

ALESSANDRA LOPES BRAGA FONSECA

**ESTIMAÇÃO DE VOLUME DE MADEIRA EM POVOAMENTO DE EUCALIPTO  
UTILIZANDO DADOS DE LASER SCANNER TERRESTRE**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Civil, para obtenção do título de *Doctor Scientiae*.

VIÇOSA  
MINAS GERAIS - BRASIL  
2018

**Ficha catalográfica preparada pela Biblioteca Central da Universidade  
Federal de Viçosa - Câmpus Viçosa**

T

F676e  
2018  
Fonseca, Alessandra Lopes Braga, 1978-  
Estimação de volume de madeira em povoamento de  
eucalipto utilizando dados de Laser Scanner Terrestre /  
Alessandra Lopes Braga Fonseca. – Viçosa, MG, 2018.  
xii, 101 f. : il. (algumas color.) ; 29 cm.

Inclui apêndices.

Orientador: Júlio César de Oliveira.

Tese (doutorado) - Universidade Federal de Viçosa.

Inclui bibliografia.

1. Eucalipto - Medição - Modelos matemáticos. 2. Redes neurais (Computação). 3. Florestas - Medição. 4. Árvores - Medição. I. Universidade Federal de Viçosa. Departamento de Engenharia Civil. Programa de Pós-Graduação em Engenharia Civil. II. Título.

CDD 22. ed. 634.973766

ALESSANDRA LOPES BRAGA FONSECA

**ESTIMAÇÃO DE VOLUME DE MADEIRA EM POVOAMENTO DE EUCALIPTO  
UTILIZANDO DADOS DE LASER SCANNER TERRESTRE**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Civil, para a obtenção do título de *Doctor Scientiae*.

APROVADA: 14 de dezembro de 2018.

  
Alessandra Lopes Braga Fonseca  
Autora

  
Júlio César de Oliveira  
Orientador

## AGRADECIMENTOS

Primeiramente agradeço a Deus pelo dom da vida e por conceder esse momento.

Aos meus queridos pais João Braga e Maria Helena, meu sincero agradecimento aos dois, pelo carinho, amor, apoio. Eu tenho uma enorme admiração aos pais que tenho.

Aos meus irmãos, João Paulo e Vanessa, por serem meus verdadeiros amigos e companheiros nas bagunças e em algumas brigas.

Ao meu marido, Francisco o meu muito obrigada por todos os momentos a mim dedicados e por ter sido um incentivador na busca dos meus objetivos. Só Deus sabe tudo que passamos para realizarmos esse sonho.

Aos meus queridos filhos, João Vitor e Alice que no futuro entenderão os verdadeiros motivos da minha ausência para o desenvolvimento desse trabalho. Sem vocês meus amores nada disso seria possível. Amo vocês!

A todos meus familiares que me ajudaram de alguma forma.

Aos amigos que cultivei em Viçosa.

À Universidade Federal Viçosa, por todos os conhecimentos adquiridos e por toda a infraestrutura disponibilizada na minha graduação, no meu mestrado e no doutorado.

A todos os professores do setor de Engenharia de Agrimensura e Cartográfica.

Ao professor Joel Gripp, agradeço a oportunidade que me concedeu desde a entrada e ao longo do doutorado. Fica aqui o meu eterno respeito, admiração e carinho.

Ao meu orientador, o professor Júlio César de Oliveira, responsável pelo meu amadurecimento e crescimento profissional. Agradeço por partilhar o conhecimento e direcionar meus passos nessa trajetória.

Ao amigo o professor Mosar Faria, obrigado pelos ensinamentos partilhados no desenvolvimento desse trabalho.

Ao professor Hélio Garcia Leite, minha eterna gratidão pelos inúmeros ensinamentos, contribuições e orientação no desenvolvimento deste trabalho.

Aos colegas de trabalho do Ifes, muito obrigada por todo apoio.

E a todos os meus amigos que, de forma direta ou indireta, contribuíram para a realização deste trabalho.

## LISTA DE ILUSTRAÇÕES

### CAPÍTULO 2

Figura 2.1 – Sistema de coordenadas polares do equipamento Laser Scanner .....	10
Figura 2.2 – Parcelas (1, 2 e 3) da rede de parcelas do inventário de pré-corte .....	14
Figura 2.3 – (a) Equipamento Laser Scanner, modelo VZ-400; (b) Alvos refletores instalados na área de cada parcela .....	15
Figura 2.4 – Disposição do posicionamento do equipamento para as parcelas 1, 2 e 3.....	17
Figura 2.5 – Representação das variáveis $dap$ e $h$ obtidas pelo processamento de dados LST .....	20
Fluxograma 2.1 – Análise estatística pelo método Leite e Oliveira (2002), aplicado à análise dos resultados das variáveis $dap$ e $h$ .....	23
Figura 2.6 – Parcelas 1, 2 e 3 representadas no espaço bidimensional em uma seção transversal com vista superior a 1,3m de altura do terreno. (a) árvore próxima ao equipamento e (b) árvore na extremidade da parcela.....	24
Figura 2.7 – Croquis do posicionamento das árvores para cada parcela para o modo única varredura com o equipamento LST, vista de topo.....	25
Gráfico 2.1 – Gráficos de dispersão das variáveis $dap$ e $h$ para as parcelas 1, 2 e 3.....	28

### CAPÍTULO 3

Figura 3.1 – Esboço de um neurônio biológico.....	39
Figura 3.2 – Representação de um neurônio artificial .....	40
Figura 3.3 – Recorte da nuvem de pontos de acordo com a delimitação em campo das parcelas: Parcela 1 (A), Parcela 2 (B), Parcela 3 (C).....	43
Figura 3.4 – Variáveis obtidas pelo processamento de dados LST. ....	44
Figura 3.5 – Representação das seções transversais do fuste .....	46

Figura 3.6 – Recorte da Parcela 1 contendo em ordem os planos para cada diferente altura de 0,0; 0,5; 1,0; 1,3; 2,0 e 4,0 m, em relação ao eixo Z.....	51
Figura 3.7 – Recorte da Parcela 2 contendo em ordem os planos para cada diferente altura de 0,0; 0,5; 1,0; 1,3; 2,0 e 4,0 m, em relação ao eixo Z.....	51
Figura 3.8 – Recorte da Parcela 3 contendo em ordem os planos para cada diferente altura de 0,0; 0,5; 1,0; 1,3; 2,0 e 4,0 m, em relação ao eixo Z.....	52
Figura 3.9 – Recorte da Parcela 3 contendo em ordem os planos para cada diferente altura de 0,0 e 4,0 m, em relação ao eixo Z.....	54
Gráfico 3.2 – Gráfico <i>Box-Plot</i> para as variáveis obtida pelo LST: $d_{(h=0.0m)}$ , $d_{(h=0.5m)}$ , $d_{(h=1.0m)}$ , $d_{ap}$ , $d_{(h=2.0m)}$ , $d_{(h=4.0m)}$ .....	53
Gráfico 3.3 – Relação entre volumes observados e estimados para dados de validação das RNA com 4 neurônios na camada intermediária, para cada cenário (A até F).....	58
Gráfico 3.4 – Relação entre volumes observados e estimados para dados de validação das RNA com 8 neurônios na camada intermediária, para cada cenário (A até F).....	59
Gráfico 3.5 – Gráfico dos resíduos obtidos pelas estimativas realizadas pelas RNA treinadas com 4 neurônios na camada intermediária, para cada cenário (A até F).....	60
Gráfico 3.6 – Gráfico dos resíduos obtidos pelas estimativas realizadas pelas RNA treinadas com 8 neurônios na camada intermediária, para cada cenário (A até F).....	61
Gráfico 3.7 – Histograma dos erros obtidos pelas estimativas realizadas pelas RNA treinadas com 4 neurônios na camada intermediária, para cada cenário (A até F).....	62
Gráfico 3.8 – Histograma dos erros obtidos pelas estimativas realizadas pelas RNA treinadas com 8 neurônios na camada intermediária, para cada cenário (A até F).....	63

## CAPÍTULO 4

Figura 4.1 – Recorte da Parcela 1 contendo em ordem os planos para cada diferente altura de 2,0 m, 3,0 m e 4,0 m, em relação ao eixo Z.....	79
---	----

Figura 4.2 – Recorte da Parcela 2 contendo em ordem os planos para cada diferente altura de 2,0 m, 3,0 m e 4,0 m, em relação ao eixo Z.....	80
Figura 4.3 – Recorte da Parcela 3 contendo em ordem os planos para cada diferente altura de 2,0 m, 3,0 m e 4,0 m, em relação ao eixo Z.....	80
Figura 4.4 – Polydata contendo uma nuvem de pontos (X, Y, Z) com o isolamento de fuste obtido pela aplicação do RANSAC .....	84
Gráfico 4.1 – Análise gráfica do ajuste do modelo Schumacher e Hall por diferentes variáveis: (a) e (d) dap e h; (b) dap e Volume <sub>2metros</sub> ; (e) dap e Volume <sub>3metros</sub> ; (c) dap, h e Volume <sub>2metros</sub> ; (f) dap, h e Volume <sub>3metros</sub> .....	87
Gráfico 4.2 – Análise gráfica do ajuste do modelo Schumacher e Hall por diferentes variáveis: (a) dap e h; (b) dap e Volume <sub>4metros</sub> ; (c) dap e Volume <sub>4metros</sub> .....	88

## LISTA DE TABELAS

### CAPÍTULO 2

Tabela 2.1 – Regras de decisão para comparação entre a metodologia tradicional e a metodologia alternativa (LST) pelo teste .....	22
Tabela 2.2 – Resumo dos resultados obtidos ao aplicar o procedimento estatístico proposto para comparação de vários métodos analíticos, Leite e Oliveira (2002) .....	29

### CAPÍTULO 3

Tabela 3.1 – Medidas descritivas para cada variável da análise: Mínimo, Máximo, Média, Mediana, Desvio padrão, Variância e Coeficiente de Variação .....	50
Tabela 3.2 – Resultados obtidos pela aplicação da RNA (unidade m <sup>3</sup> ) para os diferentes cenários variando quatro e oito neurônios na camada oculta: RNA, Dados (Treino e Validação), Volume, Bias, Bias (%), Raiz quadrada do erro quadrático médio (RQME), RQME (%), Variância, Quadrado Médio do Erro (QME) e Coeficiente de correlação (RYY) .....	55
Tabela 3.3 – Resultados obtidos pelo método Leite e Oliveira (2002) para RNA com metodologia tradicional com nuvem de pontos com as variáveis <i>dap</i> e <i>h</i> para o cenário F: Erro Médio ( $\bar{\epsilon}$ ), Teste F(H <sub>0</sub> ), Teste (t <sub><math>\bar{\epsilon}</math></sub> ) e $r_{YY1} \geq 1 -  \bar{\epsilon} $ .....	64

### CAPÍTULO 4

Tabela 4.1 – Parâmetros utilizados para a aplicação do RANSAC .....	81
Tabela 4.2 – Resultados de volume obtidos pelos métodos direto e indireto para as Parcelas 1, 2 e 3 .....	86

## LISTA DE ABREVIATURAS E SIGLAS

ABRA	Associação Brasileira de Produtores de Florestas Plantadas.
ART	<i>Adaptive Resonance Theory.</i>
CV	Coeficiente de variação.
DEM	<i>Digital Elevation Models.</i>
FOV	<i>Field of View.</i>
LASER	<i>Light Amplification by Stimulated Emission of Radiance.</i>
LIDAR	<i>Light Detection and Ranging.</i>
LSA	Laser Scanner Aerotransportado.
LST	Laser Scanner Terrestre.
MLP	<i>Multilayer Perceptron.</i>
MSA	<i>Multi Station Adjustment.</i>
PIXEL	<i>Picture Element.</i>
QME	Quadrado Médio do Erro.
RANSAC	<i>Random Sample Consensus.</i>
RGB	Red, Green e Blue.
RNA	Rede Neural Artificial.
RQME	Raiz quadrada do erro quadrático médio.
SNIF	Sistema Nacional de Informações Florestais.
TOF	<i>Time of Flight.</i>
TIN	<i>Triangulated Irregular Networks.</i>
VAR	Variância.
VOXEL	<i>Volume Element.</i>

## RESUMO

FONSECA, Alessandra Lopes Braga, D.Sc, Universidade Federal de Viçosa, dezembro de 2018. **Estimação de Volume de Madeira em Povoamento de Eucalipto utilizando dados de Laser Scanner Terrestre**. Orientador: Júlio César de Oliveira. Coorientadores: Hélio Garcia Leite e Mosar Faria Botelho.

Uma das aplicações do Laser Scanner Terrestre (LST) em engenharia florestal consiste na descrição do fuste das árvores em florestas plantadas. Desta forma, o objetivo principal deste estudo é identificar e reconstruir a estrutura espacial de árvores a partir dos dados Laser Scanner Terrestre (LST), para estimativa de parâmetros de mensuração florestal necessários ao cálculo de volume em povoamentos florestais de eucalipto. Metodologicamente, foram realizados experimentos para a mensuração das parcelas em campo, utilizando as formas única varredura e múltiplas varreduras. As nuvens de pontos foram registradas, ajustadas ao Sistema Topográfico, redimensionadas nos tamanhos das parcelas em campo e filtradas, para a obtenção das variáveis: diâmetro a 1,3 m de altura ( $d_{ap}$ ), altura total ( $h$ ) e os diâmetros em diferentes alturas  $d_{(h=0,0m)}$ ,  $d_{(h=0,5m)}$ ,  $d_{(h=1,0m)}$ ,  $d_{ap}$ ,  $d_{(h=2,0m)}$  e  $d_{(h=4,0m)}$ , foram determinadas na estrutura espacial das árvores. No primeiro artigo, foi aplicado o teste estatístico, para avaliar a hipótese de identidade das medidas ( $d_{ap}$  e  $h$ ) obtidas pelo procedimento usual de inventário florestal com as correspondentes medidas obtidas pelo LST. Já no segundo artigo, foram utilizadas as diferentes variáveis para obtenção do volume de cada fuste empregando Redes Neurais Artificiais (RNA's). Para o terceiro artigo, foram obtidos os volumes dos fustes, utilizando a interpolação sobre a nuvem de pontos e para a individualização dos fustes, foi aplicada a segmentação pelo método RANSAC (*RANdom SAmple Consensus*). Assim, o uso do LST para a obtenção das variáveis apresentou resultados satisfatórios, comprovando a eficiência da metodologia para a estimação volumétrica de madeira em povoamentos florestais de eucalipto.

## ABSTRACT

FONSECA, Alessandra Lopes Braga, D.Sc, Universidade Federal de Viçosa, December, 2018. **Estimation of Wood Volume in Eucalyptus Stands using Terrestrial Laser Scanner**. Adviser: Júlio César de Oliveira. Co-advisers: Hélio Garcia Leite and Mosar Faria Botelho.

One of the applications of the Terrestrial Laser Scanner (TLS) in forestry engineering is the description of the stem of trees in planted forests. In this way, the main objective of this study is to identify and reconstruct the spatial structure of trees from the TLS, to estimate the forest measurement parameters required to calculate the volume in forest plots of eucalyptus. Methodologically, experiments were carried out to measure the plots in the field using the single-scan and multi-scan forms. The points clouds were recorded, adjusted to the Topographic System, resized in the plot size and filtered, to obtain the variables: diameter at 1.3 m height (*dbh*), total height (*h*) and diameters at different heights  $d_{(h=0.0m)}$ ,  $d_{(h=0.5m)}$ ,  $d_{(h=1.0m)}$ ,  $dbh$ ,  $d_{(h=2.0m)}$  and  $d_{(h=4.0m)}$ , were determined in the spatial structure of the trees. The first article was applied the statistical test to evaluate the hypothesis of identity of the measures (*dap* and *h*) obtained by the usual forest inventory procedure with the corresponding measures obtained by the TLS. In the second article, the different variables were used to obtain the volume of each stem using Artificial Neural Networks (ANNs). For the third article, the volumes of the stems were obtained using the interpolation on the cloud of points and for the individualization of the stems was applied to the segmentation by the RANSAC SAmple Consensus method. Therefore, the use of the LST to obtain the variables presented satisfactory results proving the efficiency of the methodology for the volumetric estimation of wood in forest stands of eucalyptus.

## SUMÁRIO

<b>CAPÍTULO 1: INTRODUÇÃO GERAL</b> .....	<b>1</b>
<b>1.1 CONSIDERAÇÕES INICIAIS</b> .....	<b>1</b>
<b>1.2 OBJETIVO GERAL</b> .....	<b>2</b>
<b>1.3 OBJETIVO ESPECÍFICOS</b> .....	<b>2</b>
<b>1.4 ESTRUTURAÇÃO DO TRABALHO</b> .....	<b>3</b>
<b>REFERÊNCIAS BIBLIOGRÁFICAS</b> .....	<b>4</b>
<b>CAPÍTULO 2. VALIDAÇÃO ESTATÍSTICA DOS DADOS LASER SCANNER TERRESTRE PARA MEDIÇÃO DE PARCELAS DE INVENTÁRIO FLORESTAL</b> .....	<b>6</b>
<b>2.1 INTRODUÇÃO</b> .....	<b>7</b>
<b>2.2 SISTEMA LASER SCANNER TERRESTRE</b> .....	<b>8</b>
<b>2.3 PROCESSAMENTO DOS DADOS LASER APLICADO AO INVENTÁRIO FLORESTAL</b> .....	<b>11</b>
<b>2.4 MATERIAL E MÉTODOS</b> .....	<b>13</b>
<b>2.4.1 Área de Estudo</b> .....	<b>13</b>
<b>2.4.2 Aquisição dos Dados LST</b> .....	<b>14</b>
<b>2.4.3 Métodos</b> .....	<b>18</b>
<b>2.4.4 Análise Estatística</b> .....	<b>20</b>
<b>2.5 RESULTADOS</b> .....	<b>23</b>
<b>2.5.1 Única Varredura</b> .....	<b>23</b>
<b>2.5.2 Múltiplas Varreduras</b> .....	<b>25</b>
<b>2.5.3 Validação</b> .....	<b>26</b>
<b>2.6 DISCUSSÃO</b> .....	<b>30</b>
<b>2.7 CONCLUSÃO</b> .....	<b>31</b>
<b>REFERÊNCIAS BIBLIOGRÁFICAS</b> .....	<b>32</b>
<b>CAPÍTULO 3. ESTIMAÇÃO DE VOLUME DE MADEIRA EM POVOAMENTO DE EUCALIPTO UTILIZANDO LASER SCANNER TERRESTRE E INTELIGÊNCIA ARTIFICIAL</b> .....	<b>36</b>
<b>3.1 INTRODUÇÃO</b> .....	<b>37</b>
<b>3.2 REDE NEURAL ARTIFICIAL</b> .....	<b>38</b>
<b>3.3 MATERIAIS E MÉTODOS</b> .....	<b>41</b>

3.3.1 Área de estudo.....	41
3.3.2 Coleta de Dados.....	41
3.3.3 Pré-Processamento dos Dados.....	42
3.3.4 Extração das Variáveis do Fuste.....	43
3.3.5 Estimativas de Volume utilizando RNA.....	45
3.3.5.1 Treinamento das RNA's.....	45
3.3.5.2 Análise Estatística.....	48
3.4 RESULTADOS.....	49
3.4.1 Extração das Variáveis.....	49
3.4.2 Aplicação das RNA's para Estimativa de Volume.....	54
3.5 DISCUSSÃO.....	64
3.5.1 Extração das Variáveis.....	64
3.5.2 Aplicação das RNA's para Estimativa de Volume.....	65
3.6 CONCLUSÃO.....	67
REFERÊNCIAS BIBLIOGRÁFICAS.....	67
<b>CAPÍTULO 4. ESTIMAÇÃO DE VOLUME DE EUCALYPTUS EM DADOS DE SCANNER LASER TERRESTRES UTILIZANDO INTERPOLAÇÃO E MÉTODO RANSAC.....</b>	<b>72</b>
4.1 INTRODUÇÃO.....	73
4.2 RANSAC.....	74
4.3 MATERIAIS E MÉTODOS.....	76
4.3.1 Área de Estudo.....	76
4.3.2 Levantamento de Campo.....	77
4.3.3 Pré-Processamento dos Dados.....	78
4.3.4 Métodos.....	80
4.4 RESULTADOS E DISCUSSÃO.....	83
4.5 CONCLUSÃO.....	89
REFERÊNCIAS BIBLIOGRÁFICAS.....	89
<b>CAPÍTULO 5: CONCLUSÃO GERAL.....</b>	<b>93</b>
<b>APÊNDICE.....</b>	<b>95</b>
A) Resultados para as variáveis dap e h (Parcela 1).....	95
B) Resultados para as variáveis dap e h (Parcela 2).....	98
C) Resultados para as variáveis dap e h (Parcela 3).....	100

## CAPÍTULO 1: INTRODUÇÃO GERAL

### 1.1 CONSIDERAÇÕES INICIAIS

O Brasil possui uma extensa cobertura de florestas plantadas e uma enorme cadeia produtiva desde o cultivo até a geração de produtos. A área plantada no país com o gênero *Eucalyptus* totalizou 5.558.653 hectares, em 2014 (ABRAF, 2014), e, em 2016, foram totalizados 7.543.707 hectares (SNIF, 2017). O estado de Minas Gerais é o maior produtor desse plantio, com 1.880.538 hectares plantados em 2016 (SNIF, 2017). O grande investimento em pesquisa e inovação tecnológica de indústrias de papel e celulose tornam o Brasil um dos maiores produtores de eucalipto do mundo.

Durante as últimas décadas, o avanço tecnológico permitiu o desenvolvimento de técnicas para aquisição de dados espaciais. Uma dessas inovações tem sido a tecnologia de varredura Laser Scanner Terrestre (LST), que oferece a captura de dados tridimensionais (X, Y, Z), como possibilidade, de forma direta e automatizada. As principais vantagens dos levantamentos com LST são a rapidez na coleta de dados e a capacidade de gerar uma nuvem densa de pontos tridimensionais.

Desde o advento dos equipamentos LST vêm surgindo pesquisas no sentido de encontrar novas soluções relacionadas à modelagem das árvores em ambientes florestais. O uso do LST na área florestal é considerado uma alternativa não destrutiva para mensuração de árvores, podendo ser utilizado para obter medidas diretas dos parâmetros da árvore, como diâmetros, altura e localização, além dos parâmetros de forma do fuste<sup>1</sup> e da copa da árvore em ambientes florestais (HOPKINSON *et al.*, 2004; MAAS *et al.*, 2008; JUPP *et al.*, 2009; CALDERS *et al.*, 2014; MAAN *et al.*, 2014; NEWNHAM *et al.*, 2015; WILKES *et al.*, 2017).

No levantamento utilizando o LST obtém-se primeiramente a representação vertical para diferentes formações florestais presentes na área mapeada (EYSN *et al.*, 2013). Nesse levantamento, o mapeamento das árvores é realizado no espaço

---

<sup>1</sup> fuste é a parte principal do tronco de uma árvore, aquela situada entre o solo e as primeiras ramificações.

tridimensional (3D), utilizando única varredura (uma estação) e múltiplas varreduras (duas ou mais estações). Para única varredura, geralmente o equipamento é posicionado no centro da parcela e a aquisição dos dados é realizada de forma parcial em apenas um lado da árvore. Na abordagem com múltiplas varreduras, tem-se toda a superfície do tronco da árvore recoberta por pontos laser, porém os dados dos diferentes posicionamentos precisam ser corrigidos para um sistema de coordenadas comuns, através da operação de registro (ASTRUP *et al.*, 2014).

Dificuldades podem ser encontradas ao utilizar os dados obtidos pelo LST. O uso do modo única varredura pode causar efeitos de oclusão dos fustes, baixa densidade de pontos e, em certos locais da parcela, grande quantidade de ruídos (LIANG *et al.*, 2016). Por isso, esses autores sugeriram o modo “múltiplas varreduras” para contornar tais efeitos. Com base nos trabalhos supracitados, foram estabelecidos os objetivos geral e específicos que estão descritos na sequência.

## **1.2 OBJETIVO GERAL**

A presente pesquisa tem como objetivo geral identificar e reconstruir a estrutura espacial de árvores a partir dos dados Laser Scanner Terrestre (LST), para estimativa de parâmetros de mensuração florestal necessários ao cálculo de volume em povoamentos florestais de eucalipto.

## **1.3 OBJETIVO ESPECÍFICOS**

Especificamente, os objetivos foram:

- Reconstruir, com base nas coordenadas tridimensionais (3D) oriundas da nuvem de pontos, a estrutura espacial de árvores em povoamentos de eucalipto, para estimar os parâmetros da árvore;
- Avaliar estatisticamente a identidade entre as medidas *dap* e altura total (*h*) das árvores obtidas pela utilização do equipamento LST em comparação com as medidas convencionais;
- Construir, validar e aplicar um modelo de Rede Neural Artificial (RNA), para estimar o volume, com base nas variáveis obtidas por LST;

- Aplicar técnicas de modelagem tridimensional, para obtenção do volume individual do tronco.

#### 1.4 ESTRUTURAÇÃO DO TRABALHO

Este trabalho apresenta um estudo sobre a utilização dos Laser Scanner Terrestre (LST) na estimativa de parâmetros de mensuração florestal necessários ao cálculo de volume em povoamentos florestais de eucalipto. Diversas pesquisas têm demonstrado o uso de Laser Scanner Aerotransportado (LSA) na área florestal. Por outro lado, poucos estudos têm sido realizados com o uso de LST, para medição de parcelas de inventário.

O presente trabalho está organizado em cinco diferentes tópicos, organizados em três artigos, conforme segue:

- INTRODUÇÃO GERAL – neste capítulo, são apresentados, juntamente com a introdução, a descrição geral do problema, os objetivos deste trabalho e as justificativas para a realização das pesquisas.
- CAPÍTULO 1  
*VALIDAÇÃO ESTATÍSTICA DOS DADOS LASER SCANNER TERRESTRE PARA MEDIÇÃO DE PARCELAS DE INVENTÁRIO FLORESTAL* – este capítulo apresenta uma avaliação da utilização do equipamento do LST por única varredura e múltiplas varreduras, em relação ao método tradicional de medição de árvores em parcelas de inventário florestal.
- CAPÍTULO 2  
*ESTIMAÇÃO DE VOLUME DE MADEIRA EM POVOAMENTO DE EUCALIPTO UTILIZANDO LASER SCANNER TERRESTRE E INTELIGÊNCIA ARTIFICIAL* – os objetivos foram desenvolver um método para a reconstrução e medição de variáveis a partir da estrutura espacial de árvores, utilizando LST e estimar, por Redes Neurais Artificiais (RNA's), o volume de madeira em plantios florestais de eucalipto.
- CAPÍTULO 3  
*ESTIMAÇÃO DE VOLUME DE EUCALYPTUS EM DADOS DE SCANNER LASER TERRESTRES UTILIZANDO INTERPOLAÇÃO E MÉTODO DE*

*RANSAC* – os objetivos foram desenvolver metodologia que, a partir de dados do LST, possa identificar a estrutura espacial de árvores e estimar o volume do fuste. Para a individualização dos troncos, foi aplicada a segmentação pelo método *RANSAC*, pois os troncos possuem a forma parametrizável de um cilindro. Também foi objetivo avaliar o volume obtido pela forma direta com a forma tradicional, utilizando modelo Schumacher e Hall.

- **CONCLUSÃO GERAL** – são apresentadas as considerações finais relativas aos estudos desenvolvidos e recomendações para trabalhos futuros.

## REFERÊNCIAS BIBLIOGRÁFICAS

ASSOCIAÇÃO BRASILEIRA DOS PRODUTORES DE FLORESTAS PLANTADAS (ABRAF), 2012. **Anuário Estatístico**: Ano base 2012. Brasília: Abraf, 2012. Disponível: <http://www.ipef.br/estatisticas/relatorios/anuario-abraf13-br.pdf>. Acesso em: 10 de março 2017.

ASTRUP, R.; DUCEY, M. J.; GRANHUS, A.; RITTER, T.; VON LÜPKE, N. Approaches for estimating stand-level volume using terrestrial laser scanning in a single-scan mode. **Canadian journal of forest research**, v. 44, n. 6, p. 666-676, 2014.

EYSN, L.; PFEIFER, N.; RESSL, C.; HOLLAUS, M.; GRAFL, A.; MORSDORF, F. Practical approach for extracting tree models in forest environments based on equirectangular projections of terrestrial laser scans. **Remote Sensing**, v. 5, n. 11, p 5424-5448, 2013.

CALDERS, K.; NEWNHAM, G.; BURT, A.; MURPHY, S.; RAUMONEN, P.; HEROLD, M.; CULVENOR, D.; AVITABILE, V.; DISNEY, M.; ARMSTON, J.; KAASALAINEN, M. Nondestructive estimates of above-ground biomass using terrestrial laser scanning. **Methods in Ecology and Evolution**, v. 6, n. 2, p. 198-208, 2014.

HOPKINSON, C.; CHASMER, L.; YOUNG-POW, C.; TREITZ, P. Assessing forest metrics with a ground-based scanning lidar. **Canadian Journal of Forest Research**, v. 34, n. 3, p. 573-583, 2004.

JUPP, D. L.; CULVENOR, D. S.; LOVELL, J. L.; NEWNHAM, G. J.; STRAHLER, A. H.; WOODCOCK, C. E. Estimating forest LAI profiles and structural parameters using a ground-based laser called 'Echidna (R)'. **Tree Physiology**, v. 29, n. 2, p. 171-181, 2009.

MAAN, G. S.; SINGH, C. K.; SINGH, M. K.; NAGARAJAN, B. Tree species biomass and carbon stock measurement using ground based-LiDAR. **Geocarto International**, v. 6049, p. 1-18, July. 2014.

MAAS, H. G.; BIENERT, A.; SCHELLER, S.; KEANE, E. Automatic forest inventory parameter determination from terrestrial laser scanner data. **International Journal of Remote Sensing**, v. 29, n. 5, p. 1579-1593, 2008.

NEWNHAM, G. J.; ARMSTON, J. D.; CALDERS, K.; DISNEY, M. I.; LOVELL, J. L.; SCHAAF, C. B.; STRAHLER, A. H.; DANSON, F. M. Terrestrial laser scanning for plot-scale forest measurement. **Current Forestry Reports**, v. 1, n. 4, p. 239-251, 2015.

WILKES, P.; LAU, A.; DISNEY, M.; CALDERS, K.; BURT, A.; TANAGO, J. G.; HEROLD, M. Data acquisition considerations for Terrestrial Laser Scanning of forest plots. **Remote Sensing of Environment**, v. 196, p. 140-153, 2017.

## CAPÍTULO 2. VALIDAÇÃO ESTATÍSTICA DOS DADOS LASER SCANNER TERRESTRE PARA MEDIÇÃO DE PARCELAS DE INVENTÁRIO FLORESTAL

### Resumo:

Uma das aplicações do Laser Scanner Terrestre (LST) em engenharia florestal é na descrição do fuste das árvores em povoamentos equiâneos. O principal produto gerado pelo LST é a nuvem de pontos com coordenadas tridimensionais. Neste estudo, avaliamos a eficiência da aplicação do LST na determinação do diâmetro a 1,3 m de altura ( $d_{ap}$ ) e da altura total ( $h$ ) de árvores de clones de híbridos de *Eucalyptus urophylla* x *Eucalyptus grandis*, considerando diferentes posicionamentos do equipamento nas parcelas de inventário florestal. O equipamento LST utilizado foi um modelo VZ400 da RiEGL, e as parcelas foram mensuradas, utilizando as formas única varredura e múltiplas varreduras. As nuvens de pontos foram registradas, ajustadas ao Sistema Topográfico, redimensionada no tamanho da parcela em campo e filtradas, para a obtenção das variáveis  $d_{ap}$  e  $h$ . O teste estatístico foi empregado para avaliar a hipótese de identidade das medidas ( $d_{ap}$  e  $h$ ) obtidas pelo procedimento usual de inventário florestal com as correspondentes medidas obtidas pelo LST. Para a variável  $d_{ap}$ , os resultados mostram que são necessárias pelo menos duas posições de escaneamento, para que seja verificada a identidade dos métodos. Já para a variável  $h$ , não foi verificada a identidade dos métodos entre alturas do inventário e aquelas obtidas com o LST, em nenhuma das formas de escaneamento avaliados.

