões globais (ROCHA, 2003).

Uma das formas de negociação é pelo Certificado de Emissões Reduzidas (CERs). Países que, por algum motivo, não conseguirem reduzir suas emissões de gases poderão comprar este certificado nos países em desenvolvimento e usá-los para cumprir suas obrigações (FERNANDES et al., 2007; RIBEIRO, 2011; ROCHA, 2003). Apenas o MDL permite a participação de países em desenvolvimento como o Brasil, sendo, portanto, uma forma do país inserir-se no mercado de créditos de carbono.

Diversas são as atividades que podem ser desenvolvidas no âmbito do MDL. O florestamento/reflorestamento é a categoria que abrange especificamente as atividades florestais (RIBEIRO, 2011) e fazem parte das

atividades de Uso da Terra, Mudanças de Uso da Terra e Floresta (em inglês – Land Use, Land Use Change and Forestry – LULUCF).

Segundo Silva (2013), as florestas desempenham um papel importante na mitigação dos efeitos da concentração de carbono na atmosfera pelo “sequestro de carbono”.

O “sequestro de carbono”, por meio de atividades florestais, baseia-se em duas premissas. Primeira, o gás carbônico é um gás atmosférico que circula no mundo todo e, conseqüentemente, os esforços para a remoção dos GEE pelas florestas terão efeito igual, sejam eles aplicados próximos à fonte ou do outro lado do mundo. Segunda, a vegetação verde retira o gás carbônico da atmosfera por meio do processo da fotossíntese, convertendo-o em compostos orgânicos utilizados no crescimento e metabolismo vegetal e estocando-o como forma de biomassa (FERNANDES et al., 2007).

A estocagem de carbono, via plantios florestais, vem sendo analisado como um importante agente compensatório às emissões de poluentes atmosféricos em especial o CO<sub>2</sub> (TOMASI; MARQUES; BRUTTI, 2014). Acredita-se que povoamentos de eucalipto representem uma alternativa economicamente viável de curto prazo para sequestrar o carbono da atmosfera em virtude, principalmente, da sua elevada taxa de crescimento e conseqüente capacidade de remover o dióxido de carbono da atmosfera incorporando-o a sua biomassa (RIBEIRO, 2011; WATZLAWICK et al., 2003).

A biomassa florestal em sua grande parte é constituída por carbono, aproximadamente 50% e, para poder compreender melhor o comportamento, movimentação e captura deste carbono, contido na atmosfera pelas formações florestais, faz-se necessário estudos mais detalhados sobre o assunto (LACERDA et al., 2009).

Sanquetta (2002) acredita que um dos aspectos mais relevantes nos estudos de fixação de carbono em florestas é a variável biomassa, a qual precisa



ser determinada e estimada de forma fidedigna, caso contrário não haverá consistência na quantificação do carbono fixado nos ecossistemas florestais.

Entende-se por biomassa florestal ou fitomassa a quantidade expressa em unidade de massa do material lenhoso contido em uma unidade de área florestal (ARAÚJO; HIGUCHI; CARVALHO JÚNIOR, 1999). E, ainda, de acordo com Sanquetta (2002), pode significar, também, toda biomassa existente na floresta ou apenas a sua porção arbórea (madeira, galhos e folhas).

A produção de biomassa está relacionada ao crescimento dos organismos, que necessitam obter recursos naturais do seu meio (energia e minerais) e sintetizar a matéria orgânica pelo processo denominado de fotossíntese (WENDLING, 1998).

## **2.2 Quantificação do estoque de carbono**

Os métodos para a obtenção da estimativa do carbono se dá pela estimativa da biomassa florestal e podem ser destrutivos ou não destrutivos. Nos métodos destrutivos ou diretos, são derrubados, segmentados e pesados todos os componentes das árvores representativas da floresta. Enquanto nos métodos não destrutivos ou indiretos, a quantificação baseia-se em dados provenientes do inventário florestal (WATZLAWICK, 2003; WENDLING, 1998).

Os métodos destrutivos têm a vantagem da quantificação direta e, como desvantagens, esforço, tempo e custo.

Depois da derrubada e pesagem da massa úmida dos componentes das árvores, são coletadas suas amostras representativas que serão encaminhadas ao laboratório para obtenção do teor de umidade e o teor de carbono. A biomassa seca é, então, calculada, multiplicando-se o teor de umidade, obtido nas amostras, pela biomassa úmida medida em campo.

Para obtenção do estoque de carbono, multiplica-se a biomassa seca pelo teor de carbono determinado em laboratório ou por aquele já estabelecido em algum estudo (SILVA et al., 2014).

Os métodos não destrutivos utilizam de equações alométricas e/ou produtos de sensoriamento remoto.

Para utilização de equações alométricas, são feitas medições das variáveis biofísicas, diâmetro, altura e a biomassa de algumas árvores (método destrutivo). Baseados nesses dados são ajustados modelos que serão utilizados para quantificar a biomassa e um fator de correlação para o carbono.

Outra forma de quantificação pelo método não destrutivo é produto de sensoriamento remoto, que pode ser feito utilizando-se as imagens índice de vegetação, derivadas de imagens do vermelho e infravermelho próximo, que quantificam a biomassa das folhas (BOELMAN et al., 2003; FOODY et al., 2001). A restrição ao uso desse método, de acordo com Foody, Boyd e Cutler (2003), está na extrapolação das relações entre imagens de índice de vegetação e valores de biomassas determinados no campo para uma região determinada.

Como descrito anteriormente, todos os métodos possuem vantagens e desvantagens o que gera grande polêmica quanto ao melhor método a ser utilizado.

Algumas variáveis interferem na escolha do método, o método destrutivo é aplicável apenas em pequenas áreas e na calibração das equações alométricas, em razão dele permitir um melhor conhecimento da biomassa nos diferentes espaços da floresta (SALATI, 1994). Houghton (1994), levando em consideração as diferentes distribuições da biomassa ao longo dos tipos florestais, bem como ao longo do mesmo tipo e até mesmo da mesma espécie e indivíduo, defende a importância de se levar em conta as árvores de menor porte, vegetação rasteira e a vegetação subterrânea para a correta determinação da biomassa e do carbono. Outro ponto questionado em relação ao método

destrutivo é que, por se tratar de uma atividade trabalhosa, pesada e monótona, muitas vezes, opta-se por áreas mais fáceis de trabalhar e, conseqüentemente, há ausência de representatividade (BROWN; GILLESPIE; LUGO, 1989).

Recentemente, acredita-se que a melhor maneira de se quantificar a biomassa, seja a combinação dos dois métodos. Sanquetta (2002) defende que os métodos não destrutivos não devem ser utilizados sem a calibragem prévia das equações, devendo ser empregado conjuntamente com o método destrutivo. Watzlawick et al. (2002) concordam com Sanquetta (2002) na utilização dos dois métodos juntos e acrescentam que, em diferentes tipos florestais, bem como diferentes estágios de regeneração, as estimativas devem abranger todos os estágios, diferentes partes de uma árvore e diferentes compartimentos do ecossistema florestal.

Watzlawick et al. (2002) destacam a utilização de técnicas de sensoriamento remoto como método não destrutivo. De acordo com Silva et al. (2013), um dos problemas no processo de quantificação da biomassa estão na questões orçamentárias e temporais, inviabilizando a realização de um inventário completo dentro de um curto espaço de tempo. E, alternativas, utilizando sensoriamento remoto, têm sido discutidas e analisadas.

O sensoriamento remoto por meio da tecnologia LiDAR (Light Detection and Ranging) aparece atualmente como uma das alternativas eficientes para o inventário da biomassa florestal e estoque de carbono (BROWN, 2002; FREITAS; SHIMABUKURO, 2007; GIONGO et al., 2010; JENSEN, 2009; KUNTSCHIK, 2004; SIVA et al., 2013).

### **2.3 LiDAR ( Light Detectition and Ranging)**

ALS, LiDAR, LaDAR, LASERscanner, e LASERscanning são termos distintos para o mesmo sensor (ZONETE; RODRIGUEZ; PACKALÉN, 2010).

Neste trabalho, o termo utilizado será LiDAR (*Light Detection And Ranging*), em português, sistema de varredura a laser, sensor opticamente ativo transportado por aeronave.

O desenvolvimento do sistema de varredura a laser ocorreu entre as décadas de 1950 e 1970. Incluindo, desde o desenvolvimento de um laser, pela amplificação de luz por emissão estimulada de radiação, até suas primeiras utilizações em sensoriamento remoto, como monitoramento atmosférico e estudos oceanográficos (ALVES, 2010).

O uso do LiDAR, no setor florestal tem avançado desde os anos 1980 (LILLESSAND; KIEFER, 2000), em que o laser passou a ser utilizado na medição de distâncias (FOODY et al., 2001). O sensor de varredura a laser aerotransportado tem grande potencial para aplicações florestais, em função, principalmente, da sua capacidade de mobilização de grande quantidade de pontos com alta precisão, baixo custo e alta velocidade de aquisição de dados da estrutura vertical e horizontal da floresta (GIONGO et al., 2010).

No Brasil, de acordo com Rodriguez et al. (2010), a utilização da tecnologia LiDAR é promissora, pois já se observa queda nos custos dos principais itens dessa tecnologia, crescente disponibilidade de rotina de processamento de dados e um número maior de técnicos habilitados.

### **2.3.1 Características do LiDAR**

O sistema LiDAR é um sistema ativo de sensoriamento remoto, pois apresenta sua própria fonte de energia, o “*laser*”, a qual emite radiação eletromagnética, utilizado para medir a distância entre o sensor e a superfície dos objetos (HEIN; SENES; CARNEIRO, 2013).

Outra característica importante deste sensor é que os pulsos de laser podem penetrar por pequenas aberturas no dossel da floresta e fornecer

informações da estrutura florestal e, também, o relevo presente nestas áreas (GIONGO, 2010; RODRIGUEZ et al., 2010).

### **2.3.2 Componentes do LiDAR**

Os sistemas LiDAR são compostos por uma unidade de varredura a laser (sensor), um Sistema Inercial de Navegação (INS – *Inertial Navigation System*) e um receptor GPS (*Global Positioning System*), todos componentes integrados e montados sobre uma plataforma.

#### **2.3.2.1 Sensor laser**

O sensor laser usa um feixe ótico de alta potência e bem direcionado para medir a distância entre os objetos da superfície e o sensor (SOUZA, 2009).

De acordo com Silva et al. (2013), para estudos de vegetação, existem duas categorias de sensores quanto ao registro do sinal de retorno do pulso laser emitido. O primeiro e mais utilizado é conhecido como retornos discretos ou sistemas de pulso, e o segundo, por ondas contínuas ou retornos contínuos. Este possui a capacidade de registrar integralmente todo o sinal do pulso laser refletido enquanto aquele registra primeiro, intermediários e último retorno.

Segundo Alves (2010), o número de retorno registrado, para cada pulso laser emitido, dimensão do *footprint*, densidade de pontos e frequência de varredura (1000 a 200000 HZ), são as características mais importantes em um sensor laser.

*Footprint* (F) é a projeção do laser na superfície e equivale à resolução espacial das imagens LiDAR (OLIVEIRA, 2011) . Quando o feixe laser deixa a fonte emissora, ele se abre muito pouco. Em razão dessa divergência, sua

projeção na superfície não é pontual, mas em forma circular ou elíptica com dimensões variáveis (ALVES, 2010).

