



MINISTÉRIO DA CIÊNCIA E TECNOLOGIA

**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**

sid.inpe.br/mtc-m21b/2015/02.13.15.56-TDI

**INTEGRAÇÃO DE DADOS LASER SCANNER  
AEROTRANSPORTADO E IMAGENS AÉREAS NO  
INVENTÁRIO FLORESTAL PARA A ESTIMATIVA  
VOLUMÉTRICA DE MADEIRA**

Emily Tsiemi Shinzato

Dissertação de Mestrado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelo Dr. Yosio Edemir Shimabukuro, aprovada em 12 de março de 2015.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34P/3HU8SQE>>

INPE  
São José dos Campos  
2015

**PUBLICADO POR:**

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GB)

Serviço de Informação e Documentação (SID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/6921

Fax: (012) 3208-6919

E-mail: pubtc@sid.inpe.br

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

Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)

**Membros:**

Dr. Gerald Jean Francis Banon - Coordenação Observação da Terra (OBT)

Dr. Amauri Silva Montes - Coordenação Engenharia e Tecnologia Espaciais (ETE)

Dr. André de Castro Milone - Coordenação Ciências Espaciais e Atmosféricas  
(CEA)

Dr. Joaquim José Barroso de Castro - Centro de Tecnologias Espaciais (CTE)

Dr. Manoel Alonso Gan - Centro de Previsão de Tempo e Estudos Climáticos  
(CPT)

Dr<sup>a</sup> Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação

Dr. Plínio Carlos Alvalá - Centro de Ciência do Sistema Terrestre (CST)

**BIBLIOTECA DIGITAL:**

Dr. Gerald Jean Francis Banon - Coordenação de Observação da Terra (OBT)

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

**REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:**

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

Yolanda Ribeiro da Silva Souza - Serviço de Informação e Documentação (SID)

**EDITORAÇÃO ELETRÔNICA:**

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

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



MINISTÉRIO DA CIÊNCIA E TECNOLOGIA

**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**

sid.inpe.br/mtc-m21b/2015/02.13.15.56-TDI

**INTEGRAÇÃO DE DADOS LASER SCANNER  
AEROTRANSPORTADO E IMAGENS AÉREAS NO  
INVENTÁRIO FLORESTAL PARA A ESTIMATIVA  
VOLUMÉTRICA DE MADEIRA**

Emily Tsiemi Shinzato

Dissertação de Mestrado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelo Dr. Yosio Edemir Shimabukuro, aprovada em 12 de março de 2015.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34P/3HU8SQE>>

INPE  
São José dos Campos  
2015

Dados Internacionais de Catalogação na Publicação (CIP)

---

Shinzato, Emily Tsiemi.

Sh63i      Integração de dados laser scanner aerotransportado e imagens aéreas no inventário florestal para a estimativa volumétrica de madeira / Emily Tsiemi Shinzato. – São José dos Campos : INPE, 2015.

xxiv + 85 p. ; (sid.inpe.br/mtc-m21b/2015/02.13.15.56-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2015.

Orientador : Dr. Yosio Edemir Shimabukuro.

1. Florestas plantadas. 2. Sensoriamento remoto. 3. Sistemas de informações geográficas (GIS). 4. Modelagem. 5. Estimativa volumétrica. I.Título.

CDU 528.8:630

---

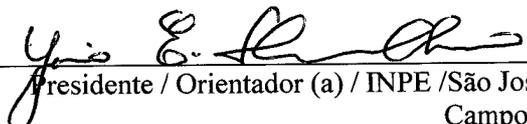


Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

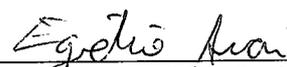
This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

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

Dr. Yosio Edemir Shimabukuro

  
Presidente / Orientador (a) / INPE / São José dos  
Campos - SP

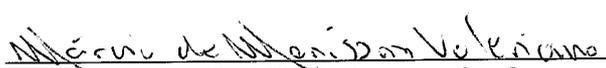
Dr. Egídio Arai

  
Membro da Banca / INPE / São José dos Campos - SP

Dr. Thales Sehn Korting

  
Membro da Banca / INPE / São José dos Campos - SP

Dr. Márcio de Morisson Valeriano

  
Membro da Banca / UNIVAP / São José dos Campos - SP

Dra. Roberta de Oliveira Averka  
Valente

  
Convidado(a) / UFSCAR / Sorocaba - SP

Este trabalho foi aprovado por:

maioria simples.

unanimidade.

Título: “INTEGRAÇÃO DE DADOS LASER SCANNER AEROTRANSPORTADO E  
IMAGENS AÉREAS NO INVENTÁRIO FLORESTAL PARA A  
ESTIMATIVA VOLUMÉTRICA DE MADEIRA.”

Aluno (a): Emily Tsiemi Shinzato

São José dos Campos, 12 de Março de 2015.



*A Deus,*

*A minha querida família*

*Ao amor da minha vida, Esthevan*

***Dedico.***



## AGRADECIMENTOS

Ao Dr. Yosio Edemir Shimabukuro pela orientação, incentivo, confiança, liberdade para desenvolver o tema do presente trabalho e por me encorajar no enfrentamento de desafios aqui superados, contribuindo no meu amadurecimento pessoal.

Ao Dr. Nicholas Coops, da Universidade de British Columbia no Canadá, que permitiu atuar em seu laboratório *Integrated Remote Sensing Studio (IRSS)* no Departamento de Manejo de Recursos Florestais da *Faculty of Forestry*, que contribuiu de forma decisiva no desenvolvimento desta dissertação juntamente com os demais pesquisadores do laboratório, que muito bem me receberam, em especial o Dr. Piotr Tompalski pela amizade, sugestões e auxílio no processamento dos dados LiDAR.

À FIBRIA S.A., nos nomes de Cesar Andrade, Dennis Bernardi, Caio Zanardo, Sebastião Oswaldo Ferreira, Ediana Bandeira e Carlos Nogueira, pela abertura de diálogo e integração entre meio privado e científico, pelo apoio à pesquisa e pela concessão dos dados referente a uma de suas áreas de reflorestamento.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo fornecimento da bolsa de mestrado.

Aos profissionais e alunos do INPE pelo incentivo, apoio e amizade, em especial ao Dr. Egídio Arai, Lorena Benitez, Carolina Athayde e Matheus Andrade.

Aos amigos Cristiane Lemos e Rodrigo Hakamada pelo incentivo na realização do mestrado.

Aos meus pais Alberto e Margareth, por todo suporte e carinho, e por sempre me motivarem na busca de novos desafios. Aos meus irmãos Yves e Henry, que sempre me trouxeram alegria em momentos de dificuldade.

Agradeço também aos meus amigos pelo afeto e preocupação em diversos momentos.

E, especialmente, ao Esthevan Gasparoto por acompanhar de perto o desenvolvimento da minha dissertação, por compartilhar seus conhecimentos, por auxiliar-me na análise de dados, e pelo carinho e apoio durante todos esses anos, fundamentais para que eu pudesse concluir mais esta etapa.

## RESUMO

O sensoriamento remoto tem sido amplamente utilizado para auxiliar no inventário florestal. Dados laser scanner aerotransportados (ALS) são enfatizados por detalharem a estrutura vertical da floresta, enquanto as imagens aéreas, por permitirem maior detalhamento da estrutura horizontal da mesma. Para a obtenção de atributos florestais, existem duas principais abordagens: a Abordagem Baseada na Área (ABA) e a Detecção Individual das Árvores (ITD). O objetivo geral do trabalho é integrar informações ALS e imagens aéreas no inventário florestal. Para tanto, o estudo foi dividido em duas etapas, sendo a primeira destinada à investigação da efetividade da integração de dados ALS e das variáveis derivadas das imagens aéreas, na estimativa do volume de madeira em plantios de *Eucalyptus urograndis*, utilizando a abordagem ABA. Dessa forma, foram avaliados inicialmente três diferentes cenários, sendo estes: o uso de métricas derivadas de dados ALS (RMSE=6,84%), o uso de variáveis derivadas das imagens aéreas multiespectrais (RMSE=8,45%) e a integração de ambas as variáveis (RMSE=5,23%). O cenário de melhor desempenho foi adotado para as demais avaliações. Já a segunda etapa, avaliou o desempenho da integração das abordagens ITD e ABA (semi-ITD) para estimar o volume de madeira por árvore. Foi feita a detecção individual das mesmas, entretanto, como esta apresentou valor inferior ao número de árvores existentes, fez-se a modelagem do erro da detecção, obtendo-se o número de árvores final. Após este passo, foi feita a divisão do volume obtido em área total, pelo número de árvores, resultando no volume individual por árvore. Ao término deste processo, obteve-se um RMSE de 12,66% na fase de modelagem do erro, resultando em um desvio de 0,37 árvores por hectare. Neste estudo foi demonstrado a detecção individual das árvores como forma de melhoria da abordagem ABA. Esta abordagem permitiu estimar o volume individual das árvores a um erro muito pequeno.



# INTEGRATION OF AIRBORNE LASER SCANNER AND AERIAL IMAGERY IN FOREST INVENTORY FOR ESTIMATING TREE-VOLUME

## ABSTRACT

Remote sensing has been increasingly used to assess forest inventory. Airborne Laser Scanning Systems (ALS) are emphasized for detailing the vertical structure of the forest, whether optical images for allowing further details of the horizontal structure of the forest. To obtain forest attributes, two main approaches are applied to process these data types: Area Based Approach (ABA), and Individual Tree Detection (ITD). In this study, our aim is to demonstrate the two main approaches to estimate stand volume in *Eucalyptus* plantations using ALS and image data. To do so, we first model the stand volume using a standard ABA approach, using different combinations of ALS-based and image-based metrics as independent model variables. Three different scenarios were compared: using only variables from ALS data (RMSE = 6.84%), only the variables derived from aerial images (RMSE = 8.45%) and the integration of both (RMSE = 5.23%), which underestimated the true value by 2.98%. Second, we utilize ITD based approach to estimate tree count and then integrate it with the stand volume predicted with ABA (semi-ITD). The merging of the two approaches allows prediction of mean individual tree volume. Then, we introduce a correction method to improve the volume predictions. After that, we downscaled the total volume prediction to single tree level. Finally, we obtained a RMSE of 12.66% in the bias modeling, resulting in a standard deviation of 0.37 trees per hectare. In this study we demonstrated a method of using individual tree locations as an enhancement of traditional area-based approach. Our approach allowed to estimate individual tree volume with negligible bias.



## LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1 - Produtividade m <sup>3</sup> /ha.ano-1 de árvores coníferas e folhosas no mundo. ....	8
Figura 2.2 – Distribuição dos maiores maciços de árvores plantadas por estado, 2013. 9	9
Figura 2.3 - Escaneamento LiDAR. Fonte: Adaptada de USGS (2007).....	12
Figura 2.4 - Técnicas de posicionamento RTK (Real Time Kinematic) e DGPS (GPS Diferencial). .....	13
Figura 2.5 - Abordagem Baseada na Área (ABA). .....	17
Figura 3.1 - Localização da área de estudo. ....	21
Figura 3.2 – Área de estudo e localização das parcelas de inventário florestal. ....	24
Figura 4.1 – Amostra de dados brutos ALS em parte da área de estudo.....	28
Figura 4.2 - Fotografia aérea de parte da área de estudo.....	29
Figura 4.3 – Descrição das Etapas para obtenção da ITD em cada uma das bandas utilizadas.....	38
Figura 5.1 - Distribuição da Altura média dos pontos ALS ressaltando dois <i>outliers</i> a serem removidos.....	43
Figura 5.2 - Melhores modelos em diferentes tamanhos, selecionados pela abordagem <i>Best Subset Selection</i> ordenados pelo critério BIC, utilizando apenas variáveis ALS. A presença destas variáveis no modelo é indicada pela coloração em tons de cinza.....	44
Figura 5.3 - Melhores modelos em diferentes tamanhos, selecionados pela abordagem <i>Best Subset Selection</i> ordenados pelo critério BIC, utilizando apenas variáveis da imagem aérea. A presença destas variáveis no modelo é indicada pela coloração em tons de cinza. ....	45

Figura 5.4 - Melhores modelos em diferentes tamanhos, selecionados pela abordagem <i>Best Subset Selection</i> ordenados pelo critério BIC, utilizando a integração das variáveis ALS e da imagem aérea. A presença destas variáveis no modelo é indicada pela coloração em tons de cinza. ....	46
Figura 5.5 - Método de validação cruzada <i>k-fold</i> para estimativa da raiz do erro quadrático médio (RMSE) com modelos com diferentes tamanhos utilizando apenas variáveis ALS. ....	47
Figura 5.6 - Método de validação cruzada <i>k-fold</i> para estimativa da raiz do erro quadrático médio (RMSE) com modelos com diferentes tamanhos utilizando apenas variáveis da imagem. ....	48
Figura 5.7 - Método de validação cruzada <i>k-fold</i> para estimativa da raiz do erro quadrático médio (RMSE) com modelos com diferentes tamanhos utilizando a integração das variáveis ALS e variáveis da imagem.....	48
Figura 5.8 - Análise gráfica de ajuste com base no cenário de apenas variáveis ALS. (A) relação do volume predito em função do valor observado, (B) dispersão dos resíduos, (C) histograma dos resíduos e (D) quantis observados em função dos quantis teóricos. ....	50
Figura 5.9 - Análise gráfica de ajuste com base no cenário de apenas variáveis da imagem multiespectral. (A) relação do volume predito em função do valor observado, (B) dispersão dos resíduos, (C) histograma dos resíduos e (D) quantis observados em função dos quantis teóricos. ....	51
Figura 5.10 - Análise gráfica de ajuste com base no cenário de integração das variáveis ALS e variáveis da imagem. (A) relação volume predito em função do valor observado, (B) dispersão dos resíduos, (C) histograma dos resíduos e (D) quantis observados em função dos quantis teóricos. ....	52
Figura 5.11 – Volume de madeira estimado em área total em m <sup>3</sup> por hectare. ....	54

Figura 5.12 – Comparação entre o volume de madeira (m <sup>3</sup> ) estimado pelo presente método (ABA utilizando informações ALS e da imagem), pela fábrica e pelo inventário (Amostragem Casual Simples), com seus respectivos intervalos de confiança. ....	55
Figura 4.13 – Comparação da imagem aérea, LiDAR e volume estimado pela integração de ambos os dados, ressaltando área com falha e mortalidade. ....	56
Figura 5.14 – Detecção Individual da Árvore (ITD) com base na filtragem da máxima local na área de estudo. ....	57
Figura 5.15 – Número de árvores por hectare segundo detecção ITD-ABA. ....	58
Figura 5.16 – Resíduo da detecção das árvores por parcela e conforme a declividade do terreno (°). ....	59
Figura 5.17 - Melhores modelos em diferentes tamanhos, selecionados pela abordagem <i>Best Subset Selection</i> ordenados pelo critério BIC. A presença destas variáveis no modelo é indicada pela coloração em tons de cinza. ....	60
Figura 5.18 - Método de validação cruzada <i>k-fold</i> para estimativa da raiz do erro quadrático médio (RMSE) com modelos com diferentes tamanhos, e intervalos de confiança obtidos em 1000 simulações. ....	60
Figura 5.19 - Análise gráfica de ajuste, sendo (A) relação valor predito em função do valor observado, (B) dispersão dos resíduos, (C) histograma dos resíduos e (D) quantis observados em função dos quantis teóricos. ....	62
Figura 5.20 – Predição do erro em área total na detecção das árvores por hectare, segundo a abordagem ABA. ....	63
Figura 5.21 – Estimativa do número de árvores por hectare. ....	64
Figura 5.22 – Classificação do volume por árvore. ....	65



## LISTA DE TABELAS

Tabela 2.1 - Uso da tecnologia LiDAR em aplicações florestais por diferentes instituições de pesquisa no Brasil. ....	15
Tabela 3.1 – Estatísticas descritivas das parcelas de inventário, para as variáveis área basal (G), diâmetro à 1,3m (DAP), altura total (HT), altura dominante (HDOM) e volume de celulose sem casca (V). ....	25
Tabela 4.1 - Metadados da campanha de aquisição de dados ALS.....	29
Tabela 4.2 - Métricas de altura e cobertura da copa derivadas da nuvem de pontos ALS. ....	32
Tabela 5.1 – Resumo do ajuste do melhor modelo de regressão linear múltipla em cada um dos cenários. Dentre as variáveis ALS estão: a moda da altura ( $H_{mode}$ ), altura nos percentis 20 ( $H_{p20}$ ), 40 ( $H_{p40}$ ) e 50 ( $H_{p50}$ ) e a altitude média ( $A_{mean}$ ). Com relação as variáveis da imagem estão: a banda do vermelho(B3), o índice de vegetação NDVI, a banda do infravermelho próximo (B4) e a razão entre as bandas: azul pela vermelha (B1/B3), azul pela infravermelho próximo (B1/B4) e a verde pela vermelha (B2/B3)...	49
Tabela 5.2 – Verificação das pressuposições do ajuste em diferentes cenários. Valores de p-valor>0,05, aceita-se a hipótese. ....	53
Tabela 5.3 – Resumo do ajuste do melhor modelo de regressão linear múltipla para estimativa do erro de detecção. Utilizando as variáveis altura máxima ( $h_{max}$ ) e a Declividade (D) e detecção individual das árvores ITD e ABA...	61
Tabela 5.4 – Verificação das pressuposições do ajuste do erro. Valores de p-valor>0,05, aceita-se a hipótese. ....	62



## LISTA DE SIGLAS E ABREVIATURAS

AAS	Amostragem Aleatória simples
ABA	<i>Area-based Approach</i> (Abordagem Baseada na Área)
AIC	<i>Akaike Information Criterion</i> (Critério de Informação de Akaike)
ALS	<i>Airborne Laser Scanner</i> (Escaneamento à Laser Aerotransportado)
BIC	<i>Bayesian Information Criterion</i> (Critério de Informação Bayesiana)
CHM	<i>Canopy Height Model</i> (Modelo de Altura do Dossel)
CV <sub>k</sub>	Validação Cruzada <i>k-fold</i>
ESALQ	Escola Superior Luíz de Queiroz
FOV	Field Of View (Visada do Sensor)
FSF/UEF	Faculty of Forestry Science/University of Eastern Finland
GNSS	Sistemas Globais de Satélite de Navegação
GPS	Sistema de Posicionamento Global
IMU	<i>Inertial Measurement Unit</i> (Unidade de Medição Inercial)
INPE	Instituto Nacional de Pesquisas Espaciais
ITC	Detecção Individual das Copas das Árvores ou <i>Individual Tree Crown</i>
ITD	Detecção Individual da Árvore ou <i>Individual Tree Detection</i>
LACTEC	Instituto de Tecnologia para o Desenvolvimento
LiDAR	Light Detection And Ranging (Detecção e Distanciamento da Luz)
MDS	Modelo Digital de Superfície
MDT	Modelo Digital de Terreno
NDVI	Índice de Vegetação de Diferença Normalizada
RTK	Real-time Kinematic
SIG	Sistema de Informações Geográficas
SIRGAS	Sistema de Referência Geocêntrico para as Américas
UFPR	Universidade Federal do Paraná
UFV	Universidade Federal de Viçosa
USDA	United States Department of Agriculture
USGS	United States Geological Survey

USP Universidade Estadual de São Paulo

UTM Universal Transversa de Mercator

## LISTA DE SÍMBOLOS

CAP	Circunferência à Altura do Peito
DAP	Diâmetro à Altura do Peito
G	Área Basal
HT	Altura Total
HDOM	Altura Dominante
V	Volume de celulose sem casca
RMSE	Root Mean Square Error (Raíz do Erro quadrático Médio)
$h_{min}$	Altura mínima derivada da nuvem de pontos ALS
$h_{max}$	Altura máxima derivada da nuvem de pontos ALS
$h_{mean}$	Altura média derivada da nuvem de pontos ALS
$h_{var}$	Variância da altura derivada da nuvem de pontos ALS
$h_{sd}$	Desvio padrão da altura derivada da nuvem de pontos ALS
$h_{cv}$	Coefficiente de variação da altura derivada da nuvem de pontos ALS
$h_{moda}$	Moda da altura derivada da nuvem de pontos ALS
$h_k$	Curtose da altura derivada da nuvem de pontos ALS
$h_{p01}$	1º Percentil da altura derivada da nuvem de pontos ALS
$h_{p05}$	5º Percentil da altura derivada da nuvem de pontos ALS
$h_{p10}$	10º Percentil da altura derivada da nuvem de pontos ALS
$h_{p20}$	20º Percentil da altura derivada da nuvem de pontos ALS
$h_{p25}$	25º Percentil da altura derivada da nuvem de pontos ALS
$h_{p30}$	30º Percentil da altura derivada da nuvem de pontos ALS
$h_{p40}$	40º Percentil da altura derivada da nuvem de pontos ALS
$h_{p50}$	50º Percentil da altura derivada da nuvem de pontos ALS
$h_{p60}$	60º Percentil da altura derivada da nuvem de pontos ALS
$h_{p70}$	70º Percentil da altura derivada da nuvem de pontos ALS
$h_{p75}$	75º Percentil da altura derivada da nuvem de pontos ALS
$h_{p80}$	80º Percentil da altura derivada da nuvem de pontos ALS
$h_{p90}$	90º Percentil da altura derivada da nuvem de pontos ALS

$h_{p95}$	95º Percentil da altura derivada da nuvem de pontos ALS
$h_{p99}$	99º Percentil da altura derivada da nuvem de pontos ALS
$C_{ab.mean}$	Número de 1ºs retornos acima da média derivada da nuvem de pontos ALS
$C\%$	Percentual de copa derivada da nuvem de pontos ALS
$D$	Declividade média do terreno (°)
$A_{mean}$	Altitude média

## SUMÁRIO

1	INTRODUÇÃO .....	1
1.1.	Motivação.....	4
1.2.	Hipóteses.....	6
2	REVISÃO BIBLIOGRÁFICA.....	7
2.1.	Setor de florestas plantadas no Brasil.....	7
2.2.	Inventário Florestal .....	9
2.3.	Sistemas Laser Scanner Aerotransportado (ALS).....	11
2.4.	Abordagem ABA na predição de atributos .....	16
2.5.	Abordagem ITD.....	18
3	ÁREA DE ESTUDO E PROCEDIMENTO DE INVENTÁRIO .....	21
4	MATERIAIS E MÉTODOS .....	27
4.1.	Dados de sensoriamento remoto .....	27
4.2.	Processamento e extração de métricas da nuvem de pontos ALS .....	30
4.3.	Variáveis derivadas da imagem.....	34
4.4.	Estimativa do volume de madeira em área total.....	35
4.4.1.	Seleção de variáveis e ajuste de modelos.....	35
4.4.2.	Validação do Modelo .....	36
4.4.3.	Verificação de pressuposições .....	37
4.4.4.	Escolha do cenário e representação gráfica do mesmo .....	37
4.5.	Volume Individual da Árvore (ITD).....	38
4.5.1.	Conversão da abordagem ITD para a abordagem ABA.....	39
4.5.2.	Detecção e correção do erro em área total .....	40
4.5.3.	Correção do número de árvores por hectare .....	41

4.5.4.	Estimativa do volume individual das árvores.....	41
5	RESULTADOS .....	43
5.1.	Estimativa do volume de madeira em área total.....	43
5.1.1.	Seleção de variáveis e ajuste de modelos.....	44
5.1.2.	Verificação de pressuposições e predição volumétrica.....	49
5.2.	Volume Individual por Árvore (ITD) .....	56
5.2.1.	Modelagem do Erro de detecção das árvores .....	59
6	DISCUSSÃO .....	67
7	CONCLUSÃO .....	73
8	RECOMENDAÇÕES PARA TRABALHOS FUTUROS.....	75
	REFERÊNCIAS BIBLIOGRÁFICAS.....	77

## 1 INTRODUÇÃO

As florestas plantadas exercem importante função no contexto nacional e internacional, por produzirem grandes quantidades de biomassa. Isto permite que a biomassa seja utilizada na forma de bioenergia, ou quando convertida, na forma de derivados de celulose, como o papel. Desta maneira, o setor possibilita a redução das pressões antrópicas sobre as florestas naturais, e gera milhões de empregos (IBÁ, 2014). No Brasil, são gerados cerca de 4,4 milhões de empregos diretos e indiretos e a área total reflorestada excede 7,6 milhões de hectares (IBÁ, 2014). Desta área, 72% é composta por *Eucalyptus* spp., gênero considerado chave nos plantios florestais brasileiros.

Entre as razões para o sucesso dos plantios de *Eucalyptus* spp., destacam-se seu rápido crescimento, homogeneidade e adaptação em diversas condições climáticas (SILVA et al., 2014). Com objetivo de monitorar o crescimento e a produtividade destes plantios, são requeridos inventários florestais anuais. Além disso, o sensoriamento remoto tem sido, comprovadamente, uma excelente ferramenta para auxiliar no inventário florestal, uma vez que são providenciadas informações precisas dos talhões florestais, tanto para auxiliar nas performances dos talhões, como para identificar os agentes causadores de distúrbios, que podem interferir no crescimento potencial.

O sensoriamento remoto exhibe um longo histórico no auxílio das estimativas de atributos florestais. De modo geral, a abordagem tradicional de inventário, em florestas plantadas, segue preceitos da teoria da amostragem, a qual está baseada em mensurações em campo, coletadas em parcelas florestais, distribuídas aleatoriamente na área de interesse. Em seguida, o atributo florestal de interesse é extrapolado para a área total, conforme o estimador utilizado (PARIS; BRUZZONE, 2015). Neste contexto, considerando as dificuldades em campo, o sensoriamento remoto representa uma importante ferramenta para monitorar amplas áreas de forma rápida, auxiliando na exatidão e precisão do processo.

Sensores remotos ativos e passivos têm sido apresentados como alternativas factíveis, por estimarem parâmetros florestais. Dados ópticos de alta resolução espacial são úteis por providenciarem informações espectrais das espécies florestais e da sanidade das mesmas (WANG et al., 2004; MONNET et al., 2010). Novas tecnologias de sensoriamento remoto ativo, tal como o LiDAR (Detecção e Distanciamento da Luz) ou o ALS (Escaneamento a Laser Aerotransportado), são muito úteis ao providenciarem dados de altura das florestas (WULDER et al., 2000). Dessa forma, o sensoriamento remoto tem sido amplamente utilizado, no controle, monitoramento e manejo dos talhões florestais (WULDER et al., 2000; POPESCU et al., 2004; WANG et al., 2004; PACKALÉN et al., 2011).

Quando se utiliza dados ALS, duas principais abordagens podem ser aplicadas para prever atributos de inventários florestal: Abordagem Baseada na Área (ABA) (NÆSSET, 2002; WHITE et al., 2013) e a Detecção Individual das Árvores (ITD ou *Individual Tree Detection*) (POPESCU et al., 2002; KAARTINEN et al., 2012). Na ABA a variável resposta (por exemplo, volume de madeira em função da área, volume/ha) é agregada à uma célula grid com tamanho predeterminado (BREINDENBACH; ASTRUP, 2014). Esta variável resposta é estimada utilizando variáveis preditoras, as quais são obtidas a partir de métricas ALS derivadas direta ou indiretamente em cada célula grid, tais como a altura média, a altura em percentis e suas densidades e proporções (NÆSSET, 2002).

O sucesso da ABA consiste na facilidade de estimar atributos florestais em amplas áreas (NÆSSET, 2002; WHITE et al., 2013). A estimativa de variáveis, tais como biomassa, volume, área basal, diâmetro médio, ou altura média, por meio de dados ALS, têm mostrado exatidão similar ou maior, quando comparados ao inventário florestal tradicional (WHITE et al., 2013). Porém, quando se requer informações em nível de árvore, tais como o número de fustes ou informações das espécies das árvores, a utilização de dados ALS na ABA é menos adequada, requerendo com frequência informações adicionais

provenientes de dados ópticos ou de outras fontes de recursos (BREINDENBACH; ASTRUP, 2014).

