

UNIVERSIDADE FEDERAL DO PARANÁ

GABRIELLE HAMBRECHT LOUREIRO

**REDES NEURAIS ARTIFICIAIS E MODELOS DE REGRESSÃO PARA  
ESTIMAÇÃO DE VARIÁVEIS DENDROMÉTRICAS EM *Pinus taeda* L: ANÁLISE  
COMPARATIVA**

CURITIBA

2016

GABRIELLE HAMBRECHT LOUREIRO

**REDES NEURAS ARTIFICIAIS E MODELOS DE REGRESSÃO PARA  
ESTIMAÇÃO DE VARIÁVEIS DENDROMÉTRICAS EM *Pinus taeda* L: ANÁLISE  
COMPARATIVA**

Tese apresentada ao Programa de Pós-graduação em Engenharia Florestal, Área de Concentração em Manejo Florestal, Departamento de Ciências Florestais, Setor de Ciências Agrárias, Universidade Federal do Paraná, como requisito para obtenção do título de Doutora em Engenharia Florestal.

Orientador: Prof. Dr. Carlos Roberto Sanquetta

Coorientadores: Prof. Dr. Renato Vinicius Oliveira  
Castro

Prof. Dr. Julio Eduardo Arce

CURITIBA

2016



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

Loureiro, Gabrielle Hambrecht

Redes neurais artificiais e modelos de regressão para estimação de variáveis dendrométricas em *Pinus taeda* L.: análise comparativa / Gabrielle Hambrecht Loureiro. – Curitiba, 2016.

153 f. : il.

Orientador: Prof. Dr. Carlos Roberto Sanquetta

Coorientadores: Prof. Dr. Renato Vinicius Oliveira Castro

Prof. Dr. Julio Eduardo Arce

Tese (Doutorado) - Universidade Federal do Paraná, Setor de Ciências Agrárias, Programa de Pós-Graduação em Engenharia Florestal. Defesa: Curitiba, 19/12/2016.

Área de concentração: Manejo Florestal.

1. Dendrometria. 2. Povoamento florestal. 3. Redes neurais (Computação). 4. *Pinus taeda*. 5. Troncos (Botânica) – Medição. 6. Florestas – Métodos estatísticos. 7. Teses. I. Sanquetta, Carlos Roberto. II. Castro, Renato Vinicius Oliveira. III. Arce, Julio Eduardo. IV. Universidade Federal do Paraná, Setor de Ciências Agrárias. V. Título.

CDD – 634.9

CDU – 634.0.5

## TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em ENGENHARIA FLORESTAL da Universidade Federal do Paraná foram convocados para realizar a arguição da tese de Doutorado de **GABRIELLE HAMBRECHT LOUREIRO** intitulada: **REDES NEURAIS ARTIFICIAIS E MODELOS DE REGRESSÃO PARA ESTIMAÇÃO DE VARIÁVEIS DENDROMÉTRICAS EM *Pinus taeda* L: ANÁLISE COMPARATIVA**, após terem inquirido a aluna e realizado e realizado a avaliação do trabalho, são de parecer pela sua APROVAÇÃO.

Curitiba, 19 de Dezembro de 2016.



CARLOS ROBERTO SANQUETTA

Presidente da Banca Examinadora (UFPR)



ELISABETE VUADEN

Avaliador Externo (UFPR)



JAIME WOJCIECHOWSKI

Avaliador Externo (UFPR)



ANA PAULA DALLA CORTE

Avaliador Externo (UFPR)



EMERSON ROBERTO SCHOENINGER

Avaliador Externo ()



**Dedico esse trabalho ao meu Pai, Elson Farias Loureiro e minha Mãe, Sandra Hambrecht Loureiro pelo apoio nas minhas escolhas e decisões.**

## **AGRADECIMENTOS**

Aos meus pais, Elson Farias Loureiro e Sandra Hambrecht Loureiro, meu irmão Guilherme Hambrecht Loureiro e minha sobrinha Mirela Souza Loureiro, os maiores incentivadores dos meus estudos e sempre presentes de coração nas minhas conquistas e vitórias;

Ao meu orientador Carlos Roberto Sanquetta, por ter acreditado no meu trabalho, pela confiança em mim depositada, e por ter proporcionado apoio, conhecimento e ferramentas.

Aos meus coorientadores Julio Eduardo Arce, pela disponibilidade, empenho, e dedicação ao longo de todo o estudo, e a Renato Vinicius Oliveira Castro por ter disponibilizado seu tempo e oferecido valiosa contribuição científica, sendo fundamentais para o andamento da pesquisa.

Ao Programa de Pós - Graduação em Engenharia Florestal da Universidade Federal do Paraná pela oportunidade. Aos funcionários pela disponibilidade e prestação de serviços.

A empresa Klabin S.A, por disponibilizar os dados para o estudo.

A Pöyry, empresa que me aceitou e apoiou para continuidade dos meus estudos, principalmente ao Altamir Ribas, por me liberar e entender minhas ausências em alguns projetos nos primeiros anos do doutorado, Gisele Bolzani por me incentivar desde o início e Lucila de Almeida Fernandes pelos inúmeros momentos de discussão técnica.

A Suzano Papel e Celulose, atual empresa que trabalho, pelo apoio e incentivo no último ano do doutorado, principalmente aos meus gestores Maria Carolina Zonete e Gilberto Ferreira Moraes, por não me deixarem desistir desse sonho.

A Rafaella De Angeli Curto, amiga e parceira neste trabalho, que mesmo distante estava sempre disposta a me ajudar. Ao amigo Aurélio Lourenço Rodrigues, pelo apoio técnico e revisões da tese, carinho e amizade, fundamental na reta final da tese. Ao amigo Dhyone Schinemann por ter me recebido com muito carinho em sua casa em Curitiba.

Aos colegas e amigos Allan Pellissari, Aline Canetti, Hassan David, Mariana Mausbach, Mariana Ferraz, Paulo André Trazzi, Pompeu Paes Guimarães, Rômulo

Môra, Sintia Valerio Kohler, e Tomaz Longhi por fazer parte da minha vida acadêmica e compartilhar conhecimentos.

Que os vossos esforços desafiem as impossibilidades, lembrai-vos de que as grandes proezas da história foram conquistadas do que parecia impossível.  
*Charles Chaplin*

## RESUMO

Estudos com Redes Neurais Artificiais (RNA) para o gênero *Pinus* são incipientes no Brasil. O objetivo deste trabalho foi testar as RNA para estimação da altura, volume e afilamento para povoamentos de *Pinus taeda* L., bem como avaliar sua aplicabilidade e compará-la com os métodos tradicionais de regressão. Para a estimação de altura por regressão e RNA foram utilizados dados de 304 parcelas permanentes, totalizando 2.454 remedições de parcela em plantios de *Pinus taeda* L. entre 3 e 21 anos, pertencentes à empresa Klabin S.A. No ajuste dos modelos hipsométricos os dados foram estratificados em ano de plantio, totalizando 11 estratos. Para cada estrato foram ajustados 4 modelos hipsométricos, e esses avaliados de acordo com o coeficiente de correlação ajustado ( $R^2$  ajust), erro padrão da estimativa (Syx%), gráficos de dispersão de resíduos, além de estatísticas complementares como viés (V), média das diferenças absolutas (MD) e desvio padrão das diferenças (DPD). Os melhores modelos aplicados nos dados de validação foram comparados às RNA, que por sua vez foram treinadas no *software* Statística 7.0, em que as 20 melhores redes foram aplicadas aos dados sem estratificação. A RNA com melhor desempenho para estimar a altura total foi comparada com o modelo de regressão por estrato. Para avaliar a precisão dos modelos hipsométricos e RNA para a redução da medição das alturas, os dados de ajuste foram reduzidos em 30% e 60%, e ajustados e treinados respectivamente. Para a estimação de volume total com casca e diâmetros e volumes ao longo do fuste e ainda volume total com casca por meio de funções de afilamento, foram utilizadas 212 cubagens de árvores com diâmetro a 1,30 (dap) entre 5 e 45 cm e aplicados o método da RNA e regressão. Na metodologia de ajuste por regressão os dados foram divididos em 4 estratos e para cada estrato ajustado 4 modelos de volume e 4 modelos de afilamento. O treinamento das RNA e seleção dos modelos de regressão foram realizados com a mesma metodologia da relação hipsométrica. As melhores RNA e modelos de regressão aplicados aos dados de validação foram comparados para verificar as melhores estimativas. Na estimativa de altura, modelos de regressão apresentaram melhor desempenho que as RNA para a base de dados total e na redução de até 60%. Na estimativa de volume total com casca os modelos estratificados por regressão apresentaram resultados mais satisfatórios, enquanto na estimativa do diâmetro e volume ao longo do fuste as RNA foram mais precisas. Conclui-se que, para as estimativas de altura e volume total de *Pinus taeda*, o uso de modelos de regressão é mais adequado especialmente em função da maior facilidade de aplicação. Já para as estimativas de diâmetros e volumes ao longo do fuste, o uso das RNA é mais adequado em razão de sua maior precisão e maior complexidade de ajuste dos modelos de afilamento.

**Palavras-chave:** desempenho, interações não lineares, modelos de regressão.

## ABSTRACT

Studies with Artificial Neural Networks (ANN) for the genus *Pinus* are incipient in Brazil. The main purpose of this work was to test ANN for height, volume and taper estimation for stands of *Pinus taeda* L., as well as to evaluate its applicability and to compare it with traditional regression methods. For the height estimation by regression and ANN, data from 304 permanent plots were used, totaling 2,454 remeasurements in *Pinus taeda* L plantations between 3 and 21 years, belonging to the company Klabin S.A. For the hypsometric models the data were stratified in year of planting, totaling 11 strata. For each stratum, 4 hypsometric models were fitted, and these were evaluated according to the adjusted correlation coefficient ( $R^2$  adjust), standard error of estimative (Syx%), residual scatter plots, as well as complementary statistics, such as bias (V), absolute differences (MD) and standard deviation of differences (DPD). The best models applied in the validation data were compared to ANN trained in the Statistica 7.0 software, in which the 20 best networks were applied to the data without stratification. The best ANN performing to estimate total height was compared with the stratum regression model. To evaluate the accuracy of the hypsometric and ANN models for the height measurements reduction, the data were reduced by 30% and 60%, and adjusted and trained, respectively. For the estimation of the total volume with bark and diameters and volumes along the stem and also total volume with bark by means of tapering functions, 212 trees were scaled with diameter at 1.30 (dbh) between 5 and 45 cm and ANN and regression method was applied. In the regression adjustment method the data were divided into 4 strata and for each stratum adjusted 4 volume models and 4 taper models. The ANN training and regression models selection were performed using the same methodology as the hypsometric relation. The best ANN and regression models applied to the validation data were compared to verify the best estimates. In height estimation, regression models presented better performance than ANN for the total database and data reduction of up to 60%. For the estimation of total volume with bark, the models stratified by regression presented more satisfactory results, whereas for the estimation of diameter and volume along the stem the ANN was more accurate. It was concluded that, for the estimates of height and total volume of *Pinus taeda*, the use of regression models is more appropriate especially due to the greater ease of application. For the estimation of diameters and volumes along the stem, the use of ANN is more adequate because of the better precision and greater complexity of adjustment of the models of tapering.

**Keywords:** Performance, nonlinear interactions, regression models.



## LISTA DE FIGURAS

FIGURA 1: FLUXOGRAMA DA APRESENTAÇÃO DO ESTUDO .....	20
FIGURA 2- CONSUMO EM METROS CÚBICOS DE MADEIRA IN NATURA DO GÊNERO PINUS SP. NO BRASIL EM 2013.....	22
FIGURA 3- ESTRUTURA DO NEURÔNIO BIOLÓGICO .....	30
FIGURA 4- REPRESENTAÇÃO DA ARQUITETURA DE UMA RNA.....	31
FIGURA 5 - ESTRUTURA DO NEURÔNIO ARTIFICIAL.....	31
FIGURA 6- PRINCIPAIS FUNÇÕES DE ATIVAÇÃO NAS RNA, ONDE A) FUNÇÃO LIMIAR, B) FUNÇÃO LINEAR POR PARTES, C) FUNÇÃO SIGMOIDE .....	33
FIGURA 7- REPRESENTAÇÃO DE PADRÕES NÃO LINEARMENTE SEPARÁVEIS .....	35
FIGURA 8- DISTRIBUIÇÃO DE IDADES DOS DADOS EM ESTUDO .....	41
FIGURA 9-RELAÇÃO h/d CONSIDERANDO DIFERENTES ESTRATOS PARA OS DADOS DE ESTUDO.....	47
FIGURA 10 - GRÁFICOS DE DISPERSÃO DE RESÍDUOS DO AJUSTE DE MODELOS DE REGRESSÃO PARA OS ESTRATOS 7, 8 E 9 .....	51
FIGURA 11- GRÁFICOS DE DISTRIBUIÇÃO DE RESÍDUOS PARA PARTE DAS REDES TREINADAS E ANALISADAS.....	54
FIGURA 12. GRÁFICOS DE DISPERSÃO DE RESÍDUOS PARA OS DADOS DE AJUSTE 100% E REDUÇÃO EM 30% E 60% DAS ALTURAS MEDIDAS .....	60
FIGURA 13. GRÁFICOS DE DISPERSÃO DE RESÍDUOS E GRÁFICOS DE FREQUÊNCIA DE RESÍDUOS PARA OS DADOS DE VALIDAÇÃO UTILIZANDO OS MODELOS COM MELHORES ESTATÍSTICAS .....	63
FIGURA 14 - GRÁFICOS DE DISPERSÃO DE RESÍDUOS PARA AS RNA SELECIONADAS PARA ESTIMAÇÃO DA ALTURA PARA OS DADOS DE AJUSTE .....	66
FIGURA 15- DISTRIBUIÇÃO DE IDADE E DE DAP DOS DADOS EM ESTUDO ....	73
FIGURA 16 - DISTRIBUIÇÃO DE IDADE E DE DAP DOS DADOS EM ESTUDO ...	78
FIGURA 17-RELAÇÃO H/D E VOLUME INDIVIDUAL COM CASCA PARA OS DADOS DE AJUSTE E VALIDAÇÃO .....	79
FIGURA 18 - DISTRIBUIÇÃO DE RESÍDUOS PARA ESTIMAÇÃO DE VOLUME POR MEIO DE REGRESSÃO.....	82

FIGURA 19- GRÁFICOS DE DISTRIBUIÇÃO DE RESÍDUOS PARA AS REDES SELECIONADAS .....	85
FIGURA 20- GRÁFICOS DE DISPERSÃO DE RESÍDUOS E GRÁFICOS DE FREQUÊNCIA PERCENTUAL DOS ERROS PERCENTUAIS PARA AS ESTIMATIVAS DE ALTURA COM REDES NEURAIS .....	87
FIGURA 21 - COMPARAÇÃO ENTRE O A MÉDIA DO VOLUME INDIVIDUAL COM CASCA OBSERVADO E AS ESTIMATIVAS POR MEIO DE REGRESSÃO E RNA E DISPERSÃO DE RESÍDUOS POR CLASSES (%) .....	90
FIGURA 22 - GRÁFICOS DE DISPERSÃO DE RESÍDUOS PARA OS DADOS DE VALIDAÇÃO.....	102
FIGURA 23 - GRÁFICOS DE DISPERSÃO DE RESÍDUOS PARA AS RNA SELECIONADAS .....	104
FIGURA 24- GRÁFICOS DE DISPERSÃO DE RESÍDUOS E GRÁFICOS DE DISPERSÃO DE RESÍDUOS POR CLASSE PARA AS RNA SELECIONADAS ....	105
FIGURA 25 - DISTRIBUIÇÃO DE FREQUÊNCIA DE RESÍDUOS PARA ESTIMATIVA DO DIÂMETRO AO LONGO DO FUSTE PARA OS DADOS DE VALIDAÇÃO. Continua... ..	107
FIGURA 26: GRÁFICOS DE DISPERSÃO DE RESÍDUOS DOS MELHORES MODELOS E MELHOR RNA PARA ESTIMAR O DIÂMETRO AO LONGO DO FUSTE NOS DADOS DE VALIDAÇÃO.....	109
FIGURA 27- GRÁFICOS DE DISTRIBUIÇÃO DE RESÍDUOS PARA ESTIMAR VOLUME TOTAL COM CASCA POR MEIO DE RNA E REGRESSÃO.....	111

## LISTA DE TABELAS

TABELA 1- ESTRATIFICAÇÃO PARA A RELAÇÃO HIPSOMÉTRICA .....	42
TABELA 2- MODELOS HIPSOMÉTRICOS.....	42
TABELA 3- ESTATÍSTICAS UTILIZADAS PARA A SELEÇÃO DE MODELOS DE RELAÇÃO HIPSOMÉTRICA.....	43
TABELA 4- ESTATÍSTICAS COMPLEMENTARES PARA ANÁLISE DOS MODELOS HIPSOMÉTRICOS .....	44
TABELA 5- ANÁLISES ESTATÍSTICAS DOS MODELOS HIPSOMÉTRICOS. Continua.....	49
TABELA 6- ESTATÍSTICAS E ESTATÍSTICAS COMPLEMENTARES PARA ESTIMAÇÃO DE ALTURA DOS DADOS DE VALIDAÇÃO- APLICAÇÃO DOS MODELOS 3 E 4 .....	52
TABELA 7- ANÁLISES ESTATÍSTICAS DAS REDES NEURAS SELECIONADAS	53
TABELA 8 - ESTATÍSTICAS DAS REDES NEURAS SELECIONADAS APLICADAS AOS DADOS DE VALIDAÇÃO TOTAL .....	55
TABELA 9 - ESTATÍSTICAS PARA A COMPARAÇÃO ENTRE OS MODELOS DE REGRESSÃO E REDES NEURAS. Continua.....	56
TABELA 10 - MÉDIAS POR ESTRATOS DAS ALTURAS OBSERVADAS E ESTIMADAS PELA REGRESSÃO E RNA. VALORES DE F ACOMPANHADOS DE $P \leq 0,05$ INDICAM SIGNIFICÂNCIA DA ANOVA. ....	57
TABELA 11- COEFICIENTE DE CORRELAÇÃO ENTRE OS TRÊS TRATAMENTOS .....	58
TABELA 12- ESTATÍSTICAS E ESTATÍSTICAS COMPLEMENTARES PARA ESTIMAR ALTURA PARA 100% DOS DADOS DE AJUSTE E POR MEIO DE REDUÇÃO EM 30%, 60% DA MEDIÇÃO DE ALTURAS.....	59
TABELA 13 - ESTATÍSTICAS PARA APLICAÇÃO DOS MODELOS AJUSTADOS COM 100% DOS DADOS E REDUÇÃO EM 30% E 60% NOS DADOS DE VALIDAÇÃO TOTAL .....	61
TABELA 14 - ESTATÍSTICAS DE AJUSTE E ESTATÍSTICAS COMPLEMENTARES PARA ESTIMAR A ALTURA PARA OS DADOS DE VALIDAÇÃO QUANDO APLICADA A RNA TREINADA COM 100% DOS DADOS.....	64

TABELA 15 - ESTATÍSTICAS E ESTATÍSTICAS COMPLEMENTARES PARA ESTIMAR A ALTURA COM OS DADOS DE AJUSTE REDUZIDOS EM 30% E 60% RESPECTIVAMENTE. Continua.....	64
TABELA 17- COMPARAÇÃO ENTRE AS ESTIMATIVAS DE ALTURA POR REGRESSÃO E RNA REDUZINDO A MEDIÇÃO DA VARIÁVEL H .....	68
TABELA 18 - ESTRATOS UTILIZADOS PARA AJUSTE DOS MODELOS VOLUMÉTRICOS- INSERIR A QUANTIDADE DE DADOS.....	73
TABELA 19 - MODELOS VOLUMÉTRICOS.....	74
TABELA 20- ESTATÍSTICAS UTILIZADAS PARA A SELEÇÃO DE MODELOS DE RELAÇÃO HIPSOMÉTRICA.....	75
TABELA 21- ESTATÍSTICAS COMPLEMENTARES PARA ANÁLISE DOS MODELOS HIPSOMÉTRICOS .....	75
TABELA 22- DISTRIBUIÇÃO DAS VARIÁVEIS DENDROMÉTRICAS E VOLUME POR ESTRATO.....	79
TABELA 23 - ANÁLISES ESTATÍSTICAS DOS MODELOS EM ESTUDO.....	80
TABELA 24 - ESTATÍSTICAS E ESTATÍSTICAS COMPLEMENTARES PARA ESTIMAR ALTURA DOS DADOS DE VALIDAÇÃO UTILIZANDO OS DOIS MELHORES MODELOS DE REGRESSÃO.....	83
TABELA 25 - ANÁLISES ESTATÍSTICAS DAS REDES NEURAS SELECIONADAS .....	84
TABELA 26- ESTATÍSTICAS DAS REDES NEURAS SELECIONADAS APLICADAS AOS DADOS DE VALIDAÇÃO TOTAL.....	85
TABELA 27- ESTATÍSTICAS PARA A COMPARAÇÃO ENTRE OS MODELOS DE REGRESSÃO E REDES NEURAS .....	88
TABELA 28 - MÉDIAS POR ESTRATOS DOS VOLUMES OBSERVADOS E ESTIMADOS PELA REGRESSÃO E RNA. VALORES DE F ACOMPANHADOS DE $p \leq 0,05$ INDICAM SIGNIFICÂNCIA DA ANOVA. ....	91
TABELA 29 - COEFICIENTE DE CORRELAÇÃO ENTRE OS TRÊS TRATAMENTOS .....	91
TABELA 30 - ESTRATOS UTILIZADOS PARA AJUSTE DOS MODELOS VOLUMÉTRICOS- INSERIR A QUANTIDADE DE DADOS.....	95
TABELA 31 - MODELOS DE AFILAMENTO.....	96
TABELA 32 - ESTATÍSTICAS UTILIZADAS PARA A SELEÇÃO DE MODELOS DE AFILAMENTO .....	96

TABELA 33 - ESTATÍSTICAS COMPLEMENTARES PARA ANÁLISE DOS MODELOS DE AFILAMENTO.....	97
TABELA 34 - ESTATÍSTICAS PARA ESTIMATIVA DO DIÂMETRO AO LONGO DO FUSTE POR MEIO DE AJUSTE POR REGRESSÃO.....	100
TABELA 35- ESTATÍSTICAS PARA OS DADOS DE VALIDAÇÃO PARA ESTIMAR DI UTILIZANDO OS DOIS MELHORES MODELOS NO AJUSTE.....	100
TABELA 36 - ESTATÍSTICAS COMPLEMENTARES PARA ESTIMATIVA DE DIÂMETRO AO LONGO DO FUSTE POR MEIO DE RNA.....	103
TABELA 37 - ESTATÍSTICAS DAS REDES NEURAI SELECIONADAS APLICADAS AOS DADOS DE VALIDAÇÃO TOTAL .....	104
TABELA 38- ESTATÍSTICAS PARA AS ESTIMATIVAS DO DIÂMETRO AO LONGO DO FUSTE POR MEIO DE REGRESSÃO E REDES NEURAI ARTIFICIAIS.....	106
TABELA 39- DISTRIBUIÇÃO DO BANCO DE DADOS DE AJUSTE POR CLASSE DE DIÂMETRO .....	107
TABELA 40 - COEFICIENTE DE CORRELAÇÃO ENTRE OS TRÊS TRATAMENTOS .....	110
TABELA 41 - ESTATÍSTICAS PARA ESTIMATIVA DE VOLUME TOTAL COM CASCA POR MEIO DE REDES NEURAI ARTIFICIAIS E MODELOS DE AFILAMENTO POR MEIO DE REGRESSÃO .....	110
TABELA 42 - MÉDIAS POR ESTRATOS DOS VOLUMES OBSERVADOS E ESTIMADOS PELA REGRESSÃO E RNA. VALORES DE F ACOMPANHADOS DE $P \leq 0,05$ INDICAM SIGNIFICÂNCIA DA ANOVA. ....	112
TABELA 43 - COEFICIENTE DE CORRELAÇÃO ENTRE OS TRÊS TRATAMENTOS .....	112

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	<b>17</b>
<b>2 OBJETIVOS ESPECÍFICOS</b> .....	<b>19</b>
<b>3 ORGANIZAÇÃO DO ESTUDO</b> .....	<b>20</b>
<b>3 REVISÃO BIBLIOGRÁFICA</b> .....	<b>21</b>
3.1 A ESPÉCIE EM ESTUDO .....	21
3.2 RELAÇÃO HIPSOMÉTRICA .....	22
3.3 EQUAÇÕES DE VOLUME .....	24
3.4 AFILAMENTO – <i>TAPER</i> .....	26
3.5 REDES NEURAS ARTIFICIAIS .....	28
<b>CAPÍTULO 1</b> .....	<b>39</b>
<b>1 INTRODUÇÃO</b> .....	<b>39</b>
<b>2 MATERIAL E MÉTODOS</b> .....	<b>41</b>
2.1 DESCRIÇÃO DOS PLANTIOS.....	41
2.2 AJUSTE POR REGRESSÃO: RELAÇÃO HIPSOMÉTRICA .....	41
2.3 SELEÇÃO E ESTATÍSTICAS DE AJUSTE DOS MODELOS DE REGRESSÃO	42
2.4 TREINAMENTO DAS REDES NEURAS ARTIFICIAIS .....	44
2.5 REDUÇÃO DA MEDIÇÃO DE ALTURA EM 30% E 60%.....	45
2.6 AVALIAÇÃO DA PERFORMANCE DOS MÉTODOS .....	46
<b>3. RESULTADOS E DISCUSSÃO</b> .....	<b>47</b>
3.1 AJUSTE DOS MODELOS DE REGRESSÃO: ESTIMAÇÃO DA ALTURA .....	48
3.2 APLICAÇÃO DOS MODELOS DE REGRESSÃO NOS DADOS DE VALIDAÇÃO- ESTIMAÇÃO DA ALTURA .....	52
3.3 TREINAMENTO DAS REDES NEURAS ARTIFICIAIS: DADOS DE AJUSTE ...	53
3.4 VALIDAÇÃO DAS REDES NEURAS ARTIFICIAIS PARA ESTIMAÇÃO DE ALTURA .....	54
3.5 COMPARAÇÕES ENTRE AS ESTIMATIVAS POR REGRESSÃO E RNA .....	55
3.6 COMPARAÇÃO DA PERFORMANCE DOS MÉTODOS .....	57
3.7 REDUÇÃO DA MEDIÇÃO DE ALTURAS EM 30% E 60% .....	58
3.7.1 Redução da medição de alturas por meio de Regressão: Dados de ajuste e validação .....	58

3.7.2 Redução da medição de alturas por meio de RNA: Dados de ajuste e validação .....	64
3.7.3 Comparação entre o método de Regressão e RNA para a redução da medição de alturas em 30% e 60% .....	67
<b>4. CONCLUSÕES .....</b>	<b>70</b>
<b>CAPÍTULO 2 .....</b>	<b>71</b>
<b>1 INTRODUÇÃO .....</b>	<b>71</b>
<b>2. MATERIAL E MÉTODOS .....</b>	<b>73</b>
2.1 DESCRIÇÃO DOS PLANTIOS.....	73
2.2. AJUSTE POR REGRESSÃO: VOLUME TOTAL.....	73
2.3 SELEÇÃO E ESTATÍSTICAS DOS MODELOS DE REGRESSÃO .....	74
2.4 TREINAMENTO DAS REDES NEURAIS.....	76
2.5 AVALIAÇÃO DA PERFORMANCE DOS MÉTODOS .....	77
<b>3. RESULTADOS E DISCUSSÃO .....</b>	<b>78</b>
3.1 AJUSTE DOS MODELOS DE REGRESSÃO: ESTIMAÇÃO DO VOLUME .....	78
3.2 APLICAÇÃO DOS MODELOS DE REGRESSÃO NOS DADOS DE VALIDAÇÃO-ESTIMAÇÃO DO VOLUME.....	83
3.3 TREINAMENTO DAS REDES NEURAIS ARTIFICIAIS: DADOS DE AJUSTE ...	83
3.4 VALIDAÇÃO DAS REDES NEURAIS ARTIFICIAIS PARA ESTIMAÇÃO DE VOLUME .....	85
3.5 COMPARAÇÕES ENTRE AS ESTIMATIVAS COM MÉTODO DE REGRESSÃO E RNA .....	88
3.6 AVALIAÇÃO DA PERFORMANCE DOS MÉTODOS .....	91
<b>4. CONCLUSÕES .....</b>	<b>93</b>
<b>CAPÍTULO 3 .....</b>	<b>94</b>
<b>1 INTRODUÇÃO .....</b>	<b>94</b>
<b>2 MATERIAL E MÉTODOS .....</b>	<b>95</b>
2.1 AJUSTE POR REGRESSÃO: DIÂMETRO AO LONGO DO FUSTE .....	95
2.2 SELEÇÃO E ESTATÍSTICAS DOS MODELOS DE REGRESSÃO .....	96
2.3 TREINAMENTO DAS REDES NEURAIS ARTIFICIAIS .....	97
2.4 AVALIAÇÃO DA PERFORMANCE DOS MÉTODOS .....	98
<b>3. RESULTADOS E DISCUSSÃO .....</b>	<b>99</b>
3.1 AJUSTE DOS MODELOS POR REGRESSÃO: ESTIMAÇÃO DO DIÂMETRO COM CASCA AO LONGO DO FUSTE .....	99

3.2 VALIDAÇÃO DOS MODELOS DE REGRESSÃO.....	100
3.3 TREINAMENTO DAS REDES NEURAI: DADOS DE AJUSTE .....	103
3.4 VALIDAÇÃO DAS REDES NEURAI PARA ESTIMAÇÃO DO DIÂMETRO AO LONGO DO FUSTE .....	104
3.5 COMPARAÇÕES ENTRE AS ESTIMATIVAS COM MÉTODO DE REGRESSÃO E RNA .....	106
3.6 AVALIAÇÃO DA PERFORMANCE DOS MÉTODOS .....	109
3.7 ESTIMAÇÃO DO VOLUME TOTAL COM CASCA POR MEIO DE AFILAMENTO E REDES NEURAI ARTIFICIAIS .....	110
3.8 AVALIAÇÃO DA PERFORMANCE DOS MÉTODOS PARA ESTIMATIVA DE VOLUME TOTAL COM CASCA .....	111
<b>4. CONCLUSÕES.....</b>	<b>113</b>
<b>REFERÊNCIAS.....</b>	<b>142</b>



# REDES NEURAIIS ARTIFICIAIS E MODELOS DE REGRESSÃO PARA ESTIMAÇÃO DE VARIÁVEIS DENDROMÉTRICAS EM *Pinus taeda* L: ANÁLISE COMPARATIVA

## 1 INTRODUÇÃO

A modelagem da altura, volume e afilamento em povoamentos florestais é bastante avançada e difundida no Brasil por meio de modelos lineares e não lineares. Apesar disso, as empresas florestais encontram dificuldades no momento do ajuste dos modelos, mais especificamente na estratificação dos dados para a modelagem e obtenção, com precisão das variáveis dependentes desejadas.

Normalmente, os estratos são definidos conforme idade, material genético, espaçamento inicial, classes de sítio, regime de manejo, entre outros. Essa estratificação, dependendo do porte da empresa, pode gerar dezenas ou até centenas de estratos e, conseqüentemente, equações, as quais podem ser atualizadas anualmente.

As redes neurais artificiais (RNA) podem permitir, por meio de uma única rede, estimar a variável dependente desejada com maior precisão que os modelos tradicionais. Na bibliografia, tal afirmação pode ser encontrada nos trabalhos de mortalidade: Guan e Gertener (1991); volume: Diamantopoulou (2005), Silva et al. (2008), Diamantopoulou e Milios (2009); prognose do crescimento em volume: Binoti (2009); e modelagem do crescimento e produção a nível de árvore individual: Castro (2011).

No Brasil, o estudo com RNA para povoamentos florestais foi iniciado há pouco tempo e os trabalhos já realizados abordaram principalmente a espécie *Eucalyptus* sp.. No entanto, em razão da grande expressão da espécie *Pinus taeda* L. no sul do Brasil, existe a necessidade do desenvolvimento de novas metodologias para melhorar a qualidade das estimativas e reduzir custos durante o processamento dos dados para essa espécie

Ciente da importância do gênero *Pinus* no contexto florestal, tanto em área plantada quanto em valor da produção, corroborando com o fato de se introduzir estudos com RNA para tal gênero, os quais ainda são incipientes no Brasil e que há um grande potencial de aplicação, sintetiza-se o objetivo geral do trabalho em:

“testar as RNA para estimação da altura, volume e afilamento para povoamentos de *Pinus taeda L.*, bem como, avaliar sua aplicabilidade e compará-la com os métodos tradicionais de regressão”.

## 2 OBJETIVOS ESPECÍFICOS

- Estimar altura, volume e afilamento para povoamentos de *Pinus taeda* L. por meio de modelos tradicionais de regressão;
- Estimar altura, volume e afilamento para povoamentos de *Pinus taeda* L. por meio de Redes Neurais Artificiais;
- Comparar as estatísticas de ajuste entre os modelos tradicionais e redes neurais verificando a melhor técnica de ajuste para a espécie em estudo.

### 3 ORGANIZAÇÃO DO ESTUDO

O estudo está organizado em três capítulos (Figura 1). No primeiro capítulo é discutido a estimativa de altura por meio de RNA e regressão, seguido da avaliação do comportamento das estimativas com a redução da medição de alturas. Já no capítulo dois é avaliada a estimativa de volume por meio de RNA e regressão. Por fim, no capítulo três avalia-se as estimativas do diâmetro ao longo do fuste e volume por meio de modelos de afilamento (regressão) e RNA.

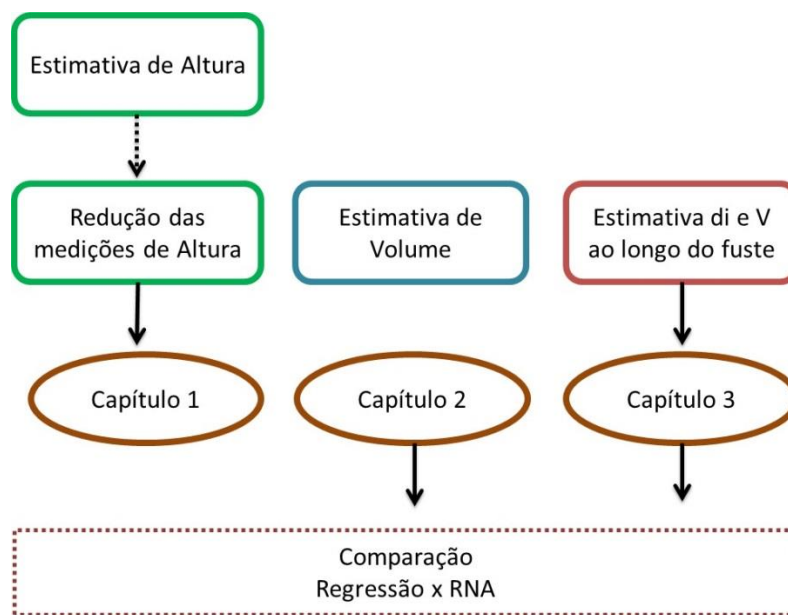


FIGURA 1: FLUXOGRAMA DA APRESENTAÇÃO DO ESTUDO  
Fonte: O autor

### 3 REVISÃO BIBLIOGRÁFICA

#### 3.1 A ESPÉCIE EM ESTUDO

A espécie *Pinus taeda* L. é natural dos Estados Unidos, onde ocorre entre os paralelos 28° e 39° N. É encontrada no sul de New Jersey, Ronda Central, oeste do Texas, norte do Vale do Mississippi, no sudeste de Oklahoma e Arkansas e sul do Tennessee. Sua faixa de dispersão vai desde o nível do mar até 2.500 m de altitude (MIROV, 1967; GARCIA *et al.*, 1996; MARCHIORI, 1996; KRONKA *et al.*, 2005).

No Brasil, em 1936 foram testadas as primeiras espécies de pinus provenientes do continente Europeu; porém, estas não se adaptaram ao clima tropical. Em 1948, o Serviço Florestal do Estado de São Paulo, Brasil, testou as espécies *Pinus palustris* Mill, *Pinus echinata* L., *Pinus elliottii* Engelm. e *Pinus taeda* L., onde as duas últimas destacaram-se pelo rápido crescimento, facilidade de tratamentos culturais e intensa reprodução na região Sul do país (ACERBI JÚNIOR, 1998; SHIMIZU; MEDRADO, 2005). Entretanto, o gênero *Pinus* se difundiu apenas na década de 1960, em função dos incentivos fiscais.

Atualmente existem aproximadamente 1,6 milhão de hectares de plantios de pinus distribuídos no país, principalmente na região Sul. Esse número representa aproximadamente 20,7% da área plantada no Brasil (IBÁ, 2016).

Os plantios de *Pinus* sp. vieram a minimizar a exploração extrativista de florestas nativas no Brasil, e o crescimento dessa atividade contribuiu para a redução do desmatamento para fins industriais (FERREIRA, 2005).

Em 2013, o consumo brasileiro de madeira de árvores plantadas para uso industrial foi de 185,3 milhões de metros cúbicos, o que representou aumento de 1,8% em relação ao consumo de 2012. O consumo *in natura* do gênero *Pinus* em 2013 foi de 40.749.376 (FIGURA 2), destacando-se o segmento de serrados e outros produtos sólidos e painéis de madeira, os quais representam 38% e 33%, respectivamente, do consumo total (IBÁ, 2014).




FIGURA 2- CONSUMO EM METROS CÚBICOS DE MADEIRA IN NATURA DO GÊNERO PINUS SP. NO BRASIL EM 2013.

FONTE: IBÁ, 2014- modificado pelo autor, 2016

No segmento de celulose e papel (3<sup>o</sup> maior consumo de madeira *in natura* de *Pinus*), esse gênero destaca-se devido às características de suas fibras (fibras longas), as quais são responsáveis pela produção de papéis com maior resistência mecânica, como papéis para embalagem, papelão ondulado e outros tipos de papel cartão.

### 3.2 RELAÇÃO HIPSOMÉTRICA

A altura das árvores é uma informação fundamental para a estimativa de volume em um povoamento florestal (SCOLFORO; FIGUEIREDO FILHO, 1998), além de também entrar como uma variável independente nas tabelas de volume, funções de afilamento e em outras relações dendrométricas (MACHADO; FIGUEIREDO FILHO, 2006). Em determinadas situações, pode servir como indicadora da qualidade produtiva de um local (SILVA et al., 2012). A obtenção da variável altura pode ser realizada por meio de medições de árvores em pé ou abatidas, com uso de hipsômetros e trenas, ou através de estimativas de relações hipsométricas (SCOLFORO; FIGUEIREDO FILHO, 1998).

A relação entre a altura das árvores e seu respectivo diâmetro para um dado povoamento, é denominada relação hipsométrica, relação altura diâmetro ou relação “h/d”, cujo ajuste pode se dar por meio de uma parábola de segundo grau, funções logarítmicas, entre outras (SCHNEIDER, 2009). Essa metodologia é bastante utilizada em florestas equiâneas e apresenta boa precisão em razão da homogeneidade dos plantios (SILVA et al., 2012).

Considerando que existe uma forte associação entre as variáveis diâmetro e altura, a relação hipsométrica pode ser descrita por um modelo matemático, dependendo da espécie e amplitude dos dados observados (FINGER, 1992), ou seja, estima-se a variável de difícil obtenção em função da mais fácil e de rápida medição (MACHADO; FIGUEIREDO FILHO, 2006; SANQUETTA *et al.*, 2009). A técnica de medir todos os diâmetros das árvores que compõem a parcela de inventário e selecionar, em geral, de 5 a 10 árvores para a mensuração de altura foi desenvolvida por Ker e Smith (1957), sendo essa metodologia ainda utilizada nos inventários florestais tradicionais do Brasil.

Na prática, são mensuradas as alturas de algumas árvores que compõem a parcela de inventário e, a partir destas, são realizadas estimativas das demais alturas por meio de equações hipsométricas (THIERSCH *et al.*, 2013). Essa metodologia resulta na redução de custos do inventário, dado o elevado custo relativo da mensuração da altura comparada à do diâmetro (ZANON *et al.*, 1996; BATISTA *et al.*, 2001; SOARES *et al.* 2004).

Em razão desse elevado custo, o uso de equações hipsométricas no inventário é frequente. Segundo Machado *et al.* (1994), na maioria das vezes, tão preciso quanto ao realizado medindo-se a altura de todas as árvores da parcela. Nesse sentido, a aplicação da relação hipsométrica é um aspecto que deve ser considerado nos inventários florestais devido ao tempo despendido em medir a altura das árvores da parcela (AZEVEDO *et al.*, 1999).

Segundo Hosokawa *et al.* (1998), além de elevar o custo do inventário, a medição de todas as alturas não acrescenta vantagens comparativas do ponto de vista de precisão, devido à fadiga, erro de medição com instrumentos hipsométricos, dentre outros.

Para captar o máximo da relação diâmetro/altura para uma massa de dados, segundo Miguel (2009), é necessário o ajuste de diversos modelos de relação hipsométrica. Isso ocorre pois nesta relação existe uma variação biológica na curva ajustada, sendo dependente da árvore, da estrutura e da homogeneidade da floresta (SCHNEIDER, 2009).

A relação hipsométrica pode ser influenciada por fatores como espécie, posição sociológica, idade, tamanho de copa, densidade, sítio, práticas silviculturais, idade que, em geral, podem afetar e influenciar o vínculo das variáveis (MACHADO

*et al.*, 2008; LOETSCH *et al.*, 1973; HUSCH *et al.*, 1982; FINGER, 1992; SCOLFORO, 1997).

Segundo Scolforo (1997), o comportamento da relação h/d pode ter uma correlação alta em povoamentos com sítios bem definidos, bem formados e bem conduzidos, pois haverá maior homogeneidade na população. Já nos povoamentos mal conduzidos, antigos e com sítios pouco definidos, espera-se uma baixa correlação entre as variáveis, pois haverá uma maior heterogeneidade da população.

Segundo Husch *et al.* (1982) os sítios bons, por apresentarem melhores condições, aceleram o crescimento favorecendo a formação de classes sociológicas mais claras, tendo como consequência uma curva de altura íngreme, enquanto em sítios pobres as curvas para uma mesma espécie são mais achatadas.

Já em relação à idade, Finger (1992) relata que a diferença entre as curvas tende a reduzir à medida que a floresta chega próxima ao seu clímax de crescimento, pois o crescimento em diâmetro e altura diminui e as mudanças da relação h/d serão muito pequenas. Segundo o mesmo autor, a densidade influencia na relação h/d de acordo com a posição sociológica (estrato) da árvore no povoamento florestal, sendo que nas árvores dominantes a altura é pouco afetada pelo espaçamento, enquanto que nas dominadas a influência do crescimento em altura é bastante acentuada, tendo como consequência diferentes relações h/d.

No trabalho de Azevedo *et al.* (1999), os autores perguntam se realmente existe a necessidade de estratificar os dados conforme as características da floresta (idade, espaçamento, sítio etc.). Segundo Barros *et al.* (2002), desde Trorey (1932) a listagem de modelos matemáticos para ajustar a relação h/d vem crescendo constantemente. A mesma metodologia de coleta de dados é utilizada desde 1932, e a estratificação conforme as características das florestas desde a década de 1990.

### 3.3 EQUAÇÕES DE VOLUME

A determinação do volume de árvores individuais é o ponto de partida de uma série de passos para a estimativa do volume de culturas florestais. Por isso, é fundamental para estudos de crescimento e produção, bem como, um requisito essencial na solução de numerosos problemas que envolvem a estimativa de volume de árvores e culturas (GRAY, 1956).



O volume constitui uma das informações mais importantes para o conhecimento do potencial florestal disponível em um local, sendo que o volume individual fornece subsídios para a avaliação do material lenhoso dos povoamentos florestais (MACHADO *et al.*, 2004).

A quantificação do volume em povoamentos florestais é indispensável para a implementação de planos de manejo sustentável de florestas, visando planejar as operações florestais, de modo a se obter estimativas da quantidade e da distribuição da madeira disponível (LEITE; ANDRADE, 2002). Segundo Figueiredo Filho *et al.* (1993), o volume de árvores tem sido estimado com facilidade e acuracidade, empregando-se equações de volume, ajustadas quase sempre a partir de medições de dap e altura total.

Nas estimativas da produção madeireira, uma ferramenta amplamente utilizada são as equações volumétricas, em que o volume é a variável dependente, associado a variáveis independentes de fácil mensuração na floresta, como o Dap e a altura (MACHADO *et al.*, 2002).

De acordo com Scolforo (2005) após a quantificação do volume de árvores, é possível compor o volume de parcelas base para os estudos de crescimento e produção e para estruturar planos de suprimento de floresta plantada e planos de manejo em floresta nativa.

Para se obter o volume por meio de modelos volumétricos, é necessário estimar inicialmente os coeficientes do modelo que resultará na equação volumétrica. Para tal, o volume individual real deve ser obtido a partir dos dados das árvores cubadas, segundo um método de cubagem tradicional, como por exemplo Smalian, Huber, Newton, onde os diâmetros são medidos a diversas alturas (YOSHITANI Jr., 2009).

Dentre as diferentes alternativas de viabilizar a estimativa do volume por meio de equações de volume, podem-se citar as de simples e dupla entrada como as mais usuais. As equações de simples entrada, em que o volume é função somente do diâmetro das árvores, são normalmente aplicadas quando a correlação entre o diâmetro e a altura é muito forte; as equações de dupla entrada, em que o volume é função do diâmetro e da altura, são aplicadas para povoamentos em que há maior heterogeneidade no desenvolvimento da altura das árvores com mesmo diâmetro (SCOLFORO, 2005).

Muitas equações matemáticas foram desenvolvidas para estimar o volume de povoamentos florestais e, apesar da eficiência de alguns modelos, estes nem sempre se ajustam a todas as espécies e condições, sendo recomendável testá-los e, por meio de estatísticas adequadas, identificar o melhor para cada caso (THOMAS *et al.*, 2006).

Para estimar o volume de madeira em florestas de pinus, várias equações matemáticas foram desenvolvidas (MACHADO *et al.*, 2000; MATTOS *et al.*, 2010; SANQUETTA *et al.*, 2010; OLIVEIRA *et al.*, 2011). Loetsch *et al.* (1973), agruparam os modelos matemáticos mais importantes existentes até aquela data, e segundo os autores, tais modelos possuem o mérito de utilizar poucas variáveis fáceis de serem medidas e sendo bem correlacionadas com o volume.

Entre os vários modelos existentes para expressar o volume de madeira, o proposto por Schumacher e Hall (1933) tem sido um dos mais difundidos na área florestal, talvez por suas propriedades estatísticas, uma vez que resulta em estimativas quase sempre não tendenciosas (CAMPOS; LEITE, 2009).

### 3.4 AFILAMENTO – *TAPER*

Os termos usados para descrever a forma das árvores, como o afilamento, forma e fator de forma, têm uma grande variedade de significados na literatura florestal (LARSON, 1963). *Taper* é um termo técnico utilizado no meio florestal para se referir ao perfil do tronco de uma árvore, definido como sendo a taxa de decréscimo do diâmetro ao longo do tronco das árvores (GRAY, 1956), também conhecido como afilamento (CAMPOS; LEITE, 2009). De acordo com Ahrens e Holbert (1981), uma função de afilamento é uma descrição matemática do perfil longitudinal de um tronco.