Segundo o mesmo autor, o *footprint* é uma característica muito importante, pois sua dimensão afeta a probabilidade de interceptação do feixe nos objetos ao longo da sua trajetória. Como consequência há detecção de vários alvos simultaneamente em um mesmo feixe.

O *footprint* é determinado pelo ângulo de divergência do feixe e a distância entre o sensor e o alvo e é classificado quanto ao diâmetro da visada laser. Se este diâmetro for superior a 1 metro, é classificado como *large-footprint*, caso contrário é classificado como *small-footprint* (SILVA et al., 2013).

Atualmente, segundo Rodriguez et al. (2010), para uso tipicamente florestal, o laser é geralmente do tipo *discrete-return small-footprint*. Ou seja, o laser é emitido em pulsos com certa frequência (até duzentos mil pulsos de luz por segundo), formando uma série não contínua de emissões e retornos com a área iluminada pelo pulso de pequena dimensão (menor que 1 metro).

Para cada pulso, o sistema LIDAR identifica e armazena as leituras de primeiro retorno (*rp*), de retorno intermediário (*ri*) e de último retorno (*ru*), (atualmente os equipamentos existentes são capazes de registrar de dois a cinco pulsos de retorno, Hein, Senes e Carneiro (2013)), produzindo um arquivo de dados que pode ser segmentado de diferentes formas (RODRIGUEZ et al., 2010). Para estudos florestais, os retornos mais importantes são o primeiro e o último, o último é utilizado para a modelagem digital do terreno, já, a diferença entre o último e o primeiro é importante na determinação da altura das árvores (OLIVEIRA, 2011; RODRIGUEZ et al., 2010).

### 2.3.2.2 Sistema de posicionamento global (GPS)

Os sistemas de navegação global por satélite (GNSS – *Global Navigation Satellite System*) são desenvolvidos, para se obter cobertura mundial, sendo operacional 24 horas por dia, proporcionando latitude, longitude, altura e tempo, independente das condições meteorológicas (SOUZA, 2009).

No presente trabalho foi utilizado o sistema de posicionamento global (GPS) que é o mais utilizado para navegação e voos georreferenciados.

O objetivo do GPS é determinar a posição da plataforma aerotransportada. Para alcançar maiores exatidões, utiliza-se, na plataforma um receptor de GPS de dupla frequência e, em terra, uma rede de estações GPS com coordenadas conhecidas. Estes equipamentos realizam medições simultâneas.

Segundo Souza (2009), utilizando-se essa rede de GPS é possível obter precisões centimétricas que são compatíveis com o levantamento a Laser.

### 2.3.2.3 Sistema de navegação inercial (INS)

Em decorrência do fato do GPS não ser sensível à altitude da aeronave, torna-se necessária a instalação de sistemas complementares, dentre os quais se destacam os sensores inerciais (SOUZA, 2009).

O sistema de navegação inercial fica acoplado ao sensor laser e utiliza uma unidade de medição inercial (IMU), para medir *roll*, *pich* e *yaw*, ou seja, rolamento, arfada e guinada da aeronave e, conseqüentemente, do sensor.

O sistema IMU é constituído por uma série de acelerômetros e giroscópios com um circuito de digitalização e uma unidade de cálculo, que produzem a posição, a velocidade e a orientação do IMU e do sensor laser (ALVES, 2010).

Para assegurar a exatidão das características do sensor, é necessário que não haja variações entre o IMU e o sensor. Logo, o IMU deve ser pequeno e leve para que seja instalado o mais próximo possível do sensor (MOSTAFA; HUTTON, 2001).

### **2.3.3 Fundamentos do LiDAR**

O princípio do LiDAR consiste na emissão de um pulso laser à velocidade da luz de uma plataforma (aérea, terrestre ou orbital) com uma elevada frequência de repetição (RODRIGUEZ et al., 2010). Um feixe de laser é disparado em direção ao terreno por um espelho, no sentido transversal à direção da linha de voo (JENSEN, 2009).

O sensor laser utiliza um feixe ótico de alta potência, bem direcionado, que mede a distância entre o objeto e o sensor. A posição do sensor, no momento da medição de cada ponto, é determinada pelo GPS, encarregado de calcular a posição (X,Y,Z), do sensor/aeronave e o sistema de navegação inercial calcula a inclinação do sensor nessas três direções (SOUZA, 2009). Todos esses dados são coletados simultaneamente e, na sequência, sincronizados determinando a posição exata de cada ponto.

Ao atingir uma superfície, o sinal de laser produz vários retornos ou pulsos. O tempo de retorno dos pulsos laser entre a plataforma e os alvos é medido pelo sensor. Este será processado para calcular as distâncias entre objetos ou da superfície terrestre (OLIVEIRA, 2011).

No caso de florestas densas, uma parte do pulso laser emitido bate na copa das árvores, outra parte penetra mais fundo, atingindo o estrato vegetal inferior ou a superfície do solo. Por isso, um mesmo pulso gera vários retornos (primeiro retorno, o retorno intermediário e o último retorno).



Para cada ponto de laser projetado no solo são armazenadas as coordenadas planimétricas, medidas de elevação da superfície registrada e o valor da reflectância dos materiais alvos. Como resultante de uma varredura a laser, há uma nuvem de pontos tridimensional referente aos objetos imageados. Para alcançar o produto final, vários procedimentos são realizados.

De acordo com Silva et al. (2013), os principais produtos obtidos pelo processamento da nuvem de pontos LiDAR são os modelos digitais de elevação, intensidade LiDAR e métricas LiDAR.

Segundo o mesmo autor, os modelos digitais de elevação podem ser subdivididos em Modelos Digitais de Superfície (DSM – *Digital Surface Models*), que contêm informações de todas as feições na paisagem, Modelos Digitais do Terreno (DTM – *Digital Terrain Models*), que contêm informações de elevação da superfície desnuda da Terra, e Modelos Digitais em Altura das Copas (CHM – *Canopy Height Models*), que representam a altura dos objetos presentes na nuvem de pontos LiDAR, que é conhecido, também, como modelos digitais de superfícies normalizados (nDSM – *normalized Digital surface models*).

A intensidade LiDAR é uma informação registrada pelo sensor e é mensurada pela quantidade de energia refletida pelo alvo (JENSEN, 2009). Sofre influência do sensor laser, do ângulo de incidência, da área de reflectância do alvo, das condições da atmosfera e da distância entre o sensor e o alvo.

Métricas LiDAR é o nome dado ao conjunto de parâmetros estatísticos que descrevem a nuvem de pontos LiDAR. Elas podem ser calculadas a partir da nuvem de pontos original, em que a coordenada Z reflete valores em elevação ou a partir da nuvem de pontos normalizada, na qual Z reflete valores em altura (SILVA et al., 2013). No presente estudo a métrica LiDAR foi obtida com base na nuvem de pontos normalizada.

Existem duas principais abordagens para obtenção de informações florestais baseadas na tecnologia LiDAR, a que trabalha com a distribuição da altura do dossel e a abordagem baseada na árvore individual.

No presente trabalho, utilizou-se a distribuição da altura do dossel. Dessa forma, as características florestais de interesse foram estimadas conforme os quantis e percentis da distribuição da altura do dossel, dada uma área fixa (NAESSET, 2004) e algumas parcelas amostrais em campo para efeito de ajuste dos dados medidos. Em seguida, modelos matemáticos foram construídos para estimar as variáveis de interesse dos talhões (volume, área basal, altura média e diâmetro).

#### **2.4 Estudo da biomassa e do estoque de carbono utilizando LiDAR**

Segundo Drake et al. (2003), a tecnologia LiDAR é um aperfeiçoamento de muitas técnicas de sensoriamento remoto existentes que são incapazes de obter estimativas confiáveis da biomassa florestal e do estoque de carbono.

Um avanço promissor nas medições remotas do carbono da biomassa florestal é o LIDAR, que coleta dados altimétricos para o topo do dossel assim como para a topografia terrestre (BROWN, 2002). De acordo com o mesmo autor, pelo LiDAR pode-se reproduzir a área da copa das árvores, a altura das árvores, a densidade da copa e o número de galhos por unidade de área, medidas altamente correlacionadas com a biomassa acima do solo de florestas tropicais.

Para Alves (2010), a tecnologia LiDAR, ao contrário das imagens de satélite e de fotografias aéreas, pode simultaneamente mapear o terreno embaixo das árvores, bem como obter a estimativa da altura das árvores segundo a qual podem-se estimar várias outras variáveis florestais.

De acordo com Lefsky et al. (2002), a estimativa do estoque de carbono em áreas florestais, que apresentam valores de biomassa de moderadas a densas,

são difíceis para tecnologias baseadas em sensores óticos convencionais e radares. Neste cenário, destaca-se a tecnologia LiDAR para estimativa da biomassa florestal e estoque de carbono. Em um estudo realizado por Freitas e Shimabukuro (2007), para estimar a biomassa florestal em florestas tropicais, utilizando os sistemas Landsat, SAR e LiDAR, os autores observaram que tanto Landsat como SAR saturam em áreas com alto valor de biomassa florestal, problema que não acontece quando utilizada a tecnologia LiDAR.

Os estudos, utilizando tecnologia LiDAR, para estimar biomassa e estoque de carbono florestal, com base na distribuição da altura do dossel, baseiam-se na modelagem conforme as métricas LiDAR e, principalmente, dos percentis de altura e intensidade e/ou variáveis de cobertura da copa. Nota-se que a regressão linear múltipla é a análise de regressão mais utilizada, mas alguns estudos já utilizam de algoritmos como *Random Forest* como alternativa à análise de regressão.

Naesset (2002) utilizou a altura e densidade de copa para construção de modelos preditivos por meio da técnica de regressão linear múltipla. Os resultados indicaram que o comportamento da biomassa pode ser 90% explicado pelos regressores LiDAR empregados no modelo.

Naesset (2004) estimou a biomassa acima e abaixo do solo, conforme métricas LiDAR, provenientes do primeiro e do último pulso laser, utilizando modelos de regressão em 143 parcelas distribuídas em floresta jovem e madura de conífera. Os modelos para biomassa acima do solo explicaram 92% da variabilidade enquanto os modelos para biomassa abaixo do solo explicaram 86%.

Poeh et al. (2010) avaliaram o uso de altura e cobertura da copa obtidas pelo processamento de dados LiDAR para os estudos de manejo e estimativa da biomassa aérea florestal, na Escócia. Os autores encontraram resultados

satisfatórios que confirmam o grande potencial desta ferramenta para o estudo da biomassa.

Stephens et al. (2012) estudaram a relação entre o estoque de carbono estimado via inventário e métricas LiDAR, em florestas da Nova Zelândia. O modelo escolhido para estimação da biomassa florestal explicou 74% da variação total do carbono e utilizou as variáveis percentis 30 da altura (P30) e cobertura da copa.

Hudak et al. (2012) avaliaram o uso do LiDAR para a quantificação da biomassa e, na dinâmica de estoque de carbono, em áreas compostas por florestas de coníferas manejadas e não manejadas, EUA. Foram utilizados métodos não paramétricos, como o algoritmo *Random Forest* para modelagem da biomassa acima do solo. Eles verificaram que, onde não houve manejo, houve um aumento do crescimento da biomassa.

Silva et al. (2013) avaliaram o uso da tecnologia LiDAR como ferramenta para estimação da biomassa aérea florestal em um povoamento de *Eucalyptus* sp. O modelo de determinação da biomassa florestal, com base nas métricas LiDAR, foi obtido por um modelo de regressão linear múltipla. As métricas selecionadas foram provenientes dos percentis de altura e de intensidade, H\_max, H\_P75, H\_P90, Int P30, Int P50. De acordo com os autores, a estimação da biomassa aérea florestal em povoamentos clonais de eucaliptos pode ser obtida com aceitável precisão conforme dados coletados com a tecnologia LiDAR.