## 2.1 INTRODUÇÃO

O inventário florestal é utilizado para quantificar e qualificar estoques de madeira (CAMPOS; LEITE, 2017) e relações entre as variáveis, quantitativas e qualitativas (QUEIROZ, 2012). As duas variáveis mais importantes obtidas nas árvores individuais são o diâmetro a 1,3 m de altura (*dap*) e a altura total (*h*). O *dap* é medido diretamente com emprego de suta ou fita diamétrica; e a altura, para algumas árvores das parcelas, com emprego de hipsômetros. Duas alternativas têm sido utilizadas no Brasil para estimar a altura de árvores não mensuradas diretamente nas parcelas de inventário: regressão e redes neurais artificiais. No primeiro caso, os modelos são ajustados, utilizando dados obtidos da medição da altura de cerca de 10 árvores em cada parcela. A variável independente é o *dap* e, às vezes, a altura dominante, o índice de sítio e a idade (CAMPOS; LEITE, 2017). A determinação da altura no campo é um componente significativo do custo marginal do inventário (BINOTI, 2013).

As medidas de *dap* e *h* são utilizadas em diversas aplicações, sendo as informações primárias para quantificação da produção, da área basal, volume e para estudos de crescimento e produção. No Brasil, em povoamentos de eucalipto, teca ou pinus, são mensuradas cerca de 10 parcelas para cada hectare de povoamento, com áreas em torno de 500 m<sup>2</sup> (CAMPOS; LEITE, 2017). Em uma empresa de médio porte, chega-se facilmente a cerca de 5.000 parcelas mensuradas apenas no inventário florestal contínuo. Além disso, é comum conduzir inventários para planejamento da colheita, com intensidade de amostragem ainda maior e, também, medição de *dap* e *h* em parcelas experimentais. Portanto, qualquer método rápido e que proporcione exatidão nas estimativas de *dap* e *h* são sempre desejáveis em objetos de pesquisa.

O avanço tecnológico nos últimos anos tem proporcionado maior rapidez e precisão das informações coletadas, com destaque para o Laser Scanner Terrestre (LST), que ganhou popularidade crescente no domínio florestal e é hoje amplamente utilizado para a medição automática de atributos de inventário florestal (OTHMANI *et al.*, 2013). Os LST foram explorados inicialmente na arquitetura, mineração, geologia, engenharia civil e na indústria. Atualmente eles são aplicados para gerar as variáveis da mensuração florestal, em pesquisas de âmbito internacional (EYSN

*et al.*, 2013; RAUMONEN *et al.*, 2013; OLSOY *et al.*, 2014; MENGESHA *et al.*, 2015; LIANG *et al.*, 2016). Em nível nacional, porém, existem poucas pesquisas realizadas.

As principais vantagens dos levantamentos com LST são a rapidez na coleta de dados e a capacidade de gerar uma nuvem densa de pontos tridimensionais. Outra vantagem do uso do LST na área florestal é que ele é uma alternativa não destrutiva para mensuração de árvores. O LST apresentado no mercado de geotecnologias gera coordenadas tridimensionais (X, Y, Z) de pontos sobre uma superfície, utilizando um sistema de varredura bidimensional.

No levantamento utilizando o LST obtém-se a representação vertical para diferentes formações florestais (EYSN *et al.*, 2013). Nesse levantamento, o mapeamento das árvores é realizado no espaço tridimensional (3D), utilizando única varredura (uma estação) e múltiplas varreduras (duas ou mais estações). Para única varredura, geralmente o equipamento é posicionado no centro da parcela e a aquisição dos dados é de forma parcial em apenas um lado da árvore. Na abordagem com múltiplas varreduras, tem-se toda a superfície do tronco da árvore recoberta por pontos laser, porém os dados dos diferentes posicionamentos precisam ser corrigidos para um sistema de coordenadas comuns, através da operação de registro (ASTRUP *et al.*, 2014).

Diversas pesquisas têm demonstrado o uso de Laser Scanner Aerotransportado (LSA) na área florestal, cujo o propósito é a estimativa da biomassa e altura das árvores (GÖRGENS *et al.*, 2016; GUERRA-HERNÁNDEZ *et al.*, 2016; GÖRGENS *et al.*, 2017). Por outro lado, poucos estudos têm sido realizados com o uso de LST para extração de informações florestais. Desta forma, o objetivo desta pesquisa consiste em avaliar a utilização do equipamento do LST por única varredura e múltiplas varreduras, em relação ao método tradicional de medição de árvores em parcelas de inventário florestal.

## **2.2 SISTEMA LASER SCANNER TERRESTRE**

Nos últimos anos, o escaneamento por sistema de Laser Scanner Terrestre (LST) tem se tornado mais evidente e de extrema importância na área florestal. A aplicação de LST fornece rapidamente parâmetros como o número e a posição das árvores, o diâmetro e a altura da árvore (BIENERT *et al.*, 2006). Outros parâmetros

podem ser obtidos com o processamento da nuvem de pontos, como o diâmetro à altura do peito (*dap*) e os parâmetros de forma, como o tronco e a copa.

O Sistema LASER Scanner disponível no mercado de geotecnologias permite gerar coordenadas tridimensionais de pontos sobre uma superfície, por meio de um sistema de varredura bidimensional. Existem dois tipos de sistemas de varredura a LASER, os conhecidos como estáticos, em que o equipamento fica estacionado em um determinado local para coleta de dados, e os dinâmicos, em que o equipamento em movimento coleta os dados (WUTKE, 2006). Nesta pesquisa, serão utilizados apenas os sistemas de varredura estáticos.

Nos sistemas estáticos, existem basicamente três princípios diferentes de medida a LASER: o princípio com base na diferença de fase (*Phase-difference*); o princípio com base na triangulação (*Triangulated Scanner*); e o princípio que se baseia no intervalo de tempo decorrido desde o instante da emissão do pulso até o instante do seu retorno ao sistema, ou seja, tempo de retorno do sinal (*Time of Flight - TOF*) (WUTKE, 2006).

Ao analisar os sistemas estáticos, constata-se que o princípio com base na diferença de fase é um método de coleta mais rápido, com equipamentos que coletam até 700.000 pontos por segundo, porém, tem-se uma considerável piora da precisão para distâncias maiores que 30 metros. A triangulação é indicada para levantamentos a curta distância, com equipamentos que coletam em torno de 500 pontos por segundo, que oferecem precisões submilimétricas para distâncias até 10 metros. O método de tempo de retorno do sinal é o mais usado para aplicações a longas distâncias, podendo variar de 100 a 1.500 metros, com equipamentos que coletam até 8.000 pontos por segundo (MÁRQUEZ, 2010).


O método de tempo de retorno do sinal é o mais utilizado entre os métodos de varredura LASER Scanner Terrestre, cujo funcionamento se baseia na utilização de um feixe LASER (*Light Amplification by Stimulated Emission of Radiance*), que é emitido na direção da superfície. Ao atingir a superfície, parte desse pulso é refletida na direção do sensor, no qual o retorno é medido junto com o tempo decorrido entre a emissão do pulso e o registro do retorno. A partir do tempo de retardo ( $t$ ), a distância ( $d$ ) entre o sensor e o objeto é calculada (Equação 2.1). Junto com esse tempo, a intensidade do retorno também é medida, pois ela oferece informações a respeito das características da superfície naquele ponto (SCHILLING, 2014).

$$d = c * \frac{t}{2} \quad (2.1)$$

Onde:  $t$  é o tempo de propagação que o sinal leva para ir do transmissor ao objeto e retornar ao sistema é medido;  $d$  é a distância entre o sensor e o objeto;  $c$  é a velocidade da luz ( $c = 3,00 \times 10^8$  km/s);  $\frac{1}{2}$  é a constante utilizada, porque é considerado o tempo de ida e de retorno do sinal.

Segundo Schilling (2014), o equipamento LASER terrestre mede as distâncias, a intensidade da energia refletida pelo objeto e os parâmetros do LASER, que são coordenadas esféricas do ponto em relação ao referencial (Figura 2.1).

Figura 2.1 – Sistema de coordenadas polares do equipamento Laser Scanner



Fonte: Schilling, (2014).

De acordo com a Figura 2.1, as coordenadas esféricas do ponto P são dadas em função de  $\theta, \varphi, d$ , em que:  $\theta$  é a elevação (orientação vertical);  $\varphi$  é o azimute (orientação horizontal); e  $d$  é a distância (Equação 2.1). As coordenadas cartesianas 3D são calculadas por meio das coordenadas polares de cada ponto, como mostra o modelo matemático a seguir (Equação 2.2):

$$\begin{cases} X = d \cdot \cos\theta \cdot \sin\varphi \\ Y = d \cdot \cos\theta \cdot \cos\varphi \\ Z = d \cdot \sin\theta \end{cases} \quad (2.2)$$

Onde:  $D$  é a distância inclinada entre o LST e o objeto;  $\theta$  é o ângulo vertical;  $\varphi$  é o ângulo horizontal.

Com essas características, podem-se obter as coordenadas tridimensionais de um objeto, por meio do sistema de varredura terrestre. Essa informação pode ser utilizada para diversos fins, por exemplo, aquisição de volume em áreas florestais, seu monitoramento e outras várias aplicações no âmbito de inventário florestal.

### **2.3 PROCESSAMENTO DOS DADOS LASER APLICADO AO INVENTÁRIO FLORESTAL**

O tratamento de dados de varredura a LASER normalmente consiste em etapas similares ao processamento de imagens digitais: aquisição de dados, pré-processamento, segmentação e classificação, podendo ser automáticas, semiautomáticas ou manuais (EYSN *et al.*, 2013). Porém, antes do processamento, é necessária a análise das informações contidas na nuvem de pontos, para detectar a feição de interesse e seu respectivo posicionamento (OLSOY *et al.*, 2014).

O processo de segmentação tem como objetivo agrupar regiões ou dados similares, com base nas coordenadas ou nos valores de retorno de intensidade LASER. A segmentação pode ser feita diretamente a partir dos dados do LASER, ou a partir de *pixels* (*picture element*) ou *voxels* (*volume element*) (LINDBERG, 2012).

No caso da aplicação na área florestal, vários processos automáticos são utilizados na detecção e individualização de árvores para estimativa de biomassa. Com base no *voxel*, Olsoy *et al.* (2014) estimaram a biomassa acima do solo com dados LST para uma área experimental nos Estados Unidos. Para essa metodologia, a nuvem de pontos (3D) é dividida em *voxels* (1 cm<sup>3</sup>). Os *voxels* que retornam algum valor da vegetação recebem valor 1, e, quando estão vazios, recebem valor 0. Os *voxels* modelam superfícies descontínuas, porém os modelos de superfície, como *Triangulated Irregular Networks* (TINs) ou *Digital Elevation Models* (DEMs), apresentam único valor de Z para cada par de coordenadas X, Y.

Schilling *et al.* (2012) utilizaram dados de nuvem de pontos convertidos em *voxel* para compor imagens bidimensionais, fatiadas horizontalmente, formando uma árvore. Com essas imagens, os autores aplicaram a transformação *Hough* a cada imagem para detectar diâmetros ao longo do tronco das árvores, formando círculos ou elipses. Em seguida, um ponto de centro foi atribuído a cada objeto detectado, para conectá-los, formando assim uma linha no centro do objeto. Para eliminar

conexões incorretas, os autores aplicaram algoritmos de busca e de classificação, para finalmente extrair um esqueleto da árvore, que permitiu determinar o diâmetro da mesma.

Vonderach *et al.* (2012), usando *voxel* dos dados LST, determinaram o volume de madeira e as alturas das árvores na região de Karlsruhe, Alemanha. Inicialmente, foi aplicado filtro Kernel 3D nos dados *voxels*, para eliminar o ruído. A superfície da nuvem de pontos foi preenchida, formando o volume total da árvore, utilizando a metodologia de interseção dos *voxels*. Os autores concluíram que são necessárias nuvens de pontos com alta resolução, pois o algoritmo baseia-se em representações de superfície fechada.

Lovell *et al.* (2011), usando dados LST com base na reflectância e na continuidade espacial, propuseram uma metodologia para medir o diâmetro de árvore a partir de uma estação de posicionamento do Laser. Os troncos das árvores são alvos sólidos com continuidade espacial na direção vertical e determinada medida na direção horizontal. Assim, assumiu-se que a superfície do tronco é *Lambertiana*, isto é, reflete a luz igualmente em todas as direções. A intensidade máxima retornará quando a superfície do feixe incidente ficar próxima do ponto perpendicular, ou seja, do ponto central de um corte transversal do tronco. Desta forma, uma função que relaciona a intensidade observada com o ângulo da superfície do tronco foi utilizada, a fim de identificar as bordas da haste, para ser convertida em medida de diâmetro.

Segundo Raumonon *et al.* (2013), quando os dados LST são utilizados para identificação de árvores e quantificação de volume determinado, problemas da Ciência Florestal podem ser resolvidos se o modelo apresentar as seguintes características:

- Abrangente: abranger toda a árvore e estimar os valores nos quais não foi mapeado;
- Preciso: os atributos topológicos e suas métricas são obtidos de forma precisa;
- Compacto: o atributo e as métricas podem ser facilmente extraídos após a reconstrução das árvores;
- Automática: possibilidade de medir um grande número de árvores;
- Rápida: permitir uma modelagem rápida das árvores.

Raunonen *et al.* (2013) propuseram uma metodologia que considera as características anteriormente descritas, para modelagem de árvore em 3D com o uso do LST. Na metodologia proposta pelos autores, utiliza-se a segmentação por crescimento de regiões, para a reconstrução do cilindro que forma a árvore. Outra metodologia proposta por Srinivasan *et al.* (2014) utiliza dados temporais do LST e fornece com melhor precisão os parâmetros de inventário florestal, como diâmetro, altura, volume e afilamento do fuste em povoamentos de pinus (*Pinus taeda*).

## **2.4 MATERIAL E MÉTODOS**

### **2.4.1 Área de Estudo**

O estudo foi realizado em um povoamento de híbrido de *Eucalyptus urophylla* x *Eucalyptus grandis*, com idade aproximada de 7 anos, com espaçamento inicial de 3,0 x 2,5 m e em regime de alto fuste. A área de estudo pertence à empresa Celulose Nipo-Brasileira S.A. (Cenibra), no projeto Caxambu, localizado no município de Belo Oriente, Estado de Minas Gerais (19° 22' 25,42" sul e 42° 28' 28,27" oeste). Três parcelas da rede de parcelas do inventário de pré-corte foram selecionadas aleatoriamente. As parcelas (Figura 2.2) tinham dimensões de 21,4 x 15,2 m (parcela 1), 18,5 x 15,1 m (parcela 2) e 19,0 x 13,5m (parcela 3).

Figura 2.2 – Parcelas (1, 2 e 3) da rede de parcelas do inventário de pré-corte



Fonte: A autora.

Em cada parcela, foram medidos de forma manual o diâmetro e a altura total de todas as árvores. O *dap* foi medido com suta e a altura, com um hipsômetro *Haglof*. As frequências de árvores encontradas nas parcelas 1, 2 e 3 foram, respectivamente, 42, 36 e 24 unidades. Os dados obtidos de forma tradicional foram comparados com dados obtidos pelo LST.

#### 2.4.2 Aquisição dos Dados LST

A varredura laser consistiu na aquisição de dados pontuais de toda superfície das árvores. No levantamento realizado por equipamentos LST, pode ser destacada a alta densidade de pontos, em curto intervalo de tempo, que permite estimativas precisas. As nuvens de pontos com coordenadas tridimensionais foram obtidas das feições presentes no campo de visada do equipamento, para reconstrução da área das parcelas retangulares em campo.

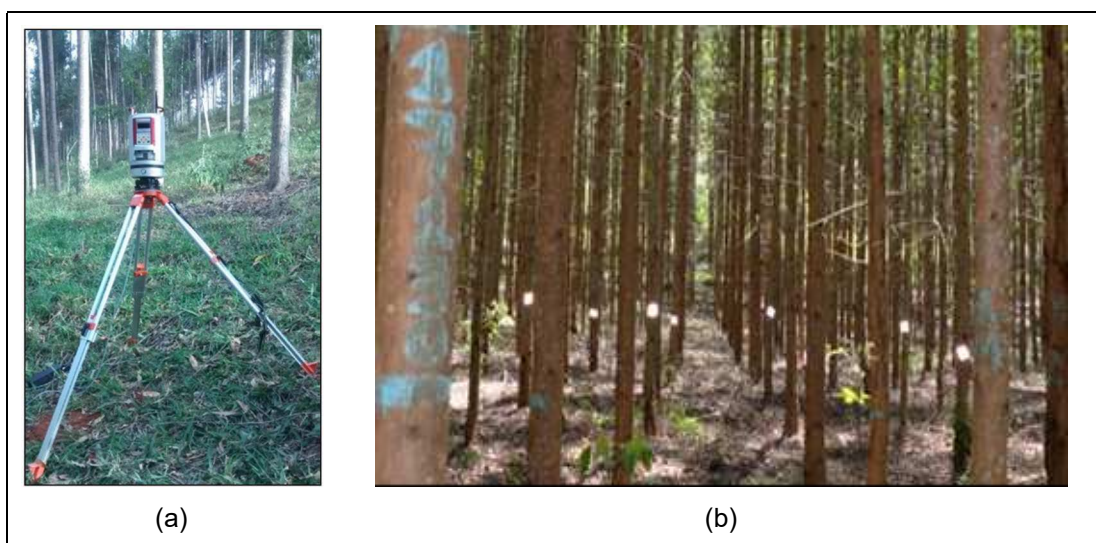
O equipamento laser scanner terrestre (LST) utilizado foi o modelo VZ-400 (Figura 2.3-a), fabricado pela *Riegl Laser Measurements GmbH*, Áustria. Este equipamento utiliza feixes laser no Infravermelho Próximo (IV próximo), não tem contato direto com os objetos escaneados e fornece alta velocidade na aquisição dos dados tridimensionais (X, Y, Z). O equipamento VZ-400 possui campo de visão -

*Field of View* (FoV): horizontal (frame) scan até 360° e vertical (frame) scan de -40° até +60°. O princípio de funcionamento do seu sensor baseia-se no tempo de retorno do sinal (*Time of Flight* - ToF).

O modo de varredura utilizado no trabalho foi o *Long Range*, com resolução angular de 0,02° (*Angle measurement resolution* = 0,02°). No *Long Range* o alcance de varredura vertical e horizontal aos objetos foram: alcances mínimo e máximo de 1 m e 600 m, respectivamente (taxa de emissão de pulso de 100Khz). No modo de varredura *Long Range*, são 42.000 pulsos por segundos com resolução e 3,5 cm a uma distância de 100 metros o equipamento para o objeto escaneado.

Ao longo da área de estudo, foram lançados 20 alvos (*targets*) conforme ilustrado na Figura 2.3-b. Esses alvos foram dispostos não linearmente e obrigatoriamente comuns a várias estações de varreduras. Desse modo, foi possível unir as cenas com precisão, em um único sistema de coordenadas local.

Figura 2.3 – (a) Equipamento Laser Scanner, modelo VZ-400; (b) Alvos refletivos instalados na área de cada parcela



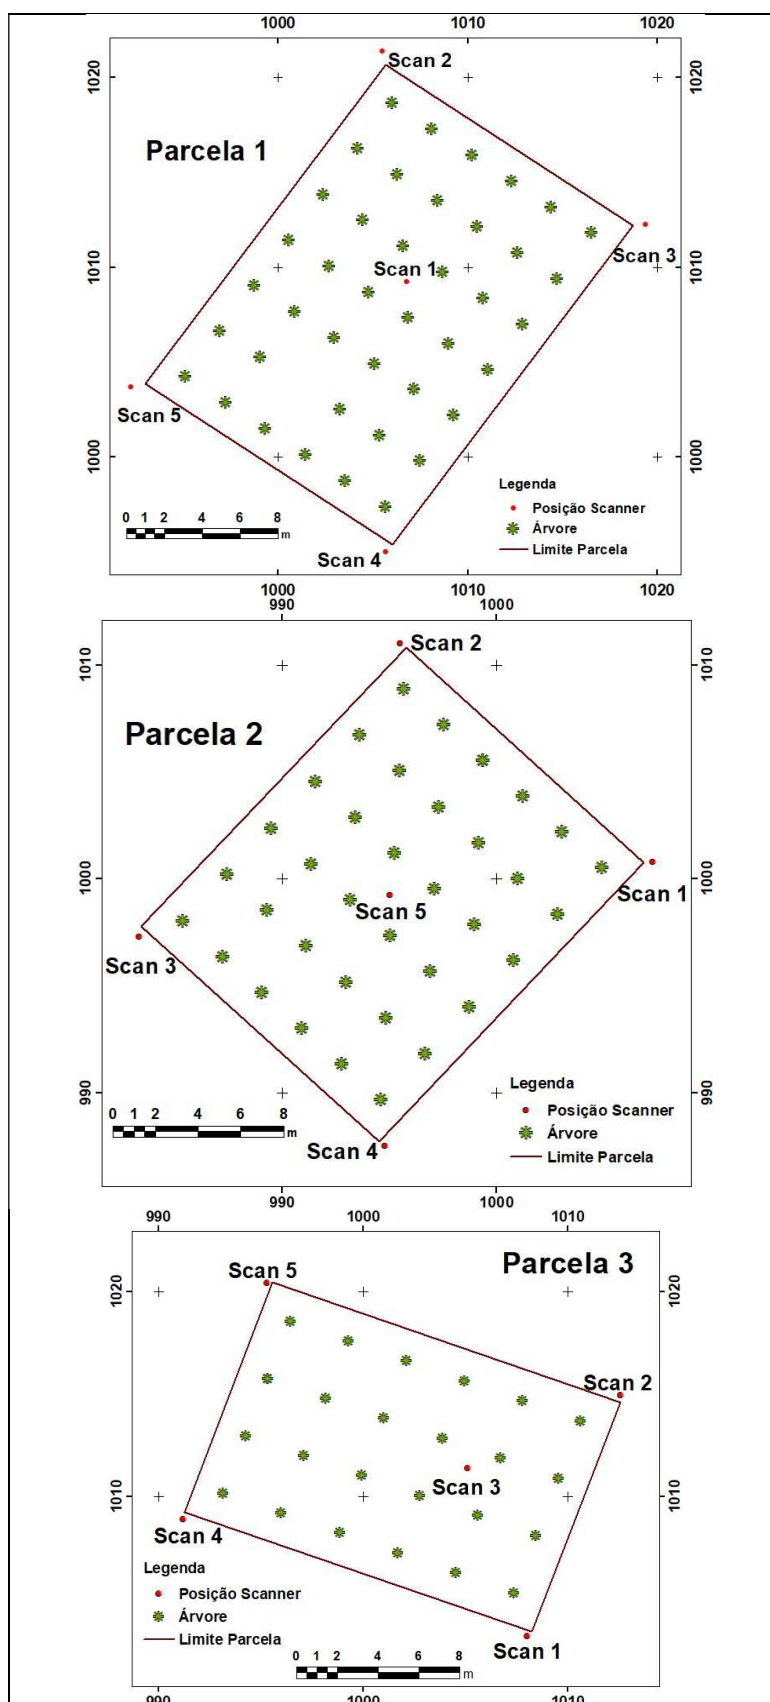
Fonte: A autora

O posicionamento do equipamento foi realizado com base na orientação das linhas de plantio. As medidas *dap* e *h* foram validadas, utilizando duas formas de posicionamento do equipamento LST. Na primeira, o equipamento foi instalado em apenas um ponto na posição central da parcela com única varredura (Figura 2.4). O uso do modo única varredura pode causar efeitos de oclusão, baixa densidade de pontos e, em certos locais da parcela, grande quantidade de ruídos (LIANG *et al.*,

2016). Por isso, esses autores sugeriram o modo múltiplas varreduras para contornar estes efeitos. Assim, o equipamento foi instalado em duas (Scan 2 e 4) e em cinco posições/estações (Scan 1 a 5), modo múltiplas varreduras, para garantir abrangência completa de todas as árvores presentes em cada parcela. Para cada posição foi realizada uma varredura de 360° (Figura 2.4).

Uma câmera calibrada foi integrada ao LST para facilitar a análise visual das nuvens de pontos. Desta forma, cada ponto da nuvem é possível obter a “cor real”, baseada nos valores de RGB (*Red*, *Green* e *Blue*) das fotografias obtidas pela câmera modelo Nikon D700.

Figura 2.4 – Disposição do posicionamento do equipamento para as parcelas 1, 2 e 3



Fonte: A autora.

### 2.4.3 Métodos

O pré-processamento e processamento dos dados foi realizado no *software* RiSCAN-PRO RiEGL Laser Measurements GmbH, Áustria, que acompanha os equipamentos LST da série VZ. Este sistema possui diversos módulos que permitem o gerenciamento e o processamento das nuvens de pontos. O RiSCAN-PRO foi utilizado para configuração do sensor, aquisição de dados, visualização, manipulação, pré-processamento e processamento dos dados com coordenadas tridimensionais e intensidades dos pontos.

O pré-processamento das nuvens de pontos foi realizado sob os dados brutos obtidos no campo, sendo dividido nas seguintes fases: registro, modificação da orientação, ajustamento multi-estação (*Multi Station Adjustment* - MSA) e recorte da parcela no tamanho pré-definido.

O registro foi realizado com as coordenadas dos posicionamentos das estações do equipamento, consistindo na unificação das nuvens de pontos sob um mesmo sistema de coordenadas local referenciadas ao centro de fase do sensor. A função registro foi determinada de forma automática com a posição e orientação do laser com base em pontos de controle correspondentes. No modo única varredura não foi necessário o registro, enquanto no modo múltiplas varreduras (duas posições e cinco posições) foi necessário fazer a junção das cenas por meio do processamento de registro ou da consolidação de nuvem de pontos. As coordenadas topográficas utilizadas no pré-processamento foram obtidas pelo levantamento topográfico por poligonação com estação total.

A fase do Registro não garante que todos os dados de varredura (objetos de interesse) fiquem alinhados devido a diversos erros ocasionados no momento do levantamento. Para contornar este problema, o RiSCAN-PRO tem um *plug-in* denominado ajustamento multiestação (*Multi Station Adjustment* - MSA), com iteração do ajustamento a cada duas posições e inserindo a cada novo processamento mais duas posições. A modificação da orientação foi feita de forma manual, modificando apenas a rotação em relação ao eixo Z, visando garantir o posicionamento correto de todos os pontos da nuvem (X, Y, Z). Após o ajustamento

de todas as posições foi feito o recorte do *polydata*<sup>2</sup> no tamanho pré-definido de cada parcela.

Após pré-processamento dos dados, com as três parcelas delimitadas de acordo com suas áreas, foi necessário proceder ao processamento delas, para a obtenção da variável *dap*. Para garantir a medida em conformidade com as medições do *dap*, foi definido um plano que continha os pontos do terreno, e, a partir dele, delimitou-se uma altura pré-definida (1,3 m de altura). Dois filtros foram aplicados: *Height filter* e *Octree filter*. O *Height filter* consiste na classificação da nuvem de pontos do LST como pertencentes ou não-pertencentes à superfície do terreno.


O filtro *Octree filter* foi aplicado para diminuir a densidade da nuvem de pontos. Esse filtro torna a nuvem de pontos mais homogênea e menos densa, sem comprometer a qualidade dos dados. Ele funciona como uma estrutura de dados hierárquica que define subdivisões de um espaço tridimensional em cubos, chamados de *voxels*. O *voxel* inicial, que normalmente cobre todo o domínio do espaço a ser estudado, é dividido em oito partes iguais, sendo que os novos cubos são chamados de *voxels* filhos. Estes, por sua vez, podem ser subdivididos da mesma forma, num processo recursivo, cujo limite pode ser definido previamente, por exemplo, tamanho mínimo do *voxel* (NIEßNER et al., 2013). A variável *dap* deve ser medida a 1,30 m de altura, portanto, com a árvore ainda em pé, e por isso os planos foram posicionados nesta medida (1,3 m) seccionando todas as árvores presentes em cada parcela.

Sobre os dados obtidos no método única varredura do LST, não foi necessário nenhum pré-processamento, sendo efetuado apenas o processamento para a obtenção do plano, para garantir as medidas do *dap* para cada árvore de cada parcela. Para duas e cinco diferentes posições, foram realizadas todas as fases do pré-processamento e do processamento. A obtenção da variável altura total *h* foi obtida diretamente sobre cada árvore presente em cada parcela (Figura 2.5).

---

<sup>2</sup> *Polydata* representa uma estrutura geométrica, consistindo de vértices, linhas, polígonos e triangulação de superfície

Figura 2.5 – Representação das variáveis *dap* e *h* obtidas pelo processamento de dados LST



Fonte: Soares *et al.*, (2011).

#### 2.4.4 Análise Estatística

Os diâmetros e alturas das árvores obtidos pela nuvem de pontos foram comparados com as correspondentes medidas obtidas na medição direta (com suta e hipsômetro). Estas comparações foram feitas empregando o procedimento estatístico proposto por Leite e Oliveira (2002). Esse procedimento é indicado para avaliar a identidade de métodos analíticos e consiste em uma regra decisória definida pela combinação do teste F de Graybill (GRAYBILL, 1972) e o teste *t* para erro relativo médio ( $t_{\bar{e}}$ ) e da análise do coeficiente de correlação linear ( $r_{y_1y_1}$ ) entre os valores dos métodos comparados. Com base nessas estatísticas (LEITE; OLIVEIRA, 2002), é proposta uma regra de decisão para o teste entre dois vetores quaisquer, ou seja, grupos de dados quantitativos. Sendo ( $Y_1$ ) e ( $Y_j$ ) dois vetores quantitativos, sendo  $Y_1$  o valor obtido no inventário (para as variáveis *dap* e *h*) e  $Y_j$  o valor correspondente obtido com o LST, foram representados através da Equação 2.3.

$$Y_1 = \begin{bmatrix} Y_{11} \\ Y_{12} \\ \vdots \\ Y_{1n} \end{bmatrix}; Y_j = \begin{bmatrix} Y_{j1} \\ Y_{j2} \\ \vdots \\ Y_{jn} \end{bmatrix} \quad (2.3)$$

A relação entre  $Y_1$  e  $Y_j$  pode ser matricialmente expressa por  $Y_j = Y_1\beta + \varepsilon$ , em que os coeficientes da correlação linear ( $r_{y_j y_1}$ ) estão representados na Equação 2.4:

$$\beta = \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix}; \varepsilon = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix} \quad (2.4)$$

sob a hipótese de normalidade (Equação 2.5):

$$F(H_0) = \frac{(\beta - \theta)'(Y_1'Y_1)(\beta - \theta)}{2QMR} \sim F_\alpha(2, n - 2 \text{ g.l.}) \quad (2.5)$$

no qual (Equação 2.6):

$$\beta = \begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \end{bmatrix}, \theta = \begin{bmatrix} 0 \\ 1 \end{bmatrix} \text{ e } Y_1'Y_1 = \begin{bmatrix} n & \sum Y_1 \\ \sum Y_1 & \sum Y_1^2 \end{bmatrix} \quad (2.6)$$

Onde QMR é o quadrado médio dos resíduos da regressão  $Y_i = \beta_0 + \beta_1 Y_1 + e$ .