A primeira tentativa analítica para representar a forma de árvores foi feita por Hojer em 1903 e desde então, muitas formas e tipos de modelo de perfil do tronco foram testados (FIGUEIREDO FILHO *et al.*, 1996). Segundo Figueiredo Filho *et al.* (1993), a partir de meados da década de 1970, com o intuito de melhorar a eficiência das funções, foram testados modelos para representar partes do tronco, como as equações segmentadas de Max e Burkhart (1976).

Assim, equações de afilamento ou *taper* são empregadas para descrever o afilamento do tronco de árvores, ou seja, o decréscimo do diâmetro ao longo do

fuste a partir da base (CAMPOS; LEITE, 2009). Assumindo-se que a secção transversal seja circular em qualquer ponto ao longo do tronco, o seu volume pode ser obtido por integração daquela função e, assim, em termos geométricos, o tronco é tratado como um sólido de revolução (AHRENS; HOLBERT, 1981).

Segundo Husch *et al.* (1982), normalmente os fustes das árvores se assemelham a sólidos geométricos do tipo cilindro, neilóide, parabolóide e cone. Como os fustes das árvores podem assumir diferentes formas, isso acarreta grandes dificuldades quando se propõe estudar sua forma por meio de funções de afilamento (LOETSCH *et al.*, 1973).

Os modelos de afilamento são ferramentas valiosas para a utilização em multiprodutos, tendo em vista sua flexibilidade em estimar diâmetros, bem como alturas correspondentes a qualquer diâmetro e volumes de diferentes seções ao longo do tronco a partir da integração da área das seções do tronco (DEMAERSCHALK, 1972).

De acordo com Prodan (1997), os modelos de afilamento constituem uma importante ferramenta estatística de uso corrente na determinação dos perfis de troncos, uma vez que permitem estimar o diâmetro em qualquer ponto do fuste, a altura total ou a altura em que se encontra um diâmetro especificado no fuste e o volume entre pontos quaisquer do fuste. Husch *et al.* (1993) afirmam que é de grande importância o conhecimento sobre o afilamento do tronco na determinação de multiprodutos de madeira.

As funções de afilamento são um poderoso instrumento para avaliar biológica e economicamente um maciço florestal e a resposta às práticas de manejo, já que permite valorar de maneira detalhada quanto renderá o povoamento florestal (FISCHER *et al.*, 2001). Diversos modelos de afilamento já foram propostos por pesquisadores florestais, destacando-se Schoepfer (1966), Kozak *et al.* (1969), Demaerschalk (1972), Ormerod (1973), Hradetzky (1976), Garay (1979), Biging (1984) e Baldwin e Feduccia (1991), entre outros em que o ajuste dos modelos foi efetuado por meio de análise de regressão. Apesar da existência desses e de muitos outros modelos, não existe um que seja eficiente em todos os casos, ou seja, para qualquer amostra de dados.

Um bom ajuste de modelo para estimar o diâmetro não necessariamente irá garantir uma boa estimativa para altura e/ou volume, e vice-versa, mesmo que para uma mesma espécie (LIMA, 1986). Souza *et al.* (2008a) em uma pesquisa realizada

com *Pinus taeda*, mostraram que para diferentes comprimentos ao longo do tronco tem-se modelos diferentes para estimar o diâmetro, sendo que a estimação do volume também se mostrou diferenciada para os diferentes comprimentos analisados.

A flexibilidade das funções de afilamento e a forma do perfil do tronco de cada espécie são os fatores que mais determinam a eficiência das funções. Assim, um modelo pode ser eficiente para determinada espécie submetida a certas condições, pode não o ser para outra (LIMA, 1986).

Para realizar a avaliação das equações ajustadas, aplicam-se conjuntamente algumas estatísticas, sendo as mais usuais na área florestal o erro padrão da estimativa ( $S_{yx}\%$ ), o coeficiente de determinação ajustado ( $R_{ajust}^2$ ) e a análise gráfica de resíduos. As estatísticas viés ( $V$ ), média das diferenças absolutas ( $MD$ ) e desvio padrão das diferenças ( $DPD$ ), também têm sido utilizadas como estatísticas complementares, sendo que, quando usadas separadamente, não dão poder de decisão sobre qual o melhor método. O viés indica a existência ou não de tendências entre os resíduos, porém não mede o quão afastado do eixo zero estão os valores residuais. Já a média das diferenças fornece justamente a ideia da amplitude dos erros, e o desvio padrão das diferenças mostra a homogeneidade entre os resíduos (SOUZA, 2009). As estatísticas complementares já foram usadas por vários autores (SCOLFARO *et al.*, 1998; FERREIRA, 1999; MENDONÇA, 2006; SOUZA *et al.*, 2008b; SOUZA *et al.*, 2008c; SOUZA, 2009; LIMA, 1986; SCHNEIDER *et al.*, 2009, entre outros).

### 3.5 REDES NEURAIIS ARTIFICIAIS

As RNA começaram a ser desenvolvidas visando simular sistemas naturais, utilizando-se de estruturas análogas às Redes Neurais Biológicas (RNB) (SANTOS, 2001). Em 1943 McCulloch e Pitts modelaram a primeira rede neural artificial no artigo “*A logical calculus of the ideas Imammament in the nervous activity*”.

Em 1949, Donald Hebb, elaborou a teoria de como funciona o processo de aprendizagem no cérebro humano. Essa teoria está publicada no artigo “*The organization of behavior*”. Já em 1956, Rochester *et al.* (1956), inspirados na teoria de Donald Hebb, desenvolveu a simulação da interconexão de centenas de

neurônios artificiais e em 1958, Frank Rosenblatt propôs o *perceptron* e um algoritmo para treinamento da rede.

Widrow e Hoff (1960), desenvolveram o modelo de RNA *Adaline*, o qual realiza processamentos paralelos, baseado na regra de aprendizagem do gradiente de minimização de erro de saída.

Nas décadas de 1960 e 1970 foram desenvolvidos trabalhos com RNA, porém não foram muito visíveis devido ao trabalho de Minsky e Papert (1969), que apresentaram limitações das redes, provando formalmente que uma rede formada por uma única camada de neurônios é capaz de resolver um problema apenas quando o conjunto de pares padrões são linearmente separáveis. Até que em 1986 Rumelhart, Hinton e Williams descreveram o algoritmo *backpropagation*, provando que o *perceptron* de multicamadas são capazes de resolver problemas não linearmente separáveis.

Na área ecológica, os trabalhos com RNA iniciaram na década de 1990 e nos anos 2000. Foram publicados trabalhos para prever a presença ou ausência de macro-invertebrados em seu habitat por meio da utilização de MLP (*Multilayer Perceptron*), desenvolvido por Hoang *et al.* (2001), trabalhos com aves, por Manel *et al.* (1999), localização de ninhos de aguias, por Fielding, (1999), cianobactérias em pântanos (MAIER *et al.*, 1998), para prever danos no campo agrícola causados por flamingo (TOURENQ *et al.*, 1999), abundância de aves, por Lusk *et al.*, 2001), e para avaliar a abundância e riqueza para espécies macro-invertebrados (LEK-ANG *et al.*, 1999)

Diversos trabalhos na área florestal vêm sendo desenvolvidos por Diamantopoulou (2005) na Grécia, como o trabalho "*Artificial neural networks as an alternative tool in pine bark volume estimation*", e Diamantopoulou (2012) no artigo "*Assessing a reliable modeling approach of features of trees through neural network models for sustainable forests*", Özçelik *et al.* (2013) no trabalho para comparar altura de árvores por meio de RNA e métodos de regressão, Özçelik *et al.* (2010), para estimar o volume de 4 espécies da Turquia utilizando RNA. No Brasil foram desenvolvidos alguns trabalhos como Castro (2011) em sua tese de doutorado intitulada "*Modelagem do crescimento em nível de árvores individuais utilizando redes neurais e autômatos celulares*", Binoti (2010) em sua dissertação de mestrado para a prognose da produção em povoamentos de *Eucalyptus* não desbastados,

Binoti (2012) na tese com título "Emprego de Redes Neurais em Mensuração e Manejo Florestal".

As redes neurais artificiais (RNA) são modelos computacionais inspirados nos neurônios naturais (FAUSETT, 1994), ou seja, possuem características de processamento similares ao cérebro humano (não linearidade, alto paralelismo e capacidade de generalizar) (ÖZÇELİK *et al.*, 2013).

Segundo Castro (2011) as RNA assemelham-se ao sistema nervoso biológico (FIGURA 3), o qual é formado por células nervosas chamadas neurônios. Os neurônios possuem extensões chamadas dendritos, que recebem impulsos nervosos de outros neurônios, os axônios, que transmitem o impulso nervoso até a terminação sináptica, e sinapse, que é ponto de contato entre os neurônios, responsável por transmitir o impulso nervoso.

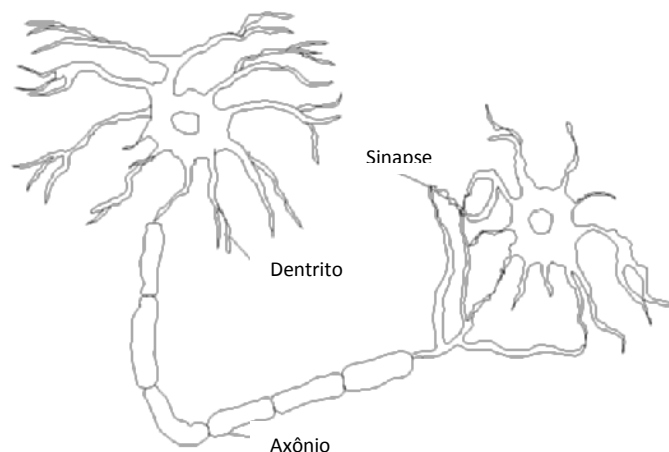


FIGURA 3- ESTRUTURA DO NEURÔNIO BIOLÓGICO  
 FONTE: Gonçalves, Lemes e Junior, 2005

Nas RNA, os neurônios estão dispostos em camadas paralelas, interligados entre si por um grande número de conexões, as quais são associadas a pesos que armazenam o conhecimento representado pela rede e ponderam a entrada recebida por cada neurônio da rede (BRAGA *et al.*, 2000). Uma rede neural artificial (RNA), frequentemente chamada de rede neural (RN) é um sistema de processamento de informação distribuída paralelamente que simula o funcionamento de neurônios no cérebro humano, responsáveis pela capacidade humana de aprender, ou seja, a RNA é um sistema adaptativo baseada nas informações que fluem ao longo da estrutura durante a fase de aprendizado (DIAMANTOPOULOU, 2012).

Segundo Haykin (2001), uma RNA pode possuir uma única camada de processamento, a camada de saída (redes de camada única) ou uma ou mais camadas intermediárias (redes de camadas múltiplas), as quais são mais complexas e possuem maior capacidade para solução de problemas.

A RNA sempre terá uma ou mais camadas de entrada e saída (FIGURA 4). A camada de entrada recebe as informações do problema e as transmite para as demais camadas. A camada de saída irá gerar a solução do problema. Uma RNA pode ter nenhuma, uma ou mais camadas intermediárias, tendo a função de extrair as características dos dados para auxiliar na solução do problema. As conexões entre os neurônios, representados por pesos, têm a função de ponderar as informações recebidas, bem como armazenar o conhecimento adquirido pela rede ao fim do treinamento (BINOTI; BINOTI, 2014).




FIGURA 4- REPRESENTAÇÃO DA ARQUITETURA DE UMA RNA  
 FONTE: Ferneda, 2006, modificado pelo autor, 2016

Um exemplo de neurônio artificial (unidade de processamento de uma RNA) e seu funcionamento estão representados de forma simplificada na FIGURA 5, o que representa como é realizado o processamento por meio de redes.




FIGURA 5 - ESTRUTURA DO NEURÔNIO ARTIFICIAL

Fonte: O autor

O neurônio artificial recebe as entradas ( $x_0, x_1, x_2, \dots, x_n$ ) ponderadas pelos pesos ( $w_0, w_1, w_2, \dots, w_n$ ). As entradas são multiplicadas pelos seus respectivos pesos e estes produtos somados (combinação linear), resultando em único valor  $u$ , que passa pela função de ativação ( $f(u)$ ), gerando a resposta do neurônio ( $y$ ). A saída do neurônio pode ser representada pela seguinte expressão, conforme apresentado por Binoti e Binoti (2014):

$$y = f(x_0 \cdot w_0 + x_1 \cdot w_1 + x_2 \cdot w_2 + \dots + x_n \cdot w_n)$$

Esse é um exemplo de um neurônio desenvolvido por McCulloch e Pitts em 1943, o qual possui função de ativação limiar. Segundo Haykin (2001), a função de ativação, também conhecida como função de transferência, é uma função matemática que, aplicada à combinação entre as variáveis de entrada e pesos que chegam a determinado neurônio, gera um valor de saída, onde normalmente esse intervalo varia entre 0 e 1.

Segundo Binoti (2010), a função de ativação pode ser: função limiar, função linear por partes e função sigmoide (FIGURA 6). O neurônio com a função de ativação de limiar terá saída igual a 1 se  $v_k \geq 0$  ou a 0 se  $v_k < 0$ . Na função linear por partes, a saída será 1 se  $v_k \geq +1/2$ , 0 se  $-1/2 > v_k > -1/2$  e 0 se  $v_k \leq -1/2$ . Enquanto que a função de ativação sigmoide é definida por:

$$\varphi(v) = \frac{1}{1 + \exp(-av)}$$

Em que:  $a$  é o parâmetro que determina a inclinação da função sigmoide.

Uma função sigmoide assume um intervalo contínuo de valores entre 0 e 1, sendo diferenciável, característica importante para as RNA.






FIGURA 6- PRINCIPAIS FUNÇÕES DE ATIVAÇÃO NAS RNA, ONDE A) FUNÇÃO LIMIAR, B) FUNÇÃO LINEAR POR PARTES, C) FUNÇÃO SIGMOIDE  
 FONTE: Castro, 2011

Já a arquitetura da rede, segundo Castro (2011), consiste na forma como os neurônios são organizados, onde usualmente essas camadas são classificadas em 3 grupos: 1) camada de entrada: onde as variáveis são apresentadas à rede; 2) camadas intermediárias ou ocultas: onde é realizada a maior parte dos processamentos e 3) camada de saída: onde o resultado final é concluído e apresentado.

Para Braga *et al.* (2000) a arquitetura da RNA é a maneira que os neurônios e suas conexões estão estruturados, ou seja, número de neurônios em cada camada, número de camadas da rede e tipo de conexão da rede. Segundo Binoti (2010), para cada variável quantitativa há um único neurônio na camada de entrada, enquanto que para as variáveis qualitativas, o número de classes desta variável é que determinará o número de neurônios, sendo necessário um neurônio para cada classe.

As redes de camada única podem ser chamadas de *perceptron* de camada única ou *Adaline* (*Adaptive Linear Element*). Segundo Binoti (2010) é a forma mais simples de uma RNA, pois a camada de entrada apenas direciona os sinais de entrada ponderados pelos pesos sinápticos à camada seguinte, ou seja, direciona à camada de saída.

O *Adaline* é um classificador de padrão adaptativo que utiliza um algoritmo de aprendizado um pouco mais avançado que o *perceptron*, chamado LMS (*Linear Mean Squared* ou Quadrado Médio Linear), o qual minimiza a soma dos quadrados dos erros lineares sobre o conjunto de treinamento (SANTOS, 2001).

Já as redes com uma ou mais camadas intermediárias, chamadas de *perceptron* de multicamadas (*Multilayer Perceptron* - MLP) são as mais populares.

Essas RNA são capazes de resolver problemas mais difíceis do que as redes de camadas simples e possuem um algoritmo central de treinamento chamado algoritmo de *back propagation*. Modelos de *back propagation* já foram descritos e utilizados extensamente (RUMELHART *et al.*, 1986; FAUSETT, 1994; HAYKIN, 1994).

O algoritmo *back propagation* é baseado na regra de aprendizagem por correção do erro (Regra Delta Generalizada), onde sinais de entrada são apresentados à rede, que gera uma saída a qual é apresentada à uma saída desejada, o que gera um erro que aciona um mecanismo de controle dos pesos sinápticos, os quais são corrigidos para minimizar o erro e aproximar a saída do resultado desejado (FAUSETT, 1994; HAYKIN, 2001; SANTOS, 2001).

Segundo Santos (2001), esse algoritmo busca minimizar o erro obtido pela rede por meio do método do gradiente descendente, o qual busca um mínimo global, considerado como uma solução teórica ótima, pois apresenta o menor erro possível. A formação de uma rede por *back propagation* envolve conexões acíclicas, também conhecidas por *feedforward* (DIAMANTOPOULOU, 2001). Quando se trata de conexões, as mais conhecidas são a *feedforward*, as quais são redes acíclicas e as redes *feedback*, que possuem pelo menos uma conexão de realimentação (HAYKIN, 2001; BULLINARIA, 2009).

*Feedforward* é um processo onde a informação sai da camada de entrada em direção à camada intermediária passando para à camada de saída sem que exista reconexão do próprio neurônio (DIAMANTOPOULOU, 2001). Segundo Loke (1995) as redes *feedforward* são sistemas de mapeamento não linear estatístico instantâneo, onde a passagem do sinal pela rede é unidirecional.

As redes *feedforward* multicamadas possuem um melhor desempenho devido à passagem unidirecional do sinal pela rede e pelo processamento da informação ocorrer no sentido progressivo por meio das interconexões entre os neurônios das camadas adjacentes. Além disso, essas redes podem ser utilizadas para a classificação de padrões não linearmente separáveis (FIGURA 7) (SANTOS, 2001).




FIGURA 7- REPRESENTAÇÃO DE PADRÕES NÃO LINEARMENTE SEPARÁVEIS  
 FONTE: Bishop, 1995

Padrões não linearmente separáveis são padrões que caem em determinadas posições do hiperplano que não podem ser separados por uma linha reta. Soluções não lineares normalmente apresentam percentuais de erro na classificação inferiores às soluções lineares para a grande maioria dos problemas (BISHOP, 1995; SANTOS, 2001).

Já as conexões cíclicas ou *feedback* são sistemas não-lineares dinâmicos, o qual é realizado por caminhos fechados ou loops, onde há fluxos de informação para as camadas anteriores e laterais (LOKE, 1995).

Uma das maiores desvantagens da utilização de MLP é que não existe um método perfeito para a determinação do número de iterações de formação da rede. Para trabalhar com essa rede podem ser estabelecidas 3 metodologias: 1) definir o nível de erro a ser atingido; 2) utilizar um método de parada, como realizado por Goodman (1996), e 3) utilizar um banco de dados de teste (ÖZESMI *et al.*, 2006).

O problema com o primeiro método é a dificuldade em decidir o nível de erro apropriado para os dados. Geralmente, o erro cai até um certo número de iterações onde se estabiliza. Porém, dependendo do número de treinamentos, a rede já pode estar “supertreinada” (ÖZESMI *et al.*, 2006) ou “viciada”, problema chamado por muitos autores como *overtraining* ou *overfitting*.

A função de base radial (RBF) é uma alternativa poderosa para as redes MLP. Ambas diferem em relação à construção da entradas e saídas, pois os neurônios de ativação da camada oculta possuem função gaussianas, que exigem menos amostras para o treinamento e são mais rápidos que as MLP (CASTELLANOS *et al.*, 2007).

A RBF é constituída por três camadas: uma de entrada, uma intermediária, a qual possui muitos neurônios e função de ativação gaussiana, e uma de saída linear (BRAGA *et al.*, 2000; HAYKIN, 2001).

As RNA possuem algumas desvantagens como: definição da melhor arquitetura, supertreinamento (*overfitting*) e interpretação de como a rede obteve os resultados (BRAGA *et al.*, 2000; ÖZESMI *et al.*, 2006) .

O supertreinamento pode ocorrer devido ao treinamento excessivo na busca para minimizar os erros. A aplicação do erro na base de dados testada será excelente, porém quando aplicada em uma nova base de dados em busca de resultados da mesma variável dependente, o resultado não será o esperado. Por isso o ideal é separar uma parte dos dados para treinamento da rede e outra parte para aplicação. Para definir a arquitetura ideal para solucionar um problema, é necessário o treinamento de diversas RNA, o que pode dispor de horas de treinamento. Já na interpretação, a RNA faz diferentes interações entre as variáveis independentes, limitando-se ao número de neurônios estipulado pelo operador, e ao gerar os resultados não torna claro quais variáveis interpolaram-se e qual seus pesos.

Krogh (2008) recomenda testar a rede em dados que não tenham sido usados em seu treinamento, e que seja realizado a validação cruzada, em que o conjunto de dados é dividido em, por exemplo, dez conjuntos de igual tamanho. Segundo Bishop (1995) o melhor desempenho na generalização é usualmente atingido com um modelo cuja complexidade não é nem muito pequena nem muito grande, por exemplo, um polinômio de primeira ordem (linha reta) pode ser muito simples para identificar a relação entre a variável independente e dependente, porém um polinômio na 15<sup>o</sup> ordem pode gerar um *ruído*. Isto também é conhecido como o *bias-variance trade-off*, onde um modelo simplista vai ter uma polarização grande enquanto um modelo muito complexo terá um grande variância.

O treinando com o ruído (*outliers*), ou a adição de ruído para os vetores de entrada, é também outra forma de reduzir a complexidade do modelo. O ruído irá tornar mais difícil para a rede ajustar pontos de dados individuais de forma exata, portanto, reduzindo o *overfitting* e melhorar a generalização (BISHOP, 1995). Um exemplo de formação de redes com o ruído foi realizada por Scardi (2001) na modelagem primária de produção de fitoplâncton.

As RNA são tratadas como modelos de caixa preta, porque o valor dos pesos das variáveis de entrada nas camadas ocultas não são interpretáveis nas camadas intermediárias, conhecidas também como camadas ocultas (ÖZCELIK *et al.*, 2010). Porém, existem alguns estudos para entender esses pesos, como o de Gevrey *et al.* (2003) os quais mostraram que o método derivado parcial, quando aplicado para *backpropagation* em redes neurais, foi útil na medição da influência de cada variável de entrada sobre variáveis de saída.

Segundo Scardi (2001) modelos de redes neurais artificiais não devem ser tratados como modelos caixa preta, mas usando várias técnicas a “caixa pode ser aberta”, e cita vários trabalhos que utilizaram diferentes metodologias para a maior transparência da RNA como Lek *et al.* (1996), Scardi (1996), Recknagel *et al.* (1997) e Olden (2000).

Braga *et al.* (2000) e Özesmi *et al.* (2006), relatam que apesar dessas dificuldades, o desempenho e capacidade computacional das RNA não são comprometidos.

As RNA têm recebido atenção considerável devido a sua capacidade de resolver problemas que são difíceis de formular, como os problemas de natureza biológica (ÖZÇELIK *et al.*, 2013), por sua metodologia ser comparável à modelagem estatística e não possuir restrições de premissas como os modelos tradicionais (DIAMANTOPOULOU, 2010).

Seu desempenho já foi demonstrado em várias áreas, notavelmente na física e economia (NICOLAS *et al.*, 1989; NARENDRA; PARTHASARATHY, 1990; REFENES *et al.*, 1993; HOPTROFF, 1993), em trabalhos na área biologia, sendo bastante desenvolvido na área médica (ZHU *et al.*, 1990; BLAZEK, *et al.*, 1991;.BAZOOK *et al.*, 1994; BELENKY *et al.*, 1994) podendo ser muito útil também para a modelagem de processos ecológicos, conforme destacado Lek *et al.* (1996), e passando a ser aplicada na década de 90 em ciências ecológicas e ambientais, conforme Lek e Guégan (1999).

Grande número de pesquisadores destacam os modelos RNA pela sua aplicabilidade na modelagem florestal, podendo-se citar Guan e Gertner (1991); Schmoldt *et al.* (1997); Zhang *et al.* (2000); Leduc *et al.* (2001); Liu *et al.* (2003) e Corne *et al.* (2004).

Mais recentemente na engenharia florestal, a superioridade das redes neurais quando comparadas com modelos tradicionais foi verificada por Gorgens (2006),

Silva *et al.* (2009), Gorgens *et al.* (2009) em estudo para estimar volume individual de *Eucalyptus* sp.; por Binoti (2010) trabalhando com a mesma espécie para estimar o volume a nível de povoamento, além das variáveis diâmetro e altura a nível de árvores individuais e por Castro (2011) para a modelagem do crescimento e produção para *Eucalyptus* sp.; Diamantopoulou e Milios (2009) na modelagem de volume total para árvores dominantes de *Pinus butia* na Grécia, entre outros.

# CAPÍTULO 1

## ESTIMATIVA DA ALTURA POR MEIO DE REGRESSÃO E REDES NEURAIAS ARTIFICIAIS PARA POVOAMENTOS DE *Pinus taeda* L.

### 1 INTRODUÇÃO

A quantificação das alturas das árvores é fundamental no inventário florestal, pois é utilizada para a estimativa do volume de madeira dos povoamentos e para fazer classificações destes quanto às suas produtividades. Por ser uma medida indireta, é sujeita a erros e, normalmente, implica maior tempo para sua quantificação quando comparada com o diâmetro (THIERSCH *et al.*, 2013).

Segundo Caldeira *et al.* (2003), muitas vezes, um modelo é ajustado com dados de diferentes estratos, podendo ser utilizada, por exemplo, a estratificação por idade, espaçamento e/ou sítio. Azevedo *et al.* (1999), questiona se realmente seria necessária uma equação independente para cada um desses estratos. O fato é que, em muitos casos, uma única equação obtida por meio de dados agrupados, poderá ser utilizada como estimativa comum para todos os estratos.

A grande dificuldade da escolha do melhor modelo para representar essas relações hipsométricas se deve à não linearidade da relação entre as variáveis envolvidas e as restrições impostas aos parâmetros dos modelos, por razões biológicas (PLÁCIDO *et al.*, 2004; SOARES *et al.*, 2004). Esses dois fatores aliados tornam o ajuste de modelos estatísticos para representar as relações hipsométricas um problema de regressão não linear, com restrições nos parâmetros (THIERSCH *et al.*, 2013).

Segundo Soares *et al.* (2004), deve-se analisar a viabilidade de uma equação genérica que permita estimativas de altura para um conjunto de dados oriundos de povoamentos com características heterogêneas. Assim, de acordo com Cardoso (1989), será possível eliminar o trabalho de ajuste e seleção de equações mais adequadas para cada parcela ou povoamento, reduzindo-se o custo de processamento dos dados.

Uma alternativa são as Redes Neurais Artificiais, que são sistemas computacionais paralelos constituídos por unidades mais simples, denominadas

neurônios, conectados entre si de uma maneira específica para desempenhar uma tarefa (BINOTI, 2010).

Segundo Haykin (2001) e Bullinaria (2010), as RNA podem apresentar desempenho superior aos modelos de regressão por possuírem características como: estrutura maciça e paralelamente distribuída; habilidade de aprender e generalizar, que as tornam hábeis a resolver problemas complexos; tolerância a falhas e ruídos; capacidade de modelar diversas variáveis e suas relações não-lineares; capacidade de modelar com variáveis categóricas (qualitativas) e numéricas.

Estudos referendados na literatura florestal já mostram o potencial do uso das RNA. Entretanto, poucos são os autores que testaram essa metodologia no gênero *Pinus*, gênero que representa a segunda maior área de plantios florestais no Brasil.

Considerando um panorama de testar uma alternativa metodológica às regressões lineares já tradicionais no âmbito do setor florestal, este trabalho teve o objetivo principal estimar altura para povoamentos de *Pinus taeda* L. por meio de modelos de regressão e redes neurais artificiais, comparando as duas metodologias, assim como verificar a aplicabilidade e qualidade das duas metodologias em reduzir o número de árvores medidas em campo.



## 2 MATERIAL E MÉTODOS

### 2.1 DESCRIÇÃO DOS PLANTIOS

Os dados do estudo são provenientes de inventários contínuos de plantios de *Pinus taeda* L. não desbastados, localizados no município de Telêmaco Borba, região centro oriental do estado do Paraná. A área amostrada no estudo abrange cerca de 3.000 ha pertencentes à empresa Klabin.

Foram mensuradas 304 parcelas, totalizando 2.454 remedições. As parcelas utilizadas apresentam forma retangular com área variável, sendo a área mínima de 446,6 m<sup>2</sup> e máxima de 979,4 m<sup>2</sup>.

A idade dos plantios mensurados no inventário contínuo variou entre 3,3 anos e 21,4 anos, com maior frequência nas idades 6 e 9 anos (FIGURA 8).




FIGURA 8- DISTRIBUIÇÃO DE IDADES DOS DADOS EM ESTUDO

### 2.2 AJUSTE POR REGRESSÃO: RELAÇÃO HIPSOMÉTRICA

Foram selecionadas as árvores com altura mensurada, excluindo aquelas com código de qualidade morta e quebrada. As parcelas foram estratificadas conforme o ano de plantio, gerando 11 estratos (TABELA 1). Os dados do estudo foram estratificados para a regressão conforme ano de plantio, projeto e espécie.

TABELA 1- ESTRATIFICAÇÃO PARA A RELAÇÃO HIPSOMÉTRICA

Estrato	Ano	N de árvores
1	1993	256
2	1995	69
3	1997	145
4	1998	54
5	2001	340
6	2002	308
7	2003	4115
8	2004	10974
9	2005	14983
10	2006	6090
11	2007	504
<b>Total</b>		<b>37.838</b>

Foram ajustados 4 modelos hipsométricos, 2 relacionando a variável dependente altura com a variável independente diâmetro a 1,30m (*dap*) e os outros 2 com as variáveis independentes *dap* e idade. Os modelos utilizados estão apresentados na TABELA 2.

TABELA 2- MODELOS HIPSOMÉTRICOS

Modelo	Modelo
1	$\ln h = b_0 + b_1 \cdot \frac{1}{dap}$
2	$\ln h = b_0 + b_1 \cdot \ln dap$
3	$\ln h = b_0 + b_1 \cdot \frac{1}{dap} + b_2 \cdot \frac{1}{I}$
4	$\ln h = b_0 + b_1 \cdot \ln dap + b_2 \cdot \frac{1}{I}$

Em que: *h* = altura total (m); *dap* = diâmetro a 1,30 m (cm); *I* = idade (anos); *b<sub>is</sub>* = parâmetros a serem estimados, ln= logaritmo neperiano.

### 2.3 SELEÇÃO E ESTATÍSTICAS DE AJUSTE DOS MODELOS DE REGRESSÃO

Para os ajustes dos modelos por meio de regressão foram utilizados 70% dos dados, sendo os outros 30% reservados para a validação das equações. A seleção dos dados foi realizada de forma aleatória.

O ajuste dos modelos foi realizado por meio do software Statistica 7.0 (STATSOFT Inc, 2009), sendo posteriormente selecionados dois modelos, os quais foram aplicados aos dados de validação. Para selecionar o modelo por estrato, foram analisadas as estatísticas coeficiente de determinação ajustado e erro padrão

da estimativa em porcentagem, sendo o mesmo recalculado utilizando Fator de Meyer de modo a permitir a correção da discrepância logarítmica, uma vez que as variáveis sofreram transformação (TABELA 3).

TABELA 3- ESTATÍSTICAS UTILIZADAS PARA A SELEÇÃO DE MODELOS DE RELAÇÃO HIPSOMÉTRICA

Estatísticas	Fórmulas	
Coeficiente de determinação ajustado	$R^2_{ajust} = 1 - \left\{ (1 - R^2) \cdot \left( \frac{n - p}{n - p - 1} \right) \right\} \quad R^2 = \frac{SQReg}{SQT}$	
Erro padrão da estimativa em porcentagem	$Syx\% = \frac{Syx}{\bar{y}} \cdot 100 \quad Syx = \sqrt{\frac{\sum_1^n (y_i - \hat{y}_i)^2}{(n - p)}}$	
Fator de Meyer (FM)	$FM = e^{0,5 (syx^2)}$	
Análise gráfica de resíduos	$Resíduo \% = \left( \frac{y_i - \hat{y}_i}{y_i} \right) \cdot 100$	

Em que:  $R^2$  = coeficiente de determinação ajustado;  $SQReg$  = soma dos quadrados da regressão;  $SQT$  = soma dos quadrados total;  $n$  = número de observações;  $p$  = número de coeficientes incluindo  $b_0$ ;  $R^2$  = coeficiente de determinação;  $Syx$  = erro padrão da estimativa;  $y_i$  = valor real de cada observação;  $\hat{y}_i$  = valor estimado de cada observação;  $e = 2,718281828$ ;

Além disso, foram utilizadas as estatísticas complementares (Tabela 3) Viés (V), Média das Diferenças Absolutas (MD) e Desvio Padrão das Diferenças (DPD), que possibilitam uma análise mais detalhada do desempenho das estimativas (TABELA 4).

TABELA 4- ESTATÍSTICAS COMPLEMENTARES PARA ANÁLISE DOS MODELOS HIPSOMÉTRICOS

Estadística	Estimador
Viés (V)	$V = \frac{\sum_{i=1}^n y_i - \sum_{i=1}^n \hat{y}_i}{n}$
Média das diferenças absolutas (MD)	$MD = \frac{\sum_{i=1}^n  y_i - \hat{y}_i }{n}$
Desvio padrão das diferenças (DPD)	$DPD = \sqrt{\left( \frac{\sum_{i=1}^n d_i^2}{n} - \left( \frac{\sum_{i=1}^n d_i}{n} \right)^2 \right) / (n-1)}$

Em que:  $y_i$ = valor observado e  $\hat{y}_i$ = valor estimado;  $n$ = número de observações; e  $d_i = (y_i - \hat{y}_i)$ .  
 Fonte: Figueiredo Filho *et al.* (1996)

O viés indica a existência ou não de tendências entre os resíduos. Porém não mede o quão afastado do eixo zero estão os valores residuais, já a média das diferenças fornece justamente a ideia da amplitude dos erros, e o desvio padrão das diferenças mostra a homogeneidade entre os resíduos (SOUZA, 2009).

Com essas três estatísticas complementares foram estabelecidas notas para os modelos, no intervalo de 1 à  $n$ , e foram classificados como melhores aqueles que resultaram na menor soma de notas.

## 2.4 TREINAMENTO DAS REDES NEURAS ARTIFICIAIS

Os mesmos dados utilizados para o ajuste de modelos por meio de regressão foram selecionados para o treinamento das redes; no entanto, neste caso os dados não foram estratificados. A estratificação foi realizada posteriormente ao treinamento das redes com o intuito de gerar as estatísticas de comparação com os modelos de regressão. A mesma proporção de dados utilizada para o ajuste das relações hipsométricas foi utilizada para o treinamento das RNA, ou seja 70%, e os outros 30% restantes foram utilizados para validação das redes selecionadas.

As redes foram treinadas para estimar a variável dependente altura total, utilizando as diferentes combinações entre as variáveis independentes quantitativas dap e idade.

As redes treinadas foram do tipo *perceptrons*, conhecidas como MLP (*Multilayer Perceptron*) com uma camada de entrada para receber os dados, três ou

quatro camadas intermediárias para processamento e uma camada de saída. Também foram treinadas redes do tipo RBF (*Radial Basis Function*) e rede linear. As funções de ativação testadas foram a linear e a logística.

Ambas as redes foram limitadas para um número máximo de 80 neurônios por camada para evitar o “*overtraining*” das redes.

Para o treinamento, utilizou-se o *software* Statistica 7.0 (Statsoft, Inc, 2009). As 60 melhores redes (menor erro) foram retidas e dentre essas foram selecionadas as 20 redes com maior correlação de Pearson entre os dados estimados e observados.

As redes selecionadas foram analisadas pelas mesmas estatísticas dos modelos hipsométricos, com exceção do coeficiente de determinação, fazendo-se uma nova seleção considerando apenas as quatro melhores redes. Essas redes foram aplicadas à base de dados total de validação, sendo finalmente selecionadas as duas melhores redes e aplicadas aos dados de validação por estrato.

## 2.5 REDUÇÃO DA MEDIÇÃO DE ALTURA EM 30% E 60%

Para a análise de redução na medição de alturas foi utilizado o banco de dados de ajuste total, classificado como 100%, e variantes onde o mesmo banco foi reduzido à 70% das alturas, denominado de “redução 30%”, seguido de uma redução em 60% das medições de altura, classificado como “redução 60%”.

Essa redução foi realizada a nível de árvore na parcela, ou seja, em cada parcela foram retiradas do banco de dados as últimas árvores (de traz para frente) até completar a redução de 30% e 60%.

A porcentagem de redução do banco de dados refere-se apenas às alturas médias, uma vez que as alturas dominantes foram mantidas pensando na aplicação prática do banco de dados, já que as alturas dominantes são utilizadas para classificação de sítio. Neste estudo não será avaliada a redução de alturas dominantes na qualidade do ajuste de modelos de sítio.

Foram ajustados os quatro modelos hipsométricos (Tabela 2) para cada estrato, e esses aplicados em seu respectivo estrato em ordem sequencial. Ou seja, os estratos foram numerados de 1 a 11 e colocados um embaixo do outro, aplicando o modelo respectivo para cada estrato, por fim foram geradas as estatísticas a nível de estrato, gerando assim, 4 estatísticas.

Os dois melhores modelos foram selecionados conforme as estatísticas apresentadas nas Tabelas 3 e 4 e gráficos de dispersão de resíduos.

Após a seleção dos dois melhores modelos para cada porcentagem de redução, conforme estatísticas apresentadas nas Tabelas 3 e 4, esses foram aplicados aos dados de validação, que não sofreram nenhuma alteração (redução). As estatísticas foram comparadas entre o banco de dados de ajuste total (100%), redução 30% e redução 60% para verificar a existência de diminuição na qualidade do ajuste dos modelos hipsométricos com a redução na medição de alturas.

As redes neurais artificiais foram treinadas para o banco de dados de ajuste 100%, redução 30% e redução 60%, conforme o item 2.4 deste capítulo. Foram selecionadas as duas melhores RNA para os dados de ajuste 100%, redução 30% e redução 60%, conforme as estatísticas das Tabelas 3 e 4. Estas redes foram aplicadas aos dados de validação e a qualidade do treinamento comparada com os resultados do ajuste 100%, redução 30% e redução 60%.

Por fim, a melhor RNA para cada tipo de redução foi comparada com o melhor modelo de regressão, avaliando se existe diferença na qualidade do ajuste e/ou treinamento e se existe diferença estatística entre as duas metodologias.

## 2.6 AVALIAÇÃO DA PERFORMANCE DOS MÉTODOS

Para avaliar a performance da regressão e redes neurais artificiais, as médias das estimativas das alturas geradas por cada método foram comparadas entre si e entre a média das alturas reais por meio de Análise de Variância (ANOVA), seguida pelo teste de Tukey a 95% de probabilidade de confiança quando existir diferença entre as alturas geradas. Os pressupostos da ANOVA (normalidade e independência dos resíduos e homogeneidade das variâncias) foram previamente verificados e atendidos. Adicionalmente, obteve-se o coeficiente de correlação linear de Pearson ( $r$ ) entre as alturas estimadas pelos diferentes métodos e a altura real.

### 3. RESULTADOS E DISCUSSÃO

Na FIGURA 9 é possível observar que a relação  $h/d$  é muito variável dentro e entre os estratos. Os pontos verdes representam o estrato 6 (plantio 2002) e os azuis o estrato 2 (plantio 1995). É possível visualizar que um mesmo diâmetro possui diferentes alturas, o que pode prejudicar o ajuste dos modelos. Por exemplo, o dap 20 cm, apresenta alturas entre 5 m e 25 m, o que resulta em um desvio padrão de 3,7 m em relação à média.

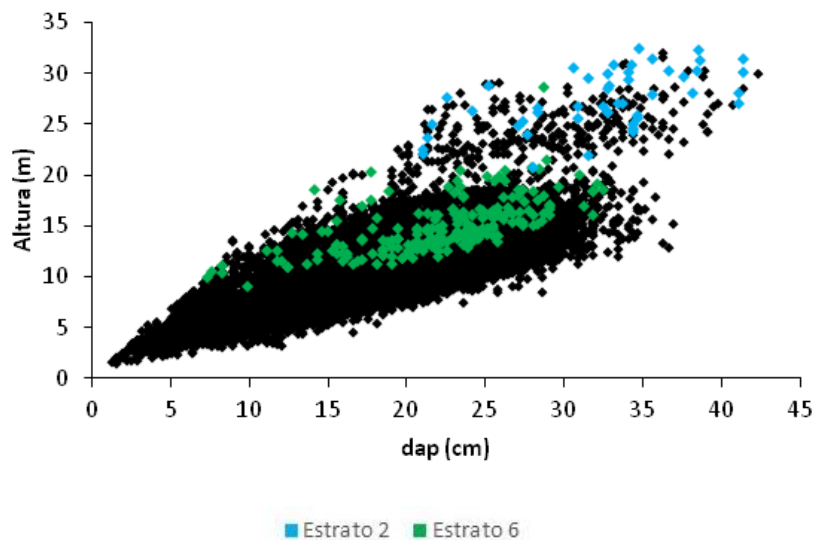


FIGURA 9-RELAÇÃO  $h/d$  CONSIDERANDO DIFERENTES ESTRATOS PARA OS DADOS DE ESTUDO.

Quando são utilizados os métodos tradicionais de regressão e os modelos são estratificados conforme as características do povoamento, dependendo do porte da empresa e extensão dos plantios, dezenas de estratos e equações podem ser gerados. Além do ajuste dos modelos, a aplicação dos mesmos ocorre de forma demorada e também pode gerar abertura ao erro humano, como aplicar o modelo errado em algum estrato.

Neste estudo foi observada a facilidade de treinamento e aplicação das RNA, pois uma única rede é capaz de estimar as alturas para toda a base de dados, diminuindo o tempo de ajuste e aplicação das RNA.

Segundo Barros (2002), a aplicação de equações genéricas que permitam estimativas para um conjunto de dados originados de povoamentos florestais com características silviculturais diferentes deve ser testada, pois permite diminuir o custo

de processamento eliminando o trabalho de ajuste e a seleção de equações mais adequadas para cada unidade amostral.

### 3.1 AJUSTE DOS MODELOS DE REGRESSÃO: ESTIMAÇÃO DA ALTURA

Nas análises estatísticas, os modelos de regressão 1 e 2, que relacionam a variável dependente altura com o diâmetro, apresentaram, em geral, estatísticas inferiores quando comparados aos modelos que relacionam a altura com as variáveis independentes diâmetro e idade. Para os modelos 1 e 2 foram gerados coeficientes de determinação ajustado ( $R^2$  ajust) de no máximo 0,7% e erro padrão da estimativa (Syx%), variando entre 8% e 20%. Como os ajustes apresentaram estatísticas pouco satisfatórias, tiveram como consequência as piores notas em viés (V), média das diferenças absolutas (MD) e desvio padrão das diferenças (DPD) (TABELA 5). Os parâmetros para cada modelo e estrato são apresentados no Apêndice 1.

O melhor desempenho dos modelos que envolvem idade e diâmetro ocorre pelo fato da estratificação ter sido realizada por ano de plantio, ou seja, em um mesmo ano de plantio existem inúmeras remedições, gerando uma alta variabilidade na relação d/h. A idade serve com um estabilizador das curvas, tornando as estimativas da altura mais homogêneas.

Bartoszeck *et al.* (2002), em trabalho com bracatingais no estado do Paraná também destacaram a inferioridade do modelo de Curtis (1967) (modelo 1) que utiliza apenas a variável diâmetro quando ajustado em nível de povoamento. No trabalho de Guimarães *et al.* (2009) em plantios de *Eucalyptus* sp. foi observado que a utilização do material genético e idade nos modelos hipsométricos gerou estimativas melhores do que nos modelos que utilizaram apenas a variável dap.

Os modelos 3 e 4, apresentaram coeficientes de determinação de no mínimo 72%, chegando a 93% no estrato 4. Já o erro padrão da estimativa variou entre 4% e 12%. Nas análises estatísticas complementares esses modelos apresentaram as melhores notas, sendo selecionados para a etapa de validação.



TABELA 5- ANÁLISES ESTATÍSTICAS DOS MODELOS HIPNOMÉTRICOS. Continua...