Cada voo LiDAR possui características específicas como altitude de voo, ângulo de varredura, dimensão do *footprint*, frequência de pulsos, densidade de pontos, entre outros. Dessa forma, vários estudos têm sido realizados no intuito de conhecer as influências dessas características na estimativa das variáveis florestais.

Goodwin, Coops e Culvenor (2006) avaliaram a estrutura da floresta, utilizando de métricas LiDAR e, também, os efeitos da plataforma de altitude. De acordo com os autores, a precisão do levantamento LiDAR depende das características da floresta e do voo. Neste estudo foi investigado o efeito de algumas dessas características de voo, sendo elas, três diferentes altitudes (1000, 2000 e 3000 m), dois ângulos de varredura a 1000 m de altitude (10 e 15°) e três tamanhos de *footprint* (0,2; 0,4 e 0,6 m). O estudo foi realizado em florestas de eucalipto na Austrália em três locais, variando a estrutura da vegetação e de relevo. Eles concluíram que o ângulo de varredura e o tamanho de footprint não influem, significativamente, na estimativa das variáveis da floresta. Em relação às altitudes, concluíram que maiores altitudes como 3000 m podem ser utilizadas para quantificar as variáveis da floresta, porém, irá obter uma menor proporção de últimos retornos o que reduzirá o número de pontos disponíveis para avaliação da estrutura vertical da floresta e desenvolvimento de modelos digitais de elevação. E, ainda, como será menor o número de retornos que reportam à copa, haverá uma subestimativa da área da copa de cada árvore e consequente volume das mesmas.

Segundo o mesmo autor, aumentando a altitude da plataforma resultará numa maior área coberta pelo scan Lidar, por outro lado, reduzirá o número de retornos por unidade de área. Ao alterar a densidade de pontos e, por conseguinte, a habilidade para delimitar árvores individuais e modelos digitais de elevação, isso poderá afetar a quantificação dos atributos da floresta.

Naesset e Gobakken (2008) analisaram os efeitos dos diferentes sensores na estimativa de variáveis biométricas em uma floresta madura de coníferas. Neste estudo avaliaram-se os efeitos de cada equipamento (ATM 1233 e ALTM 3100), o par altitude de voo (m) e frequência de pulsos (kHz) (1200 e 33; 1100 e 50; 1100 e 100; 2000 e 50) e densidade de voo (0,8; 1,4; 3 e 1,2 pontos/m<sup>2</sup>).

Segundo os autores, o efeito sensor foi a única característica de voo com impacto significativo sobre as métricas LiDAR.

Bater et al. (2011) analisaram as métricas LiDAR de quatro sobrevoos ocorridos no mesmo local e mesmo dia (podendo assumir que as condições da floresta e do terreno não mudaram), com o objetivo de obter conhecimento sobre o nível de significância das métricas Lidar no estudo da vegetação florestal. Quatro linhas sobrepostas foram sobrevoadas na ilha de Vancouver, Canadá e das quarenta parcelas presentes nas faixas sobrevoadas foram extraídas métricas LiDAR. Os resultados foram comparados por análises de variância. Os valores de intensidade diferem, significativamente, entre os voos, o que sugere que esse valor deva ser usado com precauções e após calibração. As métricas derivadas do último retorno, também, apresentaram significante diferença e foram menos robustas quando comparadas ao do primeiro retorno. A estabilidade observada nas métricas LiDAR, relacionada com altura derivada dos primeiros retornos, deve proporcionar confiança para caracterização precisa dos ambientes florestais.

## **2.5 Modelagem das Métricas LiDAR**

A modelagem das métricas LiDAR pode ser feita de duas formas. Através do modelo de regressão linear múltipla ou através do Random Forest, a saber.

### **2.5.1 Modelo de regressão linear múltipla**

Análise de regressão é definida como uma técnica estatística para modelar e investigar a relação entre variáveis (MONTGOMERY; BALCO; WILLETT, 2001). Segundo Baptistella, Steiner e Chaves Neto (2006), a técnica

de regressão linear múltipla é usada para estudar a relação entre uma variável dependente e várias variáveis independentes.

O modelo genérico que expressa a regressão linear múltipla é descrito a seguir:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_m X_{im} + \varepsilon$$

Em que:

$Y_i$ : é a  $i$ -ésima observação da variável resposta;

$X_{ik}$ : é a  $i$ -ésima observação da  $k$ -ésima variável;

$\beta_k$ : são os parâmetros do modelo;

$\varepsilon_k$ : é o resíduo de regressão associado a  $i$ -ésima unidade amostral;

$k = 0, 1, 2, \dots, m$ , que representa ao número de variáveis;

$i = 1, 2, \dots, n$ , que representa o tamanho da amostra;

$X_{i0}$ : é a constante com todos os valores iguais a 1.

A regressão descrita acima consiste em estimar os valores dos parâmetros do modelo  $\beta_k$  pela da minimização da soma dos quadrados dos resíduos dos modelos lineares, método dos quadrados mínimos (MATOS, 1995). Assim, se  $Q = \sum_i^n \varepsilon_i^2$ , é a soma dos resíduos, o seu valor mínimo deve ser encontrado para se obter uma solução de quadrados mínimos (FERREIRA, 2009).

A regressão linear múltipla possui como pressupostos (AVILA, 2010; FERREIRA, 2009; MATOS, 1995; NETER et al., 1996; TARRÉ, 2009):

- a) Linearidade: cada variável independente deve possuir relação linear, ou próxima à linearidade com a variável dependente, é analisada por diagramas de dispersão de forma a analisar cada uma das variáveis

independentes *versus* a variável dependente. Caso isto não ocorra, tornam-se necessárias as transformações das variáveis, as principais transformações são logarítmicas, raiz quadrada, quadrática, exponencial, recíproca e exponencial negativa.

- b) Normalidade dos resíduos: a normalidade dos resíduos pode ser analisada de diferentes maneiras, por um histograma que deve possuir tendência normal, pela análise gráfica dos resíduos *versus* valores ajustados em que os pontos devem estar dispostos aleatoriamente, ou ainda, pelo exame do gráfico dos resíduos ordenados *versus* quantis da distribuição normal padronizada, que deve se aproximar da bissetriz do primeiro quadrante.
- c) Homocedasticidade: variância constante. A verificação desta condição pode ser feita por análise gráfica dos resíduos da regressão *versus* os valores estimados da variável dependente, o gráfico deve apresentar pontos dispostos aleatoriamente, sem nenhum padrão definido.
- d) Resíduos independentes, distribuídos de forma aproximada à distribuição normal: para verificação mesmo gráfica idem ao item anterior e análise do pressuposto homocedasticidade.
- e) Inexistência de colinearidade ou multicolinearidade: multicolinearidade é a alta correlação entre duas ou mais variáveis independentes em um modelo de regressão linear múltipla, isto deve ser evitado, pois, caso ocorra, acarreta perturbações ao modelo resultando em valores estimados imprecisos. Para análise, determinam-se os coeficientes de correlação simples entre as variáveis independentes, caso sejam encontrados valores absolutos próximos de 1, certamente há colinearidade.



### 2.5.2 Random Forest

*Random Forest* (RF) é um algoritmo proposto por Breiman (2001). O classificador é baseado no método *bagging* e, para cada árvore gerada, é utilizado um conjunto de treinamento diferente, formado por  $n$  instâncias de treinamento escolhidas aleatoriamente (i.e., uma amostra ou *bootstrap*), esta seleção aleatória do conjunto de treinamento diminui a correlação entre as árvores e aumenta a força de cada uma individualmente (ARCHER; KIMES, 2008).

Para cada nó da árvore gerada, são escolhidos aleatoriamente  $m$  atributos que orientam o direcionamento do nó, baseado na melhor discriminação de classes do conjunto de treinamento, de acordo com uma métrica. Em geral, o valor de  $m$  deve ser bem menor que o total de atributos da base, de maneira que possam ser geradas árvores distintas, que são combinadas para classificar uma nova instância (BREIMAN, 2001).

A classificação de um vetor de características  $x$  é feita por votação, submetendo-se o vetor às árvores da floresta e atribuindo-se a  $x$  a classe mais votada. Dessa forma, a saída do classificador é dada pela classe que foi retornada como resposta pela maioria das árvores pertencentes à floresta.

Na formulação das RF, proposta por Breiman (2001), o algoritmo básico de construção das árvores é o CART – *Classification and Regression Tree*.

CART podem ser considerados como um modelo de regressão não paramétrico, que têm por objetivo estabelecer uma relação entre um vetor de variáveis preditoras  $x$  e uma única variável resposta  $y$ . Em um CART, se a variável resposta for numérica, o modelo recebe o nome de árvore de regressão; caso contrário, é tratada como uma árvore de classificação (BOULESTEIX; TUTZ, 2006; FERREIRA; SOARES; CRUZ, 2001).

De acordo com Ferreira, Soares e Cruz (2001), CART é composto basicamente de nós (do inglês, *nodes*) e regras de divisão (do inglês, *splitting rules*). As regras de divisão representam as sucessivas divisões binárias no conjunto de dados, de modo a tornar os subconjuntos resultantes cada vez mais homogêneos, em relação à variável resposta. Essas divisões são convenientemente representadas por uma estrutura de árvore binária, na qual cada nó está associado ao subconjunto resultante da aplicação de uma regra de divisão a determinado conjunto de dados.

Como vantagens desse método, destacam-se a facilidade de interpretação e a eliminação de procedimentos externos de seleção de atributos em virtude do algoritmo de criação da árvore normalmente escolher atributos mais relevantes. Segundo Hudak et al. (2008), a natureza iterativa do método confere-lhe uma vantagem em relação a outros métodos de aprendizado de máquina e, ainda, permite derivações de medidas de importância das variáveis além de prevenir problemas com variáveis correlacionadas.

De acordo com Breiman (2001), as *Random forests* são usualmente mais estáveis que árvores de classificação individuais, no sentido de serem menos sensíveis à perturbação nos dados de treinamento. E podem ser utilizadas como alternativa à regressão linear (FERREIRA; SOARES; CRUZ, 2001).

Em estudos como de Eskelson, Barrett e Temesgen (2009) e Hudak et al. (2008) demonstraram-se que a abordagem de RF tem produzido geralmente melhores resultados de predição em comparação com uma variedade de outros métodos.

RF pode funcionar de forma eficiente em grande conjunto de dados e pode lidar com milhares de variáveis de entrada (ARCHER; KIMES, 2008). E, ainda, dados com colinearidade apresentam problemas, quando utilizados em análises estatísticas paramétricas, o que não se observa quando se utiliza RF (ANDREW et al., 2007; RESCHKE; HÜTTICH, 2014).

Archer e Kimes (2008) justificam o uso do *Random Forest* em função do fato de que a maioria dos métodos de aprendizado de máquinas, como, por exemplo, *support vector machine*, redes neurais entre outros, não fornecem uma visão das melhores variáveis que contribuem para a estrutura preditiva do modelo, bem como exigem uma pré-seleção das variáveis, o que não ocorre utilizando *Random Forest*.

De acordo com Strobl, Malley e Tutz (2009), a utilização do *Random Forest* está se tornando cada vez mais popular em muitos campos científicos pela sua capacidade de trabalhar com problemas que possuem grande volume de variáveis, interações complexas e alta correlação entre as variáveis preditoras.