A estatística  $F$  é utilizada para testar a hipótese  $H_0 : \beta' = [0,1]$ , sendo que  $F(H_0) \geq F_\alpha(2, n - 2 \text{ g.l.})$  a hipótese é rejeitada e se  $F(H_0) < F_\alpha(2, n - 2 \text{ g.l.})$ , a hipótese nula não é rejeitada, admitindo-se a possibilidade de aceitação de  $H_0$ , ou seja,  $Y_1 = Y_j$  em nível  $\alpha$  de significância. Mas o procedimento inclui ainda o teste  $t$  para a nulidade do erro relativo e a análise do coeficiente de correlação (Tabela 2.1). Quando o erro médio não é significativo, é também necessário que o valor da correlação do coeficiente seja mais alto do que  $(1 - |\bar{e}|)$  e que  $F(H_0)$  seja não significativo. A regra 5 da Tabela 2.1 pode ser aceitável em alguns casos, principalmente quando o quadrado médio do resíduo (QMR) é muito pequeno. Nesse caso, o valor de  $F(H_0)$  tende a ser alto e, portanto, significativo. Esse fato pode ocorrer quando os resultados dos dois métodos são extremamente próximos (LEITE; OLIVEIRA, 2002).

Tabela 2.1 – Regras de decisão para comparação entre a metodologia tradicional e a metodologia alternativa (LST) pelo teste

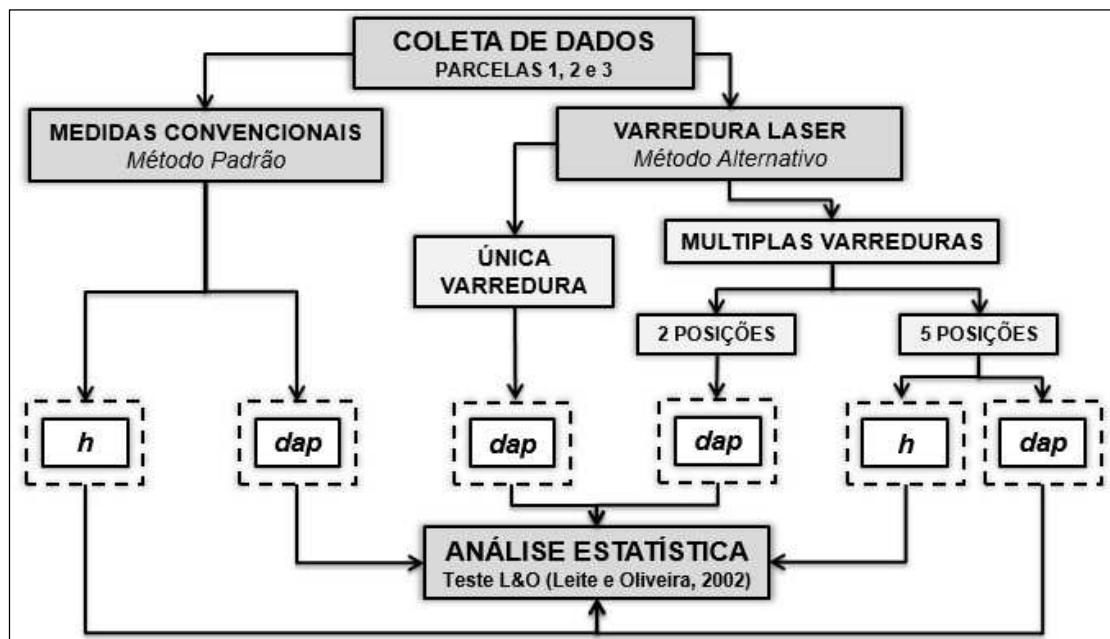
Situação	$F(H_0)$	$t_{\bar{e}}$	$r_{y_j y_1}$	Decisão
1	ns	ns	$r_{y_j y_1} \geq 1 -  \bar{e} $	$Y_j = Y_1$
2	ns	ns	$r_{y_j y_1} \leq 1 -  \bar{e} $	$Y_j \neq Y_1$
3	ns	*	$r_{y_j y_1} \geq 1 -  \bar{e} $	$Y_j \neq Y_1$
4	ns	*	$r_{y_j y_1} \leq 1 -  \bar{e} $	$Y_j \neq Y_1$
5	*	ns	$r_{y_j y_1} \geq 1 -  \bar{e} $	$Y_j \neq Y_1$
6	*	ns	$r_{y_j y_1} \leq 1 -  \bar{e} $	$Y_j \neq Y_1$
7	*	*	$r_{y_j y_1} \geq 1 -  \bar{e} $	$Y_j \neq Y_1$
8	*	*	$r_{y_j y_1} \leq 1 -  \bar{e} $	$Y_j \neq Y_1$

ns e \* denotam, respectivamente, diferenças não significativas e significativas a um nível de significância preestabelecido (LEITE; OLIVEIRA, 2002).

Fonte: A autora.

A análise estatística foi dividida em duas etapas. A primeira etapa consistiu na comparação entre os diâmetros ( $dap$ ) obtidos pelo método usual de inventário com os correspondentes obtidos com o LST para única varredura (Fluxograma 2.1). Na segunda etapa, foram comparados os diâmetros ( $dap$ ) e alturas totais ( $h$ ) obtidos no inventário com os correspondentes valores obtidos com o LST para múltiplas varreduras, conforme mostrado na Fluxograma 2.1 com os conectores

Fluxograma 2.1 – Análise estatística pelo método Leite e Oliveira (2002), aplicado à análise dos resultados das variáveis *dap* e *h*



Fonte: A autora.

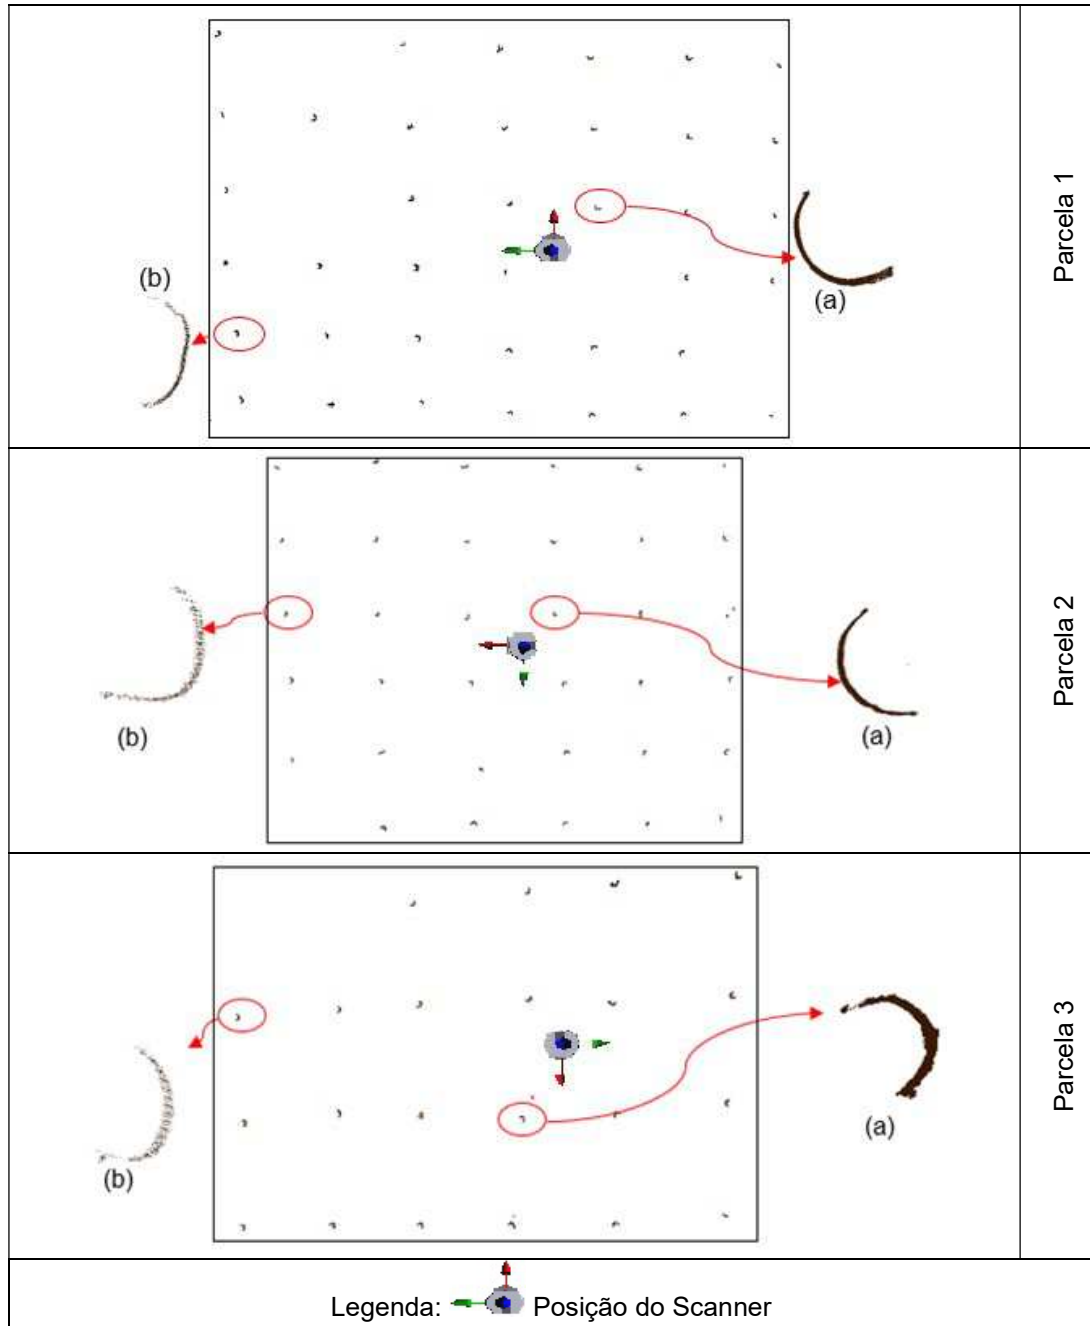
## 2.5 RESULTADOS

### 2.5.1 Única Varredura

Ao empregar o modo única varredura, foi delimitada uma área retangular referente ao tamanho de cada parcela. Os valores das variáveis *dap* e altura total *h* para única varredura estão disponíveis nos Apêndices A, B e C. Como não houve mudança na posição do equipamento LST apenas parte do fuste é levantada, representado por um semicírculo: parcela 1, parcela 2 e parcela 3 (Figura 2.6).

Os dados brutos obtidos por única varredura apresentam maior densidade de pontos próximos ao centro da varredura (Figura 2.6). À medida que aumenta a distância das árvores em relação ao equipamento, a quantidade de pontos observados é menor. Apesar dessas limitações, cabe lembrar que o uso de uma única varredura não requer na etapa de pré-processamento o registro dos escaneamentos, tornando o processo mais rápido em relação ao processamento com múltiplas varreduras.

Figura 2.6 – Parcelas 1, 2 e 3 representadas no espaço bidimensional em uma seção transversal com vista superior a 1,3m de altura do terreno. (a) árvore próxima ao equipamento e (b) árvore na extremidade da parcela



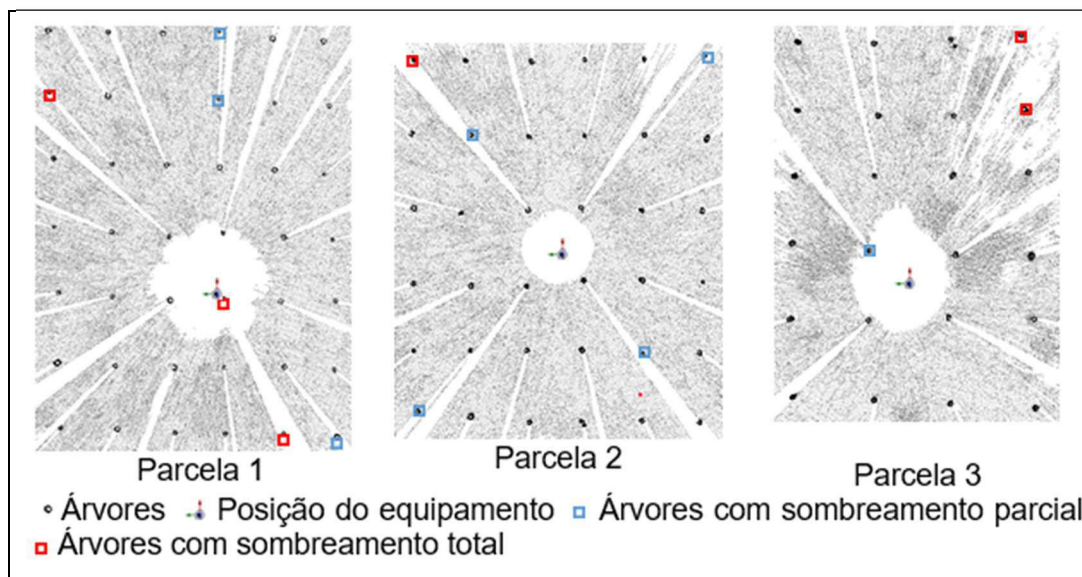
Fonte: A autora.

Com o modo única varredura foi possível obter apenas o *dap*, devido ao efeito de sombreamento, esse efeito ocorre devido ao posicionamento regular das árvores. Os resultados indicaram subestimação do *dap*, em relação aos valores obtidos pelo método usual de medição (fita). O efeito de sombreamento é maior nas bordas das parcelas, pois essas árvores ficam ocultas por causa do sombreamento de pontos

ocasionado, principalmente, por árvores mais próximas ao equipamento (ZASADA *et al.*, 2013; BUCK *et al.*, 2017). A altura  $h$  não foi obtida, pois com apenas uma posição não foi garantido o escaneamento total do fuste devido ao campo de visão vertical do equipamento VZ400 e pelo sombreamento das árvores vizinhas.

Na Figura 2.7 está ilustrada a distribuição espacial das árvores na nuvem de pontos de múltiplas varreduras, vista de topo, sendo possível determinar a localização de cada árvore para cada parcela (parcelas 1, 2 e 3). Algumas árvores foram sombreadas totalmente para única varredura. Na parcela 1, foram bloqueadas três árvores; na parcela 2, foi bloqueada uma árvore; e na parcela 3, foram duas árvores bloqueadas. Além do bloqueio das árvores, o sombreamento parcial de algumas árvores ocasionou falhas, resultando em inexatidão na mensuração da variável  $dap$  (Figura 2.7).

Figura 2.7 – Croquis do posicionamento das árvores para cada parcela para o modo única varredura com o equipamento LST, vista de topo



Fonte: A autora.

## 2.5.2 Múltiplas Varreduras

Para contornar os problemas de sombreamento de árvores vizinhas, as variáveis  $dap$  e  $h$  foram coletadas por meio de múltiplas varreduras (LIANG *et al.*, 2016) em duas posições e em cinco posições. Para obter melhor sobreposição de pontos homólogos na cena foi posicionado em duas posições opostas na parcela.

Com os posicionamentos no modo múltiplas varreduras, foram escaneadas 100% das árvores presentes em cada parcela. Os valores das variáveis *dap* e altura total *h* para múltiplas varreduras estão disponíveis nos Apêndices A, B e C.

Portanto, o uso de múltiplas varreduras apresenta como vantagem a identificação de todas as árvores. Por outro lado, o tempo de varredura em campo é maior e o processamento é moroso pelo aumento de pontos da nuvem.

### 2.5.3 Validação

No Gráfico 2.1 e na Tabela 2.2, são apresentados os diagramas de dispersão, ilustrando a relação entre a variável *dap*, obtida no inventário de pré-corte, e pela metodologia proposta nesta pesquisa (LST). Observa-se que o modo única varredura forneceu os menores valores de coeficiente de correlação ao analisar uma regressão linear entre as variáveis. Os coeficientes de correlação estimados foram iguais a 0,8601 (parcela 1), 0,8948 (parcela 2) e 0,8098 (parcela 3).

Os menores coeficientes de correlação podem ter ocorrido devido ao problema de sombreamento das árvores localizadas nas bordas das parcelas bem como o bloqueio total em algumas árvores (Tabela 2.2). No Gráfico 2.1, são observados pontos bem distantes da reta ajustada para o modo única varredura, para a variável *dap*, e o modo múltiplas varreduras, para a variável *h*, relacionados com os menores valores dos coeficientes de correlação.

Os escaneamentos obtidos com múltiplas varreduras forneceram os maiores valores do coeficiente de correlação em comparação com o modo única varredura (Tabela 2.2). Os valores foram de 0,9974 (parcela 1), 0,9960 (parcela 2) e 0,9932 (parcela 3) para escaneamento com duas posições. Para cinco posições, os coeficientes de correlação variaram 0,9986 (parcela 1), 0,9973 (parcela 2) e 0,9956 (parcela 3).

Para a variável altura, os coeficientes de correlação ( $r_{y_j y_1}$ ) para as múltiplas varreduras com cinco posições foram de 0,8883 (parcela 1), 0,9224 (parcela 2) e 0,8417 (parcela 3). O coeficiente de correlação analisado separadamente não é suficiente para testar com eficácia a identidade da variável obtida por diferentes métodos (LEITE; OLIVEIRA, 2002). Dessa forma, a hipótese de identidade entre os dois métodos foi testada, empregando o procedimento estatístico proposto por Leite

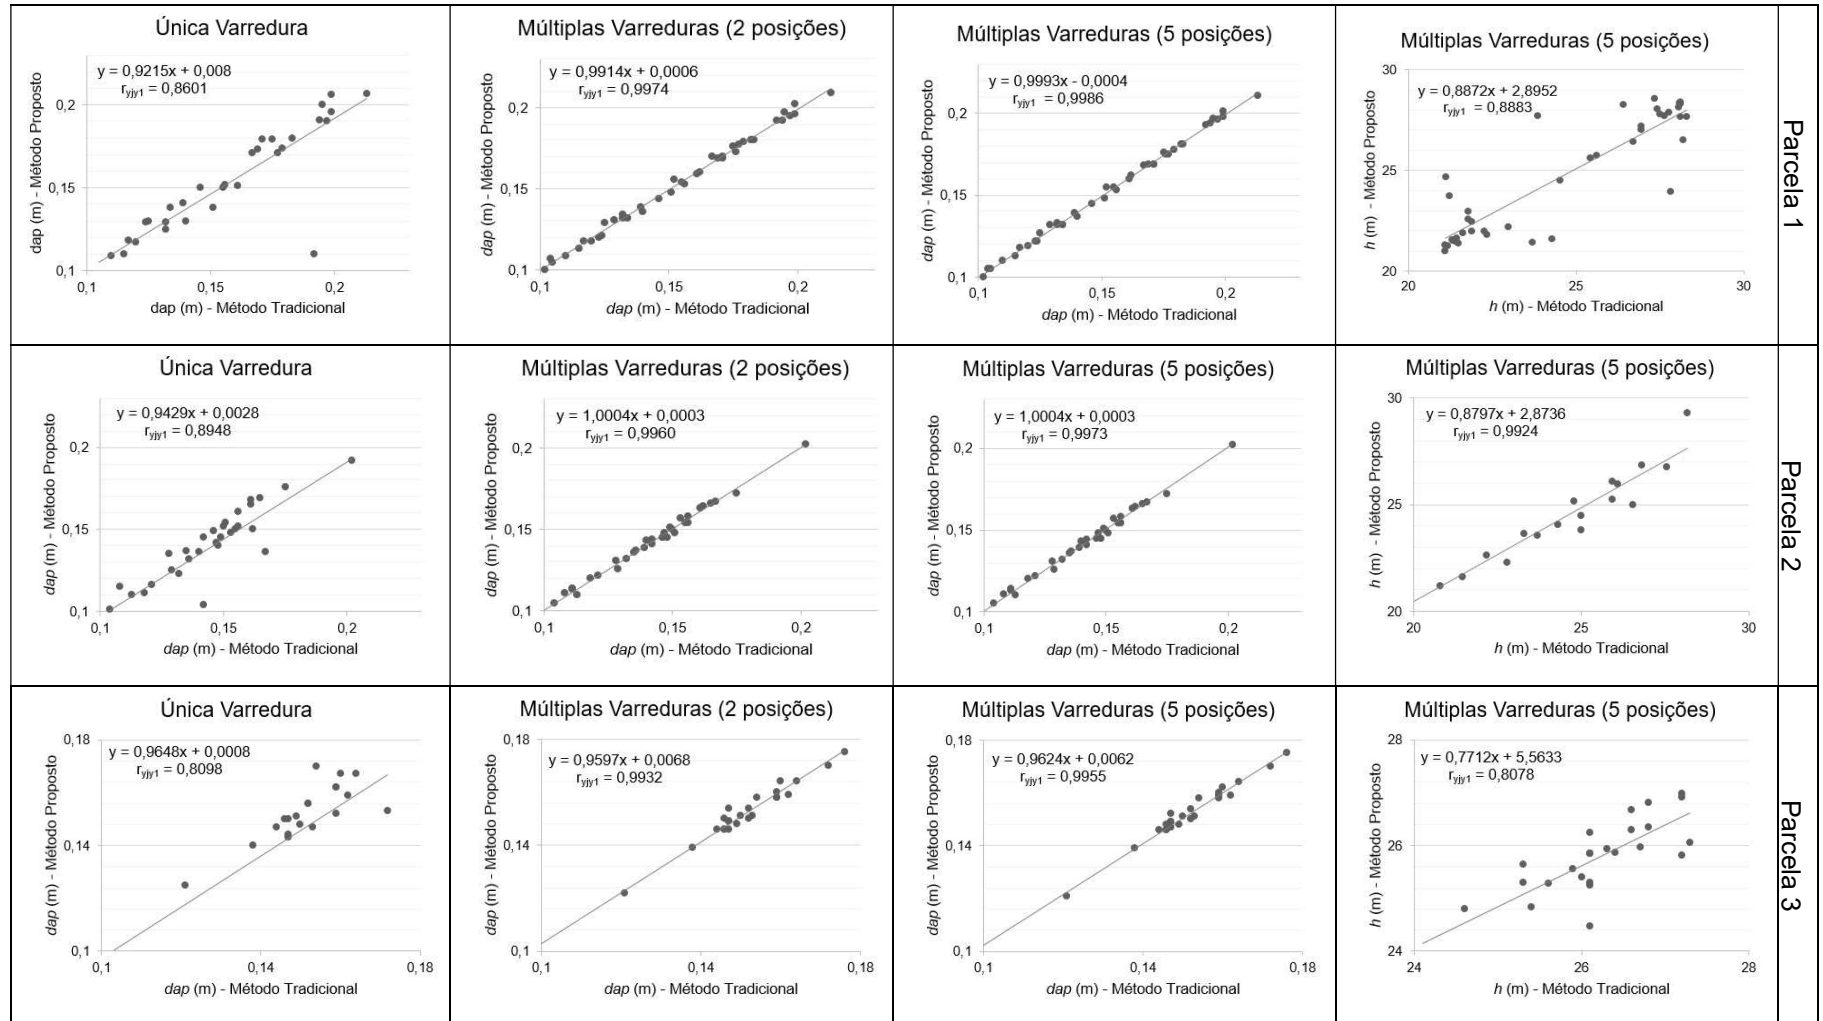
e Oliveira (2002) (Tabela 2.2). Esse método tem sido utilizado para avaliar a identidade entre métodos analíticos em diferentes estudos (LIMA *et al.*, 2011; SERRA *et al.*, 2012; CURTO *et al.*, 2014; SATO *et al.*, 2015; ROVEDA *et al.*, 2016; SILVA *et al.*, 2016; HAKAMADA *et al.*, 2017).

Ao analisar a hipótese de igualdade para a variável  $h$ , a opção foi rejeitada, a um nível de significância de 5% ( $p < 0,05$ ), considerando a igualdade empregada para todos os métodos. A identidade não foi verificada devido a não verificação da condição  $r_{y_j y_1} \geq 1 - |\bar{e}|$  (Tabela 2.2). A acurácia na aquisição da variável  $h$  foi influenciada pelo sombreamento, devido à altura das árvores, e pela ocorrência de vento no momento do levantamento.

A hipótese de igualdade entre os diâmetros ( $dap$ ) obtidos com única varredura também diferiram pelo procedimento de Leite e Oliveira (2002) (Tabela 2.2). A baixa acurácia na mensuração da variável  $dap$  com única varredura também pode ter sido consequência do sombreamento, que bloqueou algumas árvores e também resultou em falhas de algumas árvores. Conforme ilustrado na Figura 2.9, a dispersão foi ampla no método única varredura. Na Tabela 2.2, observam-se outros casos, para  $h$ , que não passaram no teste devido à presença de viés.

Para as estimativas de  $dap$  do inventário obtidas a partir do LST com múltiplas varreduras (duas e cinco posições) foi verificada a igualdade ( $p > 0,05$ ) com os valores obtidos pelas medidas convencionais (Tabela 2.2). De acordo com o procedimento proposto por Leite e Oliveira (2002), quando as duas hipóteses são testadas e aprovadas ao mesmo tempo, nesses casos os dados analisados apresentaram estimativas acuradas e precisas.

Gráfico 2.1 – Gráficos de dispersão das variáveis dap e h para as parcelas 1, 2 e 3



Fonte: A autora.

Tabela 2.2 – Resumo dos resultados obtidos ao aplicar o procedimento estatístico proposto para comparação de vários métodos analíticos, Leite e Oliveira (2002)

	Parcela 1				Parcela 2				Parcela 3				
	5 scans		2 scans		1 scan		5 scans		2 scans		1 scan		
	<i>dap</i>	<i>h</i>	<i>dap</i>	<i>Dap</i>	<i>dap</i>	<i>h</i>	<i>dap</i>	<i>Dap</i>	<i>dap</i>	<i>h</i>	<i>dap</i>	<i>dap</i>	
n	41	41	41	38	37	37	37	36	25	25	25	23	
Parâmetros	$\beta_0$	0,0013	1,8150	0,0018	0,0142	0,0017	1,3659	0,0021	0,0113	0,0028	3,0002	0,0035	0,0225
	$\beta_1$	0,0082	0,0735	0,0114	0,0902	0,0124	0,0623	0,0149	0,0807	0,0189	0,1146	0,0235	0,1509
	$r_{y_j y_1}$	0,9986	0,8883	0,9974	0,8601	0,9973	0,9224	0,9960	0,8948	0,9956	0,8417	0,9932	0,8098
	$r^2$	0,9973	0,7890	0,9949	0,7398	0,9946	0,8509	0,9921	0,8006	0,9912	0,7084	0,9864	0,6558
	RMS	<0,001	1,7668	<0,001	<0,001	<0,001	1,3794	<0,001	<0,001	<0,001	0,1976	<0,001	<0,001
	Erro Médio ( $\bar{e}$ )	-0,0032	0,0071	-0,0048	-0,0302	0,0027	0,0146	0,0041	-0,0351	0,0052	-0,0119	0,0071	-0,0129
	Erro-Padrão do ( $\bar{e}$ )	0,0017	0,0089	0,0024	0,0164	0,0026	0,0010	0,0030	0,0164	0,0029	0,0034	0,0034	0,0194
	Módulo (Erro Médio)	0,9968	0,9929	0,9952	0,9698	0,9973	0,9854	0,9959	0,9649	0,9948	0,9881	0,9929	0,9871
	F( $H_0$ )	1,8648 <sup>ns</sup>	1,3649 <sup>ns</sup>	2,6599 <sup>ns</sup>	2,1350 <sup>ns</sup>	0,6241 <sup>ns</sup>	2,7786 <sup>ns</sup>	1,1282 <sup>ns</sup>	2,9125 <sup>ns</sup>	3,3087 <sup>ns</sup>	7,0489*	3,3278 <sup>ns</sup>	0,2874 <sup>ns</sup>
	$t_{\bar{e}}$	1,8817 <sup>ns</sup>	0,7943 <sup>ns</sup>	1,9957 <sup>ns</sup>	1,8366 <sup>ns</sup>	1,0453 <sup>ns</sup>	1,4633 <sup>ns</sup>	1,3611 <sup>ns</sup>	2,1447 <sup>ns</sup>	1,7517 <sup>ns</sup>	3,4931*	2,0661 <sup>ns</sup>	0,6660 <sup>ns</sup>
	$r_{y_j y_1} \geq 1 -  \bar{e} $	Sim	Não	Sim	Não	Sim	Não	Sim	Não	Sim	Não	Sim	Não
	Conclusão	$Y_j = Y_1$	$Y_j \neq Y_1$	$Y_j = Y_1$	$Y_j \neq Y_1$	$Y_j = Y_1$	$Y_j \neq Y_1$	$Y_j = Y_1$	$Y_j \neq Y_1$	$Y_j = Y_1$	$Y_j \neq Y_1$	$Y_j = Y_1$	$Y_j \neq Y_1$

\* Significativo a 5% de probabilidade e <sup>ns</sup> não-significativo.

Fonte: A autora.

## 2.6 DISCUSSÃO

A finalidade do presente trabalho foi a avaliação por métodos estatísticos das variáveis *dap* e *h* obtidas por medição direta no inventário florestal, com as correspondentes variáveis obtidas utilizando Laser Scanner Terrestre (LST) por única varredura e múltiplas varreduras. As comparações foram efetuadas em relação ao método tradicional de inventário, no qual os diâmetros e alturas das árvores de cada parcela são mensurados, utilizando suta (ou fita) e hipsômetro, respectivamente. Os resultados mostraram que o LST, além de permitir mapear a distribuição espacial das árvores nas parcelas, fornece estimativas precisas para os diâmetros (*dap*).

Os testes realizados no presente estudo demonstraram que as estimativas de *dap* obtidas com escaneamento laser com múltiplas varreduras (com duas e com cinco posições) não diferem ( $p > 0,05$ ) das medidas obtidas pelo método tradicional de inventário. Os valores de *dap* obtidos com múltiplas varreduras com duas posições demonstraram ser precisos e com maior densidade de pontos, assim como os diâmetros obtidos com múltiplas varreduras com cinco posições. Porém, o escaneamento com cinco posições demanda maior tempo na coleta e processamento dos dados e conseqüentemente um maior custo.

Os valores de *dap* obtidos com o modo única varredura foram diferentes daqueles obtidos pelo método tradicional. Isto ocorreu devido ao sombreamento de árvores, que resultou também em subestimação das alturas. As alturas (*h*) obtidas com LST múltiplas varreduras apresentaram diferença estatística ( $p > 0,05$ ) das correspondentes alturas obtidas pelo método tradicional de inventário.

Uma vantagem relativa do emprego de LST é a possibilidade de ampliar o tamanho das parcelas, utilizando um raio suficiente para não haver sombreamento e sobreposição dos fustes. Esta ampliação, no método tradicional, é muitas vezes inviável em termos econômicos. Por isso, a área das parcelas de inventário de eucalipto no Brasil tem sido inferior a 500 m<sup>2</sup>. Parcelas maiores resultam em menor variância da produção entre parcelas. Isto é interessante no caso de estimação de intervalos de confiança para o estoque de madeira e também para modelagem do crescimento e da produção (CAMPOS; LEITE, 2017).

Outra vantagem do uso do LST na área florestal é que ele é uma alternativa não destrutiva para mensuração de árvores, pois este método permite a determinação do volume da árvore em pé. Desta forma, sugere-se para trabalhos futuros a extração de outras variáveis, como os diâmetros em diferentes alturas ao longo do tronco dos fustes para o cálculo de volume das árvores.