Estrato	Modelo	R <sup>2</sup> ajust	Syx%	V	MD	DPD	Notas	Classificação
1	1	0,58	9%	(1)-0,01	(3) 1,71	(3) 2,17	7	3
	2	0,54	9%	(3)-0,01	(4) 1,80	(4) 2,27	11	4
	<b>3</b>	<b>0,76</b>	<b>7%</b>	<b>(2)-0,01</b>	<b>(1) 1,26</b>	<b>(1) 1,63</b>	<b>4</b>	<b>1</b>
	<b>4</b>	<b>0,72</b>	<b>7%</b>	<b>(4)-0,01</b>	<b>(2) 1,40</b>	<b>(2) 1,77</b>	<b>8</b>	<b>2</b>
2	1	0,35	9%	(4) 0,10	(4) 1,96	(4) 2,39	12	4
	2	0,35	7%	(3) 0,03	(3) 1,93	(3) 2,38	9	3
	<b>3</b>	<b>0,86</b>	<b>4%</b>	<b>(1)-0,00</b>	<b>(1) 0,78</b>	<b>(1) 1,08</b>	<b>3</b>	<b>1</b>
	<b>4</b>	<b>0,87</b>	<b>4%</b>	<b>(2)-0,00</b>	<b>(2) 1,12</b>	<b>(2) 1,12</b>	<b>6</b>	<b>2</b>
3	1	0,67	7%	(4)-0,03	(4) 1,54	(3) 1,54	11	4
	2	0,64	6%	(3)-0,04	(3) 1,26	(4) 1,62	10	3
	<b>3</b>	<b>0,87</b>	<b>5%</b>	<b>(1)-0,00</b>	<b>(1) 0,93</b>	<b>(1) 1,18</b>	<b>3</b>	<b>1</b>
	<b>4</b>	<b>0,77</b>	<b>6%</b>	<b>(2)-0,01</b>	<b>(2) 1,04</b>	<b>(2) 1,30</b>	<b>6</b>	<b>2</b>
4	1	0,45	9%	(3)-0,01	(4) 1,50	(4) 1,78	11	4
	2	0,45	8%	(4) 0,02	(3) 1,49	(3) 1,77	10	3
	<b>3</b>	<b>0,93</b>	<b>3%</b>	<b>(1)-0,00</b>	<b>(1) 0,51</b>	<b>(1) 0,66</b>	<b>3</b>	<b>1</b>
	<b>4</b>	<b>0,91</b>	<b>4%</b>	<b>(2)-0,00</b>	<b>(2) 0,57</b>	<b>(2) 0,70</b>	<b>6</b>	<b>2</b>
5	1	0,60	12%	(2) 0,00	(4) 1,31	(4) 1,68	10	4
	2	0,66	12%	(3)-0,01	(3) 1,27	(3) 1,62	9	3
	<b>3</b>	<b>0,86</b>	<b>7%</b>	<b>(1)-0,00</b>	<b>(1) 0,80</b>	<b>(1) 1,01</b>	<b>3</b>	<b>1</b>
	<b>4</b>	<b>0,84</b>	<b>8%</b>	<b>(4)-0,01</b>	<b>(2) 0,87</b>	<b>(2) 1,08</b>	<b>8</b>	<b>2</b>
6	1	0,33	14%	(4) 0,09	(4) 1,59	(4) 2,12	12	4
	2	0,40	14%	(3) 0,06	(3) 1,23	(3) 1,84	9	3
	<b>3</b>	<b>0,70</b>	<b>10%</b>	<b>(2) 0,01</b>	<b>(2) 1,03</b>	<b>(2) 1,42</b>	<b>6</b>	<b>2</b>
	<b>4</b>	<b>0,71</b>	<b>10%</b>	<b>(1) 0,00</b>	<b>(1) 0,99</b>	<b>(1) 1,40</b>	<b>3</b>	<b>1</b>
7	1	0,51	17%	(3) 0,04	(4) 1,58	(4) 1,99	11	4
	2	0,49	17%	(4) 0,16	(3) 1,48	(3) 1,90	10	3
	<b>3</b>	<b>0,78</b>	<b>12%</b>	<b>(1) 0,00</b>	<b>(1) 1,04</b>	<b>(1) 1,33</b>	<b>3</b>	<b>1</b>
	<b>4</b>	<b>0,77</b>	<b>12%</b>	<b>(2)-0,01</b>	<b>(2) 1,04</b>	<b>(2) 1,34</b>	<b>6</b>	<b>2</b>
8	1	0,50	20%	(4) 0,26	(4) 1,71	(4) 2,09	12	4
	2	0,67	17%	(1) 0,00	(3) 1,42	(3) 1,79	7	3
	<b>3</b>	<b>0,81</b>	<b>12%</b>	<b>(2) 0,01</b>	<b>(2) 1,01</b>	<b>(2) 1,29</b>	<b>6</b>	<b>2</b>
	<b>4</b>	<b>0,81</b>	<b>12%</b>	<b>(3)-0,01</b>	<b>(1) 0,99</b>	<b>(1) 1,28</b>	<b>5</b>	<b>1</b>

TABELA 5. ANÁLISES ESTATÍSTICAS DOS MODELOS HIPSOMÉTRICOS. Continuação

Estrato	Modelo	R <sup>2</sup> ajust	Syx%	V	MD	DPD	Notas	Classificação
9	1	0,58	20%	(4) 0,04	(4) 1,56	(4) 1,97	12	3
	2	0,70	18%	(1) 0,01	(3) 1,33	(3) 1,71	7	2
	<b>3</b>	<b>0,82</b>	<b>13%</b>	<b>(3) 0,01</b>	<b>(2) 1,02</b>	<b>(2) 1,30</b>	<b>7</b>	<b>2</b>
	<b>4</b>	<b>0,83</b>	<b>13%</b>	<b>(2)-0,01</b>	<b>(1) 1,00</b>	<b>(1) 1,27</b>	<b>4</b>	<b>1</b>
10	1	0,42	17%	(4) 0,02	(4) 1,41	(4) 1,75	12	4
	2	0,43	16%	(3)-0,02	(3) 1,27	(3) 1,60	9	3
	<b>3</b>	<b>0,70</b>	<b>12%</b>	<b>(2) 0,01</b>	<b>(2) 1,00</b>	<b>(2) 1,26</b>	<b>6</b>	<b>2</b>
	<b>4</b>	<b>0,72</b>	<b>12%</b>	<b>(1)-0,01</b>	<b>(1) 0,96</b>	<b>(1) 1,23</b>	<b>3</b>	<b>1</b>
11	1	0,47	20%	(4) 0,28	(4) 2,23	(4) 2,86	12	4
	2	0,60	18%	(1) 0,06	(1) 1,19	(1) 2,10	3	1
	<b>3</b>	<b>0,73</b>	<b>11%</b>	<b>(3) 0,13</b>	<b>(2) 1,41</b>	<b>(2) 2,35</b>	<b>7</b>	<b>2</b>
	<b>4</b>	<b>0,75</b>	<b>11%</b>	<b>(2) 0,10</b>	<b>(3) 1,49</b>	<b>(3) 2,46</b>	<b>8</b>	<b>3</b>

Nota 1: As classificações para cada estatística complementar estão apresentadas entre parênteses.

Nota 2: Os modelos selecionados estão apresentados em negrito

Nota 3: Na coluna "Nota" está o somatório das notas de V, MD e DPD

Na análise gráfica de resíduos observa-se uma tendência em superestimar a altura das árvores menores e subestimar a das árvores maiores. Essas características são ainda mais visíveis nos modelos que apresentam como variável independente apenas o dap.

As subestimativas e superestimativas também são bem visíveis nos estratos que possuem alta variabilidade em altura, como os estratos 7, 8 e 9 (FIGURA 10). Isso pode ser explicado pelo fato de as árvores mensuradas possuírem alturas diferentes para um mesmo diâmetro, fazendo com que o modelo estime para um determinado diâmetro uma altura mais próxima daquela mais frequente nas medições. Os gráficos de dispersão de resíduos estão apresentados do Apêndice 3.

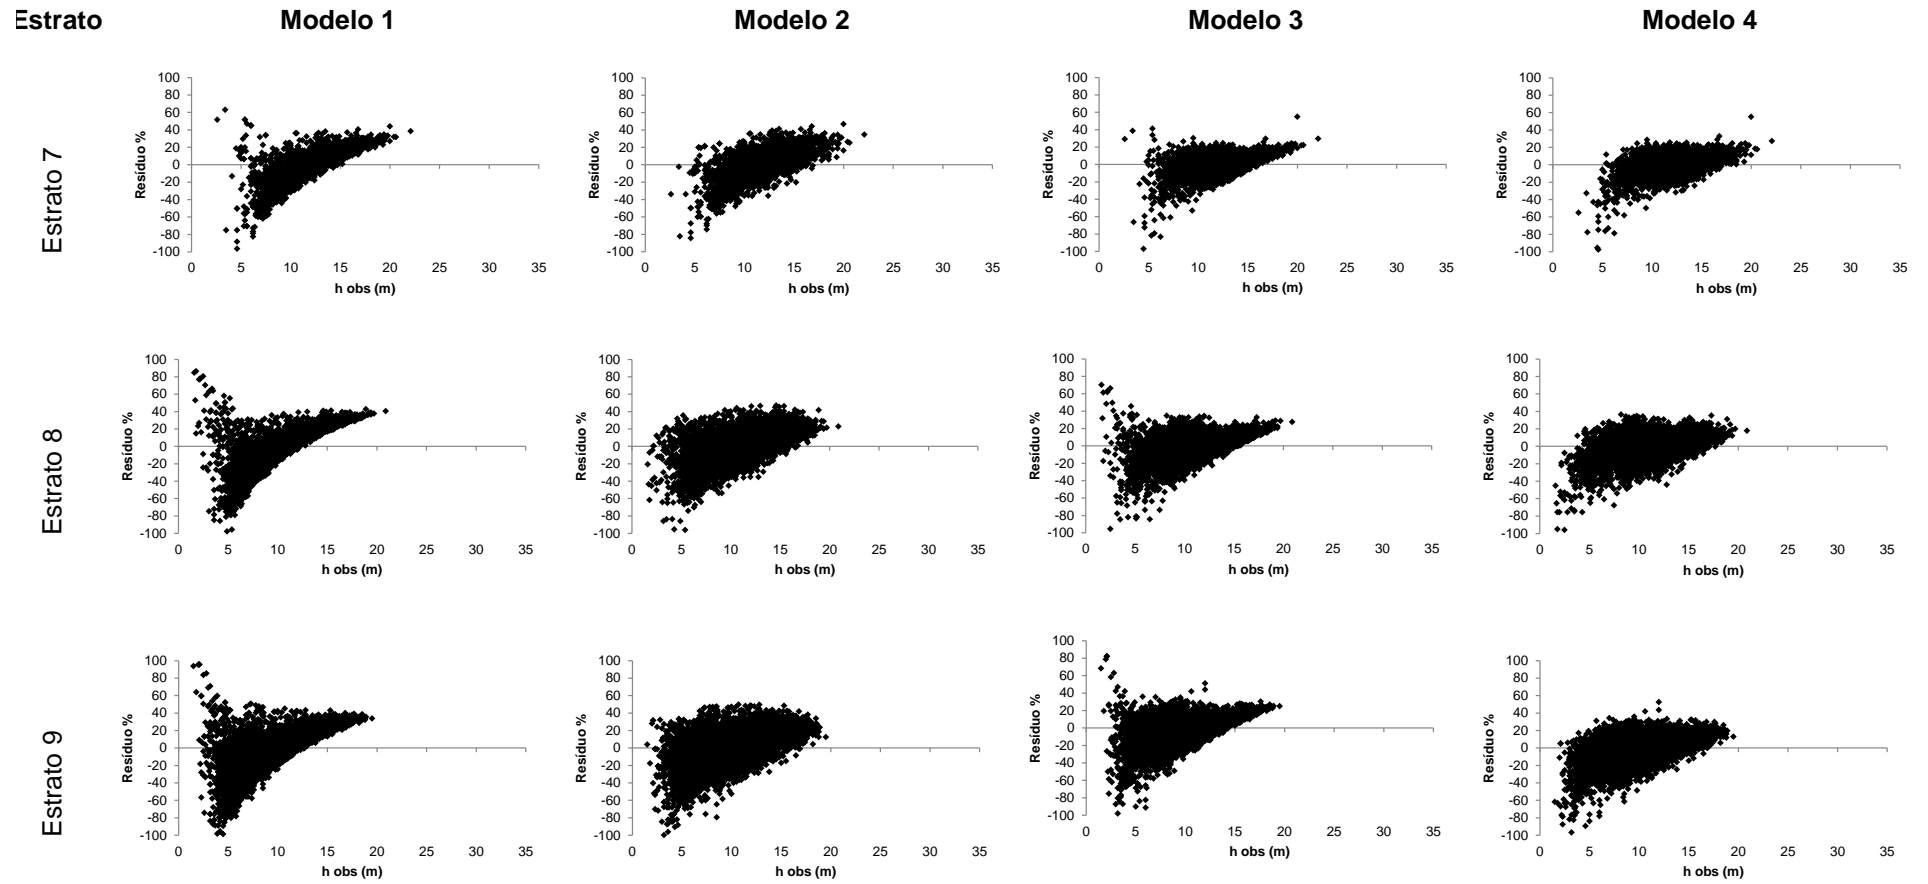


FIGURA 10 - GRÁFICOS DE DISPERSÃO DE RESÍDUOS DO AJUSTE DE MODELOS DE REGRESSÃO PARA OS ESTRATOS 7, 8 E 9

### 3.2 APLICAÇÃO DOS MODELOS DE REGRESSÃO NOS DADOS DE VALIDAÇÃO- ESTIMAÇÃO DA ALTURA

Na TABELA 6 são apresentadas as estatísticas para estimativa de altura nos dados de validação quando os dois melhores modelos ajustados (modelos 3 e 4) foram aplicados. É possível observar que as estatísticas são muito próximas e o erro padrão da estimativa tende a aumentar com o aumento do estrato, variando de 6,95% no estrato 1 e chegando a 13,46% no estrato 11. Também vale destacar os valores de Syx% de aproximadamente 4,0% para o estrato 4 que, embora possua a menor amostragem, ainda é mantem representativa.

O modelo selecionado (em negrito para cada estrato) foi comparado com a melhor rede e os resultados são apresentados no item 3.5 deste capítulo. Os gráficos de dispersão dos resíduos para os dados de validação estão apresentados no Apêndice 4.

TABELA 6- ESTATÍSTICAS E ESTATÍSTICAS COMPLEMENTARES PARA ESTIMAÇÃO DE ALTURA DOS DADOS DE VALIDAÇÃO- APLICAÇÃO DOS MODELOS 3 E 4

Estrato	Modelo	Estatísticas		Estatísticas Complementares			Nota	Classificação
		R <sup>2</sup> ajust	Syx	V	MD	DPD		
1	3	<b>0,85</b>	<b>6,95%</b>	<b>(2) -0,261</b>	<b>(1) 1,231</b>	<b>(1) 1,654</b>	4	1
	4	0,84	7,22%	(1) -0,248	(2) 1,295	(2) 1,723	5	2
2	3	<b>0,82</b>	<b>6,31%</b>	<b>(1) -0,295</b>	<b>(1) 1,201</b>	<b>(1) 1,639</b>	3	1
	4	0,82	6,49%	(2) -0,303	(2) 1,274	(2) 1,687	6	2
3	3	<b>0,88</b>	<b>5,94%</b>	<b>(2) -0,243</b>	<b>(1) 1,074</b>	<b>(1) 1,311</b>	4	1
	4	0,85	6,13%	(1) -0,215	(2) 1,142	(2) 1,377	5	2
4	3	0,95	4,62%	(2) -0,466	(2) 0,681	(2) 0,709	6	2
	4	<b>0,95</b>	<b>4,57%</b>	<b>(1) -0,456</b>	<b>(1) 0,673</b>	<b>(1) 0,705</b>	3	1
5	3	<b>0,91</b>	<b>8,51%</b>	<b>(1) -0,106</b>	<b>(1) 0,894</b>	<b>(1) 1,158</b>	3	1
	4	0,90	9,11%	(2) -0,118	(2) 0,965	(2) 1,239	6	2
6	3	0,86	8,57%	(2) 0,036	(2) 1,052	(2) 1,303	6	2
	4	<b>0,86</b>	<b>8,25%</b>	<b>(1) 0,024</b>	<b>(1) 0,993</b>	<b>(1) 1,263</b>	3	1
7	3	<b>0,89</b>	<b>11,10%</b>	<b>(2) 0,069</b>	<b>(1) 1,044</b>	<b>(1) 1,304</b>	4	1
	4	0,89	11,27%	(1) 0,028	(2) 1,060	(2) 1,326	5	2
8	3	0,90	12,52%	(2) 0,027	(2) 1,020	(2) 1,310	6	2
	4	<b>0,91</b>	<b>12,26%</b>	<b>(1) 0,014</b>	<b>(1) 1,001</b>	<b>(1) 1,282</b>	3	1
9	3	0,91	13,34%	(1) -0,000	(2) 1,012	(2) 1,294	5	2
	4	<b>0,91</b>	<b>13,21%</b>	<b>(2) -0,039</b>	<b>(1) 1,003</b>	<b>(1) 1,281</b>	4	1
10	3	0,84	12,74%	(1) 0,009	(2) 1,004	(2) 1,285	5	2
	4	<b>0,85</b>	<b>12,22%</b>	<b>(2) -0,010</b>	<b>(1) 0,963</b>	<b>(1) 1,232</b>	4	1
11	3	<b>0,88</b>	<b>13,46%</b>	<b>(1) 0,273</b>	<b>(1) 2,454</b>	<b>(1) 3,083</b>	3	1
	4	0,88	13,11%	(2) 0,290	(2) 2,556	(2) 3,180	6	2

### 3.3 TREINAMENTO DAS REDES NEURAS ARTIFICIAIS: DADOS DE AJUSTE

Foram selecionadas 60 redes neurais, 9 lineares, 25 RBF, 21 MLP com 3 camadas intermediárias e 5 MLP com 4 camadas intermediárias. Essas redes foram nomeadas, Rede 1, Rede 2, ..., Rede 60. Dessas, 20 redes com maior coeficiente de correlação (R) foram selecionadas, sendo calculadas as estatísticas e complementares (TABELA 7). As redes 21, 23, 55 e 57, além de apresentar os maiores coeficientes de correlação e menores erros, tiveram as melhores notas nas estatísticas complementares, sendo selecionadas para a etapa de validação com restante dos dados.

TABELA 7- ANÁLISES ESTATÍSTICAS DAS REDES NEURAS SELECIONADAS

Redes	R	Syx%	V	MD	DPD	Nota	Classificação
3	0,91	16%	(10) 0,14	(9) 1,08	(10) 1,39	29	7
5	0,91	19%	(20)-0,74	(19) 1,25	(18) 1,46	57	17
10	0,91	17%	(1)-0,01	(17) 1,15	(19) 1,49	37	10
20	0,91	18%	(19)-0,50	(20) 1,25	(20) 1,50	59	18
<b>21</b>	<b>0,92</b>	<b>15%</b>	<b>(5) 0,08</b>	<b>(1) 1,01</b>	<b>(1) 1,31</b>	<b>7</b>	<b>1</b>
22	0,92	15%	(8)-0,12	(3) 1,03	(3) 1,31	14	4
<b>23</b>	<b>0,92</b>	<b>15%</b>	<b>(2)-0,03</b>	<b>(5) 1,04</b>	<b>(6) 1,35</b>	<b>13</b>	<b>3</b>
24	0,92	15%	(7)-0,11	(6) 1,05	(5) 1,34	18	5
25	0,91	16%	(13)-0,22	(11) 1,11	(14) 1,41	38	11
26	0,91	16%	(14)-0,24	(12) 1,11	(13) 1,41	39	12
29	0,91	17%	(18)-0,50	(18) 1,16	(12) 1,41	48	15
42	0,91	16%	(3)-0,03	(13) 1,12	(17) 1,43	33	9
47	0,92	16%	(9)-0,12	(8) 1,06	(8) 1,36	25	6
51	0,92	16%	(12)-0,20	(10) 1,09	(9) 1,38	31	8
52	0,91	16%	(15)-0,25	(14) 1,12	(15) 1,42	44	14
53	0,91	17%	(17)-0,32	(16) 1,15	(16) 1,42	49	16
54	0,92	16%	(11)-0,16	(7) 1,07	(7) 1,35	25	6
<b>55</b>	<b>0,92</b>	<b>15%</b>	<b>(4)-0,04</b>	<b>(2) 1,02</b>	<b>(2) 1,31</b>	<b>8</b>	<b>2</b>
56	0,92	16%	(16)-0,30	(15) 1,13	(11) 1,40	42	13
<b>57</b>	<b>0,92</b>	<b>15%</b>	<b>(6) 0,11</b>	<b>(4) 1,04</b>	<b>(4) 1,32</b>	<b>14</b>	<b>4</b>

Nota 1: As classificações para cada estatística complementar estão apresentadas entre parênteses.

Nota 2: As redes selecionadas estão apresentadas em negrito

Na FIGURA 11 é possível observar que as redes 21, 23, 55 e 57, apesar de apresentarem as características de sub e superestimação, foram as que apresentarem menores tendências ao longo de todas as classes de altura. Essas redes são do tipo MLP, onde apenas a de número 23 apresenta quatro camadas

intermediárias, enquanto as demais possuem 3 camadas intermediárias. Além disso, as quatro redes possuem 2 variáveis na camada de entrada e diferentes números de neurônios nas camadas intermediárias. Os gráficos de dispersão de resíduos para estimação da altura por meio de RNA estão apresentados no Apêndice 5.

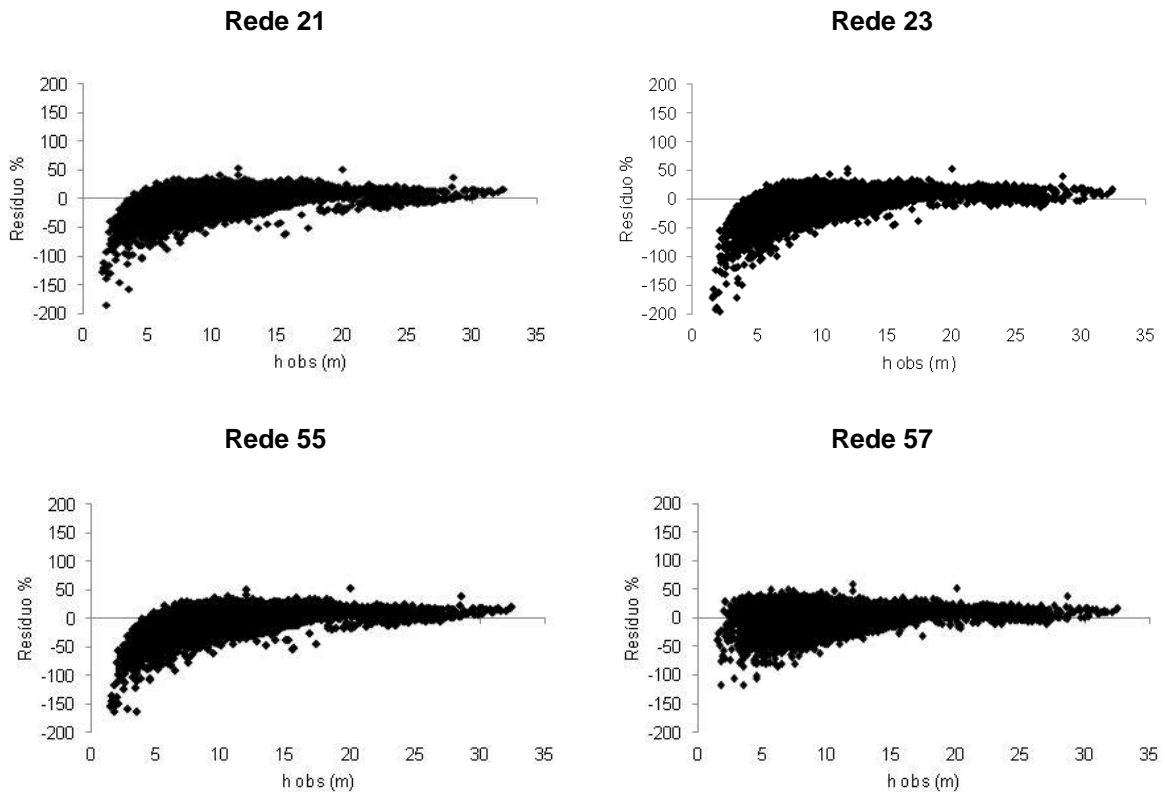


FIGURA 11- GRÁFICOS DE DISTRIBUIÇÃO DE RESÍDUOS PARA PARTE DAS REDES TREINADAS E ANALISADAS

### 3.4 VALIDAÇÃO DAS REDES NEURAIS ARTIFICIAIS PARA ESTIMAÇÃO DE ALTURA

As redes 21, 23, 55 e 57 quando aplicadas na base de dados total de validação apresentaram comportamentos e resultados estatísticos muito similares. Neste caso, a utilização de estatísticas complementares e a análise gráfica de resíduos foram fundamentais para a escolha das redes a serem aplicadas nos dados de validação estratificados.

Por meio das notas atribuídas para as estatísticas complementares viés (V), média das diferenças absolutas (MD) e desvio padrão das diferenças (DPD) a rede 21, apresentou a melhor classificação (TABELA 8).

TABELA 8 - ESTATÍSTICAS DAS REDES NEURAIS SELECIONADAS APLICADAS AOS DADOS DE VALIDAÇÃO TOTAL

Redes	Arquitetura	Estatísticas		Estatísticas complementares			Nota	Classificação
		R <sup>2</sup> ajust	Syx%	V	MD	DPD		
21	MLP 2:2-2-1:1	<b>0,93</b>	<b>12,41%</b>	<b>(3) 0,07</b>	<b>(1) 1,011</b>	<b>(1) 1,299</b>	<b>5</b>	<b>1</b>
23	MLP 2:2-27-27-1:1	0,92	12,84%	(1) -0,03	(4) 1,043	(4) 1,346	9	3
55	MLP 2:2-10-1:1	0,93	12,42%	(2) - 0,05	(2) 1,014	(2) 1,302	6	2
57	MLP 2:2-41-1:1	0,92	12,58%	(4) 0,11	(3) 1,037	(3) 1,314	10	4

### 3.5 COMPARAÇÕES ENTRE AS ESTIMATIVAS POR REGRESSÃO E RNA

Ao aplicar o modelo de regressão com as melhores estatísticas e a RNA com melhor desempenho no banco de dados de validação por estrato, ambos apresentaram comportamentos similares, com algumas exceções. Foi observado um comportamento superior dos modelos de regressão nos estratos 2 e 3, o que pode ser explicado pelo reduzido número de observações nesses estratos, pois como o treinamento das redes foi realizado com o banco de dados total, esses dois estratos não foram tão representativos como os demais, proporcionando desempenho inferior nesse método em relação à regressão. Já no método de regressão os modelos foram ajustados com os dados dos estratos separadamente, fato que pode explicar as melhores estimativas (TABELA 9).

Apesar da RNA gerar estatísticas próximas às da regressão com a aplicação de uma única rede para todos os estratos, o que pode parecer prático e desejável, o tempo de treinamento da RNA é mais longo, enquanto a organização dos dados, estratificação, ajuste dos modelos regressão, aplicação nos dados de validação para todos os estratos é realizado de forma prática e rápida pelo software Statistica 7.0. Para as duas análises foi utilizado um computador Intel Core i3 com memória RAM de 3gb.

De forma prática, na dinâmica de empresas de grande porte, as informações de inventários florestais contínuos chegam diariamente e os dados devem ser importados e processados rapidamente para gerar informações que subsidiam os processos de colheita, silvicultura e/ou investidores. De posse de uma base de dados rica, como a do presente estudo, é possível gerar modelos de regressão estratificados que podem ser utilizados e reajustados anualmente com a incorporação de novos estratos, materiais genéticos, sítios etc. Enquanto a RNA aplicada hoje nas empresas, deve ser treinada para cada nova massa de dados,

fora do banco de dados e depois das alturas estimadas, as informações são importadas para o banco de dados. A longo prazo, a aplicação de RNA fora do banco de dados não é sustentável, podendo ter o mesmo risco de erro humano no cadastro de parâmetros nos modelos de regressão, além da falta de controle das RNA utilizadas. Por isso, para a estimativa de altura utilizando os mesmos dados de entrada para a RNA e modelos de regressão, recomenda-se a utilização dos métodos tradicionais de regressão de forma estratificada.

Castro (2011) verificou eficiência de redes neurais do tipo MLP para projeção do diâmetro e altura de árvores em florestas comerciais de eucalipto da região norte do Brasil. As melhores redes apresentaram valores de R superiores a 0,98 e raiz quadrada do erro médio (RQEM) inferiores a 1% no treinamento. Após a validação do seu modelo, foram encontradas estimativas com R superior a 0,90 e RQEM inferiores a 2% para as duas variáveis.

Binoti (2010) obteve valores de R superiores a 0,98 e RQEM inferiores a 4% no treinamento de redes neurais *Perceptron* (Linear), MLP e RBF para diâmetro e altura de eucaliptos em diferentes condições de crescimento, sem o uso de índices de competição como variáveis entrada. Após aplicação das redes aos dados de generalização, foram observados valores superiores a 0,97 de R e RQEM inferiores a 5% para ambas as variáveis.

TABELA 9 - ESTATÍSTICAS PARA A COMPARAÇÃO ENTRE OS MODELOS DE REGRESSÃO E REDES NEURAIIS. Continua...

Estrato	Redes	R <sup>2</sup> ajust	Syx%	V	MD	DPD	Notas	Classificação
1	rede 21	0,73	9,7%	(2)- 0,87	(2) 1,70	(2) 2,22	6	2
	<b>modelo 3</b>	<b>0,85</b>	<b>6,9%</b>	<b>(1)-0,26</b>	<b>(1) 1,23</b>	<b>(1) 1,65</b>	<b>3</b>	<b>1</b>
2	rede 21	0,81	11,0%	(2) 2,30	(2) 2,47	(2) 1,88	6	2
	<b>modelo 3</b>	<b>0,82</b>	<b>6,3%</b>	<b>(1)- 0,29</b>	<b>(1) 1,20</b>	<b>(1) 1,64</b>	<b>3</b>	<b>1</b>
3	rede 21	0,79	14,1%	(2) 2,80	(2) 2,91	(2) 1,61	6	2
	<b>modelo 3</b>	0,88	<b>5,9%</b>	<b>(1)-0,24</b>	<b>(1) 1,07</b>	<b>(1) 1,31</b>	<b>3</b>	<b>1</b>
4	<b>rede 21</b>	<b>0,92</b>	<b>4,4%</b>	<b>(1) 0,29</b>	<b>(1) 0,66</b>	<b>(2) 0,87</b>	<b>4</b>	<b>1</b>
	modelo 4	0,95	4,6%	(2)-0,46	(2) 0,67	(1) 0,70	5	2
5	rede 21	0,90	9,3%	(2) 0,29	(2) 1,00	(2) 1,25	6	2
	<b>modelo 3</b>	<b>0,91</b>	<b>8,5%</b>	<b>(1)- 0,11</b>	<b>(1) 0,89</b>	<b>(1) 1,16</b>	<b>3</b>	<b>1</b>
6	rede 21	0,87	10,6%	(2) 1,08	(2) 1,22	(1) 1,21	5	2
	<b>modelo 4</b>	<b>0,86</b>	<b>8,3%</b>	<b>(1) 0,02</b>	<b>(1) 0,99</b>	<b>(2) 1,26</b>	<b>4</b>	<b>1</b>
7	<b>rede 21</b>	<b>0,90</b>	<b>11,1%</b>	<b>(2)- 0,23</b>	<b>(2) 1,05</b>	<b>(1) 1,29</b>	<b>5</b>	<b>1</b>
	modelo 3	0,89	11,1%	(1) 0,07	(1) 1,04	(2) 1,30	4	2



TABELA 9 - ESTATÍSTICAS PARA A COMPARAÇÃO ENTRE OS MODELOS DE REGRESSÃO E REDES NEURAIS. Continuação

Estrato	Redes	R <sup>2</sup> ajust	Syx%	V	MD	DPD	Notas	Classificação
8	rede 21	0,91	12,3%	(2)-0,31	(2) 1,02	(1) 1,25	5	2
	<b>modelo 4</b>	<b>0,91</b>	<b>12,3%</b>	<b>(1) 0,01</b>	<b>(1) 1,00</b>	<b>(2) 1,28</b>	<b>4</b>	<b>1</b>
9	<b>rede 21</b>	<b>0,92</b>	<b>12,8%</b>	<b>(2) 0,28</b>	<b>(1) 0,96</b>	<b>(1) 1,20</b>	<b>4</b>	<b>1</b>
	modelo 4	0,91	13,2%	(1)-0,04	(2) 1,00	(2) 1,28	5	2
10	<b>rede 21</b>	<b>0,85</b>	<b>12,4%</b>	<b>(2) 0,26</b>	<b>(2) 0,98</b>	<b>(1) 1,23</b>	<b>5</b>	<b>2</b>
	modelo 4	0,85	12,2%	(1)-0,01	(1) 0,96	(2) 1,23	4	1
11	<b>rede 21</b>	<b>0,88</b>	<b>14,7%</b>	<b>(2) 0,41</b>	<b>(1) 1,08</b>	<b>(1) 1,39</b>	<b>4</b>	<b>1</b>
	modelo 3	0,88	13,5%	(1) 0,27	(2) 2,45	(2) 3,08	5	2

### 3.6 COMPARAÇÃO DA PERFORMANCE DOS MÉTODOS

A média das alturas estimadas pela RNA diferiu da média das alturas observadas nos estratos 2, 3, 6, 7, 8 e 10. Por outro lado, as médias das alturas estimadas pela regressão foi igual às médias das alturas observadas em todos os estratos (TABELA 10)

TABELA 10 - MÉDIAS POR ESTRATOS DAS ALTURAS OBSERVADAS E ESTIMADAS PELA REGRESSÃO E RNA. VALORES DE F ACOMPANHADOS DE  $P \leq 0,05$  INDICAM SIGNIFICÂNCIA DA ANOVA.

Métodos	Estrato	Estrato	Estrato	Estrato	Estrato	Estrato	Estrato	Estrato	Estrato	Estrato	Estrato
	1	2	3	4	5	6	7	8	9	10	11
	<b>Médias</b>										
H obs	24,28a*	26,44a	22,74a	19,16a	13,44a	15,31a	11,77a	10,45 <sup>a</sup>	9,70a	10,09a	9,82a
H Regressão	24,70a	26,92a	23,15a	19,46a	13,73a	15,36a	11,73a	10,46 <sup>a</sup>	9,73a	10,10a	9,74a
H RNA	25,15a	23,34b	19,94b	20,08a	13,91a	14,23b	12,00b	10,77b	9,42a	9,83b	9,41a
F	2,100	14,960	29,090	0,82	0,87	7,73	3,75	13,08	15,8	9,84	1,34
p	0,125	0,000	0,000	0,4478	0,4209	0,0005	0,0237	0,000	0,000	0,0001	0,2641

\* Médias seguidas pela mesma letra não diferem estatisticamente pelo teste de Tukey a 95% de probabilidade de confiança.

Na TABELA 11 estão apresentadas as análises de correlação entre os três tratamentos. É possível observar que existe forte correlação entre os dados observados e resultados gerados pela RNA e Regressão. Também é possível observar que as estimativas geradas pela regressão, na maioria dos estratos, apresentam maior correlação com os dados observados

TABELA 11- COEFICIENTE DE CORRELAÇÃO ENTRE OS TRÊS TRATAMENTOS

Estrato	Correlação	H obs	H Regressão	H RNA
1	H obs		0,85	0,73
	H regressão	0,85		0,87
	H RNA	0,73	0,87	
2	H obs		0,82	0,83
	H regressão	0,82		0,99
	H RNA	0,83	0,99	
3	H obs		0,88	0,79
	H regressão	0,88		0,92
	H RNA	0,79	0,92	
4	H obs		0,95	0,92
	H regressão	0,95		0,99
	H RNA	0,92	0,99	
5	H obs		0,91	0,90
	H regressão	0,91		0,98
	H RNA	0,90	0,98	
6	H obs		0,86	0,87
	H regressão	0,86		0,99
	H RNA	0,87	0,99	
7	H obs		0,89	0,90
	H regressão	0,89		0,99
	H RNA	0,90	0,99	
8	H obs		0,91	0,91
	H regressão	0,91		0,99
	H RNA	0,91	0,99	
9	H obs		0,91	0,92
	H regressão	0,91		1,00
	H RNA	0,92	1,00	
10	H obs		0,85	0,85
	H regressão	0,85		0,99
	H RNA	0,85	0,99	
11	H obs		0,88	0,88
	H regressão	0,88		0,98
	H RNA	0,88	0,98	

### 3.7 REDUÇÃO DA MEDIÇÃO DE ALTURAS EM 30% E 60%

#### 3.7.1 Redução da medição de alturas por meio de Regressão: Dados de ajuste e validação

Na TABELA 12, é possível observar que os modelos 3 e 4 apresentaram as melhores estatísticas (os parâmetros dos modelos ajustados para cada estrato estão apresentados no Apêndice 2) para estimar a altura em todas as porcentagens de redução. Esses dois modelos se diferenciam dos demais por apresentar a idade e o dap como variáveis independentes. É possível observar, inclusive, uma melhora no ajuste quando reduzidas as medições em 60%.

TABELA 12- ESTATÍSTICAS E ESTATÍSTICAS COMPLEMENTARES PARA ESTIMAR ALTURA PARA 100% DOS DADOS DE AJUSTE E POR MEIO DE REDUÇÃO EM 30%, 60% DA MEDIÇÃO DE ALTURAS

Tipo	Modelo	Estatísticas		Estatísticas Complementares			Notas	Classificação
		R <sup>2</sup> ajust	Syx	V	MD	DPD		
100% dos dados	1	0,66	18,8%	(4) 0,0282	(4) 1,5822	(4) 1,9709	12	4
	2	0,73	16,6%	(1) -0,0049	(3) 1,3726	(3) 1,7472	7	3
	<b>3</b>	<b>0,85</b>	<b>12,3%</b>	<b>(2) 0,0082</b>	<b>(2) 1,0131</b>	<b>(2) 1,2953</b>	<b>6</b>	<b>2</b>
	<b>4</b>	<b>0,86</b>	<b>12,2%</b>	<b>(3) -0,0110</b>	<b>(1) 0,9949</b>	<b>(1) 1,2778</b>	<b>5</b>	<b>1</b>
Redução de 30 %	1	0,66	18,8%	(4) 0,0300	(4) 1,6020	(4) 1,9925	12	4
	2	0,74	16,4%	(2) -0,0036	(3) 1,3697	(3) 1,7438	8	3
	<b>3</b>	<b>0,86</b>	<b>12,2%</b>	<b>(1) 0,0080</b>	<b>(2) 1,0133</b>	<b>(2) 1,2982</b>	<b>5</b>	<b>1</b>
	<b>4</b>	<b>0,86</b>	<b>12,0%</b>	<b>(3) -0,0107</b>	<b>(1) 0,9934</b>	<b>(1) 1,2761</b>	<b>5</b>	<b>1</b>
Redução de 60 %	1	0,66	18,3%	(4) 0,0310	(4) 1,5993	(1) 1,9890	12	4
	2	0,75	15,8%	(1) -0,0002	(3) 1,3504	(3) 1,7208	7	3
	<b>3</b>	<b>0,86</b>	<b>11,9%</b>	<b>(2) 0,0066</b>	<b>(2) 1,0082</b>	<b>(2) 1,2906</b>	<b>6</b>	<b>2</b>
	<b>4</b>	<b>0,86</b>	<b>11,6%</b>	<b>(3) -0,0073</b>	<b>(1) 0,9881</b>	<b>(1) 1,2673</b>	<b>5</b>	<b>1</b>

No gráfico de dispersão de resíduos (FIGURA 12) pode-se verificar que utilizando o modelo 1 para os 3 tipos de redução, existem super e subestimativas para árvores com alturas de até 10 m, seguido de subestimativas para as árvores entre 10 e 15 m e uma melhora do ajuste para árvores com mais de 15 m.

O modelo 2 apresentou as mesmas tendências que o modelo 1, porém nos menores diâmetros tende a superestimar a altura. Os modelos 3 e 4 apresentaram os pontos de dispersão mais próximos do eixo x, mostrando superioridade aos anteriores, porém, com mesmas tendências para os menores e maiores diâmetros e em menor escala. Os gráficos de distribuição dos resíduos estão apresentados no Apêndice 6.

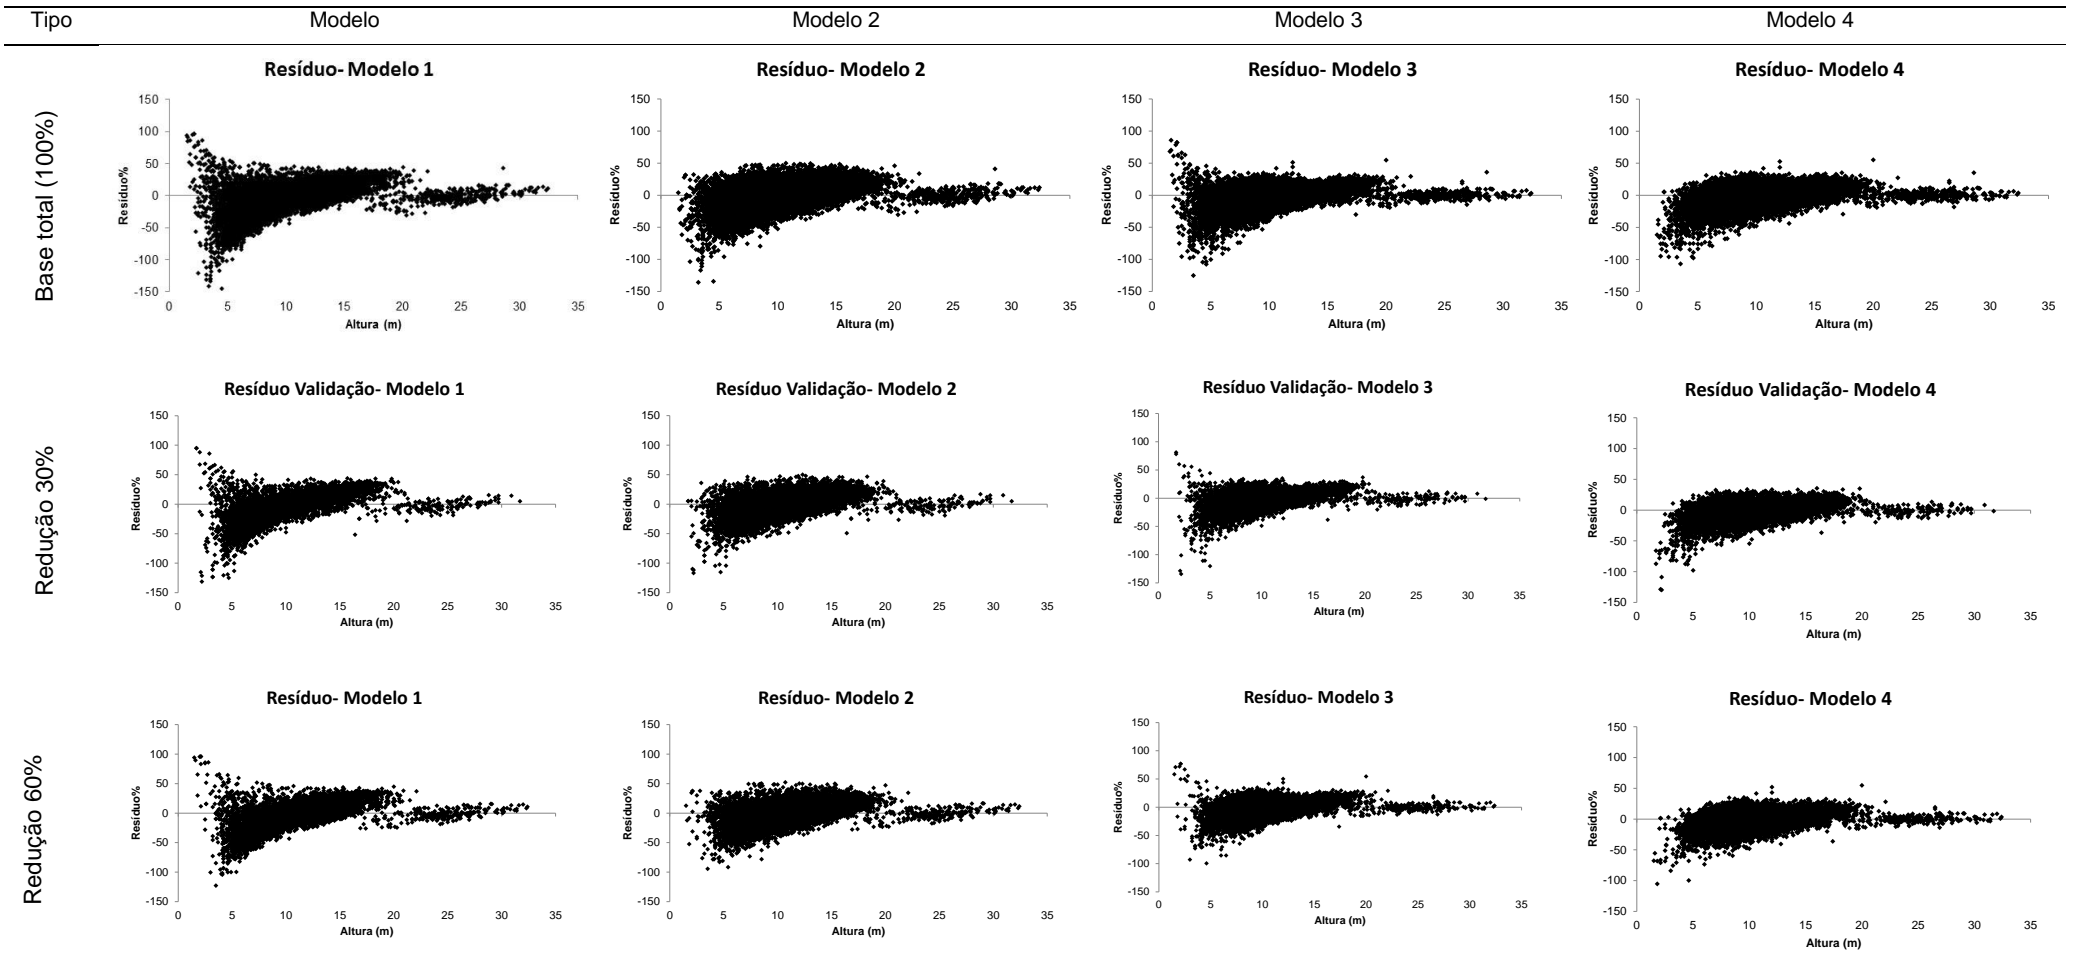


FIGURA 12. GRÁFICOS DE DISPERSÃO DE RESÍDUOS PARA OS DADOS DE AJUSTE 100% E REDUÇÃO EM 30% E 60% DAS ALTURAS MEDIDAS

Na TABELA 13 estão apresentadas as estatísticas para estimação de altura por meio de modelos de regressão ajustado para 100% dos dados, e redução em 30% e 60% das alturas medidas.

É possível observar que nos 4 modelos existe estabilização do erro com a redução das alturas em 30% e 60%, ou seja, é aceitável reduzir o número de medição das alturas em até 60% sem afetar a qualidade do ajuste para os quatro modelos de regressão.

Apesar de haver estabilização em todos os modelos testados, os modelos 3 e 4 apresentaram as melhores estatísticas para estimar a altura para os três conjuntos de bancos de dados: 100% dos dados, redução em 30% e 60%. Na redução em 30%, apesar de as estatísticas complementares apontarem para o modelo 2 como o segundo no ranking, o modelo 3 foi selecionado por apresentar um erro padrão da estimativa menor, 12,42% contra 16,84% do modelo 2, e um coeficiente de correlação ajustado maior, 0,86 para o modelo 3 e 0,74 para o modelo 2.

TABELA 13 - ESTATÍSTICAS PARA APLICAÇÃO DOS MODELOS AJUSTADOS COM 100% DOS DADOS E REDUÇÃO EM 30% E 60% NOS DADOS DE VALIDAÇÃO TOTAL

Tipo	Modelo	Estatísticas		Estatísticas Complementares			Notas	Classificação
		R <sup>2</sup> ajust	Syx	V	MD	DPD		
100% dos dados	1	0,66	18,97%	(4) 0,0258	(4) 1,5925	(4) 1,9890	2	4
	2	0,74	16,82%	(2) -0,0146	(3) 1,3857	(3) 1,7635	8	3
	<b>3</b>	<b>0,86</b>	<b>12,40%</b>	<b>(1) 0,0119</b>	<b>(2) 1,0174</b>	<b>(2) 1,3007</b>	<b>5</b>	<b>2</b>
	<b>4</b>	<b>0,86</b>	<b>12,23%</b>	<b>(3) -0,0147</b>	<b>(1) 1,0040</b>	<b>(1) 1,2820</b>	<b>5</b>	<b>1</b>
Redução de 30 %	1	0,66	18,96%	(2) 0,0167	(4) 1,5917	(4) 1,9879	0	4
	2	0,74	16,84%	(1) 0,0115	(3) 1,3846	(3) 1,7664	7	2
	<b>3</b>	<b>0,86</b>	<b>12,42%</b>	<b>(4) -0,0311</b>	<b>(2) 1,0190</b>	<b>(2) 1,3016</b>	<b>8</b>	<b>3</b>
	<b>4</b>	<b>0,86</b>	<b>12,24%</b>	<b>(3) -0,0269</b>	<b>(1) 1,0047</b>	<b>(1) 1,2836</b>	<b>5</b>	<b>1</b>
Redução de 60 %	1	0,67	18,74%	(2) 0,0269	(4) 1,5701	(4) 1,9648	0	4
	2	0,73	16,93%	(4) 0,1285	(3) 1,3768	(3) 1,7703	0	3
	<b>3</b>	<b>0,86</b>	<b>12,44%</b>	<b>(3) -0,1127</b>	<b>(2) 1,0225</b>	<b>(2) 1,2994</b>	<b>7</b>	<b>2</b>
	<b>4</b>	<b>0,86</b>	<b>12,24%</b>	<b>(1) -0,0234</b>	<b>(1) 1,0033</b>	<b>(1) 1,2828</b>	<b>3</b>	<b>1</b>

Nos gráficos de dispersão de resíduos (FIGURA 13) para os dois melhores modelos (modelo 3 e 4) é possível observar que as tendências não mudam com a redução do número de medições de altura. Os gráficos de dispersão de resíduos e

de frequência de resíduos para os dados de validação com todos os modelos estão apresentados no Apêndice 6.