### 3 MATERIAL E MÉTODOS

#### 3.1 Caracterização da área de estudo

O estudo foi realizado considerando dados coletados em plantios comerciais clonais de *Eucalyptus* spp, pertencentes à empresa Fibria Celulose S/A de oito fazendas, Santa Cruz do Sertãozinho, Santa Cecília, Patizal do Vale Feliz, São José III, Jataí, Urutay, Santa Terezinha V e Santa Terezinha VI. As fazendas estão localizadas no Vale do Paraíba Paulista, uma das mesorregiões do Estado de São Paulo (Figura 1).

O clima da região, segundo Köppen, é Cwa, caracterizado por um clima subtropical de inverno seco com temperaturas inferiores a 18°C e verão quente com temperaturas superiores a 22°C. O relevo é caracterizado como fortemente ondulado.

As parcelas foram instaladas em plantios clonais de *Eucalyptus* spp, manejados por meio de regimes silviculturais em espaçamento 3x2m, que resulta em uma densidade de plantio de 1667 covas por hectare (Tabela 1).

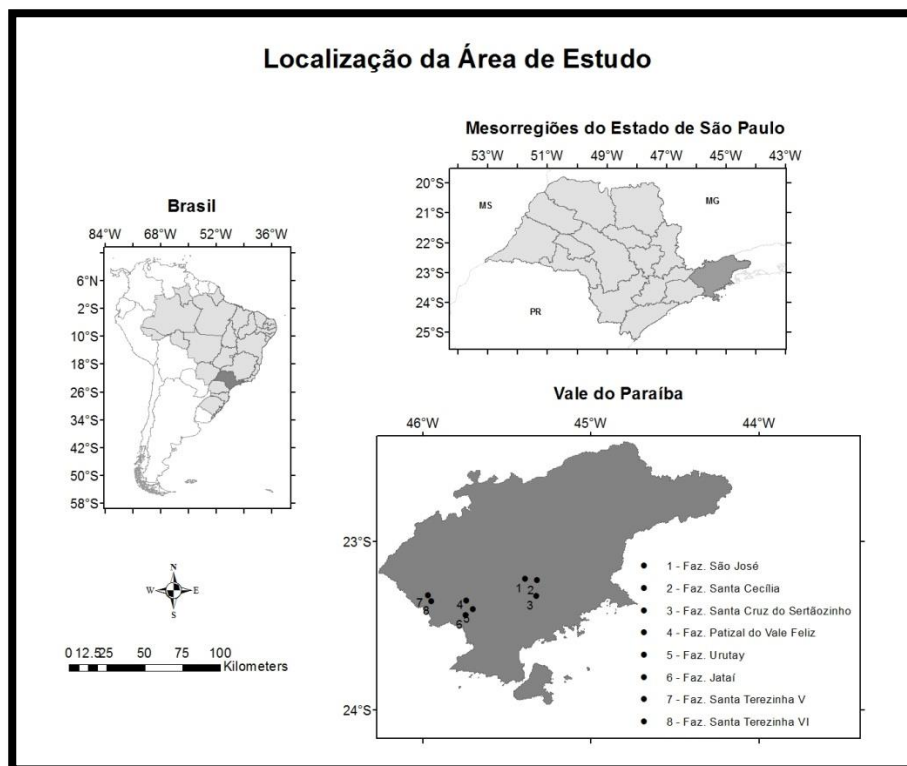


Figura 1 Localização da área de estudo

Tabela 1 Informações da área de estudo

<b>Fazendas</b>	<b>Área (ha)</b>	<b>Idade (anos)</b>
Santa Cruz do Sertãozinho	84,35	6,6
Santa Cecília	58,33	6,8
Patizal do Vale Feliz	84,81	9,5
São José III	138,96	5,4
Jataí	79,33	7,6
Urutay	80,69	6,3
Santa Terezinha V	94,16	4,3
Santa Terezinha VI	39,53	2,8

### 3.2 Estimativa do Estoque de Carbono via inventário

Para estimar o estoque de carbono, utilizou-se da equação ajustada por Silva et al. (2014) para a mesma área de estudo. O processo será descrito a seguir.

O processo em campo foi realizado em duas etapas, medição das variáveis biométricas (DAP e Ht) das árvores na parcela e coleta destrutiva da biomassa e amostras da parte aérea de 56 árvores, para posterior estimativa do carbono em laboratório.

Foram medidas 80 parcelas distribuídas nas fazendas Patizal do Vale Feliz, São José III, Jataí, Santa Terezinha V e Santa Terezinha VI. As parcelas de área circular de 400 m<sup>2</sup> foram todas georreferenciadas com GPS geodésico (Trimble ProXRT), com precisão de 10cm no pós- processamento.

Em cada parcela, mediu-se o diâmetro, a altura do peito (DAP) em centímetro (cm) de todos os indivíduos e a altura (H) em metros (m) de 15% dos indivíduos presentes na parcela e, ainda, foi contado o número de árvores bem

como avaliados seus aspectos fitossanitários. Para a mensuração do DAP, utilizou-se a suta métrica e, para medição das alturas, o clinômetro.

As árvores das parcelas que não tiveram as alturas diretamente medidas, a equipe de inventário da empresa disponibilizou estimativas calculadas com base em equações hipsométricas de acesso restrito aos funcionários da empresa.

Para a calibração e ajuste estatístico de modelos que correlacionassem as biométricas DAP e Ht diretamente com o carbono florestal, abateram-se 56 árvores no campo para a coleta destrutiva de amostras e posterior quantificação precisa do carbono presente nessas amostras, em laboratório.

Para a modelagem do carbono total de cada árvore, utilizou-se o modelo logaritimizado de Schumacher e Hall (1993) (1). O melhor modelo de regressão ajustado por Silva et al. (2014) para a estimativa do carbono total da parte aérea da árvore utiliza como variáveis independentes o logaritmo do DAP e Ht dos indivíduos (Tabela 2).

$$\ln(Y) = \beta_0 + \beta_1 * \ln(DAP) + \beta_2 * \ln(Ht) + \varepsilon \quad (1)$$

Em que:

*Ln*: logaritmo neperiano;

*Y*: carbono total – (kg.árv.<sup>-1</sup>);

*DAP*: diâmetro a 1,30m de altura, cm;

*Ht*: altura total das árvores, m;

*Bi*: parâmetros, para i= 0, 1 e 2;

$\varepsilon$ : erro aleatório

Tabela 2 Modelo de regressão ajustado para estimativa do carbono total

<b>Modelo</b>	$\text{Ln}(\text{Ctotal}) = - 2,87 + 1,95\text{Ln}(\text{DAP}) + 0,44\text{Ln}(\text{Ht})$
<b>R<sup>2</sup> ajd</b>	0,97
<b>rx<sub>y</sub></b>	0,98
<b>S<sub>yx</sub></b>	0,12
<b>RMSE (kg.árv<sup>-1</sup>)</b>	4,57
<b>RMSE (%)</b>	12,38

R<sup>2</sup>ajd: Coeficiente de determinação ajustado; r<sub>xy</sub>: Correlação Linear de Pearson entre os valores observados *versus* estimados; S<sub>yx</sub>: Erro padrão residual, RMSE: raiz do erro quadrático médio absoluto e percentual.

Os coeficientes que compõem os modelos ajustados foram todos significativos a um nível de 99% de probabilidade, pelo teste *t* de Student.

Pelo modelo descrito acima, calculou-se o estoque de carbono para cada árvore presente nas parcelas de cada fazenda, obtendo-se, ao final, o estoque de carbono total por parcela em Mg/ha ou T/ha.

### 3.3 Estimativa do estoque de carbono via LiDAR

Para se estimar o estoque de carbono via LiDAR realizou-se alguns procedimentos descritos detalhadamente a seguir.

#### 3.3.1 Aquisição dos dados LiDAR

Foram realizados dois voos LiDAR com características diferentes. Os voos aconteceram no início de 2012, utilizando uma aeronave bimotor Piper Seneca II acoplada a uma câmara HARRIER 68i, IMU/GPS Applanix 510 e sensor LiDAR Riegl LMS Q6801. Detalhes de cada voo são descritos na tabela 3.



Tabela 3 Dados técnicos dos Voos 1 e 2

Atributos	Valores – Voo 1	Valores – Voo 2
<b>Densidade do Pulso</b>	10 pontos/m <sup>2</sup>	5 pontos/m <sup>2</sup>
<b>Resolução Espacial</b>	0.15m	0.5 m
<b>Bandas</b>	RGB e IR	RGB e IR
<b>Resolução Espectral</b>	8 bits	32 bits
<b>Velocidade</b>	57m/s (205.20km/h)	55 m/s (198 km/h)
<b>Altura do Voo</b>	422.94 m	629.24 m
<b>Ângulo de Varredura</b>	45°	60°
<b>Precisão</b>	10 – 15 cm (IMU)	10 – 15 cm (IMU)
<b>Largura da Faixa de Cobertura</b>	350.37 m	726.58 m
<b>Frequência de Varredura</b>	400 Kh	300 Kh
<b>Câmera</b>	Z/1 DMC	Harrier 68i
<b>IMU/GPS</b>	Applainix 510	Applainix 510
<b>Datum</b>	SIRGAR 2000/ UTM ZONA 23S	SIRGAR 2000/ UTM ZONA 23S

### 3.3.2 Processamento dos dados

Para o processamento dos dados LiDAR, utilizou-se o aplicativo FUSION versão 3.3, desenvolvido pelo Serviço Florestal Norte Americano. O FUSION é um *software* gratuito e disponível para download em <<http://forsys.cfr.washington.edu/fusion/fusionlatest.html>>.

O processamento dos dados foi desenvolvido em diversas etapas. Inicialmente realizou-se uma análise descritiva da nuvem de pontos pela ferramenta *catalog* que permitiu uma análise detalhada da nuvem de pontos.

Na sequência, foi realizada a classificação da nuvem de pontos pela função *GroundFilter*, com o objetivo de identificar os pontos pertencentes ao terreno e os não pertencentes. Os pontos pertencentes ao terreno são as medidas

obtidas do terreno nu e que, muitas vezes, encontram-se abaixo dos objetos e os pontos não pertencentes ao terreno são as medidas dos objetos acima do solo (árvores, arbusto). Esta diferenciação é necessária para a elaboração dos Modelos Digitais do Terreno (MDT).

A função *GroundFilter* utiliza um algoritmo para filtragem, desenvolvido por Kraus e Pfeifer (1998), baseado na Interpolação Polinomial (IP) dos mínimos quadrados, de forma a distinguir os pontos pertencentes ao terreno dos pontos não pertencentes.

Trata-se de um processo iterativo; na primeira etapa, uma superfície é calculada com pesos iguais para todos os pontos registrados pelo sensor LiDAR, resultando em uma superfície que se situa entre os verdadeiros valores do terreno e a superfície do dossel da floresta. Os pontos do terreno são mais propensos a encontrarem-se abaixo da superfície calculada, enquanto os pontos da vegetação acima desta superfície. A distância e a direção da superfície são usadas para calcular os pesos para cada ponto LiDAR utilizando a seguinte função de peso (2): (ALVES, 2010; MACGAUGHEY, 2014).

$$p_i = \begin{cases} 1 & v_i \leq g \\ \frac{1}{1+(a(v_i-g)^b)} & g < v_i \leq g + v \\ 0 & g + w < v_i \end{cases} \quad (2)$$

Em que:

$a$  e  $b$ : parâmetros que determinam o peso da inclinação da função;

$g$ : determina quais os pontos são atribuídos a um peso, 1 é o valor máximo que pode assumir e, neste caso, esse valor é dado aos pontos que se encontram abaixo da superfície;

$w$ : parâmetro usado para estabelecer um limite máximo de pontos para ter uma influência sobre a superfície intermediária calculada;

$v_i$  : resíduo dos pontos em relação à superfície calculada inicialmente.