O uso de dados ALS e de dados provenientes de sensores remotos passivos, quando em conjunto, podem auxiliar na estimativa de atributos florestais, e gerar resultados ainda mais exatos ou mais próximos à realidade (NÆSSET, 2002; HUDAK et al, 2002; POPESCU et al., 2004; WULDER; SEEMANN, 2003; ROBERTS et al., 2005; PARIS; BRUZZONE, 2015). Ambas as abordagens ABA e ITD podem ser aplicadas na estimativa de biomassa de madeira ou volume em plantios florestais (NÆSSET, 2002; BRANDTBERG et al., 2003). Contudo, de acordo com Breindenbach e Astrup (2014), a abordagem ITD é intrinsecamente mais intuitiva que a abordagem ABA, já que as variáveis respostas estão relacionadas à cada árvore (menor unidade em um sistema de manejo), providenciando coordenadas que podem ser utilizadas em crescimento individual da árvore, que ligam explicitamente o crescimento das árvores e os modelos de crescimento.

De acordo com Packalén et al. (2011), a vantagem de se utilizar a abordagem ITD é que a detecção correta das árvores individuais, pode reduzir o número de parcelas de inventários necessárias para gerar um inventário florestal exato e sem erros. Independentemente do tipo de imagem utilizada (proveniente de sensores passivos ou ativos), a extração da localização exata de cada árvore é difícil, uma vez que erros são comuns na abordagem ITD, resultando em uma subestimativa do número de fustes. Em caso de dados ALS, a abordagem ITD requer alta densidade da nuvem de pontos, a qual pode ser impraticável devido ao seu custo (MEHTÄTALO et al., 2014).

O objetivo deste estudo é demonstrar as duas principais abordagens (ITD e ABA) para estimar o volume em plantações de *Eucalyptus* spp. utilizando dados ALS e imagens multiespectrais com alta resolução espacial. Para tanto, primeiramente é feito a modelagem do volume em área total utilizando diferentes combinações de métricas, baseadas em dados ALS e nas imagens, como dados de *input*. Em seguida, a abordagem ITD é utilizada para estimar a contagem das árvores, a qual é integrada ao volume predito com a ABA. A

junção das duas abordagens (semi-ITD), após uma correção na detecção das árvores, permite estimar o volume individual das árvores. O estudo finaliza com discussões das possibilidades de se utilizar a ABA para estimativa de volume individual das árvores.

### **1.1. Motivação**

Inventários florestais são executados em diferentes escalas (em âmbito nacional, regional ou local) para estimar os recursos florestais existentes, e auxiliar no manejo dos mesmos. A realização de um inventário florestal é uma das principais etapas utilizadas no controle, monitoramento e planejamento dos recursos florestais executadas por órgãos públicos e/ou privados, para fornecer informações quantitativas e qualitativas de povoamentos florestais.

Informações de inventários florestais devem ser obtidas de maneira cuidadosa, a fim de se evitar erros nas estimativas, e conseqüentemente, nas atividades de gestão dos recursos florestais. Tradicionalmente, as execuções de levantamentos em campo são extenuantes, por demandar visitas e amostragens em áreas distantes e de difícil acesso. Neste sentido, o uso do sensoriamento remoto surge como um grande aliado na obtenção e na geração das informações de interesse em diferentes escalas (NÆSSET, 2002; BREINDENBACH; ASTRUP, 2014).

O inventário florestal depende de informações provenientes de parte (ou amostras) de uma dada população, para inferir sobre um todo. A qualidade e quantidade destas informações são, rotineiramente, proporcionais ao seu custo. Desta forma, a execução de um inventário florestal tradicional pode ser custosa, tornando a redução de incertezas (ou erros de estimativa) acerca dessa população, um grande desafio (SILVA, 2013).

Frente a esse desafio, a integração de técnicas de sensoriamento remoto associados aos dados coletados em campo, vem se tornando uma tendência nos inventários florestais atuais (WHITE et al., 2013). O sensoriamento remoto por si só, auxilia prontamente na estimativa de diversos atributos florestais e

permite abranger amplas áreas à um custo acessível. Os dados levantados em campo, por sua vez, continuam a ser essenciais no inventário florestal, principalmente no que diz respeito à modelagem e validação destes atributos. Neste sentido, diversas pesquisas envolvendo a integração de ambas as informações têm sido realizadas (PACKALÉN et al., 2011).

Em contraste com o inventário tradicional, uma das linhas de pesquisa que tem quebrado paradigmas devido à possibilidade de se obter um censo florestal refere-se ao uso de sistema de escaneamento a laser aerotransportado (ALS) na geração de atributos da vegetação (PITKÄNEN, 2001; ZHANG et al, 2014). A partir de dados ALS é possível gerar informações em três dimensões (3D) referentes às amplas áreas, além de estimar direta e indiretamente diversos atributos florestais como altura, altura da copa, diâmetro, área basal, volume, biomassa, altura total, identificação de espécies, dentre outros (WULDER, 2003; PACKALÉN et al., 2011; ØRKA et al., 2012; SILVA, 2014; PARIS; BRUZZONE, 2015).

Contudo, a aquisição das informações ALS por parte das empresas florestais, ainda se mantém pouco significativa devido seu ao alto custo de aquisição, justificado pela baixa oferta e demanda dos serviços e pela capacitação ainda incipiente no manuseio das informações ALS no setor florestal. Além disso, as características intrínsecas aos dados ALS, como, por exemplo, a alta densidade de pontos quando solicitados em áreas de vegetação densa, podem requerer maior capacidade de armazenamento (PITKÄNEN, 2001).

No contexto da aquisição de imagens (satélite e ortofoto) o cenário é diferente, posto que a vantagem da utilização destas já foi amplamente difundida e o seu manuseio consolidado (PITKÄNEN, 2001). Portanto, as imagens têm se tornado cada vez mais acessíveis ao setor florestal e utilizadas em questões relacionadas ao meio científico e ao meio empresarial. De forma similar, o custo das informações ALS também poderá ser reduzido à medida que a operacionalização dos processos inerentes à esta tecnologia forem se consolidando.

Países como os Estados Unidos, já oferecem dados ALS gratuitos e vastamente disponíveis referentes às diversas regiões do país (USGS, 2015). No Brasil, isso não está longe de acontecer, prova disto, é o projeto da Embrapa Monitoramento por Satélite denominado Paisagens Sustentáveis, que tem disponibilizado informações ALS de diferentes biomas brasileiros (LEITOLD, 2014).

Seguindo esta tendência, o uso e a integração de técnicas e produtos de sensoriamento remoto (tais como dados ALS e imagens aéreas) associados às informações de inventário florestal, podem contribuir na geração de conhecimento sólido em extensas áreas. Isto auxiliará também na gestão adequada dos recursos florestais, questão importante no cenário atual onde a otimização do uso destes recursos é de extrema seriedade.

## **1.2. Hipóteses**

As hipóteses da pesquisa são:

- Associação entre dados ALS e imagem aérea, possibilitam a geração de estimativa de estoque de madeira mais robusta, quando comparada à utilização de dados ALS ou imagens, individualmente.
- A diferença temporal de até um ano entre os dados ALS e a verdade terrestre não inutiliza tais dados na predição do volume de madeira em área total.
- A abordagem ITD em plantios equiâneos, com base em imagens multiespectrais com alta resolução espacial, permite auxiliar na estimativa do volume individual de madeira na abordagem, quando transformada para abordagem ABA (semi-ITD).

## 2 REVISÃO BIBLIOGRÁFICA

A seguir listam-se tópicos da revisão de literatura mais diretamente relacionados com o escopo da dissertação. No item 2.1 há uma contextualização do setor de florestas plantadas no Brasil, descrevendo a motivação nos estudos voltados às florestas plantadas, dado o constante crescimento do setor florestal. No item 2.2 é feita uma breve revisão do inventário florestal adotado pelas empresas comerciais de celulose. No item 2.3 estão descritos os principais componentes do sistema ALS e como estes funcionam. O item 2.4 aborda os principais estudos e aplicações dos sistemas ALS. Já os itens 2.5 e 2.6, descrevem a Abordagem Baseada na Área (ABA) e a Detecção Individual das Árvores (ITD), respectivamente.

### 2.1. Setor de florestas plantadas no Brasil

De acordo com o anuário Indústria Brasileira de Árvores (IBÁ, 2014), a área com florestas plantadas no Brasil, atingiu 7,6 milhões de hectares em 2013. Destes, 72% correspondem aos plantios florestais com o gênero *Eucalyptus* spp., 21% aos plantios com gênero *Pinus* spp., e o restante às diferentes espécies como a acácia, a teca, a seringueira, o paricá etc. O setor brasileiro de florestas plantadas contribuiu no ano de 2013 com 1,2% de toda riqueza gerada no país, ou aproximadamente 56 bilhões de reais, gerando além disso, 4,4 milhões de empregos diretos e indiretos.

No que diz respeito a produção de celulose, o Brasil encontra-se na quarta posição (15,1 milhões de toneladas/ano) no ranking mundial, perdendo apenas para os Estados Unidos (50,4 milhões de toneladas/ano), a China (18,2 milhões de toneladas/ano) e o Canadá (17,1 milhões de toneladas/ano). Entretanto, destaca-se que a produtividade média do *Eucalyptus* spp. no Brasil encontra-se em torno de  $38 \text{ m}^3 \cdot \text{ha}^{-1} \cdot \text{ano}^{-1}$ , ao passo que a produtividade média dos Estados Unidos, maior produtor de celulose, atinge apenas  $15 \text{ m}^3/\text{ha} \cdot \text{ano}^{-1}$  (IBÁ, 2014) (Figura 2.1).

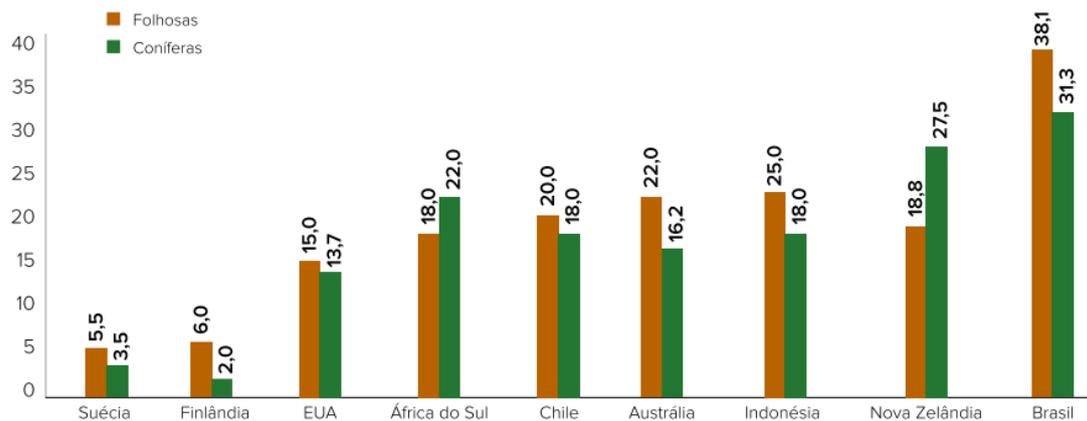


Figura 2.1 - Produtividade m³/ha.ano-1 de árvores coníferas e folhosas no mundo.  
Fonte: IBÁ (2014)

O gênero *Eucalyptus* spp. doravante denominado apenas por eucalipto, destaca-se por seu múltiplo uso e por sua grande contribuição no setor florestal. Apenas em 2013, 138 milhões de m³ de eucalipto foram utilizados em diferentes segmentos industriais, como celulose e o papel (56,6 milhões de m³), a lenha industrial (41,8 milhões de m³) e o carvão (23,5 milhões de m³), confirmando assim sua importância em diversas aplicações (IBÁ, 2014).

Os principais maciços florestais com eucalipto, encontram-se nos estados de São Paulo e Minas Gerais ocupando áreas de aproximadamente 1,4 milhões de hectares e 1 milhão de hectares, respectivamente (IBÁ, 2014) (Figura 2.2). Entretanto, dado o alto custo da terra nestas regiões, observa-se com o passar dos anos uma tendência de migração para as regiões do Centro-Oeste e Nordeste do país, onde o custo da terra é menor em relação ao da região Sudeste. Isso implica em grande diversidade de regiões edafomorfoclimáticas, onde o gênero eucalipto necessita de adaptação.

Com isso, vários fatores podem interferir na produtividade do eucalipto como: clima (radiação, ventos, temperaturas, precipitação, umidade relativa e balanço hídrico), fisiografia (relevo e drenagem), solo (características físico-químicas, biológicas e de fertilidade), manejo florestal (cultura anterior, limpeza do solo, preparo e conservação do solo, espaçamento do plantio, fertilização, mato-

competição, desbaste, corte e condução da brotação) (LEMOS, 2012). Dada a importância do eucalipto, associada à diversidade de fatores que influenciam no seu desempenho produtivo, para uma produção cada vez mais eficaz, sustentável e rentável, torna-se imprescindível o desenvolvimento de pesquisas voltadas para este tema.

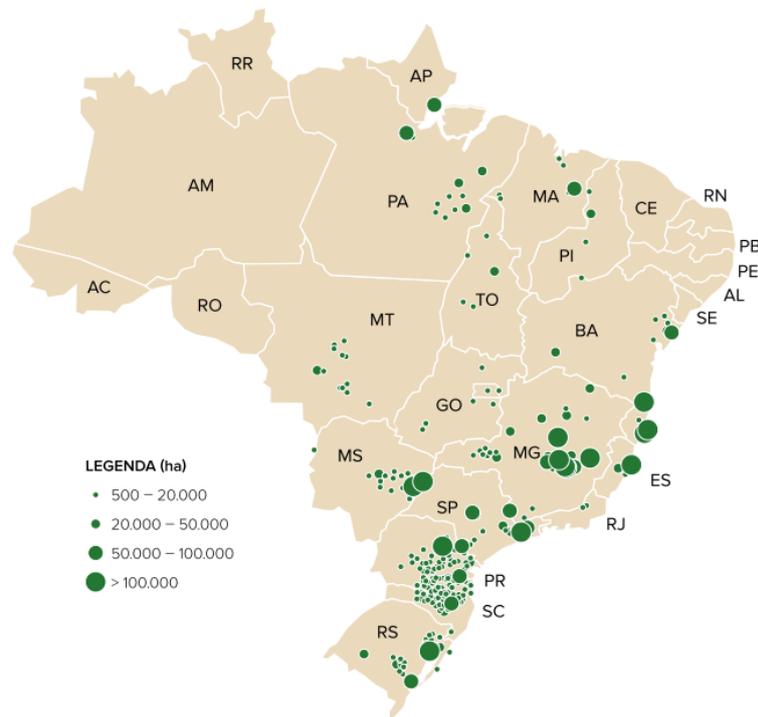


Figura 2.2 – Distribuição dos maiores maciços de árvores plantadas por estado, 2013.  
Fonte: IBÁ (2014)

## 2.2. Inventário Florestal

Inventário florestal é o ramo da ciência florestal que visa avaliar as variáveis qualitativas e quantitativas da floresta e suas inter-relações, assim como as dinâmicas de crescimento e a sucessão florestal, servindo de base para a formulação de planos de utilização dos produtos florestais, manejo sustentado integrado da floresta, bem como para alicerçar propostas de planos de desenvolvimento e política florestal de caráter regional ou nacional (QUEIROZ, 2012).

Em outras palavras, o inventário florestal fundamenta-se em técnicas e metodologias aplicadas a um povoamento de interesse, com um objetivo específico, como por exemplo, a estimativa do volume de madeira, de biomassa, do índice de sítio, etc. Tais técnicas e metodologias podem, entretanto, variar de acordo com os protocolos de cada empresa ou organização florestal.

O inventário florestal comumente utiliza-se de técnicas probabilísticas, por meio de amostragens, para inferir sobre uma população. As amostras (ou parcelas) podem assumir formato circular, quadrado, retangular ou linear. Tal formato é função dos objetivos do levantamento, das técnicas utilizadas e das características da população. De modo geral, as parcelas adotadas pelas empresas de reflorestamento são circulares com áreas variando de 100 m<sup>2</sup> a 800 m<sup>2</sup> (QUEIROZ, 2012).

O número e o modo de alocação dessas parcelas, são definidos pelo delineamento amostral adotado. Há grande variedade de delineamentos existentes, citam-se como os mais comuns para o setor de florestas plantadas: a amostragem aleatória simples, a amostragem sistemática e a amostragem aleatória estratificada.

A amostragem aleatória simples baseia-se no princípio de que cada parcela possui a mesma chance de ser sorteada independentemente das demais, ou seja, selecionam-se aleatoriamente as unidades amostrais. Este delineamento é o mais indicado em populações homogêneas. Na amostragem sistemática, apenas a primeira parcela é sorteada de forma aleatória, e as demais são espaçadas de forma regular, em espaçamento pré-determinado, para toda área de interesse, garantindo assim, a amostragem ao longo de toda população (QUEIROZ, 2012).

A amostragem estratificada consiste na divisão da população florestal em estratos, ou subpopulações, segundo uma característica agregadora, como por exemplo o material genético, espaçamento, idade e etc.. Essa amostragem é recomendável para o estudo de populações florestais que apresentem

heterogeneidade entre as subpopulações com referência à variável de interesse (QUEIROZ, 2012). Após a escolha da técnica amostral de interesse, a localização das parcelas é normalmente determinada por meio de técnicas de sensoriamento remoto em escritório.

### **2.3. Sistemas Laser Scanner Aerotransportado (ALS)**

O uso dos sistemas LiDAR (*Light Detection And Ranging*) vem comprovando a sua extraordinária capacidade de aquisição de dados com grande quantidade de informações, em pequenos intervalos de tempo (ALVES, 2010). No Brasil, esta tecnologia, voltada às florestas, possui mais de uma década de uso (PIRES, 2005; ZANDONÁ, 2006; MACEDO, 2009), confirmando a crescente demanda no manejo, monitoramento e controle dos recursos naturais.

O LiDAR (*Light Detection And Ranging*) é um dos sistemas ativos de sensoriamento remoto, que coleta informações da topografia por meio da emissão da luz laser. O LiDAR transmite o pulso laser à superfície, pela qual o pulso será refletido, retornando ao sistema que o emitiu (Figura 2.3). Desta forma, a distância até o solo pode ser calculada por meio do conhecimento da velocidade do pulso laser e do tempo entre a emissão e a detecção (KUMAR, 2012).

O termo escaneamento a laser aerotransportável (ALS) é comumente utilizado para a diferenciação entre sistemas que adquirem dados LiDAR por aeronaves, daqueles que utilizam espaçonaves ou plataformas terrestres. Grande parte dos lasers comerciais aerotransportáveis são providos de um dispositivo de escaneamento, cuja energia emitida é distribuída perpendicularmente ao trajeto da aeronave, adquirindo informações LiDAR na área de interesse (VAUHKONEN et al., 2014).

Os sistemas ALS possuem quatro principais componentes de hardware, estes são: escâner a laser, sistema de posicionamento global diferencial (GPS e unidades de solo e aeronave), unidade de medição inercial altamente sensível

(IMU) adjunto à unidade de escaneamento e computador a bordo para controlar os dados e armazená-los (KUMAR, 2012).

Tendo em vista que a reflectância da vegetação é alta em torno do comprimento de onda do infravermelho próximo, isto faz com que este comprimento de onda do espectro eletromagnético seja o mais utilizado em escâneres a laser para aplicações terrestres e em estudos de vegetação. Desta forma, o comprimento de onda 1064 nm é o de maior ocorrência (LEITOLD, 2014).

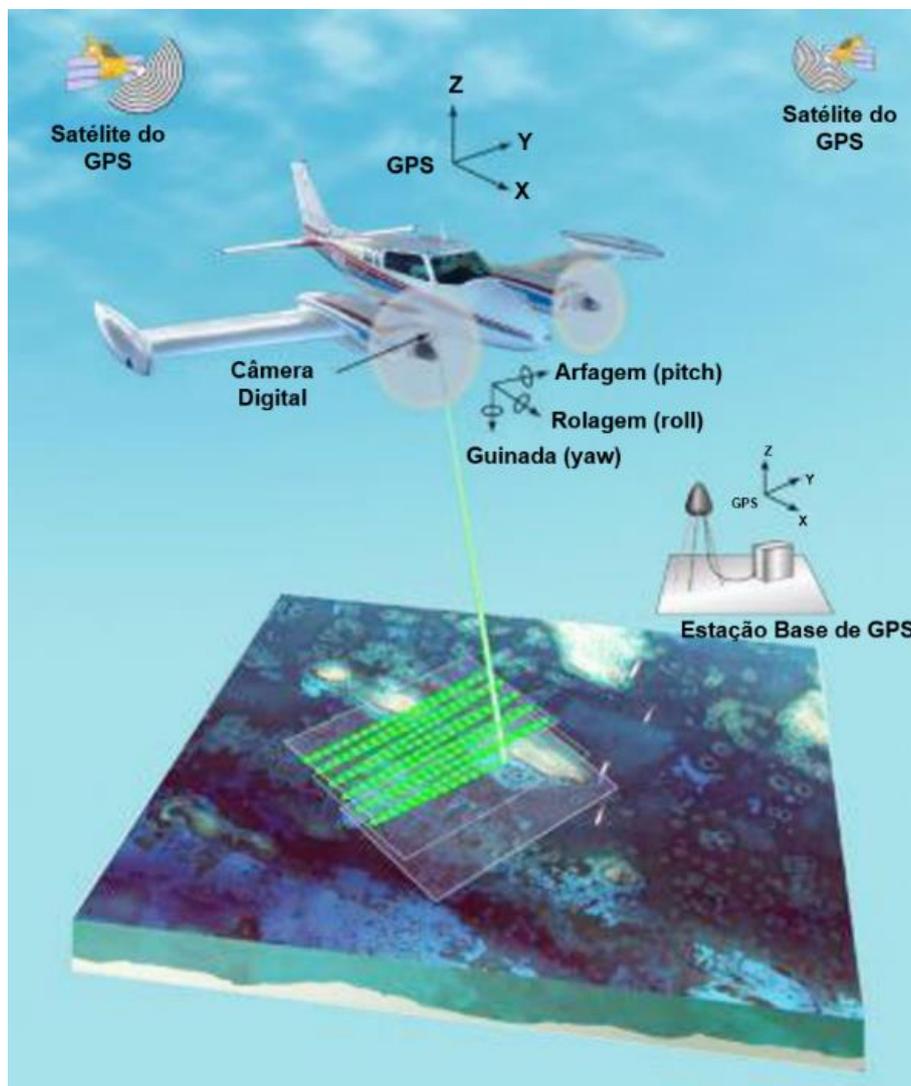


Figura 2.3 - Escaneamento LiDAR. Fonte: Adaptada de USGS (2007)

A exatidão dos dados de um sistema ALS é também influenciada e limitada pelo desempenho da integração do GPS e o sistema IMU. O GPS tem por

objetivo a determinação da posição da plataforma aerotransportada, portanto, segundo Alves (2010) são aplicados métodos de correções diferenciais de posicionamento, como as técnicas de posicionamento RTK (*Real Time Kinematic*) ou DGPS (*Differential GPS*), onde as correções dos sinais dos satélites GNSS (Sistemas Globais de Satélite de Navegação) são transmitidas em tempo real, da estação de referência (base) para a estação que se deseja determinar as coordenadas (Figura 2.4).

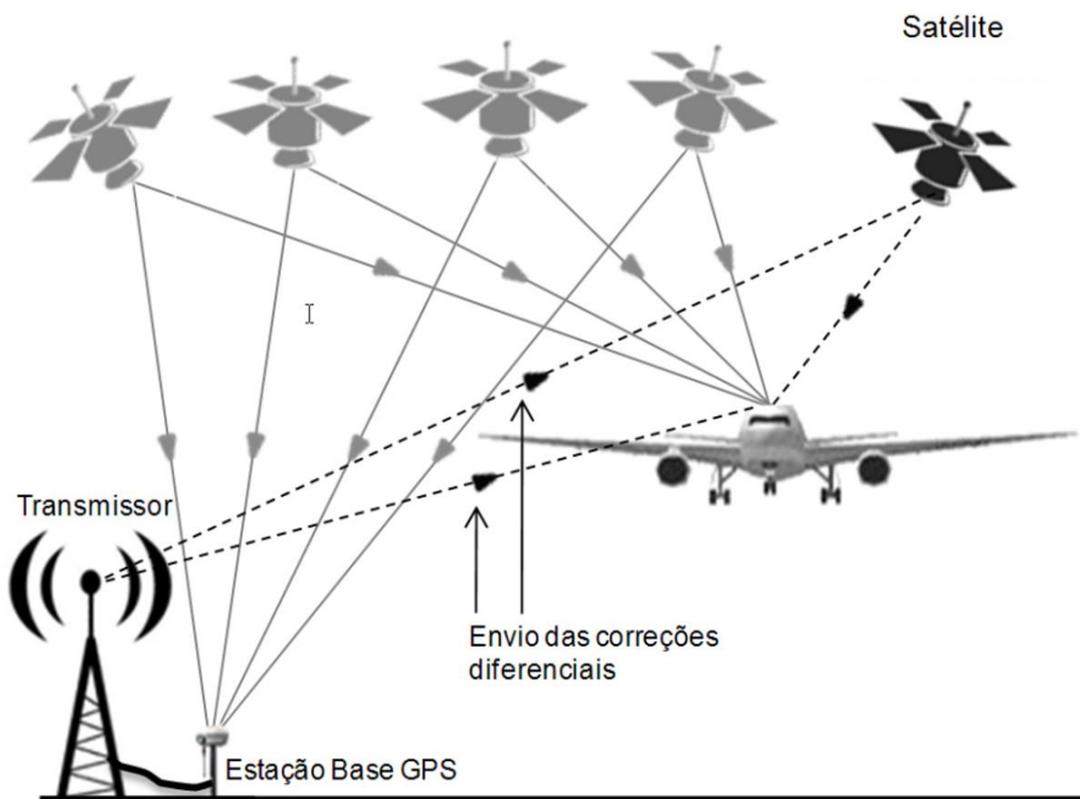


Figura 2.4 - Técnicas de posicionamento RTK (Real Time Kinematic) e DGPS (GPS Diferencial).  
Fonte: ALVES (2010)

De acordo com Leitold (2014), o tipo de informação coletada pelos retornos dos pulsos LiDAR, distinguem-se em duas grandes categorias de sensores: na primeira, o retorno discreto, que tipicamente mede apenas um, dois ou um número pequeno de alturas, com um tamanho de *footprint* de 1 metro ou menor. Característica que denomina o LiDAR de *small footprint*.

Com relação à segunda, há ainda os sensores que gravam o comprimento de onda contínua (*full-waveform*), capazes de registrar integralmente todo o sinal do pulso, com base no montante de energia que retorna ao sensor para séries de iguais intervalos, apresentando uma energia média que é retornada ao sensor em intervalos de tempo iguais, e possui um tamanho de *footprint* no geral maior do que 10 metros (LiDAR de *large footprint*). O termo *footprint*, portanto, remete à abertura do feixe laser ao deixar a fonte emissora até o alvo (ALVES, 2010).

Segundo Vauhkonen et al. (2014), instrumentos ALS em aplicações florestais são geralmente *small-footprint*, com sistema de retornos discretos, que armazenam um ou mais retornos para cada pulso emitido. Isto deve-se à facilidade de conexão exata entre os dados escaneados e as árvores individuais, as parcelas ou os talhões florestais. O espaçamento dos pulsos no solo depende de certos parâmetros como a altitude e velocidade do voo, a frequência de repetição, ângulo de visada e padrão de escaneamento.

