



UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO  
CENTRO DE CIÊNCIAS AGRÁRIAS  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS

**BRÁULIO PIZZIÔLO FURTADO CAMPOS**

**UTILIZAÇÃO DE REDES NEURAS ARTIFICIAIS EM INVENTÁRIO DE  
FLORESTAS COMERCIAIS**

JERÔNIMO MONTEIRO – ES

2014

BRÁULIO PIZZIÔLO FURTADO CAMPOS

**UTILIZAÇÃO DE REDES NEURAS ARTIFICIAIS EM INVENTÁRIO DE  
FLORESTAS COMERCIAIS**

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Florestais do Centro de Ciências Agrárias da Universidade Federal do Espírito Santo, como parte das exigências para obtenção do Título de Mestre em Ciências Florestais, na Área de Concentração Recursos Florestais.

Orientador: Prof. Dr. Gilson Fernandes da Silva.

Coorientador: Prof. Dr. Adriano Ribeiro de Mendonça.

Coorientador: Dr. Daniel Henrique Breda Binoti.

JERÔNIMO MONTEIRO – ES

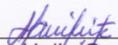
2014

**UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS EM INVENTÁRIO DE  
FLORESTAS COMERCIAIS**

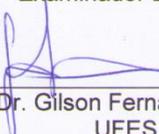
**Bráulio Pizziôlo Furtado Campos**

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Florestais do Centro de Ciências Agrárias da Universidade Federal do Espírito Santo, como parte das exigências para obtenção do Título de Mestre em Ciências Florestais na Área de Concentração Ciências Florestais.

Aprovada em 08 de dezembro de 2014.

  
\_\_\_\_\_  
Prof. Dr. Helio Garcia Leite  
UFV  
Examinador Externo

  
\_\_\_\_\_  
Dr. Daniel Henrique Breda Binoti  
DAP Florestal  
Examinador Externo

  
\_\_\_\_\_  
Prof. Dr. Gilson Fernandes da Silva  
UFES  
Orientador

Trabalhar e estudar, sempre.  
Mas nunca esquecer de “viver”!

## AGRADECIMENTOS

Aos meus pais, Maria de Fátima Pizziolo Furtado Campos e João Furtado Campos Filho, que, com exemplo de atitudes, conseguiram passar aos filhos a essência de viver: sempre batalhar pelos objetivos, com honestidade humildade e humanidade. Que o respeito não se impõe, se conquista. Agradeço por deixarem, muitas vezes, seus sonhos de lado para garantir nosso futuro. Espero retribuir todo amor, carinho, educação, admiração e confiança a mim repassados. Sem vocês essa conquista seria impossível.

Aos meus avós, que com muito amor, confiança, força, exemplos e orações nos guiaram em bons caminhos. À Estedith e Elipsio agradeço por todo amor incondicional.

Ao meu irmão Nathaniel, pelas conversas e companhia de sempre. Mesmo que distantes, temos a certeza da presença em todos os momentos.

À família Pizziôlo, pelas nossas reuniões cheias alegria, descontração, festa, companheirismo e amor.

Ao Prof. Helio Garcia Leite e ao Dr. Daniel Henrique Breda Binoti, pelo incentivo durante toda carreira acadêmica e profissional. Pelos ensinamentos e conhecimentos compartilhados. Às portas abertas (lessspa!) para o desenvolvimento pessoal e profissional. A vocês agradeço pelo profissional que me tornei.

Ao meu orientador Prof. Dr. Gilson Fernandes da Silva, que mesmo estando distante em algum momento do mestrado, sempre me orientou de forma sensata e clara. Agradeço pelos conhecimentos adquiridos e resultados encontrados neste trabalho, frutos de sua orientação.

Ao meu coorientador Prof. Dr. Adriano Ribeiro de Mendonça, por todo apoio e amizade durante todo programa de pós-graduação e estadia em Jerônimo Monteiro. Pelos conhecimentos compartilhados e orientações fundamentais para conclusão deste trabalho. Pelas “pilhas” que nos rendiam altas risadas.

Ao Diego Armando Silva da Silva (famoso Diegonça) por todos momentos de descontrações e gargalhadas, a sincera amizade formada em tão pouco tempo. Agradeço pela sua contribuição neste trabalho que, de forma companheira e amiga, auxiliou com palpites e revisões amapaenses.

Aos companheiros de república e agregados, que fizeram desta passagem por Jerônimo Monteiro uma etapa inesquecível. As amizades deixaram

saudades: Coragem (Benino); Felício Oliveira (Félix Guerreiro); Marcos Lima Pereira (Marcola); Diego de Bona (Diegão); Marcelo Dan (Gran Bon Vivant); Dênê; Milena; Pedrão; Kaio; Ju; Rafa; Evandro e; Flavim.

À Gabriela, por toda força, incentivo, companheirismo e grande amizade nesse período conturbado de adaptações no trabalho, na faculdade e em uma nova cidade.

À Dona Clarinda que, com certeza, não lerá este trabalho, mas esteve presente em todo momento. Obrigado por ter nos acolhido.

À cidade de Jerônimo Monteiro, que com seu povo acolhedor e estilo de interior, abraça a todos que por ali passam.

À Universidade Federal do Espírito Santo pela oferta do Programa de Pós-Graduação e todo apoio prestado e a Capes pela concessão da bolsa de estudo.

Atodas as pessoas que de alguma forma contribuíram com essa conquista.

## **BIOGRAFIA**

Bráulio Pizziôlo Furtado Campos, natural de Ubá, Minas Gerais. Filho de Maria de Fátima Pizziolo Furtado Campos e João Furtado Campos Filho. Nascido em 18 de julho de 1987. Em 2007, ingressou no curso de Engenharia Florestal na Universidade Federal de Viçosa (UFV). No 2º semestre de 2012, ingressou no programa de pós-graduação em ciências florestais na Universidade Federal do Espírito Santo (UFES), submetendo-se à defesa de dissertação em 08 de dezembro de 2014.

## RESUMO

CAMPOS, B. P. F. **Utilização de redes neurais artificiais em inventário de florestas comerciais**. 2014. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal do Espírito Santo, Jerônimo Monteiro, ES. Orientador: Prof. Dr. Gilson Fernandes da Silva. Coorientador: Dr. Adriano Ribeiro de Mendonça; Dr. Daniel Henrique Breda Binoti.

O objetivo deste trabalho foi de analisar o desempenho das redes neurais artificiais (RNA) em obter estimativas de variáveis dendrométricas de eucalipto e pinus em diferentes condições de crescimento, visando analisar sua capacidade de aprendizado e generalização em estimar variáveis comumente utilizadas em inventário de florestas comerciais, sendo estruturado em três capítulos. O capítulo I consiste em analisar a capacidade de uma RNA em estimar a altura total de árvores de diferentes espécies em diferentes condições de crescimento e comparar os resultados com modelos comumente utilizados por empresas florestais. Para isso, foram usados dados de altura total e diâmetro a 1,30 m de altura de uma amostra da população e de informações cadastrais como idade, local, fazenda, idade, gênero e espaçamento. O capítulo 2 visa estimar o volume de árvores de diferentes espécies e condições de crescimento por meio de redes neurais artificiais, comparando os resultados com um modelo comumente utilizado por empresas florestais. Para tanto, foram obtidos dados de cubagem rigorosa de amostra de eucalipto e pinus, coletados em diferentes condições de crescimento, formando vários estratos com amostras representativas, sendo base fundamental para analisar a capacidade de aprendizagem e generalização de uma RNA em estimar variáveis precisas e exatas de uma população heterogênea. Por fim, o capítulo III tem o objetivo de analisar a capacidade de uma RNA em descrever o perfil do fuste, estimando o diâmetro em diferentes posições ao longo do tronco, de árvores de diferentes espécies em diferentes condições de crescimento, e comparar seu desempenho com modelos comumente utilizados em por empresas florestais. Os dados utilizados foram referentes à cubagem rigorosa de árvores de eucalipto e pinus, coletados em diferentes condições de crescimento, formando vários estratos com amostras representativas, sendo base fundamental para analisar a capacidade de aprendizagem e generalização de uma RNA em descrever o perfil do fuste de forma precisa e exata de uma população heterogênea. Para gerar as estimativas das variáveis deste estudo foi utilizado o sistema livre *NeuroForest3.0*. Diante do exposto, o uso da inteligência artificial por meio de redes neurais artificiais se mostrou eficaz e eficiente, com capacidade de assimilação e generalização dos dados de diferentes espécies, podendo ser recomendada sua utilização em inventário de florestas comerciais, apresentando excelentes resultados.

**Palavras-chave:** Inventário Florestal, Manejo Florestal, Redes Neurais Artificiais.

## ABSTRACT

CAMPOS, B. P. F. **Use of artificial neural networks in inventory of commercial forests**. 2014. Dissertation (Master Degree in Forest Science) – Federal University of Espírito Santo State, Jerônimo Monteiro ES. Adviser: Dr. Gilson Fernandes da Silva. Co-adviser: Dr. Adriano Ribeiro de Mendonça; Dr. Daniel Henrique Breda Binoti.

The objective of this study was to analyze the performance of artificial neural networks (ANN) to obtain estimates of eucalyptus and pine dendrometric variables in different growing conditions in order to analyze your learning ability and generalization in estimating variables commonly used in inventory of commercial forests and is divided into three chapters. Chapter I is to examine the ability of RNA to estimate the total height of trees of different kinds in different growth conditions and compare the results with designs commonly used for forest companies. For this, we used data of total height and diameter of 1.30 m in height from a sample of the population and registration information such as age, location, farm, age, gender and spacing. Chapter 2 aims to estimate the volume of trees of different species and growing conditions through artificial neural networks, comparing the results with a model commonly used by forestry companies. To do so, they were obtained cubed data eucalyptus and pine sample collected in different growing conditions, forming several layers with representative samples being fundamental basis for analyzing the ability of learning and generalization of a RNA into precise estimate variables and exact a heterogeneous population. Finally, chapter III aims to analyze the ability of RNA to describe the shaft profile, estimating the diameter at different positions along the trunk of trees of different species in different growing conditions, and compare its performance with models commonly used in by forestry companies. The data were related to the cubed of eucalyptus and pine trees, collected in different growing conditions, forming several layers with representative samples being fundamental basis for analyzing the ability of learning and generalization of a RNA in describing the bole profile precise and exact a heterogeneous population. To generate the estimates of the variables in this study we used the free system NeuroForest 3.0. Given the above, the use of artificial intelligence through artificial neural networks proved effective and efficient assimilation capacity and generalization of data from different species, are able to recommend its use in inventory of commercial forests, with excellent results.