Dessa forma, todos os pontos com uma elevação que satisfaçam as duas primeiras condições de peso da função serão considerados como pontos pertencentes ao terreno da área objeto de estudo. Os valores dos parâmetros descritos acima  $a$ ,  $b$ ,  $g$  e  $w$ , utilizados no presente estudo, foram 1, 4, -1 e 2, respectivamente (ALVES, 2010).

Com os pontos LiDAR classificados em pertencentes ao terreno e não pertencentes ao terreno, a próxima etapa foi a elaboração dos modelos digitais. Criou-se o Modelo Digital do Terreno (DTM – *Digital Terrain Models*), a partir dos pontos pertencentes ao terreno, por meio da ferramenta *GridSurfaceCreate*. O Modelo Digital da Superfície (DSM – *Digital Surface Models*) foi criado a partir dos pontos não pertencentes ao terreno e o Modelo Digital Alturas do dossel (CHM – *Canopy Height Models*) obtido pela subtração entre os dois primeiros modelos criados. DSM e CHM foram criados pela ferramenta *CanopyModel*.

O Modelo Digital das Alturas do dossel representa a altura dos objetos presentes na nuvem de pontos LiDAR e é o modelo utilizado para obtenção das métricas LiDAR.

Antes da criação das métricas LiDAR, utilizou-se a ferramenta *ClipDATA* para recortar as áreas de cada uma das parcelas de cada fazenda.

De posse das alturas de cada ponto em cada parcela, calcularam -se as métricas LiDAR por meio da ferramenta *CloudMetrics* para pontos com valores de altura acima de 2 metros, eliminando-se pontos pertencentes ao terreno e possíveis efeitos de pedras, raízes, etc. (NAESSET, 2002). Todas estas etapas foram realizadas para os dados LiDAR do voo 1 e voo 2.

Como resultado dos procedimentos descritos acima, obteve-se um total de 40 variáveis. Cada uma delas, descritas a seguir.

a) Total de retornos contados ( $N$ ):

Em cada parcela foi computado o número total de retornos, ou seja, o número de vezes que o laser atingiu os alvos.

b) Total de retornos contados acima de 2m ( $n$ ):

Trata-se do número de retornos obtidos a partir de objetos com mais de 2 metros de altura.

c) Primeiro ( $i$ ), segundo ( $ii$ ), terceiro ( $iii$ ) e quarto ( $iv$ ) retornos contados acima de 2m:

Um único pulso laser emitido reflete inúmeros retornos. Essas variáveis descrevem o número de primeiro, segundo, terceiro e quarto retornos acima de 2 metros de altura, respectivamente.

d) Total de primeiros retornos contados ( $NI$ ):

Número de retornos contados em cada parcela, provenientes do primeiro retorno do pulso laser.

e) Porcentagem do primeiro retorno acima de 2m ( $nI$ ):

Porcentagem do número de primeiros retornos que estavam acima de 2 metros, em cada parcela.

f) Porcentagem do total de retornos acima de 2m ( $np$ ):

Porcentagem do total de retornos contados acima de 2 metros em cada parcela.

g) Razão entre total de retornos acima de dois metros e o total de primeiros retornos, multiplicado por cem de cada parcela ( $r$ ).

h) Elevação mínima ( $hmin$ ), intensidade mínima ( $inmin$ ), elevação máxima ( $hmax$ ) e intensidade máxima ( $inmax$ ):

Elevação mínima, intensidade mínima, elevação máxima e intensidade máxima obtidas em cada parcela, respectivamente.

i) Elevação ( $hmed$ ) e intensidade média ( $inmed$ ):

$$med = \frac{1}{n} \times \sum_{i=1}^n Wi \quad (3)$$

Em que:

$n$ : número de observações (número de pontos da nuvem);

$w$ : altura ou intensidade do  $i$ -ésimo ponto da nuvem de pontos.

j) Desvio padrão da altura ( $hdesv$ ) e intensidade ( $indesv$ ):

$$desv = \sqrt{\frac{1}{n-1} \times \sum_{i=1}^n (Wi - Wmed)^2} \quad (4)$$

Em que:

$Wmed$  = altura ou intensidade média da nuvem de pontos.

k) Coeficiente de variação da altura ( $hcv$ ) e intensidade ( $incv$ ):

$$cv = \frac{desv}{med} \quad (5)$$

l) Percentis da altura da nuvem de pontos LiDAR ( $p$ ):

O  $i$ -ésimo percentil de  $n$  pontos, representado na nuvem de pontos LiDAR, ordenado em valores em altura, é correspondente ao valor que ocupa a posição  $K$  do conjunto de dados, como segue a equação a seguir.

$$K = \frac{hpi(n + 1)}{100} \quad (6)$$

Em que:

$K$  = valor que ocupa o  $i$ -ésimo percentil em altura na nuvem de pontos;

$hpi$  =  $i$ -ésimo percentil em altura na nuvem de pontos;

$n$  = número de observações (número de pontos na nuvem).

Os percentis obtidos foram de  $p5$ ,  $p10$ ,  $p25$ ,  $p50$ ,  $p75$ ,  $p90$  e  $p95\%$ .

m) Canopy relief ratio ( $crr$ ):

Trata-se de uma suavização do dossel, calculada pela razão entre a diferença da altura média e mínima e a diferença entre altura máxima e mínima.

$$Crr = \frac{(hmed - hmin)}{(hmax - hmin)} \quad (7)$$

n) Densidade de pontos em cada estrato (*Stratum*);

A nuvem de pontos foi dividida em estratos iguais de 10 em 10% a partir de 0% até 95% da altura. O estrato 100% foi substituído pelo de 95% em decorrência do fato deste ser mais estável (STEPHENS et al., 2012). Logo, a

variável densidade de pontos representa o número total de retornos em cada estrato. Neste trabalho, os estratos selecionados foram 0% ( $s_0$ ), 10% ( $s_1$ ), 20% ( $s_2$ ), 30% ( $s_3$ ), 40% ( $s_4$ ), 50% ( $s_5$ ), 60% ( $s_6$ ), 70% ( $s_7$ ), 80% ( $s_8$ ), 90% ( $s_9$ ) e 95% ( $s_{10}$ ).

### 3.4 Modelagem do estoque de carbono por meio das variáveis LiDAR

Neste estudo, para modelagem do estoque de carbono pelas variáveis LiDAR, foram utilizadas duas técnicas: regressão linear múltipla e *random forest*.

#### 3.4.1 Regressão Linear Múltipla

O modelo matemático, que expressa a equação de regressão linear múltipla, é descrito a seguir:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \epsilon$$

Em que:

Y: variável dependente (Biomassa)

$\beta_0$ : intercepto no eixo Y

$\beta_i$ : coeficiente angular da  $i$ -ésima variável independente ou preditiva

k: número de variáveis independentes ou preditivas

$\epsilon$ : erro aleatório.

De posse das variáveis independentes, utilizou-se uma regressão *stepwise*, para selecionar o melhor modelo de regressão linear múltipla.

Foi utilizada a regressão *stepwise “forward”*. Escolhe-se um modelo inicial ou mínimo e a partir dele é acrescentada uma variável de cada vez e o modelo resultante é ajustado. O critério AIC é calculado para cada modelo e os que apresentarem valores menores são colocados acima do modelo inicial e os de valores maiores abaixo do modelo inicial. Esse processo se repete até que nenhuma das variáveis candidatas consiga compor um modelo com menor AIC do que o modelo atual ou quando não houver mais variáveis candidatas a entrar no modelo (FERREIRA, 2009).

O critério de informações de Akaike (AIC) é descrito por Akaike (1974):

$$AIC = -2\log\left(\left(L(\sigma^2)\right) + 2p\right) \quad (8)$$

Em que:

L: tamanho da amostra;

p: número de parâmetros do modelo;

$\sigma^2$ : estimativa da verossimilhança da variância.

Segundo este critério, quanto menor o valor de AIC obtido pelo modelo, mais plausível é o modelo e melhor sua qualidade.

Neste estudo, o modelo inicial ou mínimo utilizado foi o intercepto ( $y \sim 1$ ) e como modelo máximo, o modelo de regressão linear múltipla composto pelas variáveis independentes definidas no item anterior ( $y \sim x_1 + x_2 + x_3 + x_4 + x_5 + x_6$ ).

#### **3.4.1.1 Avaliação dos modelos construídos**

Os modelos foram primeiramente avaliados quanto à normalidade e homogeneidade de variância pela análise gráfica dos resíduos normalizados e pelos testes estatísticos de Shapiro.



Para uma avaliação quanto à sua precisão, utilizaram-se os parâmetros estatísticos da regressão: coeficiente de determinação ajustado ( $R^2_{ajd}$ ), erro padrão residual ( $S_{xy}$ ), correlação linear de Pearson ( $r_{xy}$ ), raiz quadrada do erro quadrático médio absoluto e médio percentual (RMSE e RMSE%).

### 3.4.2 *Random Forest*

*Random Forest* é uma técnica não paramétrica em que as variáveis independentes podem ser numéricas ou categóricas e, ainda, pode ser executado no modo de regressão ou classificação (HUDAK et al., 2012). Neste estudo, as variáveis são numéricas e foi utilizado o *random forest* como regressão.

Para o processamento do RF, dois parâmetros têm que ser bem definidos. O primeiro é o número de árvores utilizadas, neste estudo utilizaram-se 300 árvores por variável independente (LAFITI; NOTHDURFT; KOCH, 2010), totalizando 1800 árvores. O outro parâmetro é denominado  $m$ , definido como um subconjunto das variáveis independentes disponíveis utilizadas para determinar a divisão de cada árvore (nó). O valor de  $m$  corresponde à parte inteira da raiz quadrada do número de variáveis independentes (SMITH; GANESH; LIU, 2013) que, neste caso, foi 2. Essa seleção aleatória dos recursos em cada nó diminui a correlação entre as árvores diminuindo, assim, a taxa de erro (BREIMAN, 2001).

No final do processamento, obtém-se como resultado uma proporção da variável explicada para o modelo global e, ainda, para cada uma das variáveis de previsão.

A importância de cada variável é avaliada por duas medidas. A primeira fornece uma medida de precisão, por meio da quantificação do grau que a inclusão de uma variável no modelo diminui o erro quadrático médio.

A outra medida é o índice Gini, uma medida de impureza dos nós, que é utilizado para selecionar a separação com a menor impureza em cada nó. Dividindo um nó numa variável, faz-se com que o índice de Gini, para os dois nós descendentes, seja menor do que o nó pai. Somando essas reduções no índice de Gini para uma variável por intermédio da floresta de árvores de classificação fornece uma medida da importância variável.

Para cada árvore na floresta, a classe prevista para cada observação é obtida. A classe com o número máximo de votos entre as árvores na floresta é a classe prevista de uma observação.

### **3.5 Análise estatística**

A fim de estudar a influência das características do voo na estimativa do estoque de carbono, bem como o efeito dos dois tipos de modelagem do estoque de carbono via métricas LiDAR abordados no presente estudo, optou-se pelo uso da análise de variância, em razão da simplicidade do método e sua precisão.