Pesquisas utilizando a tecnologia LiDAR (*Light Detection And Ranging*) aplicadas às florestas, tiveram início em meados dos anos 70, utilizando instrumentos de perfilamento simples. A partir dos anos 90, maior ênfase foi dada no desenvolvimento de soluções para o inventário florestal, por meio de informações LiDAR. Dessa forma, explorou-se a capacidade desta tecnologia, a bordo de aeronave, na obtenção de informações sobre extensas áreas. Este sistema de escaneamento a laser aerotransportado ficou comumente conhecido como *Airborne Laser Scanning* ou ALS (VAUHKONEN et al., 2014).

Os trabalhos mais recentes em LiDAR permitem obter um censo de atributos florestais (PACKALÉN et al., 2011; KUMAR, 2012). Entretanto, há 15 anos atrás, a geração desse censo florestal e a obtenção de informações ao nível de árvore seria algo impraticável no Brasil (ZANDONÁ, 2006). Porém, dado o crescente desenvolvimento das pesquisas nesse tema (POPESCU et al, 2004), tal realidade vem mudando. Atualmente, no Brasil, verificam-se diferentes grupos de pesquisas nacionais e internacionais, gerando esforços na estimativa cada vez mais eficaz de parâmetros florestais. A Tabela 2.1 mostra

o desenvolvimento de estudos com dados LiDAR em diferentes instituições de pesquisa.

Estudos como o de Pires (2005) e Zandoná (2006), representaram o início das pesquisas utilizando dados ALS, voltadas para a estimativa de atributos em florestas plantadas. Estes estudos demonstraram resultados promissores quanto a estimativa da altura e do volume da floresta, respectivamente, ainda que incipientes.

Alves (2010), buscou detectar árvores individuais com base nos dados LiDAR e na utilização de filtro de máxima reflectância local em floresta de araucária. O autor relata que devido à alta complexidade da floresta, bem como a alta densidade de plantas, esta identificação ficou prejudicada. Por outro lado, este mesmo autor estimou a altura das árvores, obtendo resultados mais satisfatórios ( $R^2=0,95$ ;  $RMSE=0,91$  metros).

Tabela 2.1 - Uso da tecnologia LiDAR em aplicações florestais por diferentes instituições de pesquisa no Brasil.

<b>Parâmetro florestal</b>	<b>Forma de obtenção dos dados</b>	<b>Exemplo de aplicação na literatura brasileira</b>	<b>Instituição de Pesquisa</b>
Altura das árvores	Medida direta	Pires, J. M. (2005)	UFV
Volume de madeira	Modelagem	Macedo (2009)	INPE
Carbono	Modelagem	Silva et al. (2014)	ESALQ/USP
Diâmetro a altura do peito (DAP)	Modelagem	Zandoná et al. (2006)	LACTEC/UFPR
Delimitação das copas	Fusão com outros sensores	Zandoná et al. (2006)	LACTEC/UFPR
Altura da base da copa	Medida direta	Alves (2010)	UFPR
Biomassa	Modelagem	Packalén et al. (2011)	FSF/UEF

Packalén et al. (2011) apresentaram um modelo de índice de sitio para dar embasamento ao potencial produtivo em uma fazenda de eucalipto, o qual possibilitava a predição do efeito do clone nos ambientes avaliados. Este foi muito bem ilustrado, por meio da representação espacial do índice de sitio, em

um dos talhões de estudo, utilizando a abordagem ABA com uma célula *grid* de 15 metros.

SILVA et al. (2014) também utilizando a abordagem ABA, porém em uma célula *grid* de 5 metros, quantificaram o estoque de carbono na biomassa aérea florestal em plantios comerciais de eucalipto. Os resultados obtidos pelos autores apresentaram  $R^2$  ajustado de 0,81 e RMSE de  $7,7 \text{ Mg}\cdot\text{ha}^{-1}$  de estoque de carbono.

Estes estudos confirmam a evolução das pesquisas brasileiras na utilização de dados ALS, os quais contribuem para a popularização do seu uso e do desenvolvimento científico voltado à estimativa de atributos florestais.

#### **2.4. Abordagem ABA na predição de atributos**

A Abordagem Baseada na Área (ABA ou *Area-based Approach*) foi desenvolvida com objetivo de estimar atributos florestais por meio de dados de sensoriamento remoto para caracterizar amplas áreas, no contexto do inventário florestal operacional. Esta abordagem é aplicada principalmente em dados ALS, permitindo a mensuração precisa da altura da floresta e da sua variação (NÆSSET, 1997a; NÆSSET, 1997b; NÆSSET, 2002).

De um modo geral, essa abordagem está centrada na relação entre variáveis predictoras oriundas de métricas de ALS e as variáveis resposta provenientes das parcelas de inventário, permitindo a estimativa dos atributos florestais em toda área (*wall-to-wall*) (WHITE et al., 2013). A abordagem ABA está dividida em três momentos, que serão descritos a seguir.

O primeiro momento constitui-se na aquisição dos dados ALS em área total. No segundo momento, com propósito de se desenvolver um modelo preditivo, os pontos ALS coincidentes com as parcelas de inventário florestal, são extraídos da nuvem de pontos ALS em área total. Em seguida, tais pontos, são processados de forma a se obter diversas métricas LiDAR para cada parcela. Em paralelo, as mesmas métricas extraídas das parcelas, são obtidas em área

total, por meio da agregação dos pontos em célula *grid* de tamanho pré-determinado (WHITE et al., 2013).

E em um terceiro momento, tais métricas são relacionadas com o atributo florestal de interesse mensurado em campo permitindo o ajuste de modelos preditivos. Esses modelos são aplicados para toda área total, gerando as estimativas de interesse. Uma vez que as equações preditivas são aplicadas, cada célula do *grid* irá ter uma estimativa da variável resposta, resultando no mapeamento do atributo de interesse para toda área. A Figura 2.5 mostra os passos da ABA (WHITE et al., 2013).

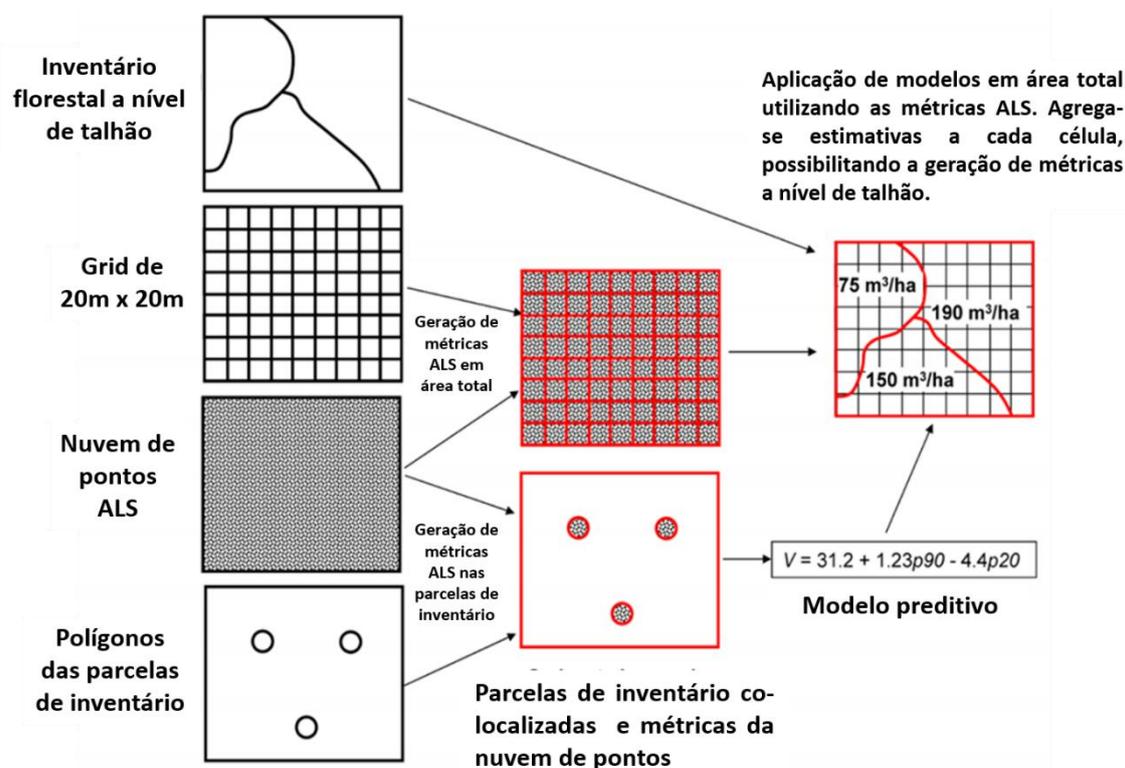


Figura 2.5 - Abordagem Baseada na Área (ABA).

Fonte: Adaptado de White et al. (2013).

Næsset (1997a, 1997b) verificou a efetividade da aplicação da abordagem ABA na detecção da altura média e do volume de madeira em talhões florestais. O autor observou que as estimativas utilizando dados laser scanner aerotransportados (ALS) foram muito próximas aos do inventário convencional, consideradas bastantes promissoras na época.

Apesar dessas vantagens no uso dos dados ALS, White et al. (2013) ressaltam que estes dados, quando em baixa resolução (resolução menor que um pulso por metro quadrado), podem não fornecer informação adequada com relação a composição das espécies de árvores, o que nesse sentido, faz do uso de dados de sensoriamento remoto passivos, grandes colaboradores no acréscimo de informação para aplicação da ABA.

## **2.5. Abordagem ITD**

A abordagem Detecção Individual das Árvores (ITD ou *Individual Tree Detection*), tem por objetivo derivar atributos florestais de interesse relativos à cada árvore, utilizando informações inerentes à sua localização (BREIDENBACH; ASTRUP, 2014). Para que esta detecção seja alcançada, dados ALS e imagens com alta resolução espacial têm sido utilizados (WANG et al., 2004; KAARTINEN et al., 2012; KUMAR, 2012). Segundo estes autores, muitos estudos têm adaptado a abordagem ITD para estimar diferentes variáveis resposta e para automatizar o processamento da ITD.

Um dos métodos mais comuns para detectar automaticamente as árvores em imagens, consiste na aplicação da filtragem da máxima local. Esta filtragem avalia o padrão de reflectância exercido pela floresta em imagens espectrais, de forma que o centro da copa das árvores, ou ponto mais alto, é atribuído ao pico de maior reflectância na imagem. Isto está atrelado também, ao alto nível de iluminação solar nas copas das árvores, fazendo com que a reflectância decresça em direção aos limites da copa (WANG et al., 2004). Dessa forma, os pontos mais escuros na imagem correspondem às sombras gerada pelas árvores adjacentes (KE; QUACKENBUSH, 2011).

Para obter esta informação, tamanhos fixos e variados de janelas de procura foram utilizados, com base na metodologia de KUMAR (2012) e Pereira (2014). Estas janelas são matrizes de pixels, cuja dimensão pode variar de acordo com o interesse e aplicação do usuário (PEREIRA, 2014). WULDER et al. (2000), utilizaram tamanhos variados de janelas para a extração da localização das árvores e estimar a área basal destas, com base em imagens de alta resolução

em talhões de *Douglas fir* e *Thuja plicata*. Com uma imagem de resolução de 1 metro, os autores utilizaram tamanhos de janela de 3 x 3, 5 x 5 e 7 x 7 metros. Já Pereira (2014), utilizou janelas de máxima de maiores proporções (8 x 8 metros) para detectar os picos das árvores de *Araucaria angustifolia*.

As configurações destes diversos filtros permitiram o destaque do centro da copa e a suavização das áreas adjacentes à esta, auxiliando assim na detecção individual das árvores (ITD). Segundo Vastaranta et al. (2011), o conhecimento da localização, do número e dos atributos de árvores individuais auxiliaria no monitoramento mais eficaz da produtividade florestal, combinando conceitos logísticos que integram os sistemas de transportes e modelos de manejo em toda cadeia dos recursos florestais. Entretanto, mesmo com a detecção automática da ITD, algumas árvores podem não ser detectadas (VASTARANTA et al., 2011).

Segundo Vastaranta et al. (2011), que estudaram as fontes de erro da ITD provenientes de dados ALS, para melhorar a estimativa da abordagem ABA, verificaram que a grande fonte de erro está atrelada à falha na detecção da árvore, e não os meios preditivos, propriamente ditos. Diante disso, estudos mais recentes mostram que é possível utilizar a abordagem ITD como meio de melhoria da abordagem ABA, tornando-a mais exata (BREIDENBACH; ASTRUP, 2014). Para tanto, faz-se necessário o conhecimento deste erro na abordagem ITD.



### 3 ÁREA DE ESTUDO E PROCEDIMENTO DE INVENTÁRIO

O estudo foi desenvolvido em uma área de reflorestamento, da empresa FIBRIA S.A., destinada à produção de celulose, localizada entre as coordenadas 23°33' S, 45°34' W e 23°30' S, 45°31' W, no município de São Luiz do Paraitinga, na região do Vale do Paraíba, no Estado de São Paulo, Brasil (Figura 3.1). A fazenda apresenta área útil, para plantios, de 139 hectares.

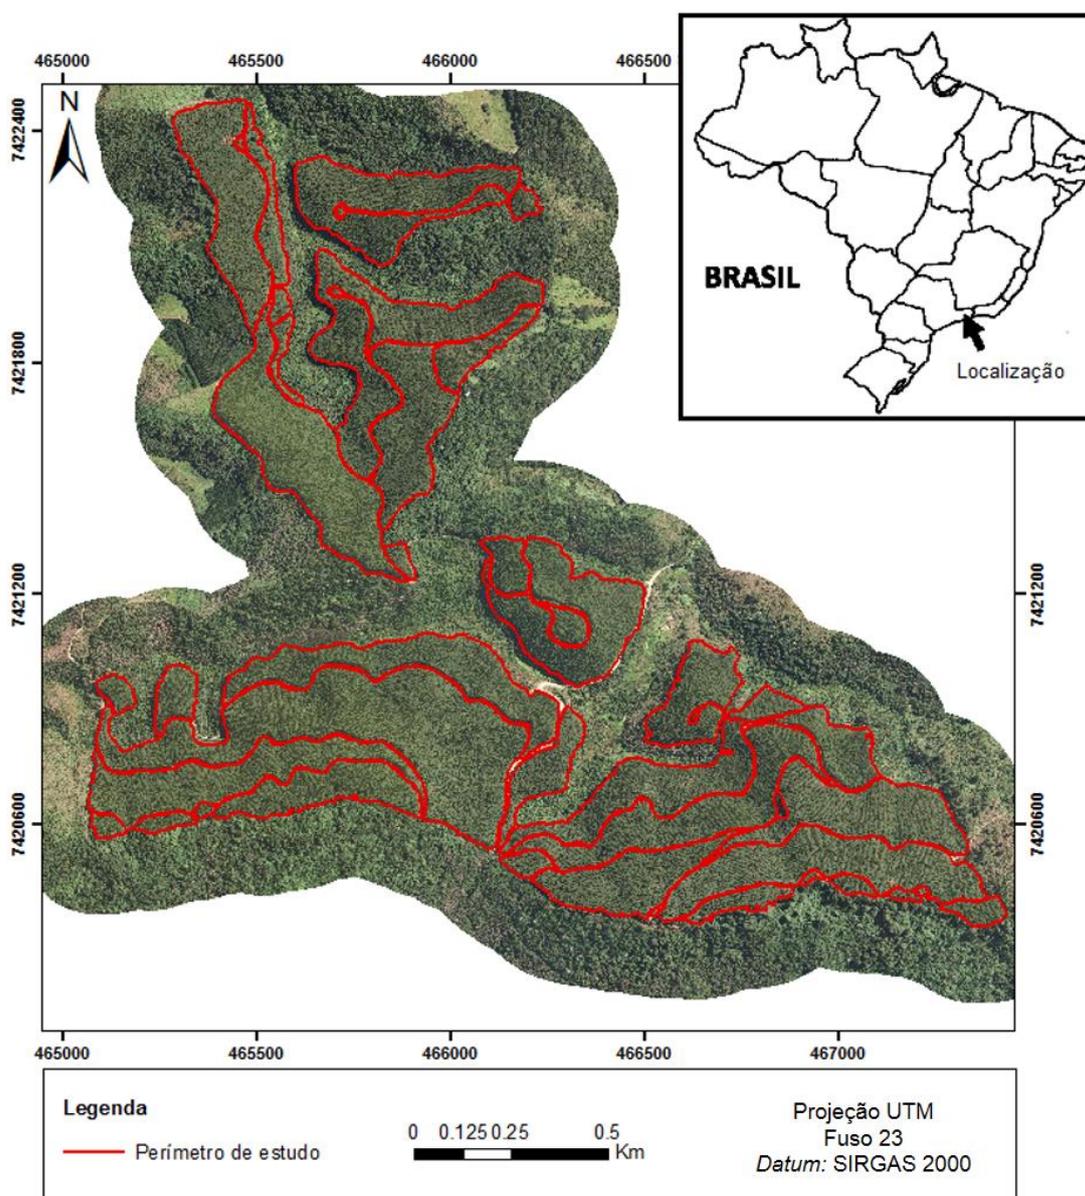


Figura 3.1 - Localização da área de estudo.

De acordo com a classificação de Köppen e Geiger (1928), o clima da região é Cwa, o que indica regiões caracterizadas por inverno rigoroso e verão chuvoso, cuja precipitação anual média varia, segundo Silva et al. (2014) de 1200 à 1232 mm e a temperatura anual de 17,1°C no mês mais frio (Julho) à 23,9°C no mês mais quente (Fevereiro). A topografia da área de estudo é complexa e varia de 974 a 1266 metros de altitude. Conforme Silva et al. (2014), os solos da região são predominantemente latossolos, variando entre argissolos e cambissolos.

A floresta estudada foi plantada em dezembro de 2006 sob regime de alto fuste, em espaçamento de 3 metros entre linhas e 2 metros entre fustes, obtendo-se uma densidade média nominal de 1667 árvores por hectare. A espécie cultivada foi o *Eucalyptus urograndis*, híbrido entre *Eucalyptus urophylla* e *Eucalyptus grandis*. Esta combinação incorpora qualidades de rápido crescimento, característica de qualidade da madeira herdada do *E. grandis*, associada a rusticidade, resistência às doenças e rápido enraizamento do *E. urophylla* (FERREIRA, 1979; SILVA et al., 2014).

A colheita da área ocorreu entre abril e maio de 2013, estando a floresta com idade média de 6,5 anos na época. Após realizada a colheita, toda madeira que foi transportada à fábrica foi pesada. A densidade da madeira foi obtida de acordo com o princípio de Arquimedes e o volume total de madeira entregue à fábrica foi definido pelas relações entre peso-volume obtidos neste processo. Uma descrição completa deste método é feita por Batista et al. (2014).

Parcelas operacionais do inventário florestal contínuo e pré-corte e as informações de fábrica, coletadas entre janeiro e abril de 2013, foram consideradas como verdade terrestre. O procedimento de amostragem utilizado foi a amostragem aleatória simples (AAS) com uma intensidade amostral média de 3 parcelas a cada 10 hectares. A metodologia de medição consistiu na utilização de parcelas circulares de 400 m<sup>2</sup>, para cada uma delas, foram medidas: a circunferência a 1,30m acima do solo (CAP) de todas as árvores, a altura total das 10 primeiras árvores centrais e a altura das árvores dominantes conforme o conceito de Assmann (1970). As alturas das demais árvores, não

medidas nas parcelas, foram estimadas por meio do modelo hipsométrico de Curtis (1967) (Equação 3.1), ajustado por parcela.

$$\ln(H) = \beta_0 + \beta_1 * \frac{1}{DAP} + \epsilon_i \quad (3.1)$$

Sendo:

H = altura total da árvore;

DAP = diâmetro a 1,30 metros do solo.

O volume por árvore foi obtido por meio do polinômio de 5° grau (SCHÖEPFER, 1966) (Equação 3.2), ajustado com base em cubagens rigorosas na região, sendo considerado o volume da parcela a somatória do volume individual das árvores.

$$\begin{aligned} v = k.DAP^2 & \left[ \beta_0^2 x_1 + (\beta_0 \beta_1 x_1^2) + \left( \frac{2}{3} \beta_0 \beta_2 + \frac{1}{3} \beta_1^2 \right) x_1^3 + \left( \frac{1}{3} \beta_0 \beta_3 + \frac{1}{2} \beta_1 \beta_2 \right) x_1^4 \right. \\ & + \left( \frac{2}{5} \beta_0 \beta_4 + \frac{2}{5} \beta_1 \beta_3 + \frac{1}{5} \beta_2^2 \right) x_1^5 \\ & + \left( \frac{1}{3} \beta_0 \beta_3 + \frac{1}{3} \beta_1 \beta_4 + \frac{1}{3} \beta_1 \beta_2 \right) x_1^6 \\ & + \left( \frac{2}{7} \beta_1 \beta_5 + \frac{2}{7} \beta_2 \beta_4 + \frac{1}{7} \beta_3^2 \right) x_1^7 + \left( \frac{1}{4} \beta_2 \beta_5 + \frac{1}{4} \beta_3 \beta_4 \right) x_1^8 \\ & \left. + \left( \frac{2}{9} \beta_3 \beta_5 + \frac{1}{9} \beta_4^2 \right) x_1^9 + \frac{1}{5} \beta_4 \beta_5 x^{10} + \frac{1}{11} \beta_5^{2x_1^{11}} \right]_{h_1}^{h_2} \quad (3.2) \end{aligned}$$

Sendo:

$$k = \frac{\pi}{40000};$$

$$x_1 = \frac{h_i}{H};$$

$h_i$  = Alturas comerciais do sólido de revolução;

H = Altura total em metros;

DAP = diâmetro à altura do peito;

$\beta_i$  = Parâmetro a ser estimado.

A localização geográfica das parcelas, e a sua localização em relação à nuvem LiDAR e imagem aérea (exigência da abordagem ABA), foram obtidas utilizando receptores de alta precisão geodésica (Trimble ProXRT) instalados no centro de cada parcela de inventário. Figura 3.2 mostra a área de estudo e a distribuição das parcelas de inventário. A Tabela 3.1 mostra a estatística descritiva das mensurações nas parcelas de inventário florestal.

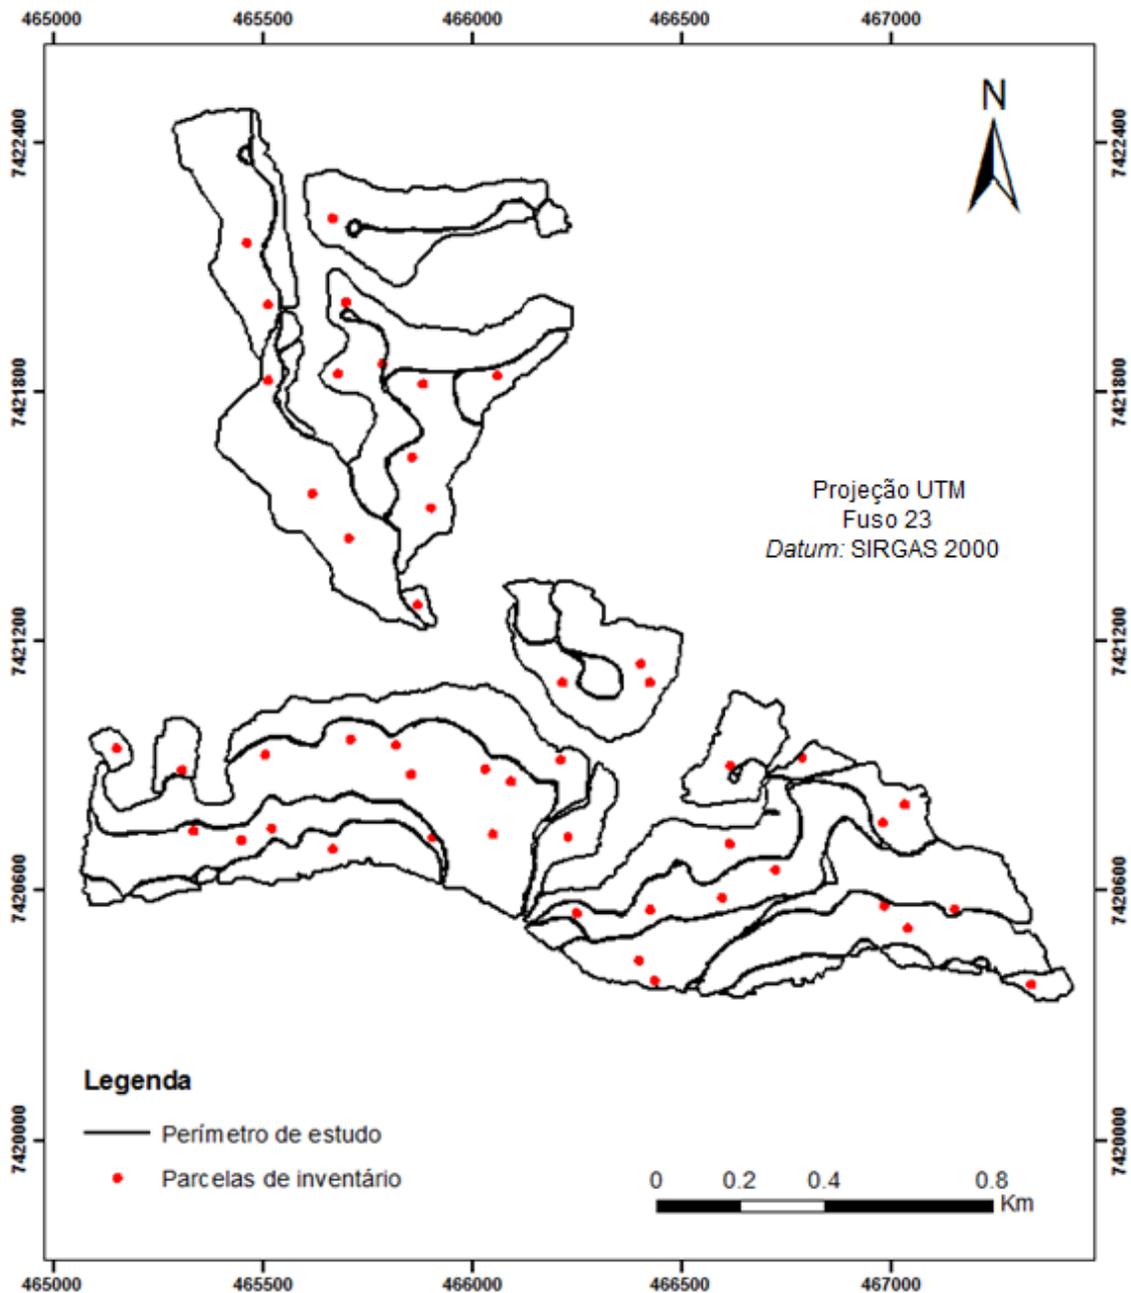


Figura 3.2 – Área de estudo e localização das parcelas de inventário florestal.

Tabela 3.1 – Estatísticas descritivas das parcelas de inventário, para as variáveis área basal (G), diâmetro à 1,3m (DAP), altura total (HT), altura dominante (HDOM) e volume de celulose sem casca (V).

	<b>G (M<sup>2</sup>.HA<sup>-1</sup>)</b>	<b>DAP (CM)</b>	<b>HT (M)</b>	<b>HDOM(M)</b>	<b>V (M<sup>3</sup>.HA<sup>-1</sup>)</b>
Mínimo	27,08	13,80	20,82	25,20	223,19
Média	33,96	16,00	24,89	29,79	331,16
Máximo	39,16	17,34	27,93	33,27	391,99
Desvio padrão	2,75	0,65	1,70	2,06	37,27
C.V.%	8,10	4,06	6,83	6,92	11,25

Um dos primeiros passos na obtenção de informações coerentes em uma análise exploratória e subsequentes ajustes de modelos preditivos é a detecção de *outliers* (BEN-GAL, 2005). Estes são caracterizados por diferir substancialmente do restante dos dados e podem impactar na geração dos resultados. Dessa forma, para detecção de *outliers*, utilizou-se análise de *boxplot* da variável altura média, excluindo-se da base, duas amostras consideradas *outliers*.