Os resultados deste estudo permitem concluir que o LST é eficiente para determinação do diâmetro das árvores em parcelas de inventário e que é importante conduzir novas pesquisas visando a estimação da altura total. Os resultados aqui obtidos apontam para uma aplicação que consiste em utilizar o sistema LST para obter os diâmetros, em parcelas com áreas bem maiores do que aquelas usuais em inventário florestal. Embora não tenha sido testado neste estudo, resultados já publicados (BINOTI *et al.*, 2012, BINOTI *et al.*, 2013; MARTINS *et al.*, 2016), mostram que a altura das árvores cujos diâmetros tenham sido mensurados pelo LST podem ser estimadas empregando redes neurais artificiais, com um esforço amostral menor para amostragem de alturas.

## 2.7 CONCLUSÃO

O objetivo deste estudo foi avaliar, por meio de métodos estatísticos, as variáveis de medição direta do Inventário Florestal, *dap* e *h*, com as variáveis correspondentes obtidas, usando única varredura e múltiplas varreduras do Laser Scanner Laser (LST). As comparações foram feitas em relação ao método tradicional de inventário, em que os diâmetros e as alturas das árvores de cada parcela são medidos usando suta e o hipsômetro *Haglof*, respectivamente. Os resultados mostraram que o LST, além de permitir mapear a distribuição espacial das árvores nas parcelas, fornece estimativas precisas para os diâmetros (*dap*) quando se utiliza duas ou mais estações do LST. Em relação à altura (*h*), foi verificada uma limitação em relação ao adensamento das copas das árvores, ocasionando o sombreamento delas.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ASTRUP, R.; DUCEY, M. J.; GRANHUS, A.; RITTER, T.; VON LÜPKE, N. Approaches for estimating stand-level volume using terrestrial laser scanning in a single-scan mode. **Canadian journal of forest research**, v. 44, n. 6, p. 666-676, 2014.
- BIENERT, A.; SCHELLER, S.; KEANE, E.; MULLOOLY, G.; MOHAN, F. Application of terrestrial laser scanners for the determination of forest inventory parameters. **International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 36, n. 5, 2006.
- BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G. SILVA, A. Redução dos custos em inventário de povoamentos equiâneos utilizando redes neurais artificiais. **Revista Brasileira de Ciências Agrárias - Agrária**, v. 8, n. 1, p. 125- 129, 2012.
- BINOTI, M. L. M. S.; BINOTI, D. H. B.; LEITE, H.G. Aplicação de redes neurais artificiais para estimação da altura de povoamentos equiâneos de eucalipto. **Revista Árvore**, v.37, n.4, p.639-645, 2013.
- BUCK, A. L. B.; LINGNAU, C.; MACHADO, Á. M. L.; NETTO, S. P. Detecção de árvores em nuvens de pontos de varredura laser terrestre. **Boletim de Ciências Geodésicas**, v.23, n.1, p. 21-38, 2017
- CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal: perguntas e respostas**. Viçosa, MG: Ed. UFV, 5 ed., 2017. 636 p.
- CURTO, R. A.; LOUREIRO, G. H.; MÔRA, R.; MIRANDA, R. O. V.; PÉLLICO NETTO, S.; SILVA, G. F. Hypsometric relations in semideciduous seasonal forest. **Revista de Ciências Agrárias/Amazonian Journal of Agricultural and Environmental Sciences**, v. 57, n. 1, p. 57-66, 2014.
- EYSN, L.; PFEIFER, N.; RESSL, C.; HOLLAUS, M.; GRAFL, A.; MORSDORF, F. Practical approach for extracting tree models in forest environments based on equirectangular projections of terrestrial laser scans. **Remote Sensing**, v. 5, n. 11, p 5424-5448, 2013. Disponível em: <http://dx.doi.org/10.3390/rs5115424>. Acesso em: 23 fev. 2017.
- GÖRGENS, E. B.; SOARES, C. P.; NUNES, M. H.; RODRIGUEZ, L. C. Characterization of Brazilian forest types utilizing canopy profiles derived from airborne laser scanning. **Applied Vegetation Science**, v. 19, n. 3, p. 518-527, 2016.
- GÖRGENS, E. B.; VALBUENA, R.; RODRIGUEZ, L. C. E. A Method for Optimizing Height Threshold When Computing Airborne Laser Scanning Metrics. **Photogrammetric Engineering & Remote Sensing**, v. 83, n. 5, p. 343-350, 2017.

GRAYBILL, F. A. **Theory and application of the linear model**. Belmont: Duxbury Press, 1976. 704p.

GUERRA-HERNÁNDEZ, J.; GÖRGENS, E. B.; GARCÍA-GUTIÉRREZ, J.; RODRIGUEZ, L. C. E.; TOMÉ, M.; GONZÁLEZ-FERREIRO, E. Comparison of ALS based models for estimating aboveground biomass in three types of Mediterranean forest. **European Journal of Remote Sensing**, v. 49, n. 1, p. 185-204, 2016.

HAKAMADA, R.; HUBBARD, R. M.; FERRAZ, S.; STAPE, J. L.; LEMOS, C. Biomass production and potential water stress increase with planting density in four highly productive clonal Eucalyptus genotypes. **Southern Forests: a Journal of Forest Science**, v. 79, p. 1-7, 2017.

LEITE, H. G.; OLIVEIRA, F. H. T. Statistical procedure to test identity between analytical methods. **Communications in Soil Science and Plant Analysis**, v. 33, n. 7-8, p. 1105-1118, 2002.

LIANG, X.; KANKARE, V.; HYYPPÄ, J.; WANG, Y.; KUKKO, A.; HAGGRÉN, H.; YU, X.; KAARTINEN, H.; JAAKKOLA, A.; GUAN, F.; HOLOPAINEN, M.; VASTARANTA, M. Terrestrial laser scanning in forest inventories. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 115, p. 63-77, 2016.

LIMA, A. M. N.; SILVA, I. R. D.; STAPE, J. L.; MENDONÇA, E. S.; NOVAIS, R. F.; BARROS, N. F. D.; NEVES, J. C. L.; PAUL, K.; SCHULTHAIS, F.; POLGLASE, P.; RAISON, J.; SOARES, E. M. B. Modeling changes in organic carbon stocks for distinct soils in southeastern Brazil after four eucalyptus rotations using the century model. **Revista Brasileira de Ciência do Solo**, v. 35, n. 3, p. 833-847, 2011.

LINDBERG, E. **Estimation of Canopy Structure and Individual Trees from Laser Scanning Data**. 2012. Tesi (Doctoral) – Department of Forest Resource Management, Faculty of Forest Sciences, Swedish University of Agricultural Sciences, Umeå, Suécia, 2012.

LOVELL, J. L.; JUPP, D. L. B.; NEWNHAMC, G. J.; CULVENOR, D. S. Measuring tree stem diameters using intensity profiles from ground-based scanning lidar from a fixed viewpoint. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, p. 46-55, 2011.

MÁRQUEZ, A. **Un tratado sobre el escaner terrestre TLS**. Mecinca, 2010. Disponível em: <http://www.mecinca.com/papers/EscanerTLS.pdf>. Acesso em: 06 de maio 2015.

MARTINS, E. R.; BINOTI, M. L. M. S.; LEITE, H. G.; BINOTI, D. H. B. Configuração de redes neurais artificiais para estimação da altura total de árvores de eucalipto. **Revista Brasileira de Ciências Agrárias - Agrária**, v. 11, n. 2, p. 117-123, 2016.

- MENGESHA, T.; HAWKINS, M.; NIEUWENHUIS, M. Validation of terrestrial laser scanning data using conventional forest inventory methods. **European journal of forest research**, v. 134, n. 2, p. 211-222, 2015.
- NIEßNER, M.; ZOLLHÖFER, M.; IZADI, S.; STAMMINGER, M. Real-time 3D reconstruction at scale using voxel hashing. **ACM Transactions on Graphics**, v. 32, n. 6, p. 169, 2013.
- OLSOY, P. J.; GLENN, N. F.; CLARK, P. E.; DERRYBERRY, D. R. Aboveground total and green biomass of dryland shrub derived from terrestrial laser scanning. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 88, p. 166-173, 2014.
- OTHMANI, A.; VOON, L. F. L. Y.; STOLZ, C.; PIBOULE, A. Single tree species classification from terrestrial laser scanning data for forest inventory. **Pattern Recognition Letters**, v. 34, n. 16, p. 2144-2150, 2013.
- QUEIROZ, W. T. **Amostragem em inventário florestal**. EDUFRA, 2012. 441p.
- RAUMONEN, P.; KAASALAINEN, M.; KERBLUM, M. A.; KAASALAINEN, S.; KAARTINEN, H.; VASTARANTA, M.; HOLOPAINEN, M.; DISNEY, M.; LEWIS, P. Fast Automatic Precision Tree Models from Terrestrial Laser Scanner Data. **Remote Sensing**, v. 5, n. 2, p. 491-520, 2013.
- ROVEDA, M.; DIAS, A. N.; FIGUEIREDO FILHO, A.; SCAVINSKI, V.; CASTRO, R. R. C. Testes de identidade de modelos aplicados na construção de curvas de índices de local e na produção de povoamentos de *Eucalyptus grandis*. **Scientia Forestalis**, v. 44, n. 109, p. 115-127, 2016.
- SATO, M. K.; GUEDES, R. S.; LIMA, H. V.; FERNANDES, A. R.; BRAZ, A. M. S. Métodos de análise textural para solos do Estado do Pará. **Revista de Ciências Agrárias/Amazonian Journal of Agricultural and Environmental Sciences**, v. 58, n. 1, p. 90-95, 2015.
- SCHILLING, A.; SCHMIDT, A.; MAAS, H. G. Tree topology representation from TLS point clouds using depth-first search in voxel space. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 78, p. 383-392, 2012.
- SCHILLING, A. **Automatic Retrieval of Skeletal Structures of Trees from Terrestrial Laser Scanner Data**. 2014. Thesis (Doctoral). Faculty of Environmental Sciences, Technische Universität Dresden, Dresden, Alemanha, 2014.
- SERRA, A. P.; MARCHETTI, M. E.; ROJAS, E. P. VITORINO, A. C. T. Beaufile ranges to assess the cotton nutrient status in the southern region of Mato Grosso. **Revista Brasileira de Ciência do Solo**, v. 36, n. 1, p. 171-182, 2012.

SILVA, A. O.; SILVA, W. M.; KURIHARA, C. H.; MERCANTE, F. M. Spectrophotometric method for quantification of soil microbial biomass carbon. **African Journal of Biotechnology**, v. 15, n. 15, p. 565-570, 2016.

SRINIVASAN, S.; POPESCU, S. C.; ERIKSSON, M.; SHERIDAN R. D.; KU, N. Multi-temporal terrestrial laser scanning for modeling tree biomass change. **Forest Ecology and Management**, v. 318, p. 304-317, 2014.

ZASADA, M.; STEREŃCZAK, K.; DUDEK, W. M.; RYBSKI, A. Horizon visibility and accuracy of stocking determination on circular sample plots using automated remote measurement techniques. **Forest ecology and management**, v. 302, p. 171-177, 2013.

VONDERACH, C.; VÖGTLE, T.; ADLER, P.; NORRA, S. Terrestrial laser scanning for estimating urban tree volume and carbon content. **International journal of remote sensing**, v. 33, n. 21, p. 6652-6667, 2012.

WUTKE, J. D. **Métodos para avaliação de um sistema laser scanner terrestre**. 2006. Dissertação (Mestrado em Ciências Geodésicas) – Setor de Ciências da Terra, Departamento de Geomática, Universidade Federal do Paraná, Paraná, Curitiba, 2006.

### CAPÍTULO 3. ESTIMAÇÃO DE VOLUME DE MADEIRA EM POVOAMENTO DE EUCALIPTO UTILIZANDO LASER SCANNER TERRESTRE E INTELIGÊNCIA ARTIFICIAL

#### Resumo:

O uso de dados Laser Scanner Terrestre (LST) é importante para coleta de dados tridimensionais de fustes de árvores de forma não destrutiva. A estimação do volume de árvores utiliza normalmente modelos de regressão. Como alternativa, podem ser utilizadas ferramentas de inteligência computacional, como as Redes Neurais Artificiais (RNA's). Assim os objetivos foram desenvolver um método para identificação e a medição de variáveis da estrutura espacial de árvores a partir do LST e, conseqüentemente, a estimativa volumétrica de madeira em povoamentos florestais de eucalipto utilizado RNA's. O levantamento de campo foi realizado em parcelas de inventário florestal em plantio florestal híbrido de *Eucalyptus urophylla* x *Eucalyptus grandis*. As parcelas foram levantadas pelo método múltiplas varreduras com o equipamento LST. As variáveis de entrada para as RNA's foram os diâmetros das seções ao longo do fuste determinadas na estrutura espacial das árvores: diâmetro à 1,3 m de altura (*dap*), altura total (*h*) e os diâmetros em diferentes alturas  $d_{(h=0,0m)}$ ,  $d_{(h=0,5m)}$ ,  $d_{(h=1,0m)}$ , *dap*,  $d_{(h=2,0m)}$  e  $d_{(h=4,0m)}$ . Diferentes cenários, com as variáveis de entradas presentes no banco de dados de cubagem, foram treinados e testados para a aplicação das RNA's. O volume individual de cada fuste foi a variável de saída. O método para a detecção das variáveis das árvores em nuvem de pontos identificou 100% dessas variáveis. As RNA's resultaram em coeficiente de correlação linear, entre volumes observados e estimados, de 0,99 para os seis cenários da análise no treinamento e na validação. Todas as variáveis do fuste foram obtidas de forma precisa e não destrutiva com o levantamento, usando o modo múltiplas varreduras. O uso das RNA's, para estimar o volume melhorou a exatidão com mais variáveis do fuste das árvores. As aplicações de RNA's, para os diferentes cenários, geram estimativas com exatidão, comprovando a eficiência da metodologia proposta.

### 3.1 INTRODUÇÃO

Métodos, instrumentos e técnicas de medição foram e continuam sendo aprimorados para quantificação dos estoques de madeira e carbono em povoamentos florestais. A determinação do volume é a principal finalidade dos levantamentos em Povoamentos equiâneos para fins comerciais (WEST, 2009). Mapeamentos com equipamentos que possuem o sistema LiDAR (*Light Detection and Ranging*) produzem informações importantes, pois os tradicionais para a mensuração florestal têm pouca integração com a aquisição dos dados espaciais e requerem grande esforço em campo (LOVELL *et al.*, 2003).

O sistema LiDAR é um sensor remoto ativo, para a obtenção de informações tridimensionais de objetos com alta precisão, sem contato direto com os aqueles mapeados. A falta de iluminação não interfere no sensor ativo LiDAR que pode operar na faixa do espectro eletromagnético do visível até o infravermelho médio (ROGALSKI; CHRZANOWSKI, 2002). A tecnologia LiDAR pode ser empregada a partir de plataformas aerotransportadas ou terrestres para diferentes tipos de mapeamentos. O Laser Scanner Aerotransportado (LSA) tem sido aplicado para a determinação de diversos parâmetros estruturais do dossel, como altura, cobertura e perfil de folhagem (LOVELL *et al.*, 2003; ASNER *et al.*, 2010, HYYPPÄ *et al.*, 2012). O Laser Scanner Terrestre (LST) pode ser utilizado, para a obtenção de biomassa acima do solo, tortuosidade do fuste e calibração dos dados obtidos pelo LSA (LIANG *et al.*, 2016). Entretanto os autores concluem que o uso do equipamento LST, para a aquisição tridimensional em formações florestais necessita de maiores estudos.

O LST fornece estimativas acuradas e não destrutivas de parâmetros como o número e a posição das árvores, o *dap* (diâmetro a altura do peito), a altura e os parâmetros de forma do fuste e da copa da árvore (HOPKINSON *et al.*, 2004; MAAS *et al.*, 2008; JUPP *et al.*, 2009; CALDERS *et al.*, 2014; NEWNHAM *et al.*, 2015; WILKES *et al.*, 2017). Ainda que não seja necessário o corte da árvore para a determinação do volume, algumas dificuldades podem ser encontradas para determinar esta medida nas partes superiores das árvores em função do efeito de sombreamento, principalmente nas partes superiores das árvores (VAN DER ZANDE *et al.*, 2010).

Normalmente, o volume de árvores é estimado com modelos de regressão com nível de precisão adequado. A utilização de ferramentas de inteligência computacional como as Redes Neurais Artificiais (RNA's) é uma alternativa aos modelos de regressão. As RNA's representam situações de não linearidade, complexidade e variabilidade dos dados de plantio florestal (BINOTI *et al.*, 2014). As RNA's podem ser utilizadas como método alternativo para o mapeamento de padrões de entrada e de saída de classes associadas em mensuração florestal (WU; JI, 2015).

As RNA's são aplicadas, para estimar a altura e o volume de árvores, o afilamento do fuste, a modelagem do crescimento em nível de povoamento, árvores individuais. Além disso, por classe de diâmetro, elas podem prever a mortalidade, estimar o estoque de carbono em plantios florestais, inventariar a sobrevivência, estimar o volume de madeira empilhada e prever a capacidade produtiva (AERTSEN *et al.*, 2010; LEITE *et al.*, 2011; ÖZÇELİK *et al.*, 2013; LIMA *et al.*, 2017).

Os objetivos desta pesquisa consistem em desenvolver um método para a reconstrução e medição de variáveis a partir da estrutura espacial de árvores utilizando Laser Scanner Terrestre (LST) e estimar, por Redes Neurais Artificiais (RNA's), o volume de madeira em plantios florestais de eucalipto.

### **3.2 REDE NEURAL ARTIFICIAL**

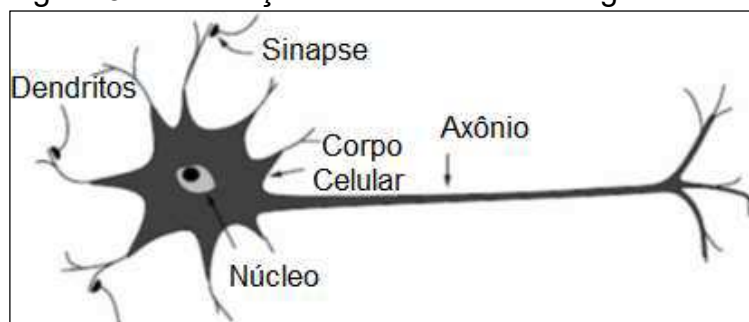
As Redes Neurais Artificiais (RNA), ou Redes Neuronais Artificiais, são um conjunto de técnicas não paramétricas que utilizam modelos matemáticos computacionais que se inspiram na forma com que os neurônios biológicos trabalham. Antes de apresentar o funcionamento de uma RNA, será descrito de forma simplificada, o funcionamento básico do cérebro humano.

O cérebro humano contém aproximadamente  $10^{11}$  neurônios. Cada um deles processa e se comunica com milhares de outros neurônios continuamente e em paralelo.

Um neurônio (ou célula de nervo) é uma célula biológica especial com capacidade de processamento de informação fundamental para a operação de uma rede neural. O neurônio (Figura 3.1) é composto pelo corpo celular e por outros dois ramos: axônio e dendritos. O corpo celular contém um núcleo com informações

sobre características hereditárias e um plasma que contém material molecular, para produção de material necessário ao neurônio. Um neurônio recebe sinais (impulsos) de outros neurônios através dos dendritos (receptores) e transmite sinais gerados pelo corpo celular ao longo do axônio (transmissor). No término dessas ramificações, estão as *sinapses*. Uma sinapse é um local de contato entre dois neurônios (uma ramificação do axônio de um neurônio e um dendrito de outro neurônio). Quando o impulso alcança o término da sinapse, substâncias químicas são liberadas, denominadas de neurotransmissores. Estes se espalham através de uma abertura sináptica, podendo seu efeito ser de ativação ou inibição. Dependendo do tipo da sinapse, o neurônio receptor possui a tendência de emitir impulsos elétricos, dando sequência à propagação. A sinapse pode ser ajustada pela passagem de sinais, por isso ela pode aprender com as atividades nas quais participa (JAIN *et al.*, 1996).

Figura 3.1 – Esboço de um neurônio biológico



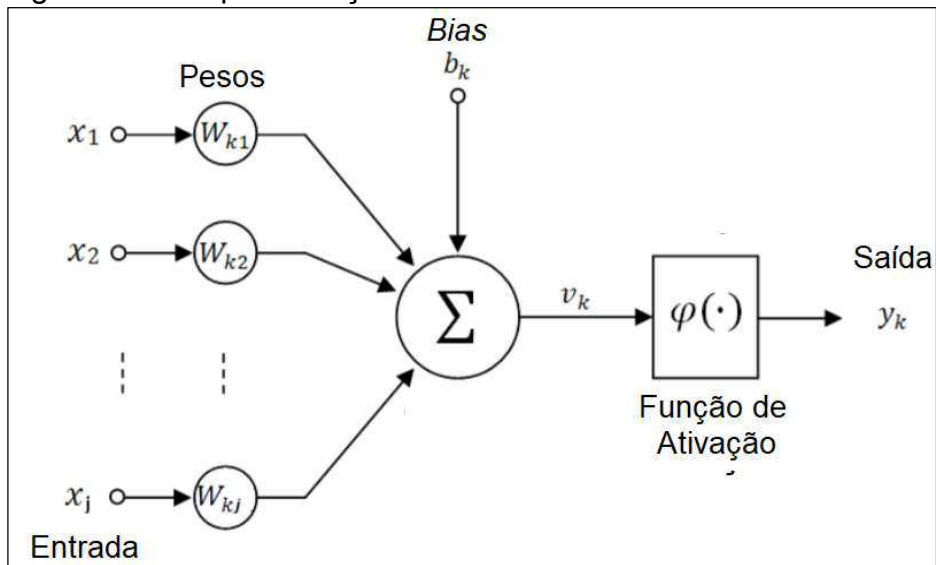
Fonte: Jain *et al.*, (1996).

As RNA's, uma vez treinadas, possuem considerável capacidade de generalização, o que permite o desenvolvimento de sistemas capazes de lidar com dados não representativos, ausentes ou ruidosos, e ainda conseguem manter os resultados em valores esperados. No processo de aprendizagem de uma RNA, alguns problemas podem ser resolvidos, como por exemplo: aproximação de função, classificações de padrões, agrupamentos de dados, predição (séries temporais), otimização, recuperação de conteúdo e controle (HAYKIN, 2001).

Os neurônios, elementos de processamento, são organizados e ligados em rede (sinapses), de modo a constituírem camadas formando as RNA's. Frequentemente, uma camada de entrada está ligada a uma camada de saída, onde apresentam o resultado do processamento, via uma ou mais camadas internas, onde processam os dados de entrada. O bias tem o efeito de aumentar ou diminuir a

entrada líquida da função de ativação, dependendo se este assume valores positivos ou negativos, respectivamente. Para restringir a amplitude de saída do neurônio, aplica-se uma função de ativação, que representa a parte não linear de cada neurônio, como: função degrau; bipolar ou rampa simétrica; linear; sigmóide ou gaussiana, resultando no valor de saída do neurônio (HAYKIN, 2001) conforme ilustrado na Figura 3.2.

Figura 3.2 – Representação de um neurônio artificial



Fonte: Haykin, (2001).

O neurônio artificial pode ser descrito pela Equação 3.1 (Haykin, 2001):

$$y_k = \varphi\left(\sum_{i=1}^n x_i w_{ki}\right) \quad (3.1)$$

Onde:  $y_k$  é a saída do neurônio;  $\varphi$  é a função de ativação;  $x_1, x_2, \dots, x_n$  são as camadas de entrada do neurônio; e  $w_{k1}, w_{k2}, \dots, w_{kn}$  são os pesos sinápticos do neurônio em questão (neurônio  $k$ ).

As RNA's têm sido empregadas com sucesso em análises florestais relacionadas à quantificação do volume de madeira (SOARES *et al.*, 2011; BINOTI *et al.*, 2014; NUNES; GÖRGENS, 2016), pois apresentam algumas vantagens sobre as metodologias estatísticas. Binoti (2012), para estimar volumes de plantios florestais, aplicou a aproximação de função direcionada. A aproximação de função consiste em projetar uma Rede Neural que aproxime a função desconhecida  $f(x)$  e

que descreva o mapeamento dos pares de entrada-saída  $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$  de um conjunto de  $n$  padrões de treinamento.

Nunes (2013) desenvolveu um sistema inteligente com base no emprego de Redes Neurais, para prever e quantificar, seja em curto, médio ou longo prazo, o sequestro de carbono em áreas de reflorestamento. O método utilizado por ele utiliza uma composição formada por uma Rede Neural da família ART (*Adaptive Resonance Theory*). A ART-Fuzzy é uma RNA antero-alimentação com múltiplas camadas, com treinamento executado via uso do algoritmo retropropagação do erro (*backpropagation*).

### **3.3 MATERIAIS E MÉTODOS**

#### **3.3.1 Área de estudo**

A área de estudo está localizada no município de Belo Oriente (19° 22' 25,42" sul e 42° 28' 28,27" oeste), estado de Minas Gerais, Brasil. Os dados foram coletados em plantios com um híbrido de *Eucalyptus urophylla* x *Eucalyptus grandis*, com idade de sete anos, espaçamento inicial de 3,0 x 2,5 m e regime de alto fuste.

As parcelas do inventário de pré-corte foram selecionadas, aleatoriamente, com as seguintes dimensões: 21 x 15 m (parcela 1), 18 x 15 m (parcela 2) e 8 x 10m (parcela 3). As árvores presentes nas parcelas foram numeradas e demarcadas com tinta azul. O relevo entre as parcelas variou de plano na parcela 1 ( $3\pm 1\%$ ), à suave ondulado na parcela 2 ( $6\pm 1\%$ ) e à ondulado na parcela 3 ( $10\pm 1\%$ ). As inclinações foram obtidas a partir da nuvem de pontos levantadas.

#### **3.3.2 Coleta de Dados**

O modelo de LST VZ-400 (RiEGL *Laser Measurement Systems*, Horn, Áustria) foi o equipamento utilizado para o mapeamento espacial das árvores presentes nas parcelas. O princípio de funcionamento do seu sensor, presente no VZ-400, baseia-se no tempo de retorno do sinal (*Time of Flight* - ToF). Foi utilizado o modo de varredura *Long Range* com resolução angular de  $0,02^\circ$  (*Angle measurement resolution*=  $0,02^\circ$ ), correspondente a uma resolução espacial de 3,5

mm para uma distância de 10 m do equipamento. A taxa de aquisição de dados foi de 42.000 pontos/segundo. Alvos refletores (*targets*) foram colocados sobre os fustes presentes em cada parcela, com o objetivo de auxiliar no registro das cenas obtidas em cada escaneamento.

O equipamento foi posicionado em estações baseadas na orientação das linhas de plantio em cinco posições, percorrendo as quatro extremidades da parcela e uma posição central. Em cada estação, o campo de visão (*Field of View* - FoV) aplicado foi de 360° na horizontal e 100° na vertical (ângulo de abertura variando entre -40 a +60°). As coordenadas planimétricas das posições do LST foram obtidas, utilizando uma estação total Topcon GTS-102N, com precisão nominal linear de 3 mm e uma precisão nominal angular de 2". Uma câmera calibrada, modelo Nikon D700, foi acoplada no equipamento para aquisição de fotos e atribuição dos valores de RGB (*Red*, *Green* e *Blue*) em cada ponto da nuvem. Esta informação permite representar a nuvem de pontos com cores, e, conseqüentemente, melhor análise dos objetos de interesse.

### 3.3.3 Pré-Processamento dos Dados


O pré-processamento dos dados consistiu do registro, ajustamento multi-estação (*Multi Station Adjustment* - MSA) e delimitação da parcela no tamanho pré-definido. As fases do pré-processamento e do processamento dos dados laser foram executadas por meio do *software* Riegl's RiSCAN PRO (*RiEGL Laser Measurement Systems*).

O registro dos dados laser foi realizado em um sistema de coordenadas local com coordenadas obtidas com o uso de estação total. A fase do registro direto não garante que todas as cenas fiquem alinhadas, devido a erros de levantamento, posicionamentos e instabilidade dos refletores. O *software* tem um plug-in denominado *Multi-Station Adjustment* (MSA), para contornar este problema. No MSA, a iteração do ajustamento é feita a cada duas posições e inserindo, a cada novo processamento, mais duas posições, até concluir todas as posições (HÖFLE *et al.*, 2013).

Após o pré-processamento, foi gerada uma *Polydata* contendo uma nuvem de pontos (X, Y, Z) provenientes das cinco posições do levantamento. Posteriormente

foi gerado um subconjunto da nuvem de pontos, representando cada parcela do inventário analisada nesta pesquisa (Figura 3.3).

Figura 3.3 – Recorte da nuvem de pontos de acordo com a delimitação em campo das parcelas: Parcela 1 (A), Parcela 2 (B), Parcela 3 (C)




Fonte: A autora.

### 3.3.4 Extração das Variáveis do Fuste

As variáveis analisadas nesta pesquisa foram o diâmetro obtido a 1,3 m de altura ( $d_{ap}$ ), a altura total ( $h$ ) das árvores, além dos diâmetros ( $d$ ) obtidos nas alturas de 0,0; 0,5; 1,0; 2,0 e 4,0 m em relação ao eixo Z, que correspondem respectivamente às variáveis  $d_{(h=0,0m)}$ ,  $d_{(h=0,5m)}$ ,  $d_{(h=1,0m)}$ ,  $d_{(h=2,0m)}$  e  $d_{(h=4,0m)}$  (Figura 3.4).

Figura 3.4 – Variáveis obtidas pelo processamento de dados LST.



Fonte: Soares *et al.*, (2011).

A variável  $h$  foi obtida diretamente sobre a nuvem de pontos com as coordenadas mínima e máxima por árvore (Equação 3.2):

$$h = \sqrt{(X_{m\acute{a}x} - X_{m\acute{i}n})^2 + (Y_{m\acute{a}x} - Y_{m\acute{i}n})^2 + (Z_{m\acute{a}x} - Z_{m\acute{i}n})^2} \quad (3.2)$$

Onde:  $h$  é altura total;  $(X_{m\acute{a}x}, Y_{m\acute{a}x}, Z_{m\acute{a}x})$  e  $(X_{m\acute{i}n}, Y_{m\acute{i}n}, Z_{m\acute{i}n})$  são as coordenadas máximas e mínimas para cada árvore.

Os diâmetros ao longo do fuste foram determinados a partir de planos paralelos ao do terreno, em alturas pré-definidas, para cada variável referente ao diâmetro. Os filtros aplicados foram o *Height filter* e *Octree filter*. O primeiro consiste na classificação da nuvem de pontos obtidas pelo LST como pertencentes ou não à superfície do terreno. O *Octree filter* foi aplicado no *Polydata* com os pontos classificados como pertencente à superfície do terreno.

O *Octree filter* torna a nuvem de pontos mais homogênea e menos densa, sem comprometer a qualidade dos dados. Ele funciona como uma estrutura de dados hierárquica que define subdivisões de um espaço tridimensional em cubos, chamados de *voxels*. O *voxel* inicial, que normalmente cobre todo o domínio do espaço a ser estudado, é dividido em oito partes iguais. Os novos cubos são chamados de *voxels* filhos, que, por sua vez, podem ser subdivididos num processo

recursivo, cujo limite pode ser definido previamente, por exemplo, tamanho mínimo do *voxel* (NIEßNER *et al.*, 2013).