**Key words:** Forest inventory, forest management, artificial neural networks.

## LISTA DE TABELAS

CAPÍTULO I – ESTIMAÇÃO DA ALTURA TOTAL DE ÁRVORES EM PLANTIOS DE DIFERENTES ESPÉCIES POR MEIO DE REDES NEURAIS ARTIFICIAIS.....	16
TABELA 1 – Proporção da área do plantio de acordo com gênero e classe de idade.....	20
TABELA 2 – Frequência observada das alturas medidas de acordo com gênero, espaçamento, rotação e espécie.....	20
TABELA 3 – Estratificação da base de dados de inventário comumente utilizada na empresa.....	22
TABELA 4 – Estatísticas descritivas das variáveis contínuas amostradas por estrato utilizado. ....	23
TABELA 5 – Frequência das árvores observada de classe de altura (Ht) por classe de diâmetro a 1,30m de altura. ....	25
TABELA 6 – Parâmetros das equações do modelo de Campos ajustadas para cada estrato.....	28
TABELA 7 – Estatísticas dos ajustes do modelo de Campos e da melhor RNA, por estrato.....	28
CAPÍTULO II – ESTIMAÇÃO DO VOLUME DE ÁRVORES EM PLANTIOS DE DIFERENTES ESPÉCIES POR MEIO DE REDES NEURAIS ARTIFICIAIS.....	38
TABELA 1 – Proporção da área de plantio de acordo com gênero e classe de idade.....	42
TABELA 2 – Frequência de árvores cubadas por gênero.....	42
TABELA 3 – Estatísticas descritivas das variáveis contínuas utilizadas para treinamento das RNA por estrato. ....	44
TABELA 4 – Frequência de árvores observada de classe de altura (Ht) por classe de diâmetro medido à 1,30 m de altura da superfície do solo (dap).....	46
TABELA 5 – Estimativa do modelo de Schumacher e Hall ajustado para cada estrato.....	50
TABELA 6 – Estatísticas dos ajustes do modelo de Schumacher e Hall e da RNA, por estrato.....	50
CAPÍTULO III – DESCRIÇÃO DO PERFIL DO TRONCO DE ÁRVORES EM PLANTIOS DE DIFERENTES ESPÉCIES POR MEIO DE REDES NEURAIS ARTIFICIAIS .....	59
TABELA 1 – Proporção da área de plantio de acordo com gênero e classe de idade.....	63
TABELA 2 – Frequência de árvores cubadas por gênero.....	63
TABELA 3 – Estatísticas descritivas das variáveis contínuas amostradas e utilizadas para treinamento das redes neurais.....	65
TABELA 4 – Parâmetros das equações dos modelos de afilamento de Garay ajustados para cada estrato. ....	70
TABELA 5 – Estatísticas dos ajustes do modelo de afilamento e das RNA, bem como descrições das configurações das RNA selecionadas.....	70

## LISTA DE FIGURAS

CAPÍTULO I – ESTIMAÇÃO DA ALTURA TOTAL DE ÁRVORES EM PLANTIOS DE DIFERENTES ESPÉCIES POR MEIO DE REDES NEURAIAS ARTIFICIAIS.....	16
FIGURA 1 – Dispersão das alturas totais em relação ao dap no povoamento de eucalipto (A) e pinus (B). .....	21
FIGURA 2 – Dispersão dos resíduos por dap e histograma de frequência de resíduos entre altura observada e altura estimada por estrato.....	31
CAPÍTULO II – ESTIMAÇÃO DO VOLUME DE ÁRVORES EM PLANTIOS DE DIFERENTES ESPÉCIES POR MEIO DE REDES NEURAIAS ARTIFICIAIS.....	38
FIGURA 1 – Relações entre dap e altura das árvores cubadas, de pinus e eucalipto (A); dap e volume das árvores cubadas, de pinus e eucalipto (B); e entre altura e volume das árvores cubadas, de pinus e eucalipto (C). .....	47
FIGURA 2 – Dispersão dos erros percentuais em função dos valores observados do dap e histograma de frequência percentual dos erros percentuais por estrato para as estimativas do volume de árvores pelas metodologias testadas.....	52
CAPÍTULO III – DESCRIÇÃO DO PERFIL DO TRONCO DE ÁRVORES EM PLANTIOS DE DIFERENTES ESPÉCIES POR MEIO DE REDES NEURAIAS ARTIFICIAIS .....	59
FIGURA 1 – Gráfico de perfil do fuste evidenciando a tendência entre as razões de posição onde foram coletados os diâmetros ao longo do fuste por altura total da árvore e diâmetro coletado ao longo do fuste por diâmetro à altura do peito (dap).....	64
FIGURA 2 – Gráficos de dispersão dos resíduos em função do dap, histograma de frequência de resíduos e gráficos de perfil do fuste evidenciando o comportamento das estimativas e desvios encontrados entre diâmetro observado e estimado ao longo do fuste. ....	72

## SUMÁRIO

1 INTRODUÇÃO GERAL .....	12
1.1 OBJETIVO GERAL.....	13
1.2 OBJETIVOS ESPECÍFICOS.....	13
2 REFERÊNCIAS.....	14
CAPÍTULO I – ESTIMAÇÃO DA ALTURA TOTAL DE ÁRVORES EM PLANTIOS DE DIFERENTES ESPÉCIES POR MEIO DE REDES NEURAI ARTIFICIAIS.....	16
RESUMO.....	16
ABSTRACT .....	17
1 INTRODUÇÃO .....	18
2 MATERIAL E MÉTODOS.....	20
2.1 DESCRIÇÃO DA ÁREA DE ESTUDO E COLETA DE DADOS.....	20
2.2 REDES NEURAI ARTIFICIAIS.....	25
3 RESULTADOS E DISCUSSÃO.....	28
4 CONCLUSÃO .....	34
5 REFERÊNCIAS.....	35
CAPÍTULO II – ESTIMAÇÃO DO VOLUME DE ÁRVORES EM PLANTIOS DE DIFERENTES ESPÉCIES POR MEIO DE REDES NEURAI ARTIFICIAIS.....	38
RESUMO.....	38
ABSTRACT .....	39
1 INTRODUÇÃO .....	40
2 MATERIAL E MÉTODOS.....	42
2.1 DESCRIÇÃO DA ÁREA DE ESTUDO E COLETA DE DADOS.....	42
2.2 REDES NEURAI ARTIFICIAIS.....	42
3 RESULTADOS E DISCUSSÃO.....	50
4 CONCLUSÃO .....	56
5 REFERÊNCIAS.....	57
CAPÍTULO III – DESCRIÇÃO DO PERFIL DO TRONCO DE ÁRVORES EM PLANTIOS DE DIFERENTES ESPÉCIES POR MEIO DE REDES NEURAI ARTIFICIAIS .....	59
RESUMO.....	59
ABSTRACT .....	60
1 INTRODUÇÃO .....	61
2 MATERIAL E MÉTODOS.....	63
2.1 DESCRIÇÃO DA ÁREA E COLETA DE DADOS .....	63
2.2 REDES NEURAI ARTIFICIAIS.....	64
2.3 AVALIAÇÃO DAS ESTIMATIVAS DAS REDES NEURAI ARTIFICIAIS E DO MODELO DE REGRESSÃO .....	68
3 RESULTADOS E DISCUSSÃO.....	70
4 CONCLUSÃO .....	75
5 REFERÊNCIAS.....	76

## 1INTRODUÇÃO GERAL

Inventário florestal consiste em procedimentos utilizados a fim de levantar informações qualitativas e/ou quantitativas de uma floresta, sendo base fundamental para estudos da dinâmica de uma população (PÉLLICO NETO; BRENA, 1997). Seu principal objetivo é a quantificação de produtos madeireiros para organização da administração e planejamento florestal, fundamental para tomadas de decisão e elaboração de planos de manejo de forma sustentável (HUSH et al., 2003).

A maioria dos inventários florestais realizados no Brasil baseia-se em métodos de amostragem, nos quais são coletados dados de uma amostra representativa da população e estimados para os demais indivíduos. Normalmente, em inventário de florestas plantadas, coletam-se os dados de diâmetro a 1,30 m de altura da superfície do solo(dap) e a altura total de algumas árvores amostradas do povoamento.

Para a estimação do volume de árvores, é comum o emprego de modelos de regressão com as expectativas de altura (CAMPOS; Leite, 2013). Porém, recentemente, vem sendo estudada a utilização de Redes Neurais Artificiais (RNA) para a estimação dessas variáveis, e foram encontrados resultados satisfatórios de sua aplicação, muitas vezes até superiores (BINOTI, 2012).

Em inventários comerciais, nota-se a possibilidade de uso de RNA em diversas etapas do processamento, tendo estudos realizados na modelagem de sobrevivência de árvores, estimação do diâmetro com e sem casca ao longo do fuste, prognose de produção volumétrica, modelagem do crescimento e produção, determinação da relação hipsométrica e quantificação de madeira empilhada.

Existem diversos estudos comprovando a eficiência de RNA em estimar variáveis utilizadas em inventários florestais, como estimação de altura (DIAMANTOPOULOU; MILIOS, 2010; BINOTI et al., 2013a; BINOTI et al., 2013b), estimar volume de árvores (DIAMANTOPOULOU, 2006; GÖRGENS et al., 2009; SILVA et al., 2009; DIAMANTOPOULOU; MILIOS, 2010; BINOTI et al., 2014; GÖRGENS et al., 2014), modelagem em nível de povoamento (BINOTI, 2010), modelagem em nível de árvores individuais (BINOTI, 2010), modelagem por classe de diâmetro (LEDUC et al., 2001; BINOTI et al., 2012; BINOTI et al., 2013c), modelagem do afilamento do fuste (DIAMANTOPOULOU, 2005a; LEITE et al., 2011; SOARES et al., 2012), quantificação de casca (DIAMANTOPOULOU, 2005b).

Nesse sentido, com o advento de novas tecnologias, o manejo florestal passa por mudanças quanto aos seus aspectos de pesquisas e tomada de decisão. O uso de ferramentas de inteligência computacional, como redes neurais artificiais na área florestal tem sido cada vez mais frequente, apresentando excelentes resultados e sendo fundamental na tomada de decisões (LIMA, 2014).

Esta dissertação foi organizada em três capítulos. O capítulo I consistiu em analisar a capacidade de uma RNA em estimar altura de árvores de diferentes espécies em diferentes condições de crescimento. No capítulo 2, foi analisada a capacidade de uma RNA em estimar o volume de árvores de diferentes espécies e condições de crescimento; e no capítulo 3 foi avaliada a capacidade de uma RNA em descrever o perfil do fuste de árvores de diferentes espécies e condições de crescimento.

## 1.1 OBJETIVO GERAL

Analisar a capacidade de aprendizado e generalização de uma RNA em obter estimativas de variáveis dendrométricas comumente utilizadas em inventário de florestais comerciais, referente a diferentes espécies em diferentes condições de crescimento.

## 1.2 OBJETIVOS ESPECÍFICOS

Analisar a capacidade de aprendizado e generalização de uma RNA em estimar a altura de árvores de diferentes espécies em diferentes condições de crescimento e comparar com resultados obtidos com um modelo hipsométrico comumente utilizados por empresas florestais.