## 4 MATERIAIS E MÉTODOS

### 4.1. Dados de sensoriamento remoto

Os dados ALS foram adquiridos dia 15 de janeiro de 2012, em condições livre de nuvens, pelo sistema de escaneamento a laser Riegl LMS Q680I, simultaneamente com as fotografias aéreas. O sistema laser estava a bordo de uma aeronave Piper Seneca II duplo-motor, sobrevoando aos 624,24 metros de altitude acima do nível do solo, utilizando um ângulo de escaneamento (*Field of View* ou FOV) de 60°. A frequência de repetição foi de 300 mil pulsos por segundo, resultando em uma densidade amostral nominal de aproximadamente 5 pulsos por m<sup>2</sup> no solo. A orientação da aeronave foi determinada por meio do sistema de medição inercial (IMU) Applanix 510. A Figura 4.1 mostra os dados brutos ALS em parte da área de estudo.

As imagens multiespectrais com alta resolução espacial foram obtidas por uma câmera Z/I DMC, com de 0,15 metros de tamanho de pixel, e 4 bandas espectrais, azul (429 - 514 nm), verde (514 - 600 nm), vermelho (600 - 676 nm) e infravermelho próximo (695 - 831 nm). A Figura 4.2 apresenta área com plantio florestal vista pelos dados brutos ALS, e a mesma área é representada na Figura 4.2, porém pela imagem aérea. Já a Tabela 4.1 mostra os metadados da campanha de aquisição dos dados ALS e das imagens.

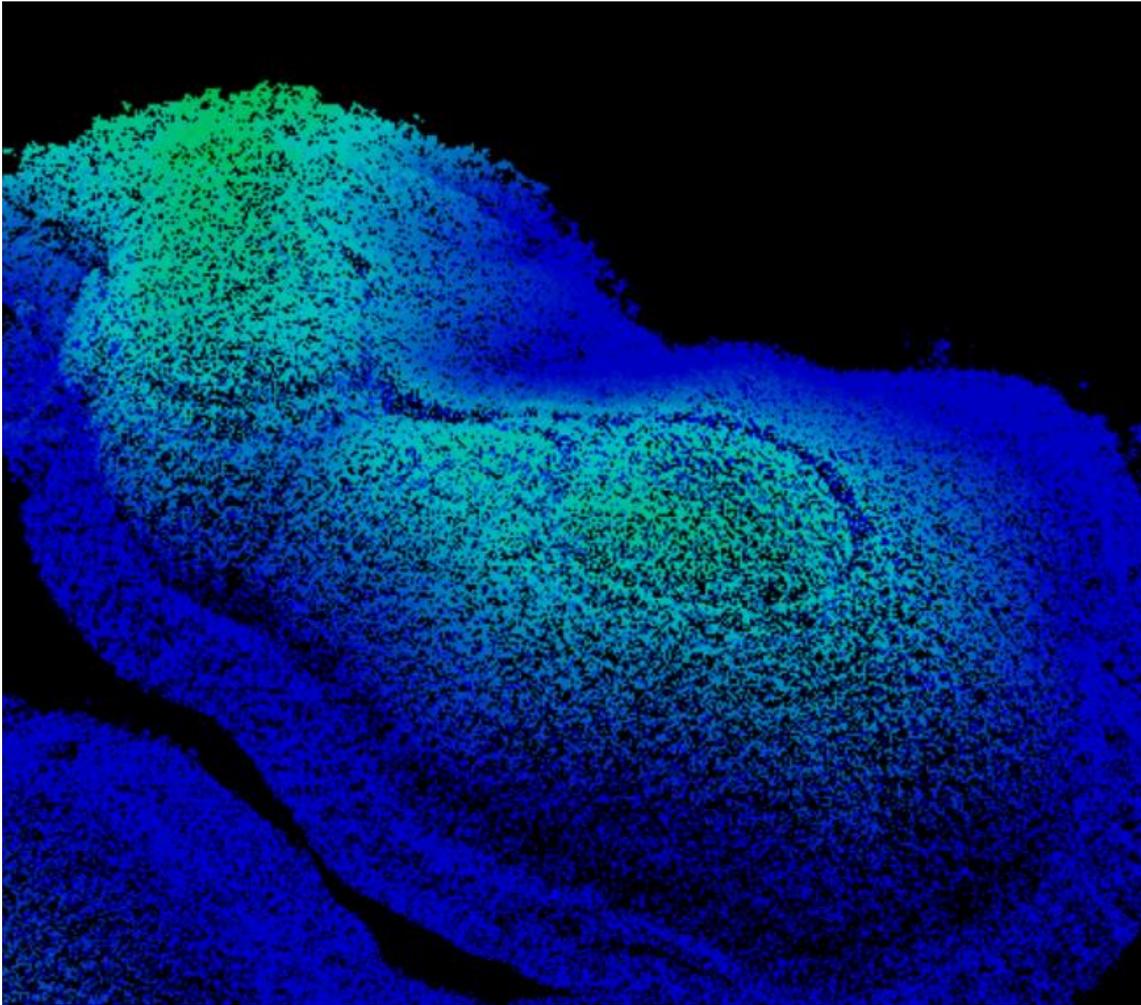


Figura 4.1 – Amostra de dados brutos ALS em parte da área de estudo.



Figura 4.2 - Fotografia aérea de parte da área de estudo.

Tabela 4.1 - Metadados da campanha de aquisição de dados ALS.

<b>Parâmetro</b>	<b>Especificação</b>
Altura do voo	629,24m
Ângulo de escaneamento (FOV)	60°
Câmera	HARRIER 68i
Datum	SIRGAS 2000
Densidade do pulso a laser	5 pulsos/m <sup>2</sup>
Escâner laser	RIEGL LMS q680i
Frequencia de varredura	300 KHz
IMU/GPS	Applanix 510
Largura da faixa de cobertura	726,58 m
Precisão da IMU	Applanix 510 (10 a 15 cm de precisão)
Resolução espacial da imagem	0,15 metros
Taxa de leitura	200 mil pulsos
Velocidade do vôo	55 m/ s

#### 4.2. Processamento e extração de métricas da nuvem de pontos ALS

Os principais produtos obtidos pelo processamento dos dados ALS neste estudo foram: Modelo Digital do Terreno (MDT), Modelo Digital da Superfície (MDS), Modelo Digital de Elevação (DEM) e as métricas da nuvem de pontos ALS. Sendo assim, na geração do MDT e MDS utilizou-se o software Lastools v111216 (ISENBURG, 2014), já para o processamento dos demais produtos, conforme a abordagem ABA, utilizou-se o software FUSION 3.42 (MCGAUGHEY, 2014).

O processamento teve início no preparo da nuvem de pontos ALS. Primeiramente verificou-se a conformidade da nuvem pelo comando *lasinfo*. Em seguida, dividiu-se a nuvem de pontos em tiles de 200 m x 200 m por meio do comando *lastile*, considerando um *buffer* de sobreposição entre tiles de 50 metros. Isso permitiu que os dados LiDAR fossem processados de maneira mais rápida e eficiente, sem que os pontos ALS sofressem distorções (KUMAR, 2012).

O retorno do solo foi separado do retorno da vegetação utilizando os comandos *lasground* e *lasclassify*, adotando-se uma janela de procura de 5 m x 5 m, por meio do filtro *Adaptive TIN* (ISENBURG, 2014). Este tamanho de janela é comumente utilizado para processamento em florestas plantadas, uma vez que tais dimensões correspondem as do maior objeto da cena (copas das árvores de eucalipto) (KUMAR, 2012).

Buscando uma redução de ruídos da nuvem de pontos ALS, inerentes a aquisição dos dados, foram removidos pontos considerados abaixo da superfície do terreno, bem como pontos excedentes à um limiar de 40m de altura acima do terreno. Pontos alusivos ao sub-bosque (abaixo de 3 metros) foram excluídos. Nessa etapa foi utilizada a função *lasheight* na remoção de ruídos.

O *buffer* inserido anteriormente foi removido com o objetivo de evitar a redundância de informações (KUMAR, 2012), unindo-se os tiles da área de

estudo e resultando novamente, em um único arquivo “.las”, contendo a nuvem de pontos ALS para toda área. Para tanto, utilizou-se o comando *lasmerge*. Em seguida utilizou-se o comando *blast2dem* para gerar o MDT com resolução de 0,15 m. O Modelo Digital da Superfície (MDS), o qual inclui a floresta de eucalipto, foi também criado utilizando o comando *blast2dem* com resolução de 0,15 m. Segundo McCullagh (1988), a resolução (S) de um MDS pode ser estimada pela Equação 4.1:

$$S = \sqrt{\frac{1}{n}} \quad (4.1)$$

Sendo:

n = número de pontos do terreno por m<sup>2</sup>.

Isso significa que a resolução do MDS deve se igualar a densidade de pontos no terreno. Considerando que a densidade média de pontos ALS é de 42,69 pontos/m<sup>2</sup>, a resolução do MDS adotada no presente estudo é de 0,15 metros.

A nuvem de pontos tridimensional foi normalizada previamente à extração das métricas de interesse, para tanto, utilizou-se o comando *clipdata* do software FUSION (MCGAUGHEY, 2014). Esse comando faz com que se tenha certeza que as coordenadas z correspondem à altura acima do solo e não da elevação dos pontos (SILVA et al., 2014). Este comando permitiu também o recorte das áreas com dados ALS, coincidentes com a área das parcelas.

Ainda utilizando o software FUSION, para gerar as métricas ALS nas parcelas e em área total foram utilizadas as funções *cloudmetrics* e *gridmetrics*, respectivamente. Entretanto, quando em área total, considerou um tamanho de janela de 5 m x 5 m seguindo o conceito ABA, cujo tamanho de pixel deve ser mais largo que a copa das árvores (WHITE et al., 2013). O diâmetro da copa do gênero *Eucalyptus* spp. variou de 2 a 3 metros, na área de estudo. Para geração das demais métricas, foram considerados os primeiros retornos apenas. A Tabela 4.2 mostra as 27 métricas ALS divididas em três categorias, a altura, a cobertura e a topografia.

Tabela 4.2 - Métricas de altura e cobertura da copa derivadas da nuvem de pontos ALS.

<b>Categoria</b>	<b>Métrica ALS</b>	<b>Acrônimo</b>
<b>Altura</b>	Altura mínima	$h_{min}$
	Altura máxima	$h_{max}$
	Altura média	$h_{mean}$
	Variância da altura	$h_{var}$
	Desvio padrão da altura	$h_{sd}$
	Coefficiente de variação da altura	$h_{cv}$
	Moda da altura	$h_{moda}$
	Curtose da altura	$h_k$
	1º Percentil da altura	$h_{p1}$
	5º Percentil da altura	$h_{p5}$
	10º Percentil da altura	$h_{p10}$
	20º Percentil da altura	$h_{p20}$
	25º Percentil da altura	$h_{p25}$
	30º Percentil da altura	$h_{p30}$
	40º Percentil da altura	$h_{p40}$
	50º Percentil da altura	$h_{p50}$
	60º Percentil da altura	$h_{p60}$
	70º Percentil da altura	$h_{p70}$
	75º Percentil da altura	$h_{p75}$
80º Percentil da altura	$h_{p80}$	
90º Percentil da altura	$h_{p90}$	
95º Percentil da altura	$h_{p95}$	
99º Percentil da altura	$h_{p99}$	
<b>Cobertura</b>	Número de 1ºs retornos acima da média	$C_{ab.mean}$
	Percentual de copa	$C\%$
<b>Topografia</b>	Declividade média do terreno (°)	$D$
	Altitude média	$A_{mean}$

As métricas ALS, foram calculadas pelas seguintes equações (SILVA, 2013; MCGAUGUEY, 2014):

$$h_{mean} = \frac{1}{n} * \sum_{i=1}^n h_i \quad (4.2)$$

Altura média de pontos ALS ( $h_{mean}$ ) (Equação 4.2).

Sendo:

$h_i$  = altura do  $i$ -ésimo ponto da nuvem de pontos  
 $n$  = número de observações (número de pontos na nuvem).

Desvio padrão da altura na nuvem de pontos ALS ( $h_{sd}$ ) (Equação 4.3).

$$h_{sd} = \sqrt{\frac{1}{n-1} * \sum_{i=1}^n (h_i - h_{mean})^2} \quad (4.3)$$

Sendo:

$h_{mean}$  = altura média do número de pontos.  
 $n$  = número de observações (número de pontos na nuvem)

Variância da altura da nuvem de pontos ALS ( $h_{var}$ ) (Equação 4.4).

$$h_{var} = \frac{1}{n-1} * \sum_{i=1}^n (h_i - h_{mean})^2 \quad (4.4)$$

Sendo:

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

Coeficiente de variação em altura na nuvem de pontos ( $h_{cv}$ ) (Equação 4.5).

$$h_{cv} = \frac{h_{sd}}{h_{mean}} \quad (4.5)$$

Percentis da altura na nuvem de pontos ALS ( $h_{pi}$ ). O  $i$ -ésimo percentil de  $n$  pontos observados na nuvem de pontos ALS (SILVA, 2013), ordenados em valores de altura é correspondente ao valor que ocupa a posição  $K$  do conjunto de dados (Equação 4.6).

$$K = \frac{h_{pi}(n+1)}{100} \quad (4.6)$$

Sendo:

$K$  = valor que ocupa o  $i$ -ésimo percentil em altura na nuvem de pontos;  
 $h_{pi}$  =  $i$ -ésimo percentil em altura na nuvem de pontos.  
 $n$  = número de observações (número de pontos na nuvem)

Curtose ( $h_k$ ) é uma medida para avaliar se os dados se concentram em um pico ou se estão espalhados em um plano, em relação a uma distribuição normal (Equação 4.7) (MCGAUGUEY, 2014). Ou seja, é o grau de achatamento da função de distribuição, onde os conjuntos de dados com alta curtose apresentam um pico distinto ao redor da média, enquanto, dados com baixo curtose tendem a ter um topo plano, perto da média, ao invés de um pico agudo. Uma distribuição uniforme seria o caso extremo.

$$h_k = \frac{\sum_{i=1}^n (Y_i - \bar{Y})^4}{(n-1)s^4} \quad (4.7)$$

Sendo:

$Y_i$  = altura de cada ponto

$s$  = desvio-padrão da altura

$\bar{Y}$  = média da altura

### 4.3. Variáveis derivadas da imagem

Para extrair métricas derivada das imagens multiespectrais com alta resolução espacial, utilizou-se o software R (R DEVELOPING CORE TEAM, 2015). As métrica foram as bandas 1, 2, 3, e 4 (azul, verde, vermelho e infravermelho próximo), as diferentes razões entre estas bandas e o índice de vegetação NDVI (*Normalized Difference Vegetation Index*). Para tanto, em cada uma das bandas agregou-se os valores médios de reflectância, aos pixels de 5 m x 5 m.

O índice de vegetação NDVI foi calculado pela Equação 4.8, uma vez que a vegetação tem alta resposta no infravermelho próximo e baixa no vermelho. Áreas de vegetação apresentam maior destaque quando em comparação com áreas não vegetadas (PONZONI; SHIMABUKURO, 2010).

$$NDVI = \frac{(NIR - VIS)}{(NIR + VIS)} \quad (4.8)$$

Sendo:

NIR = banda do infravermelho próximo;

VIS = banda do vermelho.

#### **4.4. Estimativa do volume de madeira em área total**

##### **4.4.1. Seleção de variáveis e ajuste de modelos**

Nesta etapa, foram considerados três diferentes cenários, sendo o primeiro baseado somente em variáveis derivadas dos dados ALS, o segundo somente em variáveis derivadas das imagens, e o último, a integração de ambos os conjuntos de variáveis. Os métodos descritos aqui foram executados separadamente, para cada um dos cenários.

Ao se trabalhar com um grande número de variáveis preditoras como observado no presente trabalho, uma das principais etapas na aplicação de uma regressão linear múltipla é a seleção de variáveis preditoras. Para tanto, aplicou-se método *Best Subset Selection*, por meio da função *regsubsets* do pacote “*leaps*” em ambiente R (LUMLEY; 2014; R DEVELOPMENT CORE TEAM, 2015).

Na aplicação do método, ajustam-se inicialmente todos os modelos com uma variável preditora apenas, selecionando o melhor entre eles. Na sequência, ajustam-se todos os modelos possíveis que contém duas variáveis preditoras, selecionando, nesta etapa, o melhor modelo com duas variáveis. Este processo ocorre até que o número de variáveis no modelo seja igual ao número de variáveis preditoras, ao final do processo o número total de combinações avaliadas é próximo à  $2^p$ , sendo  $p$  o número de variáveis preditoras (JAMES et al., 2014).

Uma vez selecionado o melhor modelo preditivo para cada um dos tamanhos de modelo, a etapa seguinte consiste na escolha do melhor modelo, dentre todos estes modelos selecionados. Um indicativo do melhor modelo pode ser obtido utilizando critérios de bondade de ajuste, tais como *Bayesian Information*

*Criterion* (BIC), *Akaike information criterion* (AIC) e  $R^2$  ajustado (JAMES et al., 2014).

No presente estudo utilizou-se como indicativo o critério BIC. Tal abordagem é derivada do ponto de vista bayesiano, e é similar ao AIC. A formulação do BIC

$$BIC = \frac{1}{n}(RSS + \log(n) d\hat{\sigma}^2) \quad (4.9)$$

é expressa na Equação 4.9.

Sendo:

$n$  = número de observações;

$RSS$  = raiz da soma dos quadrados;

$d$  = número de preditoras mais intercepto;

$\sigma$  = variância.

Apesar do critério BIC ser um ótimo indicativo do melhor modelo, tal abordagem utiliza os resíduos gerados pelos dados de treinamento. Isto significa que pode haver um comportamento incerto do modelo indicado, quando aplicado à uma base de dados que não foi utilizada no ajuste do modelo (JAMES et al., 2014).

#### **4.4.2. Validação do Modelo**

Além do critério BIC, para a escolha do melhor modelo baseou-se na raiz do erro quadrático médio (RMSE) obtida pela validação cruzada *k-fold* ( $CV_k$ ) com  $k=5$ . A aplicação da validação cruzada permite um melhor entendimento do comportamento do modelo frente a uma base de dados não utilizada no ajuste do mesmo (JAMES et al., 2014). Essa abordagem envolve a divisão aleatória das observações em  $k$  grupos (*folds*), de tamanhos aproximadamente iguais, sorteados aleatoriamente. No processo, o primeiro grupo de observações é removido e utilizado como dados de validação, enquanto o restante  $k - 1$  grupos, são utilizados ajustados ao modelo.

Esse procedimento é repetido  $k$  vezes, em cada vez, um diferente grupo de observações é tratado como conjunto de validação. Esse processo, portanto, resulta na estimativa do erro  $k$  vezes,  $MSE_1, MSE_2, MSE_3, \dots, MSE_k$ . A estimativa  $k$ -fold é computada pela média desses valores, cuja formulação é disposta na Equação 4.10.

$$CV_k = \frac{1}{k} \sum_{i=1}^k MSE_i \quad (4.10)$$

Sendo:

MSE = Erro Quadrático médio

Após essa etapa, pode-se comparar o valor de RMSE entre os diferentes modelos, escolhendo-se aquele que apresentou menor RMSE. No presente estudo, os intervalos de confiança com p-valor igual a 0,05 foram gerados a partir de 1000 simulações.

#### **4.4.3. Verificação de pressuposições**

De acordo com Peña e Slate (2006), o ajuste de modelos lineares depende de quatro pressuposições básicas: (1) existência de linearidade entre variáveis preditoras e variável resposta, (2) normalidade dos resíduos, (3) homocedasticidade (ou variância constante dos resíduos) e (4) independência entre resíduos. Sendo assim, após a identificação do melhor modelo para cada um dos cenários, verificou-se o atendimento de tais pressuposições por meio de análises gráficas e utilizando-se o pacote “*gvlna*” no software R, o qual realiza um conjunto de testes estatísticos para avaliar atendimento ou não das pressuposições (PEÑA; SLATE, 2014; R DEVELOPMENT CORE TEAM, 2015).

#### **4.4.4. Escolha do cenário e representação gráfica do mesmo**

Após a identificação do cenário de melhor desempenho por meio da validação cruzada e das verificações de pressuposições, gerou-se um mapa do volume de madeira em área total. Esse volume foi calculado e comparado com o volume obtido pelo inventário florestal convencional e com o volume

proveniente da área de estudo, recebido na porta da fábrica, após a colheita florestal.

#### 4.5. Volume Individual da Árvore (ITD)

O objetivo mais amplo da abordagem ITD é estimar atributos florestais a nível de árvore. Porém, em primeiro lugar é preciso identificar espacialmente cada árvore. Neste sentido, o processo de identificação das árvores adotado, é crucial na estimativa dos atributos florestais, pois determinará a exatidão da localização e do número de árvores detectadas (VASTARANTA et al., 2011). Para atingir esse objetivo, utilizou-se o software ArcGIS versão 10.2.2 no processamento da ITD.

Um dos métodos mais comumente utilizados e que apresenta boa eficiência é o método da filtragem da máxima local, onde o ponto central da copa, considerado o ponto mais alto, e o que apresenta maior brilho na imagem (WANG et al., 2004; KUMAR, 2012). Desta forma, a Figura 4.3 mostra os passos adotados no presente estudo para gerar a ITD em cada uma das bandas utilizadas neste estudo.

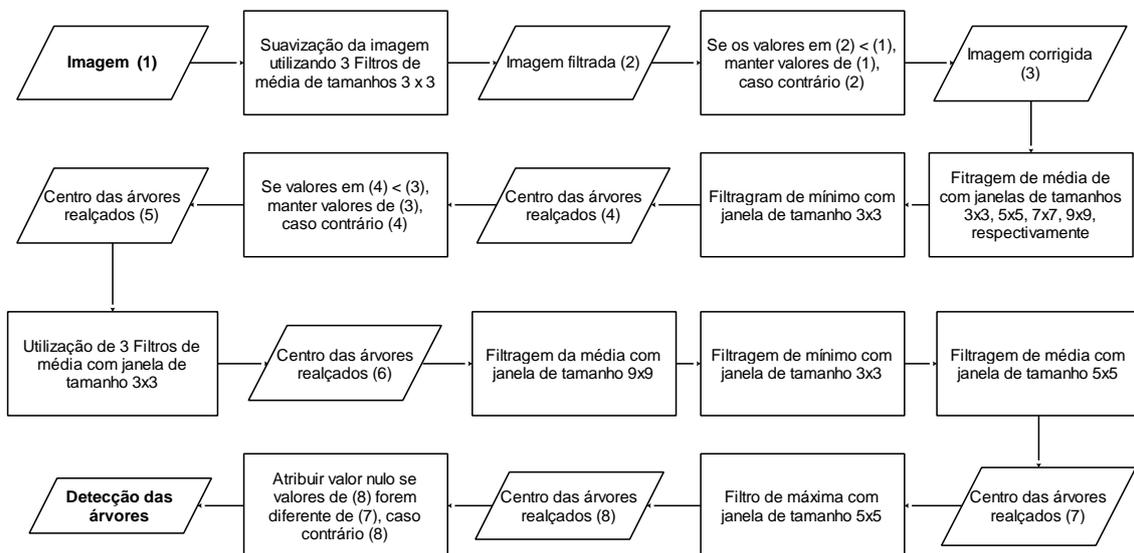


Figura 4.3 – Descrição das Etapas para obtenção da ITD em cada uma das bandas utilizadas.

Como cada banda contém diferentes informações entre si (WULDER et al., 2000), este processo de Detecção Individual das Árvores (ITD) (Figura 5.1), foi realizado para cada uma das bandas da imagem aérea. Além disso, aplicou-se o mesmo processo no primeiro componente principal (PCA 1) destas bandas, resultando em 5 diferentes planos de informações, com diferentes ITDs.

De acordo com Wang et al. (2004), o uso dos componentes principais (PCA) transforma um conjunto de imagens, em um novo conjunto de imagens (componentes) com menor correlação possível entre os componentes. Dessa forma, utilizou-se o primeiro componente principal (PCA 1) que possui a maior quantidade de informação entre os demais componentes.

Estes planos de informação foram ordenados conforme análise visual dos mesmos e tendo como base a imagem aérea de alta resolução espacial, referente à área de estudo. Para gerar o plano de informação final da ITD, os 5 planos de *layers* ordenados foram utilizados. Para tanto, o *layer* de melhor desempenho foi inicialmente tomado como base. A partir deste *layer*, considerou-se uma faixa de 0,7 metros em torno de cada árvore. Pontos exteriores a esta faixa, pertencentes ao segundo *layer* de melhor desempenho, foram adicionados, gerando um novo *layer* ITD de pontos complementares. Desta forma, tomou-se como base este novo plano de informação ITD.

Em seguida, a partir desse novo plano de informação, considerou-se novamente uma faixa de 0,7 metros em torno de cada árvore. Pontos exteriores a esta faixa, pertencentes ao terceiro *layer* de melhor desempenho, foram adicionados, gerando um novo *layer* de pontos complementares ITD. Este novo plano de informação, de pontos complementares, foi tomado como base. Desta forma, o procedimento se repetiu até que todos os planos de informação tivessem contribuído para a geração do plano de informação ITD final.

#### **4.5.1. Conversão da abordagem ITD para a abordagem ABA**

Gerado o plano de informação final da ITD, o número de árvores foi agregado a cada uma das de janela de 5 m x 5 m, conforme a abordagem ABA. Dessa forma, em cada uma das células do *grid* foi possível identificar o número de árvores existentes, detectados pelo método da máxima local na ITD, e assim, representar graficamente o número de árvores por hectare em área total.

#### **4.5.2. Detecção e correção do erro em área total**

A detecção do erro da abordagem ITD foi realizada comparando-se o número de árvores detectadas e o número de árvores observadas nas parcelas de inventário. Tal diferença foi considerada a variável resposta, enquanto métricas ALS e informações das imagens foram consideradas variáveis preditoras, possibilitando assim a modelagem do erro da ITD, e a sua consequente predição em área total.

Para tanto, aplicou-se método *Best Subset Selection*, por meio da função *regsubsets* do pacote “*leaps*” em ambiente R (LUMLEY, 2014; R DEVELOPMENT CORE TEAM, 2015), considerando-se como tamanho máximo permitido de quatro variáveis preditoras, para estimar o erro da detecção. Um indicativo do melhor modelo pode ser obtido utilizando critérios de bondade de ajuste, tais como *Bayesian information criterion* (BIC), *Akaike information criterion* (AIC) e  $R^2$  ajustado (JAMES et al., 2014).

No presente estudo utilizou-se como indicativo o critério BIC. Além deste critério BIC, para a escolha do melhor modelo, baseou-se na raiz do erro quadrático médio (RMSE) obtido pela validação cruzada *k-fold* ( $CV_k$ ) com  $k=5$ . Após essa etapa, pode-se comparar o valor de RMSE entre os diferentes modelos, escolhendo-se aquele de menor valor.

Em seguida verificaram-se as seguintes pressuposições, da mesma forma que realizado no item 4.4.3. Após essa etapa, comparam-se os diferentes modelos com até quatro variáveis, selecionando-se aquele com melhor desempenho. Ao término dessa etapa, aplicou-se o modelo selecionado, e, representou-se espacialmente o erro por hectare.

#### **4.5.3. Correção do número de árvores por hectare**

Uma vez detectado o número das árvores por hectare segundo a metodologia ITD e ABA, ou semi-ITD, bem como estimado o erro para cada pixel desta abordagem, a estimativa final do número de árvores pode ser obtida pela soma destas duas informações em cada célula de 5 m x 5 m para toda área de estudo, gerando-se assim a representação espacial do número corrigido de árvores por hectare.