Diversos *PolyDatas* foram criados com diferentes seções, para garantir o posicionamento em relação ao eixo Z das variáveis da análise:  $d_{(h=0.0m)}$ ,  $d_{(h=0.5m)}$ ,  $d_{(h=1.0m)}$ ,  $dap$ ,  $d_{(h=2.0m)}$  e  $d_{(h=4.0m)}$  (Figura 3.4). O próximo passo foi a filtragem manual para a obtenção do fuste da árvore, com a eliminação dos outros pontos (solo, galhos e folhas da copa). As variáveis analisadas foram obtidas diretamente sobre cada nuvem de pontos por parcela.


Os valores discrepantes (*outliers*) foram verificados pelo conceito do “BoxPlot” com a estatística descritiva. Os dados no gráfico “BoxPlot” foram descritos através dos elementos: mediana, primeiro quartil (ou quartil inferior - Q1), terceiro quartil (ou quartil superior - Q3), valor máximo e valor mínimo. Os valores discrepantes que apresentaram valores acima do limite do quarto quartil do gráfico “BoxPlot” foram considerados como *outlier*.

### 3.3.5 Estimativas de Volume utilizando RNA

#### 3.3.5.1 Treinamento das RNA's

As RNA's foram treinadas visando à estimação de volume das árvores por parcela. Setecentos e setenta e três árvores foram amostradas, colhidas, abatidas e cubadas em diferentes talhões do povoamento, sendo que as três parcelas descritas como área de estudo foram utilizadas no treinamento. Seções com intervalos de 1 m ao longo do fuste foram obtidas das árvores-amostra e cubadas. Os  $dap$ , o diâmetro a 0,5 m de altura e a altura total ( $h$ ), também foram medidos por árvore-amostra. O volume total com casca ( $V$ ) foi obtido pela fórmula de Smalian (Figura 3.5 e Equação 3.3) (CAMPOS; LEITE, 2017):

Figura 3.5 – Representação das seções transversais do fuste



Fonte: Campos e Leite (2017).

$$V = \left( \frac{g_1 + g_2}{2} \right) * l_i \quad (3.3)$$

Onde:  $V$  é o volume do fuste, em  $m^3$ ;  $g_1$  e  $g_2$  é a área seccional nas respectivas extremidades do fuste, dada por  $g = \frac{\pi D_i^2}{40.000}$ ;  $D_i$  é o diâmetro nas extremidades da seção;  $l_i$  é o comprimento da seção.

A estimativa de volume foi simulada com todas as combinações possíveis das variáveis de entrada contínuas (variáveis quantitativas): idade, inclinação do terreno,  $d_{ap}$ ,  $d_{(h=0.0m)}$ ,  $d_{(h=0.5m)}$ ,  $d_{(h=1.0m)}$ ,  $d_{(h=2.0m)}$ ,  $d_{(h=4.0m)}$ , e  $h$ ; e categóricas (qualitativas): projeto, genótipo, regional e regime de corte.

Os dados utilizados neste estudo para o treinamento e validação das RNA's foram obtidos de 773 árvores amostras divididos, aleatoriamente, em dois conjuntos para as variáveis disponíveis: um conjunto para o treinamento das redes (equivalente a 70% dos dados) e outro conjunto para validação das redes treinadas (30% dos dados).

As variáveis contínuas foram reescaladas, linearmente, no intervalo entre 0 e 1. A reescanalização linear considera o valor mínimo e máximo de cada variável na transformação para valores em um intervalo fechado, por exemplo, de 0 a 1, mantendo as distâncias entre os valores normalizados proporcionais às distâncias entre os dados originais, obtidos pela Equação 3.4 (VALENÇA, 2010).

$$y = \frac{(x - x_{min})(y_{máx} - y_{min})}{(x_{max} - x_{min})} + y_{min} \quad (3.4)$$

Onde:  $x'$  é o valor normalizado;  $x$  é o valor original;  $x_{min}$  é o valor mínimo da variável;  $x_{max}$  é o valor máximo da variável;  $a$  é o limite inferior do intervalo de normalização; e  $b$  é o limite superior do intervalo de normalização.

Ao final do processamento da rede, é necessário um pós-processamento, revertendo o escalonamento nos dados realizado anteriormente.

Os dados que extrapolaram a tendência geral de cada clone não foram eliminados, para verificar a capacidade das RNA's de lidar com *outliers* ou ruídos (BINOTI *et al.*, 2014). Os cenários utilizados na definição das variáveis de entrada contínuas foram: (A)  $d_{(h=0.0m)}$ ,  $d_{(h=0.5m)}$ ,  $d_{(h=1.0m)}$ ,  $dap$ ,  $d_{(h=2.0m)}$ ,  $d_{(h=4.0m)}$  e  $h$ ; (B)  $d_{(h=0.0m)}$ ,  $d_{(h=0.5m)}$ ,  $d_{(h=1.0m)}$ ,  $dap$ ,  $d_{(h=2.0m)}$  e  $h$ ; (C)  $d_{(h=0.0m)}$ ,  $d_{(h=0.5m)}$ ,  $d_{(h=1.0m)}$ ,  $dap$  e  $h$ ; (D)  $d_{(h=0.5m)}$ ,  $d_{(h=1.0m)}$ ,  $d_{(h=2.0m)}$ ,  $dap$  e  $h$ ; (E)  $d_{(h=2.0m)}$ ,  $dap$  e  $h$ ; e (F)  $dap$  e  $h$ . Esses cenários foram treinados e testados para, evitar o esforço de obtenção direta dessas variáveis em todas as árvores das parcelas de inventário.

As variáveis qualitativas foram codificadas de forma a atender às necessidades de uma rede neural. Para as variáveis categóricas, (qualitativas) como o projeto, genótipo, regional e regime de corte, os valores foram transformados em representação numérica.

As RNA's treinadas foram do tipo *perceptrons* de múltiplas camadas, conhecidas como *Multilayer Perceptron* (MLP). As MLP são organizadas por três camadas. Destas, uma formada de neurônios artificiais recebe os dados de entrada e os direcionam às camadas intermediária e de saída.

O *software* Neuro 4.0.4 (DAP Florestal) foi utilizado para treinar as redes. Cinco redes foram geradas para cada cenário com o algoritmo de treinamento *Resilient Propagation*. Este algoritmo foi escolhido em virtude do seu desempenho superior aos demais algoritmos, conforme trabalho de Binoti *et al.*, (2014).

Nesta pesquisa, foram desenvolvidos dois testes, para avaliar o desempenho das RNA's com diferentes números de neurônios na camada oculta da rede. Em ambos os testes, as RNA's utilizaram as mesmas variáveis de entrada. Entretanto o primeiro teste empregou 4 neurônios na camada oculta, e o segundo teste, 8 neurônios, para cada combinação gerou-se cinco redes, sendo considerada uma simulação. As configurações das RNA's mais simples, com o menor número de neurônios possível na camada oculta, são aplicadas para evitar o efeito do

*overfitting*, facilitando o processo de busca e otimização de sua configuração (BULLINARIA, 2004).

A camada de saída foi constituída por um neurônio, equivalente à variável de interesse (volume com casca). A função de ativação utilizada na camada oculta e na camada de saída foi a *Sigmóide* (logística). Os critérios de parada foram o erro quadrático médio menor ou igual a 0,0001 e o número máximo de 3.000 épocas (iterações). O treinamento da rede foi finalizado quando atendido pelo menos um dos critérios. A parametrização descrita tem sido eficiente e suficiente para a maioria dos casos do uso de RNA's na Ciência Florestal (CAMPOS; LEITE, 2017). As RNA's previamente treinadas foram utilizadas para a totalização das parcelas e obtenção do volume de madeira por hectare.

### 3.3.5.2 Análise Estatística

As estimativas de volume ( $\bar{V}$ ) geradas pelas RNA foram avaliadas, em relação aos valores observados ( $V$ ), por meio do coeficiente de correlação ( $R_{\bar{V}Y}$ ), *bias* (Equação 3.5), *bias%* (Equação 3.6), variância do erro (Equação 3.7). Para avaliar a exatidão, foi utilizada a raiz quadrada do erro quadrático médio (RQME) (Equação 3.8) e a raiz quadrada do erro quadrático médio em porcentagem da média (RQME%) (Equação 3.9), para todos os cenários descritos na seção anterior.

$$bias = \frac{\sum_{i=1}^n (\bar{v}_i - v_i)}{n} \quad (3.5)$$

$$bias\% = 100 * \frac{\sum_{i=1}^n (\bar{v}_i - v_i)/n}{\bar{V}} \quad (3.6)$$

$$Variância(\bar{v}_i - v_i) = \frac{\sum_{i=1}^n (bias - (\bar{v}_i - v_i))^2}{n-1} \quad (3.7)$$

$$RQME = \sqrt{\frac{\sum_{i=1}^n (\bar{v}_i - v_i)^2}{n}} \quad (3.8)$$

$$RQME\% = 100 * \frac{\sqrt{\sum_{i=1}^n (\bar{v}_i - v_i)^2 / (n)}}{\bar{V}} \quad (3.9)$$

Onde:  $\bar{V}$  é o volume médio predito;  $\bar{v}_i$  é o volume com casca predito; e  $v_i$  é o volume com casca observado.

Além disso, foram analisadas as distribuições dos erros relativos percentuais (Equação 3.10).

$$100(\bar{V} - V)/V \quad (3.10)$$

Onde:  $V$  é o volume observado; e  $\bar{V}$  é a estimativa de volume gerado pelas RNA.

O *bias* ou viés é a diferença entre a média de um conjunto de medidas estimadas e seus valores reais, podendo indicar tendência do erro das estimativas.

O RQME mostra as diferenças individuais entre a predição do volume com casca ( $\bar{v}_i$ ) e com casca observada ( $v_i$ ), onde  $n$  é o número de observações. Diferenças elevadas ao quadrado forçam os resultados negativos e positivos a serem iguais. O RQME é utilizado para medir a magnitude do erro produzido pelo modelo. Desta forma, quanto mais próximo de zero, melhor é o modelo. Esses erros geralmente se distribuem em, aproximadamente, 10% em torno de zero (0) com tendenciosidade para árvores muito pequenas (CAMPOS; LEITE, 2017).

O teste foi aplicado para a avaliação da identidade do volume com casca, obtido pela metodologia convencional, e aquele com a metodologia RNA para as variáveis  $dap$  e  $h$  para o cenário F (LEITE; OLIVEIRA, 2002). O teste consiste em uma regra decisória definida pela combinação conjunta do teste  $F$  (GRAYBILL, 1972), do teste  $t$  de *Student* para erro relativo médio ( $t_e$ ) e da análise do coeficiente de correlação linear ( $r$ ) entre os valores dos métodos comparados.

## 3.4 RESULTADOS

### 3.4.1 Extração das Variáveis

As principais estatísticas descritivas por variável ( $d_{(h=0.0m)}$ ,  $d_{(h=0.5m)}$ ,  $d_{(h=1.0m)}$ ,  $dap$ ,  $d_{(h=2.0m)}$ ,  $d_{(h=4.0m)}$  e  $h$ ) e parcela mostraram semelhança entre os dados obtidos

pelo LST. Esta semelhança pode ser observada a partir dos valores de média, desvio padrão, variância e coeficiente de variação descritos na Tabela 3.1.

Tabela 3.1 – Medidas descritivas para cada variável da análise: Mínimo, Máximo, Média, Mediana, Desvio padrão, Variância e Coeficiente de Variação


	Variável	Mínimo	Máximo	Média	Mediana	Dp <sup>a</sup>	Var <sup>b</sup>	CV (%) <sup>c</sup>
Parcela 1 (n = 41)	$d_{(h=0,0m)}$	9,1	22,4	15,6	16,2	2,9	8,2	18,4
	$d_{(h=0,5m)}$	10,8	21,2	16,2	16,6	2,9	9,3	31,9
	$d_{(h=1,0m)}$	8,1	21,3	14,4	15,0	2,8	7,8	19,3
	$dap$	7,5	20,2	13,6	14,2	2,7	7,2	19,8
	$d_{(h=2,0m)}$	7,2	19,2	12,9	13,5	2,6	6,9	20,4
	$d_{(h=4,0m)}$	6,7	18,5	12,1	12,5	2,6	6,6	21,3
	$H$	17,4	29,3	21,9	21,2	2,9	8,9	13,6
Parcela 2 (n = 36)	$d_{(h=0,0m)}$	9,1	22,4	15,6	16,2	2,9	8,2	18,4
	$d_{(h=0,5m)}$	8,8	22,0	15,1	15,7	2,8	7,9	35,4
	$d_{(h=1,0m)}$	8,1	21,3	14,4	15,0	2,8	7,8	19,3
	$dap$	7,5	20,2	13,6	14,2	2,7	7,2	19,8
	$d_{(h=2,0m)}$	7,2	19,2	12,9	13,5	2,6	6,9	20,4
	$d_{(h=4,0m)}$	6,7	18,5	12,1	12,5	2,6	6,6	21,3
	$H$	17,3	29,3	21,9	21,2	2,9	8,9	13,6
Parcela 3 (n = 24)	$d_{(h=0,0m)}$	7,8	18,7	16,5	16,7	2,1	4,3	12,6
	$d_{(h=0,5m)}$	7,3	18,4	16,0	16,2	2,1	4,3	12,9
	$d_{(h=1,0m)}$	7,2	17,8	15,3	15,3	1,9	3,9	12,9
	$dap$	7,0	17,5	14,9	14,9	1,9	3,7	12,9
	$d_{(h=2,0m)}$	6,8	17,3	14,6	14,7	1,9	3,6	13,1
	$d_{(h=4,0m)}$	5,8	17,2	13,7	13,8	1,9	3,6	13,8
	$H$	24,5	26,9	25,7	25,8	0,6	0,4	2,4

<sup>a</sup>Desvio padrão; <sup>b</sup>Variância; <sup>c</sup>Coeficiente de Variação em porcentagem (metros para a variável  $h$  e centímetros para as outras variáveis).

Fonte: A autora.


A "*Compleitude*", que se refere à porcentagem de árvores detectadas e reconstruídas, mostrou que a reconstrução do fuste, por meio dos dados oriundos do LST, reconheceu todas as árvores. As cinco posições, para o cobrimento total de cada parcela, foram importantes para obtenção de todas as variáveis de análise. A variável  $h$  foi obtida com as coordenadas mínima e máxima por árvore, pois a forma das árvores do povoamento de híbrido variou com a inclinação. Nas Figuras 3.6, 3.7 e 3.8, foram representados os planos para cada diferente altura de 0,0; 0,5; 1,0; 1,3; 2,0 e 4,0 m, em relação ao eixo Z para a obtenção dos diferentes diâmetros  $d_{(h=0.0m)}$ ,  $d_{(h=0.5m)}$ ,  $d_{(h=1.0m)}$ ,  $d_{ap}$ ,  $d_{(h=2.0m)}$ ,  $d_{(h=4.0m)}$ .

Figura 3.6 – Recorte da Parcela 1 contendo em ordem os planos para cada diferente altura de 0,0; 0,5; 1,0; 1,3; 2,0 e 4,0 m, em relação ao eixo Z




Fonte: A autora.

Figura 3.7 – Recorte da Parcela 2 contendo em ordem os planos para cada diferente altura de 0,0; 0,5; 1,0; 1,3; 2,0 e 4,0 m, em relação ao eixo Z



Fonte: A autora.

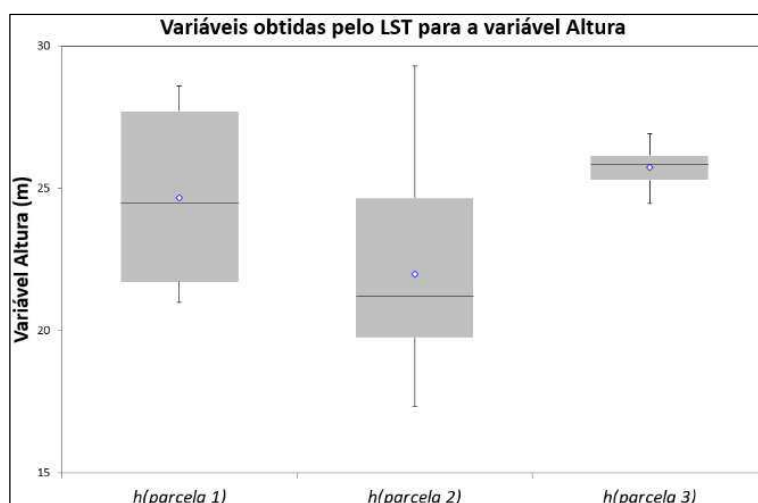
Figura 3.8 – Recorte da Parcela 3 contendo em ordem os planos para cada diferente altura de 0,0; 0,5; 1,0; 1,3; 2,0 e 4,0 m, em relação ao eixo Z



Fonte: A autora.

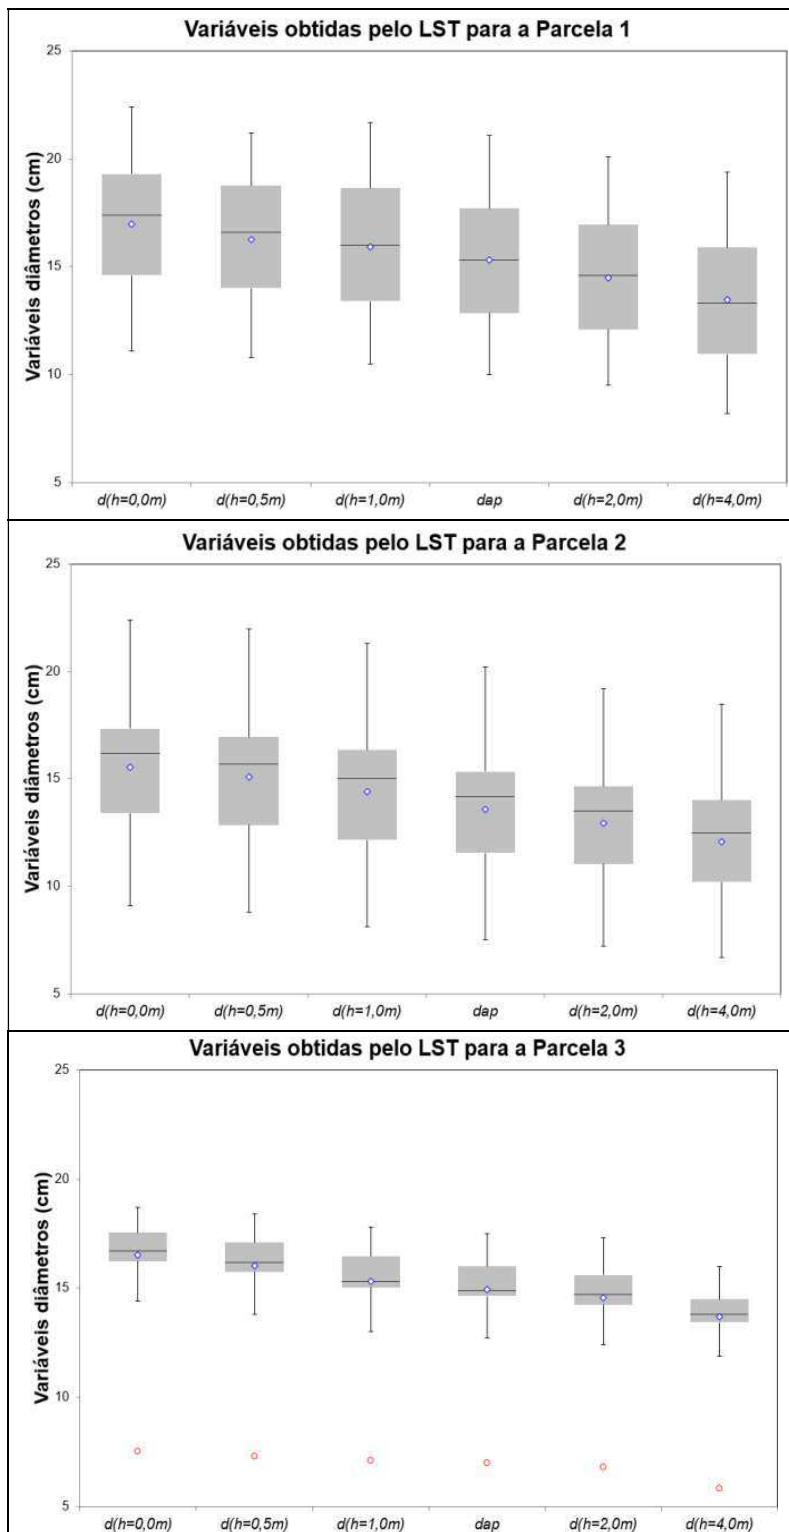
Os dados discrepantes foram verificados com o recurso do *Box-Plot* para cada parcela do estudo (Gráficos 3.1 e 3.2). Em relação a variável altura ( $h$ ) não foram observados valores discrepantes em nenhuma das três parcelas. Para as parcelas 1 e 2, não foram evidenciados valores discrepantes para todos os diâmetros analisados. Entretanto na parcela 3 foi observado um valor discrepante para a variável diâmetro em virtude de um fuste bifurcado em campo conforme destacado na Figura 3.9.

Gráfico 3.1 – Gráfico Box-Plot para cada variável  $h$  obtida pelo LST




Fonte: A autora.

Gráfico 3.2 – Gráfico *Box-Plot* para as variáveis obtida pelo LST:  $d_{(h=0.0m)}$ ,  $d_{(h=0.5m)}$ ,  $d_{(h=1.0m)}$ ,  $dap$ ,  $d_{(h=2.0m)}$ ,  $d_{(h=4.0m)}$



Fonte: A autora.

Figura 3.9 – Recorte da Parcela 3 contendo em ordem os planos para cada diferente altura de 0,0 e 4,0 m, em relação ao eixo Z



Fonte: A autora.

### 3.4.2 Aplicação das RNA's para Estimativa de Volume

Um banco histórico de cubagem foi utilizado para o treinamento de RNA, para estimar o volume de árvores em função das variáveis  $dap$ ,  $h$ , os diâmetros nas alturas 0,5, 1,0, 2,0 e 4,0 m, idade, e as variáveis categóricas disponíveis, como projeto, genótipo, regional e regime de corte. Foram testados diferentes cenários para as variáveis de entrada contínuas: (A)  $d_{(h=0.0m)}$ ,  $d_{(h=0.5m)}$ ,  $d_{(h=1.0m)}$ ,  $dap$ ,  $d_{(h=2.0m)}$ ,  $d_{(h=4.0m)}$  e  $h$ ; (B)  $d_{(h=0.0m)}$ ,  $d_{(h=0.5m)}$ ,  $d_{(h=1.0m)}$ ,  $dap$ ,  $d_{(h=2.0m)}$  e  $h$ ; (C)  $d_{(h=0.0m)}$ ,  $d_{(h=0.5m)}$ ,  $d_{(h=1.0m)}$ ,  $dap$  e  $h$ ; (D)  $d_{(h=0.5m)}$ ,  $d_{(h=1.0m)}$ ,  $d_{(h=2.0m)}$ ,  $dap$  e  $h$ ; (E)  $d_{(h=2.0m)}$ ,  $dap$  e  $h$ ; e (F)  $dap$  e  $h$ . A RNA com melhor ajuste foi aplicada para a estimação do volume de cada árvore mensurada pelo LST, totalizando o volume das parcelas. A escolha entre as cinco RNAs geradas foi feita avaliando o erro quadrático médio e o desvio padrão dos erros quadráticos de cada cenário (Tabela 3.2). A estimativa do volume individual de clones de *Eucalyptus urophylla* x *Eucalyptus grandis* com as variáveis ao longo do fuste apresentaram volumes semelhantes (Tabela 3.2).

Tabela 3.2 – Resultados obtidos pela aplicação da RNA (unidade m<sup>3</sup>) para os diferentes cenários variando quatro e oito neurônios na camada oculta: RNA, Dados (Treino e Validação), Volume, Bias, Bias (%), Raiz quadrada do erro quadrático médio (RQME), RQME (%), Variância, Quadrado Médio do Erro (QME) e Coeficiente de correlação ( $R_{\hat{Y}Y}$ )

Continua.

	<b>RNA</b>	<b>Dados</b>	$\bar{V}$ (m <sup>3</sup> )	<b>Bias</b>	<b>Bias (%)</b>	<b>RQME</b>	<b>RQME (%)</b>	<b>VAR</b>	<b>QME</b>	$R_{\hat{Y}Y}$
Cenário A	RNA 1	Treino	0,3959	-0,0003	-0,0647	0,0161	4,0630	0,0003	0,1415	0,9985
	4 neurônios	Validação	0,3887	-0,0058	-1,5036	0,0326	8,3869	0,0010	0,2402	0,9948
	RNA 5	Treino	0,3980	-0,0001	-0,0223	0,0132	3,3129	0,0002	0,0958	0,9991
	8 neurônios	Validação	0,3687	0,0017	0,4636	0,0239	6,4812	0,0006	0,1267	0,9961
Cenário B	RNA 3	Treino	0,3959	-0,0001	-0,0344	0,0195	4,9173	0,0004	0,1910	0,9979
	4 neurônios	Validação	0,4121	-0,0012	-0,3010	0,0377	9,1474	0,0014	0,3822	0,9913
	RNA 2	Treino	0,3958	-0,0003	-0,0847	0,0170	4,2855	0,0003	0,1608	0,9984
	8 neurônios	Validação	0,3646	-0,0033	-0,9157	0,0462	12,6742	0,0021	0,4571	0,9859
Cenário C	RNA 3	Treino	0,3962	0,0002	0,0575	0,0237	5,9826	0,0006	0,2898	0,9968
	4 neurônios	Validação	0,3476	-0,0067	-1,9285	0,0395	11,3700	0,0015	0,4013	0,9920
	RNA 3	Treino	0,3830	-0,0002	-0,0556	0,0197	5,1422	0,0004	0,2091	0,9977
	8 neurônios	Validação	0,3996	-0,0037	-0,9367	0,0459	11,4754	0,0021	0,4922	0,9896

Fonte: A autora.


Continuação.

	<b>RNA</b>	<b>Dados</b>	$\hat{V}(m^3)$	<b>Bias</b>	<b>Bias (%)</b>	<b>RQME</b>	<b>RQME (%)</b>	<b>VAR</b>	<b>QME</b>	$R_{\hat{Y}Y}$
Cenário D	RNA 5	Treino	0,3995	-0,0001	-0,0365	0,0162	4,0600	0,0003	0,1402	0,9985
	4 neurônios	Validação	0,3668	-0,0027	-0,7281	0,0311	8,4693	0,0010	0,2316	0,9944
	RNA 4	Treino	0,3824	-0,0001	-0,0204	0,0245	6,4140	0,0006	0,3249	0,9964
	8 neurônios	Validação	0,4127	0,0019	0,4686	0,0717	17,3729	0,0052	1,1975	0,9738
Cenário E	RNA 1	Treino	0,3867	-0,0001	-0,0348	0,0217	5,6111	0,0005	0,2595	0,9974
	4 neurônios	Validação	0,3861	0,0015	0,4005	0,0287	7,4442	0,0008	0,1834	0,9951
	RNA 1	Treino	0,3905	0,0000	0,0092	0,0166	4,2591	0,0003	0,1510	0,9984
	8 neurônios	Validação	0,3891	-0,0025	-0,6534	0,0369	9,4797	0,0014	0,3088	0,9930
Cenário F	RNA 5	Treino	0,3963	-0,0003	-0,0790	0,0253	6,3735	0,0006	0,3394	0,9965
	4 neurônios	Validação	0,3781	0,0029	0,7697	0,0378	9,9962	0,0014	0,3442	0,9913
	RNA 5	Treino	0,3887	-0,0001	-0,0233	0,0194	4,9985	0,0004	0,2073	0,9978
	8 neurônios	Validação	0,3875	-0,0054	-1,3934	0,0463	11,9567	0,0021	0,4810	0,9888

Fonte: A autora.

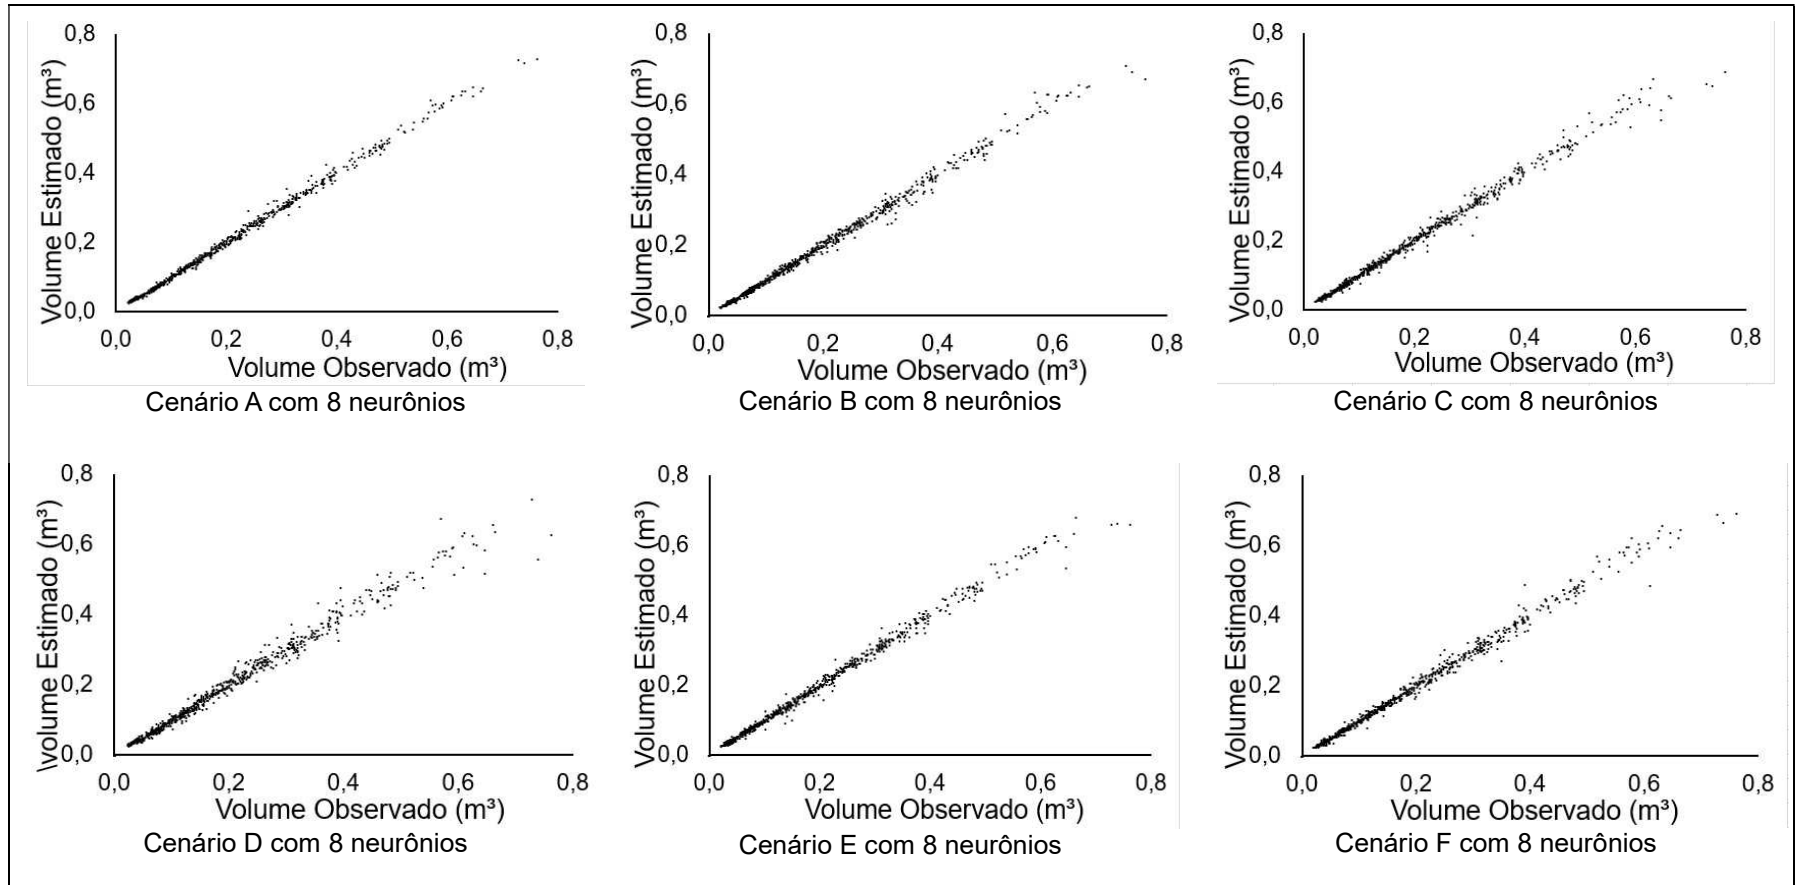
O número de neurônios da camada oculta foram quatro e oito com a estabilização do RQME e com maior correlação ( $R_{\hat{y}y}$ ). As duas melhores redes foram selecionadas, uma com quatro e outra com oito neurônios na camada oculta, para os seis cenários representados de A até F (variáveis contínuas). Os valores de desempenho das métricas Bias, Bias (%), Raiz quadrada do erro quadrático médio (RQME), RQME (%), Variância, quadrado médio do erro (QME) e Coeficiente de correlação são apresentados para cada cenário (Tabela 3.2). A correlação e o RQME, para avaliação estatística das estimativas das redes, no treinamento e na validação, mostrou que as redes do cenário (A) geraram estimativas mais precisas do que as redes dos demais cenários, com maior correlação e menores RQME e RQME%. As RNA's resultaram em coeficiente de correlação linear, entre volumes observados e estimados, superior a 0,99 para todos os seis cenários da análise no treinamento e validação. A análise gráfica de resíduos e a dispersão entre valores observados e estimados estão apresentadas nos Gráficos 3.3, 3.4, 3.5, 3.6, 3.7 e 3.8.