Avaliar a capacidade de aprendizado e generalização de uma RNA em estimar o volume de árvores de diferentes espécies e condições de crescimento, e comparar os resultados obtidos com o emprego de um modelo volumétrico usual.

Verificar a capacidade de aprendizado e generalização de uma RNA para estimar diâmetros em diferentes alturas, descrevendo o perfil do fuste, de diferentes espécies e condições de crescimento, e comparar com resultados obtidos com um modelo de afilamento usual no Brasil.

## 2 REFERÊNCIAS

- BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G. Configuração de redes neurais artificiais para estimação do volume de árvores. **Ciência da Madeira** (Braz. J. Wood Sci.), v.5, n.1, p.58-67, 2014.
- BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G. Redução dos custos em inventário de povoamentos equiâneos. **Agrária - Revista Brasileira de Ciências Agrárias**, v.8, n.1, p.125-129, 2013b.
- BINOTI, D. H. B.; BINOTI, M. L. M.; LEITE, H. G.; SILVA, A. A. L.; SANTOS, A. C. A. Modelagem da distribuição diamétrica em povoamentos de Eucalipto submetidos a desbaste utilizando autômatos celulares. **Revista Árvore**, v.36, n.5, p. 931-940, 2012.
- BINOTI, D. H. B.; BINOTI, M. L. M.; LEITE, H. G.; SILVA, A. A. L.; SANTOS, A. C. A. Modelagem da distribuição de diâmetros utilizando autômatos celulares e redes neurais artificiais. **Cerne**, v.19, n.4, p. 677-685, 2013c.
- BINOTI, M. L. M. DA S. **Redes neurais artificiais para prognose da produção de povoamentos não desbastados de Eucalipto**. 2010. 54f. 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**. 2012. 130f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2012.
- BINOTI, M. L. M. S.; BINOTI, D. H. B.; LEITE, H. G. Aplicação de redes neurais artificiais para estimação da altura de povoamentos equiâneos de Eucalipto. **Revista Árvore**, v.37, n.4, p. 639-645, 2013a.
- CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal: Perguntas e Respostas**. 4. ed. Viçosa: UFV, p. 605, 2013.
- DIAMANTOPOULOU, M.; MILIOS, E. Modelling total volume of dominant pine trees in reforestations via multivariate analysis and artificial neural network models. **Biosystems Engineering**, v.105, p.306-315, 2010.
- DIAMANTOPOULOU, M. J. Tree-Bole Volume Estimation on Standing Pine Trees Using Cascade Correlation Artificial Neural Network Models. **Agricultural Engineering International: The CIGR EJournal**, VIII, 2006.
- DIAMANTOPOULOU, M. J. Predicting fir trees stem diameters using Artificial Neural Network models. **Southern African Forestry Journal**, v. 205, n. 1, p. 39–44, nov.2005a.
- DIAMANTOPOULOU, M. J. Artificial neural networks as an alternative tool in pine bark volume estimation. **Computers and electronics in agriculture**, v. 10, p. 235-244, 2005b.
- GÖRGENS, E. B.; LEITE, H. G.; GLERIANI, J. M.; SOARES, C. P. B., CEOLIN, A. Influência da arquitetura na estimativa de volume de árvores individuais por meio de redes neurais artificiais. **Revista Árvore**, v.38, n.2, p. 289-295, 2014.

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

HUSCH, B.; BEERS, T.W.; KERSHAW JUNIOR.J.A. **Forest mensuration**. New York: John Wiley & Sons, INC, 2003. 443 p.

LIMA, R. B. de. **Distribuição diamétrica e volumetria em vegetação de caatinga arbustiva-arbórea, Floresta-PE**. 2014. 138 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal Rural de Pernambuco, Recife, 2014.

LEDUC, D. J.; MATNEY, T. G.; BELLI, K. L.; JR., V. C. B. Book, Online. Predicting diameter distributions of longleaf pine plantations **U.S. Dept. of Agriculture, Forest Service, Southern Research Station, Asheville**, 18 p, 2001.

LEITE, H. G.; SILVA, M. L. M.; BINOTI, D. H. B.; FARDIN, L.; TAKIZAWA, F. H. Estimation of inside-bark diameter and heartwood diameter for *Tectonagrandis* Linn. trees using artificial neural networks. **European Journal of Forest Research**, v.130, n.2, p.263-269, 2011.

PELLICO NETO, S; BRENA, D. A. **Inventário florestal**. Curitiba: Edição dos autores. 1997. 316p.

SILVA, M. L. M.; BINOTI, D. H. B.; GLERIANE, J. M.; LEITE, H. G. Ajuste do modelo de Schumacher e Hall e aplicações de redes neurais artificiais para estimar volume de árvores de Eucalipto. **Revista Árvore**, v. 33, n. 6, p. 1133-1139, 2009.

SOARES, F. A. A. M. N.; FLÔRES, E. L.; CABACINHA, C. D.; CARRIJO, G. A.; VEIGA, A. C. P. Recursive diameter prediction for calculating merchantable volume of *Eucalyptus* clones without previous knowledge of total tree height using artificial neural networks. **Applied Soft Computing**. 12 (2012) 2030–2039.

## **CAPÍTULO I –ESTIMAÇÃO DA ALTURA TOTAL DE ÁRVORES EM PLANTIOS DE DIFERENTES ESPÉCIES POR MEIO DE REDES NEURAIS ARTIFICIAIS**

### **RESUMO**

Com a necessidade de estudar novas tecnologias a fim de se obter ganhos em acurácia e eficiência na realização de inventários de florestas equiâneas, ferramentas de inteligência artificial, como redes neurais artificiais (RNA), vêm sendo estudadas e demonstraram resultados promissores quanto ao ganho na acurácia das estimativas produzidas pelo inventário de florestas comerciais, normalmente obtidas via modelos de regressão. Sendo assim, o objetivo deste trabalho foi analisar a capacidade de uma rede neural artificial (RNA) em estimar a altura total de árvores de duas espécies em diferentes condições de crescimento. Para isso, foram utilizados dados de inventário florestal contínuo de uma fazenda que possui plantios de pinus e eucalipto em diferentes idades, ciclos e espaçamentos referentes a 13.817 árvores. Para o treinamento da RNA foram consideradas como entrada, as seguintes variáveis qualitativas: gênero, espécie e rotação. As variáveis de entrada contínuas foram o diâmetro com casca medido a 1,30 m de altura da superfície do solo (dap), a altura dominante média da parcela, a idade e o número de árvores por hectare, sendo utilizado como saída a altura total. Para gerar as estimativas das variáveis de estudo foi utilizado o sistema livre NeuroForest3.0. Para fins de comparação, também foi ajustado o modelo hipsométrico de Campos, aplicado por estrato conforme o gênero, espécie, rotação, espaçamento e classe de idade dos dados. A avaliação das redes neurais artificiais e do modelo de Campos foi realizada com base no coeficiente de correlação entre as alturas observadas e estimadas, a raiz quadrada do erro quadrático médio percentual (RMSE) e análise visual dos gráficos de dispersão dos resíduos por dap e histograma de frequência de resíduos por estrato. As aplicações das redes neurais artificiais apresentaram resultados satisfatórios que comprovam a capacidade em estimar a altura de árvores de diferentes espécies utilizando apenas uma RNA, com maior praticidade em relação aos modelos de regressão avaliados, podendo ser uma ferramenta adotada em inventários de florestas comerciais para estimar a altura total de árvores em plantio comerciais.

**Palavras-chave:** Relação Hipsométrica, Inventários Florestais, Redes Neurais Artificiais.

## CHAPTER I –ESTIMATION THE TOTAL HEIGHT OF TREES IN PLANTATIONS OF DIFFERENT SPECIES THROUGH ARTIFICIAL NEURAL NETWORKS

### ABSTRACT

With the need to study new technologies in order to make gains in accuracy and efficiency in conducting aged forest inventories, tools of artificial intelligence, such as artificial neural networks (ANN) have been studied and have shown promising results as the gain in accuracy the estimates produced by the inventory of commercial forests, usually obtained via regression models. Thus, the aim of this study was to analyze the ability of an artificial neural network (ANN) to estimate the total height of two tree species in different growing conditions. For this, continuous forest inventory data to a farm that has pine and eucalyptus plantations were used at different ages, cycles and gaps related to 13.817 trees. For the training of RNA were considered as input, the following qualitative variables: gender, species and rotation. The continuous input variables were the measured peel diameter 1.30 m high from the ground surface (dap), the dominant portion of the average height, age and the number of trees per hectare is used as output the full height . To generate estimates of the study variables, we used the free system NeuroForest 3.0. For comparison purposes, it was also adjusted the hypsometric model Campos, applied by layer as the genus, species, rotation, spacing and data age class. Evaluation of artificial neural networks and the Campos model was based on the correlation coefficient between the observed and estimated heights, the square root of the mean square percentage error (RMSE) and visual analysis of the waste scatter plots for dap and histogram frequency of waste per stratum. Applications of artificial neural networks showed satisfactory results that prove the capacity to estimate the height of trees of different species using only one RNA, with greater practicality from the models evaluated and it might be a tool adopted in commercial forest inventories to estimate the total height of trees in commercial plantations.

**Keywords:** Hypsometric relation, Forest Inventories, Artificial Neural Networks.

## 1 INTRODUÇÃO

Na ciência florestal há uma demanda contínua por novas tecnologias em diversas áreas. No setor produtivo, parte desta demanda tecnológica é proveniente da necessidade de estimação de variáveis dendrométricas para a determinação do estoque de madeira atual e futuro (POSSATO et al., 2013).

Para explorar o recurso florestal madeireiro de maneira eficiente é necessário o conhecimento sobre o estoque em crescimento e de colheita, o qual é obtido por meio da medição e estimação de características das árvores e da área na qual elas estão plantadas. Este conhecimento é importante no manejo florestal, uma vez que fornece informações quantitativas sobre a floresta, auxiliando na definição de planos de manejo e em análises econômicas de prescrições de manejo (HUSCH et al., 2003).

Uma característica importante medida nos inventários florestais é a altura total das árvores, uma vez que possui uma alta correlação com o volume. Conforme Leite e Andrade (2004), a estimação da altura de árvores em campo é um componente significativo no custo do inventário florestal, tendo grande importância os estudos sobre modelos, procedimentos e equipamentos para esta estimação. Os modelos de regressão sempre foram utilizados para estimar esta variável. Com o passar dos anos, ferramentas de inteligência computacional, como as redes neurais artificiais (RNA), têm sido empregadas na área de inventário florestal em substituição aos modelos de regressão, apresentando muitas vezes superioridade na acurácia das estimativas de variáveis (GORGENS, 2009; SILVA et al., 2009).