O nível de confiança foi de 5% e foi testado voo1, voo2, regressão linear múltipla e *random forest*. Posteriormente, para complementar o teste de análise de variância, foi realizado o teste de comparação de média de Tuckey-Kramer.

## 4 RESULTADOS E DISCUSSÕES

### 4.1 Estoque de carbono via inventário

O estoque de carbono total estimado baseado na equação (9), obtida por Silva et al. (2014), para cada fazenda, encontra-se na tabela 4.

$$\ln(C_{total}) = -2,87 + 1,95 \times \ln(DAP) + 0,44 \times \ln(Ht) \quad (9)$$

Tabela 4 Estoque de Carbono Total

Fazenda	C total (Mg/ha)	Área (ha)	C total (Mg)
Santa Cruz do Sertãozinho	75,61	84,35	6377,79
Santa Cecília	67,33	58,33	3927,54
Patizal do Vale Feliz	75,19	84,81	6376,77
São José III	70,82	138,96	9840,66
Jataí	61,74	79,33	4897,77
Urutay	66,46	80,69	5362,66
Santa Terezinha V	49,12	94,16	4624,73
Santa Terezinha VI	27,87	39,53	1101,51

### 4.2 Estoque de carbono via métricas LiDAR

Os resultados do estoque de carbono via métricas LiDAR estão descritos a seguir.

#### 4.2.1 Produtos do processamento do voo LiDAR

Os produtos obtidos pelo processamento de dados LiDAR, foram:

- a) Modelo Digital do Terreno (DTM);

- b) Modelo Digital da Superfície (DSM);
- c) Modelo Digital da Altura das Copas (CHM);
- d) Métricas da nuvem de pontos LiDAR.

#### **4.2.2 Modelagem do estoque de carbono via LiDAR**

Os resultados da modelagem do estoque de carbono via LiDAR através dos métodos regressão linear múltipla e Random Forest estão descritos a seguir.

##### **4.2.2.1 Regressão linear múltipla**

O método utilizado para gerar o modelo de estoque de carbono com base nas métricas LiDAR foi o *stepwise*. Este método seleciona as melhores variáveis, bem como os melhores métodos de acordo com o critério AIC. O modelo mínimo ou inicial é representado pelo intercepto e cada variável independente é testada quanto sua entrada ou não no modelo, sua entrada ocorre se o valor do AIC relacionado a ela for menor em relação às demais e, ainda, se o valor do AIC do modelo com sua entrada for menor que o AIC sem ela.

Os modelos selecionados para os voos 1 e 2 podem ser observados na tabela 5.

Tabela 5 Modelos de regressão linear múltipla para métricas LiDAR

<b>Voo</b>	<b>Modelo</b>	<b>R<sup>2</sup><sub>ajd</sub></b>	<b>S<sub>yx</sub></b>	<b>RMSE (Mg/ha)</b>	<b>RMSE (%)</b>
<b>1</b>	$C_{total}^{1/2} = -1,13 + 1,79(h_{p50}^{1/2}) + 0,01(S_{VI}^{1/2})$	0,83	0,50	7,82	12,60
<b>2</b>	$C_{total}^{1/2} = -1,07 + 1,79(h_{p50}^{1/2}) + 0,01(S_{VI}^{1/2})$	0,84	0,49	7,71	12,41

$R^2_{ajd}$ : coeficiente de determinação ajustado;  $S_{yx}$ : erro padrão residual;  $RMSE$ : Raiz quadrada do erro quadrático médio absoluto e percentual.

Os modelos ajustados foram aceitos quanto aos pressupostos de normalidade e homogeneidade de variâncias.

O pressuposto de normalidade foi avaliado graficamente (Figura 2 B e C) pelo gráfico qq-Plot, em que os pontos no gráfico se aproximaram de uma reta característica da distribuição normal. Quanto à avaliação pelo teste de Shapiro-Wilk (Tabela 6), como os valores de significância foram superiores a 0,05, os dados apresentaram distribuição normal.

O pressuposto de homogeneidade de variâncias ou homoscedasticidade foi avaliado pelo gráfico de resíduos *versus* valores ajustados (Figuras 2 A e D). Não houve nenhuma tendência, ou seja, os pontos estão distribuídos aleatoriamente em torno do 0, indicando que a variância dos resíduos é homoscedástica, o que foi observado neste estudo (Figuras 2 A e D).

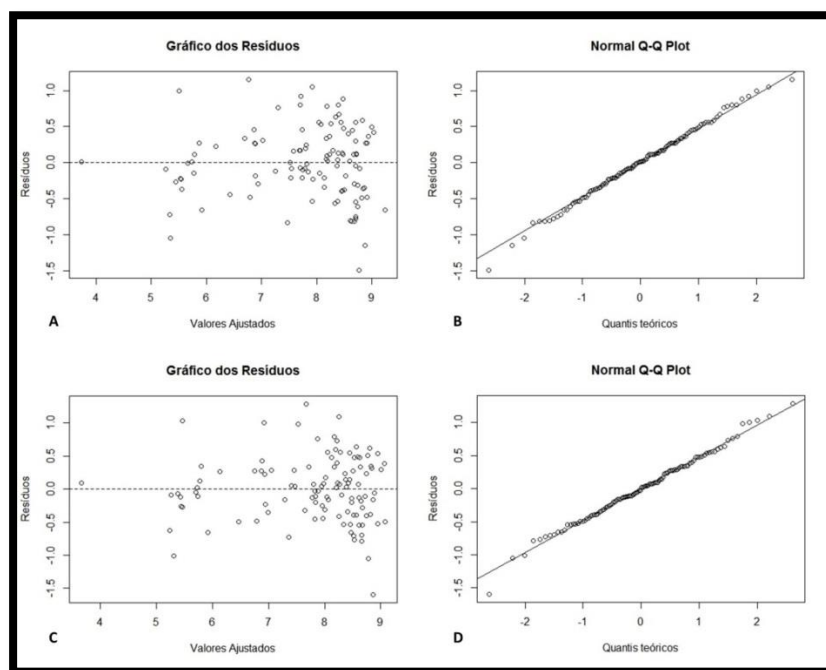


Figura 2 Análise Gráfica dos resíduos. A e B: gráficos do voo 1; C e D: gráficos do voo 2

Tabela 6 Teste de normalidade pelo método Shapiro-Wilk

Voo	Shapiro-Wilk	
	Estatística	Sig.
1	0,99	0,98
2	0,99	0,85

Sig: Significância do teste a 95% de probabilidade. Sig > 0,05, aceita Ho.

Analisando os parâmetros estatísticos, verifica-se que os modelos se ajustaram bem aos dados observados. Em relação aos coeficientes de determinação ajustados ( $R^2_{ajd}$ ), as variáveis independentes apresentam um poder explicativo do comportamento da variável dependente, estoque de carbono, de

83 e 84% para voos 1 e 2, respectivamente. Os valores da correlação linear de Pearson foram de 91 e 92%, voo 1 e voo 2, respectivamente, demonstrando uma alta correlação entre os valores estimados e observados. E, ainda, os baixos valores de RMSE garantem uma maior exatidão dos modelos ajustados.

Estes parâmetros estatísticos dos modelos ajustados foram similares aos encontrados nos trabalhos envolvendo modelagem das métricas LiDAR por regressão linear múltipla para estimar biomassa florestal e estoque de carbono acima do solo. Os coeficientes de determinação entre métricas LiDAR e biomassa florestal acima do solo variaram entre 0,74 e 0,96 nos estudos de Lefsky et al. (2002), Naesset (2004), Nelson, Niemann e Wulder (2007), Silva et al. (2014) e Stephens et al. (2012).

Os coeficientes que compõem os modelos ajustados, para a estimativa do estoque de carbono total, tanto no voo 1 quanto no voo 2 foram todos significativos com 95% de probabilidade, pelo teste “t”, de Student, como podem ser observados na tabela 7.

Tabela 7 Estatística para os coeficientes dos modelos

Voo	Variáveis	Estimativa	SE	t valor	Pr(> t )	Sign
1	<i>Intercepto</i>	-1,13	0,5017	-2,249	0,0265	*
	$h_{p50}$	1,79	0,1157	15,487	< 2E-16	***
	$S_{VI}$	0,01	0,0023	4,436	2,2E-5	***
2	<i>Intercepto</i>	-1,07	0,4697	-2,278	0,0247	*
	$h_{p50}$	1,79	0,1076	16,612	< 2E-16	***
	$S_{VI}$	0,01	0,0137	4,195	5,57E-5	***

SE: Erro padrão; Sign: Significância; ‘\*\*\*’ 0,001, ‘\*’ 0,05

Para ambos os voos, as variáveis selecionadas para comporem o modelo foram altura no percentil 50 e *Stratum VI* (densidade de pontos no estrato entre as alturas de 23,4 e 27,30 metros).

Observa-se uma constante nos estudos que estimam biomassa e/ou carbono, a partir das métricas LiDAR, no que diz respeito aos percentis altura e cobertura do dossel.

Naesset e Gobakken (2008), estimando a biomassa florestal acima do solo a partir das métricas LiDAR, utilizaram percentil 90 da altura e densidade do dossel como variáveis independentes da regressão. Segundo eles, a variável altura do dossel era mais explicativa para biomassa aérea florestal do que a densidade do dossel.

Stephens et al. (2012), realizando um inventário do estoque de carbono na Nova Zelândia, desenvolveram um modelo de regressão a partir do percentil 30 da altura e cobertura do dossel. Silva et al. (2014), estimando o estoque de carbono acima do solo presente em um plantio de eucalipto, desenvolveram o modelo de estimativa a partir do percentil 95, do coeficiente de variação e do desvio padrão da altura, do percentil 80 da intensidade e da cobertura do dossel.

Os nossos modelos apresentaram no lugar da variável cobertura do dossel a variável *Stratum*. Durante o desenvolvimento do modelo, observou-se uma alta correlação entre estas variáveis; isto se justifica, pois o *Stratum* está relacionado à cobertura do dossel compreendida entre um intervalo de altura (HUDAK et al., 2012).

#### **4.2.2.2 *Random Forest***

Para o processamento do RF, fixou-se o número de árvores em 1800 e o valor de  $m$  em 2. A primeira corrida foi realizada com as seis variáveis independentes.



A partir das figuras 3 e 4, observa-se a importância global de cada uma das variáveis (%IncMSE), bem como o grau de pureza de cada uma delas (IncNodePurity), nos voos 1 e 2, respectivamente.

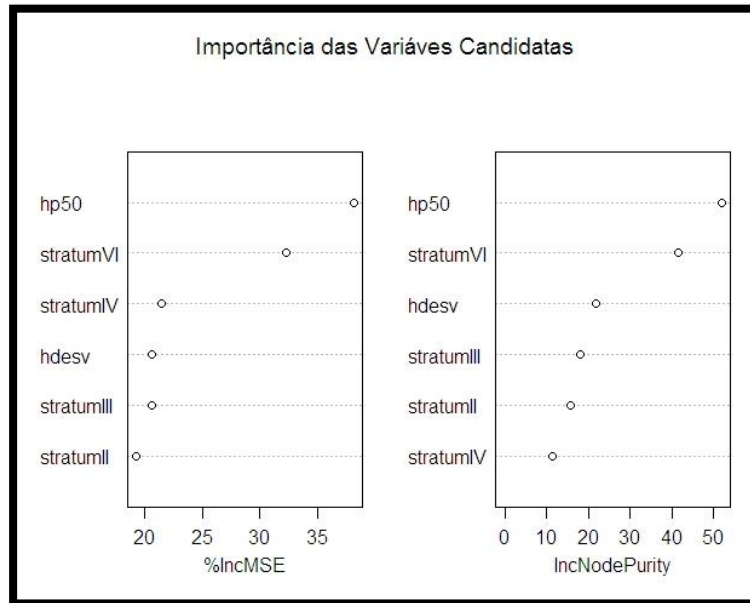


Figura 3 Importância das variáveis candidatas do voo 1




Figura 4 Importância das variáveis candidatas do voo 2

Assim como na regressão linear múltipla, o RF, também, foi processado diversas vezes buscando-se o melhor modelo de predição para o estoque de carbono.