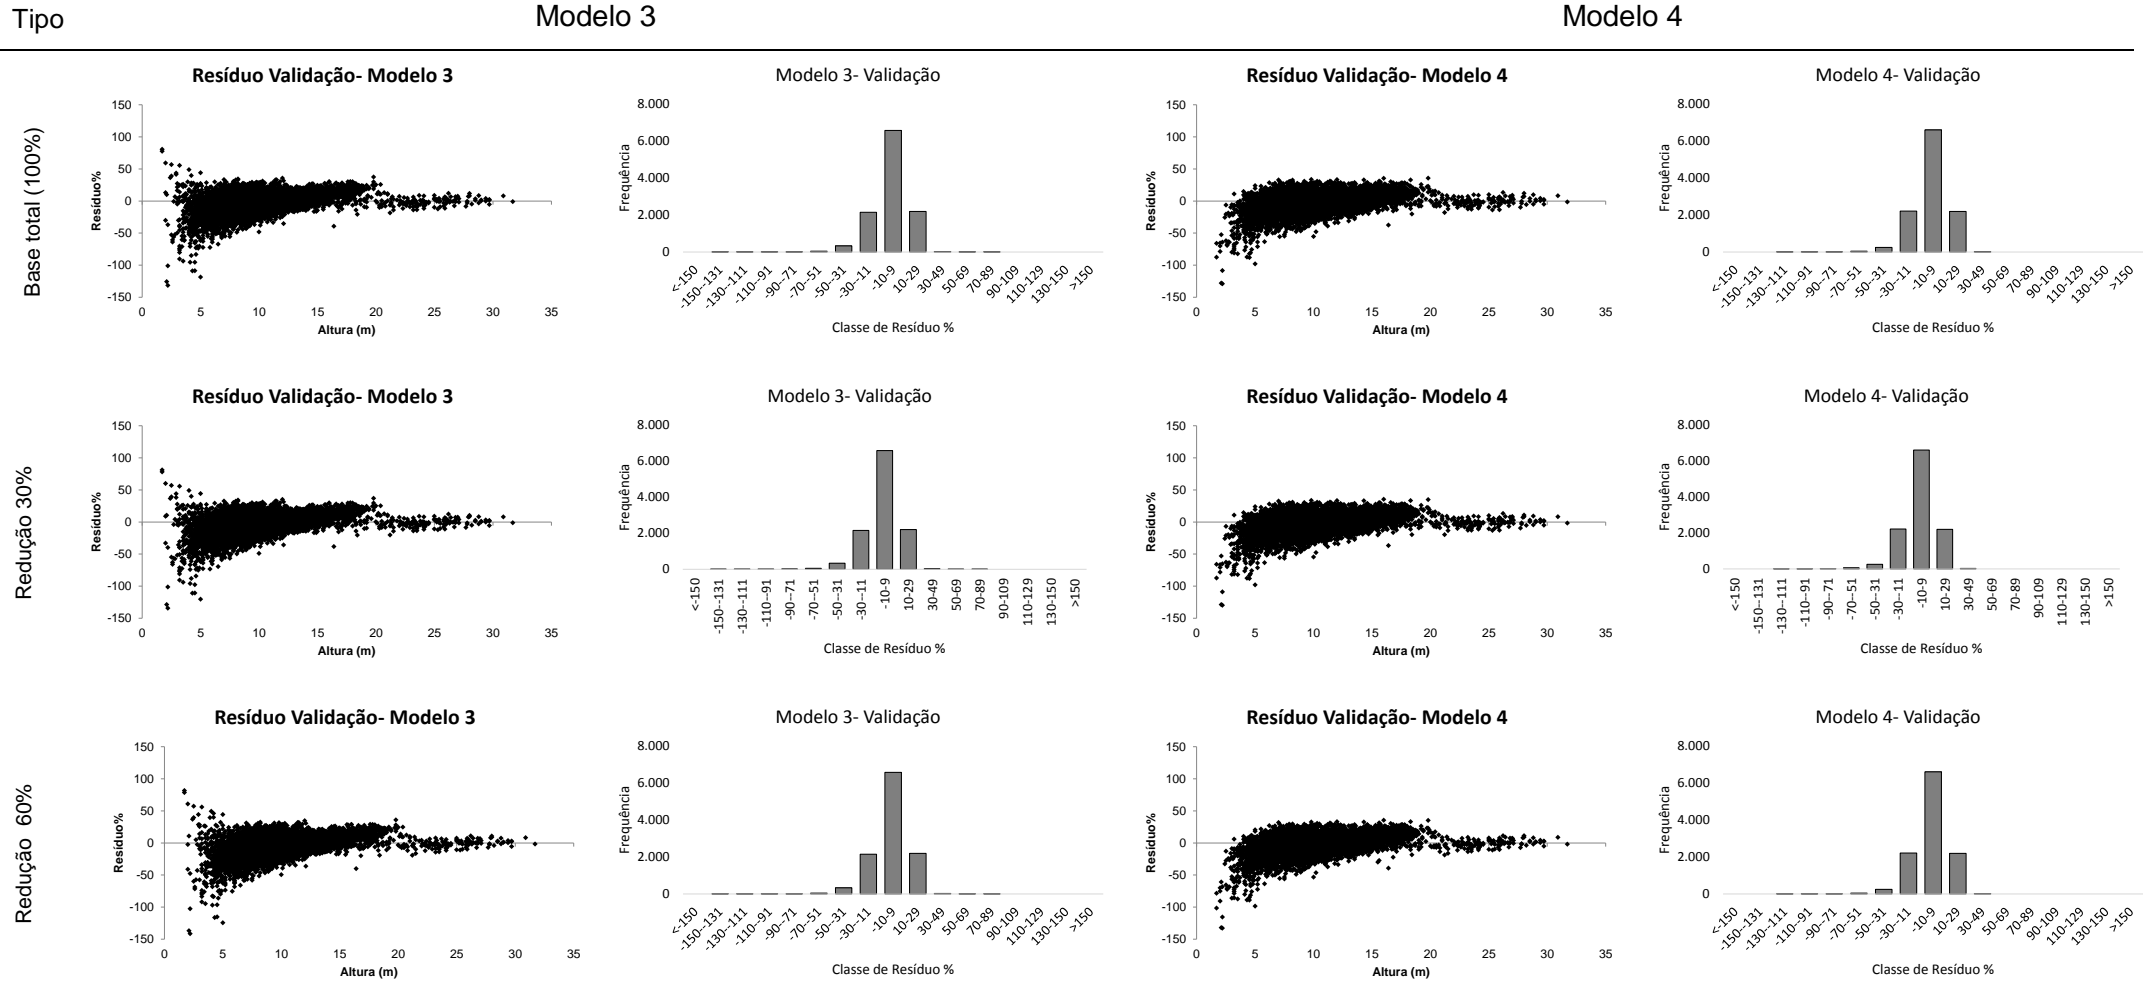


FIGURA 13. GRÁFICOS DE DISPERSÃO DE RESÍDUOS E GRÁFICOS DE FREQUÊNCIA DE RESÍDUOS PARA OS DADOS DE VALIDAÇÃO UTILIZANDO OS MODELOS COM MELHORES ESTATÍSTICAS

### 3.7.2 Redução da medição de alturas por meio de RNA: Dados de ajuste e validação

Assim como citado no item 3.4 deste capítulo, quando utilizada a base de dados total de ajuste (100%) a melhor RNA aplicada aos dados de validação obteve erro de 12,41% (TABELA 14).

TABELA 14 - ESTATÍSTICAS DE AJUSTE E ESTATÍSTICAS COMPLEMENTARES PARA ESTIMAR A ALTURA PARA OS DADOS DE VALIDAÇÃO QUANDO APLICADA A RNA TREINADA COM 100% DOS DADOS

Redes	Estatísticas		Estatísticas complementares			Notas	Classificação
	R <sup>2</sup> ajust	Syx%	V	MD	DPD		
<b>21</b>	<b>0,93</b>	<b>12,41%</b>	<b>(3) 0,07</b>	<b>(1) 1,011</b>	<b>(1) 1,299</b>	<b>5</b>	<b>1</b>
23	0,92	12,84%	(1) -0,03	(4) 1,043	(4) 1,346	9	3
55	0,93	12,42%	(2) - 0,05	(2) 1,014	(2) 1,302	6	2
57	0,92	12,58%	(4) 0,11	(3) 1,037	(3) 1,314	10	4

Para a seleção das melhores RNAs para estimativa da altura reduzindo-se as medições em 30% e 60%, foram selecionadas as 20 RNA com maior coeficiente de correlação para cada tipo de redução (**Erro! Fonte de referência não encontrada.**). Dessas, as quatro com melhores ajustes foram aplicadas aos dados de validação, apresentados na Tabela 15.

TABELA 15 - ESTATÍSTICAS E ESTATÍSTICAS COMPLEMENTARES PARA ESTIMAR A ALTURA COM OS DADOS DE AJUSTE REDUZIDOS EM 30% E 60% RESPECTIVAMENTE. Continua...

Tipo	Rede	Estatísticas		Estatísticas Complementares			Notas	Classificação
		R <sup>2</sup>	Syx%	V	MD	DPD		
Redução de 30 %	15	0,926	12,58%	(5)0,00082	(5)1,00372	(20)1,29705	30	8
	20	0,926	12,56%	(8)0,00172	(10)1,00795	(14)1,29448	32	11
	40	0,926	12,57%	(18)0,00680	(16)1,01046	(15)1,29513	49	15
	43	0,926	12,58%	(19)0,00731	(20)1,01215	(19)1,29621	58	18
	45	0,926	12,57%	(20)0,01307	(17)1,01081	(18)1,29575	55	17
	46	0,926	12,57%	(3)-0,00060	(19)1,01107	(16)1,29518	38	14
	47	0,926	12,57%	(17)-0,00516	(18)1,01083	(17)1,29558	52	16
	48	0,927	12,53%	(13)0,00336	(11)1,00880	(11)1,29116	35	13
	49	0,926	12,54%	(1)0,00024	(15)1,01009	(13)1,29299	29	7
	50	0,927	12,52%	(11)0,00270	(13)1,00992	(7)1,29014	31	9
	51	0,927	12,52%	(16)0,00506	(8)1,00698	(8)1,29017	32	10
	52	0,927	12,52%	(6)-0,00092	(12)1,00920	(10)1,29092	28	6
	53	0,927	12,53%	(7)-0,00143	(14)1,00997	(12)1,29196	33	12
	54	0,927	12,50%	(9)0,00185	(7)1,00489	(6)1,28885	22	4
	55	0,927	12,52%	(14)0,00359	(9)1,00793	(9)1,29042	32	11
	56	0,927	12,48%	(12)0,00272	(6)1,00478	(5)1,28657	23	5
	<b>57</b>	<b>0,928</b>	<b>12,46%</b>	<b>(2)-0,00046</b>	<b>(4)1,00301</b>	<b>(4)1,28402</b>	<b>10</b>	<b>1</b>
	<b>58</b>	<b>0,928</b>	<b>12,45%</b>	<b>(4)0,00079</b>	<b>(3)1,00152</b>	<b>(3)1,28321</b>	<b>10</b>	<b>1</b>
	<b>59</b>	<b>0,928</b>	<b>12,41%</b>	<b>(10)-0,00230</b>	<b>(2)0,99949</b>	<b>(1)1,27904</b>	<b>13</b>	<b>2</b>
	<b>60</b>	<b>0,928</b>	<b>12,42%</b>	<b>(15)0,00493</b>	<b>(1)0,99869</b>	<b>(2)1,28031</b>	<b>18</b>	<b>3</b>



TABELA 15 - ESTATÍSTICAS E ESTATÍSTICAS COMPLEMENTARES PARA ESTIMAR A ALTURA

Tipo	Rede	Estatísticas		Estatísticas Complementares			Notas	Classificação
		R <sup>2</sup> ajust	Syx%	V	MD	DPD		
Redução de 60 %	21	0,927	11,75%	(1)0,00000	0,99551	(20)1,27970	34	13
	22	0,927	11,75%	(1)0,00000	0,99666	(19)1,27876	36	16
	23	0,928	11,74%	(1)-0,00000	0,99737	(18)1,27782	36	16
	24	0,928	11,74%	(1)0,00000	0,99803	(17)1,27778	38	17
	25	0,928	11,73%	(1)-0,00000	0,99746	(16)1,27622	35	15
	26	0,928	11,72%	(1)-0,00000	0,99767	(15)1,27565	35	14
	27	0,928	11,69%	(1)0,00000	0,99629	(14)1,27255	30	12
	28	0,928	11,69%	(1)0,00000	0,99586	(13)1,27229	28	11
	29	0,928	11,69%	(1)0,00000	0,99430	(12)1,27216	23	9
	30	0,928	11,68%	(1)0,00000	0,99518	(11)1,27098	24	10
	31	0,928	11,67%	(1)0,00000	0,99500	(10)1,27033	22	8
	32	0,929	11,66%	(1)-0,00000	0,99280	(9)1,26943	17	7
	33	0,929	11,66%	(1)0,00000	0,99295	(8)1,26861	17	7
	34	0,929	11,65%	(1)0,00000	0,99311	(7)1,26832	17	7
	35	0,929	11,64%	(1)0,00000	0,99165	(6)1,26709	11	5
	36	0,929	11,64%	(1)-0,00000	0,99183	(5)1,26661	12	6
	37	<b>0,929</b>	<b>11,63%</b>	<b>(1)0,00000</b>	<b>0,99164</b>	<b>(4)1,26625</b>	<b>8</b>	<b>4</b>
	38	<b>0,929</b>	<b>11,63%</b>	<b>(1)0,00000</b>	<b>0,99166</b>	<b>(3)1,26621</b>	<b>9</b>	<b>3</b>
	39	<b>0,929</b>	<b>11,63%</b>	<b>(1)0,00000</b>	<b>0,99157</b>	<b>(2)1,26596</b>	<b>5</b>	<b>2</b>
	40	<b>0,929</b>	<b>11,63%</b>	<b>(1)-0,00000</b>	<b>0,99111</b>	<b>(1)1,26567</b>	<b>3</b>	<b>1</b>

COM OS DADOS DE AJUSTE REDUZIDOS EM 30% E 60% RESPECTIVAMENTE. Continua...

Nos gráficos de dispersão dos resíduos é possível observar que nas redes selecionadas para a redução em 30% dos dados, as redes 57 e 59 geraram uma leve superestimativa nas alturas de até 10 m, enquanto nas redes 58 e 60, essa tendência foi observada com menor intensidade. Já na redução em 60% dos dados, em que se esperaria maiores erros nas estimações, nota-se uma boa performance do método. Os gráficos de dispersão dos resíduos para as demais RNAs reduzindo-se 30% e 60% dos dados, estão apresentados nos Apêndices 7 e 8, respectivamente (FIGURA 14).

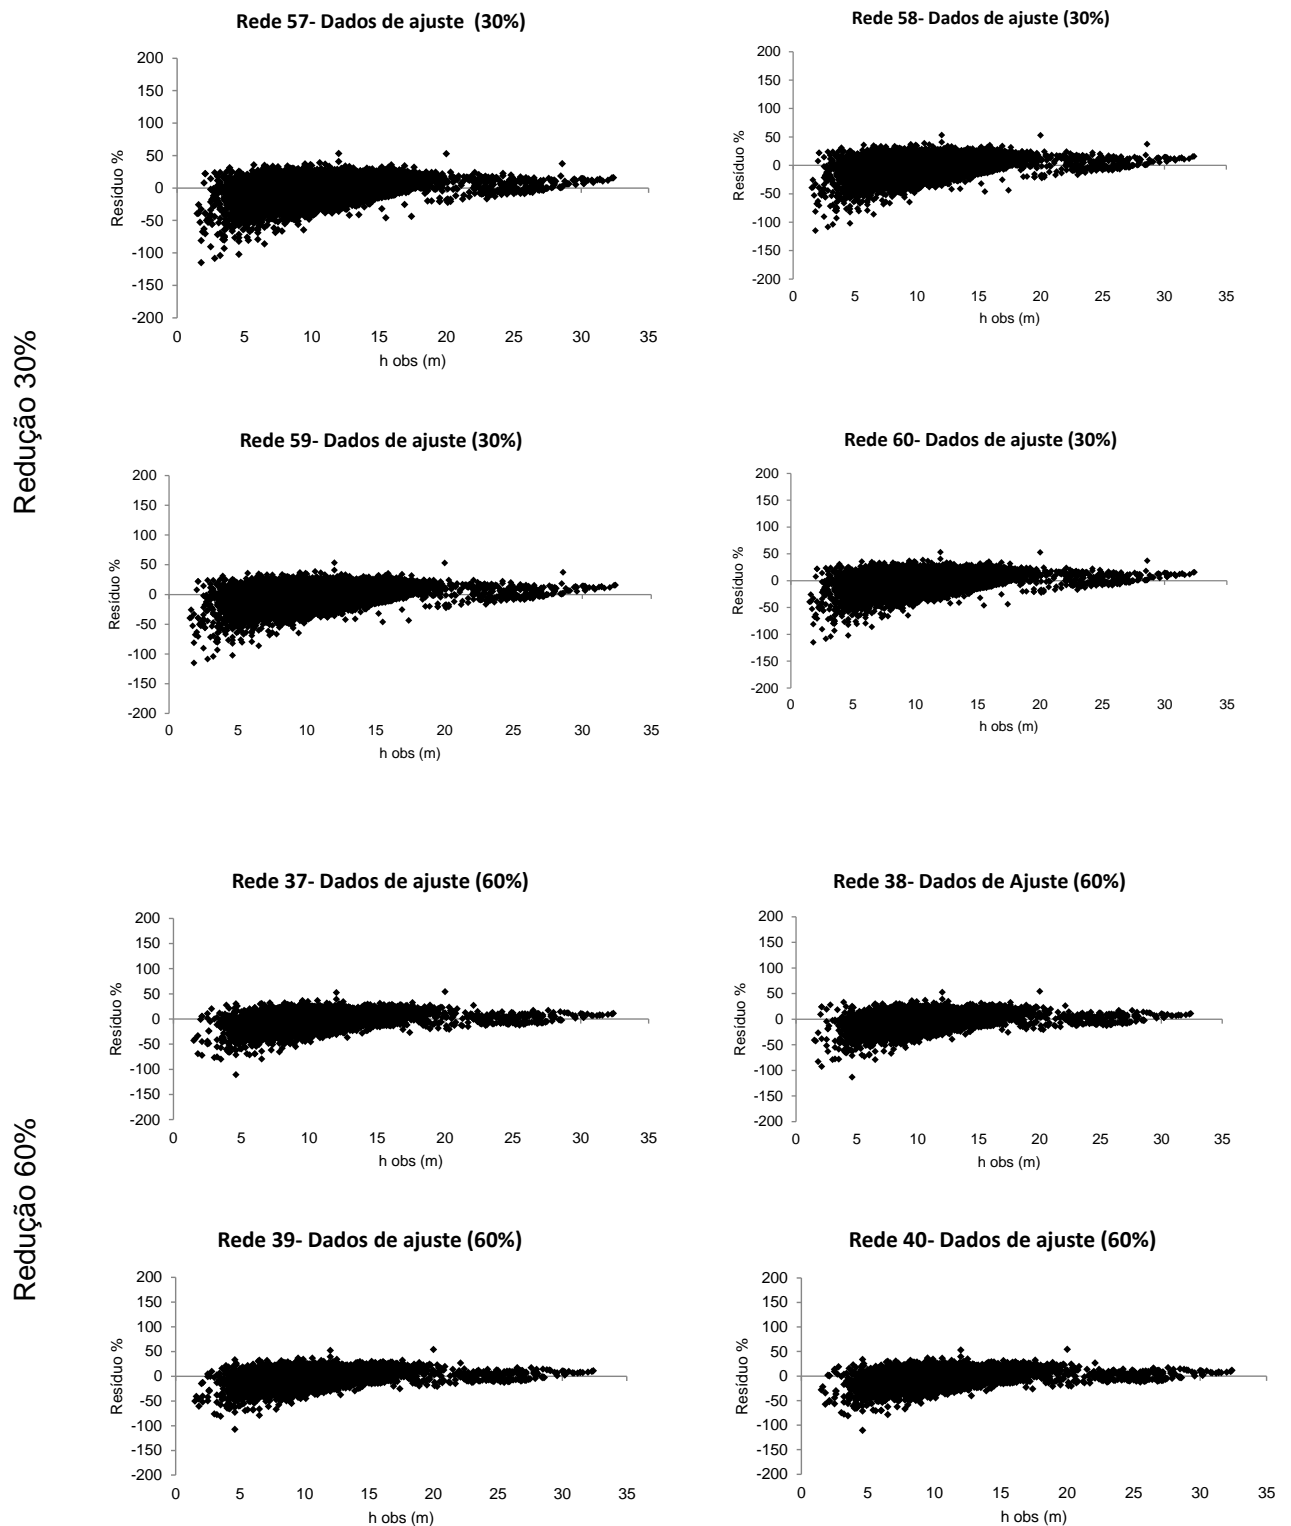


FIGURA 14 - GRÁFICOS DE DISPERSÃO DE RESÍDUOS PARA AS RNA SELECIONADAS PARA ESTIMAÇÃO DA ALTURA PARA OS DADOS DE AJUSTE

Na **Erro! Fonte de referência não encontrada.** estão os resultados para a estimação de alturas quando aplicadas as 4 melhores RNA para cada tipo de redução nos dados de validação. Percebe-se que na base de dados total e redução

em 30% das alturas, as melhores redes são do tipo MLP. Com a base de dados completa, a melhor rede (RNA 21) utilizou apenas 3 camadas e o mínimo de neurônios possíveis para gerar a estimativa da altura, já com a redução em 30% foram necessárias 4 camadas e a interação entre as variáveis atingiu o limite permitido para treinamento, 80 neurônios. Na redução em 60% dos dados, todas as redes são da arquitetura RBF, com 2 neurônios na camada de entrada (idade e dap) e duas camadas intermediárias, o que indica que para uma redução intensa dos dados as RNA do tipo RBF geram melhores estimativas.

Destaca-se também a melhora do erro padrão da estimativa com a redução das medições em altura. Tal fato pode ser atribuído a dois principais motivos: um mal treinamento das RNA para a base total de dados ou uma maior homogeneidade dos dados quando reduzidas as alturas, permitindo melhores estimativas.

TABELA 16- ESTATÍSTICAS E ESTATÍSTICAS COMPLEMENTARES PARA ESTIMATIVA DE ALTURA POR MEIO DE RNA PARA TODOS OS DADOS DE VALIDAÇÃO

Estrato	Modelo	Tipo de Rede	Estatísticas		Estatísticas Complementares			Notas	Classificação
			R <sup>2</sup> ajust	Syx	V	MD	DPD		
Base total (100%)	21	MLP 2:2-2-1:1	<b>0,93</b>	<b>12,41%</b>	<b>(3)0,0680</b>	<b>(1)1,0112</b>	<b>(1)1,2994</b>	!	1
	23	MLP 2:2-27-27-1:1	0,92	12,84%	(1)-0,0339	(4)1,0431	(4)1,3465	!	3
	55	MLP 2:2-10-1:1	0,93	12,42%	(2)-0,0469	(2)1,0144	(2)1,3017	!	2
	57	MLP 2:2-41-1:1	0,92	12,58%	(4)0,1099	(3)1,0368	(3)1,3145	0	4
Redução de 30 %	57	MLP 2:2-80-54-1:1	0,93	12,09%	(3)-0,0126	(4)0,9934	(4)1,2681	1	4
	58	MLP 2:2-79-38-1:1	0,93	12,06%	(2)-0,0095	(1)0,9892	(3)1,2648	!	2
	59	MLP 2:2-80-49-1:1	0,93	12,05%	(4)-0,0135	(3)0,9902	(1)1,2638	!	3
	60	MLP 2:2-80-51-1:1	<b>0,93</b>	<b>12,06%</b>	<b>(1)-0,0063</b>	<b>(2)0,9894</b>	<b>(2)1,2645</b>	!	1
Redução de 60 %	37	RBF 2:2-49-1:1	<b>0,93</b>	<b>12,05%</b>	<b>(4)-0,0120</b>	<b>(2)0,9893</b>	<b>(2)1,2632</b>	!	3
	38	RBF 2:2-49-1:1	0,93	12,05%	(2)-0,0107	(4)0,9899	(4)1,2639	0	4
	39	RBF 2:2-49-1:1	0,93	12,04%	(1)-0,0105	(3)0,9898	(3)1,2631	!	2
	40	RBF 2:2-49-1:1	0,93	12,04%	(3)-0,0116	(1)0,9891	(1)1,2626	!	1

### 3.7.3 Comparação entre o método de Regressão e RNA para a redução da medição de alturas em 30% e 60%

Na TABELA 16 pode-se observar que o erro padrão da estimativa manteve-se estável com a redução em 30% e 60% das medições de altura, tanto pelo método de regressão, quanto por meio de redes neurais artificiais.

TABELA 16- COMPARAÇÃO ENTRE AS ESTIMATIVAS DE ALTURA POR REGRESSÃO E RNA REDUZINDO A MEDIÇÃO DA VARIÁVEL H

Métodos	Tipo	Modelo	Estatísticas		Estatísticas Complementares			Notas	Classificação
			R <sup>2</sup> ajust	Syx	V	MD	DPD		
RNA	100%	21	0,93	12,41%	(2)0,0680	(2)1,0112	(2)1,2994	6	2
Regressão	100%	4	0,86	12,23%	(1)-0,0147	(1)1,0040	(1)1,2820	3	1
RNA	30%	59	0,93	12,05%	(1)-0,0135	(1)0,9902	(1)1,2638	3	1
Regressão	30%	4	0,86	12,24%	(2)-0,02689	(2)1,00470	(2)1,28356	6	2
RNA	60%	40	0,93	12,04%	(1)-0,0116	(1)0,9891	(1)1,2626	3	1
Regressão	60%	4	0,86	12,24%	(2)-0,0234	(2)1,0033	(2)1,2828	6	2

Também é possível observar que as estatísticas são muito próximas e aceitáveis para as duas metodologias. No trabalho desenvolvido por Binoti (2010), a autora destaca que a redução das medições em altura por meio de RNA pode reduzir o tempo de medição em até 20%, e gerar uma redução de custos de até 16%.

No estudo em questão é clara a aplicabilidade das RNA para a redução de alturas, porém os métodos tradicionais de regressão também se mostram eficientes para estimar alturas com redução de custos de medição da variável em questão.

Binoti *et al.* (2013) em seu trabalho sobre redução da medição de altura utilizou duas estratificações de dados para treinamento das RNA: (a) quando há a introdução de um novo material genético e não existem informações sobre a relação hipsométrica deste; e (b) quando já se conhece a tendência de crescimento em altura dos povoamentos implantados, obtida pela existência de medições em parcelas de Inventário Florestal Contínuo (IFC). Os autores observaram melhores resultados quando são treinadas uma rede para cada clone, porém, recomendam a utilização de apenas uma rede para todo o povoamento.

Essa recomendação feita pelos autores supracitados para o caso da RNA já é adotada há décadas quando se considera a regressão. Adicionalmente, por meio da Tabela 13, pode-se comprovar que não há comprometimento nos ajustes com redução do número de medições de altura por meio de regressão, desde que os dados estejam devidamente estratificados.

As grandes empresas no Brasil do setor de celulose e papel trabalham com inventários florestais contínuos, em sua maioria anuais, possuindo um banco de dados de alturas muito rico. Sendo assim o banco de dados disponível é geralmente

suficiente para ajustar modelos de regressão satisfatórios, tornando desnecessário o uso de RNA para as estimativas quando utilizadas as mesmas variáveis independentes que a regressão.

#### **4. CONCLUSÕES**

- Na estimativa da altura por meio de regressão, os modelos que envolvem as variáveis diâmetro e idade apresentaram melhores ajustes que os modelos que envolvem apenas a variável dap, apresentando erro de 4,0% em determinados estratos.
- Dentre as RNA selecionadas, aquelas com arquitetura MLP e com 3 e 4 camadas apresentaram as melhores estimativas de altura, frente as redes RBF e linear.
- Os modelos de regressão apresentaram estimativas satisfatórias para altura. Quando utilizadas as mesmas variáveis de entrada para a regressão e RNA, empregar modelos hipsométricos estratificados gera estimativas mais precisas.
- Tanto as RNA quanto a regressão mostraram-se viáveis para estimar a altura com redução de até 60% na base de dados de alturas médias.

## CAPÍTULO 2

### ESTIMATIVA DO VOLUME INDIVIDUAL POR MEIO DO MÉTODO DE REGRESSÃO E REDES NEURAS ARTIFICIAS PARA *Pinus taeda* L.

#### 1 INTRODUÇÃO

O emprego de equações volumétricas constitui uma das principais ferramentas para quantificação da produção de povoamentos florestais, sendo base para o manejo sustentável de plantações florestais (LEITE; ANDRADE, 2003). Por isso, a estimação de equações volumétricas em empresas do setor privado, há muito tempo é prática usual (OLIVEIRA *et al.*, 2009).

Todavia, a quantificação volumétrica dos povoamentos florestais comerciais depende altos custos às empresas. Estes custos são ainda maiores quando se deseja obter menores erros nas estimativas das variáveis dendrométricas de interesse. Neste contexto, técnicas e ferramentas que melhoram a precisão nas estimativas e minimizam os elevados custos dos inventários florestais, bem como a utilização de variáveis de fácil obtenção na floresta nos ajustes dos modelos, são bem quistas (LEAL *et al.*, 2015).

Muitos modelos matemáticos foram sendo criados e testados para o ajuste de equação de volume (MACHADO *et al.*, 2002; TEWARI; KUMAR, 2003; SCOLFORO *et al.*, 2004). Apesar de o uso ter consagrado alguns desses modelos, nenhum deles será sempre o de melhor performance para todas as espécies e condições (MORAES NETO, 2009).

Os modelos devem ser ajustados de forma a representar as variações dos povoamentos florestais como a espécie, o sítio, a densidade e a idade. Com isso, um grande número de equações é gerado, o que dificulta o trabalho do profissional responsável pelas estimativas de produção de uma determinada empresa. Mas, esse trabalho, pode ser feito gerando uma única regressão, de forma a diminuir o número de equações (SCOLFORO, 2005), o qual pode acarretar a maiores erros nas estimativas. Convém, portanto, testar novas metodologias, que garantam um baixo erro de estimativa e um número restrito de equações. Assim, em 2010 inicia-se os primeiros estudos com as Redes Neurais Artificiais (RNA) no setor florestal brasileiro.

Segundo Binoti (2012), a utilização de RNA tem se mostrado uma alternativa promissora em relação às técnicas de regressão e diversos trabalhos como o de Silva et al., (2009), Gorgens *et al.* (2009), Binoti (2010), Diamantopoulou e Milios (2010), Leite et al. (2010), Castro (2011), vem sendo difundidos mostrando a superioridade das redes em relação às técnicas tradicionais de modelagem.

Além da obtenção de erros inferiores nas estimativas, trabalhos como o de Lopes *et al.*, (2014) também comprovaram que as RNA podem reduzir o número de amostras necessárias para estimação de variáveis dendrométricas. Assim, ter-se-ia uma metodologia que tanto obtém resultados superiores, quanto reduz a quantidade de amostras e, conseqüentemente, os custos nelas embutidos.

Apesar do potencial das RNA, ainda são escassos os trabalhos com ou uso desta ferramenta no setor florestal. Especificamente, o gênero abordado neste trabalho, o Pinus, tem-se publicações ainda mais incipientes no que tange este tema.

Diante do exposto o objetivo principal desse trabalho foi comparar e testar o desempenho das redes neurais artificiais e o método de regressão tradicional na estimativa de volume total, em um plantio florestal comercial de *Pinus taeda* L.



## 2. MATERIAL E MÉTODOS

### 2.1 DESCRIÇÃO DOS PLANTIOS

Foram cubadas 302 árvores por meio do método de Smalian com idades variando entre 4 e 19 anos e dap's entre 5 e 45 cm. Todos os indivíduos cubados pertencem à empresa Klabin S.A e localizados no município de Telêmaco Borba, região centro oriental do estado do Paraná.

Na FIGURA 15 estão apresentadas as distribuições diamétricas e de idade das árvores cubadas.




FIGURA 15- DISTRIBUIÇÃO DE IDADE E DE DAP DOS DADOS EM ESTUDO

### 2.2. AJUSTE POR REGRESSÃO: VOLUME TOTAL

Para a estimação de volume total, as árvores foram estratificadas de acordo com a metodologia utilizada pela Klabin, buscando retratar o mais próximo da realidade da empresa (TABELA 17).

TABELA 17 - ESTRATOS UTILIZADOS PARA AJUSTE DOS MODELOS VOLUMÉTRICOS-INSERIR A QUANTIDADE DE DADOS

Estrato	Intervalo idade 1 (anos)	Intervalo idade 2 (anos)	Classe Dap 1 (cm)	Classe Dap 2 (cm)
1	0	14,9	0	17,9
2	0	14,9	18	29,9
3	0	14,9	30	70
4	> 15	-	0	70

Foram ajustados 4 modelos volumétricos, dois relacionando a variável dependente volume com a variável independente diâmetro à 1,30m (*dap*) e os outros dois com as variáveis independentes *dap* e altura. Os modelos utilizados estão apresentados na TABELA 18.

TABELA 18 - MODELOS VOLUMÉTRICOS

Número	Autor	Modelo
1	Berkhout	$V = b_0 + b_1 \cdot dap$
2	Hush	$\ln V = b_0 + b_1 \cdot \ln dap$
3	Schumacher e Hall	$LL V = b_0 + b_1 \cdot \ln dap + b_2 \cdot \ln h$
4	Spurr	$V = b_0 + b_1 \cdot dap^2 \cdot h$

Em que:  $V$  = volume total com casca  $h$  = altura total (m);  $dap$  = diâmetro a 1,30 m (cm);  $\ln$  = logarítimo neperiano

### 2.3 SELEÇÃO E ESTATÍSTICAS DOS MODELOS DE REGRESSÃO

Para os ajustes dos modelos por meio de regressão foram utilizados 70% dos dados, e os outros 30% utilizados para a validação das equações. A seleção dos dados foi realizada de forma aleatória.

O ajuste dos modelos foi realizado por meio do software Statistica 7.0 (Statsoft, Inc, 2009), sendo posteriormente selecionados dois modelos, os quais foram aplicados aos dados de validação. Para selecionar o modelo por estrato, foram analisadas as estatísticas coeficiente de determinação ajustado e erro padrão da estimativa em porcentagem, sendo este último recalculado utilizando Fator de Meyer de modo a permitir a correção da discrepância logarítmica uma vez que as variáveis sofreram transformação logarítmica (TABELA 19).

TABELA 19- ESTATÍSTICAS UTILIZADAS PARA A SELEÇÃO DE MODELOS DE RELAÇÃO HIPSOMÉTRICA

Estadísticas	Fórmulas
Coefficiente de determinação ajustado	$R^2_{ajust} = 1 - \left\{ (1 - R^2) \cdot \left( \frac{n - p}{n - p - 1} \right) \right\}$ $R^2 = \frac{SQReg}{SQT}$
Erro padrão da estimativa em porcentagem	$Syx\% = \frac{Syx}{\bar{y}} \cdot 100$ $Syx = \sqrt{\frac{\sum_1^n (y_i - \hat{y}_i)^2}{(n - p)}}$
Fator de Meyer (FM)	$FM = e^{0,5(Syx^2)}$
Análise gráfica de resíduos	$Resíduo \% = \left( \frac{y_i - \hat{y}_i}{y_i} \right) \cdot 100$

Em que:  $R^2$ = coeficiente de determinação ajustado;  $SQReg$ = soma dos quadrados da regressão;  $SQT$ = soma dos quadrados total;  $n$ = número de observações;  $p$ = número de coeficientes incluindo  $b_0$ ;  $R$ = coeficiente de determinação;  $Syx$ = erro padrão da estimativa;  $y_i$ = valor real de cada observação;  $\hat{y}_i$ = valor estimado de cada observação;  $e = 2,718281828$ ;

Além disso foram utilizadas, também, as estatísticas complementares (Tabela 20) Viés (V), Média das Diferenças Absolutas (MD) e Desvio Padrão das Diferenças (DPD), que possibilitam uma análise mais detalhada do desempenho das estimativas (TABELA 20).

TABELA 20- ESTATÍSTICAS COMPLEMENTARES PARA ANÁLISE DOS MODELOS HIPSOMÉTRICOS

Estadística	Estimador
Viés (V)	$V = \frac{\sum_{i=1}^n y_i - \sum_{i=1}^n \hat{y}_i}{n}$
Média das diferenças absolutas (MD)	$MD = \frac{\sum_{i=1}^n  y_i - \hat{y}_i }{n}$
Desvio padrão das diferenças (DPD)	$DPD = \sqrt{\left( \frac{\sum_{i=1}^n d_i^2 - \left( \frac{\sum_{i=1}^n d_i}{n} \right)^2}{n} \right) / n - 1}$

Em que:  $y_i$ = valor observado e  $\hat{y}_i$ = valor estimado;  $n$ = número de observações; e  $d_i = (y_i - \hat{y}_i)$ .  
Fonte: Figueiredo Filho *et al.* (1996)

O viés indica a existência ou não de tendências entre os resíduos, porém não mede o quão afastado do eixo zero estão os valores residuais. Já a média das diferenças fornece justamente a ideia da amplitude dos erros, e o desvio padrão das diferenças mostra a homogeneidade entre os resíduos (SOUZA, 2009).

Com essas três estatísticas complementares foram estabelecidas notas para os modelos e foram classificados como melhores aqueles que resultaram na menor soma de notas.

## 2.4 TREINAMENTO DAS REDES NEURAIS

Os mesmos dados utilizados para o ajuste de modelos por meio de regressão foram selecionados para o treinamento das redes; no entanto, neste caso os dados não foram estratificados. A estratificação foi realizada posteriormente ao treinamento das redes com o intuito de gerar as estatísticas de comparação com os modelos de regressão. A mesma proporção de dados utilizada para o ajuste das relações hipsométricas foi utilizada para o treinamento das RNA, sendo 70%, e os outros 30% restantes foram utilizados para validação das redes selecionadas.

As redes treinadas foram do tipo *perceptrons*, conhecidas como MLP (*Multilayer Perceptron*) com uma camada de entrada para receber os dados, três ou quatro camadas intermediárias para processamento e uma camada de saída. Também foram treinadas redes do tipo RBF (*Radial Basis Function*) e rede linear. As funções de ativação testadas foram a linear e a logística.

Foram limitadas para ambas as redes um número máximo de 80 neurônios por camada, uma vez que o número de neurônios deve ser limitado para evitar o “*overtraining*” das redes.

Na construção e treinamento, utilizou-se o *software* Statistica 7.0 (Statsoft, Inc, 2009). As 60 redes com menor erro padrão da estimativa calculadas no programa Statistica. Dessas, foram selecionadas as 20 redes com maior correlação entre os dados estimados e observados.

As redes selecionadas foram analisadas pelas mesmas estatísticas dos modelos hipsométricos. As redes selecionadas foram aplicadas à base de dados total de validação, sendo finalmente selecionadas as duas melhores redes e aplicadas aos dados de validação por estrato.

## 2.5 AVALIAÇÃO DA PERFORMANCE DOS MÉTODOS

Para avaliar a performance da regressão e redes neurais artificiais, a média das estimativas dos volumes gerados por cada método foi comparada entre si e entre a média dos volumes reais por meio de Análise de Variância (ANOVA), seguida pelo teste de Tukey a 95% de probabilidade de confiança. Os pressupostos da ANOVA (normalidade e independência dos resíduos e homogeneidade das variâncias) foram previamente observados. Adicionalmente, obteve-se o coeficiente de correlação linear de Pearson ( $r$ ) entre as alturas estimadas pelos diferentes métodos e a altura real.

### 3. RESULTADOS E DISCUSSÃO

#### 3.1 AJUSTE DOS MODELOS DE REGRESSÃO: ESTIMAÇÃO DO VOLUME

No estudo, das 302 árvores cubadas, 211 foram utilizadas para o ajuste, sendo que a maioria dos fustes encontram-se nas classes 1 e 2. O restante, 91 árvores, foram utilizadas para validação dos modelos, em que a maioria dos fustes estão na classe 1 e 4 (FIGURA 16).




FIGURA 16 - DISTRIBUIÇÃO DE IDADE E DE DAP DOS DADOS EM ESTUDO

Na distribuição de diâmetro e altura por estrato, como já esperado, não existe sobreposição de diâmetros em classes diferentes devido à estratificação ser realizada por classe diamétrica, com exceção do estrato 4 que é estratificado pela idade. Na FIGURA 17, também é possível observar mesmas alturas e volumes para diferentes classes diamétricas ao longo dos estratos.

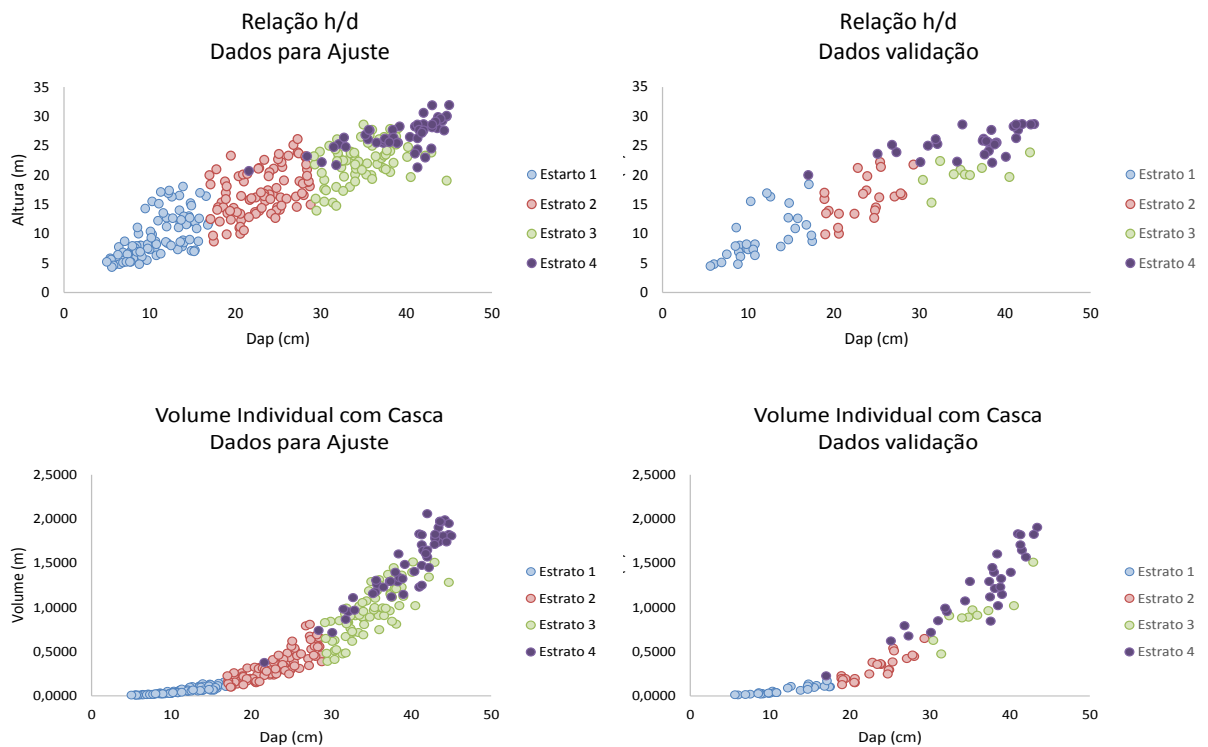


FIGURA 17-RELAÇÃO H/D E VOLUME INDIVIDUAL COM CASCA PARA OS DADOS DE AJUSTE E VALIDAÇÃO

Na TABELA 21 estão as estatísticas descritivas para altura, diâmetro e volume individual com casca para os dados do estudo.

TABELA 21- DISTRIBUIÇÃO DAS VARIÁVEIS DENDROMÉTRICAS E VOLUME POR ESTRATO

Estatística descritiva	Dados ajuste			Dados validação		
	VICC (m <sup>3</sup> )	dap (cm)	altura (m)	VICC (m <sup>3</sup> )	dap (cm)	altura (m)
Média	0,5907	24,95	17,68	0,5906	24,94	17,40
Erro padrão	0,0323	0,66	0,41	0,0592	1,20	0,76
Mediana	0,3807	24,85	17,89	0,3779	24,90	17,00
Desvio padrão	0,56	11,44	7,15	0,56	11,42	7,26
Variância da amostra	0,32	130,77	51,19	0,32	130,45	52,77
Curtose	-0,43	-1,21	-1,07	-0,64	-1,30	-1,21
Assimetria	0,83	-0,01	-0,12	0,77	-0,02	-0,14
Intervalo	2,05	40,00	27,65	1,90	37,80	24,20
Mínimo	0,0073	5	4,3	0,0086	5,6	4,5
Máximo	2,0597	45	31,95	1,9044	43,4	28,7
Contagem	302	302	302	91	91	91
Nível de confiança(95,0%)	0,06	1,29	0,81	0,12	2,38	1,51

Na TABELA 22 é possível observar que os modelos 1 e 2, os quais possuem como variável dependente o dap, apresentaram as piores estatísticas. Foram gerados coeficientes de determinação entre 68% e 91% e erro padrão da estimativa variando entre 11% e 36%. Essas equações apresentaram as piores notas em viés, média das diferenças absolutas e desvio padrão das diferenças. Segundo Miguel (2009), em equações de simples entrada (volume estimado em função do dap), o diâmetro deve estar fortemente correlacionado com altura. Já as equações de dupla entrada (volume estimado em função do dap e altura) são recomendáveis quando há uma maior heterogeneidade na relação altura-diâmetro, ou seja, o diâmetro não está fortemente correlacionado com a altura.

Os modelos 3 e 4, que relacionam o volume com as variáveis independentes diâmetro e altura, apresentaram coeficientes de determinação de no mínimo 93% a 98%. Já o erro padrão da estimativa variou entre 7% e 10%. As análises estatísticas complementares apresentaram as melhores notas para esses modelos, sendo, portanto, selecionados para a etapa de validação. Os parâmetros ajustados por meio de regressão estão no Apêndice 9.