Entre os diversos fatores para o desempenho superior das RNA em relação aos modelos de regressão, Haykin (2001) cita: habilidade de aprender e generalizar, que as tornam capazes de resolver problemas complexos; capacidade de modelar diversas variáveis e suas relações não lineares; capacidade de modelagem com variáveis categóricas (qualitativas), além das numéricas (quantitativas); e analogia neurobiológica.

Diversos estudos foram realizados comprovando a eficiência de RNA para estimar variáveis comumente utilizadas em inventários florestais, como a estimação de altura (DIAMANTOPOULOU; MILIOS, 2010; BINOTI et al., 2013a; BINOTI et al., 2013b), estimação de volume de árvores (DIAMANTOPOULOU, 2006; GÖRGENS et al., 2009; SILVA et al., 2009; DIAMANTOPOULOU; MILIOS, 2010; BINOTI et al.,

2014; GÖRGENS et al., 2014), modelagem do crescimento e da produção em nível de povoamento (BINOTI, 2010), modelagem do crescimento e produção de árvores individuais (Guan; Gertner (1991); BINOTI, 2010; CASTRO et al, 2013; VIEIRA, 2015), modelagem do crescimento e produção por classe de diâmetro (LEDUC et al., 2001; BINOTI et al., 2012; BINOTI et al., 2013c), modelagem do afilamento do fuste (DIAMANTOPOULOU, 2005a; LEITE et al., 2011), quantificação de casca (DIAMANTOPOULOU, 2005b).

Nesse sentido, o objetivo deste trabalho foi analisar a capacidade de uma única rede neural artificial (RNA) para estimar altura de eucalipto e de pinus de diferentes espécies em diferentes condições de crescimento e de idades.

## 2 MATERIAL E MÉTODOS

### 2.1 DESCRIÇÃO DA ÁREA DE ESTUDO E COLETA DE DADOS

Os dados utilizados para realização deste estudo foram provenientes de 13.817 árvores, os quais foram medidos diâmetro a 1,30m de altura da superfície do solo (dap) e a altura total (Ht) no inventário florestal contínuo realizado em 2014, em uma fazenda pertencente a uma empresa florestal na região do Triângulo Mineiro, em Minas Gerais. A área total da fazenda é de 22.624 hectares, onde são encontrados plantios de pinus e de eucalipto, em diferentes idades, ciclos e espaçamentos de plantio (Tabelas 1 e 2).

Tabela 1 – Proporção da área do plantio de acordo com gênero e classe de idade.

Gênero		Classe de Idade (anos)							Total
		2,0 - 3,0	3,0 - 4,0	4,0 - 5,0	5,0 - 6,0	6,0 - 7,0	7,0 - 8,0	8,0 - 9,0	
Eucalipto	Área (ha)	5.117	6.679	1.839	3.104	3.319	2.092		22.149
	% do Total	23%	30%	8%	14%	15%	9%		98%
Pinus	Área (ha)						225	250	475
	% do Total						1%	1%	2%
Total	Área (ha)	5.117	6.679	1.839	3.104	3.319	2.318	250	22.624
	% do Total	23%	30%	8%	14%	15%	10%	1%	100%

Tabela 2 – Frequência observada das alturas medidas de acordo com gênero, espaçamento, rotação e espécie.

Gênero	Espaçamento	Rotação	Espécie	Nº de alturas medidas
EUC	2,80 X 3,20	1	E	3.987
			EGR	150
	3,00 X 1,90	1	HGU	1.896
			E	3.289
	3,00 X 2,00	1	EGR	40
			HGU	2.736
3,00 X 3,00	2	E	400	
		HGU	945	
PIN	2,80 X 2,15	1	E	100
			HGU	15
			PCH	180
			POO	79
<b>Total</b>				<b>13.817</b>

em que: E = *Eucalyptus spp.*, EGR = *Eucalyptus grandis*, HGU = Híbrido *Eucalyptus grandis* X *Eucalyptus urophylla*, PCH = *Pinus caribaea* var. *hondurensis* POO = *Pinus oocarpa*.

Para o ajuste dos modelos hipsométricos empregou-se a estratificação normalmente utilizada na empresa (Tabela 3). A distribuição de frequência dos dados por classe de altura e diâmetro utilizados para treinamento das RNA (Tabela 3) e ajuste do modelo hipsométrico é apresentada na Tabela 4. As dispersões de Ht em relação ao dap, para cada gênero, são apresentadas na Figura 1. Na tabela 5 é apresentada a distribuição de alturas e diâmetros para os dados utilizados.

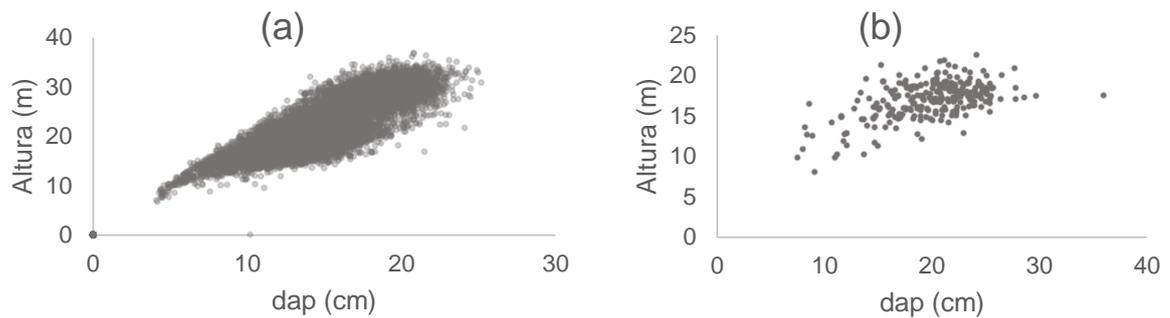


Figura 1 – Dispersão das alturas totais em relação ao dap no povoamento de eucalipto (a) e pinus (b).

Tabela 3 – Estratificação da base de dados de inventário comumente utilizada na empresa.

Estrato	Rotação	Idade	Espaçamento	Gênero	Espécie
1	1	2,0 - 3,0	3,00 X 1,90	EUC	E
		4,0 - 5,0	2,80 X 3,20	EUC	E
2	1	3,0 - 4,0	3,00 X 1,90	EUC	E
		5,0 - 6,0	2,80 X 3,20	EUC	E
3	1	3,0 - 4,0	3,00 X 2,00	EUC	E
		6,0 - 7,0	2,80 X 3,20	EUC	E
4	1	4,0 - 5,0	3,00 X 2,00	EUC	E
		7,0 - 8,0	2,80 X 3,20	EUC	E
5	1	6,0 - 7,0	2,80 X 3,20	EUC	EGR
6	1	2,0 - 3,0	3,00 X 1,90	EUC	HGU
		4,0 - 5,0	2,80 X 3,20	EUC	HGU
7	1	3,0 - 4,0	3,00 X 1,90	EUC	HGU
		5,0 - 6,0	2,80 X 3,20	EUC	HGU
8	1	3,0 - 4,0	3,00 X 2,00	EUC	HGU
		6,0 - 7,0	2,80 X 3,20	EUC	HGU
9	1	4,0 - 5,0	3,00 X 2,00	EUC	HGU
		7,0 - 8,0	2,80 X 3,20	EUC	HGU
10	1	4,0 - 5,0	2,80 X 3,20	EUC	E
11	2	3,0 - 4,0	3,00 X 3,00	EUC	E
		3,0 - 4,0	3,00 X 3,00	EUC	HGU
12	1	2,0 - 3,0	3,00 X 1,90	EUC	EGR
13	1	7,0 - 8,0	2,80 X 2,15	PIN	PCH
		8,0 - 9,0	2,80 X 2,15	PIN	PCH
14	1	7,0 - 8,0	2,80 X 2,15	PIN	POO
		8,0 - 9,0	2,80 X 2,15	PIN	POO

E = *Eucalyptus spp.*, EGR = *Eucalyptus grandis*, HGU = Híbrido *Eucalyptus grandis* X *Eucalyptus urophylla*, PCH = *Pinus caribaea* var. *hondurensis* POO = *Pinus oocarpa*.

Tabela 4 – Estatísticas descritivas das variáveis contínuas amostradas por estrato utilizado.

Variável	Estrato	Estatísticas descritivas					Estrato	Estatísticas descritivas				
		Mínimo	Máximo	Média	Mediana	Desv. Pad.		Mínimo	Máximo	Média	Mediana	Desv. Pad.
<i>Idade (meses)</i>	1	27,9	60,0	34,9	31,0	10,0	8	42,2	83,2	63,1	73,3	16,3
dap (cm)		4,4	24,5	13,1	12,9	2,9		4,6	24,0	16,5	16,7	3,0
Ht (m)		7,5	31,1	17,6	16,5	4,1		8,2	34,7	25,5	26,3	4,6
HD (m)		15,1	29,0	18,6	17,1	3,8		19,6	34,0	26,0	27,3	4,2
<i>Idade (meses)</i>	2	36,9	74,6	55,3	49,2	13,8	9	50,1	96,4	73,4	84,8	19,2
dap (cm)		4,2	23,4	15,8	16,1	3,0		4,5	24,9	17,0	17,7	3,5
Ht (m)		6,7	33,5	23,0	23,0	4,4		7,5	33,8	26,2	27,6	5,0
HD (m)		16,4	31,9	23,8	24,0	4,2		21,4	33,1	27,2	29,0	3,9
<i>Idade (meses)</i>	3	42,6	87,6	75,4	78,3	11,5	10	57,3	65,0	60,6	57,3	3,6
dap (cm)		7,0	24,4	18,1	18,6	2,7		7,3	23,7	17,2	17,8	3,6
Ht (m)		13,0	33,2	27,4	28,1	3,3		13,0	28,0	22,9	23,2	3,2
HD (m)		20,4	32,2	28,3	29,1	2,9		21,4	27,4	24,4	25,5	2,3
<i>Idade (meses)</i>	4	49,7	96,6	81,7	89,2	16,4	11	40,5	42,8	41,9	41,8	0,7
dap (cm)		4,6	25,2	17,4	17,8	3,1		6,0	18,0	13,4	13,8	2,1
Ht (m)		8,6	36,7	27,4	28,4	4,3		12,3	24,5	20,3	20,5	2,1
HD (m)		20,1	34,1	28,4	29,6	3,5		19,6	22,6	21,1	21,0	0,9
<i>Idade (meses)</i>	5	63,6	87,2	78,4	83,6	8,8	12	31,7	31,9	31,8	31,8	0,1
dap (cm)		11,6	24,4	17,7	17,7	2,7		4,5	16,2	11,15	11,1	2,6
Ht (m)		17,6	33,8	25,6	25,9	2,9		8,2	19,8	14,6	14,9	2,8
HD (m)		22,1	30,7	26,6	26,9	2,2		13,9	16,7	15,3	15,3	1,4
<i>Idade (meses)</i>	6	27,8	59,9	34,5	33,4	7,3	13	89,0	102,4	96,8	95,2	4,3
dap (cm)		4,3	21,8	13,2	13,1	2,2		7,5	36,0	20,3	20,9	4,2
Ht (m)		8,5	32,0	17,9	17,4	3,3		8,0	22,5	16,6	17,0	2,1
HD (m)		12,6	28,9	18,4	17,7	3,0		15,0	19,0	17,4	17,5	0,9

Variável	Estrato	Estatísticas descritivas					Estrato	Estatísticas descritivas				
		Mínimo	Máximo	Média	Mediana	Desv. Pad.		Mínimo	Máximo	Média	Mediana	Desv. Pad.
<i>Idade (meses)</i>		37,1	77,2	49,3	45,7	10,8		90,8	104,9	101,7	104,9	5,6
<i>dap (cm)</i>	7	4,1	23,4	14,6	14,5	3,0	14	8,0	27,7	19,0	19,6	4,1
<i>Ht (m)</i>		7,0	33,1	21,7	20,7	4,3		10,2	21,8	17,7	18,4	2,5
<i>HD (m)</i>		15,1	31,2	22,3	21,2	3,9		15,2	19,6	18,6	18,9	1,2

em que: *dap* = diâmetro medido a 1,30 m de altura; *N* = número de árvores por hectares; *Ht* = altura total das árvores e; *HD* = altura média das árvores dominantes.