Para ambos os voos, o melhor modelo obtido foi o que utilizou de duas variáveis independentes, sendo elas, *hp<sub>50</sub>* e *stratum VI*. O modelo selecionado para o voo 1 obteve 82% da variável resposta explicada enquanto para o voo 2 esse valor foi de 79 %, os valores de RMSE foram de 8,02 e 8,72 Mg ha<sup>-1</sup> e RMSE% de 12,91% e 14,04% para os voos 1 e 2, respectivamente.

Os valores acima descritos foram considerados bons e similares ao encontrado por Hudak et al. (2012), que, ao modelarem as métricas LiDAR utilizando RF, obtiveram um modelo cujas variáveis preditivas foram altura média do dossel e distribuição da copa com poder explicativo de 80% para estimar o estoque de carbono.

Latifi et al. (2010) analisaram o desempenho de preditores não paramétricos na estimativa da biomassa florestal e do volume em florestas temperadas a partir das métricas LiDAR. Dentre os métodos analisados, o random forest obteve melhores resultados com um RMSE% de 23,52 para biomassa florestal e 23,26% para volume.

### 4.3 Análise estatística

Realizou-se a análise estatística a fim de identificar qual dos modelos apresentados anteriormente melhor representava os dados estudados.

O tratamento 1 representa o modelo obtido a partir dos dados provenientes do voo 1 modelados, via regressão linear múltipla, tratamento 2 voo 1 modelado, via *Random Forest*, tratamento 3 voo 2 modelado, via regressão linear múltipla e tratamento 4 voo 2 modelado via *Random Forest*.

A análise de variância pode ser observada na tabela 8.

Tabela 8 Análise de variância para os tratamentos 1, 2, 3 e 4.

<b>FV</b>	<b>GL</b>	<b>SQ</b>	<b>QM</b>	<b>Fc</b>	<b>Pr&gt;F</b>
<b>Tratamento</b>	3	4,63	1,54	0,006	1,00
<b>Erro</b>	444	109482,45	246,58		
<b>Total</b>	447	109487,08			
<b>Corrigido</b>					
<b>CV (%):</b>	25,41				
<b>Média Geral:</b>	61,80				

FV: fator de variação; GL: grau de liberdade; SQ: soma de quadrado; QM: quadrado médio; Fc: F calculado.

Observando-se o resultado do teste F na análise de variância, deve-se aceitar a hipótese nula de igualdade de efeito dos tratamentos, considerando um valor nominal de significância de 5%.

Os voos 1 e 2 não apresentaram diferenças significativas em virtude do fato de ambos terem sido realizados com o mesmo sensor. Naeset (2009), estudando os efeitos dos diferentes sensores, altitudes de voo, frequência de varredura e densidade de pontos, na estimativa de altura da árvore e volume de madeira, observou diferenças maiores variando-se os sensores do que para as demais características.

Goodwin, Coops e Culvenor (2006) estudaram o efeito da plataforma de altitude em estudos da vegetação a partir das métricas LiDAR para um mesmo sensor. Avaliaram-se três diferentes plataformas de altitude (1000, 2000 e 3000 m), dois ângulos de varredura (10° e 15°) e três tamanhos de footprint (0,2, 0,4 e 0,6 m). Não obtiveram diferença significativa entre os voos.

Acredita-se, também, que a variação de alguns parâmetros do voo 1 para o 2 foi pequena e, dessa forma, não houve diferença nos resultados finais. Resultados similares foram observados no estudo realizado por Naeset e Gobakken (2008) que utilizaram quatro instrumentos ALS diferentes variando a densidade de pontos de 0,7 a 1,2 m<sup>2</sup> e ângulo de varredura de 13 a 15° para o estudo da biomassa florestal.

As métricas LiDAR modeladas a partir do *Random Forest* e da Regressão linear múltipla não apresentaram diferenças significativas. Smith, Ganesh e Liu (2013) compararam *Random Forest* e regressão linear múltipla para predição em neurociência e concluíram que regressão linear múltipla apresentou-se superior em termos de predição e valor de erro. Segundo eles, isto ocorreu em razão de o fato de as variáveis neurológicas apresentarem interações complexas e não lineares de múltiplas variáveis.

Diferentemente do estudo citado acima, as variáveis florestais, tais como biomassa e estoque de carbono se ajustam bem à modelagem a partir do algoritmo *Random Forest*. Lafiti, Nothdurft e Koch (2010) analisaram o desempenho de preditores não paramétricos na estimativa da biomassa florestal a partir das métricas LiDAR e obtiveram como melhor método o *Ranom Forest*. Hudak et al. (2008), estimando área basal e densidade de árvores a partir de métricas LiDAR, por meio de métodos de imputação, com base na distância euclidiana normalizada e não normalizada, concluíram que RF foi o mais robusto e flexível entre os métodos de imputação testadas. E, também, que as métricas LiDAR são ideais para métodos de imputação.

A estimativa do estoque de carbono total (Mg) para cada fazenda nos quatro tratamentos pode ser observada na tabela 9.

Tabela 9 Estoque de carbono total (Mg)

<b>Fazenda</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>
<b>Santa Cruz do Sertãozinho</b>	6399,62	6104,35	6447,27	6163,87
<b>Santa Cecília</b>	4025,08	4074,04	4144,55	4051,38
<b>Patizal do Vale Feliz</b>	6536,94	6335,34	6485,58	6193,09
<b>São José III</b>	9263,27	9435,46	9214,89	9292,06
<b>Jataí</b>	4711,33	4793,15	4832,44	4925,33
<b>Urutay</b>	5216,63	5345,64	5113,99	5383,49
<b>Santa Terezinha V</b>	4597,82	4638,51	4606,34	4624,38
<b>Santa Terezinha VI</b>	1212,94	1189,46	1193,07	1194,14

1: tratamento 1 (voo1 e regressão linear múltipla); 2: tratamento 2 (voo1 e *Random Forest*); 3: tratamento 3 (voo 2 e regressão linear múltipla); 4: tratamento 4 (voo 2 e *Random Forest*).

## 5 CONCLUSÕES

Conclui-se que:

- a) As métricas LiDAR estão correlacionadas ao estoque de carbono, ou seja, a partir das métricas LiDAR é possível obter estimativas acuradas do estoque de carbono em florestas plantadas de eucalipto.
- b) As métricas LiDAR percentis da altura e densidade de pontos (*stratum*) foram as mais correlacionadas ao estoque de carbono.
- c) Não houve diferença significativa na estimativa do estoque de carbono obtido pelo voo 1 e voo 2.
- d) Não houve diferença significativa entre a modelagem do estoque de carbono a partir da regressão linear múltipla ou *Random Forest*.
- e) A modelagem das métricas LiDAR por meio do *Random Forest* para estimativa do estoque de carbono pode ser reproduzida em trabalhos futuros.

## REFERÊNCIAS

- AKAIKE, H. A new look at the statistical model identification. **IEEE Transactions on Automatic Control**, Boston, v. 19, n. 6, p. 716-723, Dec. 1974.
- ALVES, M. V. G. **Estimativa de variáveis florestais com perfilamento a laser (LiDAR)**. 2010. 140 f. Tese (Doutorado em Engenharia Florestal) - Universidade Federal do Paraná, Curitiba, 2010.
- ANDREW, T. et al. Regression modeling and mapping of coniferous forest basal area and tree density from discrete-return lidar and multispectral satellite data. **Canadian Journal Remote Sensing**, Ottawa, v. 32, n. 2, p. 126-138, Apr. 2007.
- ARAÚJO, T. M.; HIGUCHI, N.; CARVALHO JÚNIOR, A. Comparison of formulae for biomass content determination in a tropical rain forest site in the state of Pará, Brazil. **Forest Ecology and Management**, Amsterdam, v. 117, n. 1/3, p. 43-52, May 1999.
- ARCHER, K.; KIMES, R. Empirical characterization of random forest variable importance measures. **Computational Statistics & Data Analysis**, New York, v. 52, n. 4, p. 2249-2260, 2008.
- AVILA, F. M. **Regressão linear múltipla**: ferramenta utilizada na determinação do valor de mercado de imóveis. 2010. 102 p. Monografia (Graduação em Engenharia Civil) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2010.
- BAPTISTELLA, M.; STEINER, M. T. A.; CHAVES NETO, A. O uso de redes neurais e regressão linear múltipla na engenharia de avaliações: determinação dos valores venais de imóveis urbanos. In: SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, 38., 2006, Goiânia. **Anais...** Goiânia: UFG, 2006. 1 CD-ROM.

BATER, W. C. et al. Stability of sample-based scanning-LiDAR-derived vegetation metrics for forest monitoring. **Transactions on Geosciences and Remote Sensing**, Piscataway, v. 49, n. 6, p. 2385-2392, 2011.

BOELMAN, N. T. et al. Response of NDVI, biomass and ecosystem gas exchange to long-term warming and fertilization in wet sedge tundra. **Oecologia**, Berlin, v. 135, n. 3, p. 414-421, May 2003.

BOULESTEIX, A.; TUTZ, G. Identification of interaction patterns and classification with applications to microarray data. **Computational Statistics & Data Analysis**, New York, v. 50, p. 783-802, 2006.

BREIMAN, L. Random forest. **Machine Learning**, Boston, v. 45, n. 1, p. 5-32, Oct. 2001.

BROWN, S. Measuring carbon in forests: current status and future challenges. **Environmental Pollution**, Barking, v. 116, n. 3, p. 363-372, Mar. 2002.

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

DANILIN, I. M.; MEDVEDEV, E. M. Forest inventory and biomass assessment by the use of airborne laser scanning method (example from Siberia). **Remote Sensing and Spatial Information Sciences**, New York, v. 36, n. 8, p. 139-144, Mar. 2004.

DRAKE, J. B. et al. Above-ground biomass estimation in closed canopy Neotropical forests using lidar remote sensing: factors affecting the generality of relationships. **Global Ecology & Biogeography**, Oxford, v. 12, n. 12, p. 147-159, 2003.

ESKELSON, B. N. I.; BARRETT, T. M.; TEMESGEN, H. Imputing mean annual change to estimate current forest attributes. **Silva Fennica**, Helsinki, v. 43, n. 4, p. 649-658, June 2009.



FERNANDES, T. J. G. et al. Quantificação do carbono estocado na parte aérea e raízes de *Heveasp.*, aos 12 anos de idade, na Zona da Mata. **Revista Árvore**, Viçosa, MG, v. 31, n. 4, p. 657-665, jul./ago. 2007.

FERREIRA, C. A.; SOARES, J. F.; CRUZ, F. R. B. Reconhecimento de padrões em estatística: uma abordagem comparativa. In: CONGRESSO BRASILEIRO DE REDES NEURAIS, 5., 2001, Rio de Janeiro. **Anais...** Rio de Janeiro: PUC, 2001. p. 409-414.