TABELA 22 - ANÁLISES ESTATÍSTICAS DOS MODELOS EM ESTUDO

Estrato	Modelo	R <sup>2</sup> ajust	Syx%	V	MD	DPD	Total	Classificação
1	1	0,79	36%	(2) 0,0000	(4) 0,0137	(4) 0,0220	10	4
	2	0,80	36%	(3) 0,0004	(3) 0,0131	(3) 0,0216	9	3
	3	0,97	13%	(4) 0,0006	(2) 0,0044	(2) 0,0080	8	2
	<b>4</b>	<b>0,98</b>	<b>10%</b>	<b>(1) 0,0000</b>	<b>(1) 0,0042</b>	<b>(1) 0,0061</b>	<b>3</b>	<b>1</b>
2	1	0,72	22%	(1) 0,0000	(4) 0,0615	(3) 0,0773	8	2
	2	0,72	22%	(3)-0,0001	(3) 0,0612	(4) 0,0774	10	3
	<b>3</b>	<b>0,95</b>	<b>10%</b>	<b>(4) 0,0003</b>	<b>(1) 0,0219</b>	<b>(1) 0,0337</b>	<b>6</b>	<b>1</b>
	4	0,95	10%	(2)-0,0000	(2) 0,0224	(2) 0,0341	6	1
3	1	0,69	17%	(1)-0,0000	(3) 0,1135	(3) 0,1372	7	2
	2	0,68	18%	(2)-0,0035	(4) 0,1141	(4) 0,1395	10	4
	<b>3</b>	<b>0,94</b>	<b>7%</b>	<b>(3)-0,0002</b>	<b>(1) 0,0420</b>	<b>(1) 0,0575</b>	<b>5</b>	<b>1</b>
	4	0,93	7%	(4) 0,0308	(2) 0,0701	(2) 0,0727	8	3
4	1	0,90	11%	(2)-0,0000	(2) 0,0992	(4) 0,1366	8	2
	2	0,91	11%	(4) 0,0071	(3) 0,0992	(3) 0,1358	10	3
	<b>3</b>	<b>0,94</b>	<b>9%</b>	<b>(3)-0,0027</b>	<b>(1) 0,0816</b>	<b>(1) 0,1113</b>	<b>5</b>	<b>1</b>
	4	0,93	9%	(1) 0,0000	(2) 0,0854	(2) 0,1142	5	1

Nota 1: As classificações para cada estatística complementar estão apresentadas entre parênteses.

Nota 2: Os modelos selecionados estão apresentados em negrito



Na análise gráfica de resíduos (FIGURA 18) observa-se as maiores dispersões de resíduos nos modelos 1 e 2, enquanto os modelos 3 e 4 apresentaram as dispersões mais próximas do eixo x, o que significa menores tendenciosidades em super ou subestimar os volumes. No estrato 1 destaca-se as tendências do modelo 1 em superestimar os volumes dos menores dap's e subestimar os maiores dap.

Estrato

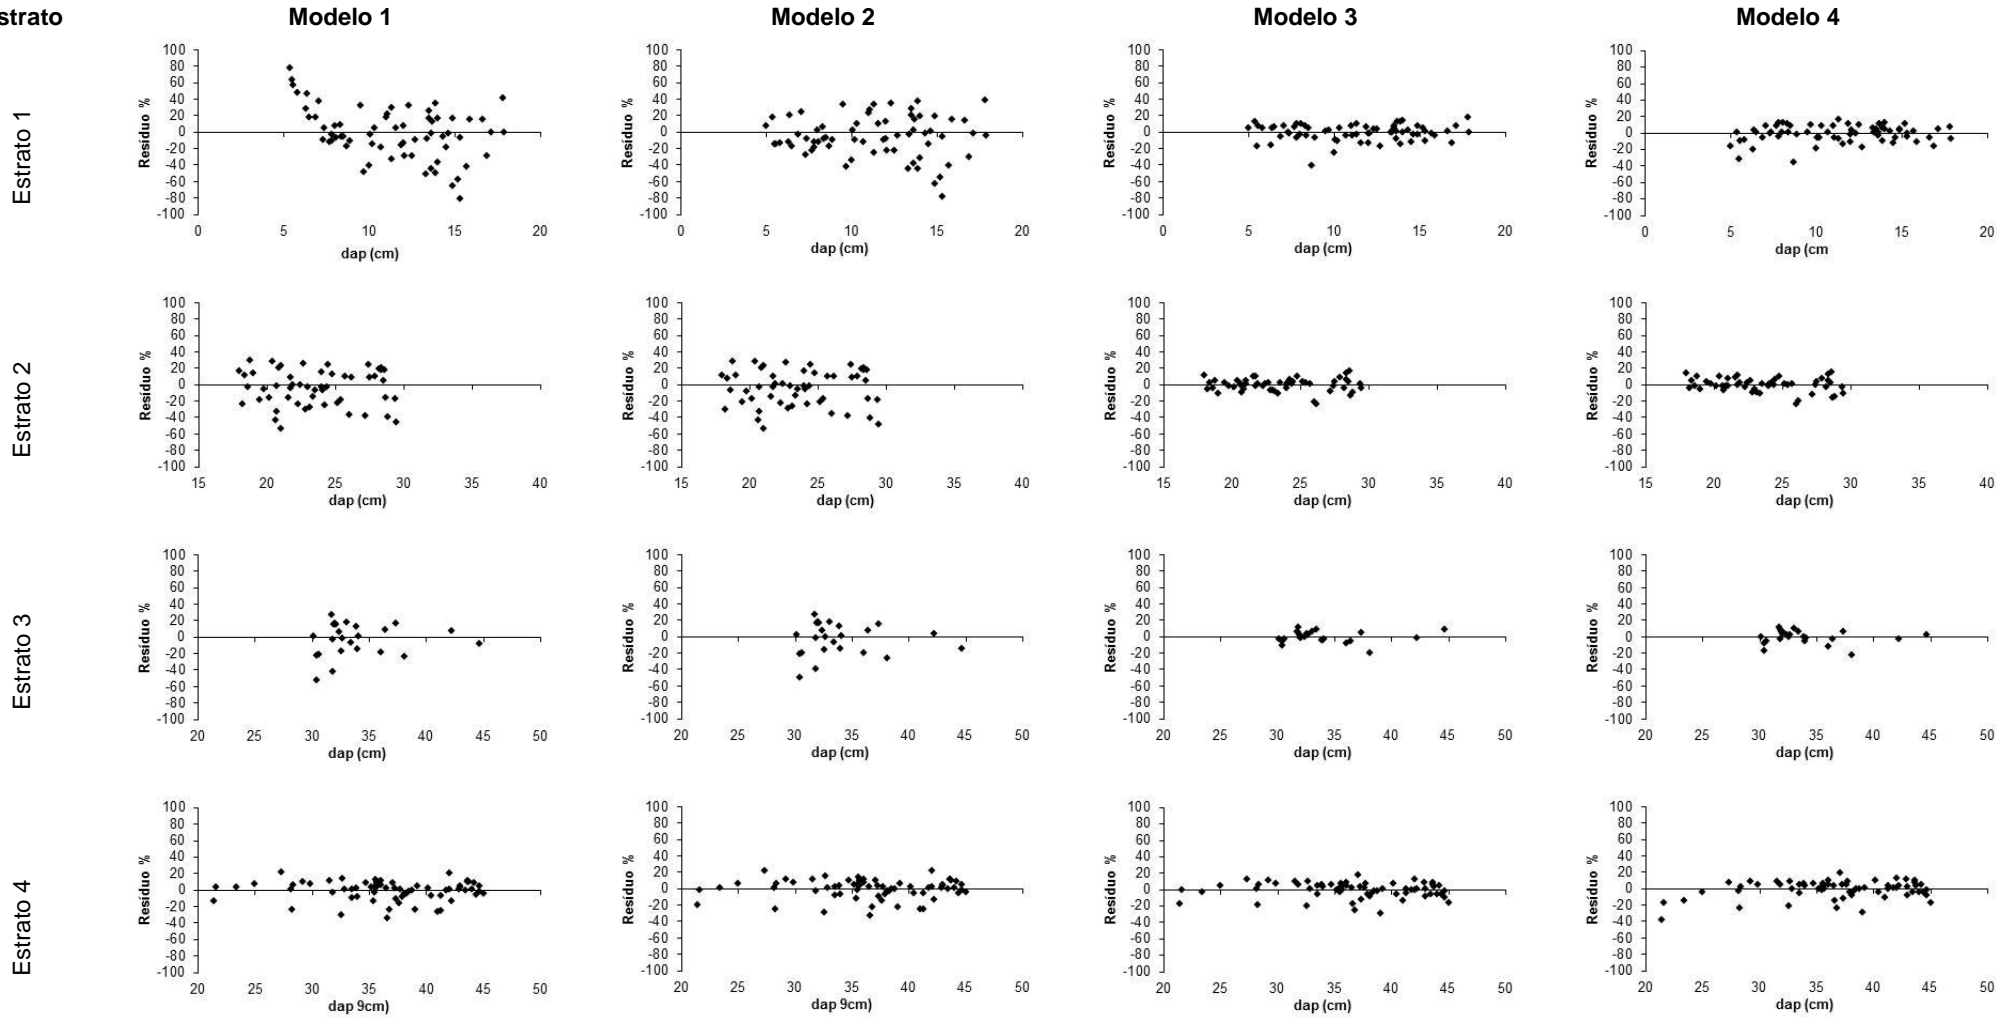


FIGURA 18 - DISTRIBUIÇÃO DE RESÍDUOS PARA ESTIMAÇÃO DE VOLUME POR MEIO DE REGRESSÃO

### 3.2 APLICAÇÃO DOS MODELOS DE REGRESSÃO NOS DADOS DE VALIDAÇÃO-ESTIMAÇÃO DO VOLUME

Na TABELA 23 estão apresentadas as estatísticas para estimativa de volume dos dados de validação quando os dois melhores modelos ajustados são aplicados. É possível observar que no estrato 1 e 2 os melhores modelos para estimar o volume para os dados de ajuste não foram os melhores para estimar o volume nos dados de validação.

O modelo selecionado (em negrito) será comparado com a melhor rede no item 3.5 deste capítulo. Os gráficos de dispersão dos resíduos estão apresentados no Apêndice 9.

TABELA 23 - ESTATÍSTICAS E ESTATÍSTICAS COMPLEMENTARES PARA ESTIMAR ALTURA DOS DADOS DE VALIDAÇÃO UTILIZANDO OS DOIS MELHORES MODELOS DE REGRESSÃO

Estrato	Modelo	R <sup>2</sup> ajust	Syx	V	MD	DPD	Notas	Classificação
1	<b>3</b>	<b>0,93</b>	<b>9,2%</b>	<b>(2) 0,0506</b>	<b>(1) 0,0555</b>	<b>(1) 0,055</b>	<b>4</b>	<b>1</b>
	4	0,91	11,1%	(1) 0,0169	(2) 0,1018	(2) 0,133	5	2
2	<b>3</b>	<b>0,98</b>	<b>6,3%</b>	<b>(1) -0,0021</b>	<b>(1) 0,0143</b>	<b>(1) 0,020</b>	<b>3</b>	<b>1</b>
	4	0,98	6,3%	(2) - 0,0031	(2) 0,0160	(1) 0,020	5	2
3	2	0,79	15,1%	(1) 0,0320	(2) 0,1016	(2) 0,133	5	2
	<b>3</b>	<b>0,93</b>	<b>9,2%</b>	<b>(2) 0,0506</b>	<b>(1) 0,0555</b>	<b>(1) 0,055</b>	<b>4</b>	<b>1</b>
3	<b>3</b>	<b>0,91</b>	<b>11,1%</b>	<b>(1) 0,0169</b>	<b>(1) 0,1018</b>	<b>(2) 0,133</b>	<b>4</b>	<b>1</b>
	4	0,90	11,0%	(2) 0,0229	(2) 0,1042	(1) 0,132	5	2

### 3.3 TREINAMENTO DAS REDES NEURAS ARTIFICIAIS: DADOS DE AJUSTE

Foram selecionadas as 20 redes com maior coeficiente de correlação (R) e calculadas suas estatísticas e estatísticas complementares (TABELA 24). As redes 24, 26, 29, 30 além de apresentarem os maiores coeficientes de correlação e menores erros padrão da estimativa, apresentaram as melhores notas nas estatísticas complementares, sendo selecionadas para a etapa de validação com a base de dados total.

TABELA 24 - ANÁLISES ESTATÍSTICAS DAS REDES NEURAI SELECIONADAS

Redes	R <sup>2</sup> ajust	Syx%	V	MD	DPD	Notas	Classificação
9	0,97	22%	(18)-0,0030	(20) 0,098	(18) 0,131	56	17
10	0,98	19%	(17) 0,0026	(11) 0,074	(11) 0,114	39	11
11	0,97	22%	(19)-0,0031	(18) 0,089	(19) 0,132	56	16
12	0,98	19%	(13) 0,0021	(17) 0,086	(12) 0,116	42	14
13	0,99	14%	(1) 0,0001	(9) 0,055	(9) 0,084	19	5
14	0,99	15%	(20) 0,0060	(10) 0,061	(10) 0,091	40	12
18	0,98	21%	(8)-0,0010	(14) 0,082	(16) 0,125	38	10
19	0,98	21%	(7)-0,0009	(15) 0,083	(15) 0,124	37	9
20	0,98	21%	(15)-0,0022	(13) 0,081	(13) 0,123	41	13
21	0,98	21%	(11)-0,0017	(12) 0,081	(14) 0,123	37	9
22	0,97	21%	(12)-0,0019	(16) 0,086	(17) 0,126	45	15
23	0,99	12%	(5) 0,0008	(8) 0,043	(8) 0,072	21	7
<b>24</b>	<b>0,99</b>	<b>12%</b>	<b>(2) 0,0002</b>	<b>(7) 0,042</b>	<b>(7) 0,072</b>	<b>16</b>	<b>3</b>
25	0,99	12%	(10) 0,0014	(5) 0,041	(6) 0,072	21	7
<b>26</b>	<b>0,99</b>	<b>12%</b>	<b>(6) 0,0009</b>	<b>(6) 0,041</b>	<b>(5) 0,071</b>	<b>17</b>	<b>4</b>
27	0,99	12%	(14) 0,0022	(3) 0,039	(3) 0,070	20	6
28	0,99	12%	(16) 0,0024	(4) 0,040	(4) 0,071	24	8
<b>29</b>	<b>0,99</b>	<b>11%</b>	<b>(9) 0,0012</b>	<b>(1) 0,038</b>	<b>(2) 0,068</b>	<b>12</b>	<b>2</b>
<b>30</b>	<b>0,99</b>	<b>11%</b>	<b>(4) 0,0006</b>	<b>(2) 0,039</b>	<b>(1) 0,067</b>	<b>7</b>	<b>1</b>
5	0,97	23%	(3)-0,0002	(19) 0,097	(20) 0,137	42	14

Nota 1: As classificações para cada estatística complementar estão apresentadas entre parênteses.

Nota 2: As redes selecionadas estão apresentadas em negrito

Nos gráficos de dispersão de resíduos para todas as redes testadas estão apresentados no Apêndice 10. As redes 24, 26, 29 e 30 estão apresentadas na FIGURA 19 e, apesar de apresentarem as características de sub e superestimação nos menores diâmetros, foram as que apresentarem menores tendências ao longo das classes de diamétricas.

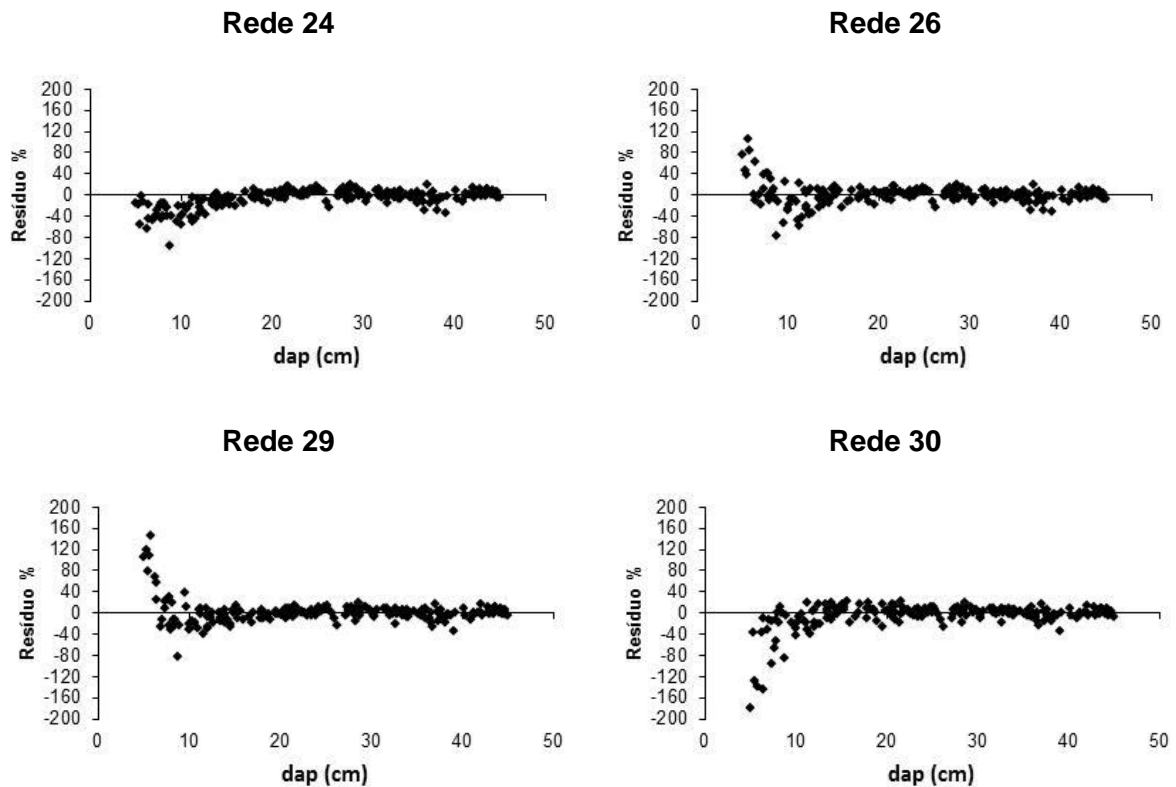


FIGURA 19- GRÁFICOS DE DISTRIBUIÇÃO DE RESÍDUOS PARA AS REDES SELECIONADAS

### 3.4 VALIDAÇÃO DAS REDES NEURAIS ARTIFICIAIS PARA ESTIMAÇÃO DE VOLUME

As redes 24, 26, 29 e 30, ambas do tipo MLP com 3 e 4 camadas intermediárias, quando aplicadas na base de dados total de validação apresentam comportamentos e resultados estatísticos muito similares (TABELA 25). Neste caso, a utilização de estatísticas complementares e a análise gráfica de resíduos foram fundamentais para a escolha das redes a serem aplicadas nos dados de validação estratificados.

Por meio das notas de Viés, Média das diferenças absolutas e desvio padrão das diferenças, a rede 26 apresentou a melhor classificação.

TABELA 25- ESTATÍSTICAS DAS REDES NEURAIS SELECIONADAS APLICADAS AOS DADOS DE VALIDAÇÃO TOTAL

Redes	Tipo	R	Syx%	V	MD	DPD	Notas	Classificação
24	MLP 2: 2-3-2:1	0,99	13%	(1) 0,0057	(2) 0,0466	(2) 0,078	5	2
<b>26</b>	<b>MLP 2:2-23-2:1</b>	<b>0,99</b>	<b>13%</b>	<b>(2) 0,0072</b>	<b>(1) 0,0455</b>	<b>(1) 0,078</b>	<b>4</b>	<b>1</b>
29	MLP 3:3-24-1:1	0,99	14%	(3) 0,0099	(3) 0,0470	(4) 0,081	10	3
30	MLP 3:3-50-30-1:1	0,99	13%	(4) 0,0103	(4) 0,0479	(3) 0,079	11	4

Os gráficos de dispersão de resíduos estão apresentados na FIGURA 20.

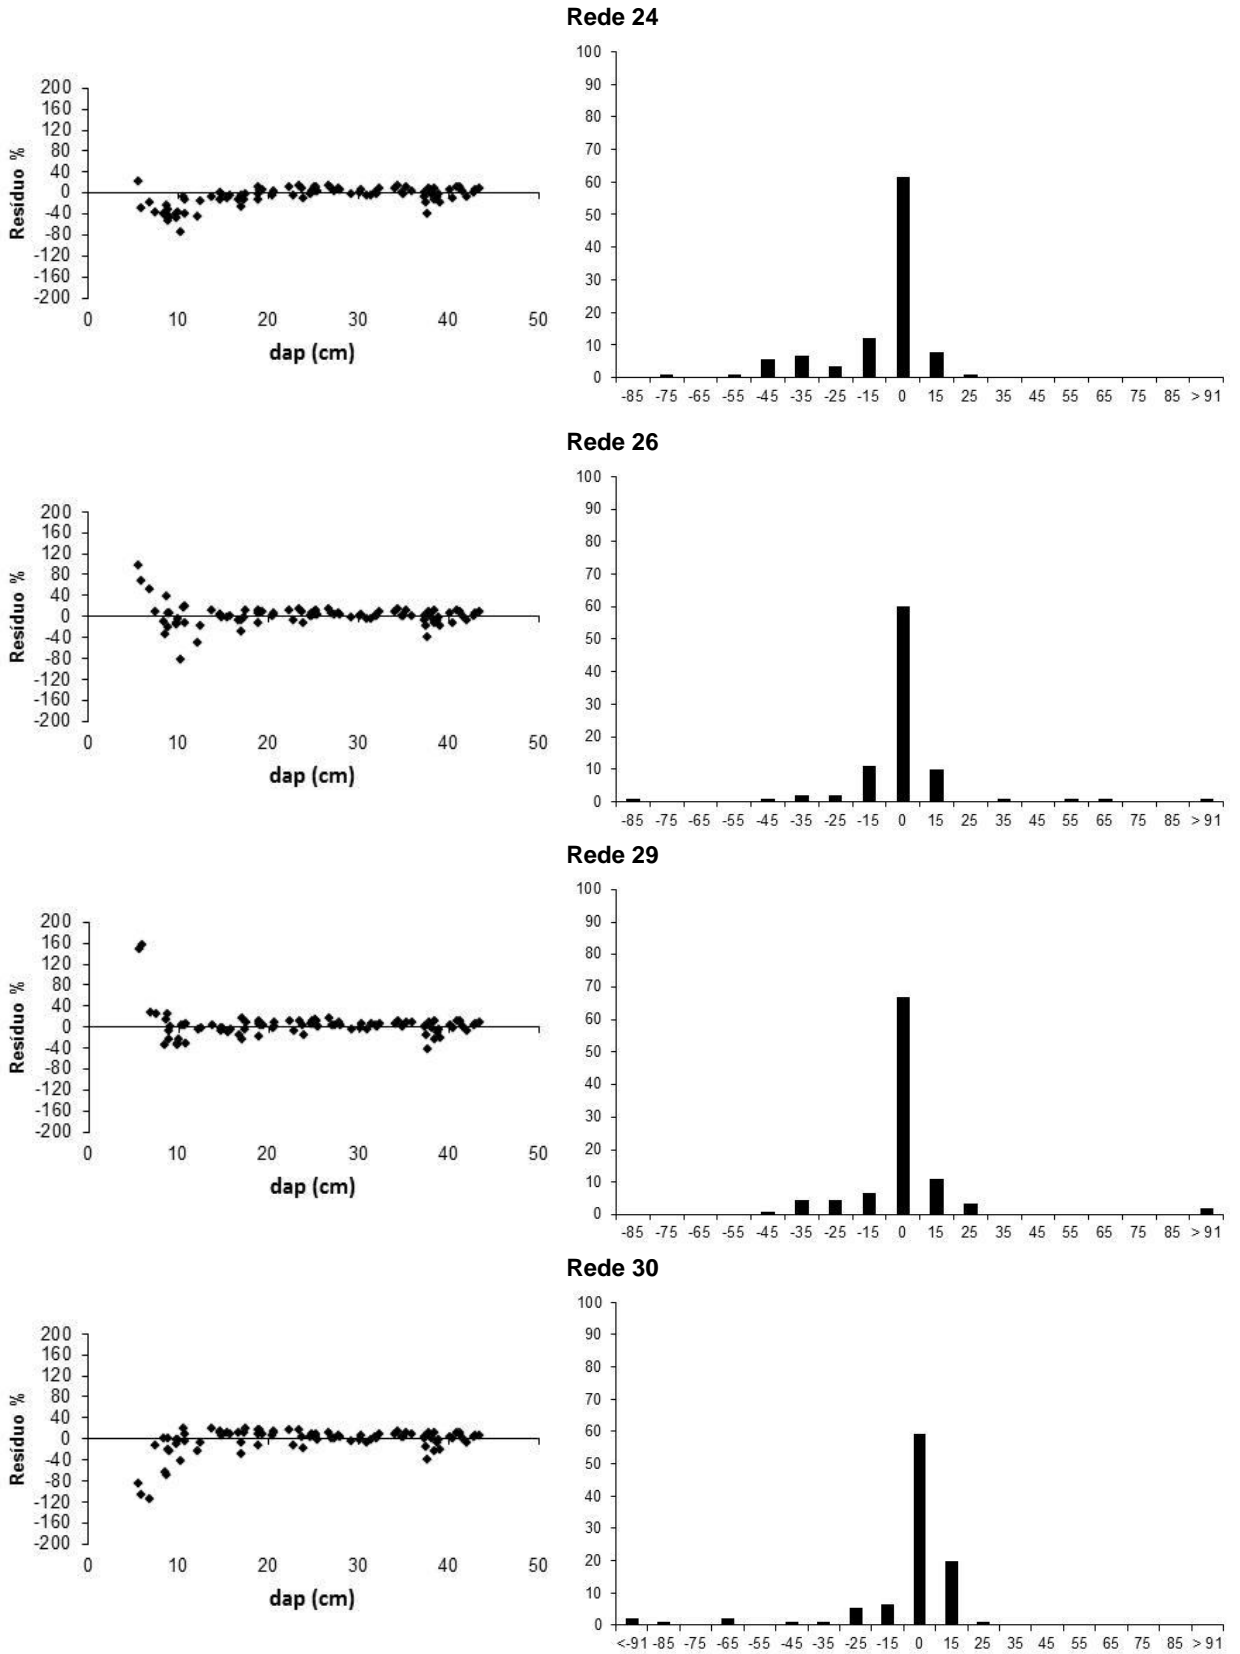


FIGURA 20- GRÁFICOS DE DISPERSÃO DE RESÍDUOS E GRÁFICOS DE FREQUÊNCIA PERCENTUAL DOS ERROS PERCENTUAIS PARA AS ESTIMATIVAS DE ALTURA COM REDES NEURAIS

### 3.5 COMPARAÇÕES ENTRE AS ESTIMATIVAS COM MÉTODO DE REGRESSÃO E RNA

Ao aplicar o melhor modelo de regressão e a melhor rede neural no banco de dados de validação por estrato, ambos apresentam comportamentos similares, em que os modelos de regressão foram selecionados nos estratos 1 e 2 e as RNA nos estratos 3 e 4 (TABELA 26).

Binoti et al. (2014) aplicaram o modelo tradicional de Schumacher Hall para estimar o volume individual de árvores de eucalipto spp., comparando com diferentes configurações de RNA. O modelo de regressão apresentou um RMSE (%) de 7,28, enquanto a rede apresentou valor menor que 1.

TABELA 26- ESTATÍSTICAS PARA A COMPARAÇÃO ENTRE OS MODELOS DE REGRESSÃO E REDES NEURAIS

Estrato	Redes	R	Syx%	V	MD	DPD	Total	Classificação
1	rede 26	0,96	27,1%	(1)-0,004	(1) 0,010	(1) 0,016	3	1
	<b>modelo 3</b>	0,93	9,2%	(2) 0,0506	(2) 0,0555	(2) 0,055	6	2
2	rede 26	0,99	7,6%	(2) 0,011	(2) 0,020	(2) 0,023	6	2
	<b>modelo 3</b>	<b>0,98</b>	<b>6,3%</b>	<b>(1)-0,002</b>	<b>(1) 0,014</b>	<b>(1) 0,020</b>	3	<b>1</b>
3	<b>rede 26</b>	<b>0,97</b>	<b>7,3%</b>	<b>(1) 0,008</b>	<b>(1) 0,053</b>	<b>(2) 0,074</b>	<b>4</b>	<b>1</b>
	modelo 3	0,93	9,2%	(2) 0,051	(2) 0,055	(1) 0,055	5	2
4	<b>rede 26</b>	<b>0,95</b>	<b>10,5%</b>	<b>(1) 0,015</b>	<b>(1) 0,099</b>	<b>(1) 0,132</b>	<b>3</b>	<b>1</b>
	modelo 3	0,91	11,1%	(2) 0,017	(2) 0,102	(2) 0,133	6	2

No estrato 1, houve uma superestimativa das RNA em relação à média dos volumes (FIGURA 21), que pode ser explicado pelo treinamento das redes ser realizado com os dados totais, ou seja, aproximadamente 70% dos dados estão presentes em classes de volume superior ao da classe 1. Também é possível observar que na distribuição de resíduos por classe, a regressão teve a maior concentração nas classes inferiores, o que é desejável.



No estrato 2, apesar das diferenças entre as estatísticas das duas metodologias serem inferiores às do estrato anterior. As RNA subestimam a média dos volumes, apesar de no gráfico de dispersão de resíduos por classe as duas estimativas (RNA e Regressão) possuem as mesmas classes de resíduos.




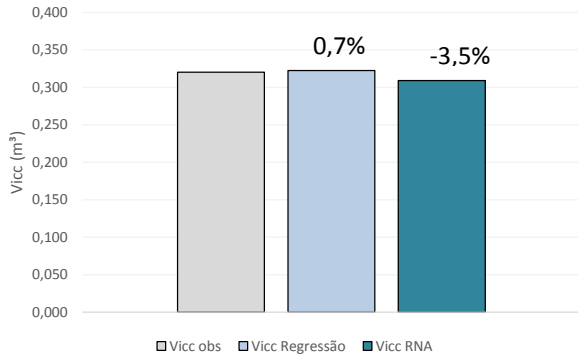
No estrato 3 as duas metodologias tenderam a subestimar em relação à média, e as RNA resultam em estatísticas mais desejáveis que a regressão, apesar dos resíduos estarem nas mesmas classes.

As estimativas do estrato 4 também apresentam subestimativas. Nas RNA isso é esperado, porque aproximadamente 80% dos dados para treinamento são de classes de volume inferiores ao dessa classe. Já na regressão espera-se um ajuste ruim pelo fato de ser realizado com um número pequeno de dados nesta classe e não abranger todas as classes de volume possíveis na validação.


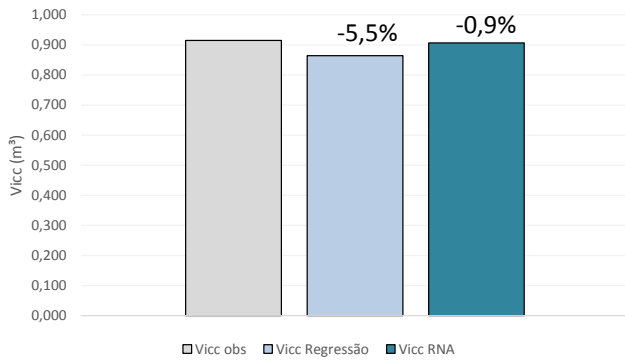
**Estrato 1**





**Estrato 2**



**Estrato 3**



**Estrato 4**



**FIGURA 21 - COMPARAÇÃO ENTRE O A MÉDIA DO VOLUME INDIVIDUAL COM CASCA OBSERVADO E AS ESTIMATIVAS POR MEIO DE REGRESSÃO E RNA E DISPERSÃO DE RESÍDUOS POR CLASSES (%)**

### 3.6 AVALIAÇÃO DA PERFORMANCE DOS MÉTODOS

Na TABELA 27 estão apresentados os resultados do teste de comparação de médias entre os três tratamentos: volume observado, volume estimado pela regressão e volume estimado pela RNA. Não existe diferenças estatísticas entre os três tratamentos.

TABELA 27 - MÉDIAS POR ESTRATOS DOS VOLUMES OBSERVADOS E ESTIMADOS PELA REGRESSÃO E RNA. VALORES DE F ACOMPANHADOS DE  $p \leq 0,05$  INDICAM SIGNIFICÂNCIA DA ANOVA.

Métodos	Estrato 1	Estrato 2	Estrato 3	Estrato 4
	Médias			
V obs (m <sup>3</sup> )	0,0585 a	0,3091a	0,9151a	1,2023 a
V Regressão (m <sup>3</sup> )	0,0598 a	0,3202a	0,8716a	1,2097a
V RNA (m <sup>3</sup> )	0,063 a	0,3233a	0,9066a	1,2252a
F	0,070	0,060	0,070	0,030
P	0,936	0,938	0,930	0,974

\* Médias seguidas pela mesma letra não diferem estatisticamente pelo teste de Tukey a 95% de probabilidade de confiança.

Na TABELA 28 é possível observar a alta correlação entre os três tratamentos, a qual tende a ser levemente mais forte entre os dados de volume observados e volumes estimados por meio da regressão.

TABELA 28 - COEFICIENTE DE CORRELAÇÃO ENTRE OS TRÊS TRATAMENTOS

Estrato	Correlação	V obs	V Regressão	V RNA
Estrato 1	V obs		0,988	0,964
	V Regressão	0,988		0,977
	V RNA	0,964	0,977	
Estrato 2	V obs		0,991	0,987
	V Regressão	0,991		0,994
	V RNA	0,987	0,994	
Estrato 3	V obs		0,971	0,969
	V Regressão	0,971		0,999
	V RNA	0,969	0,999	
Estrato 4	V obs		0,955	0,953
	V Regressão	0,955		0,997
	V RNA	0,953	0,997	

Apesar de não haver diferenças estatísticas entre os dados observados e as duas metodologias, com exceção das estimativas para o estrato 1 com RNA, as duas técnicas apresentarem estatísticas satisfatórias para estimar o volume total com casca.

Na prática, o tempo de treinamento das RNA foi de aproximadamente 7 horas, muito próximo ao do ajuste dos modelos volumétricos, porém a aplicabilidade da RNA em empresas florestais de grande porte torna-se pouco sustentável a longo prazo, pois precisa ser realizada em *softwares* específicos fora do banco de dados.

Além disso, nas empresas florestais as equipes de inventário florestal, responsáveis por gerar os volumes das florestas, a nível de talhão, fazenda ou região, são frequentemente questionadas sobre as variações dessa variável. Em um modelo de regressão essas variações são facilmente compreendidas com base nas relações entre as variáveis independentes e o volume, expressa por meio dos coeficientes. Por outro lado, no caso das RNA, essas relações não são tão explícitas, pois são geradas inúmeras informações sobre a interação entre as variáveis para explicar a tendência. Por isso, para estimar o volume total com casca recomenda-se utilizar as metodologias tradicionais de regressão.

#### **4. CONCLUSÕES**

- Os modelos de Schumacher e Hall e Spurr (modelo 3 e 4, respectivamente), geraram as melhores estimativas para o volume total com casca nos 4 estratos.
- Dentre as RNAs selecionadas, aquelas com arquitetura MLP e com três e quatro camadas intermediárias foram as que apresentaram as melhores estimativas.
- As estimativas de volume total com casca por meio de regressão foram melhores no estrato 1 e 2, utilizando o modelo de Schumacher e Hall, e no estrato 3 e 4 as RNA obtiveram estimativas mais precisas.
- Tanto as estimativas de volume total com casa por meio de RNA, quanto a regressão foram satisfatórias e ambas não apresentaram diferenças estatísticas em relação aos volumes observados. Como a aplicação das RNA ocorre de forma mais complexa e as tendências nas mudanças da variável dependente são mais difíceis de serem explicadas, a estimação do volume por meio de regressão de forma estratificada é mais viável.

### CAPÍTULO 3

## ESTIMATIVA DO DIÂMETRO E VOLUME INDIVIDUAL POR MEIO DE MODELOS DE AFILAMENTO E REDES NEURAS ARTIFICIAS PARA *Pinus taeda* L.

### 1 INTRODUÇÃO

No setor florestal, maximizar o rendimento econômico baseado em técnicas de otimização do processo é de suma importância. A conversão de árvores em multiprodutos é uma alternativa que vem sendo muito empregada no setor florestal, possibilitando um aumento significativo da receita oriunda de um povoamento florestal (PIZZIOLO *et al.*, 2014).

Para isso é necessário o emprego de modelos de sortimento florestal, ou melhor, funções de afilamento (*taper*). Estas destacam-se pela grande flexibilidade em estimar diâmetros em qualquer altura, alturas em qualquer diâmetro, e volumes parciais, totais e comerciais do tronco de árvores (MÔRA *et al.*, 2014).

Modelos de afilamento visam, portanto, retratar as variações do tronco com a finalidade de estimar o volume de madeira considerando as árvores como um sólido de revolução (CHAVES; CARVALHO, 2014).

Segundo Figueiredo Filho *et al.* (1996), funções de afilamento têm sido usadas no Brasil desde os anos 70. Dentre elas destacam-se os modelos polinomiais não segmentados, tais como o Polinômio do Quinto Grau e o Polinômio de Potências Fracionárias e Inteiras (modelo de Hradetzky). Tais modelos tem sido amplamente utilizados para descrever, com precisão, o perfil do fuste nos plantios de *Pinus taeda* e *Pinus elliottii* na região sul do Brasil.

Porém, a precisão de cada modelo dependerá do objetivo em que será empregado. Um modelo que estime com maior precisão o diâmetro, não necessariamente expressará melhor as alturas e os volumes (CAMPOS; LEITE, 2013).

Dentre as técnicas de modelagem, que são ferramentas valiosas para o planejamento dos possíveis produtos da área sob manejo, possibilitando prever multiprodutos, destacam-se também as Redes Neurais Artificiais (RNA).

Na literatura existem trabalhos para estimar a altura e diâmetro a nível de árvore individual, entre eles destacam-se trabalhos de Porras (2007), o qual projetou o diâmetro e altura de *Pinus cooperi* em uma floresta do México, e Binoti (2010) e

Castro (2011) que projetando diâmetro e a altura de árvores individuais de *Eucalyptus* spp. no Brasil. Entretanto, são praticamente inexistentes os estudos que abordam funções *taper*, com intuito de obtenção dos volumes por sortimento.

Tal situação ainda é agravada pela quase inexistência de estudos de RNA com o gênero *Pinus*. Tem-se uma ferramenta muito promissora, mas que exige ser testada nos diferentes plantios e situações de manejo que integram o complexo setor florestal brasileiro.

Diante disto o presente estudo teve como objetivo principal “avaliar a eficiência de redes neurais para estimar o diâmetro ao longo do fuste e volume comercial com casca em povoamentos de *Pinus taeda* L., comparando os resultados com os métodos tradicionais de ajuste de modelos de afilamento”.

## 2 MATERIAL E MÉTODOS

### 2.1 AJUSTE POR REGRESSÃO: DIÂMETRO AO LONGO DO FUSTE

Para a estimação de volume total e afilamento, as árvores foram estratificadas de acordo com a metodologia utilizada pela Klabin, buscando retratar o mais próximo da realidade da empresa (TABELA 29).

TABELA 29 - ESTRATOS UTILIZADOS PARA AJUSTE DOS MODELOS VOLUMÉTRICOS-INSERIR A QUANTIDADE DE DADOS

Estrato	Idade 1 (anos)	Idade 2 (anos)	Dap 1 (cm)	Dap 2 (cm)
1	0	14,9	0	17,9
2	0	14,9	18	29,9
3	0	14,9	30	70
4	> 15	-	0	70

Para o ajuste por regressão por meio de afilamento foram utilizados os modelos de Schöepfer (1966), Kozak *et al.* (1969), Demaerschalk (1972) e Garay (1979) (TABELA 30).

TABELA 30 - MODELOS DE AFILAMENTO

Número	Autor	Modelo
1	Schöepfer (1966)	$\frac{d_i}{D} = \beta_0 + \beta_1 \left(\frac{h_i}{H}\right) + \beta_2 \left(\frac{h_i}{H}\right)^2 + \beta_3 \left(\frac{h_i}{H}\right)^3 + \beta_4 \left(\frac{h_i}{H}\right)^4 + \beta_5 \left(\frac{h_i}{H}\right)^5 + e_i$
2	Hradetzky (1976)	$\frac{d_i}{D} = \beta_0 + \beta_1 \left(\frac{h_i}{H}\right)^{p1} + \beta_2 \left(\frac{h_i}{H}\right)^{p2} + \dots + \beta_n \left(\frac{h_i}{H}\right)^{pn} + e_i$
3	Demaerschalk (1972)	$\left(\frac{d_i}{D}\right)^2 = 10^{2.B0} \cdot D^{2B1-2} \cdot (H - h_i)^{2.B2} \cdot H^{2.B2} + e_i$
4	Garay (1979)	$\left(\frac{d_i}{D}\right) = \beta_0 \cdot (1 + \beta_1 \cdot \ln 1 - \beta_2 \cdot H^{\beta_3} \cdot H^{-\beta_3}) + e_i$

## 2.2 SELEÇÃO E ESTATÍSTICAS DOS MODELOS DE REGRESSÃO

Para os ajustes dos modelos por meio de regressão para estimar o diâmetro ao longo do fuste foram utilizados 70% dos dados, e os outros 30% utilizados para a validação das equações. A seleção dos dados foi realizada de forma aleatória.

O ajuste dos modelos foi realizado por meio do software Statistica 7.0 (Statsoft, Inc, 2009), sendo posteriormente selecionados dois modelos, os quais foram aplicados aos dados de validação. Para selecionar o modelo por estrato, foram analisadas as estatísticas coeficiente de determinação ajustado e erro padrão da estimativa em porcentagem, sendo o mesmo recalculado utilizando Fator de Meyer de modo a permitir a correção da discrepância logarítmica uma vez que as variáveis sofreram transformação logarítmica (TABELA 31).

TABELA 31 - ESTATÍSTICAS UTILIZADAS PARA A SELEÇÃO DE MODELOS DE AFILAMENTO

Estatísticas	Fórmulas
Coeficiente de determinação ajustado	$R^2_{ajust} = 1 - \left\{ (1 - R^2) \cdot \left( \frac{n - p}{n - p - 1} \right) \right\}$ $R^2 = \frac{SQReg}{SQT}$
Erro padrão da estimativa em porcentagem	$Syx\% = \frac{Syx}{\bar{y}} \cdot 100$ $Syx = \sqrt{\frac{\sum_1^n (y_i - \hat{y}_i)^2}{(n - p)}}$
Fator de Meyer (FM)	$FM = e^{0,5 \cdot (syx^2)}$
Análise gráfica de resíduos	$Resíduo \% = \left( \frac{y_i - \hat{y}_i}{y_i} \right) \cdot 100$

Em que:  $R^2$  = coeficiente de determinação ajustado;  $SQReg$  = soma dos quadrados da regressão;  $SQT$  = soma dos quadrados total;  $n$  = número de observações;  $p$  = número de coeficientes incluindo  $b_0$ ;  $R$  =



coeficiente de determinação;  $S_{yx}$ = erro padrão da estimativa;  $y_i$ = valor real de cada observação;  $\hat{y}_i$ = valor estimado de cada observação;  $e = 2,718281828$ ;

Além disso foram utilizadas, também, as estatísticas complementares (Tabela 3) Viés (V), Média das Diferenças Absolutas (MD) e Desvio Padrão das Diferenças (DPD), que possibilitam uma análise mais detalhada do desempenho das estimativas (TABELA 32).

TABELA 32 - ESTATÍSTICAS COMPLEMENTARES PARA ANÁLISE DOS MODELOS DE AFILAMENTO

Estadística	Estimador
Viés (V)	$V = \frac{\sum_{i=1}^n y_i - \sum_{i=1}^n \hat{y}_i}{n}$
Média das diferenças absolutas (MD)	$MD = \frac{\sum_{i=1}^n  y_i - \hat{y}_i }{n}$
Desvio padrão das diferenças (DPD)	$DPD = \sqrt{\left( \frac{\sum_{i=1}^n d_i^2 - \left( \frac{\sum_{i=1}^n d_i}{n} \right)^2}{n-1} \right)}$

Em que:  $y_i$ = valor observado e  $\hat{y}_i$ = valor estimado;  $n$ = número de observações; e  $d_i = (y_i - \hat{y}_i)$ .  
Fonte: Figueiredo Filho *et al.* (1996)

O viés indica a existência ou não de tendências entre os resíduos, porém não mede o quão afastado do eixo zero estão os valores residuais. Já a média das diferenças fornece justamente a ideia da amplitude dos erros, e o desvio padrão das diferenças mostra a homogeneidade entre os resíduos (SOUZA, 2009).

Com essas três estatísticas complementares foram estabelecidas notas para os modelos e foram classificados como melhores aqueles que resultaram na menor soma de notas.

### 2.3 TREINAMENTO DAS REDES NEURAS ARTIFICIAIS

Os mesmos dados utilizados para o ajuste de modelos por meio de regressão foram selecionados para o treinamento das redes; no entanto, neste caso os dados não foram estratificados. A estratificação foi realizada posteriormente ao treinamento das redes com o intuito de gerar as estatísticas de comparação com os modelos de regressão. A mesma proporção de dados utilizada para o ajuste dos modelos de

afilamento foi utilizada para o treinamento das RNA, sendo 70%, e os outros 30% restantes foram utilizados para validação das redes selecionadas.

As redes treinadas foram do tipo *perceptrons*, conhecidas como MLP (*Multilayer Perceptron*) com uma camada de entrada para receber os dados, três ou quatro camadas intermediárias para processamento e uma camada de saída. Também foram treinadas redes do tipo RBF (*Radial Basis Function*) e rede linear. As funções de ativação testadas foram a linear e a logística.

Foram limitadas para ambas as redes um número máximo de 80 neurônios por camada, uma vez que o número de neurônios deve ser limitado para evitar o “*overtraining*” das redes.

Na construção e treinamento, utilizou-se o *software* Statistica 7.0 (Statsoft, Inc, 2009). As 60 melhores redes (menor erro) foram retidas por meio, dessas, foram selecionadas as 20 redes com maior correlação entre os dados estimados e observados.

As redes selecionadas foram analisadas pelas mesmas estatísticas dos modelos de afilamento, com exceção do coeficiente de determinação, fazendo-se uma nova seleção considerando apenas as quatro melhores redes. Essas redes foram aplicadas à base de dados total de validação, sendo finalmente selecionadas as duas melhores redes e aplicadas aos dados de validação por estrato.

Após a seleção do melhor modelo de afilamento para estimar diâmetro ao longo do fuste ( $d_i$ ), os  $d_i$  estimados foram utilizados para gerar o volume da seção nos dados de validação. Para as RNA, foi realizado o mesmo procedimento. Os volumes totais das árvores estimados pelas duas metodologias foram comparados com o volume real por meio de  $R^2$  e  $Syx\%$ , descritos anteriormente.

## 2.4 AVALIAÇÃO DA PERFORMANCE DOS MÉTODOS

Para avaliar a performance da regressão e redes neurais artificiais, obteve-se o coeficiente de correlação linear de Pearson ( $r$ ) entre os diâmetros ao longo do fuste estimados pelos diferentes métodos e respectivo diâmetro real. Para esse caso, optou-se por não efetuar a comparação de médias haja vista a subdivisão da variável de interesse (diâmetro) em múltiplos representantes ao longo do fuste, com seções em tamanho variável.

### 3. RESULTADOS E DISCUSSÃO

#### 3.1 AJUSTE DOS MODELOS POR REGRESSÃO: ESTIMAÇÃO DO DIÂMETRO COM CASCA AO LONGO DO FUSTE

Em todos os estratos, o modelo de Hradetzky foi o que apresentou as melhores estatísticas para a estimativa do diâmetro ao longo do fuste, seguido do modelo de Garay e Demaerschalk, respectivamente. Entre os quatro modelos testados, o polinômio de 5º grau foi o de menor performance. É esperado um bom desempenho do modelo de Hradetzky pelo fato de o mesmo ser flexível ao número de potências e a seleção das mesmas ocorrer por meio do procedimento *forward*, ou seja, somente é incluído no modelo as potências com maior correlação aos dados (TABELA 33).