#### **4.5.4. Estimativa do volume individual das árvores**

Para a geração do volume por árvore em cada célula grid de 5 m x 5 m , basta-se dividir volume em área total ( $m^3/ha$ ), gerado anteriormente no item 4.4, pela integração de métricas derivadas de dados ALS e imagens de alta resolução espacial, pelo número de árvores detectadas pela abordagem ITD e ABA (semi-ITD). Para melhor visualização do resultado de tal divisão, classificou-se o volume de árvores individuais em 5 grupos.



## 5 RESULTADOS

### 5.1. Estimativa do volume de madeira em área total

Em uma análise exploratória, utilizando-se gráficos *boxplot* da variável altura média ( $h_{mean}$ ) obtida por dados ALS, observou-se a existência de dois *outliers*. Uma vez que a abordagem ABA exige a confiança na localização das parcelas e com base no conhecimento *a priori* da altura das mesmas em campo, constatou-se então a inconsistência na localização destas duas amostras, optando-se por removê-las da base. A Figura 5.1 mostra os dois *outliers* identificados e removidos da base de dados.

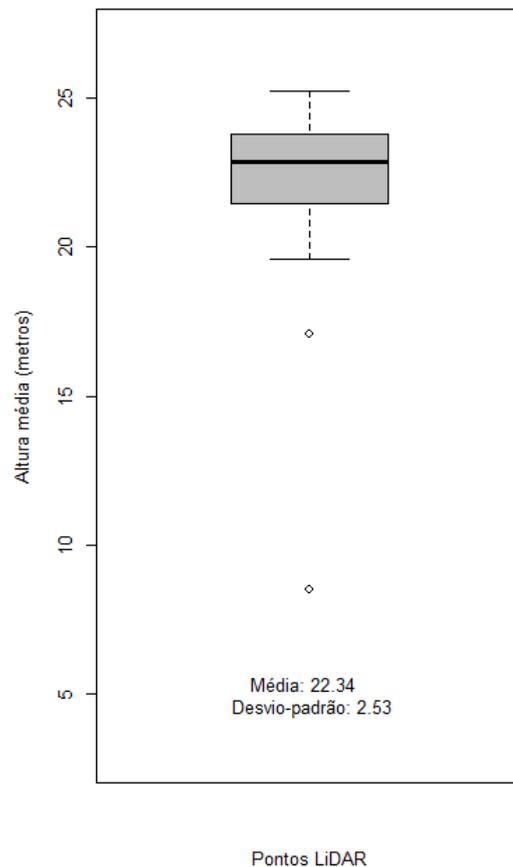


Figura 5.1 - Distribuição da Altura média dos pontos ALS ressaltando dois *outliers* a serem removidos.

### 5.1.1. Seleção de variáveis e ajuste de modelos

Os resultados da abordagem *Best Subset Selection* utilizando o critério BIC na identificação dos melhores modelos em seus diferentes tamanhos, são apresentadas nas Figuras 5.2, 5.3, 5.4. Estas figuras ilustram cada um dos três diferentes cenários, sendo que o primeiro utiliza variáveis ALS apenas, o segundo apenas variáveis da imagem e o terceiro utiliza ambas as variáveis, respectivamente.

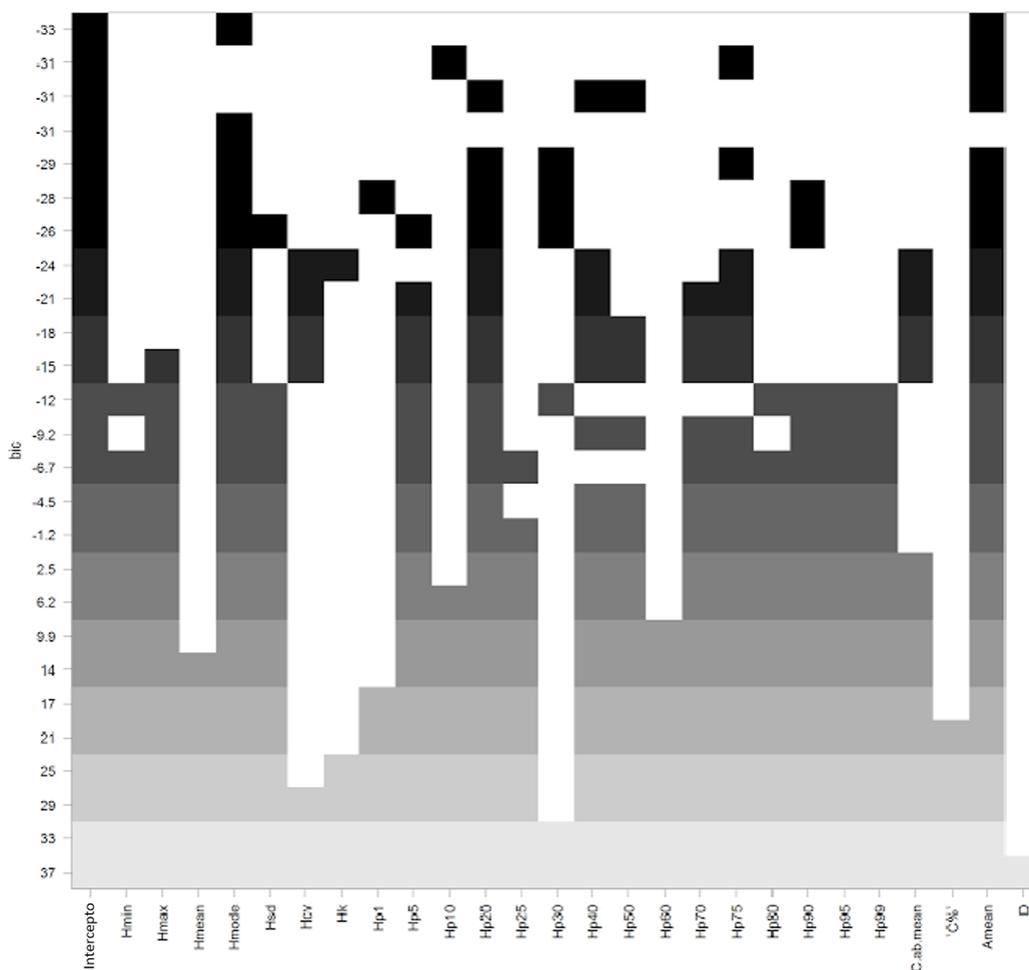


Figura 5.2 - Melhores modelos em diferentes tamanhos, selecionados pela abordagem *Best Subset Selection* ordenados pelo critério BIC, utilizando apenas variáveis ALS. A presença destas variáveis no modelo é indicada pela coloração em tons de cinza.

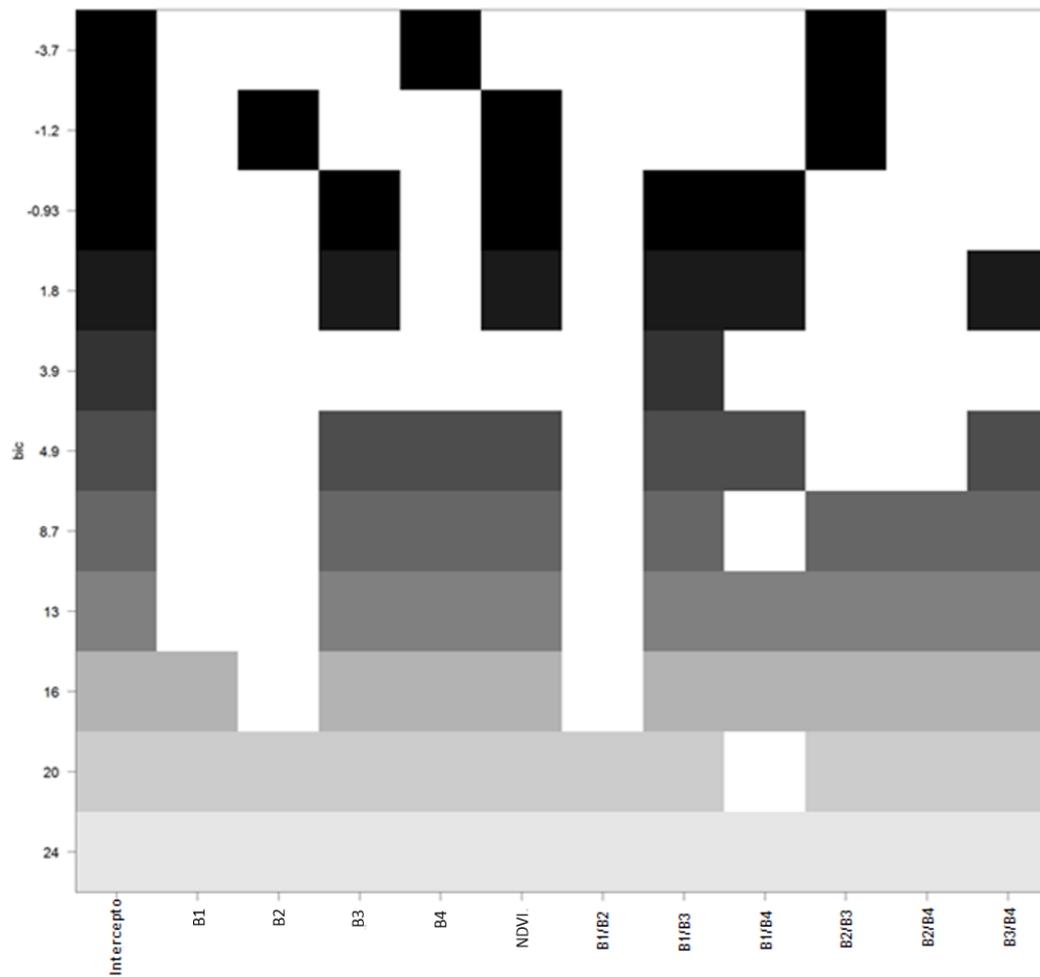


Figura 5.3 - Melhores modelos em diferentes tamanhos, selecionados pela abordagem *Best Subset Selection* ordenados pelo critério BIC, utilizando apenas variáveis da imagem aérea. A presença destas variáveis no modelo é indicada pela coloração em tons de cinza.

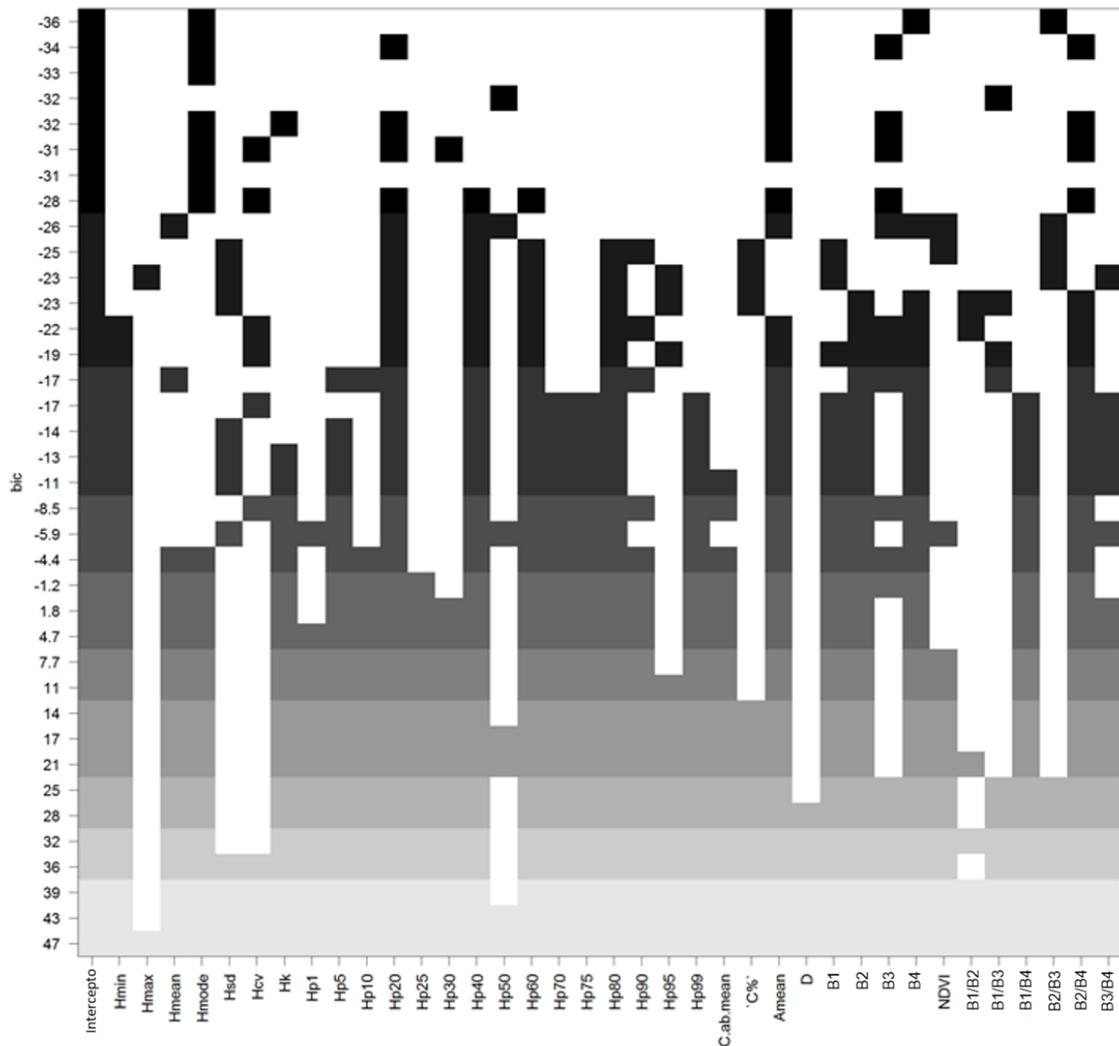


Figura 5.4 - Melhores modelos em diferentes tamanhos, selecionados pela abordagem *Best Subset Selection* ordenados pelo critério BIC, utilizando a integração das variáveis ALS e da imagem aérea. A presença destas variáveis no modelo é indicada pela coloração em tons de cinza.

A escolha do melhor modelo dentre os demonstrados nas Figuras 5.2, 5.3 e 5.4 anteriormente, deu-se por meio da validação cruzada *k-fold*, esta foi responsável pela seleção do modelo com o menor valor de raiz do erro quadrático médio (RMSE). As Figuras 5.5, 5.6 e 5.7, mostram o resultado da validação cruzada *k-fold* ( $k=5$ ), bem como o modelo selecionado por apresentar o menor RMSE.

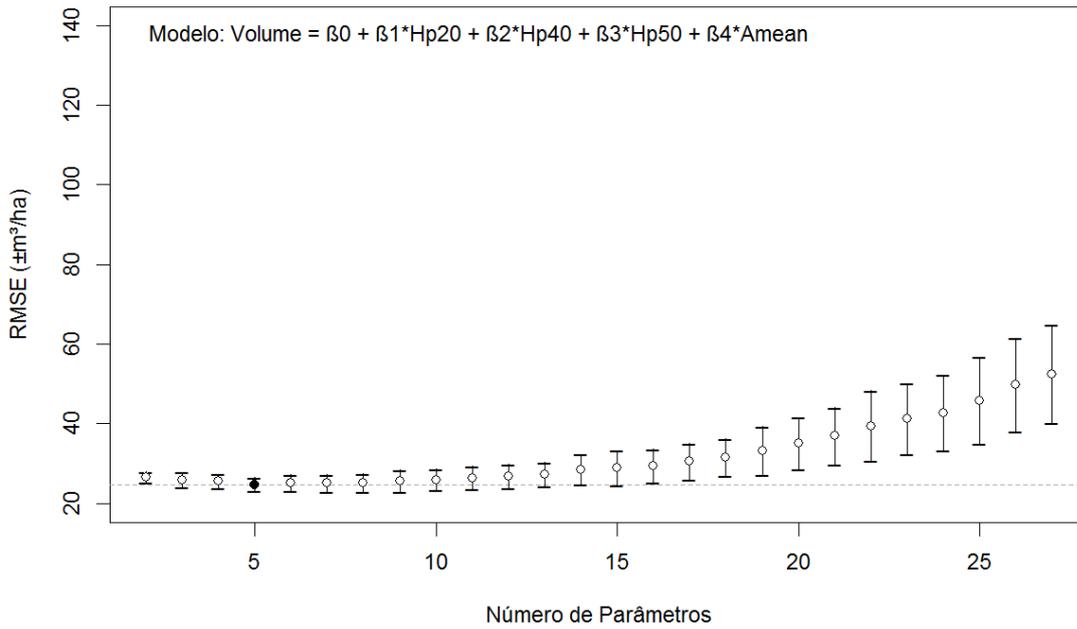


Figura 5.5 - Método de validação cruzada *k-fold* para estimativa da raiz do erro quadrático médio (RMSE) com modelos com diferentes tamanhos utilizando apenas variáveis ALS.

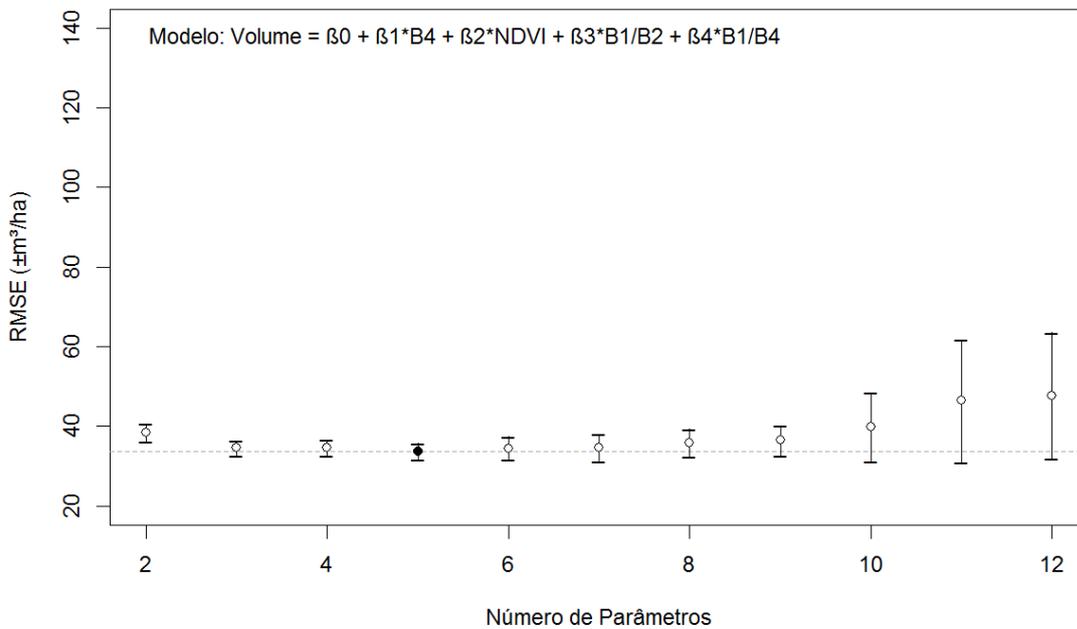


Figura 5.6 - Método de validação cruzada *k-fold* para estimativa da raiz do erro quadrático médio (RMSE) com modelos com diferentes tamanhos utilizando apenas variáveis da imagem.

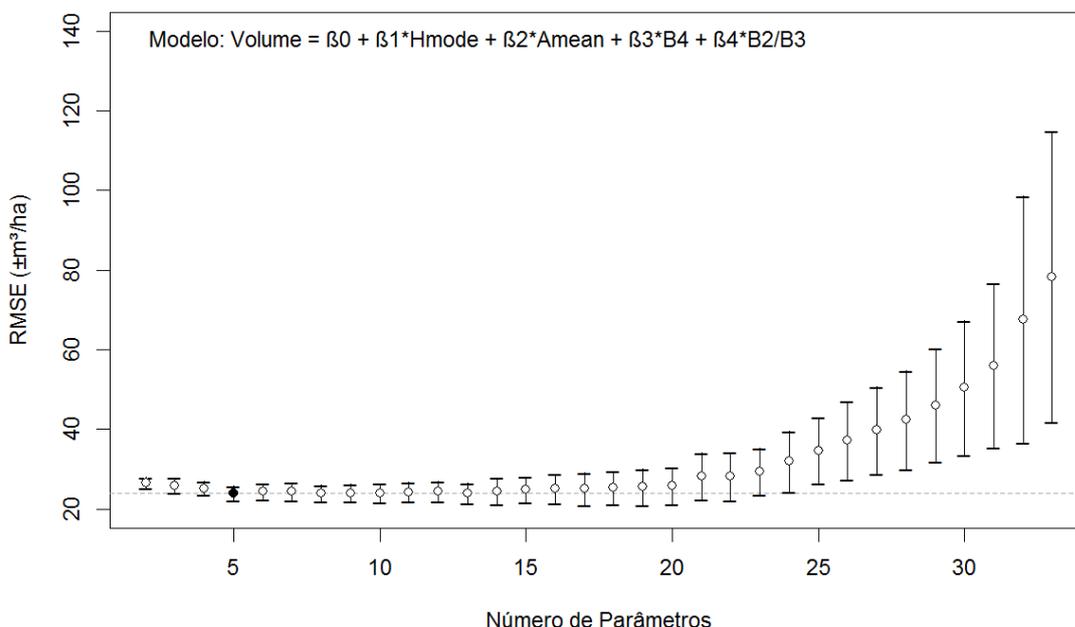


Figura 5.7 - Método de validação cruzada *k-fold* para estimativa da raiz do erro quadrático médio (RMSE) com modelos com diferentes tamanhos utilizando a integração das variáveis ALS e variáveis da imagem.

Conforme os resultados da validação cruzada, para todos os cenários o melhor modelo contou com 5 parâmetros, considerando o intercepto. No primeiro cenário (uso de variáveis de dados ALS), o melhor modelo considerou as variáveis  $H_{p20}$ ,  $H_{p40}$ ,  $H_{p50}$  e  $A_{mean}$ , no segundo cenário as variáveis do modelo escolhido foram  $B_3$ ,  $NDVI$ ,  $B_1/B_3$  e  $B_1/B_4$ . Já no último cenário, que disponibiliza ambas as informações de sensoriamento remoto ao processo de seleção de variáveis, o modelo contou com as variáveis  $H_{mode}$ ,  $A_{mean}$ ,  $B_4$  e  $B_2/B_3$ .

O RMSE em cada cenário foi de 6,84%, 8,45% e 5,23%, respectivamente. Isso demonstra que dentre os três cenários analisados, aquele que combina informações de dados ALS e da imagem, apresentou melhor desempenho, confirmando-se isso também pelo  $R^2$  ajustado para cada cenário. A Tabela 5.1

mostra os coeficientes que compõe o modelo ajustado em cada diferente cenário. Observa-se também que apenas o modelo do terceiro cenário apresentou coeficientes altamente significativos.

Tabela 5.1 – Resumo do ajuste do melhor modelo de regressão linear múltipla em cada um dos cenários. Dentre as variáveis ALS estão: a moda da altura ( $H_{mode}$ ), altura nos percentis 20 ( $H_{p20}$ ), 40 ( $H_{p40}$ ) e 50 ( $H_{p50}$ ) e a altitude média ( $A_{mean}$ ). Com relação as variáveis da imagem estão: a banda do vermelho(B3), o índice de vegetação NDVI, a banda do infravermelho próximo (B4) e a razão entre as bandas: azul pela vermelha (B1/B3), azul pela infravermelho próximo (B1/B4) e a verde pela vermelha (B2/B3).

Cenário	Variáveis	Estimativa	SE	t valor	Pr(> t )	Signif.	R <sup>2</sup> ajustado
<b>Dados ALS</b>	Intercepto	-585,17	186,77	-3,13	0,00328	**	0,65
	$H_{p20}$	22,48	9,74	2,31	0,02630	*	
	$H_{p40}$	-165,27	62,34	-2,65	0,01154	*	
	$H_{p50}$	170,09	55,08	3,09	0,00370	**	
	$A_{mean}$	0,22	0,10	2,22	0,03224	*	
<b>Dados da imagem aérea</b>	Intercepto	-8313,82	3429,58	-2,42	0,0201	*	0,48
	B3	7,86	1,81	4,33	9,98x10 <sup>-5</sup>	***	
	NDVI	16167,59	6402,97	2,52	0,0157	*	
	B1/B3	-5101,24	1971,56	-2,59	0,0135	*	
<b>Dados ALS e dados da imagem aérea</b>	B1/B4	15192,16	6464,70	2,35	0,0239	*	0,79
	Intercepto	-378,52	146,28	-2,59	0,01351	*	
	$H_{mode}$	20,96	2,92	7,18	1,2x10 <sup>-8</sup>	***	
	$A_{mean}$	0,20	0,07	2,76	0,00886	**	
	B4	1,93	0,45	4,30	0,00011	***	
	B2/B3	-368,96	70,08	-5,27	5,41x10 <sup>-6</sup>	***	

SE: Erro padrão; Signif.=Significância: '\*\*\*', '\*\*', '\*', equivalente à 0,001, 0,01 e 0,05.

### 5.1.2. Verificação de pressuposições e predição volumétrica

A análise gráfica dos ajustes em cada cenário pode ser observada nas Figuras 5.8, 5.9 e 5.10. As relações entre os valores de volume observado e volume predito refletiram, de certo modo, coerência e exatidão (5.8 A, 5.9 A, e 5.10 A), estando a nuvem de pontos dispersa ao longo da linha  $y=x$ .

No que diz respeito à análise dos resíduos, observa-se pelas Figuras 5.8 B, 5.9 B, e 5.10 B, que todos os cenários apresentaram homocedasticidade, enquanto que na verificação de normalidade dos resíduos nas Figuras 5.8 à 5.10, C e D, verificou-se que os cenários 1 e 2 apresentaram distribuições assimétricas, sugerindo a falta de normalidade, enquanto que o cenário 3, tais pressuposições demonstram-se claramente atendidas.

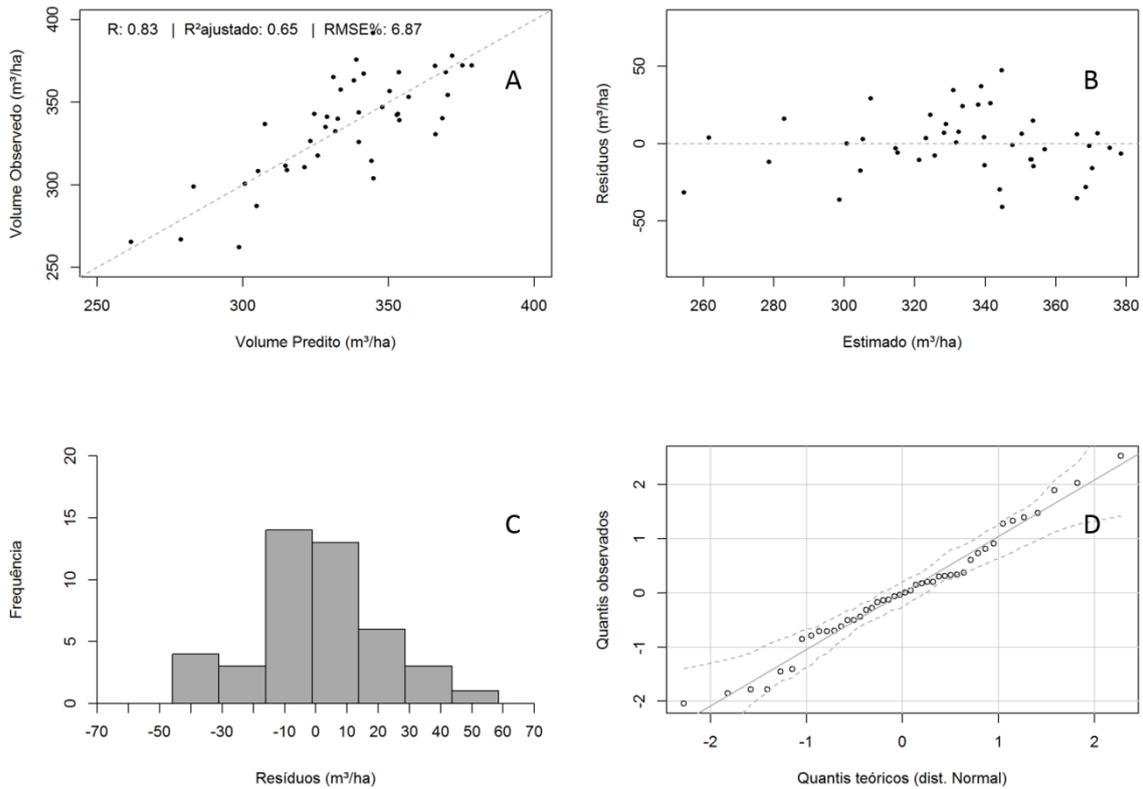


Figura 5.8 - Análise gráfica de ajuste com base no cenário de apenas variáveis ALS. (A) relação do volume predito em função do valor observado, (B) dispersão dos resíduos, (C) histograma dos resíduos e (D) quantis observados em função dos quantis teóricos.