FERREIRA, D. F. **Recursos computacionais utilizando R**. Lavras: UFLA, 2009. 238 p.

FOODY, G. M.; BOYD, D. S.; CUTLER, M. E. Predictive relations of tropical Forest biomass from Landsat TM data and their transferability between regions. **Remote Sensing of Environment**, New York, v. 85, n. 4, p. 463-474, June 2003.

FOODY, G. M. et al. Mapping the biomass of Bornean tropical rain Forest from remotely sensed data. **Global Ecology & Biogeography**, Oxford, v. 10, n. 4, p. 379-387, July 2001.

FREITAS, S. R.; SHIMABUKURO, Y. E. Diagnosticando florestas tropicais através do sensoriamento remoto. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. **Anais...** Florianópolis: INPE, 2007. p. 1671-1678.

GIONGO, M. et al. LiDAR: princípios e aplicações florestais. **Pesquisa Florestal Brasileira**, Colombo, v. 30, n. 63, p. 231-244, ago./out. 2010.

GOODWIN, N. R.; COOPS, N. C.; CULVENOR, D. S. Assessment of forest structure with airborne LiDAR and the effects of platform altitude. **Remote Sensing of Environment**, New York, v. 103, n. 2, p. 140-152, July 2006.

HEIN, F. F. P.; SENES, L. P.; CARNEIRO, C. L. Laser aerotransportado e sua aplicação na geomorfologia. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16., 2013, Foz do Iguaçu. **Anais...** Foz do Iguaçu: INPE, 2013. 1 CD-ROM.

HOUGHTON, R. A. As florestas e o ciclo de carbono global: armazenamento e emissões atuais. In: \_\_\_\_\_. **Emissão x seqüestro de CO<sub>2</sub>**: uma nova oportunidade de negócios para o Brasil. Rio de Janeiro: UFRJ, 1994. p. 38-76.

HUDACK, A. T. et al. Quantifying aboveground forest carbon pools and fluxes from repeat LiDAR surveys. **Remote Sensing of Environment**, New York, v. 123, n. 1, p. 25-40, Aug. 2012.

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

INSTITUTO BRASILEIRO DE ÁRVORES. **Anuário estatístico, ano base 2013**. Brasília, 2014. 80 p.

JENSEN, J. R. **Sensoriamento remoto do ambiente**: uma perspectiva em recursos terrestres. São José dos Campos: Parêntese, 2009. 598 p.

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

KUNTSCHIK, G. **Estimativa de biomassa vegetal lenhosa em cerrado por meio de sensoriamento remoto óptico e radar**. 2004. 165 f. Tese (Doutorado em Ecologia) - Universidade de São Paulo, São Paulo, 2004.

LAFITI, H.; NOTHDURFT, A.; KOCH, B. Non-parametric prediction and mapping of standing timber volume and biomass in a temperate forest: application of multiple optical/LiDAR-derived predictors. **Forestry**, Oxford, v. 83, n. 4, p. 395-407, 2010.

LEFSKY, M. A. et al. LiDAR remote sensing of aboveground biomass in three biomes. **Global Ecology and Biogeography**, Oxford, v. 11, n. 5, p. 393-399, Sept. 2002.

LILLESSAND, T. M.; KIEFER, R. W. **Remote sensing and image interpretation**. 4<sup>th</sup> ed. New York: J. Wiley, 2000. 724 p.

MACGAUGHEY, R. J. **FUSION/LDV**: software for LiDAR data analysis and visualization. Fusion Version 3.42. Washington: USDA, 2004. 175 p.

MATOS, M. A. **Manual operacional para a regressão linear**. Porto: FEUP, 1995. 26 p.

MONTGOMERY, D. R.; BALCO, G.; WILLETT, S. D. Climate, tectonics, and the morphology of the Andes. **Geological Society of America**, Washington, v. 29, n. 7, p. 579-582, July 2001.

MOSTAFA, M. M. R.; HUTTON, J. Direct positioning and orientation systems. **International Archives of Photogrammetry and Remote Sensing**, Beijing, v. 59, n. 4, p. 909-915, Apr. 2010.

MÜLLER, M. D. et al. Estimativa de acúmulo de biomassa e carbono em sistemas agrossilvipastoril na Zona da Mata. **Pesquisa Florestal Brasileira**, Colombo, n. 60, p. 11-17, dez. 2009. Edição especial.

NAESSET, E. Effects of different sensors, flying altitudes, and pulse repetition frequencies on forest canopy metrics and biophysical stand properties derived from small-footprint airborne laser data. **Remote Sensing of Environment**, New York, v. 113, n. 1, p. 148-159, Jan. 2009.

NAESSET, E. Estimation of above and below-ground biomass in boreal Forest ecosystems. **International Archives of Photogrammetry, Remote Sensing and Spatial Information Science**, Freiburg, v. 36, n. 8, p. 145-148, Oct. 2004.

NÆSSET, E. Predicting forest stand characteristics with airborne scanning laser using a practical two-stage procedure and field data. **Remote Sensing of Environment**, New York, v. 80, n. 1, p. 88-99, Apr. 2002.

NAESSET, E.; GOBAKKEN, T. Estimation of above- and belowground biomass across regions of the boreal forest zone using airborne laser. **Remote Sensing of Environment**, New York, v. 112, n. 6, p. 3079-3090, June 2008.

NELSON, T.; NIEMANN, O.; WULDER, M. A. Spatial statistical techniques for aggregating point objects extrated from high spatial resolution remotely sensed imagery. **Journal of Geographical Systems**, New York, v. 4, n. 4, p. 423-433, Dec. 2007.

NETER, J. et al. **Applied linear statistical models**. 4<sup>th</sup> ed. Boston: McGraw Hill, 1996. 368 p.

OLIVEIRA, L. T. **Aplicação do LiDAR no inventário de florestas plantadas**. 2011. 118 p. Tese (Doutorado em Engenharia Florestal) - Universidade Federal de Lavras, Lavras, 2011.

POEH, C. et al. The user of LiDAR technology for sustainable Forest managment in Glen Affric. **European Association of Remote Sensing Laboratories**, Paris, v. 30, n. 1, p. 365-370, May/June 2010.

RESCHKE, J.; HÜTTICH, C. Continuous field mapping of Mediterranean wetlands using sub-pixel spectral signatures and multi-temporal Landsat data. **International Journal of Applied Earth Observation and Geoinformation**, Enschede, v. 8, p. 220-229, May 2014.

RIBEIRO, S. C. **Estoque de biomassa e carbono em cerrado e em plantio comercial de eucalipto no Estado de Minas Gerais**. 2011. 71 p. Tese (Doutorado em Ciências Florestais) - Universidade Federal de Viçosa, Viçosa, MG, 2011.

ROCHA, M. T. **Aquecimento global e o mercado de carbono: uma aplicação do modelo CERT.** 2003. 214 p. Tese (Doutorado em Economia Aplicada) - Escola Superior de Agricultura “Luiz de Queiroz”, Piracicaba, 2003.

RODRIGUEZ, L. C. E. et al. Inventário florestal com tecnologia *laser* aerotransportada de plantios de *Eucalyptus* spp no Brasil. **Ambiência - Revista do Setor de Ciências Agrárias e Ambientais**, Guarapuava, v. 6, p. 3-14, 2010. Edição especial.

SALATI, E. Emissão X seqüestro de CO<sub>2</sub>: uma nova oportunidade de negócios para o Brasil. In: \_\_\_\_\_. **Emissão x sequestro de co2: uma nova oportunidade de negócios para o Brasil.** Rio de Janeiro: UFRJ, 1994. p. 13-37.

SANQUETTA, C. R. Métodos de determinação de biomassa florestal. In: SANQUETTA, C. R. et al. (Ed.). **As florestas e o carbono.** Curitiba: FUPEF, 2002. p. 119-140.

SILVA, C. A. **Carbono na parte aérea de plantios de *Eucalyptus* spp. em nível de árvore por amostragem destrutiva e para talhões inteiros após o ajuste de métricas LiDAR.** 2013. 152 p. Dissertação (Mestrado em Recursos Florestais) - Escola Superior de Agricultura “Luiz de Queiroz”, Piracicaba, 2013.

SILVA, C. A. et al. Mapping aboveground carbon stocks using LiDAR data in *Eucalyptus* spp. plantations in the state of São Paulo, Brazil. **Scientia Agraria**, Piracicaba, v. 42, n. 104, p. 591-604, Dec. 2014.

SILVA, C. A. B. et al. Utilização da tecnologia LiDAR para estimação da biomassa florestal em povoamentos de *Eucalyptus* spp. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16., 2013, Foz do Iguaçu. **Anais...** Foz do Iguaçu: INPE, 2013. 1 CD-ROM.

SMITH, P. F.; GANESH, S.; LIU, P. A comparison of random forest regression and multiple linear regression for prediction in neuroscience. **Journal of Neuroscience Methods**, Amsterdam, v. 220, n. 1, p. 85-91, Oct. 2013.

SOUZA, A. L. N. **Avaliação de qualidade cartográfica e extração de bordas de objetos não pertencentes ao terreno em produtos gerados pelo sistema de varredura a laser aerotransportado**. 2009. 103 p. Dissertação (Mestrado em Engenharia) - Universidade de São Paulo, São Paulo, 2009.

STEPHENS, P. R. et al. Airborne scanning LiDAR in a double sampling forest carbon inventory. **Remote Sensing of Environment**, New York, v. 117, p. 348-357, Feb. 2012.

STROBL, C.; MALLEY, J.; TUTZ, G. An introduction to recursive partitioning: rationale, application, and characteristics of classification and regression trees, bagging, and random forests. **Psychological Methods**, Washington, v. 14, p. 323-348, Dec. 2009.

TARRÉ, A. F. M. V. **Análise de valores de avaliação de apartamentos no âmbito do Crédito a Habitação, para duas zonas distintas do concelho de Lisboa: recurso a modelos hedônicos**. 2009. 82 p. Dissertação (Mestrado em Economia) - Instituto Superior de Economia e Gestão, Universidade Técnica de Lisboa, Lisboa, 2009.

TOMASI, L. C.; MARQUES, M.; BRUTTI, P. C. **Estoque de carbono em florestas plantadas**. São Gabriel: Universidade Federal do Pampa, 2014. 19 p.

WATZLAWICK, L. F. **Estimativa de biomassa e carbono em floresta ombrófila mista e plantações florestais a partir de dados de imagens do satélite Ikonos II**. 2003. 138 f. Tese (Doutorado em Engenharia Florestal) - Universidade Federal do Paraná, Curitiba, 2003.

WATZLAWICK, L. F. et al. Total biomass and organic carbon quantification of *Araucaria angustifolia* (BERT.) O. kuntze stands in southern Parana, Brazil. **Revista Acadêmica: Ciências Agrárias e Ambientais**, Curitiba, v. 1, n. 2, p. 63-68, abr./jun. 2003.

WENDLING, J. L. Ç. **Modelos matemáticos de crescimento e de produção em biomassa para árvores de *Euterpe edulis* MART. plantadas a céu aberto**.

1998. 185 f. Dissertação (Mestrado em Engenharia Florestal) - Universidade Federal do Paraná, Curitiba, 1998.

XAVIER, M. E. R.; KERR, A. S. Análise do efeito estufa em textos paradidáticos e periódicos jornalísticos. **Caderno Brasileiro de Ensino de Física**, São Paulo, v. 21, n. 3, p. 325-349, dez. 2004.

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