No trabalho de Teo *et al.* (2013), com *Pinus elliottii* na região de Caçador – SC, foi possível observar uma vantagem do Polinômio de Potências Fracionárias (Hradetzky) sobre o Polinômio de 5º Grau quando utilizado para estimar o diâmetro ao longo do fuste em todas idades do plantio. Os mesmos autores também observaram que ao considerar as estatísticas complementares V, MD e PDP, de maneira conjunta, verifica-se que o modelo de Hradetzky proporcionou as estimativas de diâmetro com casca mais acuradas para a maioria das alturas relativas do fuste de *Pinus elliottii*, em todas as idades estudadas.

Os parâmetros ajustados por estrato por meio de regressão estão apresentados no Apêndice 11.

Scolforo *et al.* (1998) estudaram a precisão de diversas equações de afilamento para estimativa de volume total de *Pinus elliottii*, dentre as quais o Polinômio de Potências Fracionárias e o Polinômio de 5º Grau apresentaram valores de entre 0,97 e 0,99 e entre 5,36 e 7,91, com ligeira superioridade para o Polinômio de Potências Fracionárias.

TABELA 33 - ESTATÍSTICAS PARA ESTIMATIVA DO DIÂMETRO AO LONGO DO FUSTE POR MEIO DE AJUSTE POR REGRESSÃO

Estrato	Modelo	R <sup>2</sup> ajust	Syx %	V	MD	DPD	Notas	Classificação
1	1	0,95	11%	(4)-0,13	(3) 0,80	(3) 1,10	10	4
	<b>2</b>	<b>0,95</b>	<b>11%</b>	<b>(3)-0,13</b>	<b>(2) 0,77</b>	<b>(2) 1,07</b>	<b>7</b>	<b>2</b>
	3	0,93	13%	(1) 0,06	(4) 0,87	(4) 1,27	9	3
	<b>4</b>	<b>0,95</b>	<b>11%</b>	<b>(2) 0,09</b>	<b>(1) 0,75</b>	<b>(1) 1,05</b>	<b>4</b>	<b>1</b>
2	1	0,96	9%	(2)-0,02	(3) 1,14	(3) 1,61	8	3
	<b>2</b>	<b>0,96</b>	<b>9%</b>	<b>(1)-0,02</b>	<b>(2) 1,07</b>	<b>(2) 1,56</b>	<b>5</b>	<b>1</b>
	3	0,94	11%	(3) 0,03	(4) 1,40	(4) 1,95	11	4
	<b>4</b>	<b>0,95</b>	<b>11%</b>	<b>(4) 0,09</b>	<b>(1) 0,75</b>	<b>(1) 1,05</b>	<b>6</b>	<b>2</b>
3	<b>1</b>	<b>0,97</b>	<b>8%</b>	<b>(1)-0,01</b>	<b>(2) 1,36</b>	<b>(2) 1,92</b>	<b>5</b>	<b>1</b>
	<b>2</b>	<b>0,97</b>	<b>4,8%</b>	<b>(4)-0,03</b>	<b>(1) 1,28</b>	<b>(1) 1,88</b>	<b>6</b>	<b>2</b>
	3	0,96	10%	(3) 0,07	(3) 1,68	(3) 2,38	9	3
	4	0,77	23%	(2) 0,02	(4) 4,50	(4) 5,44	10	4
4	1	0,97	9%	(4)-0,11	(2) 1,64	(2) 2,22	8	3
	<b>2</b>	<b>0,97</b>	<b>9%</b>	<b>(3)-0,10</b>	<b>(1) 1,45</b>	<b>(1) 2,05</b>	<b>5</b>	<b>1</b>
	<b>3</b>	<b>0,95</b>	<b>11%</b>	<b>(1)-0,03</b>	<b>(3) 1,97</b>	<b>(3) 2,69</b>	<b>7</b>	<b>2</b>
	4	0,74	26%	(2) 0,08	(4) 5,27	(4) 6,43	10	4

Nos gráficos de dispersão de resíduos, no Apêndice 12, é possível observar que o modelo de Garay (modelo 4), apesar de apresentar estatísticas satisfatórias, possui uma grande tendência em superestimar as menores classes de diâmetro.

### 3.2 VALIDAÇÃO DOS MODELOS DE REGRESSÃO

Quando as equações ajustadas são aplicadas aos dados de validação, existe uma adaptabilidade de distintos modelos para cada estrato, como apresentado na

TABELA 34.

TABELA 34- ESTATÍSTICAS PARA OS DADOS DE VALIDAÇÃO PARA ESTIMAR DI UTILIZANDO OS DOIS MELHORES MODELOS NO AJUSTE

Estrato	Modelo	R <sup>2</sup> ajust	Syx%	V	MD	DPD	Notas	Classificação
1	2	0,98	11%	(2) -0,26	(2) 0,81	(1) 0,67	5	2
	<b>4</b>	<b>0,98</b>	<b>10%</b>	<b>(1) -0,04</b>	<b>(1) 0,78</b>	<b>(2) 1,00</b>	<b>4</b>	<b>1</b>
2	<b>2</b>	<b>0,99</b>	<b>7%</b>	<b>(2) -0,05</b>	<b>(1) 0,36</b>	<b>(1) 0,75</b>	<b>4</b>	<b>2</b>
	4	0,88	22%	(1) -0,05	(2) 3,15	(2) 3,82	5	1
3	1	0,99	8%	(2) 0,55	(3) 1,45	(2) 1,82	6	2
	<b>2</b>	<b>0,99</b>	<b>7%</b>	<b>(1) 0,51</b>	<b>(1) 1,32</b>	<b>(1) 1,71</b>	<b>3</b>	<b>1</b>
4	<b>2</b>	<b>0,98</b>	<b>9%</b>	<b>(2) 0,19</b>	<b>(2) 1,57</b>	<b>(2) 2,32</b>	<b>6</b>	<b>2</b>
	3	0,97	8%	(1) 0,10	(1) 0,97	(1) 2,02	3	1

No estrato 1, apesar de os dois modelos apresentarem estatísticas muito próximas, o modelo de Garay (modelo 4), não apresenta tendências em superestimar os diâmetros acima de 15 cm, como pode ser visualizado no gráfico de dispersão de resíduos do modelo de Hradetzky (modelo 2) na FIGURA 22.

No estrato 2, apesar das estatísticas complementares apontarem para o modelo 4 como o melhor, o erro padrão da estimativa foi muito elevado para esse modelo (22%). Esse erro, relativamente alto, pode ser explicado na FIGURA 22, pois este modelo é muito eficiente para os diâmetros acima de 10 cm. Porém, nos menores diâmetros gera estimativas com erros de 600%. Por isso o modelo 2, Hradetzky, foi selecionado como o que melhor explica a variável dependente diâmetro ao longo do fuste.

No estrato 3, o modelo de Hradetzky (modelo 2) é o eleito, apesar de apresentar estatísticas muito semelhantes com o modelo de Schopfer (modelo 1). No gráfico de dispersão de resíduos, é possível observar que o modelo 1 apresenta maiores subestimativas para os diâmetros abaixo de 10 cm.

No estrato 4, apesar do modelo 3 apresentar estatísticas levemente superiores do modelo 2, no gráfico de dispersão de resíduos é possível observar que ambos apresentam superestimativas para os menores diâmetros, porém o modelo 2 não apresenta subestimativas nos diâmetros acima de 40 cm, fato que ocorre no modelo 3.

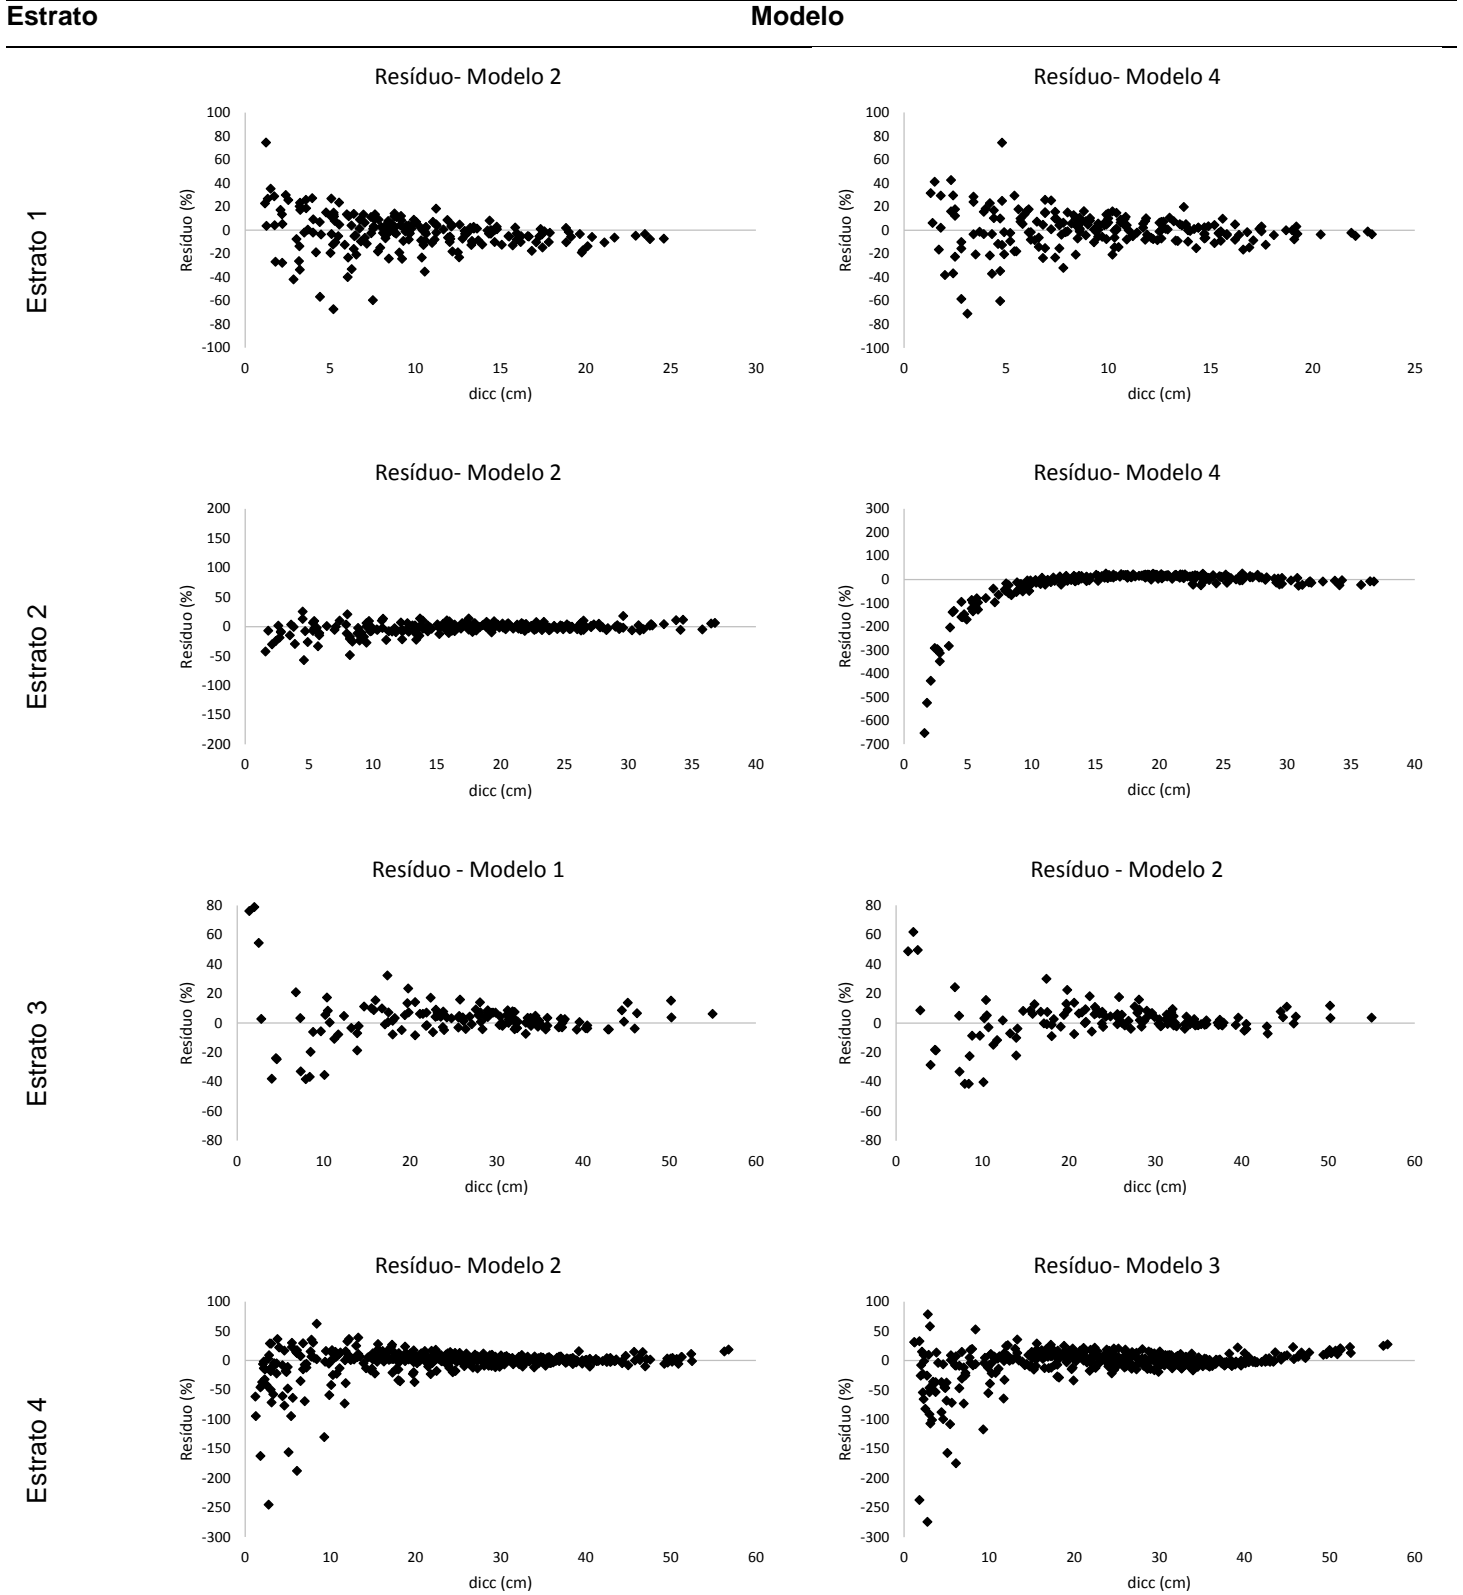


FIGURA 22 - GRÁFICOS DE DISPERSÃO DE RESÍDUOS PARA OS DADOS DE VALIDAÇÃO

### 3.3 TREINAMENTO DAS REDES NEURAIIS: DADOS DE AJUSTE

Na TABELA 35 estão apresentadas as estatísticas das redes neurais treinadas para estimar o diâmetro ao longo do fuste. É possível observar que entre as redes selecionadas, as redes 17, 26, 27 e 30, foram as que apresentaram o melhor desempenho.

TABELA 35 - ESTATÍSTICAS COMPLEMENTARES PARA ESTIMATIVA DE DIÂMETRO AO LONGO DO FUSTE POR MEIO DE RNA

Redes	R	Syx%	V	MD	DPD	Notas	Classificação
4	0,97	15%	(8) 0,008	(20) 2,17	(18) 2,93	46	11
10	0,97	15%	(12)-0,023	(19) 2,13	(19) 2,97	50	13
11	0,97	15%	(19) 0,046	(18) 2,11	(20) 2,96	57	14
12	0,97	14%	(16) 0,039	(14) 2,05	(17) 2,89	47	12
13	0,97	14%	(15)-0,033	(15) 2,08	(13) 2,78	43	10
14	0,98	11%	(17) 0,040	(5) 1,50	(10) 2,20	32	7
15	0,99	10%	(20) 0,054	(3) 1,44	(3) 2,01	26	5
16	0,99	10%	(18) 0,045	(2) 1,42	(2) 1,97	22	3
<b>17</b>	<b>0,99</b>	<b>9%</b>	<b>(14)-0,028</b>	<b>(1) 1,23</b>	<b>(1) 1,77</b>	<b>16</b>	<b>2</b>
18	0,97	14%	(13) 0,024	(13) 2,02	(16) 2,88	42	9
21	0,97	14%	(9)-0,016	(16) 2,10	(14) 2,82	39	8
22	0,97	14%	(10)-0,017	(17) 2,10	(15) 2,84	42	9
23	0,98	12%	(2) 0,002	(12) 1,75	(12) 2,39	26	5
24	0,98	12%	(6) 0,004	(11) 1,63	(11) 2,27	28	6
25	0,98	11%	(3) -0,003	(10) 1,54	(7) 2,14	20	3
<b>26</b>	<b>0,98</b>	<b>11%</b>	<b>(1) 0,001</b>	<b>(7) 1,52</b>	<b>(6) 2,12</b>	<b>14</b>	<b>1</b>
<b>27</b>	<b>0,98</b>	<b>11%</b>	<b>(7) 0,007</b>	<b>(4) 1,49</b>	<b>(5) 2,11</b>	<b>16</b>	<b>2</b>
28	0,98	11%	(11) 0,017	(9) 1,54	(8) 2,14	28	6
29	0,98	11%	(5) -0,004	(8) 1,54	(9) 2,15	22	4
<b>30</b>	<b>0,98</b>	<b>10%</b>	<b>(4) -0,003</b>	<b>(6) 1,51</b>	<b>(4) 2,09</b>	<b>14</b>	<b>1</b>

Nos gráficos de dispersão de resíduos (FIGURA 23) é possível observar uma maior proximidade dos resíduos ao eixo x na rede 17. Os demais gráficos de dispersão de resíduos estão apresentados no Apêndice 13.

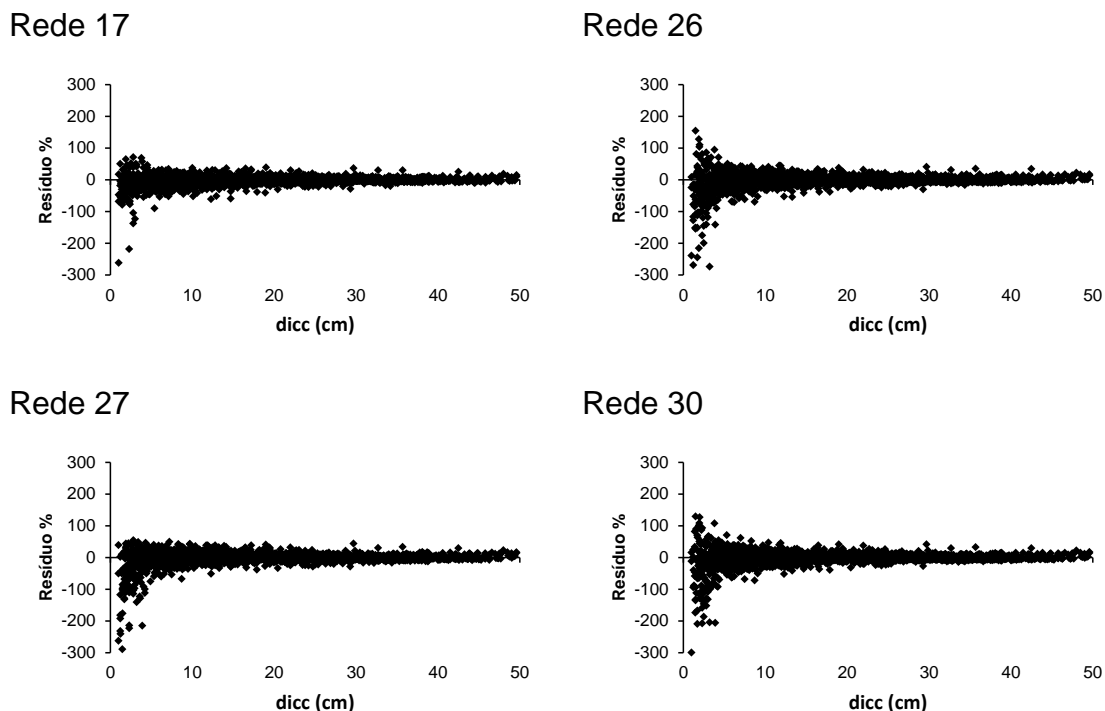


FIGURA 23 - GRÁFICOS DE DISPERSÃO DE RESÍDUOS PARA AS RNA SELECIONADAS

### 3.4 VALIDAÇÃO DAS REDES NEURAS PARA ESTIMAÇÃO DO DIÂMETRO AO LONGO DO FUSTE

Assim como, esperado a RNA 17 apresentou as estatísticas mais satisfatórias para os dados de validação, além de apresentar maior coeficiente de correlação (99%), e menor erro padrão da estimativa (10%). A soma das notas de Viés, Média das diferenças absolutas e desvio padrão das diferenças da rede 17, gerou a melhor classificação final (TABELA 36). Também é possível observar que essa rede se difere das demais por apresentar arquitetura MLP com quatro camadas intermediárias.

TABELA 36 - ESTATÍSTICAS DAS REDES NEURAS SELECIONADAS APLICADAS AOS DADOS DE VALIDAÇÃO TOTAL


Redes	Arquitetura	R	Syx%	V	MD	DPD	Notas	Classificação
17	<i>MLP3:3-49-10-1:1</i>	<b>0,99</b>	<b>10%</b>	<b>(4)- 0,2759</b>	<b>(1) 0,7575</b>	<b>(1) 0,953</b>	<b>6</b>	<b>1</b>
26	RBF 3:3-41-1:1	0,98	11%	(3)- 0,1987	(3) 0,8852	(2) 1,112	8	2
27	RBF 3:3-41-1:1	0,98	11%	(1)- 0,0538	(2) 0,8736	(3) 1,124	6	1
30	RBF 3:3-41-1:1	0,98	13%	(2)-0,1398	(4) 0,9927	(4) 1,254	10	3

Na FIGURA 24 estão apresentados os gráficos de dispersão de resíduos e a dispersão dos resíduos por classe. É possível observar que a maior concentração de




resíduos na Rede 17 encontra-se na menor classe (-5 a 9), na rede 26 na classe -10 a -24, ou seja, maior parte dos dados está subestimado. Nas redes 27 e 30 apesar de apresentarem menos outliers que as duas primeiras, não passam de -5 a 69, a distribuição não é tão intensa nas menores classes.


Rede 17



Rede 26



Rede 27



Rede 30




FIGURA 24- GRÁFICOS DE DISPERSÃO DE RESÍDUOS E GRÁFICOS DE DISPERSÃO DE RESÍDUOS POR CLASSE PARA AS RNA SELECIONADAS

### 3.5 COMPARAÇÕES ENTRE AS ESTIMATIVAS COM MÉTODO DE REGRESSÃO E RNA

Ao aplicar a melhor rede neural para o banco de dados e o melhor modelo para cada estrato, as estatísticas são muito similares. Porém, as redes destacam-se nos estratos 1 e 3, enquanto os modelos de regressão, explicam melhor a variável dependente para os estratos 2 e 4 (TABELA 37). Vale salientar que a rede foi treinada com o banco de dados total, enquanto os modelos de afilamento foram ajustados especificamente para cada estrato.

TABELA 37- ESTATÍSTICAS PARA AS ESTIMATIVAS DO DIÂMETRO AO LONGO DO FUSTE POR MEIO DE REGRESSÃO E REDES NEURAIS ARTIFICIAIS

Estrato	Redes	R <sup>2</sup> ajust	Syx %	V	MD	DPD	Notas	Classificação
1	rede 17 modelo 4	0,98	10,2 %	(2) -0,279	(1) 0,761	(1) 0,957	4	1
		0,98	10,4 %	(1) -0,038	(2) 0,777	(2) 1,001	5	2
2	rede 17 modelo 2	0,99	7,7%	(2) -0,148	(2) 1,110	(2) 1,359	6	2
		0,99	6,7%	(1) -0,053	(1) 0,363	(1) 0,748	3	1
3	rede 17 modelo 2	0,99	6,3%	(1) 0,222	(1) 1,214	(1) 1,612	3	1
		0,99	7,1%	(2) 0,515	(2) 1,324	(2) 1,714	6	2
4	rede 17 modelo 2	0,98	13,6 %	(1) 0,896	(2) 3,528	(2) 3,310	5	2
		0,97	9,3%	(2) 0,193	(1) 1,571	(1) 2,317	4	1

É importante destacar a superioridade das redes nos estratos 1 e 3, pois são os menos representativos no banco de dados total, 21% e 13 %, respectivamente. Isso significa que a rede necessita de um número menor de dados para explicar a variável dependente di. Isso pode ser explicado por esses estratos apresentarem diâmetros ao longo do fuste representados em quase todas as classes do banco de dados (TABELA 38).

Já nos estratos 2 e 4, representando 24% e 42%, respectivamente, do banco de dados, a RNA desempenhou resultados estatísticos satisfatórios. Porém, os modelos de afilamento foram ajustados com um banco de dados bem representativo, resultando em melhores estatísticas.

TABELA 38- DISTRIBUIÇÃO DO BANCO DE DADOS DE AJUSTE POR CLASSE DE DIÂMETRO

Classe dicc (cm)	Estrato 1	Estrato 2	Estrato 3	Estrato 4
1-10	283	122	48	170
11-20	200	227	73	183
21-30	9	199	93	285
31-40		25	80	262
41-50		1	17	103
51-60				14
61-70			2	

Ao analisar a FIGURA 25, com exceção do estrato 4, existe grande semelhança na distribuição de frequência entre as estimativas por regressão e RNA. No estrato 4, a maior parte dos resíduos está na classe 0 a +9, já na distribuição do modelo 2, ajustado por regressão os dados concentram-se em duas classes, uma positiva e outra negativa, -10 a 1 e 0 a 9.

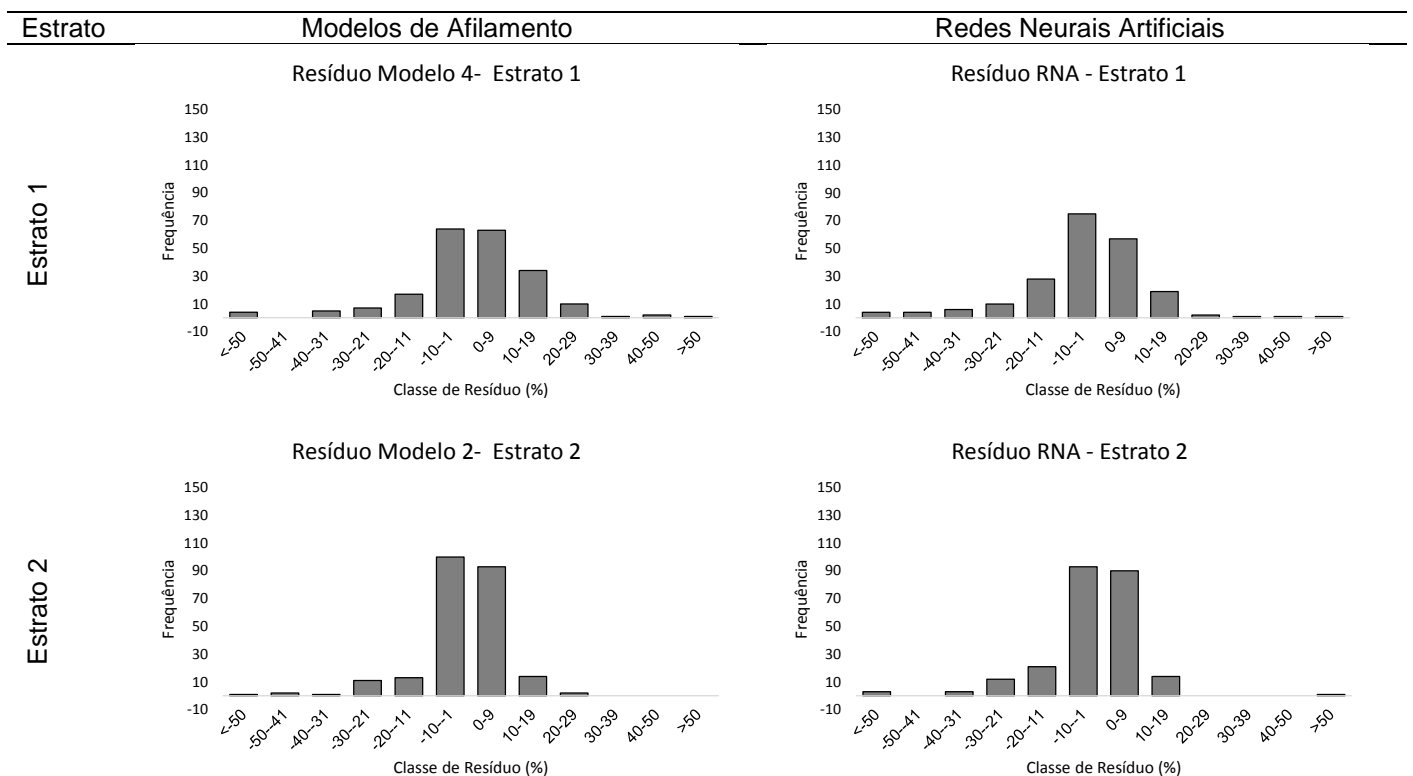


FIGURA 25 - DISTRIBUIÇÃO DE FREQUÊNCIA DE RESÍDUOS PARA ESTIMATIVA DO DIÂMETRO AO LONGO DO FUSTE PARA OS DADOS DE VALIDAÇÃO. Continua...

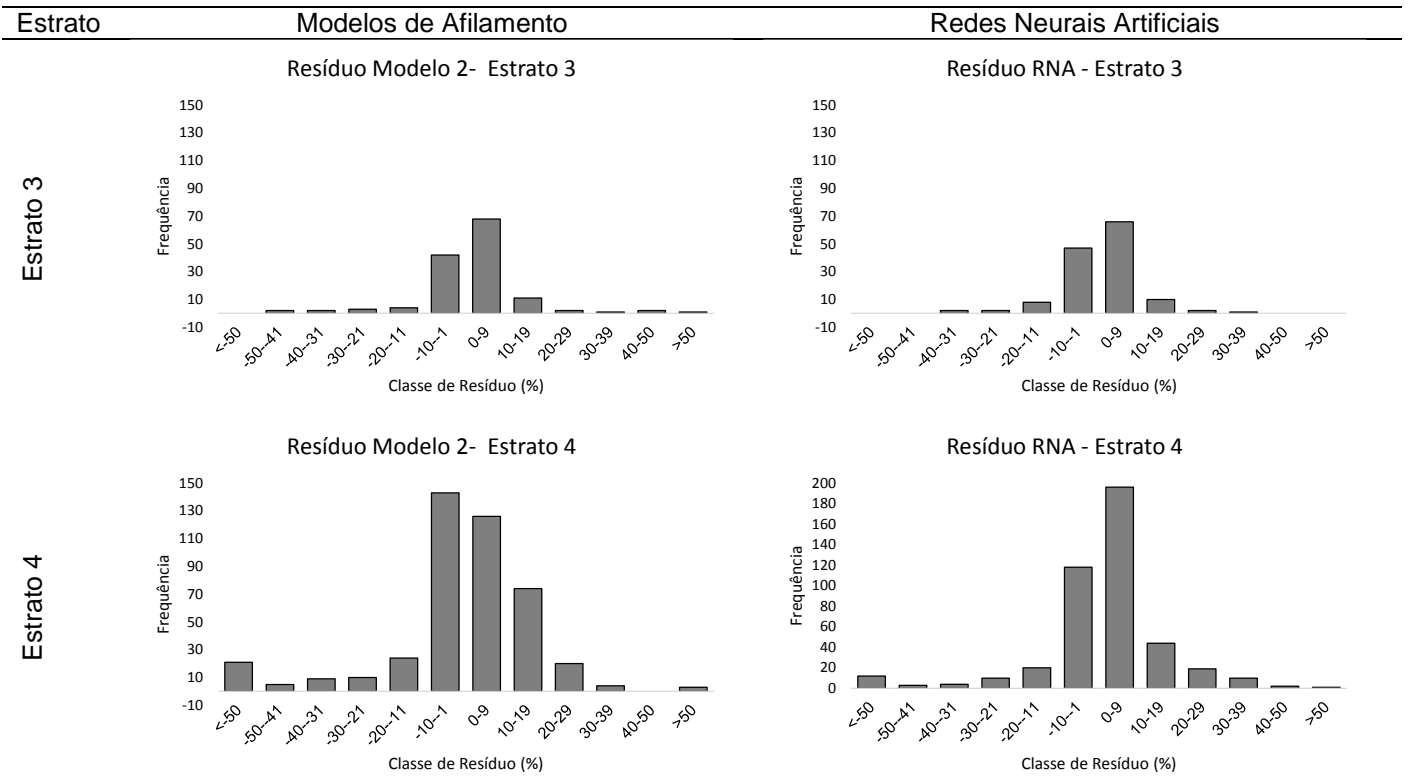


FIGURA 25 - DISTRIBUIÇÃO DE FREQUÊNCIA DE RESÍDUOS PARA ESTIMATIVA DO DIÂMETRO AO LONGO DO FUSTE PARA OS DADOS DE VALIDAÇÃO. Continuação

O ajuste de modelos de afilamento por meio de regressão é complexo e requer mais tempo. Tais complicações são amplificadas quando se deseja estimar o diâmetro ao longo do fuste utilizando o modelo de Hradetzky, modelo este que apresentou excelentes estimativas para os dados em estudo. O tempo de ajuste deste modelo e de treinamento de uma RNA são os mesmos. Portanto, na prática, as aplicações dos modelos de regressão para o afilamento são mais fáceis, porém, ao analisar o gráfico de dispersão de resíduos, nos menores diâmetros é visível a superioridade da RNA (FIGURA 26), treinada com a base de dados total. Por isso, quando são utilizados os mesmos dados para o ajuste de modelos de afilamento para estimativa do di por regressão e RNA, as redes explicam melhor o comportamento da forma do fuste.

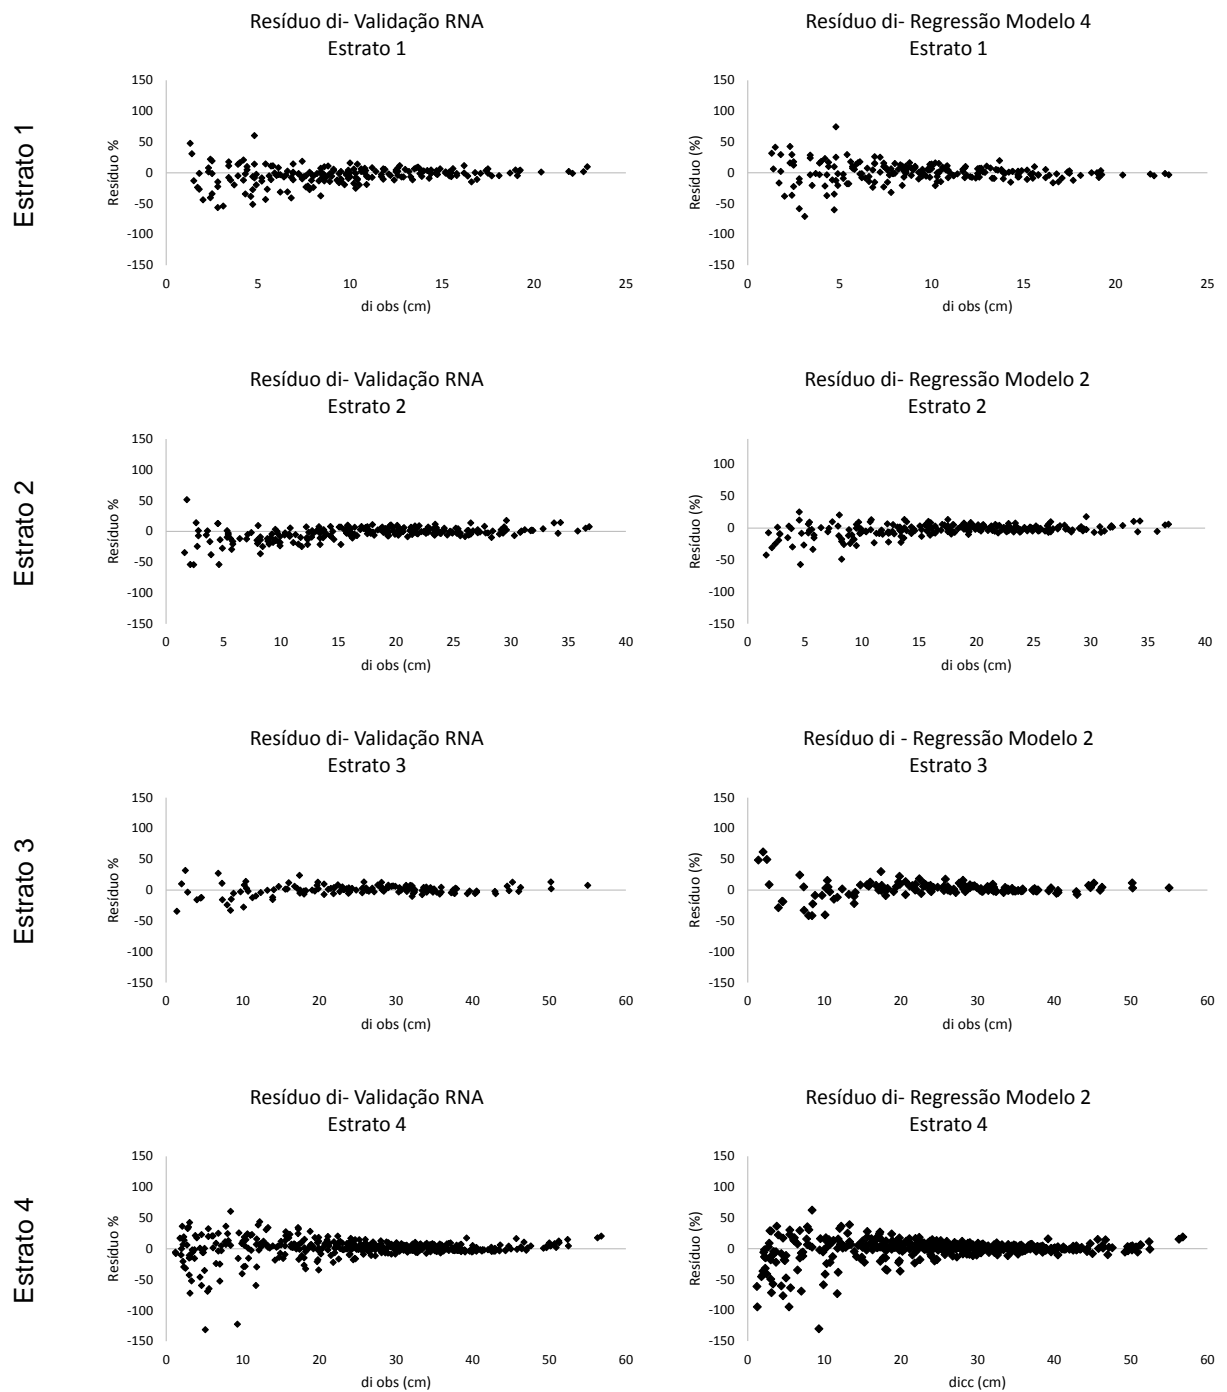


FIGURA 26: GRÁFICOS DE DISPERSÃO DE RESÍDUOS DOS MELHORES MODELOS E MELHOR RNA PARA ESTIMAR O DIÂMETRO AO LONGO DO FUSTE NOS DADOS DE VALIDAÇÃO

### 3.6 AVALIAÇÃO DA PERFORMANCE DOS MÉTODOS

As correlações entre os diâmetros observados e estimados pelos dois métodos foram fortes em todos os estratos, indicando a boa aplicabilidade tanto do modelo de afilamento ajustado por meio da regressão e RNA (TABELA 39).

TABELA 39 - COEFICIENTE DE CORRELAÇÃO ENTRE OS TRÊS TRATAMENTOS

<b>Estrato</b>	<b>Correlação</b>	<b>di obs</b>	<b>di Regressão</b>	<b>di RNA</b>
Estrato 1	di obs		0,981	0,981
	di Regressão	0,981		0,990
	RNA	0,981	0,990	
Estrato 2	di obs		0,990	0,988
	di Regressão	0,990		0,995
	RNA	0,988	0,995	
Estrato 3	di obs		0,989	0,990
	di Regressão	0,989		0,997
	RNA	0,990	0,997	
Estrato 4	di obs		0,983	0,983
	di Regressão	0,983		0,997
	RNA	0,983	0,997	

### 3.7 ESTIMAÇÃO DO VOLUME TOTAL COM CASCA POR MEIO DE AFILAMENTO E REDES NEURAS ARTIFICIAIS

Ao estimar o volume total com casca a partir da rede 17 e dos modelos de afilamento mais apropriados para cada estrato, a rede apresentou resultados mais satisfatórios que os modelos de regressão. O erro padrão da estimativa foi de 14%, contra 18% dos modelos de regressão (TABELA 40).

TABELA 40 - ESTATÍSTICAS PARA ESTIMATIVA DE VOLUME TOTAL COM CASCA POR MEIO DE REDES NEURAS ARTIFICIAIS E MODELOS DE AFILAMENTO POR MEIO DE REGRESSÃO

<b>Tipo</b>	<b>R<sup>2</sup></b>	<b>Syx%</b>
<b>RNA</b>	<b>0,98</b>	<b>14%</b>
<b>Regressão</b>	<b>0,97</b>	<b>18%</b>

Diamantopoulou (2005) também comprovou a superioridade das RNA em relação aos algoritmos de regressão não linear para estudar o volume de casca em Pinus e concluiu que as RNA têm grande potencial para muitas aplicações em modelagem florestal, sendo útil como alternativa às tradicionais.

Gorgens (2006), utilizando dados de cubagem de diferentes empresas florestais, testou algumas formas de pré-processamento dos dados e arquiteturas de RNA para estimar volume de árvores de eucalipto (*Eucalyptus* spp.) e teca (*Tectona grandis* L.f.). Silva (2008) obteve redes neurais que estimaram, os diâmetros sem

casca e do cerne ao longo do fuste para árvores de teca de forma precisa, superando os resultados obtidos por modelo de afilamento de Kozak.

Na FIGURA 27 estão os gráficos de dispersão de resíduos e gráficos de distribuição de frequência de resíduos para as estimativas com RNA e modelos de afilamento.

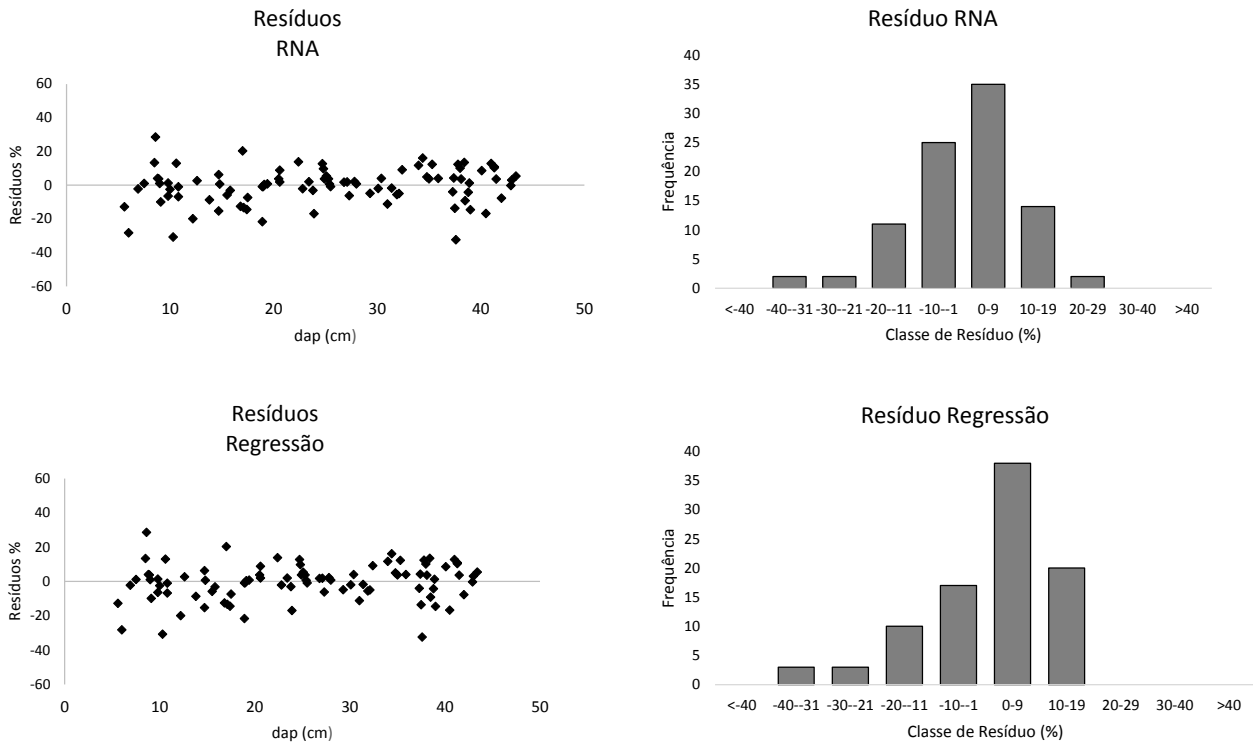


FIGURA 27- GRÁFICOS DE DISTRIBUIÇÃO DE RESÍDUOS PARA ESTIMAR VOLUME TOTAL COM CASCA POR MEIO DE RNA E REGRESSÃO

### 3.8 AVALIAÇÃO DA PERFORMANCE DOS MÉTODOS PARA ESTIMATIVA DE VOLUME TOTAL COM CASCA

Na TABELA 41 estão apresentados os resultados do teste de comparação de médias entre os três tratamentos: volume observado, volume estimado pela regressão e volume estimado pela RNA. Não houve diferenças estatísticas entre os três tratamentos.

TABELA 41 - MÉDIAS POR ESTRATOS DOS VOLUMES OBSERVADOS E ESTIMADOS PELA REGRESSÃO E RNA. VALORES DE F ACOMPANHADOS DE  $P \leq 0,05$  INDICAM SIGNIFICÂNCIA DA ANOVA.

Métodos	Estrato 1	Estrato 2	Estrato 3	Estrato 4
	Médias			
Vcc (m <sup>3</sup> )	0,0554a	0,314a	0,9079a	1,22052a
V Regressão	0,0577a	0,2937a	1,0746a	1,20021a
V RNA 26	0,0584a	0,3135a	0,8891a	1,19348a
F	0,03	0,15	1,1	0,04
P	0,9688	0,8581	0,3463	0,9642

\* Médias seguidas pela mesma letra não diferem estatisticamente pelo teste de Tukey a 95% de probabilidade de confiança.

Na TABELA 42 é possível observar a alta correlação entre os três tratamentos, a qual tende a ser levemente mais forte entre os dados de volume observados e volumes estimados por meio da regressão.