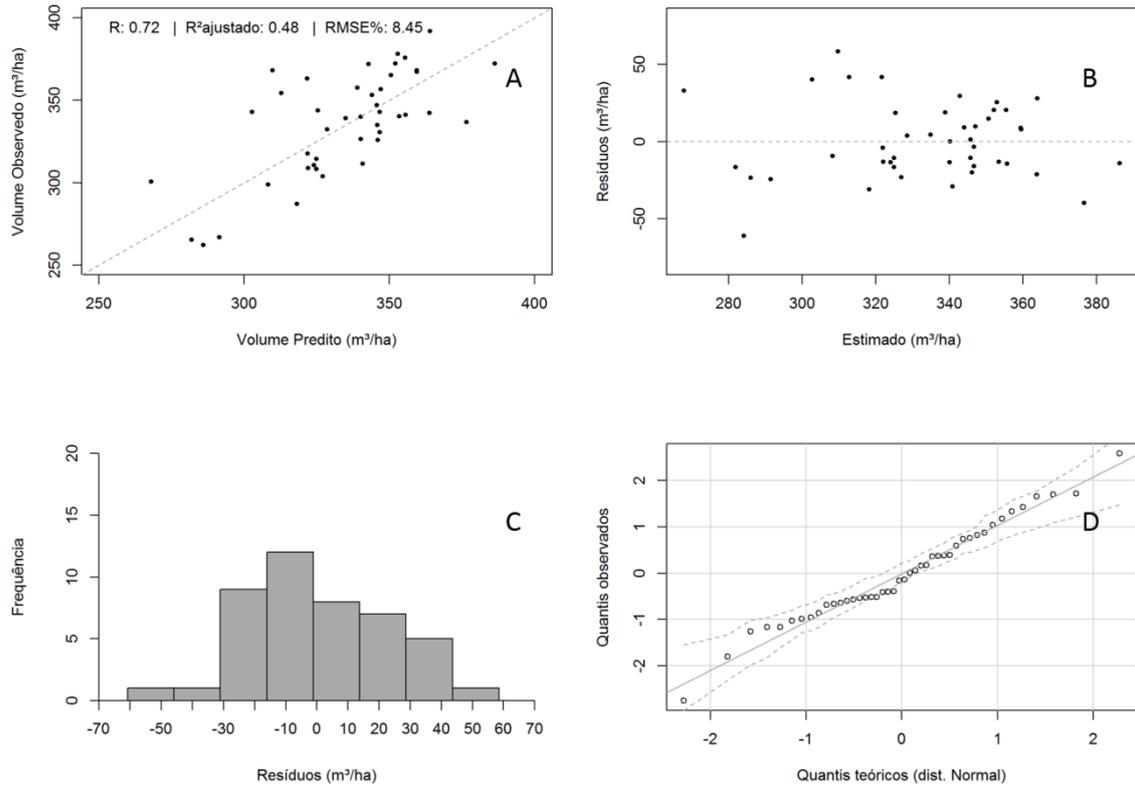


Figura 5.9 - Análise gráfica de ajuste com base no cenário de apenas variáveis da imagem multiespectral. (A) relação do volume predito em função do valor observado, (B) dispersão dos resíduos, (C) histograma dos resíduos e (D) quantis observados em função dos quantis teóricos.

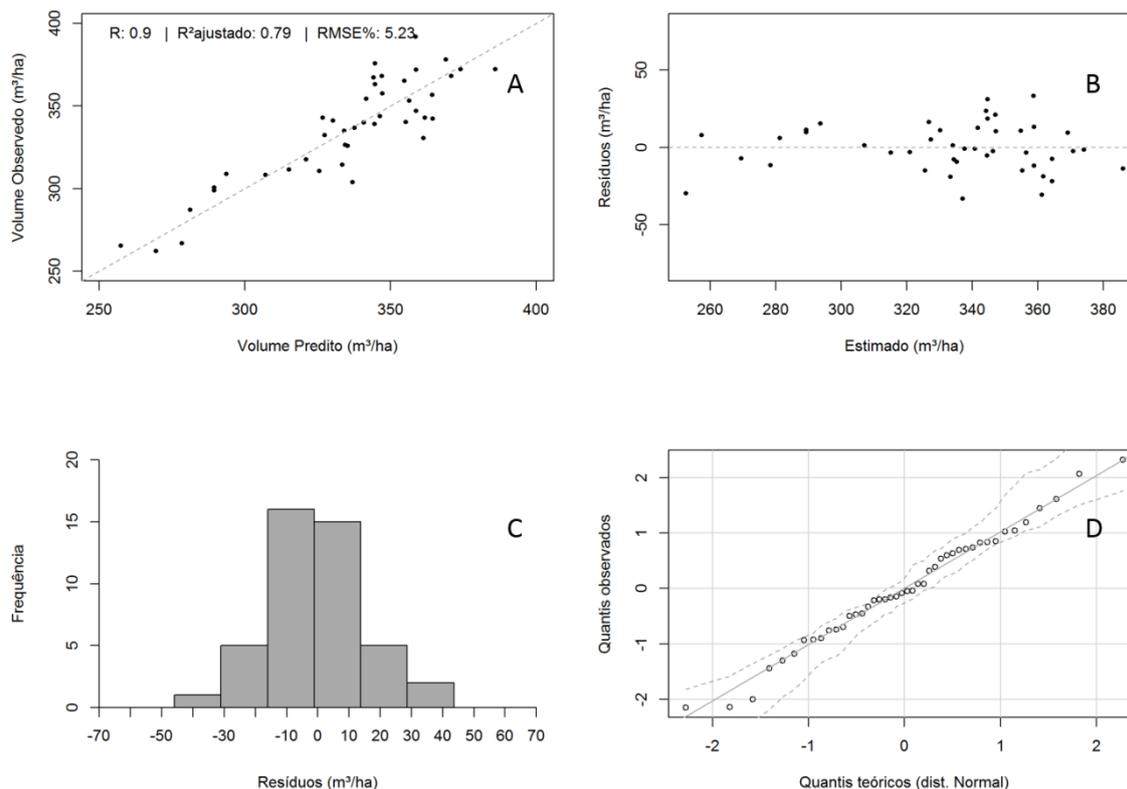


Figura 5.10 - Análise gráfica de ajuste com base no cenário de integração das variáveis ALS e variáveis da imagem. (A) relação volume predito em função do valor observado, (B) dispersão dos resíduos, (C) histograma dos resíduos e (D) quantis observados em função dos quantis teóricos.

Da mesma forma, a verificação global das pressuposições do ajuste realizada pela função “*gvlma*” no software R (PEÑA; SLATE, 2014; DALGAARD, 2008; R DEVELOPMENT CORE TEAM, 2015), mostraram-se atendidas no cenário 2 e 3, enquanto que no cenário, conforme mostra a Tabela 5.2, para pelo menos uma das variáveis predictoras, a pressuposição de linearidade foi rejeitada, ao nível de significância de 5%.

Sendo assim, com base nas análises gráficas, na verificação de pressuposições e nos valores de bondade de ajuste, tais como o valor de RMSE e de  $R^2$  ajustado, verificou-se que o melhor cenário dentre os 3 analisados, consiste naquele que faz a integração dos dados ALS e imagem para estimativa do volume de madeira. Desta forma, selecionou-se tal cenário para predição volumétrica em área total e conseqüentes comparações com o volume de inventário e volume posto-fábrica.

Tabela 5.2 – Verificação das pressuposições do ajuste em diferentes cenários. Valores de p-valor > 0,05, aceita-se a hipótese.

<b>Cenário</b>	<b>Pressupostos</b>	<b>Valor</b>	<b>p-valor</b>	<b>Decisão</b>
<b>Dados ALS</b>	Qualidade Global	4,75	0,31	Aceita
	Assimetria	0,06	0,81	Aceita
	Curtose	0,05	0,82	Aceita
	Linearidade	4,63	0,03	Rejeitada
	Homocedasticidade	0,01	0,91	Aceita
<b>Dados da imagem aérea</b>	Qualidade Global	3.35	0,50	Aceita
	Assimetria	0,27	0,60	Aceita
	Curtose	0,03	0,86	Aceita
	Linearidade	1,42	0,23	Aceita
	Homocedasticidade	1,63	0,20	Aceita
<b>Dados ALS e dados da imagem aérea</b>	Qualidade Global	3.23	0,52	Aceita
	Assimetria	0,03	0,87	Aceita
	Curtose	0,18	0,67	Aceita
	Linearidade	3,01	0,08	Aceita
	Homocedasticidade	0,01	0,90	Aceita

Após a predição em área total (Figura 5.11), observou-se um volume médio por hectare de 319,9 m<sup>3</sup>, totalizando assim, 44.466,1 m<sup>3</sup> de estoque de madeira em área total. Ao se comparar este resultado com o volume mensurado na fábrica (considerado o volume real da área pela empresa), o método ABA o subestimou em 2,98%, enquanto o inventário florestal, utilizando o estimador da amostragem aleatória simples (sem a utilização de dados de sensoriamento remoto), o superestimou em 3,29%. A Figura 5.12 mostra a comparação do volume (m<sup>3</sup>) estimado pelos diferentes métodos.

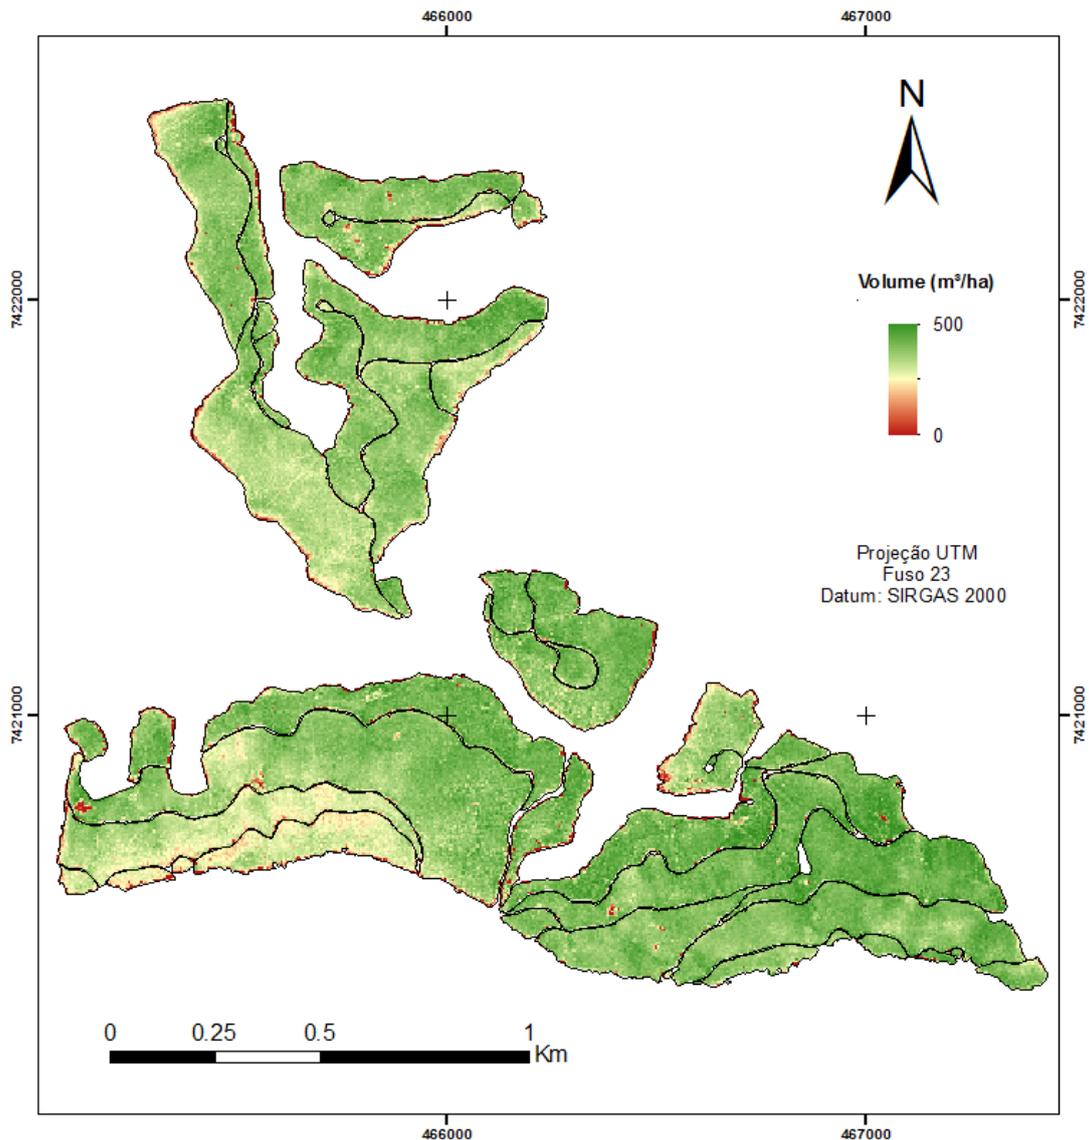


Figura 5.11 – Volume de madeira estimado em área total em m<sup>3</sup> por hectare.

A integração dos dados ALS e da imagem permitiram melhor caracterização da floresta. Ao se utilizar ambos os dados de sensoriamento remoto no modelo preditivo de volume, o mapa final de volume de madeira, segundo a abordagem ABA, confere características verticais e horizontais da floresta, sendo possível identificar com maiores detalhes, até mesmo, a sanidade da mesma. A Figura 5.13 mostra as falhas e mortalidades da floresta segundo as perspectivas dos dados ALS e da imagem e como a integração destes resultou na detecção de características tais como a seca, onde somente o uso de dados ALS não a detectaria.

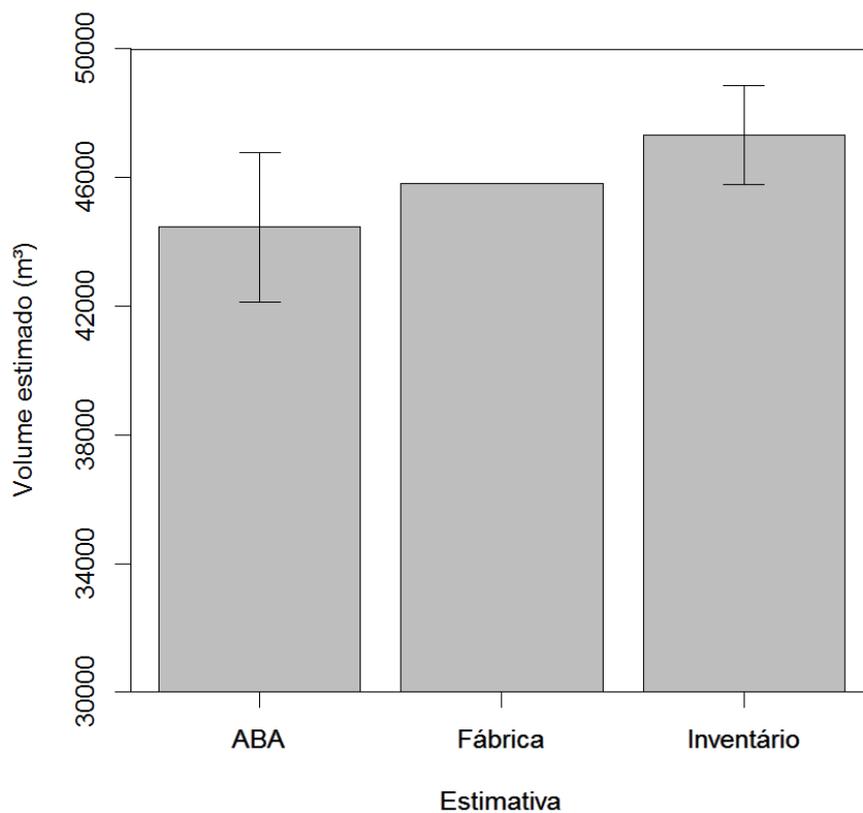


Figura 5.12 – Comparação entre o volume de madeira (m<sup>3</sup>) estimado pelo presente método (ABA utilizando informações ALS e da imagem), pela fábrica e pelo inventário (Amostragem Casual Simples), com seus respectivos intervalos de confiança.

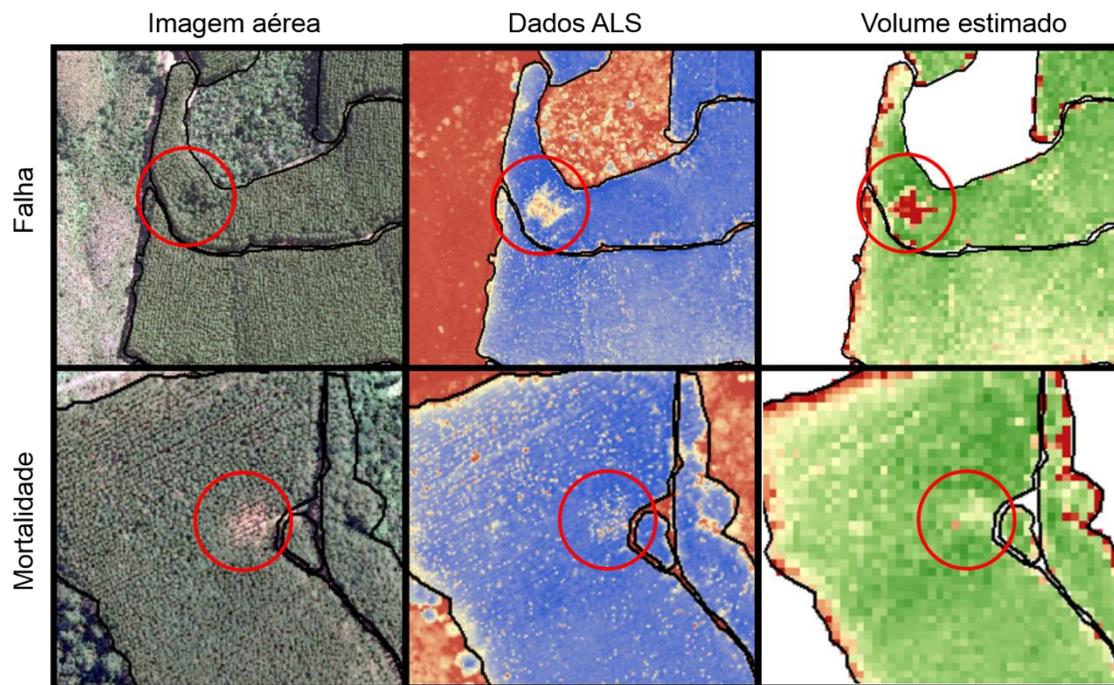


Figura 4.13 – Comparação da imagem aérea, LiDAR e volume estimado pela integração de ambos os dados, ressaltando área com falha e mortalidade.

## 5.2. Volume Individual por Árvore (ITD)

A Figura 5.14 mostra a detecção das árvores individuais com base nas imagens aéreas, por meio da filtragem da máxima local (ITD), enquanto que a Figura 5.15 mostra a agregação da detecção de árvores na célula *grid* de 5 m x 5 m (ABA) para a área total.

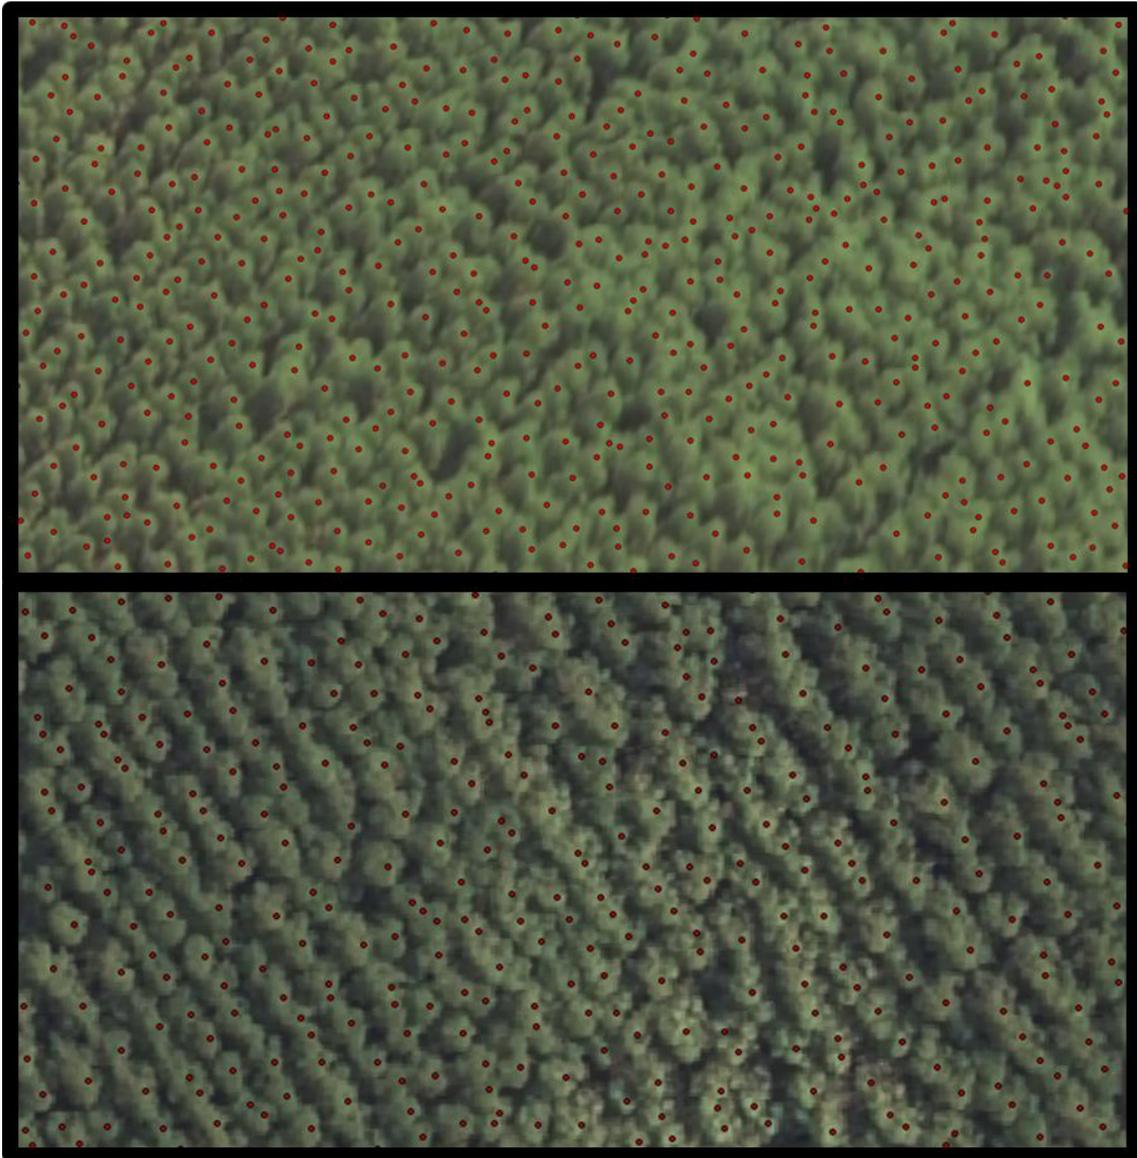


Figura 5.14 – Detecção Individual da Árvore (ITD) com base na filtragem da máxima local na área de estudo.

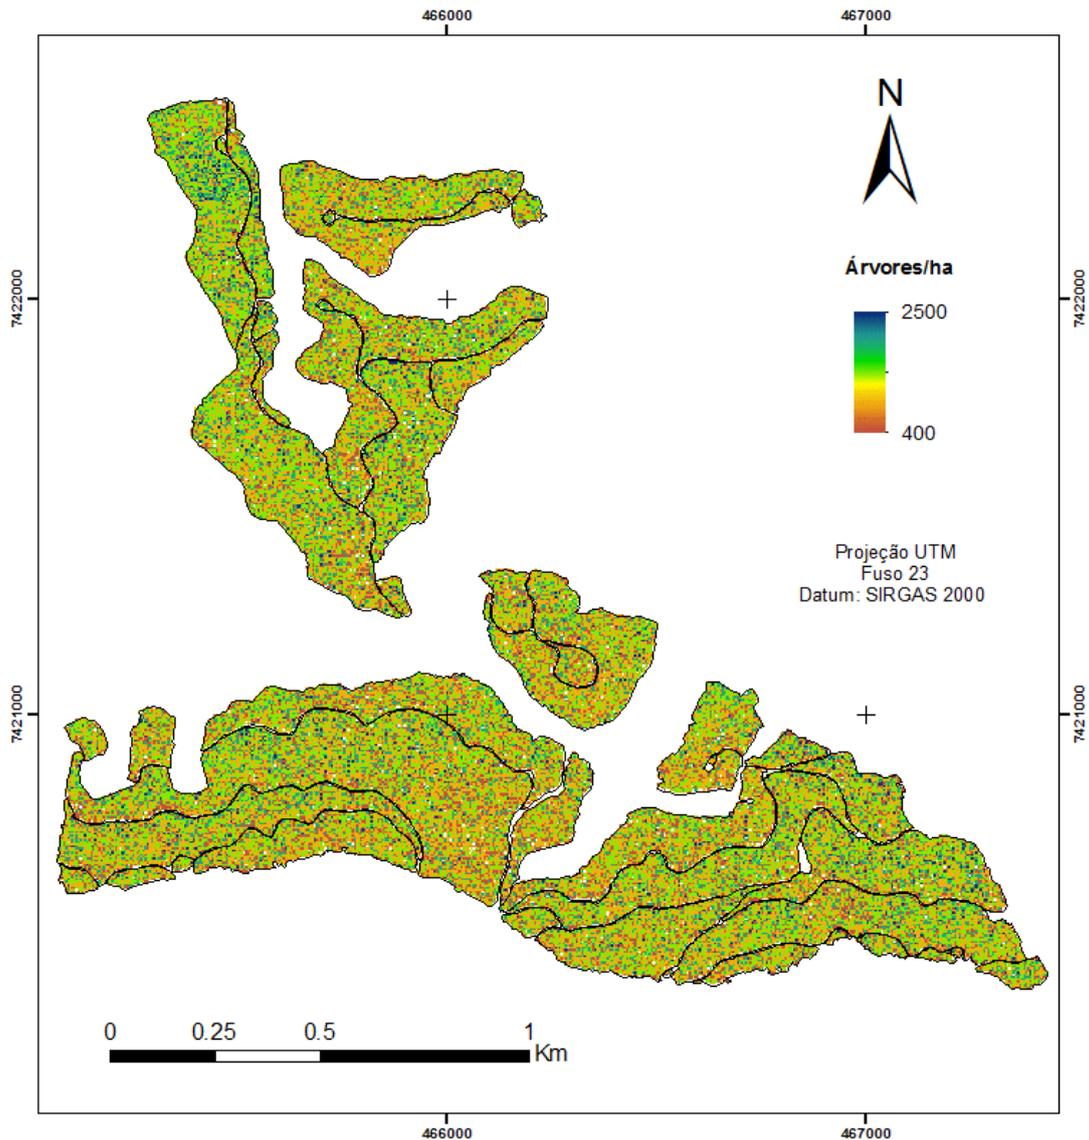


Figura 5.15 – Número de árvores por hectare segundo detecção ITD-ABA.