Tabela 5 – Frequência das árvores observada de classe de altura (Ht) por classe de diâmetro a 1,30m de altura.

Classe dap (cm)	Classe Ht (m)						Total
	6,1-12,1	12,1-18,1	18,1-24,1	24,1-30,1	30,1-36,1	36,1-42,1	
<b>4-8</b>	104	117					<b>221</b>
<b>8-12</b>	22	1.423	474	4			<b>1.923</b>
<b>12-16</b>	5	1.682	2.971	602	13		<b>5.273</b>
<b>16-20</b>		108	815	3.422	612		<b>4.957</b>
<b>20-24</b>		60	78	702	545	4	<b>1.389</b>
<b>24-28</b>		19	19	4	9		<b>51</b>
<b>28-32</b>		2					<b>2</b>
<b>32-36</b>		1					<b>1</b>
<b>Total</b>	<b>131</b>	<b>3.412</b>	<b>4.357</b>	<b>4.734</b>	<b>1.179</b>	<b>4</b>	<b>13.817</b>

## 2.2 REDES NEURAIS ARTIFICIAIS

O treinamento da RNA foi realizado visando estimar a altura total das árvores utilizando informações comumente coletadas em inventário de florestas comerciais. Foram consideradas como entrada para treinamento da RNA, as seguintes variáveis qualitativas: gênero (eucalipto e pinus), espécie (E, EGR, HGU, PCH e POO) e rotação (1ª e 2ª). E como variáveis contínuas: diâmetro com casca medido a 1,30 m de altura da superfície do solo (dap em cm), altura dominante média da parcela (m), idade (meses) e número de árvores por hectare, totalizando quatro variáveis contínuas. A saída da rede foi a altura total das árvores medidas (m). As estatísticas descritivas das variáveis quantitativas são apresentadas na Tabela 3. As variáveis contínuas foram normalizadas linearmente no intervalo de 0 a 1, e as variáveis categóricas foram normalizadas utilizando a metodologia 1-de-N (GOLDSCHMIDT; PASSOS, 2005; HEATON, 2011).

O número de neurônios na camada de entrada variou de acordo com as variáveis consideradas. O número de neurônios na camada oculta variou entre 4 e 16 neurônios (com incremento a cada dois neurônios). A camada de saída foi constituída por um neurônio, sendo este referente à altura total da árvore. Como funções de ativação da camada oculta e de saída foram testadas as funções tangente hiperbólica, logística e sigmoide (BRAGA et al., 2007).

As Redes Neurais Artificiais testadas foram do tipo *MultilayerPerceptron* (MLP), e os algoritmos de treinamento testados foram o *errorbackpropagation* e o *resilientpropagation* (Haykin, 2001).

Para o algoritmo *errorbackpropagation* foram testadas variações no valor da taxa de aprendizado e no parâmetro *momentum*, variando ambos para os valores de 0,001; 0,0005 e 0,0001. Além das variações testadas, foram analisadas as estratégias de autoajuste destes parâmetros, em que o processo reduz os valores dos parâmetros ao longo da evolução do algoritmo. Já para o algoritmo *resilientpropagation* foi utilizada a variação RPROP+ (HEATON, 2011). Como critérios de parada dos treinamentos das RNA foram utilizados o número total de 30.000 ciclos ou o erro quadrático médio inferior a 0,1%.

Os pesos iniciais de todas as redes foram gerados de forma aleatória. Para cada combinação avaliada foram treinadas cinco redes, sendo selecionada a melhor destas para posterior comparação entre as combinações. Para treinamento e aplicação das RNA foi utilizado o sistema livre NeuroForest 3.0 (<http://neuroforest.ucoz.com/>).

Para efeito de comparação utilizou-se modelos hipsométricos comumente empregados pelas empresas brasileiras para estimação da altura em plantios comerciais (Equação 1, 2 e 3). Cada modelo foi ajustado por estrato, definidos pelo gênero, espécie, rotação, espaçamento e classe de idade (Tabela 5).

a) Campos et al. (1984)

$$Ht_i = \exp [\beta_0 + \beta_1(dap_i)^{-1} + \beta_2 \ln(Hd_i)] + \varepsilon_i \quad (1)$$

b) Curtis (1967)

$$Ht_i = \beta_0 \exp\left(\frac{\beta_1}{dap_i}\right) + \varepsilon_i \quad (2)$$

c) Prodan (1968)

$$Ht_i - 1,30 = \frac{dap_i^2}{\beta_0 + \beta_1 dap_i + \beta_2 dap_i^2} + \varepsilon_i$$

(3)

em que:

*Ht*: altura total da árvore (m);

*Hd*: é a altura dominante da parcela (m);

*dap*: diâmetro medido a 1,30 m de altura da superfície do solo (cm);

*Ln*: logaritmo Neperiano.

A avaliação das redes neurais artificiais foi feita com base no coeficiente de correlação entre as alturas observadas e estimadas ( $r_{\hat{y}y}$ ), na raiz quadrada do erro quadrático médio (RMSE), por meio da análise visual dos resíduos e pela observação do histograma de frequência de resíduos. Foi escolhida a RNA que apresentou maior coeficiente de correlação e menor RMSE, e gráficos de dispersão dos resíduos e histogramas sem tendenciosidade, com maior ocorrência de observações em torno de zero.

$$erro(\%) = \frac{\hat{Y}_i - Y_i}{Y_i} \cdot 100 \quad (4)$$

em que:

$Y$ : altura total observada e;

$\hat{Y}$ : altura total estimada.

$$r_{\hat{y}y} = \frac{cov(\hat{y}, y)}{\sqrt{s^2(\hat{y})s^2(y)}} \quad (5)$$

em que:

$s^2$ : variância e;

$cov$ : covariância.

$$RMSE(\%) = \frac{100}{\bar{Y}} \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad (6)$$

em que:

$Y$ : altura total observada;

$\hat{Y}$ : altura total estimada;

$\bar{Y}$ : média das alturas totais observadas e;

$n$ : número total de dados.

### 3 RESULTADOS E DISCUSSÃO

Foram estimadas 14 equações para cada modelo hipsométrico e, de acordo com análises do coeficiente de correlação e RMSE, realizada a análise visual dos gráficos de dispersão dos resíduos e histograma de frequência dos resíduos. O modelo de Campos foi o que obteve melhor desempenhos em estimar as alturas, sendo suas estimativas comparadas com as estimativas obtidas pelas RNA (Tabela 6 e 7 e Figura 2).