TABELA 42 - COEFICIENTE DE CORRELAÇÃO ENTRE OS TRÊS TRATAMENTOS

Estrato	Correlação	V obs	V Regressão	V RNA
Estrato 1	V obs		0,99	0,9914
	V Regressão	0,9900		0,9983
	V RNA	0,9914	0,9983	
Estrato 2	V obs		0,9931	0,9899
	V Regressão	0,9931		0,9976
	V RNA	0,9899	0,9976	
Estrato 3	V obs		0,954	0,9593
	V Regressão	0,954		0,9972
	V RNA	0,9593	0,9972	
Estrato 4	V obs		0,9585	0,9571
	V Regressão	0,9585		0,9979
	V RNA	0,9571	0,9979	

Com base no erro padrão da estimativa para estimar volume total com casca por meio de afilamento, as RNA resultaram em melhores estimativas, principalmente por apresentar menores tendências para estimar os diâmetros na parte superior da árvore. Como as duas técnicas não apresentam diferenças estatísticas com os dados observados, e se tratarem de duas metodologias complexas, optou-se para aplicação de RNA como a mais precisa para estimar o volume total com casca, quando utilizados dados de diâmetros e alturas ao longo do fuste.



#### **4. CONCLUSÕES**

- Para estimar o diâmetro ao longo do fuste por meio de regressão, o modelo de Garay (modelo 4) foi o mais aderente no estrato 1, nos demais estratos, o modelo de Hradetzky (modelo 2) teve superioridade.
- A rede neural artificial mais apropriada para estimar o diâmetro ao longo do fuste foi a RNA 17, com arquitetura MLP com 4 camadas intermediárias.
- Como as duas técnicas são complexas, e não tiveram diferenças estatísticas com os dados observados de diâmetro ao longo do fuste e volume, a RNA foi escolhida como melhor método para estimativa de diâmetros e volumes ao longo do fuste.

**APÊNDICE 1: PARÂMETROS AJUSTADOS PARA CADA ESTRATO PARA ESTIMAÇÃO DE ALTURA POR MEIO DE REGRESSÃO.**













<i>Modelo</i>	<i>Estrato</i>	<i>b0</i>	<i>b1</i>	<i>b2</i>
1	1	3,622	-11,469	-
	2	3,620	-9,884	-
	3	3,410	-7,569	-
	4	3,230	-6,521	-
	5	2,980	-6,484	-
	6	2,994	-6,375	-
	7	2,962	-9,622	-
	8	2,719	-6,564	-
	9	2,784	-8,251	-
	10	2,654	-5,980	-
	11	2,789	-8,560	-
2	1	1,621	0,474	-
	2	2,104	0,347	-
	3	1,881	0,376	-
	4	2,037	0,286	-
	5	1,135	0,501	-
	6	1,386	0,424	-
	7	0,364	0,704	-
	8	0,317	0,700	-
	9	-0,029	0,816	-
	10	0,506	0,626	-
	11	*0,146	0,749	-
3	1	4,198	-10,386	-11,216
	2	4,285	-5,542	-13,019
	3	3,868	-6,874	-6,321
	4	4,112	-5,483	-11,562
	5	3,649	-6,031	-6,267
	6	3,582	-4,821	-5,687
	7	3,460	-6,980	-4,756
	8	3,363	-4,843	-4,933
	9	3,235	-5,031	-3,598
	10	3,332	-4,929	-4,307
	11	3,484	-6,325	-4,690
4	1	2,397	0,425	-11,160
	2	3,437	0,193	-12,950
	3	2,482	0,339	-6,250
	4	3,114	0,236	-11,436
	5	1,896	0,456	-5,667
	6	2,361	0,309	-5,353
	7	1,544	0,502	-4,327
	8	1,460	0,510	-3,968
	9	1,294	0,532	-2,886
	10	1,484	0,506	-3,680
	11	1,434	0,553	-4,133


**APÊNDICE 2: PARÂMETROS AJUSTADOS PARA A REDUÇÃO EM 30 % E 60% NA ESTIMATIVA DE ALTURA. Continua...**

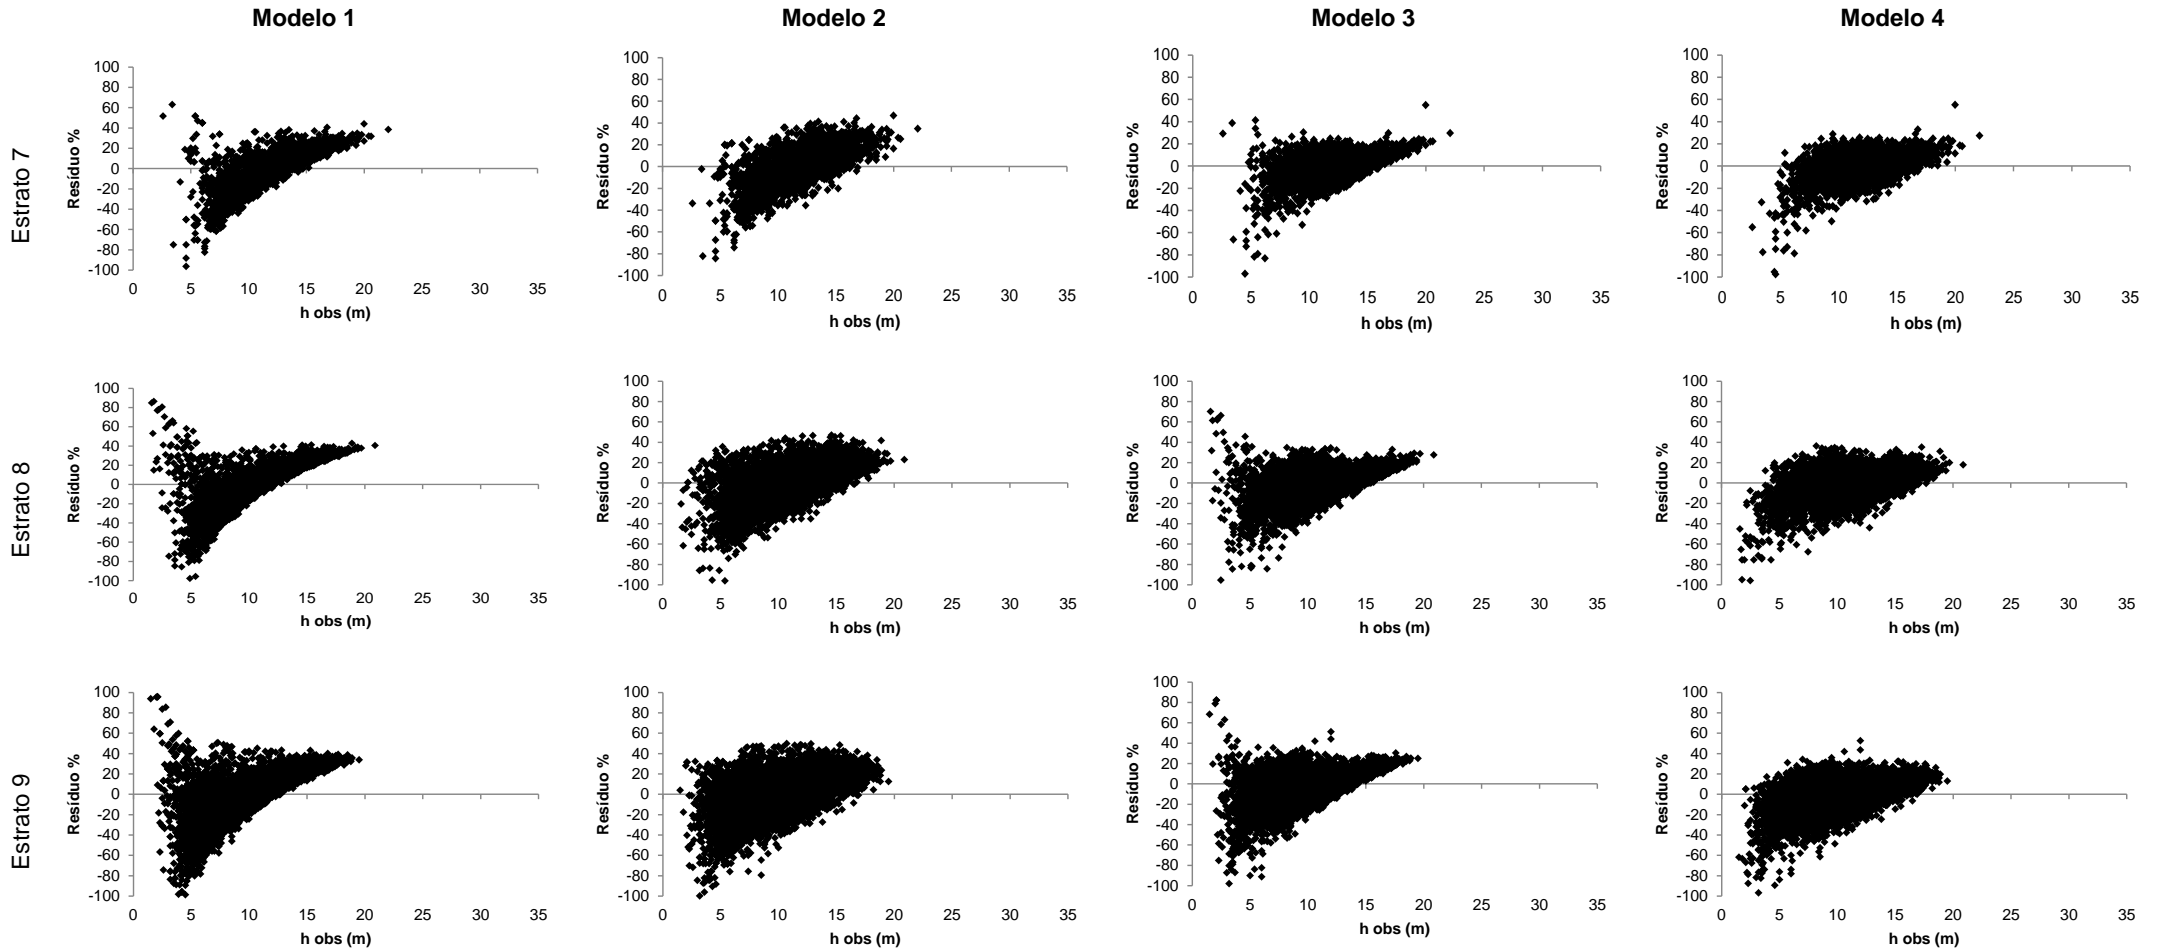
Modelo	Redução	Estrato	b0	b1	b2	
1	30%		1	3,604	-11,121	
			2	3,617	-9,409	
			3	3,404	-7,488	
			4	3,190	-5,586	
			5	2,996	-6,731	
			6	3,068	-7,994	
			7	2,995	-10,306	
			8	2,724	-6,661	
			9	2,779	-8,223	
			10	2,663	-5,895	
			11	2,774	-8,007	
2	30%		1	1,746	0,435	
			2	2,194	0,324	
			3	1,860	0,381	
			2	2,165	0,246	
			5	1,254	0,462	
			6	1,294	0,453	
			7	0,347	0,708	
			8	0,290	0,706	
			9	-0,055	0,823	
			10	0,435	0,658	
			11	0,127	0,765	
3	30%		1	4,227	-10,252	-11,869
			2	4,243	-5,655	-12,131
			3	3,858	-6,810	-6,251
			4	4,116	-4,768	-11,955
			5	3,656	-5,908	-6,364
			6	3,592	-5,187	-5,594
			7	3,467	-7,297	-4,672
			8	3,365	-4,878	-4,908
			9	3,238	-4,898	-3,640
			10	3,333	-4,736	-4,335
			11	3,484	-5,983	-4,763
4	30%		1	2,525	0,397	-11,830
			2	3,399	0,192	-12,135
			3	2,456	0,344	-6,173
			4	3,248	0,203	-11,742
			5	2,115	0,398	-6,043
			6	2,423	0,292	-5,389
			7	1,564	0,494	-4,298
			8	1,452	0,510	-3,914
			9	1,298	0,529	-2,869
			10	1,425	0,522	-3,543
			11	1,383	0,575	-4,112

**APÊNDICE 2: PARÂMETROS AJUSTADOS PARA A REDUÇÃO EM 30 % E 60% NA ESTIMATIVA DE ALTURA. Continuação**

Modelo	Redução	Estrato	b0	b1	b2
1	60%	1	3,552	-9,566	
		2	3,600	-8,883	
		3	3,449	-8,996	
		4	3,188	-5,620	
		5	3,026	-7,444	
		6	3,131	-9,533	
		7	3,047	-11,465	
		8	2,761	-7,294	
		9	2,783	-8,346	
		10	2,750	-7,207	
		11	2,962	-11,021	
2	60%	1	2,055	0,345	
		2	2,255	0,306	
		3	1,867	0,375	
		4	2,137	0,253	
		5	1,041	0,528	
		6	1,110	0,510	
		7	0,277	0,727	
		8	0,239	0,719	
		9	-0,135	0,846	
		10	0,426	0,660	
		11	0,112	0,768	
3	60%	1	4,145	-8,504	-11,401
		2	4,279	-6,145	-12,516
		3	3,923	-7,934	-6,677
		4	4,138	-4,634	-12,281
		5	3,672	-6,117	-6,402
		6	3,620	-6,246	-5,410
		7	3,471	-7,657	-4,554
		8	3,370	-4,922	-4,869
		9	3,242	-4,562	-3,729
		10	3,361	-5,588	-4,135
		11	3,510	-8,321	-4,052
4	60%	1	2,819	0,302	-11,227
		2	3,360	0,208	-12,489
		3	2,526	0,325	-6,411
		4	3,292	0,195	-11,973
		5	2,014	0,425	-5,917
		6	2,295	0,327	-5,228
		7	1,597	0,478	-4,212
		8	1,533	0,482	-3,923
		9	1,329	0,516	-2,844
		10	1,464	0,504	-3,456
		11	1,312	0,577	-3,754





**APÊNDICE 3: GRÁFICOS DE DISPERSÃO DOS RESÍDUOS PARA ESTIMAÇÃO DE ALTURA POR MEIO DE REGRESSÃO- DADOS DE AJUSTE.***Continua...***Modelo 1****Modelo 2****Modelo 3****Modelo 4****Estrato 1****Estrato 2****Estrato 3**

**APÊNDICE 3: GRÁFICOS DE DISPERSÃO DOS RESÍDUOS PARA ESTIMAÇÃO DE ALTURA POR MEIO DE REGRESSÃO- DADOS DE AJUSTE.****Continuação.**





**APÊNDICE 3: GRÁFICOS DE DISPERSÃO DOS RESÍDUOS PARA ESTIMAÇÃO DE ALTURA POR MEIO DE REGRESSÃO- DADOS DE AJUSTE.****Continuação.**

**APÊNDICE 3: GRÁFICOS DE DISPERSÃO DOS RESÍDUOS PARA ESTIMAÇÃO DE ALTURA POR MEIO DE REGRESSÃO- DADOS DE AJUSTE.****Conclusão.**

Estrato 10

**Modelo 1****Modelo 2****Modelo 3****Modelo 4**

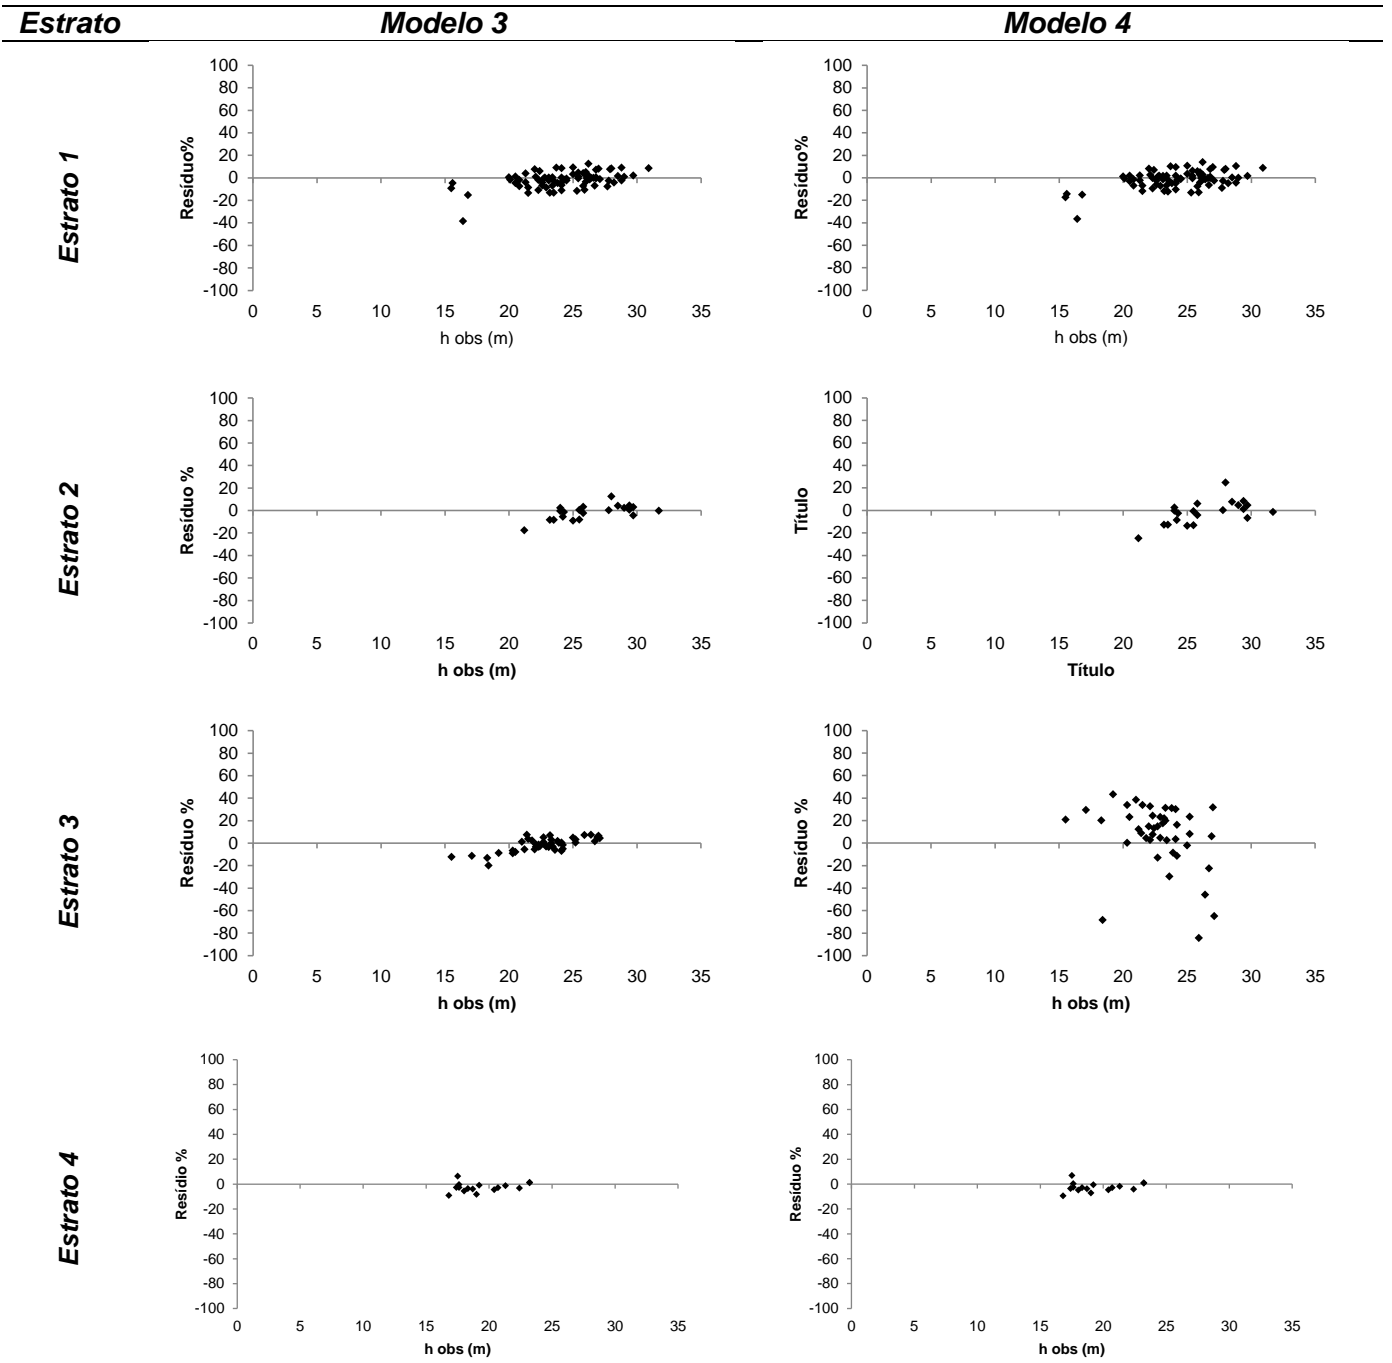
Estrato 11



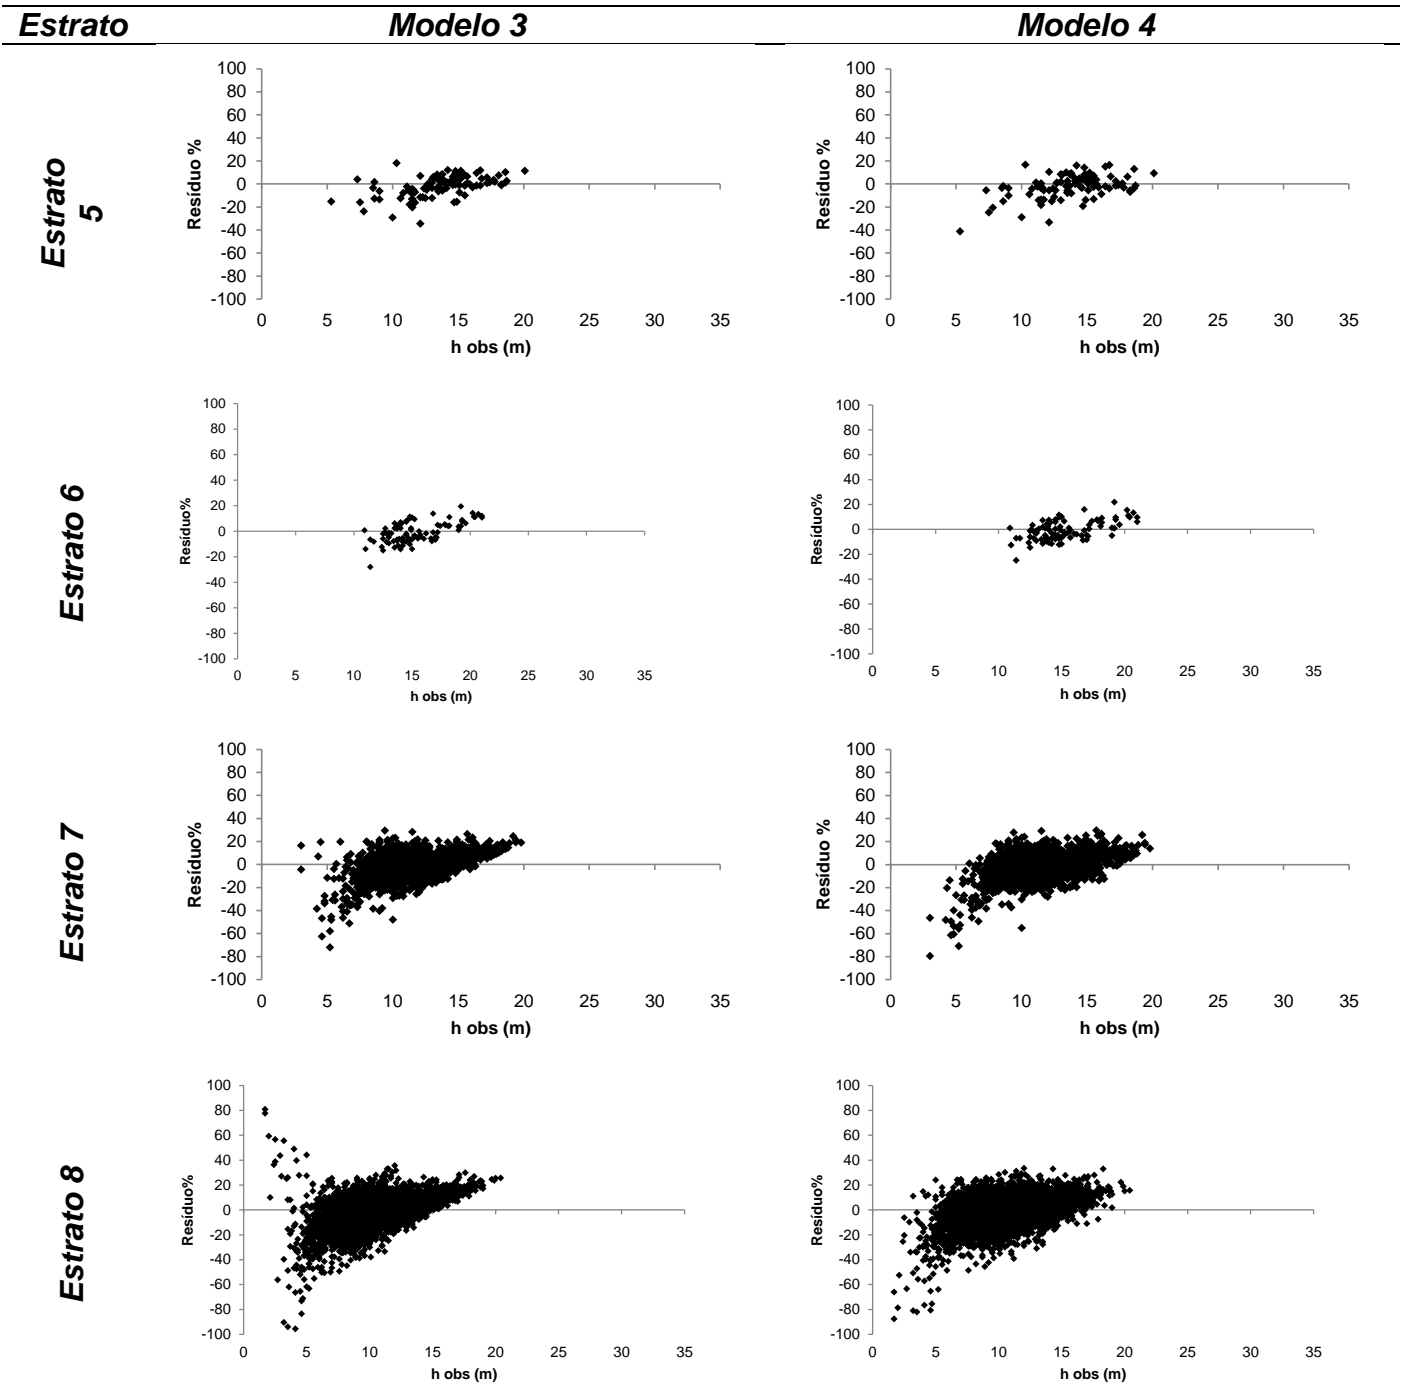


**APÊNDICE 4: GRÁFICOS DE DISPERSÃO DE RESÍDUOS PARA ESTIMAÇÃO DA ALTURA DOS DADOS DE VALIDAÇÃO UTILIZANDO OS DOIS MELHORES MODELOS DE REGRESSÃO.**

*Continua...*

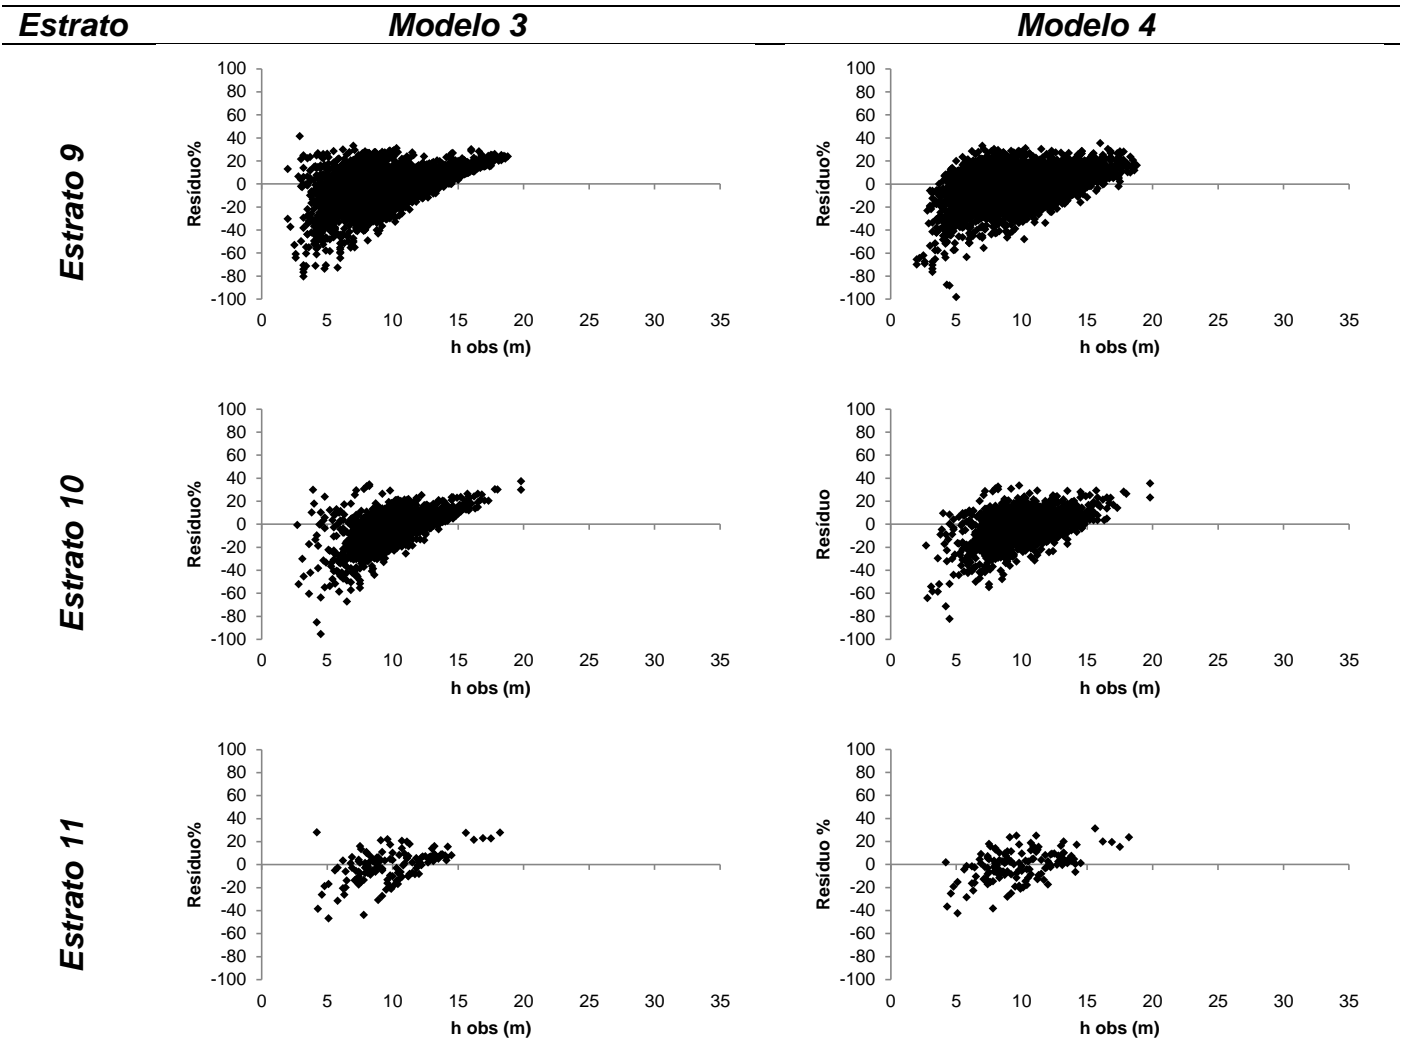











**APÊNDICE 4: GRÁFICOS DE DISPERSÃO DE RESÍDUOS PARA ESTIMAÇÃO DE ALTURA DOS DADOS DE VALIDAÇÃO UTILIZANDO OS DOIS MELHORES MODELOS DE REGRESSÃO.**  
*Continuação...*














**APÊNDICE 4: GRÁFICOS DE DISPERSÃO DE RESÍDUOS PARA ESTIMAÇÃO DE ALTURA DOS DADOS DE VALIDAÇÃO UTILIZANDO OS DOIS MELHORES MODELOS DE REGRESSÃO.**

*Continuação...*

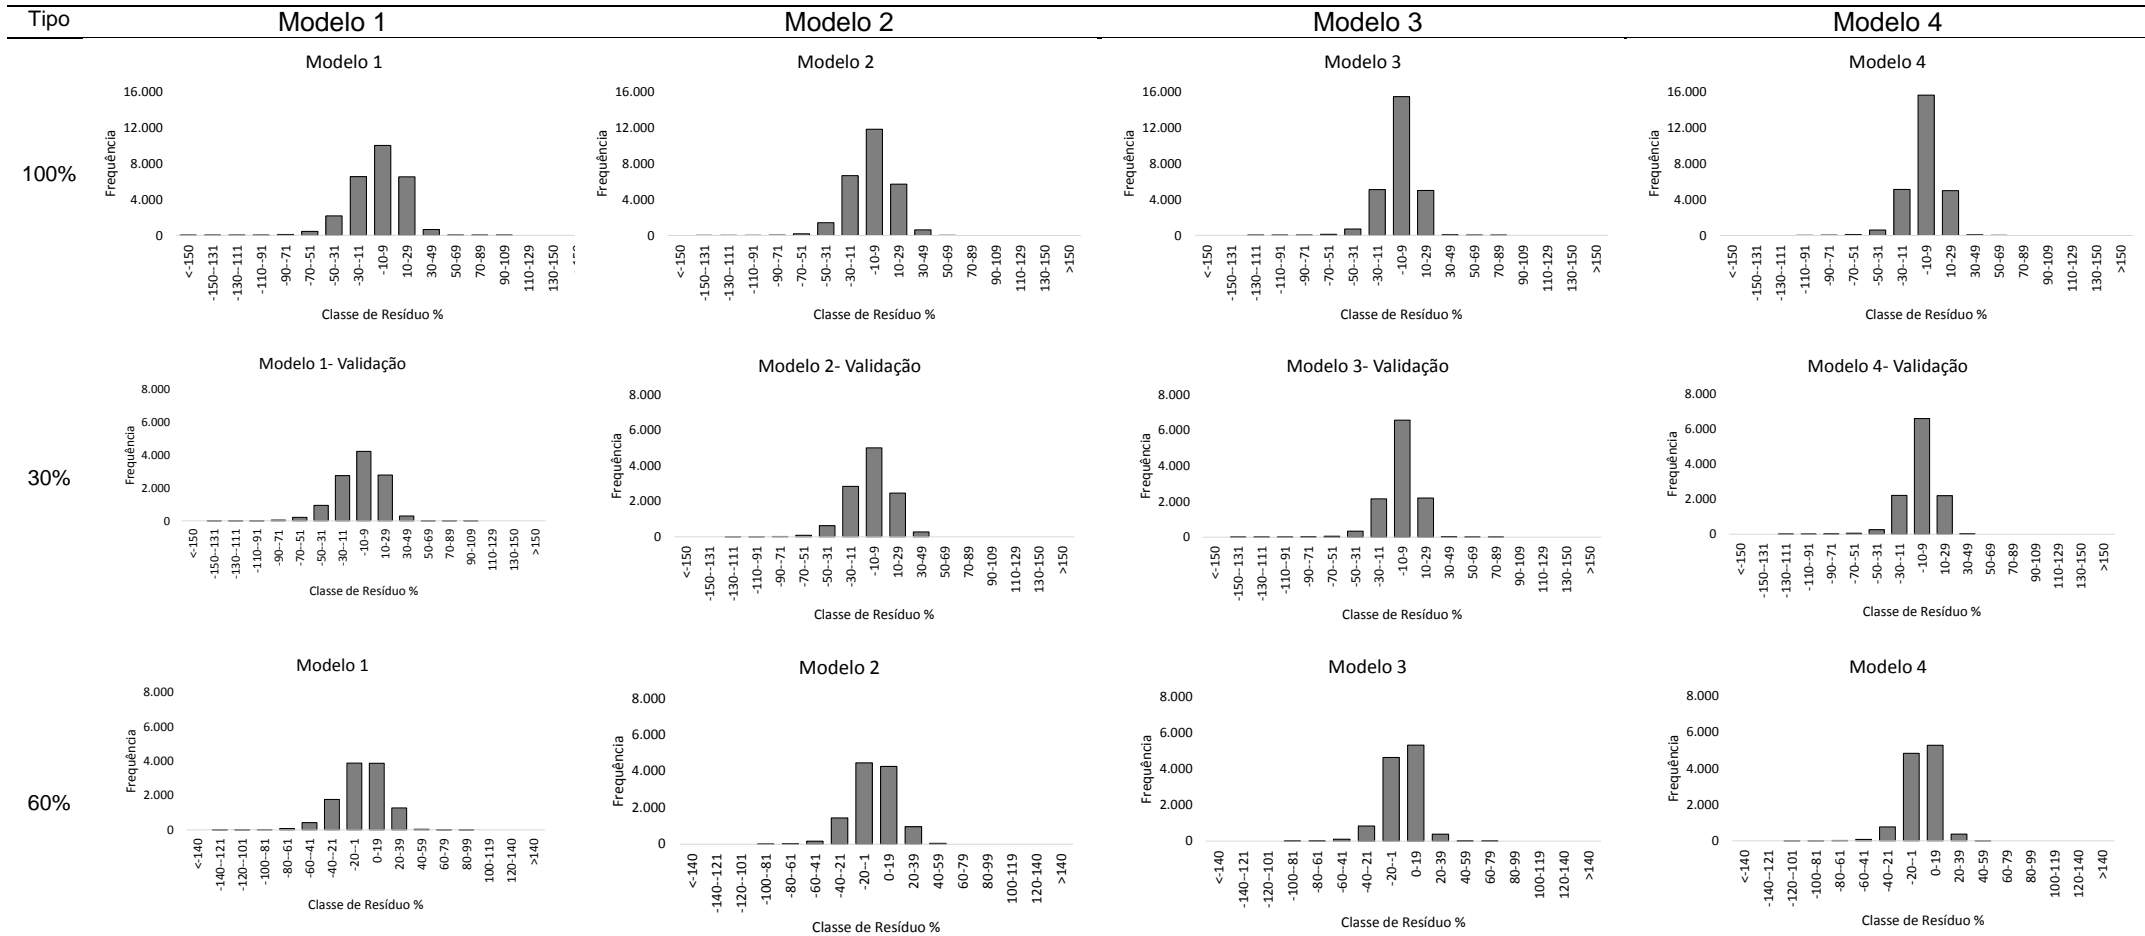


**APÊNDICE 5: GRÁFICOS DE DISPERSÃO DE RESÍDUOS PARA AS ESTIMATIVAS DE ALTURA COM RNA. Continua...****RNA3****RNA5****RNA10****RNA20****RNA 21****RNA22****RNA23****RNA24****RNA25**

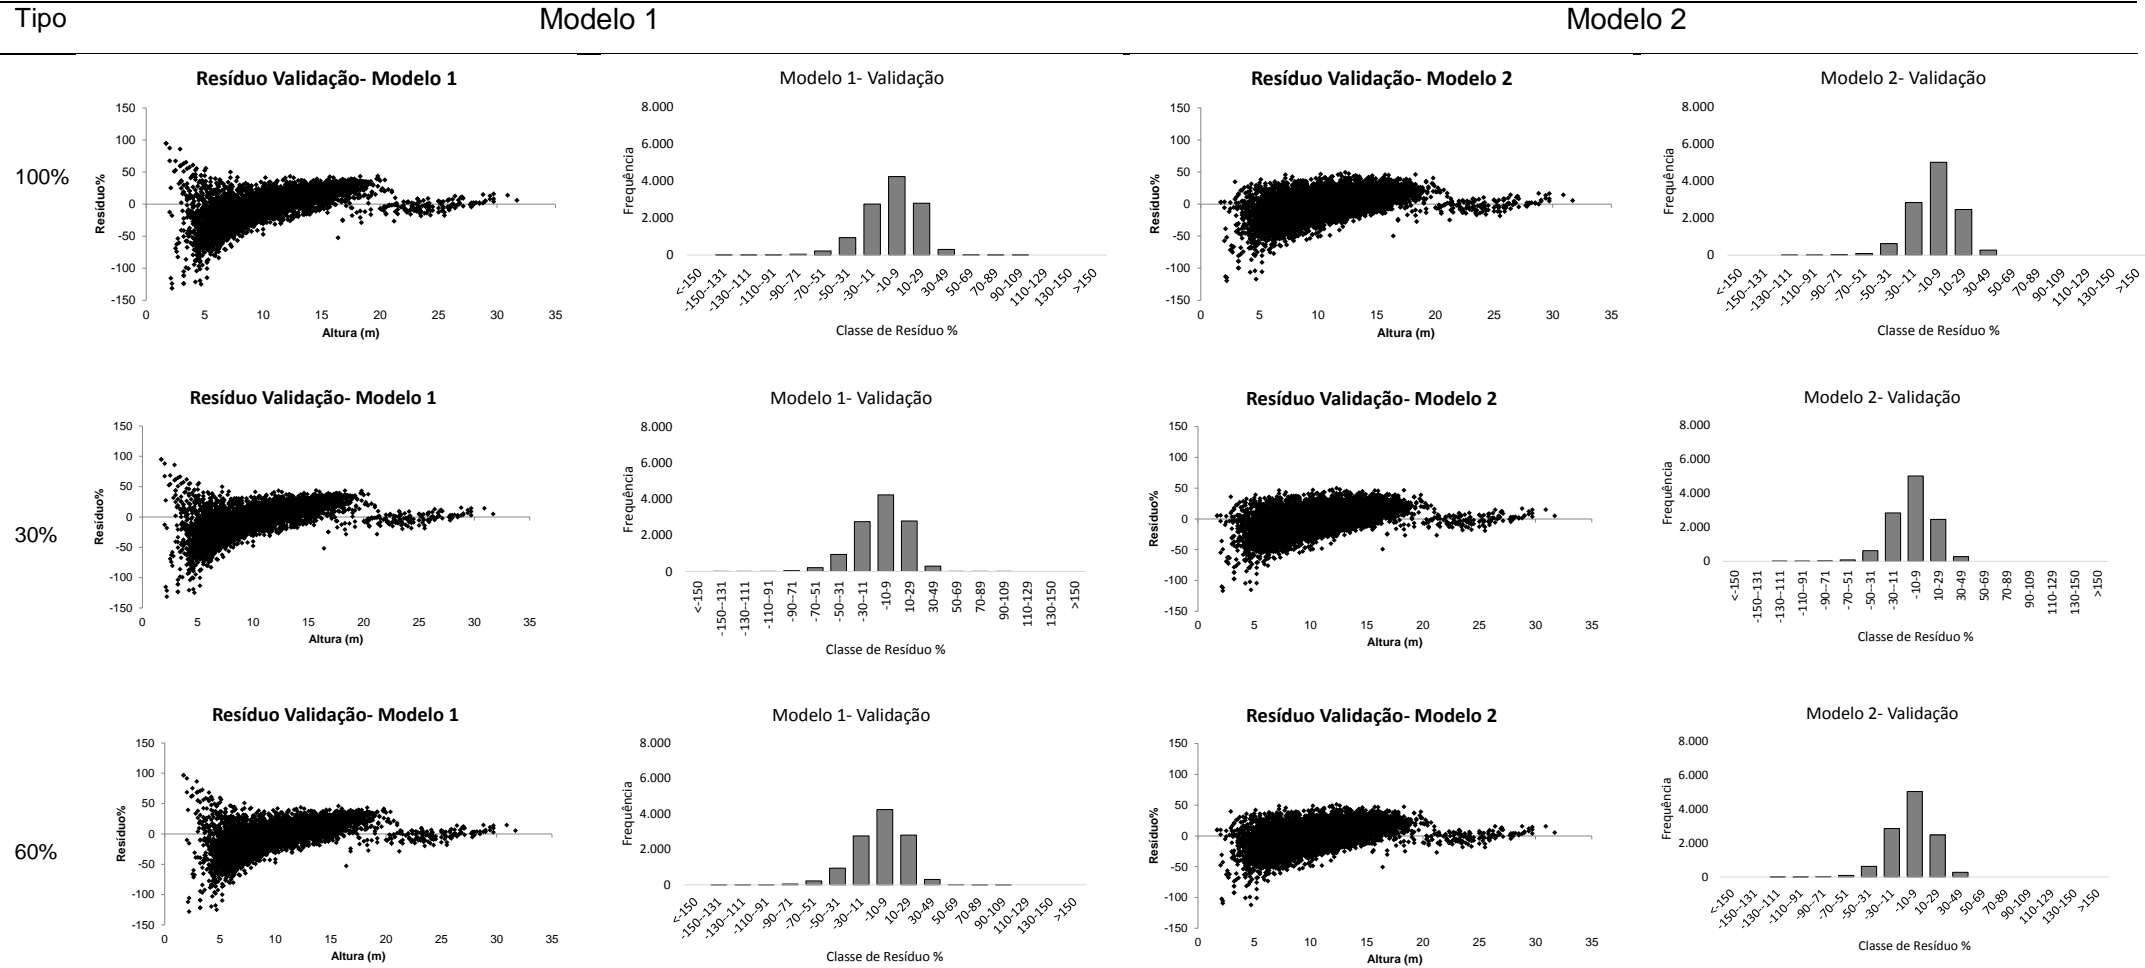
**APÊNDICE 5: GRÁFICOS DE DISPERSÃO DE RESÍDUOS PARA AS ESTIMATIVAS DE ALTURA COM RNA. Continuação...****RNA26****RNA29****RNA42****RNA47****RNA51****RNA52**

**APÊNDICE 5: GRÁFICOS DE DISPERSÃO DE RESÍDUOS PARA AS ESTIMATIVAS DE ALTURA COM RNA****RNA53****RNA54****RNA55****RNA56****RNA57**

**APÊNDICE 6: GRÁFICOS DE FREQUÊNCIA DE RESÍDUOS PARA AS ESTIMATIVAS DE ALTURA COM A BASE TOTAL DOS DADOS DE AJUSTE (100%) E REDUÇÃO EM 30% E 60% DAS MEDIÇÕES DE ALTURA.**