O número de árvores detectadas, foi de 151.048 árvores na área total, e o número médio de árvores detectadas foi equivalente a 994 árvores por hectare. Dessa forma, ao comparar com o número médio de árvores por hectare estimado pelo inventário florestal (1708 árvores por hectare) verificou-se que aproximadamente 42% das árvores não foram detectadas, ressaltando a necessidade de se corrigir esta detecção.

### 5.2.1. Modelagem do Erro de detecção das árvores

Teoricamente a correção do erro poderia ser feita identificando o erro médio das parcelas e atribuindo este erro médio para cada célula *grid*, obtendo-se assim, um fator de correção da detecção em área total. Entretanto, observou-se que o erro na detecção é influenciado pela declividade do terreno (Figura 5.16), o que provoca um maior viés em áreas mais declivosas. Tal circunstância impediu a correção do erro da metodologia ITD e ABA por meio de um simples fator de correção em função da média, exigindo então a modelagem deste erro por meio de variáveis preditoras (VASTARANTA et al., 2011).

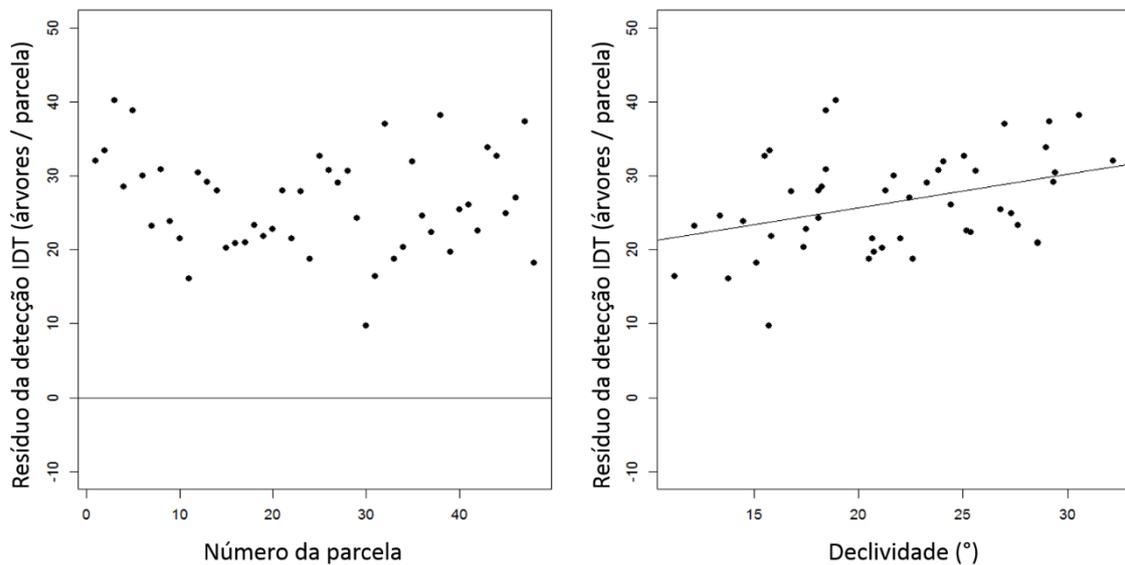


Figura 5.16 – Resíduo da detecção das árvores por parcela e conforme a declividade do terreno (°).

A Figura 5.17 mostra os resultados da abordagem *Best Subset Selection* utilizando o critério BIC na identificação do melhor modelo em seus diferentes tamanhos (número máximo de 4 variáveis).

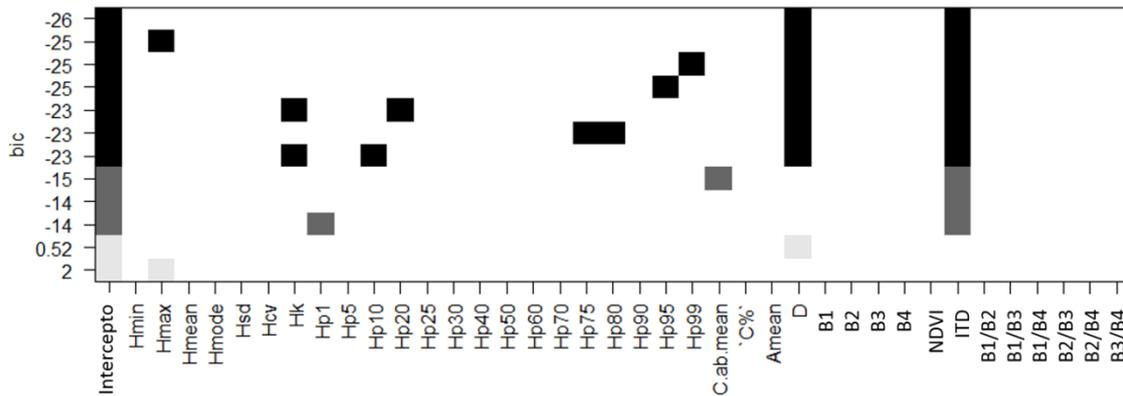


Figura 5.17 - Melhores modelos em diferentes tamanhos, selecionados pela abordagem *Best Subset Selection* ordenados pelo critério BIC. A presença destas variáveis no modelo é indicada pela coloração em tons de cinza.

Em seguida, por meio da validação cruzada *k-fold* ( $k=5$ ), identificou-se o melhor modelo dentre os modelos candidatos, conforme indicado pela Figura 5.18.

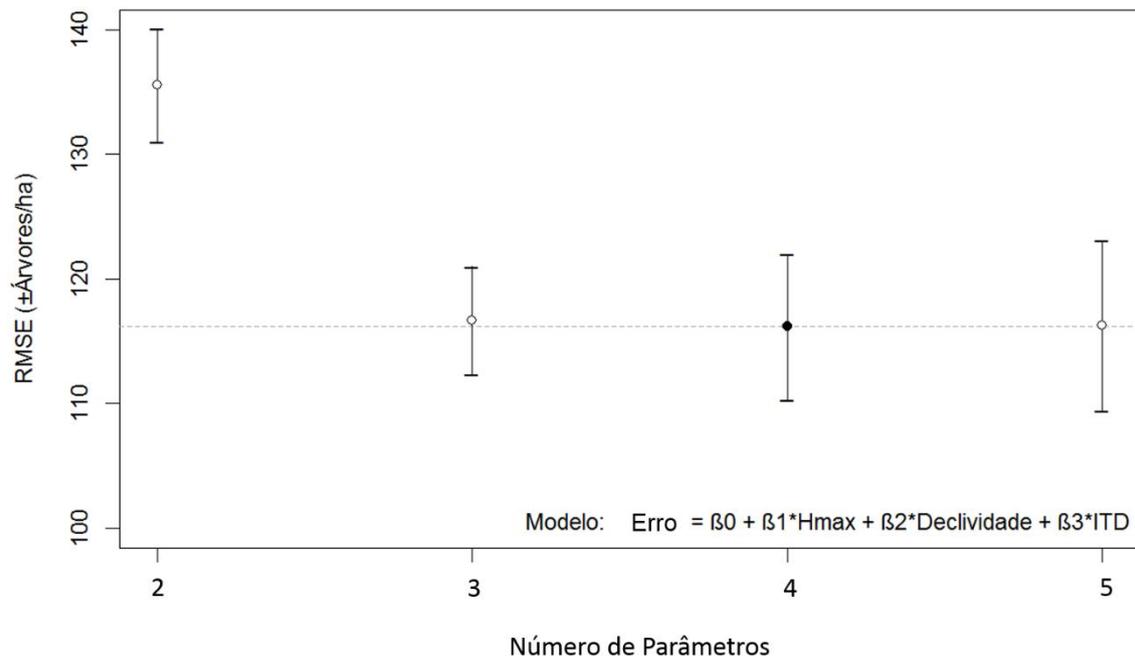


Figura 5.18 - Método de validação cruzada *k-fold* para estimativa da raiz do erro quadrático médio (RMSE) com modelos com diferentes tamanhos, e intervalos de confiança obtidos em 1000 simulações.

Após a identificação do melhor modelo preditivo do erro, foi realizado o ajuste linear do mesmo pelo método dos mínimos quadrados, o modelo selecionado utilizou 3 variáveis, sendo estas a altura máxima ( $h_{max}$ ) e a declividade ( $D$ )

estimada por dados ALS, bem como a detecção das árvores em imagem aérea segundo a abordagem ITD-ABA, cujo RMSE foi de 12,66%. A Tabela 5.3 mostra o coeficiente do ajuste deste modelo.

Tabela 5.3 – Resumo do ajuste do melhor modelo de regressão linear múltipla para estimativa do erro de detecção. Utilizando as variáveis altura máxima ( $h_{max}$ ) e a Declividade ( $D$ ) e detecção individual das árvores ITD e ABA.

Modelo	Variáveis	Estimativa	SE	t valor	Pr(> t )	Signif.	R <sup>2</sup> ajustado
Erro	Intercepto	982,70	269,15	3,45	0,00136	**	0,75
	$h_{max}$	13,73	7,92	1,73	0,09076	.	
	D	13,95	2,19	6,37	1,61x10 <sup>-7</sup>	***	
	ITD	-22,45	2,59	-8,67	1,22x10 <sup>-10</sup>	***	

SE: Erro padrão; Signif.=Significância: '\*\*\*', '\*\*', '\*', '.', equivalente à 0,001, 0,01, 0,05 e 0,1.

Após essa etapa, verificou-se a conformidade das pressuposições dos modelos lineares por meio da análise gráfica e estatística, utilizando o pacote “*gvlma*” de Peña e Slate (2014). Com relação à análise gráfica do ajuste, esta pode ser observada na Figura 5.19, enquanto os resultados da validação de pressuposições podem ser observados na Tabela 5.4.

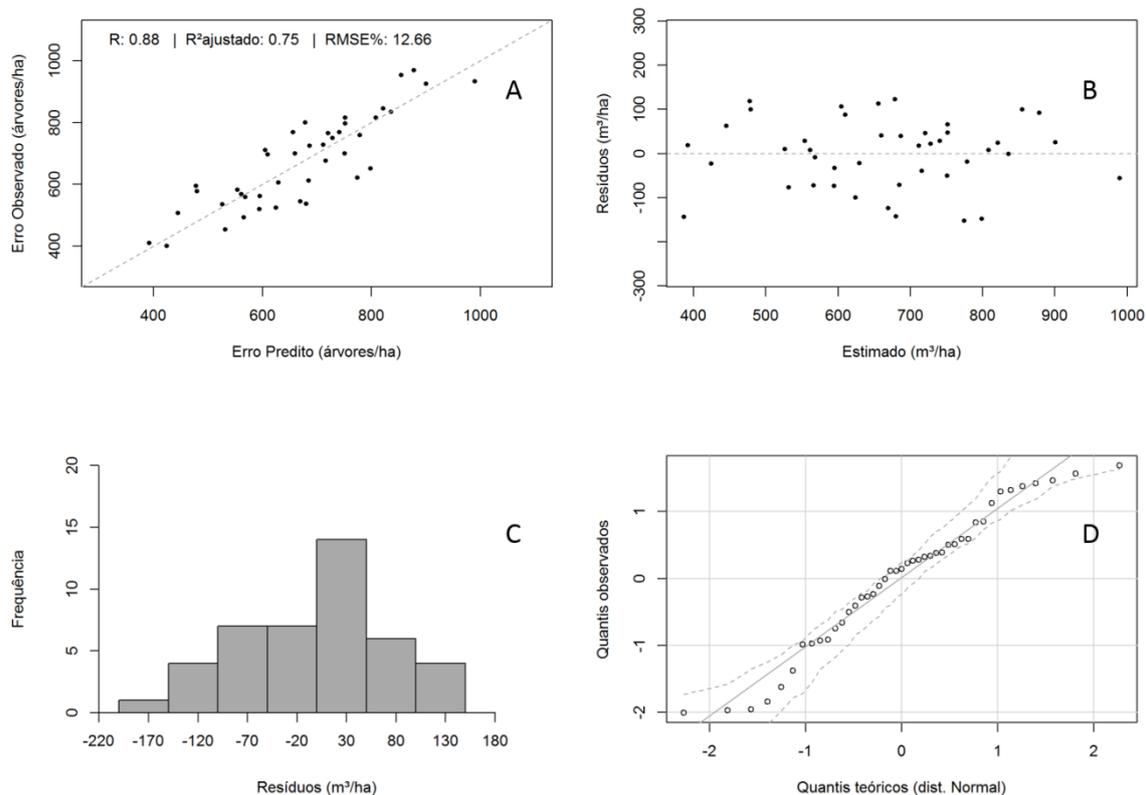


Figura 5.19 - Análise gráfica de ajuste, sendo (A) relação valor predito em função do valor observado, (B) dispersão dos resíduos, (C) histograma dos resíduos e (D) quantis observados em função dos quantis teóricos.

As relações entre os valores do erro observado e do erro predito refletiram de certo modo coerência e exatidão (5.19 A), estando a nuvem de pontos dispersa ao longo da linha  $y=x$ , indicando a existência de linearidade entre variáveis preditivas e variáveis preditoras. No que diz respeito à análise dos resíduos, observa-se pelas Figuras 5.19 B, que estes apresentaram homocedasticidade, enquanto que na verificação de normalidade dos resíduos nas Figuras 5.19 C e 5.19 D, verificou-se que apresentaram distribuições normais.

Tabela 5.4 – Verificação das pressuposições do ajuste do erro. Valores de  $p\text{-valor} > 0,05$ , aceita-se a hipótese.

Modelo	Pressupostos	Valor	p-valor	Decisão
Erro	Qualidade Global	1,74	0,78	Aceita
	Assimetria	0,83	0,36	Aceita
	Curtose	0,87	0,35	Aceita
	Linearidade	0,02	0,90	Aceita
	Homocedasticidade	0,02	0,88	Aceita

A Figura 5.20 mostra o mapa de predição do erro da abordagem ITD e ABA (semi-ITD). Já a Figura 5.21 mostra o mapa final de contagem de árvores por hectare após a correção, ou seja, tal mapa representa a somatória das Figuras 5.15 e 5.20.

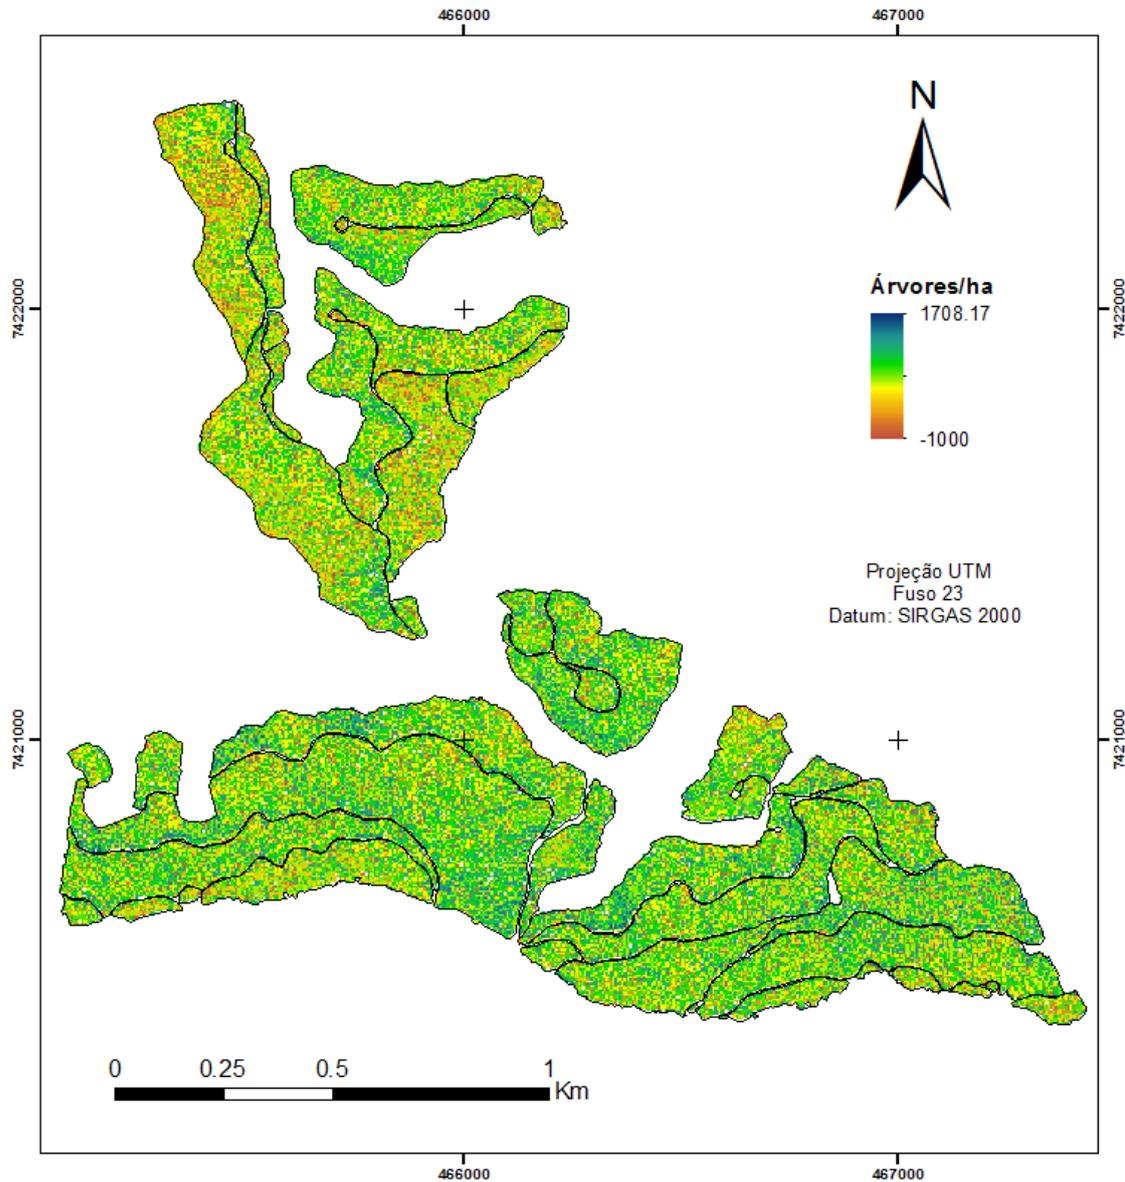


Figura 5.20 – Predição do erro em área total na detecção das árvores por hectare, segundo a abordagem ABA.

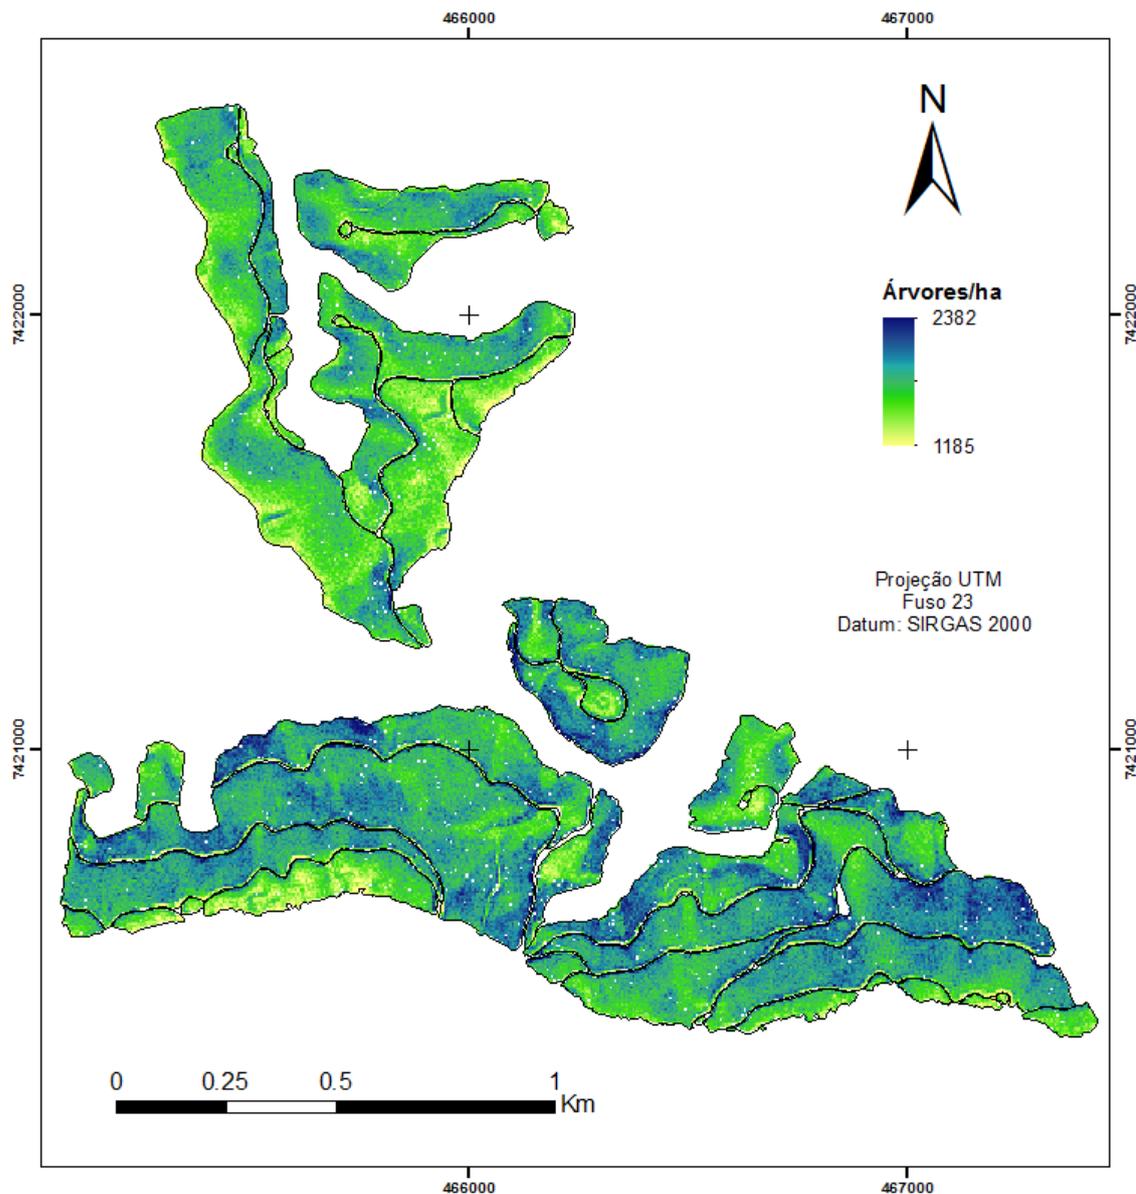


Figura 5.21 – Estimativa do número de árvores por hectare.

O número médio de árvores detectado na área total, pelo método ITD e ABA, ou semi-ITD, após a correção do erro foi de 1707,7 árvores por hectare, já pelo inventário foi de 1708,3 árvores por hectare. Desta maneira, o volume médio por árvore detectado neste trabalho foi de 0,188 m<sup>3</sup>, enquanto que o volume individual do inventário florestal foi de 0,195 m<sup>3</sup>. A Figura 5.22 mostra o volume de árvores em área total gerado neste trabalho.

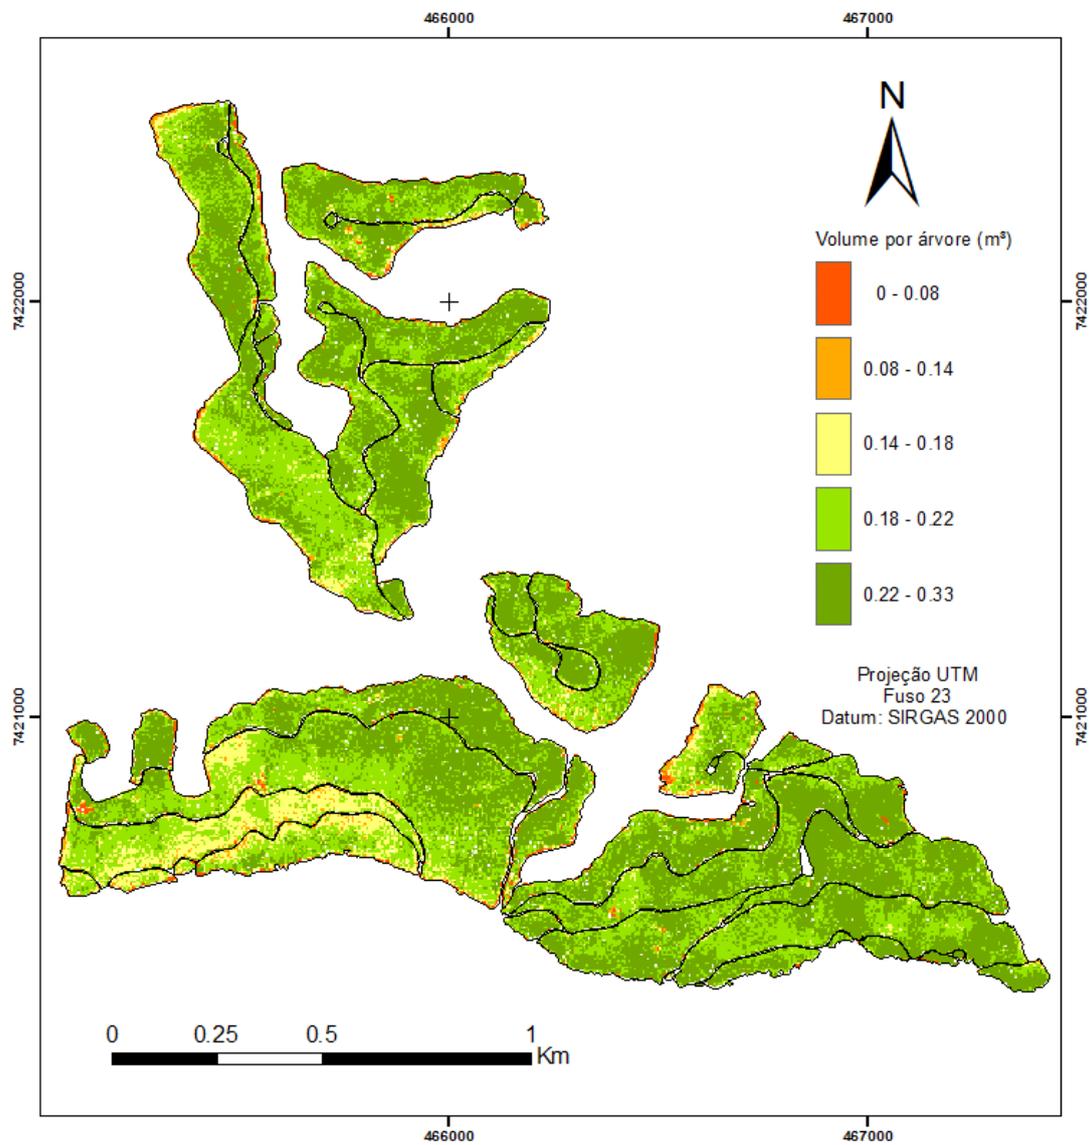


Figura 5.22 – Classificação do volume por árvore.



## 6 DISCUSSÃO

As estimativas exatas, dos atributos florestais, são consideradas críticas para o planejamento florestal, devido ao rápido crescimento das árvores. Para o manejo adequado das plantações florestais, informações individuais das árvores são consideradas de grande valor (SIMÕES, 2008). Neste sentido, o sensoriamento remoto tem provado ser uma excelente ferramenta no suporte ao manejo florestal (WULDER et al., 2000), contudo, a obtenção de estimativas com menor erro possível, são cada vez mais desafiadoras (SAARELA et al., 2014).