Gráfico 3.3 – Relação entre volumes observados e estimados para dados de validação das RNA com 4 neurônios na camada intermediária, para cada cenário (A até F)



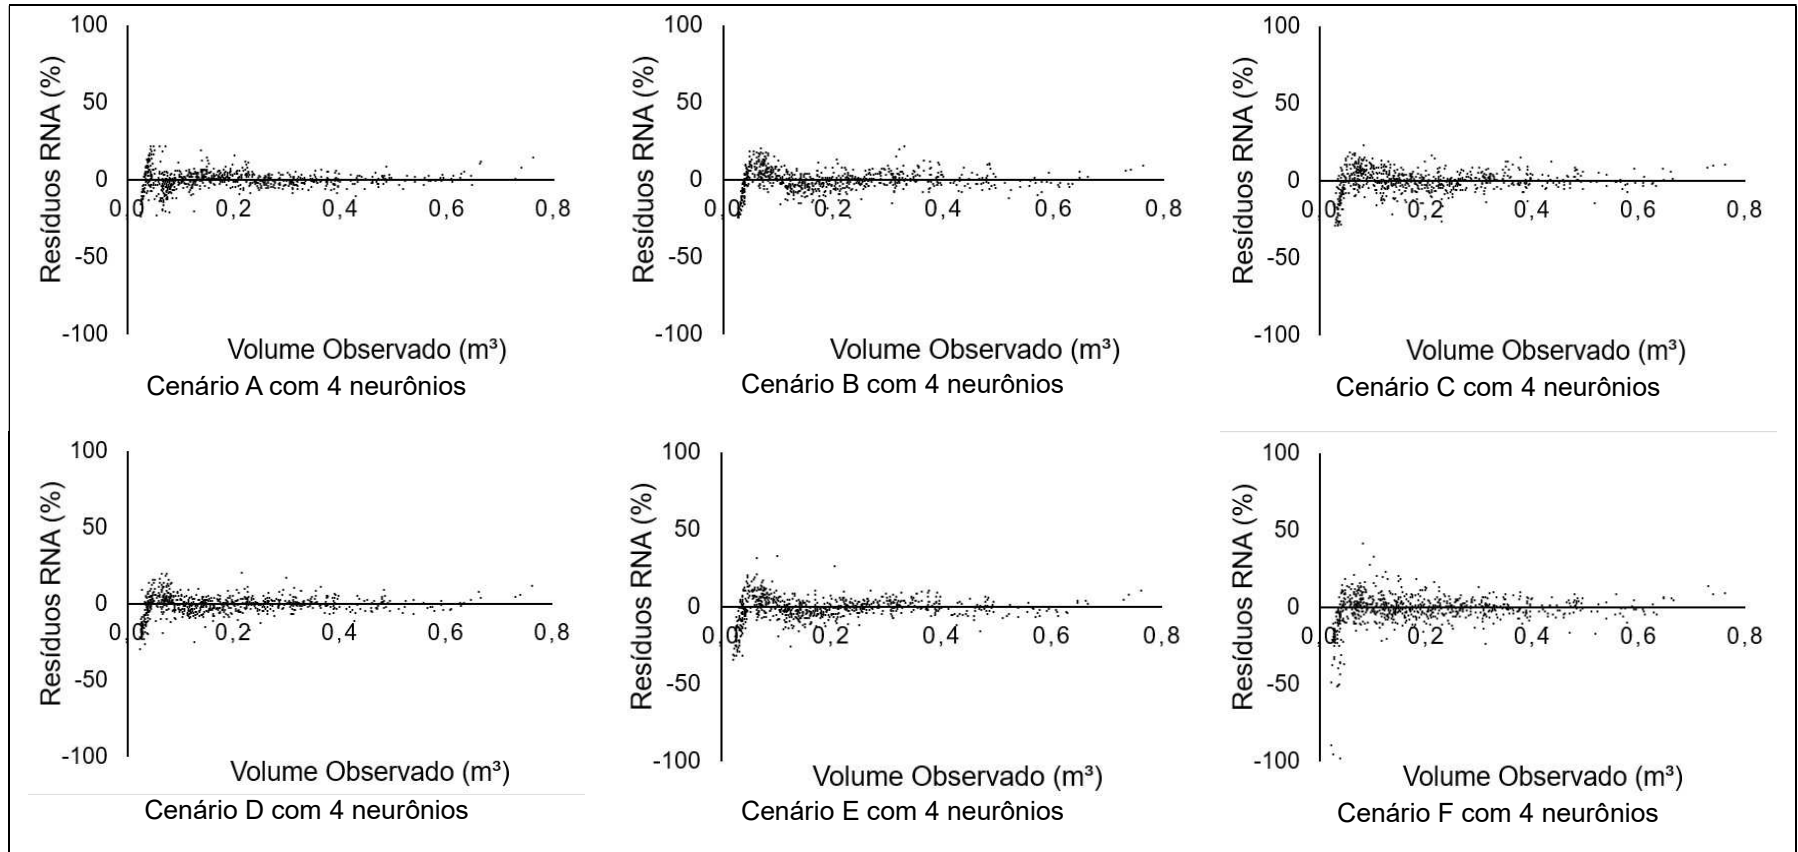
Fonte: A autora.

Gráfico 3.4 – Relação entre volumes observados e estimados para dados de validação das RNA com 8 neurônios na camada intermediária, para cada cenário (A até F)



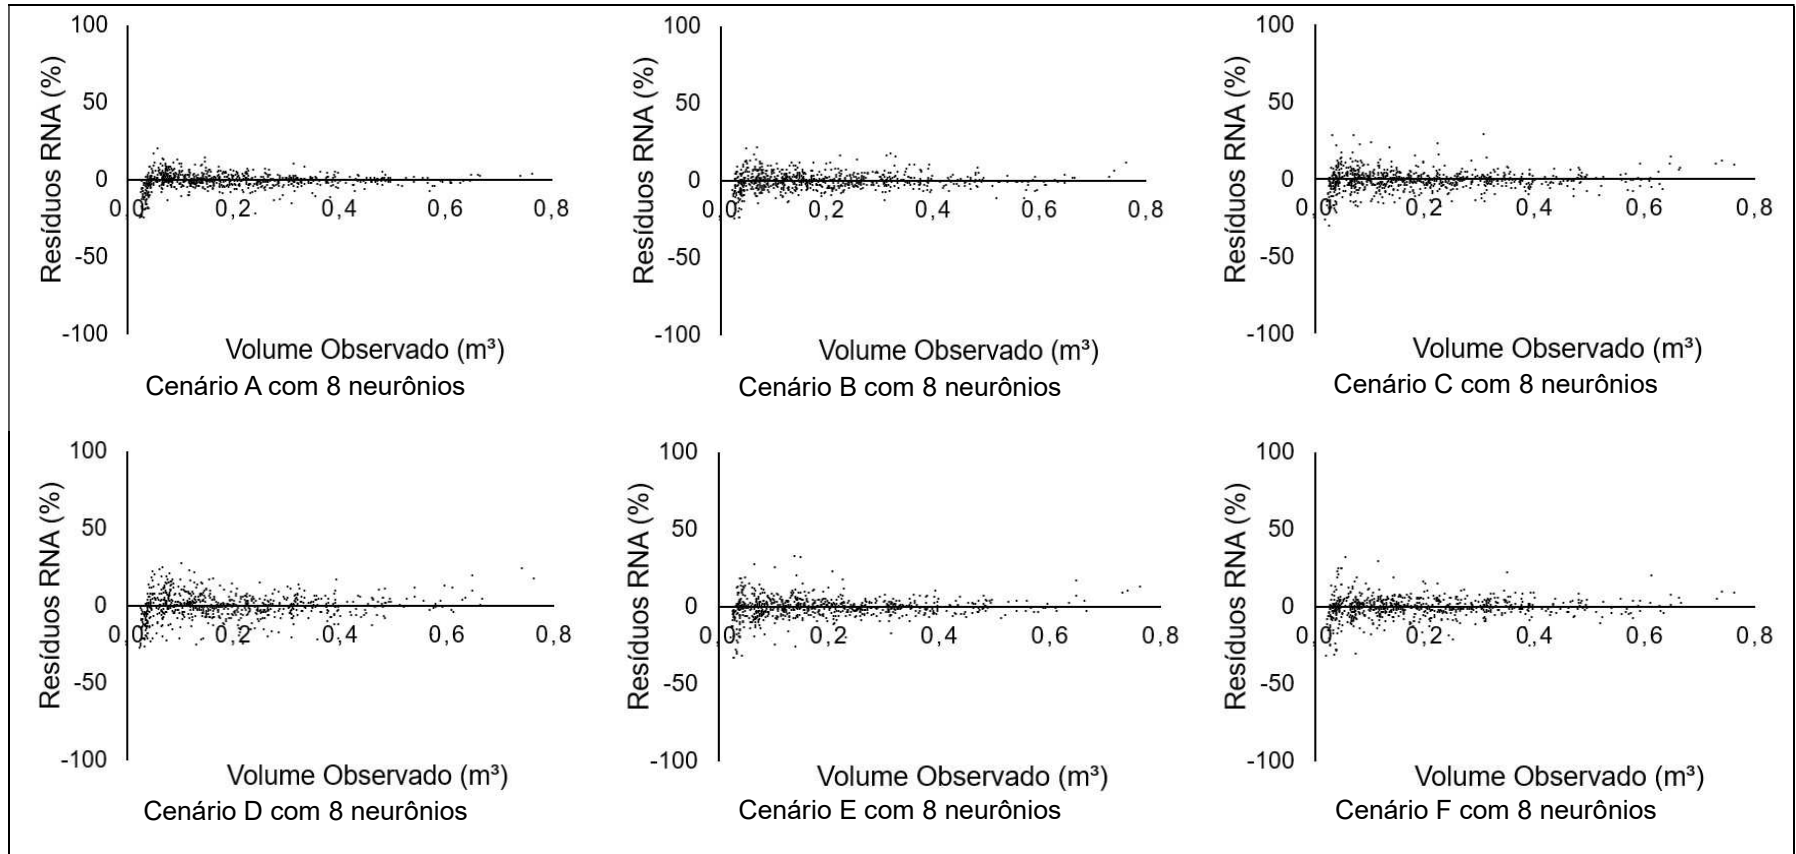
Fonte: A autora.

Gráfico 3.5 – Gráfico dos resíduos obtidos pelas estimativas realizadas pelas RNA treinadas com 4 neurônios na camada intermediária, para cada cenário (A até F)




Fonte: A autora.

Gráfico 3.6 – Gráfico dos resíduos obtidos pelas estimativas realizadas pelas RNA treinadas com 8 neurônios na camada intermediária, para cada cenário (A até F)



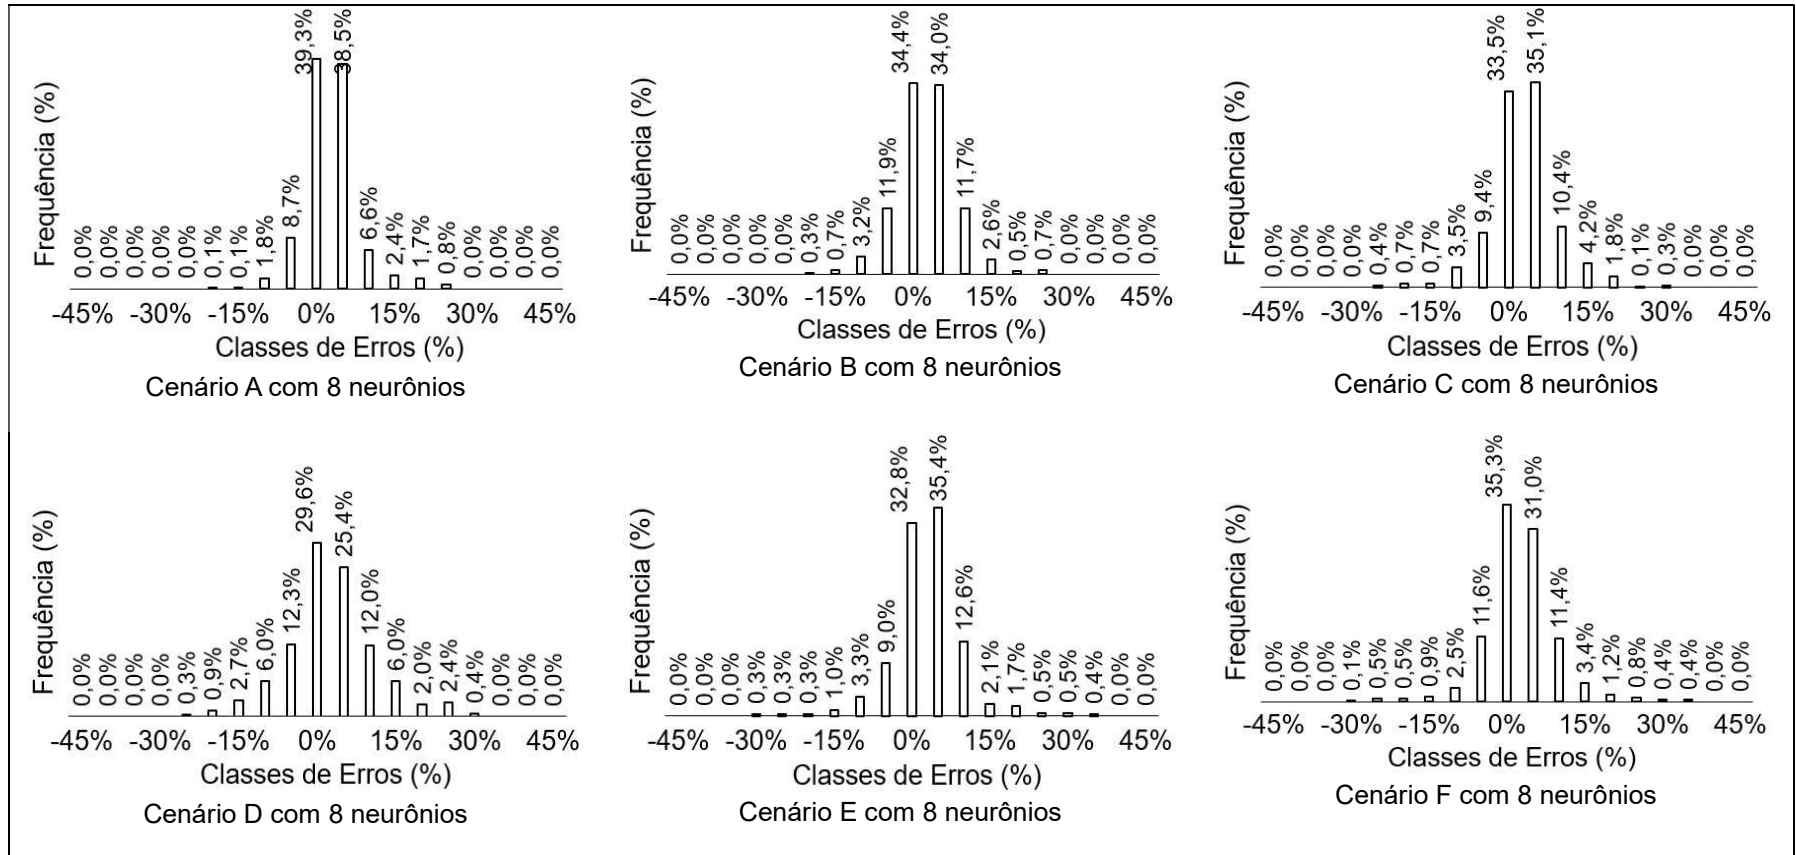
Fonte: A autora.

Gráfico 3.7 – Histograma dos erros obtidos pelas estimativas realizadas pelas RNA treinadas com 4 neurônios na camada intermediária, para cada cenário (A até F)



Fonte: A autora.

Gráfico 3.8 – Histograma dos erros obtidos pelas estimativas realizadas pelas RNA treinadas com 8 neurônios na camada intermediária, para cada cenário (A até F)



Fonte: A autora.

Os coeficientes de correlação entre a metodologia convencional e a RNA para as variáveis *dap* e *h* foram 0,9896, usando 4 neurônios e 0,9945, utilizando 8 neurônios na camada intermediária. O valor do coeficiente de correlação foi elevado e não permitiu diferenciação entre os métodos (LEITE; OLIVEIRA, 2002). Dessa forma, a hipótese de identidade entre os dois métodos foi testada empregando o procedimento estatístico proposto por Leite e Oliveira (2002). Os volumes com casca obtidos pela metodologia convencional e o obtido pela metodologia RNA, utilizando apenas o cenário F, diferem estatisticamente ( $p < 0,05$ ) para todas as parcelas levantadas (Tabela 3.3). Nesta análise, os valores de  $F(H_0)$  e  $t_{\bar{\epsilon}}$  foram não significativos, porém a identidade analítica entre os métodos foi rejeitada por não satisfazer a condição  $r_{Y_j Y_1} \geq 1 - |\bar{\epsilon}|$ . Em relação ao erro médio ( $\bar{\epsilon}$ ), é importante que seja menor que 1, comprovando a alta correlação  $r_{Y_j Y_1} \geq 1 - |\bar{\epsilon}|$  (LEITE; OLIVEIRA, 2002).

Tabela 3.3 – Resultados obtidos pelo método Leite e Oliveira (2002) para RNA com metodologia tradicional com nuvem de pontos com as variáveis *dap* e *h* para o cenário F: Erro Médio ( $\bar{\epsilon}$ ), Teste  $F(H_0)$ , Teste ( $t_{\bar{\epsilon}}$ ) e  $r_{Y_j Y_1} \geq 1 - |\bar{\epsilon}|$

RNA	Erro Médio ( $\bar{\epsilon}$ )	$F(H_0)$	$t_{\bar{\epsilon}}$	$r_{Y_j Y_1} \geq 1 -  \bar{\epsilon} $	Conclusão
4 neurônios	-0,0017	0,4419 <sup>ns</sup>	0,2640 <sup>ns</sup>	Não	$Y_j \neq Y_1$
8 neurônios	-0,0025	2,9399 <sup>ns</sup>	0,8430 <sup>ns</sup>	Não	$Y_j \neq Y_1$

\* Significativo a 5% de significância e <sup>ns</sup> não significativo.

Fonte: A autora.

## 3.5 DISCUSSÃO

### 3.5.1 Extração das Variáveis

As partes superiores dos fustes das árvores não foram totalmente escaneados pelo equipamento LST. Desta forma, as variáveis foram obtidas até altura de 4 metros (Tabela 3.1), pois as partes inferiores dos fustes possuem melhor escaneamento pelo LST, podendo ser modeladas para dar estimativas precisas aos volumes totais (EYSN *et al.*, 2013; RAUMONEN *et al.*, 2013). As partes superiores,

fustes acima de 4 metros, não foram totalmente escaneados devido à ação do vento no momento do levantamento, dificultando a modelagem completa dos fustes.

Os dados LST permitem determinação confiável das variáveis dos fustes de árvores em condições de campo (NÖLKE *et al.*, 2015). No campo, quanto menor for o espaçamento entre árvores maior é o sombreamento dos fustes vizinhos. O método de posicionamento única varredura, no qual o equipamento é posicionado no centro da parcela, gera um escaneamento de apenas um lado do fuste e demanda menor tempo e custo (OLOFSSON *et al.*, 2014; RITTER *et al.*, 2017). Neste método, a precisão da nuvem de pontos diminui à medida que os alvos estão mais afastados do equipamento devido à resolução angular (ASTRUP *et al.*, 2014; LIANG *et al.*, 2016). O método de posicionamento múltiplas varreduras, como por exemplo o método composto por cinco posições, produz nuvens de pontos com qualidade, sendo possível detectar todas as árvores presentes na parcela e reduzir as oclusões (LI *et al.*, 2014).

A reconstrução do fuste melhora a variável  $h$ , pois é possível estimar sua inclinação e sua curvatura (BROLLY; KIRALY, 2009). O valor discrepante encontrado na parcela 3 representa em campo uma árvore bifurcada. Este atributo reduz o volume aproveitável do fuste da árvore (RAUMONEN *et al.*, 2013).

### **3.5.2 Aplicação das RNA's para Estimativa de Volume**

As RNA's já são utilizadas para estimar altura e volume de fustes de árvores, adotando-se o  $dap$  e  $h$  como variáveis de entrada (DIAMANTOPOULOU; MILIOS, 2010; ÖZÇELIK *et al.*, 2010; ÖZÇELIK *et al.*, 2013). As árvores com o mesmo  $dap$  e  $h$  fornecem a mesma modelagem, entretanto a variabilidade de fustes pode resultar em valores de volumes distintos. A variação de forma do fuste do eucalipto é maior na parte basal das árvores e com maior volume. Isto mostra a opção de se utilizar as medidas de diâmetro na base das árvores ainda em pé e utilizá-las, juntamente com o  $dap$  e  $h$ , para estimação do volume das árvores em parcelas de inventário. Medidas de diâmetro em alturas acessíveis poderiam ser utilizadas nas equações de volume, aumentando a exatidão de suas estimativas. O treinamento de um RNA pode ser aplicado na estimativa de novas amostras de árvores, mantendo todo aprendizado acumulado de conjuntos de dados anteriores (NUNES; GÖRGENS, 2016).

Os resultados para as RNA's foram melhores com a seleção de uma mistura de árvores para os diferentes diâmetros obtidos pelo LST. O cenário (A) foi superior aos demais com variáveis contínuas e, portanto, estima o volume com casca com maior precisão. O aumento do número de variáveis incluídas para o treinamento e validação reduz a RQME e aumenta a correlação ( $R_{\hat{Y}Y}$ ) (CASTADO-DORADO *et al.*, 2006). Os cenários (A), (B), (C) e (D) mostraram pequena tendenciosidade, com superestimação do volume para o treinamento (valores bias). Por outro lado, os cenários (E) e (F) mostraram tendência de subestimação (Tabela 3.2). Essa tendenciosidade não constitui um problema, pois árvores têm volumes pequenos e seus erros não resultam em viés no volume total das parcelas (CAMPOS; LEITE, 2017). A amplitude dos erros relativos encontrados nesta pesquisa está dentro de limites usualmente observados em estudos sobre volume de árvores (SOARES *et al.*, 2013). As distribuições dos erros relativos percentuais são semelhantes aos procedimentos usuais de inventário florestal, com a maioria desses erros foram distribuídos aproximadamente em 10%, uma faixa comum em métodos usuais de inventário. Os procedimentos e métodos apresentados foram considerados tecnicamente adequados para estimação do volume de parcelas de inventário florestal. A aplicação, entretanto, requer um banco de dados histórico de cubagem de árvores-amostra colhidas no povoamento. Isto não é um inconveniente, pois as empresas florestais dispõem desse tipo de dado.

Os coeficientes das equações de regressões foram significativos ao nível de 5% de significância pelo teste *t* de *Student* para o volume com casca, obtido pela metodologia convencional comparada com a metodologia RNA para as variáveis *dap* e *h*. Para estas variáveis, houve correlação linear entre os volumes obtidos. O Teste *F* de *Graybill* não foi significativo (Tabela 3.3), e as estimativas de volume com casca não diferiram estatisticamente considerando um nível de 95% de confiança. A identidade não foi verificada devido à condição  $r_{\hat{Y}Y} \geq 1 - |\epsilon|$ . O teste proposto por Leite e Oliveira (2002) é muito rígido devido às restrições estatísticas que devem ser consideradas (LIMA *et al.*, 2011).

### 3.6 CONCLUSÃO

O sistema de Laser Scanner Terrestre (LST) com um modelo de Redes Neurais Artificiais (RNA's) comprova a eficiência para a estimação do volume de árvores em parcelas com a precisão requerida no inventário. A metodologia proposta permitiu de forma eficiente identificar a estrutura espacial de árvores a partir dos dados LST e quantificar o volume com casca de forma não destrutiva, possibilitando a redução dos custos para a construção de equações volumétrica.

### REFERÊNCIAS BIBLIOGRÁFICAS

- AERTSEN, W.; KINT, V.; VAN ORSHOVEN, J.; ÖZKAN, K.; MUYS, B. Comparison and ranking of different modelling techniques for prediction of site index in Mediterranean mountain forests. **Ecological modelling**, v. 221, n. 8, p. 1119-1130, 2010.
- ASNER, G. P.; POWELL, G. V.; MASCARO, J.; KNAPP, D. E.; CLARK, J. K.; JACOBSON, J.; SECADA, L.; KENNEDY-BOWDOINA, T.; BALAJIA, A.; PAEZ-ACOSTAA, G.; VICTORIAC, E.; SECADAD, L.; VALQUID M.; FLINT HUGHES, R. High-resolution forest carbon stocks and emissions in the Amazon. **Proceedings of the National Academy of Sciences**, v. 107, n. 38, p. 16738-16742, 2010.
- ASTRUP, R.; DUCEY, M. J.; GRANHUS, A.; RITTER, T.; VON LÜPKE, N. Approaches for estimating stand-level volume using terrestrial laser scanning in a single-scan mode. **Canadian Journal of Forest Research**, v. 44, n. 6, p. 666-676, 2014.
- BINOTI, M. L. M. S. **Emprego de Redes Neurais Artificiais em Mensuração e Manejo Florestal**. 2012. Tese (Doutorado em Ciência Florestal) – Departamento de Engenharia Florestal, Universidade Federal de Viçosa, Viçosa, MG, 2012.
- BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G. Configuração de redes neurais artificiais para estimação do volume de árvores. **Revista Ciência da Madeira**, v. 5, n. 1, p. 58-67, 2014.
- BROLLY, G.; KIRALY, G. Algorithms for stem mapping by means of terrestrial laser scanning. **Acta Silvatica & Lignaria Hungarica**, v. 5, p. 119-130, 2009.
- BULLINARIA, J. A. **Introduction to Neural Computation**. Course Material and Useful Links, 2004. Disponível em: <http://www.cs.bham.ac.uk/~jxb/inn.html>. Acesso em: 15 nov. 2017.

CALDERS, K.; NEWNHAM, G.; BURT, A.; MURPHY, S.; RAUMONEN, P.; HEROLD, M.; CULVENOR, D.; AVITABILE, V.; DISNEY, M.; ARMSTON, J.; KAASALAINEN, M. Nondestructive estimates of above-ground biomass using terrestrial laser scanning. **Methods in Ecology and Evolution**, v. 6, n. 2, p. 198-208, 2014.

CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal: perguntas e respostas**. Viçosa, MG: Ed. UFV, 5 ed., 2017. 636 p.

CASTADO-DORADO, F.; DIÉGUEZ-ARANDA, U.; BARRIO ANTA, M.; SÁNCHEZ RODRÍGUEZ, M.; GADOW, K. V. A generalized height-diameter model including random components for radiata pine plantations in northwestern Spain. **Forest Ecology and Management**, v. 229, n. 1, p. 202-213, 2006.

DIAMANTOPOULOU, M.J.; MILIOS, E. Modelling total volume of dominant pine trees in reforestations via multivariate analysis and artificial neural network models. **Biosystems engineering**, v. 105, n. 3, p. 306-315, 2010.

EYSN, L.; PFEIFER, N.; RESSL, C.; HOLLAUS, M.; GRAFL, A.; MORSDORF, F. A practical approach for extracting tree models in forest environments based on equirectangular projections of terrestrial laser scans. **Remote Sensing**, v. 5, n. 11, p. 5424-5448, 2013.

GRAYBILL, F. A. **Theory and application of the linear model**. Belmont: Duxbury Press, 1976. 704p.

HAYKIN, S. **Redes Neurais: Princípios e prática**. Porto Alegre: Bookman, Tradução: Paulo Martins Engel, 889 p., 2001.

HÖFLE, B.; GRIESBAUM, L.; FORBRIGER, M. GIS-based detection of gullies in Terrestrial LiDAR data of the Cerro Llamoca Peatland (Peru). **Remote Sensing**, v. 5, n. 11, p. 5851-5870, 2013.

HOPKINSON, C.; CHASMER, L.; YOUNG-POW, C.; TREITZ, P. Assessing forest metrics with a ground-based scanning lidar. **Canadian Journal of Forest Research**, v. 34, n. 3, p. 573-583, 2004.

HYYPPÄ, J.; HOLOPAINEN, M.; OLSSON, H. Laser scanning in forests. **Remote Sensing**, v. 4, n. 10, p. 2919-2922, 2012.

JAIN, A. K.; MAO, J.; MOHIUDDIN, K. Artificial Neural Networks: A Tutorial. **Institute of Electrical and Electronics Engineers (IEEE) Computer**, v. 29, n. 3, p. 31-44, 1996.

JUPP, D. L.; CULVENOR, D. S.; LOVELL, J. L.; NEWNHAM, G. J.; STRAHLER, A. H.; WOODCOCK, C. E. Estimating forest LAI profiles and structural parameters using a ground-based laser called 'Echidna (R)'. **Tree Physiology**, v. 29, n. 2, p. 171-181, 2009.