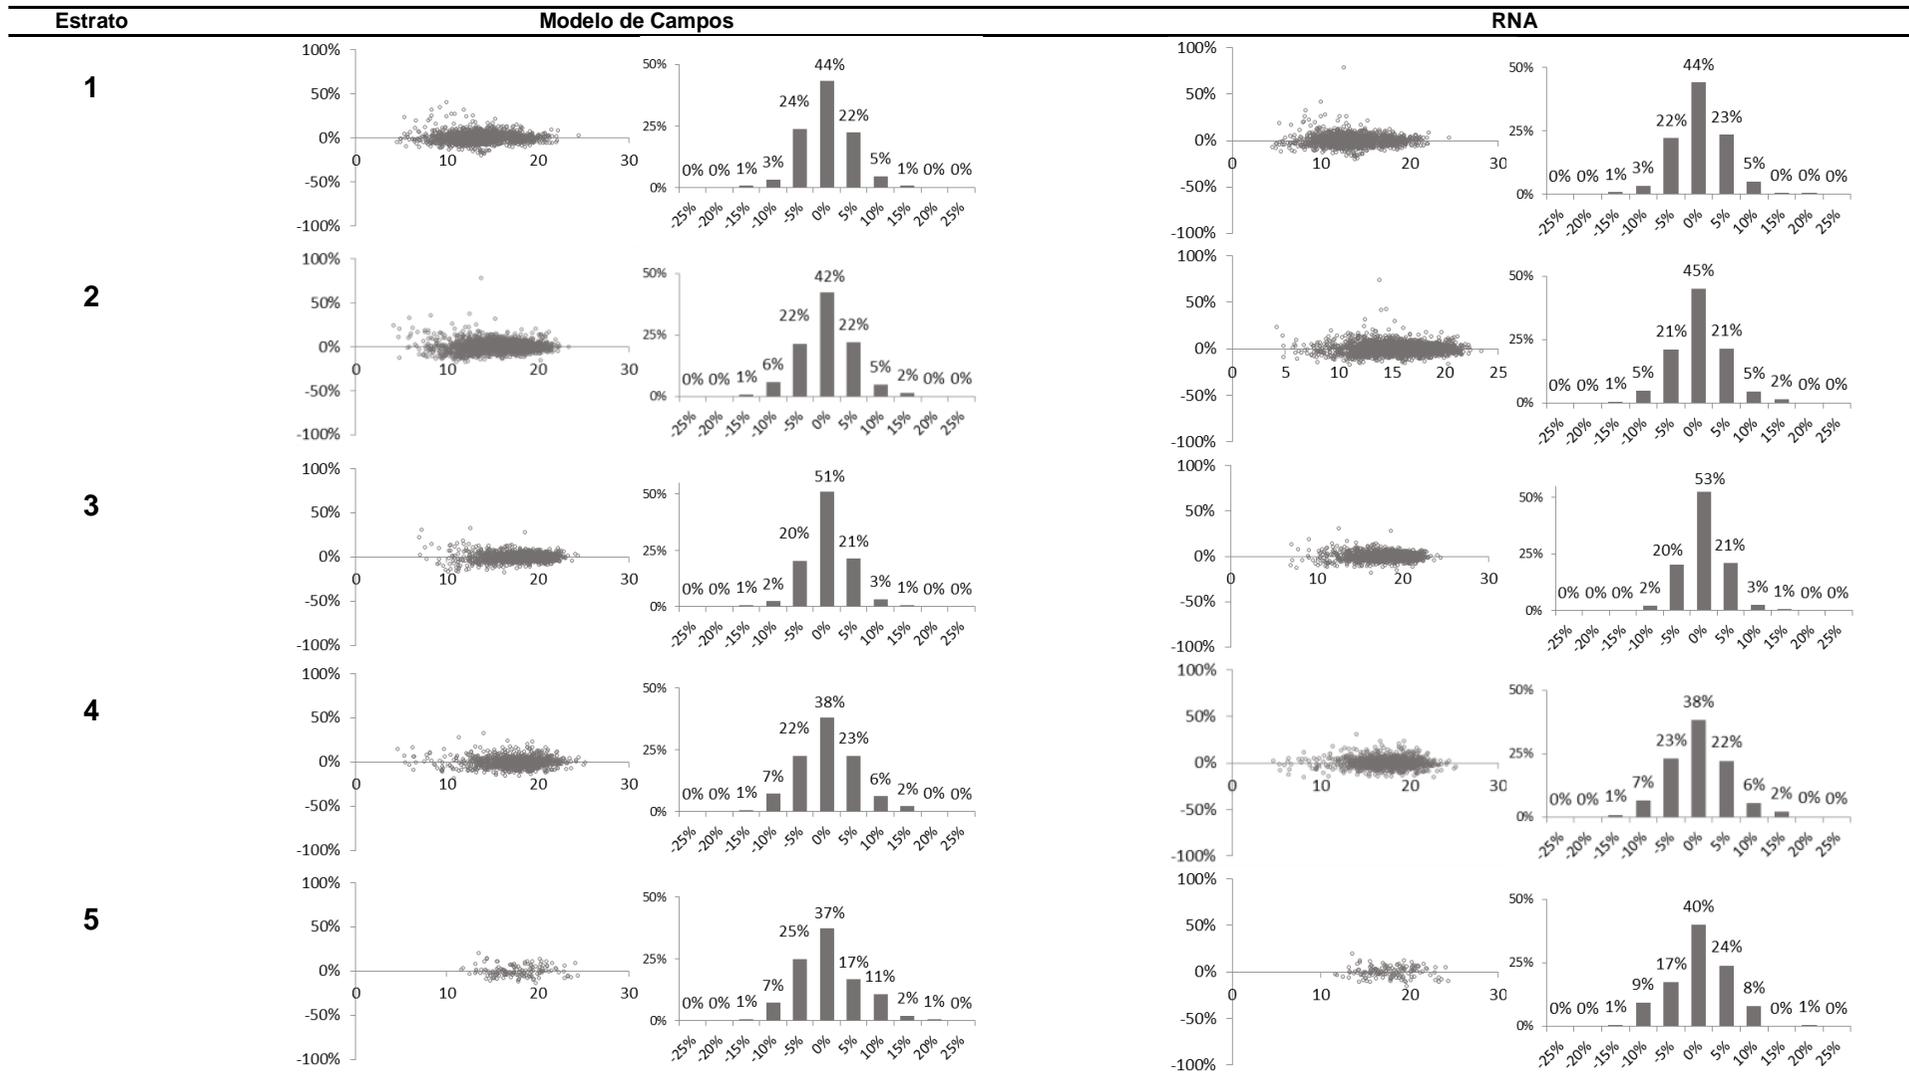
Tabela 6 – Parâmetros das equações do modelo de Campos ajustadas para cada estrato.

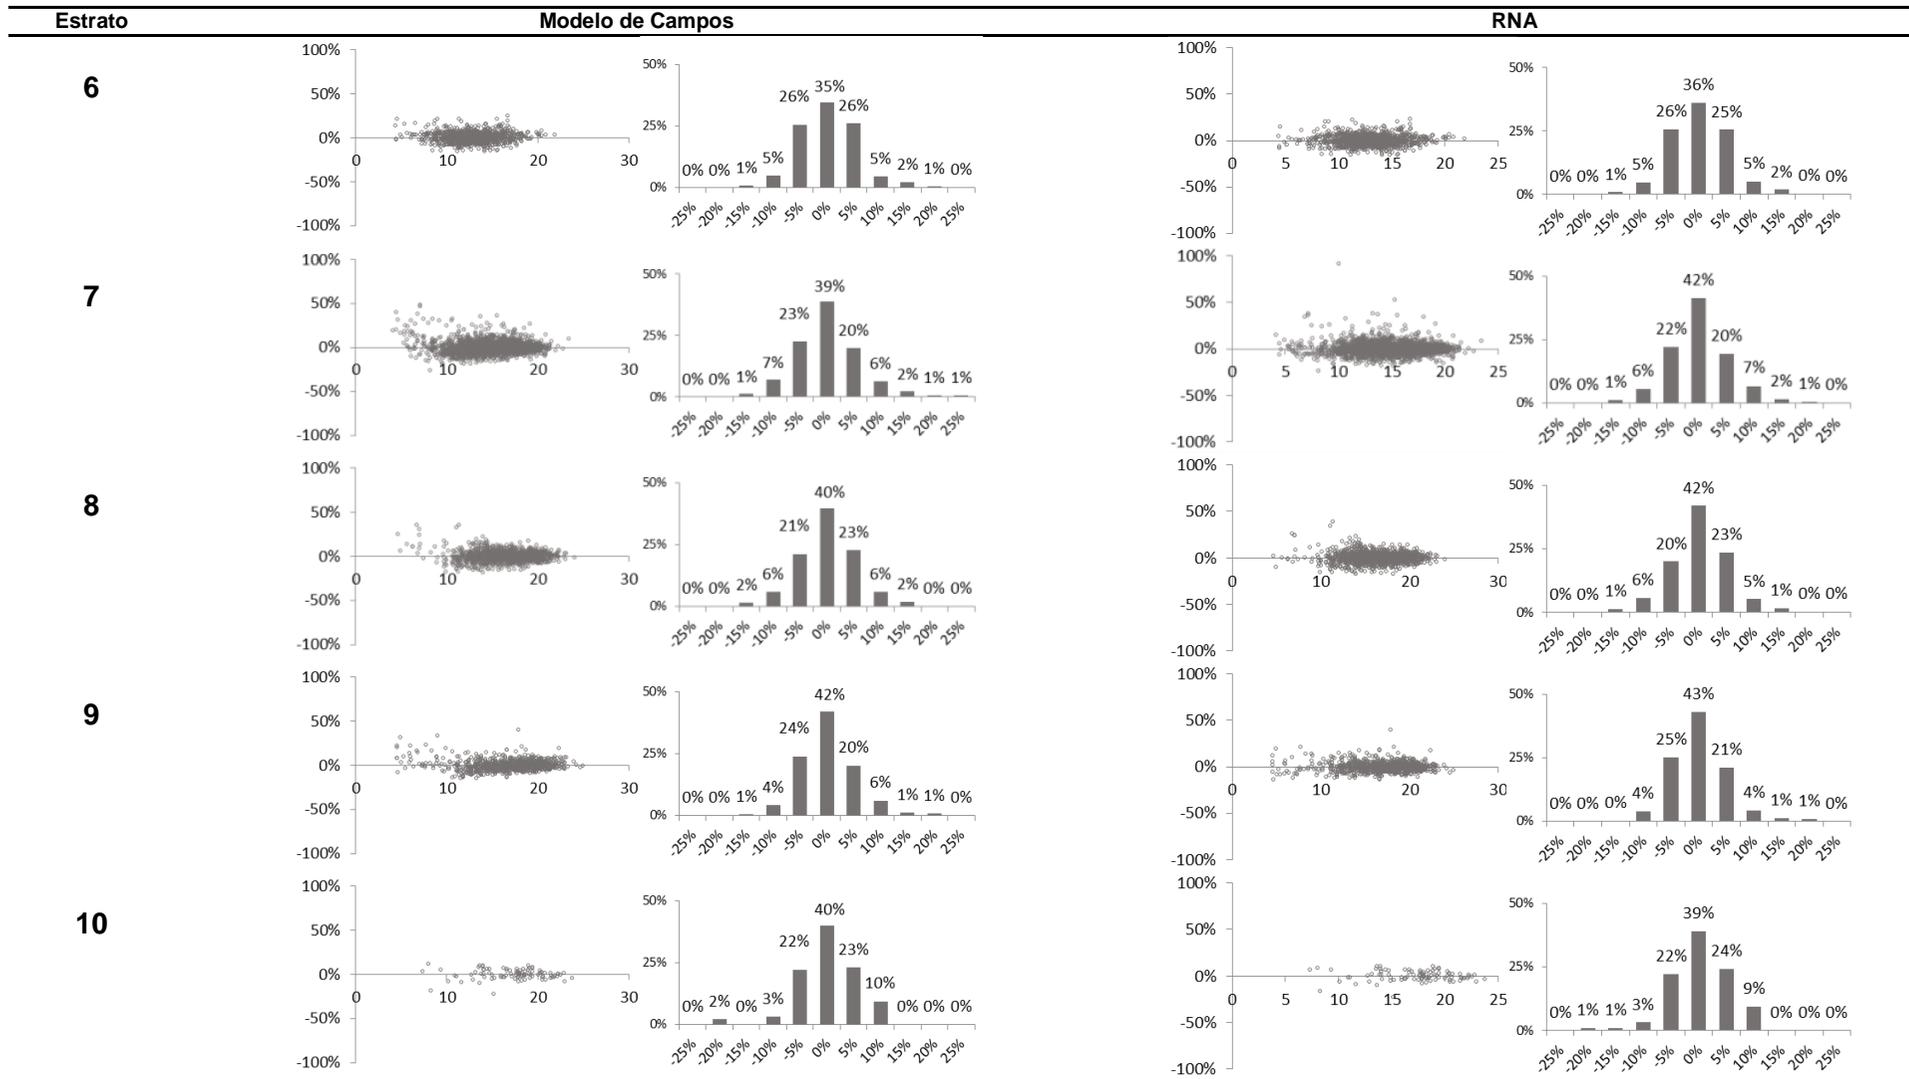
Estratos	Estimativas dos Parâmetros		
	$\hat{\beta}_0$	$\hat{\beta}_1$	$\hat{\beta}_2$
1	0,7482	-3,9059	0,8337
2	0,9809	-4,7197	0,7765
3	1,1666	-5,8470	0,7397
4	1,1165	-5,4218	0,7517
5	0,5857	-5,6584	0,9094
6	0,5533	-3,4981	0,8937
7	1,0231	-4,5909	0,7657
8	1,1369	-5,0940	0,7418
9	1,0200	-5,7089	0,7850
10	0,7000	-5,5196	0,8664
11	2,1020	-4,9011	0,4222
12	1,9414	-5,1196	0,4471
13	0,7257	-5,2078	0,8230
14	-0,2542	-4,8812	1,1610

$$Ht_i = \exp [\beta_0 + \beta_1(dap_i)^{-1} + \beta_2 \ln(Hd_i)] + \varepsilon_i$$

Tabela 7 – Estatísticas dos ajustes do modelo de Campos e da melhor RNA, por estrato.