Neste estudo, foram utilizadas duas abordagens para estimar o volume em plantações de *Eucalyptus* spp. utilizando dados ALS e imagens multiespectrais com alta resolução espacial. Primeiramente, foi feita a modelagem do volume em área total utilizando a ABA, em diferentes combinações de dados de sensoriamento remoto, gerando três diferentes cenários. Em seguida, foi feito a contagem das árvores segundo a abordagem ITD, introduzindo o método de correção para melhoria das estimativas de volume. Então, esta estimativa foi integrada à informação do volume, predito anteriormente com a ABA, obtendo-se a média do volume das árvores.

Os resultados atingidos, indicaram que a combinação de dados de sensoriamento remoto passivo e ativo, mostraram bom desempenho na estimativa do volume total de madeira (RMSE = 5,23%). Apesar da ABA ter subestimado o volume (2,98%), os resultados aqui alcançados foram muito próximos ao volume de referência (madeira entregue à fábrica). O modelo aplicado na estimativa volumétrica utilizou dois parâmetros derivados da imagem, a banda do infravermelho próximo ( $B4$ ) e a razão entre bandas ( $B2/B3$ ), e outros dois parâmetros, derivados da altura ( $h_{mode}$ ) e da cobertura ( $A_{mean}$ ) de dados ALS.

A reflectância na banda do infravermelho próximo, está ligada ao espalhamento pelo mesófilo, que ocorre devido à interação da radiação solar com a estrutura interna das folhas (CAMPBELL; WYNNE, 2011). Por outro lado, a razão das

bandas verde e vermelha, têm o mesmo conceito da razão das bandas infravermelho próximo e vermelho, ou seja, a luz vermelha é absorvida pela clorofila e refletida pelos tecidos mesofílicos, como radiação verde (CAMPBELL; WYNNE, 2011). Desta forma, a razão entre estas bandas evidencia o vigor vegetativo e a abundância vegetativa. Ambas estas informações são complementares às métricas ALS.

A aplicação de modelos preditivos utilizando dados ALS apenas, já está relativamente concretizada e apresenta respostas próximas à realidade (PACKALÉN et al, 2011). De modo geral, conforme White et al. (2013), os modelos preditivos mais comuns, são aqueles que envolvem a variação de altura e de cobertura de dados ALS. Neste estudo, embora o primeiro cenário (utilizando apenas dados ALS) não tenha atendido as exigências de linearidade, seu desempenho foi muito próximo ao do melhor modelo, cenário 3 (integração dos dados). Esta questão poderia ser solucionada por meio da transformação das variáveis preditoras, como realizado por Saarela et al. (2014). Com relação ao segundo cenário (utilizando variáveis da imagem), apesar do uso de dados de alta resolução espacial, houve pior desempenho entre os cenários (RMSE = 8,45%).

Desta forma, o uso individual dessas informações pode suprir a necessidade preditiva, caso as exigências de precisão e exatidão forem abrandadas. Contudo, ressalta-se que na disponibilidade de ambas as informações, a integração destas, assim como mostrado neste estudo, produzirá melhores resultados. Mesmo em situações onde a diferença temporal entre a aquisição dos dados (2012) e a mensuração de campo (2013), é de até um ano, assim como observado no trabalho. Uma vez que as aquisições ALS podem ser custosas, a utilização de dados com diferença temporal permite uma maior longevidade das informações adquiridas, reduzindo assim os custos na frequência de aquisição.

No Brasil, Packalén et al. (2011) aplicaram a abordagem ABA utilizando uma janela de 15 m x 15 m em plantios de eucalipto pouco adensados (833 árvores por hectare) no Sul da Bahia. Os autores utilizaram apenas dados ALS para

modelar o índice de sítio e estimar o volume de madeira em área total. As variáveis utilizadas pelos autores foram  $h_{p90}$ ,  $h_{p95}$  e  $h_{mean}$ , obtendo-se assim um valor de RMSE de 8,2%.

Canavesi et al. (2010) utilizaram variáveis de imagens hiperespectrais do sensor Hyperion EO-1 e dados SRTM na predição volumétrica em plantios eucalipto na região de Capão Bonito (SP), considerando as diferentes classes de iluminações do terreno, sendo observados melhores ajustes em regiões escuras ( $R^2$  ajustado = 0,72). Entretanto, ao se considerar todas as classes de iluminação, os autores obtiveram uma superestimativa mediana de 209 m<sup>3</sup>/ha ao se comparar com o volume das parcelas.

Saarela et al. (2015) utilizaram a integração de dados ALS e imagens Landsat com intuito de aumentar a precisão da estimativa de volume de madeira em plantios de *Pinus sylvestris*. Os autores verificaram que a integração das variáveis de ambos os dados de sensoriamento remoto permitiu melhor desempenho (RMSE = 27%), quando comparado com estimativas de variáveis ALS (RMSE = 30%) e da imagem (RMSE = 85%) apenas. Entretanto o modelo preditivo utilizado pelos autores contou com 12 variáveis preditoras, sendo estas: a raiz quadrada das bandas do satélite Landsat (banda 1 à banda 7), a altura média em dados ALS, bem como os percentis 75, 80 e 90, além do número de pontos acima de 2 metros (SAARELA et al., 2015).

Enquanto a ABA providencia estimativas de volume de madeira em área total, o delineamento de árvores individuais, detectadas pelas imagens, permite diminuir a escala das estimativas, atingindo o nível de árvore. Sendo assim, mesmo de posse de ambos os dados de sensoriamento remoto, neste trabalho, optou-se apenas pelo uso das imagens aéreas, pois estas agregam toda a radiação em um pixel, a qual faz com que a interpolação seja mais fácil. Ainda, a obtenção de dados ALS, obtida por pulsos, pode não atingir exatamente o topo das árvores, requerendo-se, dessa forma, um aumento na densidade de pontos (PACKALÉN et al., 2011).

Os algoritmos que detectam árvores individuais têm mostrado boa performance, com exatidão típica de 70% (PERSSON et al., 2002). Koukoulas e Blackburn (2005) compararam o resultado da detecção individual das árvores por dados LiDAR e pela imagem multiespectral em plantações florestais, obtendo bom desempenho no uso de ambas as informações de sensoriamento remoto na detecção das árvores individuais, sendo detectadas 80% das árvores totais utilizando LiDAR e 91% destas, utilizando a imagem.

Contudo, com a utilização de tais métodos de maneira automática, algumas árvores podem não ser detectadas, interferindo assim na predição de parâmetros da floresta de interesse em inventários florestais (BREIDENBACH; ASTRUP, 2014). Vastaranta et al. (2011) investigando a predição de parâmetros florestais utilizando a abordagem ITD, verificaram que dentre as diferentes fontes de erro durante o processo de predição, os erros mais significativos estão relacionados a detecção de árvores individuais e não ao processo de modelagem e predição.

Assim como levantado por Breidenbach e Astrup (2014), quando não há a detecção exata de todas as árvores, por não terem sido detectadas na abordagem ITD, o pressuposto de que cada árvore detectada corresponde a uma de campo, é abandonado. Para tanto, sugere-se converter a detecção ITD na abordagem ABA (semi-ITD). Com isto, apesar da perda da informação x e y de cada árvore neste processo, pôde-se corrigir os desvios da detecção das árvores, obtendo-se a correta estimativa do número de árvores em cada célula grid, a qual é uma variável importante na contribuição da estimativa de parâmetros florestais.

A exatidão obtida da detecção das árvores, neste estudo, não foi satisfatória para desempenhar tal operação, fazendo-se necessário um fator correção. Esta correção, baseada na declividade e em outras variáveis, permitiu aumentar a exatidão e atingir uma estimativa de volume de árvores individuais com erro muito pequeno. Notou-se também, que com o aumento da declividade uma maior agregação das copas, uma vez que, do ponto de vista das imagens, um número maior de árvores ocorre em uma mesma área projetada.

Koch et al. (2006) estudando os fatores que causam erros na detecção ITD, concluíram que a presença de copas muito homogêneas e adensadas podem dificultar na detecção das árvores. Segundo Wang et al. (2004), o processo de escolha dos filtros é uma etapa fundamental no uso da abordagem ITD. Sendo assim, muitos testes devem ser realizados até se encontrar a configuração ideal para detecção do objeto de interesse. Dessa forma, os autores afirmam, ainda, que atingir a configuração ideal dos filtros é um processo muito difícil, pois, uma vez que os filtros podem salientar a reflectância do centro de algumas árvores na imagem, os mesmos podem suavizá-los dada a diversidade de tamanho dos objetos, ângulo de captura da imagem e sombreamento.

De modo geral, o procedimento de correção aplicada na estimativa de contagem das árvores, mostrou bom desempenho, atingindo um erro muito pequeno e com baixo RMSE (12,66%). Este procedimento corrigiu em média 713,7 árvores por hectare, somando-se estas àquelas detectadas pelo método ITD, na imagem de alta resolução espacial. A estimativa final obtida pela divisão entre a predição volumétrica por hectare (ABA) e a predição do número de árvores por hectare (ITD e ABA) foi de 0,188 m<sup>3</sup> por árvore. Tal informação é interessante para o planejamento da colheita, em casos de plantios para celulose e papel, e para o planejamento de desbastes de madeira, em casos de plantios para serraria (SIMÕES, 2008; PACKALÉN et al., 2011).



## **7 CONCLUSÃO**

Informações exatas sobre o volume de madeira em área total e a nível individual das árvores são requeridos para auxiliar no manejo de florestas plantadas. A integração das informações geométricas e espectrais providenciadas por dados ALS e pelas imagens multiespectrais com alta resolução espacial, respectivamente, permitiram a estimativa confiável do volume em ambos os níveis mencionados anteriormente, à um erro muito pequeno. Este estudo reforça os trabalhos já existentes nas áreas de sensoriamento remoto e LiDAR, demonstrando à aplicação de tal conhecimento para a estimativa de parâmetros florestais.



## 8 RECOMENDAÇÕES PARA TRABALHOS FUTUROS

Para dar continuidade à pesquisa, sugere-se o estudo de outros métodos para à detecção das árvores a partir da imagem aérea multiespectral, como a segmentação *watershed* e a segmentação por regiões de crescimento. Sugere-se também o uso de outros produtos derivados da imagem, como o índice de vegetação *enhanced vegetation index* (EVI), e o uso de outros tamanhos de janela.

Ressalta-se que a detecção das árvores por dados LiDAR pode ser efetiva, entretanto, neste trabalho, a densidade do povoamento estudado foi alta. Espera-se que em áreas com linhas de plantios mais espaçadas, os resultados possam ser ainda mais eficazes.

O processo de estimativa do volume por árvore foi acurado, porém, se perdeu a localização exata das árvores, quando se passa da abordagem ITD para a ABA (semi-ITD). Neste sentido, seria de grande relevância o estudo que utilizasse a abordagem ITD para outras aplicações, como a detecção de falhas em plantios, controle de pragas e doenças, e principalmente, aquela envolvendo desbastes seletivos, não apenas em plantios florestais, mas também, em florestas nativas.

Apesar do presente estudo ter utilizado dados LiDAR com diferença temporal de até um ano, em relação aos dados provenientes de parcelas em campo, sem o comprometimento dos resultados, sugere-se o estudo mais detalhado, abrangendo a utilização de dados com diferentes missões de vôo ao longo do tempo.



## REFERÊNCIAS BIBLIOGRÁFICAS

- ALVES, G. V. M. **Estimativa de variáveis florestais com perfilamento a laser (LiDAR)**. Doutorado em Ciências Florestais – Universidade Federal do Paraná, Curitiba, Brasil, 2010.
- ASSMANN, E. **The principles of forest yield study**. Oxford/New York: Pergamon, 1970. 504 p.
- BATISTA, J. L. F.; COUTO, H. T. Z.; FILHO, D. F. S. **Quantificação dos Recursos Florestais: árvores, arvoredos e florestas**. 1 ed. – São Paulo: Oficina de Textos, 2014. 384p.
- BEN-GAL, I. Outlier detection. In: MAIMON, O.; ROKACH, L. (eds.). **Data mining and knowledge discovery handbook**. Springer Science + Business Media Dordrecht, Tel-Aviv University, Israel, 2005, p.132-146.
- BRANDTBERG, T.; WARNER, T. A.; LANDENBERGER, R. E.; MCGRAW, J. B. Detection and analysis of individual leaf-off tree crowns in small footprint, high sampling density lidar data from the eastern deciduous forest in North America. **Remote Sensing of Environment**, v. 85, p. 290-303, 2003.
- BREINDENBACH, J.; ASTRUP, R. The semi-individual tree crown approach. In: MALTAMO, M. (ed.). **Forestry applications of airborne laser scanning: concepts and case studies**. Dordrecht: Springer Science + Business Media, 2014. p.113-133.
- CAMPBELL, J. B.; WYNNE, R. H. **Introduction to remote sensing**. New York: The Guildford Press, 2011.667 p. ISBN 978-1-60918-176-5.
- CANAVESI, V.; PONZONI, F.; VALERIANO, M. M. Estimativa de volume de madeira em plantios de *Eucalyptus* spp. utilizando dados hiperespectrais e dados topográficos. **Revista Árvore**, Viçosa-MG, v. 34, n. 3, p. 539-549, 2010.

CURTIS, R. Height-diameter and height-diameter-age equations for second-growth Douglas-fir. **Forest science**, Amsterdam, v.13, n.4, p.365-375, 1967.

DALGAARD, P. **Introductory statistics with R**. Springer Science+Business Media, LLC, 363p, 2008. e-ISBN: 978-0-387-79054-1.

FERREIRA, M. Escolha de espécies de eucalipto. **Circular técnica IPEF**, v.47, p.1-30, 1979.

HUDAK, A. T.; LEFSKY, M.; COHEN, W. B.; BERTERRETICHE, M. Integration of lidar and Landsat ETM+ data for estimating and mapping forest canopy height. **Remote Sensing of Environment**. v. 82, p. 397-416, 2002.

IBÁ - Industria Brasileira de Árvore. 2014. Disponível em: [http://www.bracelpa.org.br/shared/iba\\_2014\\_pt.pdf](http://www.bracelpa.org.br/shared/iba_2014_pt.pdf). Acesso em: 11 de janeiro de 2015.

ISENBURG, M. **LASTOOLS Version 111216**: Software for Lidar Processing (2015). [Computer program]. Gilching: rapidlasso GmbH. Disponível em: <http://lastools.org>. Acesso em: 03 de fevereiro de 2014.

JAMES, G; WITTEN, D.; HASTIE, T.; TIBSHIRANI, R. **An introduction to statistical learning with applications in R**. New York: Springer Science+Business Media, 2014. ISBN 987-1-4614-7138-7.

KAARTINEN, H.; HYYPPÄ, J.; YU, X.; VASTARANTA, M.; HYYPPÄ, H.; KUKKO, A.; HOLOPAINEN, M.; HEIPKE, C.; HIRSCHMUGL, M.; MORSDORF, F.; NÆSSET, E.; PITKÄNEN, J.; POPESCU, S.; SOLBERG, S.; WOLF, B. M.; WU, J. An international comparison of individual tree detection and extraction using airborne laser scanning. **Remote Sensing**, v. 4, p. 950-974, 2012.

KE, Y.; QUACKENBUSH, L. J. A review of methods for an automatic individual tree-crown detection and delineation from passive remote sensing. **International Journal of Remote Sensing**, v. 32, n. 17 p.4725-4747, 2011.

KOCH, B.; HEYDER, U.; WEINACKER, H. Detection of individual tree crowns in airborne lidar data. **Photogrammetric Engineering & Remote Sensing**, v. 72, n. 4, pp. 357-363, 2006.

KÖPPEN, W.; GEIGER, R. **Klimate der Erde**. Gotha: VerlagJustus Perthes, 1928. Wall-map 150cmx200cm.

KOUKOULAS, S.; BLACKBURN, G. A. Mapping individual tree location, height and species in broadleaved deciduous forest using airborne LIDAR and multi-spectral remotely sensed data. **International Journal of Remote Sensing**, v. 26, n. 3, p. 431-455, 2005.

KUMAR, V. **Forest inventory parameters and carbono mapping from airborne LiDAR**. 2012. Msc (Master of Science) in Geo-information Science and Earth Observations – The University of Twente, Enschede, The Netherlands, 2012.

LEITOLD, V. **Airborne lidar-based estimates of tropical forest structure and ground topography in a mountainous area of the brazilian atlantic forest**. 2014. 122 p. (sid.inpe.br/mtc-m21b/2014/03.17.04.12-TDI). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2014. Disponível em: <<http://urlib.net/8JMKD3MGP5W34M/3FU3382>>. Acesso em: 26 fev. 2015.

LEMOS, C. C. Z. Aprimoramentos, teste e uso do modelo 3-PG em plantios clonais de *Eucalyptus* no nordeste do estado de São Paulo. Tese (Doutorado) em Recursos Florestais – Escola Superior de Agricultura “Luiz de Queiroz”, Piracicaba, 2012.

LUMLEY, T. **LEAPS**: R package version 2.9 for regression subset selection including exhaustive search. Washington: University of Washington, 2009. 8p. Disponível em: <http://cran.r-project.org/web/packages/leaps/leaps.pdf>. Acesso em: 08 de Novembro de 2014.

MACEDO, R. C. **Estimativa volumétrica de povoamento clonal de Eucalyptus sp. através de laserscanner aerotransportado**. 2009. 143 p. (INPE-15743-TDI/1488). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2009. Disponível em: <<http://urlib.net/8JMKD3MGP8W/34NUA58>>. Acesso em: 26 fev. 2015.

MALTAMO, M.; PACKALÉN, P. **Species-specific Management Inventory in Finland**. Dordrech: Springer Science+Business Media, 2014. ISBN 978-94-017-8662-1.

MCCULLAGH, M. J. Terrain and surface modelling systems: theory and practice. **Photogrammetric Record**, v.12, n. 72, p. 747-749, 1988.

MCGAUGHEY, R. J. **FUSION/LDV**: software for LiDAR DATA Analysis and Visualization [Computer program]. Washington: USDA, Forest Service Pacific Northwest Research Station, 2013. 150 p. Disponível em: [http://forsys.cfr.washington.edu/fusion/FUSION\\_manual.pdf](http://forsys.cfr.washington.edu/fusion/FUSION_manual.pdf). Acesso em: 12 de Março de 2014.

MEHTÄTALO, L.; NYBLÖM, J.; VIROLAINEN, A. A Model-Based Approach for the Recovery of Forest Attributes Using Airborne Laser Scanning. In: MALTAMO, M. (ed.). **Forestry applications of airborne laser scanning: concepts and case studies**. Dordrecht: Springer Science + Business Media, 2014. p. 193-211.

MONNET, J.; MERMIM, E.; CHANUSSOT, J.; BERGER, F. Tree top detection using local maxima filtering: a parameter sensitivity analysis. In: International conference on lidar application for assessing forest ecosystems, 10., 2010, Freiburg, Germany: Proceedings... Freiburg: Silvilaser, 2010.

NÆSSET, E. Determination of mean tree height of forest stands using airborne laser scanner data. **ISPRS Journal of Photogrammetry & Remote Sensing**, v. 52, p. 49-56, 1997a.

NÆSSET, E. Estimating timber volume of forest stands using airborne laser scanner data. **Remote Sensing of Environment**, v. 61, p.246-253, 1997b.

NÆSSET, E. Predicting forest stand characteristics with airborne laser using a practical two-stage procedure field data. **Remote Sensing of Environment**, v. 80, p. 88-90, 2002.

OLIVEIRA, L. T.; CARVALHO, L. M. T.; FERREIRA, M. Z.; OLIVEIRA, T. C. A.; JUNIOR, F. W. A. Application of LiDAR to forest inventory for tree count in stands of Eucalyptus sp. **Cerne**, Lavras, v. 18, p. 175-184, abr./jun. 2012.

ØRKA, H. O.; GOBAKKEN, T.; NÆSSET, E.; ENE, L.; LIEN, V. Simultaneously acquired airborne laser scanning and multispectral imagery for individual tree species identification. **Canadian Journal of Remote Sensing**, v. 38, p. 125-136, 2012.

PACKALÉN, P.; MEHTÄTALO, L.; MALTAMO, M. ALS-based estimation of plot volume and site index in a eucalyptus plantation with a nonlinear mixed-effect model that accounts for the clone effect. **Annals of Forest Science**, Springer Verlag (Germany), v. 68, n.6, p. 1085-1092, 2011. <10.1007/s13595-011-0124-9>. <hal-00930694>

PARIS, C.; BRUZZONE, L. A Three-Dimensional Model-Based Approach to the Estimation of the Tree Top Height by Fusing Low-Density LiDAR Data and Very High Resolution Optical Images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 53, n.1, Jan. 2015.

PEÑA, E. A.; SLATE, E. H. Global validation of linear model assumptions. **Journal of the American Statistical Association**, v. 101, n. 473, p. 341-354, 2006.

PEÑA, E. A.; SLATE, E. H. **gvlma**: Global Validation of Linear Models Assumptions. R package version 1.0.0.2. 2014. Disponível em: <<http://CRAN.R-project.org/package=gvlma>>. Acesso em: 20 de dezembro de 2014.

PEREIRA, J. P. **Mensuração automática de copas de Araucaria angustifolia (Bertol.) Kuntze a partir de dados LiDAR para estimativa de variáveis dendrométricas.** 174 p. 2014. Dissertação (Mestrado em Engenharia Florestal) – Universidade do Estado de Santa Catarina, Lages, 2014.

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

PIRES, J. M. **Uso do Lidar (light detection and ranging) para estimação da altura de árvores em povoamentos de eucalipto.** 39p. 2005. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2005.

PITKÄNEN, J. Individual tree detection in digital aerial images by combining locally adaptive binarization and local maxima methods. **Can. J. For. Res.** V.31 p. 832 – 844, 2001.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento remoto no estudo da vegetação.** São José dos Campos: Parêntese, 2010. 144 p.

POPESCU, S. C.; WYNNE, R. H.; NELSON, R. F. Estimating plot level tree heights with lidar: local filtering with canopy-height based variable window size. **Computers and Electronics**, v. 37 p. 71-95, 2002.

POPESCU, S. C.; WYNNE, R. H.; SCRIVANI, J. A. Fusion of small-footprint lidar and multispectral data to estimate plot- level volume and biomass in deciduous. **Forest Science**, v. 50, n. 4, 2004.

QUEIROZ, W. T. **Amostragem em inventário florestal.** Belém, Universidade Rural do Amazônia, 2012. 441p. ISBN 978-85-7295-070-1.

R DEVELOPMENT CORE TEAM. **R: a language and environment for statistical computing.** Vienna, Austria: R Foundation for Statistical Computing, 2007. Disponível em <http://www.r-project.org/> com acesso em 07 de janeiro de 2015.

ROBERTS, S. D.; DEAN, T. J.; EVANS, D. L.; MCOMBS, J. W.;  
HARRINGTON, R. L.; GLASS, P. A. Estimating individual tree leaf area in  
loblolly pine plantations using LiDAR-derived measurements of height and  
crown dimensions. **Forest Ecology and Management**, v. 213, p.54-70, 2005.

SAARELA, S.; GRAFSTRÖM, A.; STAHL, G.; KANGAS, A.; HOLOPAINEN, M.;  
TUOMINEN, S.; NORDKVIST, K.; HYYPPÄ, J. Model-assisted estimation of  
growing stock volume using different combinations of LiDAR and Landsat data  
as auxiliary information. **Remote Sensing of Environment**, v. 158, p. 431-440,  
2015.

SCHÖEPFER, W. Automatisierung des massen, Sorten und Wertberechnung  
stehender Waldbestände Schriftenreihe Bad. Berlin: Wurt-Forstl., 1966. n.p.

SILVA, A. G. P. **Estimativa da biomassa de lenho em povoamentos de  
*Eucalyptus grandis* baseada em estatísticas do perfil de dossel geradas  
por escaneamento a laser aerotransportado.** 146 p-. 2014. Dissertação  
(Mestrado em Ciências) – Escola Superior de Agricultura Luiz de Queiroz,  
Piracicaba, 2014.

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

SILVA, C. A.; KLAUBERG, C.; CARVALHO, S. P. C.; HUDAK, A. T.;  
RODRIGUEZ, L. C. E. Mapping aboveground carbono stocks using LiDAR data  
in *Eucalyptus* spp. Plantations in the state of São Paulo, Brazil. **Revista  
Scientia Forestalis**, v. 42, n. 104, dez. 2014.

SILVA, C. D.; NASCIMENTO, J. S.; SCARPINATI, E. A.; PAULA, R. C.  
Classification of *Eucalyptus urograndis* hybrids under different water availability  
based on biometric traits. **Forest Systems**, v.23, n.2, p. 209-215, 2014.

SIMÕES, D. **Avaliação econômica de dois sistemas de colheita florestal mecanizada de eucalipto**. 105 p. 2008. Dissertação (Mestrado em Agronomia) – Faculdade de Ciências Agrônômica da UNESP, Botucatu, 2008.

USGS. **Bathmetry** – LIDAR. Florida Integrated Science Center. Disponível em: [http://gulfsi.usgs.gov/tampabay/data/1\\_bathymetry\\_lidar/images/Eaar11.gif](http://gulfsi.usgs.gov/tampabay/data/1_bathymetry_lidar/images/Eaar11.gif). Acesso em 06 de janeiro de 2015.

USGS. **Earth explorer**. 2014. Disponível em : <http://earthexplorer.usgs.gov/>. Acesso em: 19 de janeiro de 2015.

VASTARANTA, M.; HOLOPAINEN, M.; YU, X.; HYPPÄ, J.; MÄKINEN, A.; RASINMÄKI, J.; MELKAS, T.; KAARTINEN, H.; HYYPPÄ, H. Effects of individual tree detection error sources on forest management planning calculations. **Remote Sensing**, v. 3, p. 1614-1626, 2011.

VAUHKONEN, J; MALTAMO, M.; MCROBERTS, R. E.; NÆSSET, E. In: MALTAMO, M.; NÆSSET, E.; VAUHKONEN, J. **Forestry applications of airborne laser scanning** – concepts and case studies. Springer Science + Business Media Dordrecht, Netherlands, 2014, p.01-16. ISBN 978-94-017-8663-8 (eBook).

WANG, L.; GONG, P.; BIGING, G. S. Individual Tree-Crown Delineation and Treetop Detection in High-Spatial-Resolution Aerial Imagery. **Photogrammetric Engineering & Remote Sensing**, v. 70, n. 3, pp. 351–357, 2004.

WHITE, J. C.; WULDER, M. A.; VARHOLE, A.; VASTARANTA, M.; COOPS, N. C.; COOK, D. C.; PITT, D.; WOODS, M. **A best practices guide for generating forest inventory attributes from airborne laser scanning data using an area-based approach** (Version 2.0). Victoria British Columbia, Canada: Natural Resources Canada, Canadian Forest Service and Canadian Wood Fiber Centre, 2013.

WULDER, M.; NIEMANN, K. O.; GOODENOUGH, D.G. Local Maximum Filtering for the extraction of tree locations and basal area from high spatial resolution imagery. **Remote Sensing of Environment**, 73, pp. 103–114, 2000.

WULDER, M.; SEEMANN, D. Forest inventory height update through the integration of lidar data with segmented Landsat imagery. **Canadian Journal of Remote Sensing**, v. 29, n.5, pp.536-543, 2003.

ZANDONÁ, D. F. **Potencial uso dos dados laser scanner aerotransportado para estimativa de variáveis dendrométricas**. 92 p. 2006. Dissertação (Mestrado em Engenharia Florestal) – Universidade Federal do Paraná, Curitiba, Brasil, 2006.

ZHANG, J.; SOHN, G.; BRÈDIF, M. A hybrid framework for single tree detection from airborne laser scanning data: a case study in temperate mature coniferous forests in Ontario, Canada. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 98, p.44-57, 2014.