- LEITE, H. G.; OLIVEIRA, F. H. T. (2002) Statistical procedure to test identity between analytical methods. **Communications in Soil Science and Plant Analysis**, v. 33, v. 7-8, p. 1105-1118, 2002.
- LEITE, H. G., SILVA, M. L. M., BINOTI, D. H. B., FARDIN, L., TAKIZAWA, F. H. Estimation of inside-bark diameter and heartwood diameter for *Tectona grandis* Linn. trees using artificial neural networks. **European Journal of Forest Research**, v. 130, n. 2, p. 263-269, 2011.
- LI, Y.; HESS, C.; VON WEHRDEN, H.; HÄRDTLE, W.; VON OHEIMB, G. Assessing tree dendrometrics in young regenerating plantations using terrestrial laser scanning. **Annals of Forest Science**, v. 71, n. 4, p. 453-462, 2014.
- LIANG, X.; KANKARE, V.; HYYPPÄ, J.; WANG, Y.; KUKKO, A.; HAGGRÉN, H.; YU, X.; KAARTINEN, H.; JAAKKOLA, A.; GUAN, F.; HOLOPAINEN, M.; VASTARANTA, M. Terrestrial laser scanning in forest inventories. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 115, p. 63-77, 2016.
- LIMA, A. M. N.; SILVA, I. R. D.; STAPE, J. L.; MENDONÇA, E. S.; NOVAIS, R. F.; BARROS, N. F. D.; NEVES, J. C. L.; PAUL, K.; SCHULTHAIS, F.; POLGLASE, P.; RAISON, J.; SOARES, E. M. B. Modeling changes in organic carbon stocks for distinct soils in southeastern Brazil after four eucalyptus rotations using the century model. **Revista Brasileira de Ciência do Solo**, v. 35, n. 3, p. 833-847, 2011.
- LIMA, M. B. O.; JUNIOR, I. M. L.; OLIVEIRA, E. M.; FERREIRA, J. E. C. B.; SOARES, K. A. L.; MIGUEL, E. P. Artificial neural networks in whole-stand level modeling of Eucalyptus plants. **African Journal of Agricultural Research**, v. 12, n. 7, p. 524-534, 2017.
- LOVELL, J. L.; JUPP, D. L.; CULVENOR, D. S.; COOPS, N. C. Using airborne and ground-based ranging lidar to measure canopy structure in Australian forests. **Canadian Journal of Remote Sensing**, v. 29, n. 5, p. 607-622, 2003.
- MAAS, H. G.; BIENERT, A.; SCHELLER, S.; KEANE, E. Automatic forest inventory parameter determination from terrestrial laser scanner data. **International Journal of Remote Sensing**, v. 29, n. 5, p. 1579-1593, 2008.
- NEWNHAM, G. J.; ARMSTON, J. D.; CALDERS, K.; DISNEY, M. I.; LOVELL, J. L.; SCHAFF, C. B.; STRAHLER, A. H.; DANSON, F. M. Terrestrial laser scanning for plot-scale forest measurement. **Current Forestry Reports**, v. 1, n. 4, p. 239-251, 2015.
- NIEßNER, M.; ZOLLHÖFER, M.; IZADI, S.; STAMMINGER, M. Real-time 3D reconstruction at scale using voxel hashing. **ACM Transactions on Graphics**, v. 32, n. 6, p. 169, 2013.
- NÖLKE, N.; FEHRMANN, L.; I NENGAH, S. J.; TIRYANA, T.; SEIDEL, D.; KLEINN, C. On the geometry and allometry of big-buttressed trees-a

challenge for forest monitoring: new insights from 3D-modeling with terrestrial laser scanning. **iForest-Biogeosciences and Forestry**, v. 8, n. 5, p. 574, 2015.

NUNES, C. **Predição do sequestro do carbono em área reflorestada utilizando redes neurais artificiais**. 2004. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista, Ilha Solteira, SP, 2004.

NUNES, M. H.; GÖRGENS, E. B. Artificial intelligence procedures for tree taper estimation within a complex vegetation mosaic in brazil. **PLoS ONE**, v. 11, n. 5, p. e0154738, 2016.

OLOFSSON, K.; HOLMGREN, J.; OLSSON, H. Tree stem and height measurements using terrestrial laser scanning and the RANSAC algorithm. **Remote Sensing**, v. 6, n. 5, p. 4323-4344, 2014.

ÖZÇELİK, R.; DIAMANTOPOULOU, M. J.; BROOKS, J. R.; WIANT JR, H. V. Estimating tree bole volume using artificial neural network models for four species in Turkey. **Journal of Environmental Management**, v. 91, n. 3, p. 742-753, 2010.

ÖZÇELİK, R.; DIAMANTOPOULOU, M. J.; CRECENTE-CAMPO, F.; ELER, U. Estimating Crimean juniper tree height using nonlinear regression and artificial neural network models. **Forest Ecology and Management**, v. 306, p. 52-60, 2013.

RAUMONEN, P.; KAASALAINEN, M.; ÅKERBLOM, M.; KAASALAINEN, S.; KAARTINEN, H.; VASTARANTA, M.; HOLOPAINEN, M.; DISNEY, M.; LEWIS, P. Fast automatic precision tree models from terrestrial laser scanner data. **Remote Sensing**, v. 5, n. 2, p. 491-520, 2013.

RITTER, T.; SCHWARZ, M.; TOCKNER, A.; LEISCH, F.; NOTHDURFT, A. Automatic Mapping of Forest Stands Based on Three-Dimensional Point Clouds Derived from Terrestrial Laser-Scanning. **Forests**, v. 8, n. 8, p. 265, 2017.

ROGALSKI, A.; CHRZANOWSKI, K. Infrared devices and techniques. **Optoelectronics Review**, v. 10, n. 2, p. 111-136, 2002.

SOARES, F. A. A.; FLÔRES, E. L.; CABACINHA, C. D.; CARRIJO, G. A.; VEIGA, A. C. P. Recursive diameter prediction and volume calculation of eucalyptus trees using Multilayer Perceptron Networks. **Computers and Electronics in Agriculture**, v. 78, n. 1, p. 19-27, 2011.

SOARES, F. A. A.; FLÔRES, E. L.; CABACINHA, C. D.; CARRIJO, G. A.; VEIGA, A. C. P. Recursive diameter prediction for calculating merchantable volume of eucalyptus clones using Multilayer Perceptron. **Neural Computing and Applications**, v. 22, n. 7-8, p. 1407-1418, 2013.

VALENÇA, M. **Fundamentos das redes neurais: exemplos em Java**. 2ª ed. ver. ampl., Olinda, PE, Ed: Livro Rápido, 2010, 386 p.

VAN DER ZANDE, D.; STUCKENS, J.; VERSTRAETEN, W. W.; MUYS, B.; COPPIN, P. Assessment of light environment variability in broadleaved forest canopies using terrestrial laser scanning. **Remote Sensing**, v. 2, n. 6, p. 1564-1574, 2010.

WEST, P. W. **Tree and forest measurement**. Vol. 20. Heidelberg: Springer, 2009. 190 p.

WILKES, P.; LAU, A.; DISNEY, M.; CALDERS, K.; BURT, A.; TANAGO, J. G.; HEROLD, M. Data acquisition considerations for Terrestrial Laser Scanning of forest plots. **Remote Sensing of Environment**, v. 196, p. 140-153, 2017.

WU, D.; JI, Y. Dynamic estimation of forest volume based on multi-source data and neural network model. **Journal of Agricultural Science**, v. 7, n. 3, p. 18-31, 2015.

## CAPÍTULO 4. ESTIMAÇÃO DE VOLUME DE EUCALYPTUS EM DADOS DE SCANNER LASER TERRESTRES UTILIZANDO INTERPOLAÇÃO E MÉTODO RANSAC

### Resumo:

Os Laser Scanner Terrestre (LST) são utilizados em levantamentos de parcelas de inventário florestal de forma rápida e não destrutiva. Dessa forma, o objetivo deste trabalho foi desenvolver metodologias, para identificar a estrutura espacial de árvores a partir dos dados do LST, para estimar o volume de árvores em povoamentos florestais de eucalipto. O equipamento utilizado durante os experimentos foi um LST modelo VZ400 da Riegl. As parcelas possuíam o formato retangular. Para a redução do efeito de sombreamento do fuste das árvores, o equipamento foi posicionado nas suas quatro extremidades. As parcelas foram delimitadas e filtradas, a partir das nuvens de pontos registradas e ajustadas. O volume foi obtido por duas formas: direta e indireta. Na forma direta, as variáveis foram obtidas diretamente sobre a nuvem de pontos para o cálculo do volume. Na forma indireta, foi utilizada a interpolação pela triangulação de *Delaunay*. Este processo de triangulação obtido diretamente na nuvem de pontos interpola os troncos de árvores vizinhos. Para a individualização dos fustes, foi aplicada a segmentação pelo método RANSAC (*RANdom SAmple Consensus*), pois os fustes possuem a forma parametrizável de um cilindro. O cálculo do volume foi obtido por três interpoladores: Mínimo, Bilinear e Máximo. Para avaliação da qualidade dos resultados obtidos pela metodologia aplicada, foi calculado o erro relativo percentual entre os valores obtidos pelo método direto e pelo método indireto para cada árvore. O menor desvio foi obtido pelo método de interpolação bilinear para as parcelas. A interpolação bilinear apresentou melhor resultado em relação aos interpoladores de mínimo e máximo, pelo fato da rasterização ser realizada, utilizando a média dos seus vizinhos mais próximos.

## 4.1 INTRODUÇÃO

Atualmente, é crescente a demanda por produtos florestais, sejam eles madeireiros ou não-madeireiros. As florestas plantadas suprem grande parte dessa demanda para a produção de celulose e madeira. No Brasil a área plantada com o gênero *Eucalyptus* totalizou 5.105.245 hectares em 2012, sendo Minas Gerais o estado com a maior concentração desse plantio. O investimento em pesquisa e inovação tecnológica de indústrias de papel e celulose tornam o Brasil um dos maiores produtores de eucalipto do mundo (ABRAF, 2012).

O avanço tecnológico nos últimos anos tem proporcionado maior rapidez e precisão das informações coletadas, com destaque para os Laser Scanner Terrestre (LST), que ganharam popularidade crescente no domínio florestal. Atualmente, os LST são amplamente utilizados para a medição automática de atributos de inventário florestal (OTHMANI *et al.*, 2013; EYSN *et al.*, 2013; RAUMONEN *et al.*, 2013; OLSOY *et al.*, 2014; MENGESHA *et al.*, 2015; LIANG *et al.*, 2016).

As principais vantagens dos levantamentos com LST são a rapidez na coleta de dados, além de possuir uma capacidade na geração de uma densa nuvem de pontos tridimensionais. Outra vantagem do uso do LST na área florestal é que ele é uma alternativa não destrutiva para mensuração de árvores (BIENERT *et al.*, 2006). O LST disponível no mercado de geotecnologias gera coordenadas tridimensionais de pontos sobre uma superfície por meio de um sistema de varredura bidimensional.

O levantamento de dados, utilizando o LST permite obter a representação vertical para diferentes formações florestais (EYSN *et al.*, 2013). No levantamento realizado pelo LST, o mapeamento das árvores é realizado, utilizando única varredura (uma estação ou escaneamento) e múltiplas varreduras (duas ou mais estações ou escaneamentos). Para única varredura, geralmente o equipamento é posicionado no centro da parcela florestal e a aquisição dos dados é realizada de forma parcial, em apenas um lado da árvore. Na abordagem de múltiplas varreduras, tem-se toda a superfície do tronco da árvore recoberta por pontos laser, porém os dados dos diferentes posicionamentos precisam ser corrigidos para um sistema de coordenadas comuns, através da operação de registro (ASTRUP *et al.*, 2014).

A nuvem de pontos representa a superfície do tronco da árvore, objeto de interesse, assim como pontos de galhos, folhas e demais objetos que se encontram

no campo de visada do equipamento. Na aplicação da modelagem tridimensional, é necessária a eliminação dos objetos que não fazem parte do tronco das árvores (LITKEY *et al.*, 2008; LIANG *et al.*, 2008). O isolamento da superfície do tronco é uma etapa indispensável à construção de um modelo tridimensional do tronco. O método RANSAC (*RANdom SAmple Consensus*) é um método muito robusto empregado para reconhecimento de objetos parametrizáveis, determinando a forma do objeto a partir de nuvens de pontos (FISCHLER; BOLLES, 1981).

O objetivo deste trabalho foi desenvolver metodologias para identificar a estrutura espacial de árvores a partir dos dados do LST, bem com estimar o volume de árvores em povoamentos florestais de eucalipto, a partir da nuvem de pontos. Para a individualização dos troncos, foi aplicada a segmentação pelo método RANSAC, pois os troncos possuem a forma parametrizável de um cilindro. O volume foi obtido por duas formas: a direta e a indireta. Na forma direta, as variáveis foram obtidas diretamente sobre a nuvem de pontos para o cálculo do volume. Já na forma indireta, foi utilizada a interpolação pela triangulação de *Delaunay*. Como objetivo específico, avaliou-se o desempenho do volume obtido pela forma direta com a modelagem tradicional de Schumacher e Hall (1933).

## 4.2 RANSAC

O RANSAC é um algoritmo robusto, para ajuste de modelos, que foi publicado inicialmente por Fischler e Bolles em 1981 (FISCHLER; BOLLES, 1981). Na computação RANSAC, o tempo é dependente dos objetos que estão disponíveis na nuvem dos pontos a serem parametrizáveis e no número de iterações máximas. O RANSAC foi desenvolvido para detectar diversas formas geométricas, entre elas: planos, esferas, cilindros, cones e anéis em nuvens de pontos. A otimização para RANSAC utiliza o filtro *octree*, para estabelecer a proximidade espacial entre as entradas, aprimorando a detecção de planos, esferas, cilindros, cones e anéis, utilizando pontos num espaço 3-D como entrada (SCHNABEL *et al.*, 2007).

O RANSAC consiste num Método para estimação de parâmetros de um modelo a partir de um conjunto de dados que apresenta erros grosseiros (*outliers*). No RANSAC, o menor conjunto de dados é utilizado na tentativa de acrescentar iterativamente as observações corretas (*inliers*) a um conjunto consistente

(consenso). Assumindo que o modelo matemático foi definido com objetivo de ajustar de forma robusta um modelo para um conjunto de pontos  $S$  que contém *outliers* (FISCHLER; BOLLES, 1981; FENG; HUNG, 2003; HARTLEY; ZISSERMAN, 2003; DERPANIS, 2010). Desta forma, as etapas a seguir descrevem o funcionamento do algoritmo (FISCHLER; BOLLES, 1981):

1. Dado um modelo hipotético ( $M$ ) que requer  $n$  observações para ser realizado e o conjunto  $P$  de todas as observações, tal que  $\#P \geq n\#$ , onde  $\#$  é o operador cardinalidade de um dado conjunto;
2. Selecionar aleatoriamente um subconjunto  $S_1$  com  $n$  observações e realizar o modelo  $M$ , obtendo assim o modelo realizado  $M_r$ ;
3. Utilizar o modelo  $M_r$  para gerar um subconjunto  $S_1^*$  de  $P$ , tal que  $S_1^*$  que contenha as observações consistentes com  $M_r$  (uma observação é consistente com  $M_r$  se o erro entre o valor observado e o correspondente valor predito pelo  $M_r$  estiver abaixo de uma tolerância), dessa forma o subconjunto  $S_1^*$  é denominado conjunto consenso de  $S_1$ ;
4. Se  $\#S_1^*$  for maior que um limiar  $t$ , que pode ser estimado em função do conhecimento da taxa de erros grosseiros em  $P$ , usar  $S_1^*$  para restabelecer um novo modelo hipotético  $M_r^*$ , usando por exemplo o Método dos Mínimos Quadrados (MMQ);
5. Se  $\#S_1^*$  for menor que um limiar  $t$ , selecionar um novo subconjunto  $S_2$ , tal que  $\#S_2 = n$ , e voltar à etapa 2.

De acordo com Fischler e Bolles (1981), se, após certo número de iterações, nenhum conjunto consenso, compatível com o limiar  $t$ , for encontrado, deve-se considerar uma das seguintes possibilidades: realizar o conjunto  $M$  com o maior conjunto consenso encontrado, ou assumir que o procedimento falhou e encerrá-lo.

A quantidade de iterações, para encontrar o conjunto consenso é escolhida como sendo alta o suficiente para garantir, com uma probabilidade  $p$  (geralmente selecionada como 0,99), que ao menos um dos conjuntos de observações selecionados não contenha observações incorretas. Assumindo que  $u$  seja a probabilidade de que qualquer ponto de dados selecionado seja um *inlier* e  $v = 1 - u$  seja a probabilidade de observar um *outlier*, e que  $m$  represente a quantidade de pontos mínima, para estimar os parâmetros do modelo, a quantidade de iterações

mínima  $N(p, v, m)$  (Equação 4.1) (FISCHLER; BOLLES, 1981; HARTLEY; ZISSERMAN, 2003; DERPANIS, 2010):

$$1 - p = (1 - u^m)^N \quad (4.1)$$

Onde:  $p$  é a probabilidade;  $u$  é a probabilidade de que qualquer ponto de dados selecionado seja um *inlier*;  $v = 1 - u$  seja a probabilidade de observar um *outlier*;  $m$  é a quantidade de pontos mínimos; e  $N$  número de interações.

assim o número de iterações necessárias é dado por (Equação 4.2):

$$N = \frac{\log(1-p)}{\log[1-(1-v)^m]} \quad (2)$$

Diversas aplicações para extração de planos de telhados de edificações apresentam métodos, utilizando o algoritmo RANSAC (FORLANI *et al.*, 2006; YAN *et al.*, 2012; YANO; DAL POZ, 2016). O RANSAC também foi aplicado como filtro para a eliminação da vegetação (DRESCH; SANTOS, 2015). Outra aplicação é uma versão modificada do algoritmo RANSAC, utilizando paraboloides elípticos como modelo matemático para modelagem da copa das árvores. Com essa aplicação, torna-se possível extrair informações da vegetação, utilizando modelos de regressão com métricas extraídas em campo (TASHA-KURDI *et al.*, 2008; TITTMANN *et al.*, 2011).

## 4.3 MATERIAIS E MÉTODOS

### 4.3.1 Área de Estudo

Os dados utilizados neste trabalho são provenientes de povoamentos de clones eucalipto, localizados no município de Belo Oriente, Estado de Minas Gerais, região próxima às coordenadas geográficas 19° 22' 25,42" Sul e 42° 28' 28,27" Oeste. Três parcelas do inventário de pré-corte foram levantadas aleatoriamente. As parcelas tinham dimensões de 21 x 15 m (parcela 1), 18 x 15 m (parcela 2) e 8 x 10m (parcela 3). A área de estudo foi mensurada em um povoamento comercial de eucalipto em idade técnica de corte com aproximadamente 7 anos.

### 4.3.2 Levantamento de Campo

Para realização deste trabalho, foi desenvolvida uma metodologia a partir dos dados Laser Scanner Terrestre (LST, para explorar medidas convencionais em aplicações florestais). A varredura laser realizada no presente estudo consistiu na aquisição de dados pontuais de toda superfície das árvores. As nuvens de pontos com coordenadas tridimensionais (X, Y, Z) foram obtidas das feições presentes no campo de visada do equipamento, para reconstrução da área das parcelas retangulares em campo.

Destaca-se que o tipo de LST utilizado na mensuração florestal deve atender às características do equipamento com a qualidade e quantidade de pontos a serem mapeados. Para levantamentos a curtas distâncias, que necessitem de uma alta densidade de pontos coletados, seria mais indicado um equipamento com princípio baseado na diferença de fase (MÁRQUEZ, 2010). Já no caso de levantamento de objetos que estão a grandes distâncias, um equipamento cujo sistema opera baseado no tempo de retorno do sinal tem as características mais adequadas para essas aplicações. Para aplicações florestais que se utilizam de informações distribuídas ao longo de um plantio, os equipamentos que recorrem ao sistema de tempo de retorno do sinal são os mais utilizados. Nesta pesquisa, foi utilizado o equipamento LST da Riegl VZ-400, que opera com o princípio de tempo de retorno de sinal.

O equipamento VZ-400 possui campo de visão (*Field of View* - FoV) de Hz: 360° e V: 100° e alta velocidade de varrimento. O modo de varredura utilizado foi o *Long Range* com resolução angular de 0,02° (*Angle measurement resolution*= 0,02°), correspondente a uma resolução espacial de 3,5 mm para uma distância de 10 m do equipamento. No *Long Range*, o alcance de varredura vertical e horizontal aos objetos foram: alcances mínimo e máximo de 1 m e 600 m (taxa de emissão de pulso de 100Khz). No modo de varredura *Long Range*, a máxima distância foi de 500 m para refletores naturais (refletividade  $\rho \geq 80\%$ ) e 160 m para refletores com  $\rho \geq 10\%$ . Uma câmera modelo Nikon D700 calibrada foi acoplada no equipamento, para aquisição de fotos e atribuição dos valores de RGB (*Red*, *Green* e *Blue*) em cada ponto da nuvem. Esta informação permite representar a nuvem de pontos com cores e, conseqüentemente, melhor análise visual dos objetos de interesse.

Os alvos (*targets*) do tipo faixas adesivas refletoras foram colocados sobre os troncos das árvores. Em cada parcela da área de estudo, foram distribuídos 20 alvos em diferentes troncos das árvores dispostos não linearmente. A disposição destes alvos observou que os mesmos deveriam ser visualizados em mais de um escaneamento. O propósito destes alvos é a possibilidade de identificação com precisão de pontos homólogos entre as cenas e, conseqüentemente, a elaboração de um conjunto de dados em um único sistema de coordenadas local.

O posicionamento do equipamento foi realizado com base na orientação das linhas de plantio. As medidas ao longo do tronco foram obtidas, utilizando a forma múltiplas varreduras de posicionamento do equipamento LST com cinco posições, contemplando todas as parcelas. Essa medida foi tomada, pois, ao utilizar única varredura, pode-se causar efeitos de oclusão, baixa densidade de pontos e, em certos locais da parcela, grande quantidade de ruídos (LIANG *et al.*, 2016). Assim, esses autores sugeriram o modo múltiplas varreduras para contornar estes efeitos.

#### **4.3.3 Pré-Processamento dos Dados**

A etapa de pré-processamento dos dados LST tem como objetivo a separação dos pontos pertencentes aos troncos dos demais pontos da nuvem de pontos, bem como a separação da nuvem de pontos de cada tronco. Para coleta, visualização, registro, união e filtragem manual e automática das árvores foi utilizado o software da Riegl RiSCAN-PRO (RiEGL Laser Measurement Systems, Horn, Austria), que acompanha os equipamentos LST da série VZ (RIEGL, 2015). O RiSCAN-PRO possui diversos módulos que permitem o gerenciamento e o processamento da nuvem de pontos. Este software foi utilizado para configuração do sensor, aquisição de dados, visualização, manipulação e processamento dos dados com coordenadas tridimensionais, intensidade dos pontos e dos valores RGB (*Red*, *Green* e *Blue*).


Devido a erros de levantamento, posicionamentos e instabilidade dos refletores, a fase do registro direto não garante que todas as cenas fiquem alinhadas. Para contornar este problema, o software tem um plug-in denominado *Multi-Station Adjustment* (MSA). No MSA, a iteração do ajustamento é realizada a cada duas posições (*scan positions*). Insere-se, a cada novo processamento, mais

duas posições (*scan positions*), até concluir todas as posições (*scan positions*) a serem ajustadas (HÖFLE *et al.*, 2013).

Para as três parcelas delimitadas de acordo com suas áreas, foi necessário proceder à filtragem para extração do tronco devido à presença de galhos e sub-bosque. Para extração dos troncos, dois filtros foram aplicados: *Height filter* e *Octree filter*. O filtro *Height filter* consiste na classificação da nuvem de pontos do LST como pertencente ou não-pertencente à superfície do terreno. O filtro *Octree filter* foi aplicado, para diminuir a densidade da nuvem de pontos, tornando-a mais homogênea e menos densa, sem comprometer a qualidade dos dados. Ele funciona como uma estrutura de dados hierárquica que define subdivisões de um espaço tridimensional em cubos, chamados de *voxels*. O *voxel* inicial, que normalmente cobre todo o domínio do espaço a ser analisado, é dividido em oito partes iguais, gerando novos cubos, que são chamados de *voxels* filhos. Estes, por sua vez, podem ser subdivididos da mesma forma, num processo recursivo, cujo limite da divisão pode ser definido previamente, como, por exemplo, no tamanho mínimo do *voxel* (NIEßNER *et al.*, 2013).


Após o pré-processamento, foi gerada uma *Polydata*, contendo uma nuvem de pontos com os pontos obtidos nas cinco posições de levantamento. Posteriormente, foi gerado um subconjunto da nuvem pontos, representando cada parcela do inventário analisada para cada 2 metros, 3 metros e 4 metros de altura dos fustes (Figuras 4.1, 4.2 e 4.3).

Figura 4.1 – Recorte da Parcela 1 contendo em ordem os planos para cada diferente altura de 2,0 m, 3,0 m e 4,0 m, em relação ao eixo Z




Fonte: A autora.

Figura 4.2 – Recorte da Parcela 2 contendo em ordem os planos para cada diferente altura de 2,0 m, 3,0 m e 4,0 m, em relação ao eixo Z



Fonte: A autora.

Figura 4.3 – Recorte da Parcela 3 contendo em ordem os planos para cada diferente altura de 2,0 m, 3,0 m e 4,0 m, em relação ao eixo Z



Fonte: A autora.

#### 4.3.4 Métodos

A metodologia desenvolvida no presente estudo consistiu em obter o volume por dois diferentes métodos, o método direto e o indireto. No método direto, o volume foi calculado a partir das variáveis obtidas nas alturas de 0,0; 0,5; 1,0; 1,3; 2,0 e 4,0 m em relação ao eixo Z, diretamente sobre a nuvem de pontos obtida pelo LST, que corresponde respectivamente às variáveis  $d_{(h=0,0m)}$ ,  $d_{(h=0,5m)}$ ,  $d_{(h=1,0m)}$ ,  $d_{ap}$ ,  $d_{(h=2,0m)}$  e  $d_{(h=4,0m)}$ .

O método indireto consistiu em extrair os contornos das formas de cada tronco a partir da nuvem de pontos gerados pelo LST. Para isso, foi implementado o processo de identificação da nuvem de pontos de cada tronco a partir do uso do

algoritmo RANSAC. Posteriormente, sobre a nuvem de pontos extraídos para cada tronco, foi realizada a triangulação de *Delaunay*, para modelar as respectivas formas.

Para a aplicação do RANSAC, foi utilizado o *plugin Efficient RANSAC for Point-Cloud Shape Detection* (SCHNABEL *et al.*, 2007), disponível no *software* livre CloudCompare 3D (CLOUDCOMPARE, 2017) para processamento de nuvem de pontos e de malha (*mesh*). Para a aplicação do algoritmo, alguns parâmetros foram selecionados de forma empírica, para individualização de cada fuste presente nas parcelas 1, 2 e 3:

1. Primitivo do tipo cilindro;
2. Mínimo de pontos por primitivo 1.200 pontos;
3. Desvio normal máximo  $\alpha = 45^\circ$ ;
4. Probabilidade de 99% ( $\alpha = 1\%$ ).

A Tabela 4.1 mostra o resumo dos parâmetros usados para cada parcela da análise. O valor referente a 1.200 pontos, definido empiricamente após observação e análise em cada uma das parcelas da área de estudo, equivale ao mínimo provável de pontos para reconstrução de um cilindro baseado na densidade de pontos e em uma área formada pelo cilindro. Foram utilizados 0,111 metros (Parcela 1), 0,014 metros (Parcela 2) e 0,095 metros (Parcela 3) para as distâncias máximas da nuvem de pontos ao cilindro filtrado, para evitar qualquer excesso ou escassez de pontos. A resolução utilizada para a amostragem foi de 0,221 metros (Parcela 1), 0,227 metros (Parcela 2) e 0,191 metros (Parcela 3), para garantir o número mínimo de pontos do cilindro. Para diminuir o número de iterações, tornando o processamento rápido, a probabilidade utilizada foi de 99% para que um ponto cujo erro de ajuste seja menor ou igual a sigma, ou seja, um *inlier*.

Tabela 4.1 – Parâmetros utilizados para a aplicação do RANSAC

<b>Parâmetro</b>	<b>Parcela 1</b>	<b>Parcela 2</b>	<b>Parcela 3</b>
Mínimo de pontos	1.200	1.200	1.200
Máxima distância (m)	0,121	0,014	0,095
Resolução (m)	0,221	0,227	0,191
Probabilidade	99% ( $\alpha = 1\%$ )	99% ( $\alpha = 1\%$ )	99% ( $\alpha = 1\%$ )

Fonte: A autora.

Para aquisição de volumes, foram interpoladas as nuvens de pontos relativas às alturas de 2 metros, 3 metros e 4 metros, para cada árvore presente em cada parcela. Todos os pontos foram triangulados com um algoritmo de triangulação 2D-*Delaunay*. A triangulação de *Delaunay* foi calculada a partir de coordenadas (X, Y) dos vértices mapeados no plano de referência. O volume é calculado entre o plano, obtido pela nuvem de pontos do terreno, e a superfície resultante. No processo de rasterização, foram utilizados três diferentes interpoladores: Mínimo, Bilinear e Máximo com resolução espacial de 1 centímetro. Esse processamento não foi viável, utilizando os outros tipos de posicionamento com o equipamento LST, pois para uma posição e duas posições ocorreu oclusão de dados no momento do levantamento. O interpolador Bilinear utiliza uma média ponderada de distância dos quatro pixels vizinhos mais próximos para determinar a intensidade do valor de cada pixel na imagem resultante. Para os interpoladores Mínimo e Máximo, são utilizados, respectivamente, apenas os pontos com menor e maior distância ao plano de referência.

A fim de avaliar a qualidade dos resultados obtidos pela metodologia aplicada, foi calculado o desvio relativo percentual entre os valores estimados e os valores medidos dos volumes dos fustes com alturas até 2 metros, 3 metros e 4 metros (Equação 4.3).

$$Desvio(\%) = \frac{(Volume_{Interpolação} - Volume_{LST})}{Volume_{LST}} * 100 \quad (4.3)$$

Os volumes individuais foram obtidos por meio do modelo volumétrico adotado, proposto por Schumacher e Hall (1933) e representado na Equação 4.4:

$$V = \beta_0 * dap_{(LST)}^{\beta_1} * h_{(LST)}^{\beta_2} * V_{(LST)}^{\beta_3} * \varepsilon \quad (4.4)$$

Onde:  $V$  = volume ( $m^3$ );  $V_{LST}$  = volume ( $m^3$ ) obtido pelo LST com alturas de 2, 3 ou 4 metros do fuste;  $dap_{(LST)}$  = diâmetro (cm) a 1,3 m de altura obtido pelo LST;  $h_{(LST)}$  = altura total (m) da árvore obtida pelo LST;  $\beta_i$  = parâmetros; e  $\varepsilon$  = erro aleatório,  $\varepsilon \sim Normal(0, \sigma^2)$ .

Para obter a estimativa dos parâmetros pelo Método dos Mínimos Quadrados Ordinários, procedeu-se à aproximação linear do modelo de Schumacher e Hall (1933), através da transformação logarítmica, conforme Equação 4.5:


$$\ln V = \beta_0 + \beta_1 * \ln dap + \beta_2 * \ln h + \beta_3 * \ln V_{LST} + \varepsilon \quad (4.5)$$

#### 4.4 RESULTADOS E DISCUSSÃO


Os resultados foram analisados visualmente e numericamente. A análise visual foi realizada a partir da inspeção visual dos cilindros de cada tronco de árvore, sobrepostos na nuvem de pontos. A análise numérica foi feita através do cálculo dos desvios obtidos em relação aos volumes de cada fuste. Os resultados dos primitivos do cilindro, representando cada fuste em cada parcela da área de estudos, são mostrados na Figura 4.4. As nuvens de pontos foram obtidas até altura de 4 metros, pois as partes inferiores dos troncos possuem melhor escaneamento pelo LST, podendo ser modeladas para dar estimativas precisas aos volumes totais (EYSN *et al.*, 2013; RAUMONEN *et al.*, 2013). As partes superiores dos fustes com altura acima de 4 metros não foram totalmente modeladas devido à ação do vento no momento do levantamento.