Estatísticas	Estratos														
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	
Campos	$r_{\hat{y}y}$	97,6	96,5	94,3	93,2	86,5	96,2	95,5	95,6	96,6	92,4	80,9	75,1	70,2	79,4
	RMSE	5,0	6,5	6,1	8,7	8,3	5,5	7,2	7,6	7,2	6,9	7,1	10,7	8,4	8,6
RNA	$r_{\hat{y}y}$	97,5	96,7	94,8	93,4	87,0	96,4	95,6	95,9	97,1	92,4	83,2	75,8	71,7	80,3
	RMSE	5,1	6,3	5,8	8,5	8,1	5,4	7,1	7,4	6,7	6,9	6,7	10,6	8,2	8,4





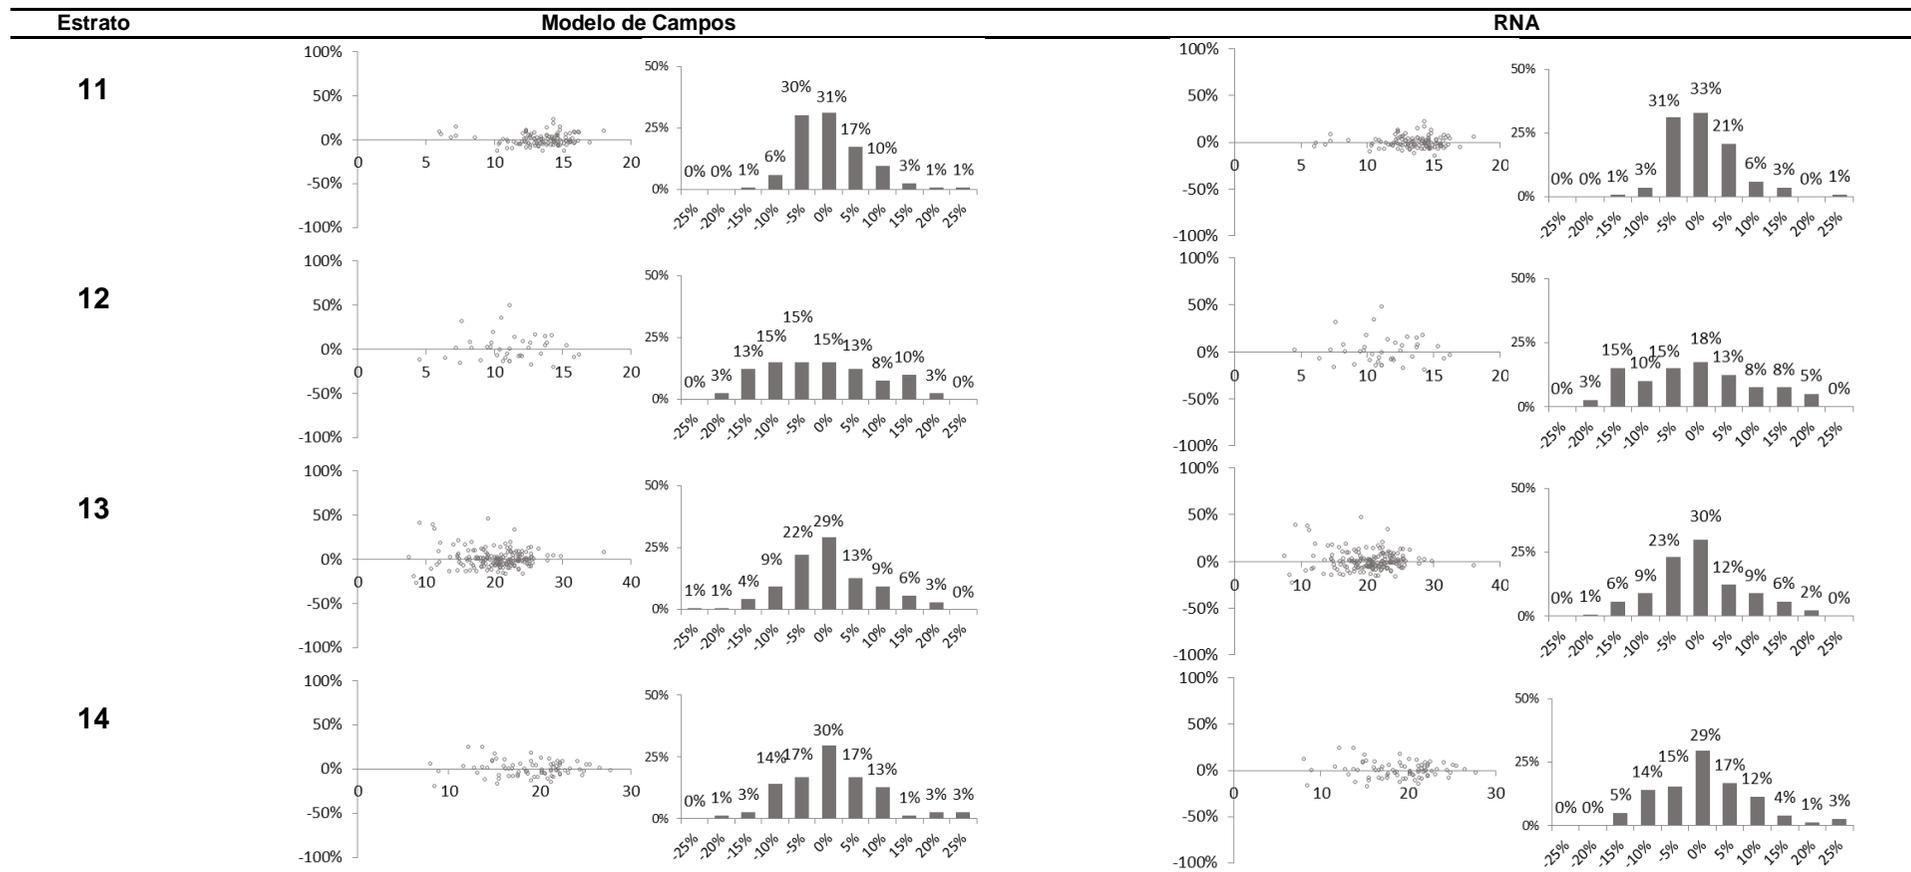


Figura 2 – Dispersão dos resíduos por dap e histograma de frequência de resíduos entre altura observada e altura estimada por estrato.

O modelo de Campos foi acurado em estimar as alturas para os povoamentos de pinus e de eucalipto ( $r_{\hat{y}y} = 97,57\%$  e  $RMSE = 5,30\%$ ), com gráfico de dispersão dos resíduos com ligeira tendência em superestimar alturas para diâmetros menores que 10 cm, sendo este resultado corroborado pelo encontrado no histograma de frequência dos resíduos. Observou-se também as maiores ocorrências em torno de zero, com 85% das frequências entre -5% e 5%. Ao analisar os resultados obtidos por estrato, notam-se altos coeficientes de correlação para a maioria dos estratos, com resíduos distribuídos de forma homogênea e histograma de frequência apresentando tendência de distribuição normal. Para o estrato 12 ( $r_{\hat{y}y} = 75,1\%$  e  $RMSE = 10,7\%$ ), havendo neste caso acurácia inferior à encontrada para os demais estratos.

No sentido de se comparar os resultados encontrados pelo ajuste do modelo de Campos com os encontrados empregando-se RNA, foi selecionada uma RNA levando-se em conta análises gráficas e coeficientes estatísticos. A RNA selecionada apresenta quatro neurônios na camada oculta e para ela encontrou-se valores de  $r_{\hat{y}y}$  de 97,7% e  $RMSE = 5,16\%$ . Pela análise do gráfico de dispersão dos resíduos é possível notar menor amplitude de dispersão dos resíduos e maiores ocorrências em torno de zero quando comparado aos gráficos do modelo de Campos, com 87% das frequências ocorrendo entre -5% e 5%. Os resultados obtidos por estrato apresentam altos coeficientes de correlação para maioria dos estratos, com resíduos distribuídos de forma homogênea e histograma de frequência apresentando tendência de distribuição normal. Para o estrato 12, encontrou-se  $r_{\hat{y}y} = 75,8\%$  e  $RMSE = 10,6\%$ , ou seja, houve um desempenho inferior do processo de estimação para este estrato, em termos de acurácia, quando comparado aos demais estratos, semelhante ao que ocorreu com o modelo de Campos. Este resultado pode ser explicado pelo tamanho reduzido da área de plantio do estrato 12, isto é, apenas 85 hectares, o que levou a uma amostragem menos intensa daquele estrato, impedindo que a tendência de crescimento fosse melhor captada.

Resultados satisfatórios foram encontrados com configurações de apenas 3 ou 4 neurônios na camada oculta, evidenciando que não são necessárias estruturas complexas para estimação da altura de árvores. Provavelmente esta resposta pode estar ligada ao número de neurônios na camada oculta representarem a não linearidade entre os dados (BRAGA et al., 2007; BINOTI, 2012) e, para este caso,

não houve necessidade de grande complexidade da estrutura da rede para captar a tendência de crescimento. De acordo com Braga et al. (2007) e Bullinaria (2010) recomenda-se configurações mais simples para essa aplicação das RNA, evitando ocorrência de *overfitting* facilitando o processo de busca e otimização da configuração para determinada tarefa.

Embora o algoritmo *errorbackpropagation* tenha tido resultados satisfatórios, o algoritmo *Resilientpropagation* resultou em melhor desempenho ao estimar a altura de árvores de pinus e eucalipto. As três funções de ativação testadas, tangente hiperbólica, logística e sigmoideal, apresentaram resultados satisfatórios para estimação de altura, tanto na camada oculta quanto na camada de saída. Os valores de taxa de aprendizado e *momentum* testados para o algoritmo *errorbackpropagation* não influenciaram no tempo de treinamento da RNA.

Pode-se observar pouca diferença na acurácia das estimativas obtidas pela equação de regressão e a obtida pela RNA. É importante destacar que as estimativas produzidas pelo modelo de Campos foram obtidas a partir de 14 equações hipsométricas, sendo uma para cada estrato proposto. Esta estratificação requer maior quantidade de unidades de amostra para cada estrato a fim de obter ajustes satisfatórios das equações, o que nem sempre ocorre. Observando a Tabela 3, nota-se a união de estratos mais homogêneos a fim de obter intensidade amostral adequada para ajuste.