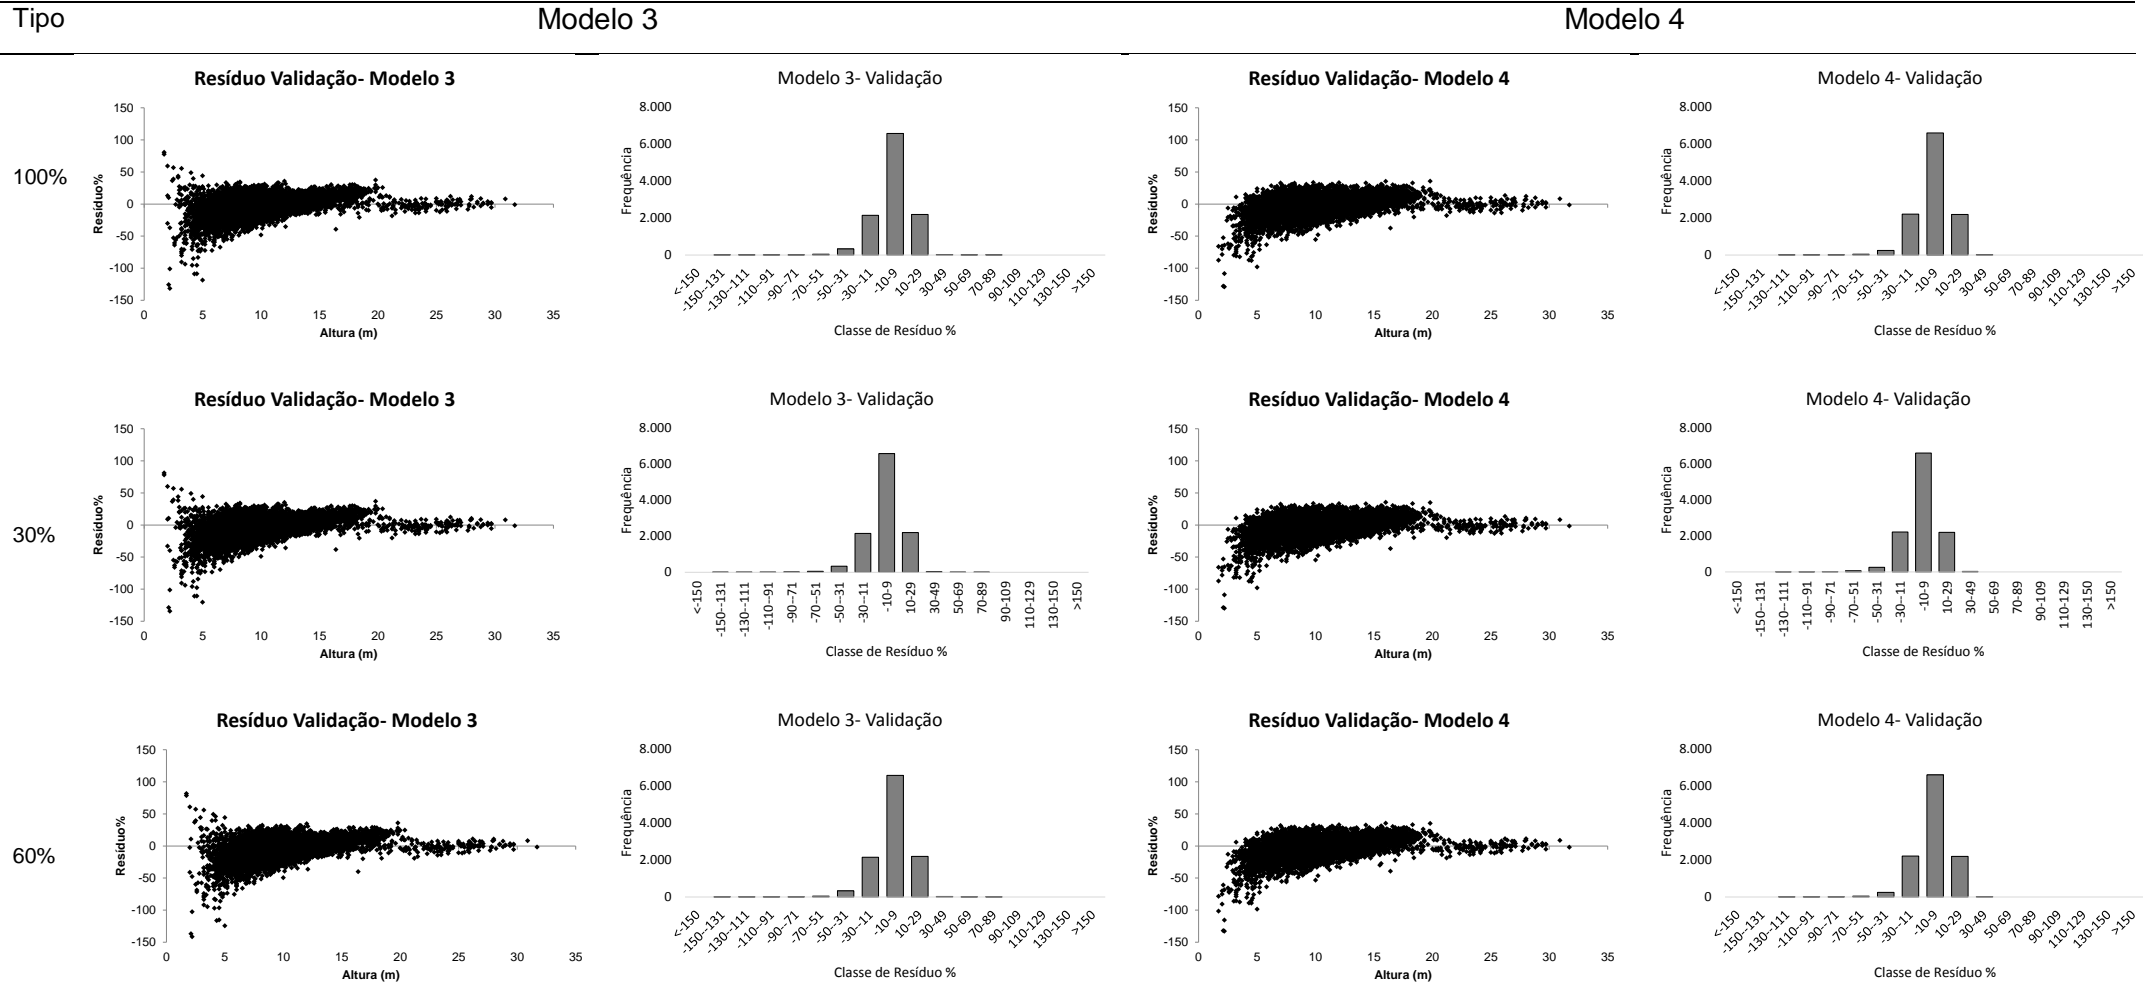


**APÊNDICE 6: GRÁFICOS DE DISPERSÃO DE RESÍDUOSE FREQUÊNCIA DE RESÍDUOS PARA AS ESTIMATIVAS DE ALTURA COM 100% DOS DADOS E REDUÇÃO EM 30% E 60% DAS MEDIÇÕES. APLICADOS AOS DADOS DE VALIDAÇÃO. Continua...**





















**APÊNDICE 6: GRÁFICOS DE DISPERSÃO DE RESÍDUOSE FREQUÊNCIA DE RESÍDUOS PARA AS ESTIMATIVAS DE ALTURA COM 100% DOS DADOS E REDUÇÃO EM 30% E 60% DAS MEDIÇÕES. APLICADOS AOS DADOS DE VALIDAÇÃO. Continuação**




**APÊNDICE 7: GRÁFICOS DE DISPERSÃO DE RESÍDUOS PARA ESTIMATIVA DE ALTURA POR MEIO DE RNA PARA OS DADOS DE AJUSTE REDUZINDO 30% DAS MEDIÇÕES DE ALTURA Continua...**

**RNA15****RMA20****RNA40****RNA43****RNA45****RNA46****RNA47****RNA48****RNA49****RNA50****RNA51****RNA52**


**APÊNDICE 7: GRÁFICOS DE DISPERSÃO DE RESÍDUOS PARA ESTIMATIVA DE ALTURA POR MEIO DE RNA PARA OS DADOS DE AJUSTE REDUZINDO 30% DAS MEDIÇÕES DE ALTURA Continua...**

**RNA53****RMA54****RNA55****RNA56****RNA57**


Rede 57- Dados de ajuste (30%)

**RNA58**


Rede 58- Dados de ajuste (30%)

**RNA59**













Rede 59- Dados de ajuste (30%)

**RNA60**





Rede 60- Dados de ajuste (30%)




**APÊNDICE 8: GRÁFICOS DE DISPERSÃO DE RESÍDUOS PARA ESTIMATIVA DE ALTURA PARA OS DADOS DE AJUSTE REDUZINDO 60% DAS MEDIÇÕES DE ALTURA Continua...**

**RNA 21****RNA22****RNA23****RNA24****RNA25****RNA26****RNA27****RNA28****RNA29****RNA30****RNA31****RNA32**


**APÊNDICE 8: GRÁFICOS DE DISPERSÃO DE RESÍDUOS PARA ESTIMATIVA DE ALTURA PARA OS DADOS DE AJUSTE REDUZINDO 60% DAS MEDIÇÕES DE ALTURA Continua...**

**RNA33****RNA34****RNA35****RNA36****RNA37**


Rede 37- Dados de ajuste (60%)

**RNA38**


Rede 38- Dados de Ajuste (60%)

**RNA39**

Rede 39- Dados de ajuste (60%)










**RNA40**










Rede 40- Dados de ajuste (60%)





**APÊNDICE 9: PARÂMETROS AJUSTADOS PARA A ESTIMAÇÃO DE VOLUME POR MEIO DE REGRESSÃO.**

<b>Estrato</b>	<b>Modelo</b>	<b>b0</b>	<b>b1</b>	<b>b2</b>
1	1	-0,013	0,001	
	2	-9,031	2,488	
	3	-9,239	1,816	0,809
	4	0,004	0,000	
2	1	-0,081	0,001	
	2	-8,943	2,473	
	3	-10,154	1,849	1,137
	4	-0,005	0,000	
3	1	-0,035	0,001	
	2	-8,230	2,262	
	3	-10,287	1,766	1,266
	4	0,014	0,000	
4	1	-0,093	0,001	
	2	-7,608	2,164	
	3	-9,093	1,866	0,789
	4	0,151	0,000	

**APÊNDICE 10: GRÁFICOS DE DISTRIBUIÇÃO DE RESÍDUO PARA ESTIMAÇÃO DE VOLUME POR MEIO DE RNA. Continua...****RNA9****RNA10****RNA11****RNA12****RNA13****RNA14****RNA18****RNA19****RNA20**

**APÊNDICE 10: GRÁFICOS DE DISTRIBUIÇÃO DE RESÍDUO PARA ESTIMAÇÃO DE VOLUME POR MEIO DE RNA. Continuação...****RNA21****RNA22****RNA23****RNA24****RNA25****RNA26****RNA27****RNA28****RNA29**




**APÊNDICE 10: GRÁFICOS DE DISTRIBUIÇÃO DE RESÍDUO PARA ESTIMAÇÃO DE VOLUME POR MEIO DE RNA.****RNA30****RNA5**

**APÊNDICE 11: PARÂMETROS AJUSTADOS POR ESTRATO PARA ESTIMAR O DIÂMETRO AO LONGO DO FUSTE POR MEIO DE REGRESSÃO**

<b>Estrato</b>	<b>Modelo</b>	<b>b0</b>	<b>b1</b>	<b>b2</b>	<b>b3</b>	<b>b4</b>	<b>b5</b>
1	1	1,385	-5,020	21,723	-50,204	51,785	-19,667
	2	8,911	-7,936	-0,380	-0,521		
	3	0,247	0,935	0,920	-1,009		
	4	2,050	0,197	0,993	0,034		
2	1	1,260	-4,368	18,932	-42,081	40,708	-14,432
	2	15,223	-14,343	-0,379	-1,973	1,543	
	3	0,123	0,952	0,877	-0,878		
	4	0,377	0,025	-827,469	-19,490		
3	1	1,217	-3,955	16,230	-35,512	34,128	-12,108
	2	14,703	-13,856	-0,305	-0,529		
	3	0,041	0,993	0,905	-0,895		
	4	0,358	0,018	-1014,106	-29,162		
4	1	1,196	-4,177	18,385	-39,098	35,748	-12,056
	2	5,158	-4,408	-0,135	-1,935	1,299	0,090
	3	0,331	0,925	0,789	-0,916		
	4	0,381	0,011	-1617,047	-43,046		


**APÊNDICE 12: GRÁFICO DE DISPERSÃO DE RESÍDUOS PARA ESTIMATIVA DO DIÂMETRO AO LONGO DO FUSTE POR MEIO DE MODELOS DE AFILAMENTO AJUSTADOS POR REGRESSÃO**




**APÊNDICE 13: GRÁFICO DE DISPERSÃO DE RESÍDUOS PARA ESTIMATIVA DO DIÂMETRO AO LONGO DO FUSTE POR MEIO DE RNA.**

Continua...


RNA 4




RNA 10




RNA 11




RNA 12




RNA 13




RNA 14




RNA15




RNA 16




RNA 17




RNA18



RNA 21




RNA22




**APÊNDICE 13: GRÁFICO DE DISPERSÃO DE RESÍDUOS PARA ESTIMATIVA DO DIÂMETRO AO LONGO DO FUSTE POR MEIO DE RNA.**

Continuação...


REDE 23





REDE 24



REDE 25




REDE 26




REDE 27


REDE 28



REDE 29



REDE 30



## REFERÊNCIAS

- ACERBI JÚNIOR, F.W. Definição de regimes de desbastes e poda economicamente ótimos para *Pinus taeda*., **Dissertação** (Mestrado em Engenharia Florestal). Universidade Federal de Lavras, Lavras, 177f., 1998.
- AHRENS, S.; HOLBERT, D. Uma função para forma de tronco e volume de *Pinus taeda* L. In: **Boletim de pesquisa florestal, unidade regional de pesquisa florestal Centro-Sul**, EMBRAPA, 03, p. 37-68, 1981.
- AZEVEDO, C. P. de, MUROYA, K., GARCIA, L. C., LIMA, R. M. B. de, MOURA, J. B. de, NEVES, E. J. M. Relação hipsométrica para quatro espécies florestais em plantio homogêneo e em diferentes idades na Amazônia Ocidental. **Boletim de Pesquisa Florestal**, Colombo, n. 39, p. 5-29, jul./dez. 1999
- BALDWIN JR, V. C.; FEDUCCIA, D. P. Compatible Tree-volume and upper-stem diameter equations for plantation Loblolly Pines in the West Gulf region. *South. Journal Applied Forestry*, v. 15, n. 2, p. 92-97, 1991.
- BARROS, D.A.; MACHADO, S.A.; JÚNIOR, F.W.A.; SCOLFORO, J.R.S. 2002. Comportamento de modelos hipsométricos tradicionais e genéricos para plantações de *Pinus oocarpa* em diferentes tratamentos. **Boletim de Pesquisa Florestal**, Colombo, n.45, p.3-28.
- BARTOSZECK, A.C.P.S. et al. Modelagem da relação hipsométrica para bracingais da região metropolitana de Curitiba-PR. **Floresta**, v.32, n.2, p.189-204, 2002.
- BATISTA, J. L. F.; COUTO, H. T. Z. do; MARQUESINI, M. Desempenho de modelos de relações hipsométricas: estudo de três tipos de floresta. *Scientia Forestalis*, n.60, p.149-163, dez. 2001.
- BAZOOK, M., STACEY, D.A., CUI, C., HARAUZ, G., 1994. A hierarchical artificial neural network system for the classification of cortical cells. In: *Proceedings of the IEEE International Conference on Neural Networks*. IEEE, Orlando, FL, pp. 3525-3529.
- BELENKY, G., SING, H.C., THOMAS, M.L., SHAHAM, Y., BALWINSKI, S., THORNE, D.R., REDMOND, D.P. AND BALKIN, J.T., 1994. Discrimination of rested from sleep-deprived EEG in awake normal humans by artificial neural network. In: *Proceedings of the IEEE International Conference on Neural Networks*.
- BIGING, G. S. Taper equations for second mixed-conifers of Northean California. **Forest Science**, v.30, n.4, p.1103-1117, 1984.
- BINOTI, M. L. M. S. Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto. 54 f. **Dissertação** (Mestrado em Ciência Florestal). Universidade Federal de Viçosa, Viçosa, 2010.

BINOTI, M. L. M. S. Emprego de Redes Neurais Artificiais em Mensuração e Manejo Florestal. 130f. **Tese**. (Doutorado em Ciência Florestal). Universidade Federal de Viçosa, Viçosa, 2012.

BINOTI, D. H. B. B., BINOTI, M. L. M. S. Redes Neurais Artificiais Aplicadas à Ciência Florestal. Instituto de Inovação em Engenharia e Meio Ambiente-AMBINOVA: **Material de Apoio**. Viçosa, Minas Gerais. 2014. 83 p

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, Rev. Árvore, Viçosa, v.37, n.4, Jul/Ag 2013

BISHOP, C.M. **Neural networks for pattern recognition**. New York, Oxford University Press. 1995. 482 p

BLAZEK, M., PANCOSKA, P. AND KEIDERLING, T.A., Backpropagation neural network analysis of circular dichroism spectra of globular proteins. **Neurocomputing**, v. 3, p. 247-257, 1991.

BRAGA, A. de P.; CARVALHO, A. P. de L. F. de; LUDEMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. Rio de Janeiro; Editora LTC, 2000, 262 p.

BULLINARIA, J.A. Introduction to Neural computation. Notas de aula. 2009. Disponível em: <http://www.cs.bham.ac.uk/~jxb/inc.html>. Acesso em: 02 de janeiro de 2016.

CALDEIRA, M. V. W., SCHUMACHER, M. V., SCHEEREN, L. W., WATZLAWICK, L. F., Relação hipsométrica para *Araucaria angustifolia* (Bert.) o. Ktze na região oeste do estado do Paraná. **Revista Acadêmica: ciências agrárias e ambientais**, Curitiba, v.1, n.2, p. 79-88, abr./jun. 2003

CAMPOS, J. C. C., LEITE, H. G. **Mensuração florestal: perguntas e respostas**. 3. ed. Viçosa, MG: UFV, 548 p., 2009.

CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal: perguntas e respostas**. 4. ed. Viçosa: Editora UFV, 605 p, 2013.

CASTELLANOS, A., BLANCO, A. M., PALENCIA, V. applications of radial basis neural networks for area forest. **International Journal "Information Theories & Applications"**, v.14, p 218- 222, 2007

CARDOSO, D. J. Avaliação da influência dos fatores sítio, idade, densidade e posição sociológica na relação hipsométrica para *Pinus taeda* nas regiões central e sudoeste do estado do Paraná. 1989. 106f. **Dissertação** (Mestrado em Engenharia Florestal) – Universidade Federal do Paraná, Curitiba, 1989

CASTRO, R. V. O. **Modelagem do crescimento em nível de árvores individuais utilizando redes neurais e autômatos celulares**. 80f. Tese (Doutorado em Ciência Florestal). Universidade Federal de Viçosa, Viçosa, 2011

CHAVES E CARVALHO, S. P., RODRIGUEZ, L. C. E., CALEGARIO, N., SAVIAN, T. V., LIMA, M. P., SILVA, C. A., MENDONÇA, A. R., NICOLETTI, M. F. Modelagem não linear mista para descrever o afilamento de árvores clonais de *Eucalyptus* sp. **Scientia Forestalis**, Piracicaba, v. 42, n. 104, p. 605-614, dez. 2014

CORNE, S.A., CARVER, S.J., KUNIN, W.E., LENNON, J.J., VAN HEES, W.W.S. Predicting forest attributes in southeast Alaska using artificial neural networks. **Forest Science**. v.50 (2), p. 259–276, 2004.

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

DEMAERSCHALK, J. P. Converting volume equations to compatible taper equations. **Forest Science**, v.18, n.3, p.241-245,1972.

DIAMANTOPOULOU, M. J. Artificial neural networks as an alternative tool in pine bark volume estimation. **Computers and Electronics in Agriculture**, v. 48, p 235–244, 2005.

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 5, p. 306-315, 2009.

DIAMANTOPOULOU, M, J. Filling gaps in diameter measurements on standing tree boles in the urban forest of Thessaloniki, Greece. **Environmental Modelling & Software**. v 25, p. 1857-1865, 2010

DIAMANTOPOULOU, M.J. Assessing a reliable modeling approach of features of trees through neural network models for sustainable forests. **Sustainable Computing: Informatics and Systems**. V. 2, p.190– 197, 2012

FAUSETT, L., **Fundamentals of neural networks architectures**. Algorithms and Applications. Prentice Hall, EUA, 1994. 461p

FERNEDA, E. Redes neurais e sua aplicação em sistemas de recuperação de informação. **Ci. Inf.**, v. 35, n. 1, p. 25-30, jan./abr, 2006.

FERREIRA, S. O. **Estudo da forma do fuste de *Eucalyptus grandis* e *Eucalyptus cloeziana***. 1999. 132p. Dissertação (Mestrado em Engenharia Florestal) – Universidade Federal de Lavras, Lavras, 1999.

FERREIRA R.A. **Análise genética e seleção em testes dialélicos de *Pinus taeda* L.** 220f. Tese (Doutorado em Engenharia Florestal). Universidade Federal do Paraná, Curitiba, 2005.

FIELDING, A.H., 1999. An introduction to machine learning methods. In: Fielding, A.H. (Ed.), *Machine Learning Methods for Ecological Applications*. Kluwer, Dordrecht, pp. 1–35.



FIGUEIREDO FILHO, A., OLIVEIRA, C.G., MOURA, J.B. et al. Conservação de equações de volume em equações de forma compatíveis para *Pinus elliottii*. In: Congresso Florestal Panamericano, 1., Congresso Florestal Brasileiro, 7., 1993. Curitiba. **Anais...** Curitiba: SBS/SBEF, p. 501-504, 1993.

FIGUEIREDO FILHO, A.; BORDERS, B. E.; HITCH, K. L. Taper equations for *Pinus taeda* in Southern Brazil. **Forest Ecology and Management**, n. 83, p. 39-46, 1996.

FINGER, C.A.G. **Fundamentos de biometria florestal**. Santa Maria. 1992. 269p.

FISCHER, F.; SCOLFORO, J. R. S.; ACERBI JUNIOR, F. W.; MELLO, J. M.; MAESTRI, R. Exatidão dos modelos polinomiais não segmentados e das razões entre volumes para representar o perfil do tronco de *Pinus taeda*. **Ciência Florestal**, v. 11, n. 1, p. 167-188, 2001.

GARCIA E. L., GUINDEO C., A., PALACIOS P. **Maderas de Coníferas: anatomia de gêneros**. Madrid: Fundación conde Del Valle de Salazar. 349p. 1996.

GARAY, L. Tropical forest utilization system. VIII. A taper model for entire stem profile including buttressing. Seattle: Coll. **Forest. Resour.**, Inst. Forest Prod. Univ. Wash., 64 p, 1979. (Contrib. 36).

GRAY, H.R. **The form and taper of forest-tree stems**. Imperial Forestry Institute, University of Oxford, p.78.1956.

GEVREY, M., DIMOPOULOS, I., LEK, S. Review and comparison of methods to study the contribution of variables in artificial neural network models. **Ecological modelling**. 160, 49–264, 2003

GOODMAN, P.H., 1996. NevProp Software, Version 3. University of Nevada, Reno, NV Em: <http://brain.unr.edu/index.php>. Acessado em: 02 de janeiro de 2016

GORGENS, E. B. Estimacão do volume de árvores utilizando redes neurais artificiais. 84f. **Dissertação** (Mestrado em Ciência Florestal). Universidade Federal de Viçosa, Viçosa, 2006.

GORGENS, E. B., LEITE, H. G., SANTOS, H. N. GLERIANI, J. M. Estimacão do volume de árvores utilizando redes neurais artificiais. **Rev. Árvore**, v.33, n.6, p.1141-1147, 2009.

GONÇALVES, M., LEMES, M. R. JUNIOR, A.D.P. Redes Neurais artificiais: Noções básicas. **Phychiatry online Brasil**. Fev. 2005. v.2, n. 2. p

GUAN, B.T., GERTNER, G. Modeling red pine tree survival with an artificial neural network. **Forest Science**. V. 37, p. 1429–1440, 1991.

HAYKIN, S. **Neural networks: a comprehensive foundation**. Ontario, Prentice Hall International, 1994. 696 p

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

HOANG, H., RECKNAGEL, F., MARSHALL, J., CHOY, S. Predictive modelling of macroinvertebrate assemblages for stream habitat assessments in Queensland (Australia). **Ecological Modelling**. v.195, p 195–206, 2001

HOPTROFF, R.G. The principles and practice of time series forecasting and business modelling using neural nets. **Neural Computing & Applications**, v.1, p. 59-66, 1993

HOSOKAWA, R. T.; MOURA, J. B.; CUNHA, U. S. **Introdução ao manejo e economia de florestas**. Curitiba: UFPR, 1998. 162 p.

HRADETZKY J. Analyse und interpretation statistischer abhängigkeiten. (Biometrische Beiträge zu aktuellen forschungs projekten). Baden: Württemberg Mitteilungen der FVA, Helf 76, 1976. 146p.

HUSCH, B.; MILLER, C. I.; BEERS, T. W. **Forest Mensuration**. 3a ed., John Wiley & Sons. New York: 1982.

HUSCH, B.; MILLER, C.I.; BEERS, T.W. **Forest inventory**. Malabar: Krieger Publishing Company, 402p., 1993.

HUSCH, B., **Forest Mensuration and Statistics**. New York: The Ronald Press Company, 1963, 474p.

IBÁ- **Anuário Estatístico da Industria Brasileira de Árvores**- Brasília, 2014. p. 99. Acessado em 13 dez. 2014. Disponível em: [www.iba.org](http://www.iba.org)

IBÁ- **Anuário Estatístico da Industria Brasileira de Árvores**- Brasília, 2016. p. 96. Acessado em 12 set. 2016. Disponível em: [www.iba.org](http://www.iba.org)

IMANÃ ENCINAS, J.; SILVA, G. F. da; PINTO, J. R. R. Idade e crescimento das árvores. **Comunicações técnicas florestais**, Brasília, UFB, Departamento de Engenharia Florestal, v.7, n.1, 2005. ISSN 1517-1922. 43p.

KOZAK, A.; MUNRO, D. D.; SMITH, J. H. G. Taper functions and their application in Forest inventory. **Forestry Chronicle**, v. 45, n. 4, p. 278-283, 1969.

KER, J.; SMITH, J. Sampling for height-diameter relationships. *Journal os forestry*, v.55, n.3, p.205-207, 1957.

KROGH, A. What are artificial neural networks? **Nature biotechnology**. v. 26, n 2, p 195-197, 2008

KRONKA, F.J.N.; BERTOLANI, F.; PONCE, R.H. **A cultura do Pinus no Brasil**. São Paulo: Sociedade Brasileira de Silvicultura, 156p, 2005.

LARSON, P. R. **Stem form development of forest trees**. Washington: [s.n.], 1963. 42 p. (Forest Science Monography, 5).

LEAL, F. A., MIGUEL, E. P., MATRICARDI, E. A. T., PEREIRA, R. S. Redes neurais artificiais na estimativa de volume em um plantio de eucalipto em função de fotografias hemisféricas e número de árvores. **Rev. Bras. Biom.**, São Paulo, v.33, n.2, p.233-249, 2015

LEDUC, D.J., MATNEY, T.G., BELLI, K.L., BALDWIN, V.C., 2001. Predicting diameter distributions of longleaf pine plantations: a comparison between artificial neural networks and other accepted methodologies. **USDA Forest Service**, Southern Research Station 025, Asheville, NC.

LEITE, H. G.; ANDRADE, V. C. L. Um método para condução de inventários florestais sem o uso de equações volumétricas. **Revista Árvore**, v.26, n.3, p.321-328, 2002.

LEITE, H. G.; ANDRADE, V. C. L. Importância das variáveis altura dominante e altura total em equações hipsométricas e volumétricas. **Rev. Árvore**, v.27, n.3, p.301-310, 2003.

LEK-ANG, S., DEHARVENG, L., LEK, S., Predictive models of collembolan diversity and abundance in a riparian habitat. **Ecological Modelling**. v. 120 (2–3), p. 247–260, 1999

LEK, S., DELACOSTE, M., BARAN, P., DIMOPOULOS, I., LAUGA, J., AULAGNIER, S. Application of neural networks to modelling nonlinear relationships in ecology. **Ecological Modelling**, v. 90, p. 39-52, 1996

LEK, S., BELAUD, A., BARAN, P., DIMOPOULOS, I., DELACOSTE, M. Role of some environmental variables in trout abundance models using neural networks. **Aquatic. Living Resource**, v.9, p. 23–29, 1996.

LEK, S., GUÉGAN, J.F. Artificial neural networks as a tool in ecological modelling, an introduction. **Ecological Modelling**, v. 120, p. 65–73, 1999

LERUER B. Feature selection and chromosome classification using a multilayer perceptron neural network. **In: Proceedings of the IEEE International Conference on Neural Networks**. IEEE, Orlando, FL, pp. 3540-3545., Orlando, FL, pp. 3521-3524., 1994

LIMA, F. S. Análise de funções de *Taper* destinadas à avaliação de multiprodutos de árvores de *Pinus elliottii*: 1986. 96 f. **Dissertação** (Mestrado em Ciência Florestal). Programa de Pós-Graduação em Ciência Florestal, Universidade Federal de Viçosa, Viçosa, 1986.

LIU, C., ZHANG, L., DAVIS, C.J., SOLOMON, D.S., BRANN, T.B., CALDWELL, L.E. Comparison of neural networks and statistical methods in classification of ecological habitats using FIA data. **Forest Science**, v 49 (4), p. 619–631, 2003

LOETSCH, F.; ZÖHRER, F.; HALLER, K. E. **Forest inventory**. Reinbek: Federal Research Organization for Forestry and Forest Products. 469p. v. 2.1973

LOKE, E. **Introduction to artificial neural networks in urban hydrology**. 47 p. 1995

LOPES, P. F., TEIXEIRA, T. R., OLIVEIRA NETO, R. R., MAIA, H. M., COSTA, C. B., FERNANDES, G. F. S., FARDIN, L. P., BINOTI, D. H. B. Aplicação de redes neurais artificiais para estimativa de produção florestal utilizando imagens Landsat. VIII simpósio de pós graduação em ciências florestais, Recife- PE. Acesso em: Setembro/2016; <http://dx.doi.org/10.12702/VIII.SimposFloresta.2014.8-528-1>

LUSK, J.J., GUTHERY, F.S., DEMASO, S.J. Northern bobwhite (*Colinus virginianus*) abundance in relation to yearly weather and long-term climate patterns. **Ecological Modelling**. v. 146, p. 3–15, 2001

MACHADO, S. A.; BAILEY, R. L.; BASSO, S. F.; BEVILACQUA JUNIOR, V. G. Análise do comportamento da relação hipsométrica com respeito à idade para plantações de *Pinus elliotti* no Paraná. **Revista Cerne**, Lavras, v.1, n. 1, p. 5-12, 1994.

MACHADO, S. A.; MELLO, J. M.; BARROS, D. A. Comparação entre métodos para avaliação de volume total de madeira por unidade de área, para o pinheiro do paraná, na região sul do Brasil. **Revista Cerne**, v.6, n.2, p.55 – 66, 2000.

MACHADO, S.A., CONCEIÇÃO, M. B., FIGUEIREDO, D. J. Modelagem do volume individual para diferentes idades e regimes de desbaste em Plantios de *Pinus oocarpa*. **Rev. Ciências Exatas e Naturais**, Guarapuava, v. 4, n. 2, p.185-197, jul-dez, 2002

MACHADO, S. A.; URBANO, E.; CONCEIÇÃO, M.B; FIGUEIREDO FILHO, A.; FIGUEIREDO, J.D. Comparação de modelos de afilamento do tronco para diferentes idades e regimes de desbaste em plantações de *Pinus oocarpa* Schiede. **Pesquisa Florestal Brasileira**, Colombo, PR, n.48, p. 41-64, 2004.

MACHADO, S. A.; FIGUEIREDO FILHO, A. **Dendrometria**. 2a ed. Guarapuava, Paraná: Editora Unicentro, 316 p 2006.

MACHADO, S.A. et al. Comportamento da relação hipsométrica de *Araucaria angustifolia* no capão da Engenharia Florestal da UFPR. **Pesquisa Florestal Brasileira**, n.56, p.5-16, 2008.

MAIER, H.R., DANDY, G.C., BURCH, M.D., Use of artificial neural networks for modelling cyanobacteria *Anabaena* spp. in the River Murray, South Australia. **Ecological Modelling**. v105 (2–3), p. 257–272, 1998.

MARCHIORI, J. N. C. **Dendrologia das gimnospermas**. Santa Maria: Ed. UFSM, 1996. 158 p.

MANEL, S., DIAS, J.-M., ORMEROD, S.J. Comparing discriminant analysis, neural networks and logistic regression for predicting species distributions: a case study with a Himalayan river bird. **Ecological Modelling**. v. 120, p. 337–347, 1999.

MATTOS, P. P.; BRAZ, E. M.; BERNDT, E. J.; OLIVEIRA, Y. M. M. **Equação de volume para araucárias centenárias da Reserva Florestal Embrapa/Epagri**. Colombo: Embrapa Florestas, 2010. 4 p. (Embrapa Florestas. Comunicado técnico, 256).

MAX, T. A.; BURKHART, H.E. Segmented polynomial regression applied to taper equations. **Forest Science**, Washington, v.22, n.3, p.283-289, Sept, 1976.

MCCULLOCH S.; PITTS, W. A logical calculus of ideas imanente in nervous activity. **Bulletin of Mathernatical Biophysics**, v. 5, p. 115-133, 1943

MENDONÇA, A. R. **Avaliação de uma Metodologia para Otimização do Volume de Toras Comerciais de *Eucalyptus* sp. em Função da Qualidade do Fuste**. 2006. 91 p. Dissertação (Mestrado em Produção Vegetal) - Universidade Federal do Espírito Santo, Alegre, 2006

MIGUEL, E.P. Avaliação biométrica e prognose da produção de *Eucalyptus urophylla* (S.T. Blake) na região norte do estado de Goiás. 2009. 165p. **Dissertação** (Mestrado em Engenharia Florestal) - Universidade Federal do Paraná.

MINSKY, M.; PAPERT, S. 1969. **Perceptrons**: an introduction to computacional geometry. MIT Presse, Massachusetts. 308 p.

MIROV, N. T. **The Genus Pinus**. New York: Ronald Press Company, 1967. 602p.

MÔRA, R., SILVA, G. F., GONÇALVES, F. G., SOARES, C. P. B., CHICHORRO, J. F., CURTO, R. A. Análise de diferentes formas de ajuste de funções de afilamento. **Scientia Forestalis**, Piracicaba, v. 42, n. 102, p. 237-249, jun. 2014

MORAES NETO, S. P. Estimativa do volume de *Pinus caribaea var hondurensis* no Cerrado do Distrito Federal, DF. Boletim de Pesquisa e Desenvolvimento. **Boletim de Pesquisa e Desenvolvimento**. Embrapa Cerrados, Planaltina, DF, n 231, p. 16, 2009

NARENDRA, K. AND PARTHASARATHY, K., 1990. Identification and control of dynamical systems using neural networks. Disponível em <http://www.tnnls.org/tnnls/>. Acesso em: 3 de janeiro de 2016

NICOLAS, J.M., LEMER, A. AND LEGITIMUS, D. 1989. Identification automatique de bruits impulsifs en acoustique sous-madne par réseaux multi-couches. **In**: Neuro-N~mes'89, International Workshop Neural Networks and their Applications, N~mes (France), 13-16 November 1989. EC2, Nanterre, pp. 269-278.

OLDEN, J.D., An artificial neural network approach for studying phytoplankton succession. **Hydrobiology**, v. 436, p 131–143, 2000.

OLIVEIRA, M. F. de.; MATTOS, P. P. de; BRAZ, E. M.; ROSOT, M. A. D.; ROSOT, N. C.; SANTOS, W. C. **In**: Equação de volume para um plantio de *Araucaria angustifolia* em Rio Negro, PR. Colombo: Embrapa Florestas, il. (Embrapa Florestas. Comunicado técnico, 275), 2011. 4 p.

OLIVEIRA, M. L. R., LEITE, H. G., GARCIA, S. L. R., CAMPOS, J. C. C., SOARES, C. P. B., SANTANA, R. C. Estimação do volume de árvores de clones de eucalipto pelo método da similaridade de perfil. **R. Árvore**, Viçosa-MG, v.33, n.1, p.133-141, 2009

ORMEROD, D. W. A simples bole model. **Forestry Chronicle**, V. 49, n. 3, p.136 – 138, 1973.

ÖZESMI, S. L., TAN, C. O., ÖZESMI, U. Methodological issues in building, training, and testing artificial neural networks in ecological applications. **Ecological modelling**, p. 83–93, 2006

ÖZCELİK, 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, 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**. p. 52–60, 2013.

PLÁCIDO, A. C., MACHADO, S. A.; FIGUEIREDO FILHO, A., OLIVEIRA, E. B. Dinâmica da relação hipsométrica em função da idade, do sítio e da densidade inicial de povoamentos de Bracatinga da Região Metropolitana de Curitiba, PR. **Revista Árvore**, v.28, n.4, p.517-533, 2004.

PIZZIÔLO, B., CAMPOS, F., BINOTI, D. H. B., SILVA, M. L., LEITE, H. G., BINOTI, M. L. M. S. Efeito do modelo de afilamento utilizado sobre a conversão de fustes de árvores em multiprodutos. **Scientia. Forestalis**, Piracicaba, v. 42, n. 104, p. 513-520, dez. 2014

PORRAS, J. C. Growth Evaluation of a Conifer Forest (Pinus Cooperi Blanco) using a Neural Net Backpropagation Trained with Distance Independent Competition Measures. **Computación y Sistemas**, Vol. 10 No. 4, pp 415-427, 2007.

PRODAN, M.; PETERS, R.; COX, F. **Mensura forestal**. San José, Costa Rica: IICA, 586p., 1997.

RECKNAGEL, F., FRENCH, M., HARKONEN, P., YABUNAKA, K. Artificial neural network approach for modelling and prediction of algal blooms. **Ecological modelling**. v. 96, p. 11–28, 1997

REFENES, A.N., AZEMA-BARAC, M., CHEN, W. AND KAROUSSOS, S.A. Currency exchange rate prediction and neural network design strategies. **Neural Computing & Applications**, v. 1, p. 46-58, 1993

RUMELHART, D. E; HINTON, G. E.; WILLIAMS, R.J. Learning representations by back-propagating error. **Nature**, 323, p. 533-536, 1986.

SANQUETTA, C. R., WATZLAWICK, L.F., CORTE, A. P. D., FERNANDES, L. DE A. V. Inventários Florestais: Planejamento e Execução. 2ª Edição. 2. ed. Curitiba: Multigraphics, v. 1. 307 p. 2009

SANQUETTA, C. R.; THIELE, P.; CÔRTE, A. P. D. Crescimento, mortalidade e recrutamento de duas Florestas de Araucária no Estado do Paraná, Brasil, no período de 1995-2007. **Naturalia**, Rio Claro, v.33, p. 117-126, 2010.

SANTOS, C.C., **Modelagem de bacias urbanas com redes neurais artificiais**. 134 f. **Dissertação** (Mestrado em Engenharia). Universidade de São Paulo, São Paulo. 2001

SCARDI, M., Artificial neural networks as empirical models for estimating phytoplankton production. **Marine Ecology Progress Series**, v 139, p 289–299, 1996.

SCARDI, M. Advances in neural network modeling of phytoplankton primary production. **Ecological modelling**. v.146, p 33–45. 2001

SCHMOLDT, D.L., LI, P., ABBOTT, A.L., Machine vision using artificial neural networks with local 3D neighborhoods. **Computers and Electronics in Agriculture**. v.16 (5), p. 255–271,1997.

SCHNEIDER, P.R. **Manejo Florestal: planejamento da produção florestal**. Santa Maria: CEPEF/FATEC, 613p. 2009.

SCHNEIDER, P. R. et al. **Análise de regressão aplicada à engenharia florestal**, FACOS-UFSM, Santa Maria, 294 p. 2009,

SCHMOLDT, D.L., LI, P., ABBOTT, A.L., Machine vision using artificial neural networks with local 3D neighborhoods. **Computers and Electronics in Agriculture**. v.16 (5), p. 255–271,1997.

SCHÖEPFER W. Automatisierung des Masse, Sorten und Wertberechnung stenender Waldbestände Schriftenreihe Bad. [S.I]: Wurt- Forstl.,1966. n.p.

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

SCOLFORO, J. R. S. Biometria Florestal 2, **Técnicas de regressão aplicada para estimar: volume, biomassa, relação hipsométrica e múltiplos produtos de madeira**, UFLA/FAEPE/DCF, 1997. 292p.

SCOLFORO, J. R. S.; FIGUEIREDO FILHO, A. Biometria Florestal: medição e volumetria de árvores. Textos técnicos. UFLA. Lavras. 1998. 310p.

SCOLFORO, J.R.S.; RIOS, M.S.; OLIVEIRA, A.D.; MELLO, J.M.; MAESTRI, R. Acuracidade de equações de afilamento para representar o perfil de *Pinus elliottii*. **Revista Cerne**, Lavras. v. 4, n.1, p. 100-122, 1998.

SCOLFORO, J.R.S. **Biometria florestal**: parte I: modelos de regressão linear e não-linear; parte II: modelos para relação hipsométrica, volume, afilamento e peso de matéria seca. Lavras: UFLA/FAEPE, p.352, 2005.

SHIMIZU, J.Y.; MEDRADO, M.J.S. **Cultivo do *Pinus*. Sistemas de Produção Embrapa Florestas**, n.5, p.1-18, 2005. Acessado em: 13 dez. 2015. Disponível em: [https://www.spo.cnptia.embrapa.br/conteudo?p\\_p\\_id=conteudoportlet\\_WAR\\_sistema\\_sdeproducao16\\_1ga1ceportlet&p\\_p\\_lifecycle=0&p\\_p\\_state=normal&p\\_p\\_mode=view&p\\_p\\_col\\_id=column-3&p\\_p\\_col\\_count=1&p\\_r\\_p\\_-76293187\\_sistemaProducaoId=3715&p\\_r\\_p\\_-996514994\\_topicId=3228](https://www.spo.cnptia.embrapa.br/conteudo?p_p_id=conteudoportlet_WAR_sistema_sdeproducao16_1ga1ceportlet&p_p_lifecycle=0&p_p_state=normal&p_p_mode=view&p_p_col_id=column-3&p_p_col_count=1&p_r_p_-76293187_sistemaProducaoId=3715&p_r_p_-996514994_topicId=3228)

SILVA, G. F.; CURTO, R. A.; SOARES, C. P. B.; PIASSI, L. C. Avaliação de métodos de medição de altura em florestas naturais. *Revista Árvore*, v. 36, n. 2, p. 341-348, 2012.

SILVA, M. L. M. Estimacão do diâmetro sem casca e diâmetro do cerne para árvores de *Tectona grandis* Linn. utilizando redes neurais artificiais. 2008. 47f. **Monografia** (Exigência para conclusão do curso de Engenharia Florestal) – Universidade Federal de Viçosa, Viçosa, MG, 2008

SOARES, T.S.; SCOLFORO, J.R.S.; FERREIRA S.O.; MELLO, J.M. Uso de diferentes alternativas para viabilizar a relação hipsométrica no povoamento florestal. **Revista Árvore**, Viçosa-MG, v.28, n.6, p.845-854. 2004.

SOUZA, C. A. M.; CHASSOT, T.; FINGER, C. A. G.; SCHNEIDER, P. R.; FLEIG, F. D. Modelos de afilamento para o sortimento do fuste de *Pinus taeda* L. **Revista Ciência Rural**, Santa Maria-RS, v.38, n.9, p.2506-2511, 2008.(a)

SOUZA, C. A. M.; SILVA, G. F.; XAVIER, A. C.; MEDONCA, A. R.; ALMEIDA, A. Q. Avaliação de modelos de afilamento não-segmentados na estimacão da altura e volume comercial de *Eucalyptus* sp. **Ciência Florestal**, v. 18, p. 393-405, 2008.(b)

SOUZA, C. A. M.; SILVA, G. F.; XAVIER, A. C.; CHICHORRO, J. F.; SOARES, C. P. B.; SOUZA, A. L. Avaliação de modelos de afilamento segmentados na estimacão da altura e volume comercial de fustes de *Eucalyptus* sp. **Revista Árvore**, v. 32, p. 453-463, 2008.(c)

SOUZA, C. A. M. Modelos de Afilamento para *Pinus taeda* L. ajustados segundo a forma do tronco e métodos de estratificacão. Santa Maria: UFSM, 2009. 120p. **Tese** (Doutorado em Engenharia Florestal) – Universidade Federal de Santa Maria, Santa Maria, RS, Brasil, 2009.

SPITZ, F., LEK, S. Environmental impact prediction using neural network modelling. An example in wildlife damage. **Journal of Applied Ecology**, v. 36, p. 317–326, 1999.

STATSOFT, INC. Statistica (data analysis software system), version 7.0. 2009.

TÉO, S. J., MARCON, A., EHLERS, T., BIANCHI, J. C., PELOSO A., NAVA, P. R., COSTA, R. H. Modelos de afilamento para *pinus elliottii* em diferentes idades, na



região de Caçador, SC. **Rev. Floresta**, Curitiba, PR, v. 43, n. 3, p. 439 - 452, jul. / set. 2013.

TEWARI, V. P., KUMAR, V. S. K., Volume equations and their validation for irrigated plantations of *Eucalyptus calmadulensis* in the hot deserts of India. **Journal of Tropical Forest Science**, Kuala Lumpur, v. 15, n. 1, p. 136-146, 2003

THIERSCH, C. R.; ANDRADE, M. G.; MOREIRA, M. F. B.; LOIBEL, S. Estimativa da relação hipsométrica em clones de *Eucalyptus* sp. com o modelo de Curtis ajustado por métodos bayesianos empíricos. **Revista Árvore**, v. 37, n. 1, p. 1-8, 2013.

THOMAS, C.; ANDRADE, C.M.; SCHNEIDER, P.R.; FINGER, C.A.G. Comparação de equações volumétricas ajustadas com dados de cubagem e análise de tronco. **Ciência Florestal**, v. 16, n. 3, 2006.

TOURENQ, C., AULAGNIER, S., MESLEARD, F., DURIEUX, L., JOHNSON, A., GONZALEZ, G., LEK, S. Use of artificial neural networks for predicting rice crop damage by greater flamingos in the Camargue, France. **Ecological Modelling**, v. 120, p. 349–358, 1999.

YOSHITANI Jr., M. Avaliação biométrica e econômica de plantios de *Pinus taeda* L. em Santa Catarina. **Dissertação de mestrado** (Programa de Pós-Graduação em Engenharia Florestal) Universidade Federal do Paraná. 2009.

WALBEL, A., HANAZAWA, T., HINTON, G. SHIKANO, K. AND LANG, K.J. Phoneme recognition using time-delay neural networks. *IEEE Trans. Acoust., Speech Signal Process.*, v. 37, p. 328-339, 1989.

WIDROW, B.; HOFF, M.E. Adaptive switching circuits. **Instituto of Radio Engineers, Western Electronic Show and Convention**, p. 96-104, 1960

ZANON, M. L. B.; FINGER, C. A. G.; SCHNEIDER, P. R. Funções para descrever a relação altura e diâmetro de *Eucalyptus dunnii* Maiden. **Ciência Rural**, Santa Maria, v.26, n.1, p.87-90, 1996.

ZHANG, Q.B., HEBDA, R.I., ZHANG, Q.J., ALFARO, R.I., Tree-ring growth responses to climatic variables using artificial neural networks. *Forest Science*. v.46 (2), p. 229–239, 2000.

ZHU, K., NOAKES, P.D. AND GREEN, A.D.P. 1990. Training neural networks for ECG feature recognition. **In: Proceeding of the International Neural Networks Conference**, Paris, p. 137-140.