O algoritmo RANSAC é iterativo e probabilístico, e, por ser robusto, tem um custo computacional elevado. De acordo com Simões (2017), a filtragem utilizada no pré-processamento reduz o número de pontos numa grande escala e diminuiu a quantidade de recursos computacionais gastos na execução do algoritmo. Para diminuir o esforço computacional, foi realizada a filtragem como forma de extrair os galhos e sub-bosque presentes nas parcelas.


Figura 4.4 – *Polydata* contendo uma nuvem de pontos (X, Y, Z) com o isolamento de fuste obtido pela aplicação do RANSAC



Parcela 1



Parcela 2



Parcela 3

Fonte: A autora.

Para avaliação da qualidade dos resultados obtidos pela metodologia aplicada, foi calculado o desvio relativo percentual entre os valores de volumes pelo método direto e pelo método indireto para cada árvore, com altura até 4 metros (Equação 4.3).

Na Tabela 4.2, é apresentado o volume total dos fustes presentes nas respectivas parcelas obtidos pelas metodologias direta e indireta. A menor porcentagem do desvio foi obtida pelo método de interpolação bilinear para todas as três parcelas. A interpolação bilinear apresentou melhor resultado em relação aos interpoladores de mínimo e máximo, pelo fato da rasterização ter sido realizada a partir da média dos vizinhos mais próximos. Na parcela 1, os menores desvios tiveram variação negativa, enquanto na parcela 3, o maior desvio teve com variação positiva.

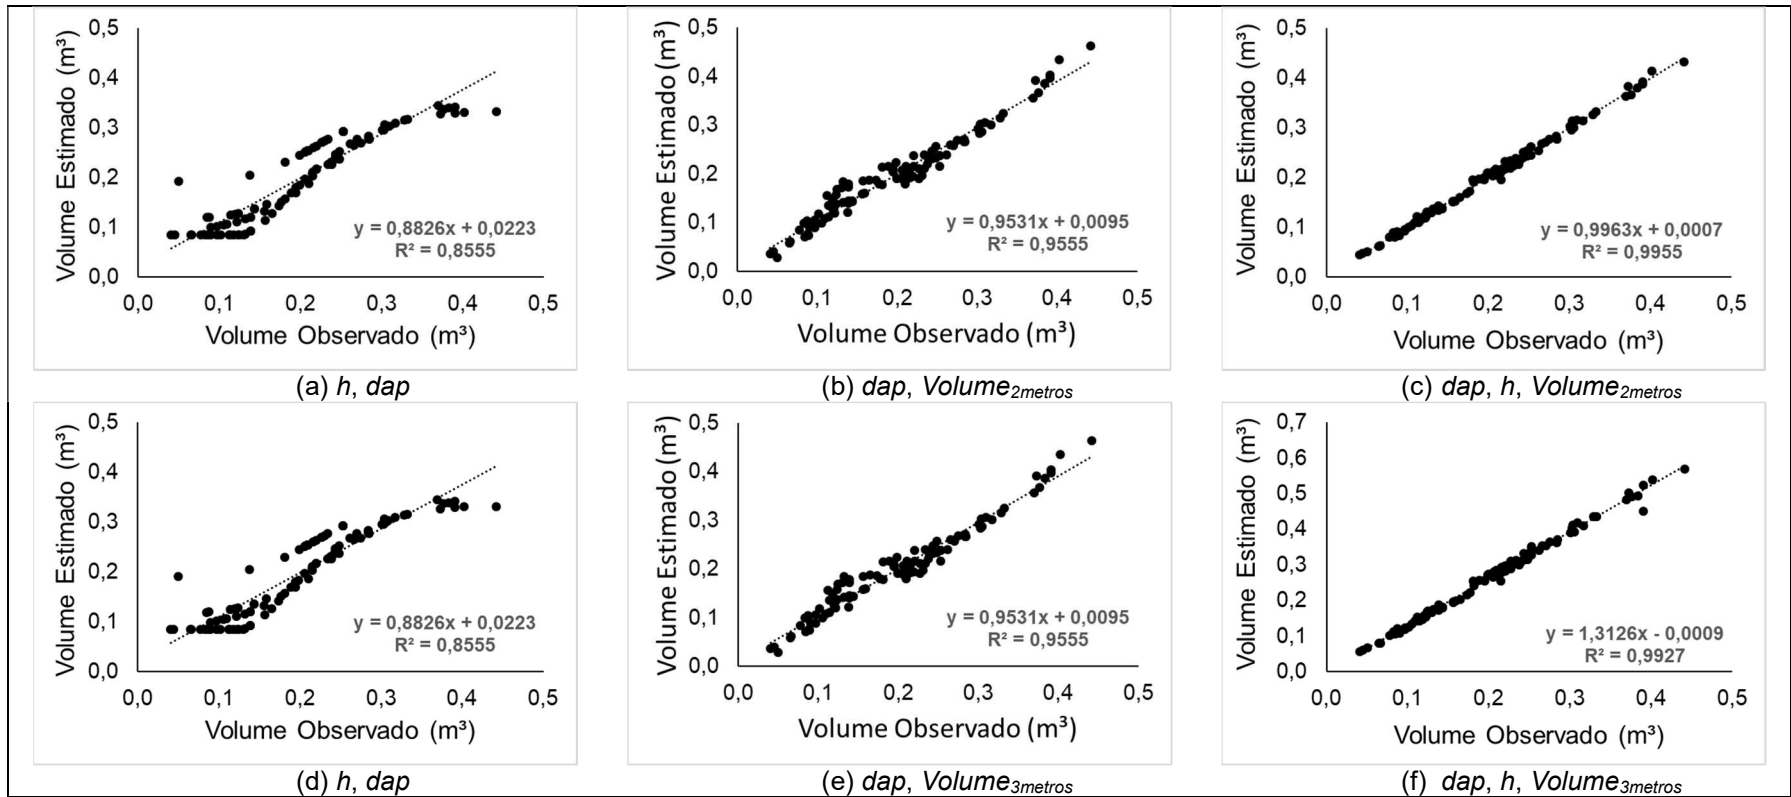
De acordo com a Tabela 4.2, os menores desvios foram obtidos pelo interpolador Bilinear. Desta forma, os valores obtidos por estes interpoladores foram confrontados com a metodologia tradicional, utilizando o modelo de Schumacher e Hall. Na análise gráfica dos ajustes do modelo de Schumacher e Hall (Gráficos 4.1 e 4.2), verifica-se que as variáveis  $dap$ ,  $h$  e os diferentes *Volumes* ( $Volume_{2metros}$ ,  $Volume_{3metros}$  e  $Volume_{4metros}$ ) obtidos pelo LST apresentaram melhor ajuste dos dados. Os piores ajustes foram obtidos com as variáveis  $dap$  e  $h$  obtidas pelo LST. Analisando os resultados, verifica-se como solução eficiente o cálculo do volume para a modelagem dos dados com as variáveis  $dap$ ,  $h$  e  $Volume_{2metros}$ . Não é necessário o cálculo do volume com alturas superiores, como as alturas de 3 m e 4 m.

Tabela 4.2 – Resultados de volume obtidos pelos métodos direto e indireto para as Parcelas 1, 2 e 3

		Volume	Volume Indireto (m <sup>3</sup> )		
		Direto (m <sup>3</sup> )	Mínimo	Bilinear	Máximo
Parcela 1	4 m	3,2337	2,0292	3,2317	4,0628
		Desvio (%)	-37,2491	<b>-0,0603</b>	25,6387
	3 m	2,5976	1,6075	2,5953	2,1764
		Desvio (%)	-38,1158	<b>-0,0910</b>	-16,2164
	2 m	1,9161	0,9104	1,9167	1,2012
		Desvio (%)	-52,4858	<b>-0,0308</b>	-37,3104
		Volume	Volume Indireto (m <sup>3</sup> )		
		Direto (m <sup>3</sup> )	Mínimo	Bilinear	Máximo
Parcela 2	4 m	2,3528	2,1968	2,3567	2,7283
		Desvio (%)	-6,6306	<b>0,1646</b>	-15,9561
	3 m	1,9002	0,6575	1,8966	0,5349
		Desvio (%)	-65,3992	<b>-0,1874</b>	-71,8504
	2 m	1,4094	0,3431	1,4092	0,3527
		Desvio (%)	-75,6594	<b>-0,0188</b>	-74,9757
		Volume	Volume Indireto (m <sup>3</sup> )		
		Direto (m <sup>3</sup> )	Mínimo	Bilinear	Máximo
Parcela 3	4 m	2,3528	1,5762	1,8836	2,1335
		Desvio (%)	-16,3552	<b>-0,0402</b>	13,2202
	3 m	1,9002	0,3811	1,4963	0,3849
		Desvio (%)	-74,5001	<b>0,1191</b>	-74,2422
	2 m	1,4094	0,2207	1,0828	0,2235
		Desvio (%)	-79,6170	<b>-0,0069</b>	-79,3650


Fonte: A autora.

Gráfico 4.1 – Análise gráfica do ajuste do modelo Schumacher e Hall por diferentes variáveis: (a) e (d) *dap* e *h*; (b) *dap* e *Volume*<sub>2metros</sub>; (e) *dap* e *Volume*<sub>3metros</sub>; (c) *dap*, *h* e *Volume*<sub>2metros</sub>; (f) *dap*, *h* e *Volume*<sub>3metros</sub>



Fonte: A autora.

Gráfico 4.2 – Análise gráfica do ajuste do modelo Schumacher e Hall por diferentes variáveis: (a) *dap* e *h*; (b) *dap* e *Volume*<sub>4metros</sub>; (c) *dap* e *Volume*<sub>4metros</sub>



Fonte: A autora.

## 4.5 CONCLUSÃO

O sistema Laser Scanner Terrestre (LST) com o algoritmo RANSAC e a triangulação *Delaunay* comprovam a eficiência para a estimação do volume de árvores em parcelas com a precisão requerida no inventário. A taxa de detecção de árvores foi de 100% para todas as parcelas, ou seja, não ocorre o problema de fustes sombreados, pois o levantamento das parcelas foi obtido pelo modo múltiplas varreduras com cinco posições.

A aplicação do algoritmo RANSAC para o isolamento do tronco de árvores resultou em dados adequados à modelagem tridimensional, nos quais a nuvem de pontos manteve as características geométricas do tronco da árvore para quantificar o volume de forma não destrutiva. A interpolação bilinear apresentou melhor resultado em relação aos interpoladores de mínimo e de máximo, pelo fato da rasterização ser realizada, utilizando a média dos pontos vizinhos mais próximos. O ajuste do modelo de Schumacher e Hall pode ser usado na sua forma linear, com boa representatividade.

## REFERÊNCIAS BIBLIOGRÁFICAS

ASSOCIAÇÃO BRASILEIRA DOS PRODUTORES DE FLORESTAS PLANTADAS (ABRAF), 2012. **Anuário Estatístico**: Ano base 2012. Brasília: Abraf, 2012. Disponível em: <http://www.ipef.br/estatisticas/relatorios/anuario-abraf13-br.pdf>. Acesso em: 10 de mar. 2017.

ASTRUP, R.; DUCEY, M. J.; GRANHUS, A.; RITTER, T.; VON LÜPKE, N. Approaches for estimating stand-level volume using terrestrial laser scanning in a single-scan mode. **Canadian journal of forest research**, v. 44, n. 6, p. 666-676, 2014. doi: 10.1139/cjfr-2013-0535

BIENERT, A.; MAAS, H. G.; SCHELLER, S. Analysis of the Information Content of Terrestrial Laser scanner Point Clouds for the Automatic Determination of Forest Inventory Parameters. In: **Proceedings of the International, Workshop on 3D Remote Sensing in Forestry**, Vienna, Austria, 14-15 February, p. 55-60, 2006.

Cloud Compare V2, Version: 2.8 beta. GLP Software. 2017. Disponível em: <http://www.cloudcompare.org>. Acesso em: 20 mar. 2017.

DERPANIS, K. G. **Overview of the ransac algorithm**. 2010. Disponível em: <[http://www.cse.yorku.ca/~kosta/CompVis\\_Notes/ransac.pdf](http://www.cse.yorku.ca/~kosta/CompVis_Notes/ransac.pdf)> [Acesso em 04 de janeiro de 2017].

DRESH, G.; SANTOS, D. R. Avaliação automática da acurácia relativa de dados LiDAR aerotransportado. **Boletim de Ciências Geodésicas**, v. 21, n. 4, p. 730-749, 2015.

EYSN, L.; PFEIFER, N.; RESSL, C.; HOLLAUS, M.; GRAFL, A.; MORSDORF, F. A practical approach for extracting tree models in forest environments based on equirectangular projections of terrestrial laser scans. **Remote Sensing**, v. 5, n. 11, p. 5424-5448. 2013.

FENG, C. L.; HUNG, Y. S. A Robust Method for Estimating the Fundamental Matrix. *In: DIGITAL IMAGE COMPUTING: TECHNIQUES AND APPLICATIONS*, v.24, n. 3, p. 271-300, 2003.

FISCHLER, M. A.; BOLLES, R. C. A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography. *In: (reprinted): READINGS IN COMPUTER VISION, COMMUNICATIONS OF THE ACM*, v. 24, n. 6, p. 381-395, 1981.

FORLANI, G.; NARDINOCCHI, C.; SCAIONI, M.; ZINGARETTI, P. Complete classification of raw lidar data and 3d reconstruction of buildings. **Pattern Analysis and Applications**, v. 8, n. 4, p. 357-374, 2006.

HARTLEY, R.; ZISSERMAN, A. **Multiple view geometry in computer vision**. 2 ed. Cambridge: Cambridge university press, 2006.

HÖFLE, B.; GRIESBAUM, L.; FORBRIGER, M. GIS-based detection of gullies in Terrestrial LiDAR data of the Cerro Llamoca Peatland (Peru). **Remote Sensing**, v. 5, n. 11, p. 5851-5870, 2013.

LIANG, X.; LITKEY, P.; HYYPPÄ, J.; KUKKO, A.; KAARTINEN, H.; HOLOPAINEN, M. 2008. Plot-Level Trunk Detection and Reconstruction Using One-Scan-Mode Terrestrial Laser Scanning Data. *In: EARTH OBSERVATION AND REMOTE SENSING APPLICATIONS (EORSA 2008), INTERNATIONAL WORKSHOP ON*, Beijing, p. 1-5, 2008.

LIANG, X.; KANKARE, V.; HYYPPÄ, J.; WANG, Y.; KUKKO, A.; HAGGRÉN, H.; YU, X.; KAARTINEN, H.; JAAKKOLA, A.; GUAN, F.; HOLOPAINEN, M.; VASTARANTA, M.. Terrestrial laser scanning in forest inventories. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 115, p. 63-77, 2016.

LITKEY, P.; LIANG, X.; KAARTINEN, H.; HYYPPÄ, J.; KUKKO, A.; HOLOPAINEN, M. Single-scan TLS methods for Forest parameter retrieval. *In: SILVILASER 2008*, Edinburgh, p. 295-304, 2008.

MÁRQUEZ, A. **Un tratado sobre el escaner terrestre TLS**, Mecinca, 2010. Disponível em: <http://www.mecinca.com/papers/EscanerTLS.pdf>. Acesso em 17 jun. 2017.

MENGESHA, T.; HAWKINS, M.; NIEUWENHUIS, M. Validation of terrestrial laser scanning data using conventional forest inventory methods. **European Journal of Forest Research**, v. 134, n. 2, p. 211-222, 2015.

NIEßNER, M.; ZOLLHÖFER, M.; IZADI, S.; STAMMINGER, M. Real-time 3D reconstruction at scale using voxel hashing. **ACM Transactions on Graphics**, v. 32, n. 6, p. 169, 2013.

Olsoy, P. J.; Glenn, N. F.; Clark, P. E.; Derryberry, D. R. Aboveground total and green biomass of dryland shrub derived from terrestrial laser scanning. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 88, p. 166-173, 2014.

OTHMANI, A.; VOON, L. F. L. Y.; STOLZ, C.; PIBOULE, A. Single tree species classification from terrestrial laser scanning data for forest inventory. **Pattern Recognition Letters**, v. 34, n. 16, p. 2144-2150, 2013.

RAUMONEN, P.; KAASALAINEN, M.; ÅKERBLOM, M.; KAASALAINEN, S.; KAARTINEN, H.; VASTARANTA, M.; HOLOPAINEN, M.; DISNEY, M.; LEWIS, P. Fast automatic precision tree models from terrestrial laser scanner data. **Remote Sensing**, 5(2), p. 491-520. 2013.

Riegl Laser Measurement Systems, Version: 2.1.1. 2015. Disponível em: [www.riegl.com](http://www.riegl.com). Acesso em: 05 mar. 2015.

SCHNABEL, R.; WAHL, R.; KLEIN, R. Efficient ransac for point-cloud shape detection. **Computer Graphics Forum**, v. 26, n. 2, p. 214–226, 2007.

SCHUMACHER, F.; HALL, F. Logarithmic expression of timber-tree volume. **Journal of Agricultural Research**, v.47, n.9, p. 719-734, 1933.

SIMÕES, A. C. B. 2017. **Sensorização 3D e Controlo de Manipuladores Industriais através de uma plataforma de baixo custo**. 2017. Dissertação (Mestrado Integrado em Engenharia Eletrotécnica e de Computadores) – Faculdade de Engenharia, Universidade do Porto, Porto, Portugal, 2017.

TASHA-KURDI, F.; LANDES, T.; GRUSSENMEYER, P. Extended ransac algorithm for automatic detection of building roof planes from lidar data. **The Photogrammetric Journal of Finland**, v. 21, n. 1, p. 97-109, 2008.

TITTMANN, P.; SHAFII, S.; HARTSOUGH, B.; HAMANN, B. Tree detection and delineation from LiDAR point clouds using RANSAC. *In: PROCEEDINGS OF SILVILASER*, 2011, Hobart, Australia, 16-19 October 2011.

YAN, J.; JIANG, W.; SHAN, J. Quality analysis on ransac-based roof facets extraction from airborne lidar data. *In: INTERNATIONAL ARCHIVES OF THE PHOTOGRAMMETRY, REMOTE SENSING AND SPATIAL INFORMATION SCIENCES*. v. 1, p.367-372, 2012.

YANO, M. S.; DAL POZ, A. P. Segmentação de Faces de Telhados de Edifícios em Dados de Varredura LASER usando o Método RANSAC. **Revista Brasileira de Cartografia**, v.68. n. 7, p. 1257-1267, 2016.

## CAPÍTULO 5: CONCLUSÃO GERAL

A utilização de equipamentos de Laser Scanner Terrestre (LST), para aplicações em ambiente florestal disponibilizou uma grande quantidade de dados tridimensionais das cenas de varredura. O LST é uma tendência tecnológica que tem encontrado espaço entre as diversas técnicas clássicas já consolidadas para aplicações em florestas. Equipamentos cada vez mais modernos, com maior alcance, melhor qualidade, boa precisão espacial dos dados tornam o uso do LST uma ferramenta viável na execução dos levantamentos. Por outro lado, os fatores limitantes para o uso do LST em ambientes florestais são as intempéries, como chuva e vento.

No primeiro Capítulo, foi proposta uma metodologia para avaliar a identidade das variáveis obtidas pela medição direta do Inventário Florestal, *dap* e *h*, com as variáveis correspondentes obtidas, usando única varredura e múltiplas varreduras do Laser Scanner Laser (LST). As comparações foram feitas em relação ao método tradicional de inventário, em que os diâmetros e as alturas das árvores de cada parcela são medidos, usando suta e o hipsômetro Haglof, respectivamente.

O LST é uma alternativa não destrutiva para mensuração de árvores, que permite mapear a forma das árvores, o afilamento, e o volume real do fuste. Os resultados mostraram que o LST, além de permitir mapear a distribuição espacial das árvores nas parcelas, fornece estimativas precisas para os diâmetros (*dap*). O uso de múltiplas varreduras é recomendável quando o objetivo do levantamento exige maior precisão. Um grande benefício do emprego do LST em área florestal é a possibilidade de ampliar o tamanho das parcelas em campo. Isso porque esta ampliação, no método tradicional, é muitas vezes inviável em termos econômicos. Por isso, a área das parcelas de inventário de eucalipto no Brasil tem sido inferior a 500 m<sup>2</sup>.

A proposta para a reconstrução e medição de variáveis a partir da estrutura espacial de árvores, utilizando LST para estimar, por Redes Neurais Artificiais (RNA's), o volume de madeira em plantios florestais de eucalipto foi explorada no Capítulo 2. Estimou-se, além do *dap* e *h*, os diâmetros (*d*) obtidos nas alturas de 0,0; 0,5; 1,0; 2,0 e 4,0 m em relação ao eixo Z, que correspondem respectivamente

às variáveis  $d_{(h=0,0m)}$ ,  $d_{(h=0,5m)}$ ,  $d_{(h=1,0m)}$ ,  $d_{(h=2,0m)}$  e  $d_{(h=4,0m)}$ . A estimativa de volume utiliza, na maioria das vezes, apenas altura total ( $h$ ) e  $dap$  com aplicação de equações volumétricas. Embora os resultados desses modelos sejam bem confiáveis, as empresas florestais perdem o controle de muitas características, como o afilamento do fuste. A técnica de RNA apresentou um excelente desempenho nas estimativas volumétricas. A utilização das variáveis de diâmetro em diferentes alturas do fuste resultou no aumento da exatidão de suas estimativas.

Com o método aplicado no Capítulo 3, foi possível estimar o volume dos fustes diretamente sobre a nuvem de pontos obtida pelo LST, que permite a determinação do volume da árvore em pé. Para a individualização dos troncos, foi aplicada a segmentação pelo método RANSAC, pois os troncos possuem a forma parametrizável de um cilindro. Para a aquisição dos volumes, foram interpoladas as nuvens de pontos para cada árvore presente em cada parcela, até a altura de 2, 3 e 4 metros. Analisando os resultados, uma solução eficiente, para otimizar o volume total é a utilização das variáveis  $dap$ ,  $h$  e  $Volume_{2metros}$  utilizando o modelo de Schumacher e Hall.

Com base nos resultados obtidos, pode-se concluir que a tecnologia LST pode ser aplicada com sucesso na quantificação volumétrica de povoamento comercial de eucalipto. Espera-se, através deste trabalho, a incorporação da tecnologia de varredura por LST e o uso de toda sua potencialidade na produção de modelos tridimensionais, com fins de mensuração e de inventário florestal, além da alimentação das bases de dados para Sistemas de Informação Geográfica.

Sugere-se para trabalhos futuros: comparar os resultados obtidos nesta pesquisa com outros modelos de equipamentos LST; avaliar economicamente o uso da tecnologia no setor florestal e sua operacionalidade; testar outras resoluções de varredura (densidade de pontos da nuvem) inferiores às usadas nesta pesquisa, para verificar se é possível determinar os diferentes diâmetros com boa precisão. Outras aplicações para a Tecnologia LST no setor florestal seria muito importante, tais como: controle de pragas e doenças; planejamento de estradas florestais; entre outras.

## APÊNDICE

### A) Resultados para as variáveis *dap* e *h* (Parcela 1)

Valores resultantes das aplicações dos métodos tradicionais e obtidos pelo escaneamento uma posição, duas posições e cinco posições, para as variáveis *dap* e altura total (*h*)

Continua.

Fila	Cova	Método Tradicional		Escaneamento (LST)			
		<i>dap</i> (m)	<i>h</i> (m)	Uma Posição	Duas Posições	Cinco Posições	
				<i>dap</i> (m)	<i>dap</i> (m)	<i>dap</i> (m)	<i>h</i> (m)
1	1	0,192	28,300	0,110	0,192	0,193	27,673
	2	0,132	21,780	0,129	0,132	0,132	22,967
	3	0,155	24,300	0,150	0,154	0,155	24,569
	4	0,117	21,300	0,118	0,118	0,118	21,541
	5	0,105	21,111	0,092	0,105	0,105	21,645
	6	0,146	22,983	0,150	0,144	0,145	22,161
	7	0,175	27,346	0,179	0,176	0,176	28,581
2	8	0,195	28,089	0,200	0,197	0,197	28,331
	9	0,124	21,448	0,129	0,121	0,122	21,639
	10	0,197	28,111	0,190	0,195	0,196	28,382
	11	0,171	26,951	0,179	0,170	0,169	27,173
	12	0,169	26,706	0,173	0,169	0,169	26,402
	13	0,177	27,499	0,171	0,177	0,175	27,781
	14	0,129	21,634	-	0,131	0,132	21,867

“-“ árvores ausentes.

Continua.

3	15	0,151	23,691	0,138	0,148	0,148	23,408
	16	0,132	21,780	0,125	0,134	0,133	22,578
	17	0,176	27,426	-	0,173	0,175	28,041
	18	0,110	21,164	0,109	0,109	0,110	21,222
	19	0,199	28,128	0,206	0,202	0,201	27,668
	20	0,139	22,254	0,141	0,139	0,139	21,982
	21	0,115	21,237	0,110	0,113	0,113	23,704
4	22	0,179	27,627	0,174	0,179	0,178	27,715
	23	-	-	-	-	-	-
	24	0,161	25,439	0,151	0,159	0,160	25,599
	25	0,120	21,338	0,117	0,118	0,119	21,499
	26	0,199	28,128	0,196	0,196	0,198	28,296
	27	0,194	28,077	0,191	0,192	0,194	28,129
	28	0,125	21,481	0,130	0,129	0,127	21,385
5	29	0,183	27,818	0,180	0,180	0,181	23,947
	30	0,167	26,428	0,171	0,170	0,168	28,256
	31	0,140	22,340	0,130	0,136	0,137	21,778
	32	0,156	24,537	0,152	0,153	0,153	24,501
	33	0,134	21,894	0,138	0,132	0,132	22,431
	34	0,213	28,193	0,207	0,209	0,211	26,522
	35	0,152	23,851	0,091	0,156	0,155	27,692
6	36	0,182	27,777	0,180	0,180	0,181	27,880
	37	0,123	21,418	-	0,120	0,122	21,468
	38	0,134	21,894	0,128	0,132	0,132	21,972
	39	0,102	21,087	0,110	0,100	0,100	21,282
	40	0,162	25,616	0,154	0,160	0,162	25,745

“-“ árvores ausentes.

							Continuação.
6	41	0,171	26,951	0,176	0,169	0,169	27,018
	42	0,104	21,103	0,111	0,107	0,105	20,985

“-“ árvores ausentes.

Fonte: A autora.

## B) Resultados para as variáveis *dap* e *h* (Parcela 2)

Valores resultantes das aplicações dos métodos tradicionais e obtidos pelo escaneamento uma posição, duas posições e cinco posições, para as variáveis *dap* e altura total (*h*)

Continua.

Fila	Cova	Método Tradicional		Escaneamento (LST)			
		<i>dap</i> (m)	<i>h</i> (m)	Uma Posição	Duas Posições	Cinco Posições	
				<i>dap</i> (m)	<i>dap</i> (m)	<i>dap</i> (m)	<i>h</i> (m)
1	1	0,167	26,800	0,136	0,166	0,167	26,855
	2	0,118	19,100	0,111	0,120	0,120	19,871
	3	0,146	20,800	0,149	0,145	0,145	21,207
	4	0,175	27,554	0,176	0,172	0,172	26,769
	5	0,142	19,583	0,145	0,144	0,144	19,814
	6	0,111	19,110	-	0,113	0,113	19,840
2	7	0,104	19,109	0,101	0,105	0,105	19,154
	8	0,165	26,544	0,169	0,167	0,166	26,988
	9	0,094	19,109	0,104	0,093	0,093	18,259
	10	0,161	25,922	0,165	0,163	0,163	26,101
	11	0,132	19,116	0,123	0,134	0,132	20,133
	12	0,202	28,165	0,192	0,201	0,202	29,287
3	13	0,147	21,470	0,142	0,148	0,148	21,593
	14	0,149	22,789	0,145	0,152	0,151	22,298
	15	0,136	19,126	0,132	0,137	0,137	21,404
	16	0,156	24,993	0,152	0,153	0,154	24,482
	17	0,135	19,121	0,137	0,137	0,136	20,100
	18	0,151	23,690	0,154	0,148	0,148	23,537

"-" árvores ausentes.

							Continuação.
4	19	0,129	19,114	0,125	0,125	0,126	20,297
	20	0,108	19,110	0,115	0,112	0,111	17,351
	21	0,155	24,781	0,150	0,152	0,154	25,160
	22	0,128	19,113	0,135	0,133	0,131	19,607
	23	0,156	24,993	0,161	0,159	0,158	23,819
	24	0,076	19,109	0,080	0,077	0,077	20,149
	24	0,072	19,108	0,073	0,071	0,071	20,148
5	25	0,150	23,287	0,152	0,151	0,150	23,643
	26	0,111	19,110	0,077	0,114	0,114	18,267
	27	0,153	24,305	0,148	0,149	0,157	24,054
	28	0,121	19,111	0,116	0,124	0,122	18,792
	29	0,162	26,089	0,150	0,164	0,164	25,961
	30	0,113	19,110	0,110	0,110	0,110	19,650
6	31	0,139	19,169	0,090	0,141	0,139	20,132
	32	0,140	19,219	0,136	0,143	0,143	20,135
	33	0,161	25,922	0,168	0,164	0,163	25,243
	34	0,095	19,109	0,093	0,095	0,092	19,441
	35	0,148	22,179	0,140	0,145	0,145	22,634
	36	0,142	19,583	0,104	0,141	0,141	18,090

Fonte: A autora.

### C) Resultados para as variáveis *dap* e *h* (Parcela 3)

Valores resultantes das aplicações dos métodos tradicionais e obtidos pelo escaneamento uma posição, duas posições e cinco posições, para as variáveis *dap* e altura total (*h*)

Fila	Cova	Método Tradicional		Escaneamento (LST)			
		<i>dap</i> (m)	<i>h</i> (m)	Uma Posição <i>dap</i> (m)	Duas Posições <i>dap</i> (m)	Cinco Posições <i>dap</i> (m) <i>h</i> (m)	
1	1	0,146	26,1	0,088	0,146	0,146	25,844
	2	0,160	25,3	0,167	0,164	0,162	25,637
	3	0,172	26,8	0,153	0,170	0,170	26,807
	4	0,147	26,1	0,150	0,154	0,152	25,851
	5	0,121	24,6	0,125	0,122	0,121	24,795
	6	0,153	26,7	0,147	0,151	0,151	25,966
2	7	0,147	26,1	0,143	0,146	0,147	26,236
	8	0,152	26,6	0,156	0,150	0,150	26,293
	9	0,147	26,1	0,143	0,149	0,147	25,302
	10	0,147	26,1	0,144	0,149	0,149	25,253
	11	0,150	26,4	0,148	0,151	0,151	25,861
	12	0,162	25,3	0,159	0,159	0,159	25,290
3	13	0,138	25,4	0,140	0,139	0,139	24,831
	14	0,159	27,2	0,162	0,158	0,159	27,813
	15	0,164	25,6	0,167	0,164	0,164	25,288
	16	0,154	26,8	0,170	0,158	0,158	26,340
	17	0,152	26,6	0,156	0,154	0,154	26,666
	18	0,159	27,2	0,162	0,158	0,158	26,911
	18	0,069	24,1	0,070	0,072	0,072	23,859

Continuação.

Continuação.

	19	0,147	26,1	-	0,149	0,149	24,468
	20	0,176	27,3	-	0,175	0,175	26,052
	21	0,146	26,0	0,150	0,150	0,148	25,392
4	22	0,159	27,2	0,152	0,160	0,160	26,979
	23	0,144	25,9	0,147	0,146	0,146	25,560
	24	0,149	26,3	0,151	0,148	0,148	25,941
	24	0,146	26,1	0,088	0,146	0,146	25,844

“-“ árvores ausentes.