O uso de RNA para estimação de altura pode permitir ganho de tempo com determinação da estratificação, ajustes e avaliações de modelos hipsométricos por estrato. A substituição de modelos estatísticos por RNA também pode gerar redução de custos em estimar altura de árvores, reduzindo o número de alturas amostradas no inventário sem perda de precisão. Nesse estudo não foi considerada a possibilidade de redução no número de árvores, uma vez que isto já foi verificado por Binoti et al. (2013a). Estes autores obtiveram maior exatidão nas estimativas de altura de árvores ao empregarem RNA. Os mesmos concluíram que as redes foram eficientes para alcançar os objetivos propostos, garantindo exatidão das estimativas para clones recém-introduzidos no povoamento, dos quais não se conhecia a relação hipsométrica.

#### **4CONCLUSÃO**

Os resultados deste estudo permitiram concluir que a altura de árvores de diferentes espécies, em distintas condições de crescimento e estados, podem ser estimadas de modo simples, utilizando uma única rede neural com a mesma eficiência e exatidão normalmente obtidas com o emprego de equações de regressão.

## 5 REFERÊNCIAS

- BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G. Configuração de redes neurais artificiais para estimação do volume de árvores. **Ciência da Madeira**, v.5, n.1, p.58-67, 2014.
- BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G. Redução dos custos em inventário de povoamentos equiâneos. **Agrária - Revista Brasileira de Ciências Agrárias**, v.8, n.1, p.125-129, 2013b.
- BINOTI, D. H. B.; BINOTI, M. L. M.; LEITE, H. G.; SILVA, A. A. L.; SANTOS, A. C. A. Modelagem da distribuição diamétrica em povoamentos de eucalipto submetidos a desbaste utilizando autômatos celulares. **Revista Árvore**, v.36, n.5, p. 931-940, 2012.
- BINOTI, D. H. B.; BINOTI, M. L. M.; LEITE, H. G.; SILVA, A. A. L.; SANTOS, A. C. A. Modelagem da distribuição de diâmetros utilizando autômatos celulares e redes neurais artificiais. **Cerne**, v.19, n.4, p. 677-685, 2013c.
- BINOTI, M. L. M. DA S. **Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto**. 2010. 54f. 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**. 2012. 130f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2012.
- BINOTI, M. L. M. S.; BINOTI, D. H. B.; LEITE, H. G. Aplicação de redes neurais artificiais para estimação da altura de povoamentos equiâneos de eucalipto. **Revista Árvore**, v.37, n.4, p. 639-645, 2013a.
- BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDEMIR, T. B. **Redes neurais artificiais: teoria e aplicação**. Rio de Janeiro: Editora LTC, 2007. 262p.
- BULLINARIA, J. A. **Introduction to Neural Computation**. Notas de aula. Disponível em: <http://www.cs.bham.ac.uk/~jxb/inc.html>. 2010.
- CAMPOS, J. C. C; RIBEIRO, J. O.; PAULA NETO, F. **Inventário florestal nacional: reflorestamento**: Minas Gerais. Brasília, DF: IBDF, 1984. 126 p.
- CASTRO, R. V. O. et al. Individual growth model for *Eucalyptus* stands in Brazil using artificial neural network. **ISRN Forestry**, [S.l.], v. 2013, p. 1-12, 2013.
- CURTIS, R. Height-diameter and height-diameter-age equations for second-growth Douglas-fir. **Forest science**, Amsterdam, v. 13, n. 4, p. 365-375, 1967.
- DIAMANTOPOULOU, M.; MILIOS, E. Modelling total volume of dominant pine trees in reforestations via multivariate analysis and artificial neural network models. **Biosystems Engineering**, v.105, p.306-315, 2010.
- DIAMANTOPOULOU, M. J. Tree-Bole Volume Estimation on Standing Pine Trees Using Cascade Correlation Artificial Neural Network Models. **Agricultural Engineering International: The CIGR EJournal**, VIII, 2006.

DIAMANTOPOULOU, M. J. Predicting fir trees stem diameters using Artificial Neural Network models. **Southern African Forestry Journal**, v. 205, n. 1, p. 39–44, nov. 2005a.

DIAMANTOPOULOU, M. J. Artificial neural networks as an alternative tool in pine bark volume estimation. **Computers and electronics in agriculture**, v. 10, p. 235-244, 2005b.

GOLDSCHMIDT, R. R., PASSOS, E. **Data Mining: Um Guia Prático**. 1. ed. Rio de Janeiro: Campos, 2005. 261p.

GÖRGENS, E. B.; LEITE, H. G.; GLERIANI, J. M.; SOARES, C. P. B., CEOLIN, A. Influência da arquitetura na estimativa de volume de árvores individuais por meio de redes neurais artificiais. **Revista Árvore**, v.38, n.2, p. 289-295, 2014.

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

GUAN, B.T.; GERTNER, G.Z. Modeling red pine tree survival with an artificial neural network. **Forest Science**, Bethesda, v. 37, n. 5, p.1429-1440, Nov. 1991.

HAYKIN, S. **Redes Neurais: princípios e prática**. Porto Alegre, 2001.900 p.

HEATON, J. **Programming Neural Networks with Encog3 in Java**. 2nd ed. Heaton Research, Inc. 2011.226 p.

HUSCH, B.; BEERS, T.W.; KERSHAW JUNIOR.J.A. **Forest mensuration**. New York: John Wiley & Sons, INC, 2003. 443 p.

LEDUC, D. J.; MATNEY, T. G.; BELLI, K. L.; JR., V. C. B. Book, Online. Predicting diameter distributions of longleaf pine plantations **U.S. Dept. of Agriculture, Forest Service, Southern Research Station, Asheville**, 18 p, 2001.

LEITE, H.G.; ANDRADE, V. C. L. Uso do método da altura relativa em inventário florestal de um povoamento de Pinus. **Revista Árvore**, v.28, n.6, p. 865-873, 2004.

LEITE, H. G.; SILVA, M. L. M.; BINOTI, D. H. B.; FARDIN, L.; TAKIZAWA, F. H. Estimation of inside-bark diameter and heartwood diameter for *Tectonagrandis* Linn. trees using artificial neural networks. **European Journal of Forest Research**, v.130, n.2, p.263-269, 2011.

PELLICO NETO, S; BRENA, D. A. **Inventário florestal**. Curitiba: Edição dos autores. 1997. 316p.

PRODAN, M. **Forest biometrics**. Oxford: Pergamon, 1968. 447 p.

POSSATO, E. L.; JUNIOR, M. A. I.; MELO, E. A.; CALEGARIO, N.; ABREU, A. A. A. **M. Estimativa de altura total de eucalipto utilizando rede neural artificial e modelo de regressão não linear**. In: II Congresso Brasileiro de Eucalipto. São Paulo/SP. 2013.

SILVA, M. L. M.; BINOTI, D. H. B.; GLERIANE, J. M.; LEITE, H. G. Ajuste do modelo de Schumacher e Hall e aplicações de redes neurais artificiais para estimar volume de árvores de Eucalipto. **Revista Árvore**, v. 33, n. 6, p. 1133-1139, 2009.

VIEIRA, G. C. **Prognose do diâmetro e da altura de árvores individuais utilizando inteligência artificial**. 2015. 51 f. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal do Espírito Santo, Jerônimo Monteiro. 2015

## **CAPÍTULO II – ESTIMAÇÃO DO VOLUME DE ÁRVORES EM PLANTIOS DE DIFERENTES ESPÉCIES POR MEIO DE REDES NEURAI ARTIFICIAIS**

### **RESUMO**

O manejo de florestas comerciais é baseado, entre outras coisas, no conhecimento do volume do estoque de madeira, sendo tomadas importantes decisões com base nesta informação. A fim de se ter um plano de manejo representativo do povoamento, deve-se buscar ferramentas cada vez mais eficazes e eficientes para que se tenha essa informação. Em função disso, diversos pesquisadores têm buscado tecnologias que consigam obter estimativas acuradas de volume de forma generalizada, possibilitando ganhos nos processamentos e nas estimativas. Considerando o exposto, o objetivo deste trabalho foi analisar a capacidade de uma única rede neural artificial (RNA) em estimar o volume de árvores de diferentes espécies em diferentes condições de crescimento. Foram utilizados dados de 611 árvores cubadas de plantios de pinus e eucalipto em diferentes idades, rotações e espaçamentos de plantio. Para o treinamento das RNA foram utilizadas como variáveis de entrada qualitativas: gênero, espécie e rotação atual. E como variáveis contínuas: o dap (diâmetro medido a 1,30m de altura da superfície do solo), altura total das árvores, idade e número de árvores por hectare. O treinamento das RNA foi realizado visando estimar o volume total das árvores (saída). Para gerar as estimativas das variáveis de estudo foi utilizado o sistema livre NeuroForest3.0. Para fins de comparação, também foi ajustado o modelo volumétrico não-linear de Schumacher e Hall, aplicado por estrato conforme o gênero, espécie, rotação, espaçamento e classe de idade dos dados. A avaliação das redes neurais artificiais e do modelo de Schumacher e Hall foi realizada com base no coeficiente de correlação entre os volumes observados e estimados, na raiz quadrada do erro quadrático médio percentual, na análise gráfica da dispersão dos erros percentuais em função do dap e no histograma de frequência dos erros percentuais. Foram selecionadas as RNA que apresentaram maiores coeficientes de correlação e menores RMSE, com os gráficos de dispersão dos resíduos e histograma de resíduos sem tendenciosidade e com estimativas mais exatas (maior ocorrência de estimativas em torno de 0% de erro). A aplicação de redes neurais artificiais apresentaram resultados satisfatórios, comprovando a capacidade das RNA em estimar o volume de árvores de diferentes espécies em diferentes condições de crescimento. Além disso a abordagem apresenta maior praticidade em relação ao modelo de regressão avaliado, uma vez que uma única RNA é capaz de estimar o volume para diferentes estratos, podendo ser uma ferramenta eficaz a ser adotada em inventário de florestas comerciais.

**Palavras-chave:** Inventário Florestal, Manejo Florestal, Redes Neurais Artificiais.

## CHAPTER II - ESTIMATION THE VOLUME OF TREES IN PLANTATIONS OF DIFFERENT SPECIES THROUGH ARTIFICIAL NEURAL NETWORKS

### ABSTRACT

The management of commercial forests is based, among other things, knowledge of wood stock volume, and taken important decisions based on this information. In order to have a representative management plan for the settlement, one must seek ever more effective and efficient tools in order to have this information. As a result, many researchers have sought technology that they obtain accurate estimates of volume across the board, enabling gains in processing and estimates. Considering the above, the objective of this study was to analyze the capacity of a single artificial neural network (ANN) to estimate the volume of trees of different species in different growing conditions. They used data from 611 cubed trees of pine and eucalyptus plantations at different ages, rotations and planting spacing. For the training of RNA were used as qualitative input variables: gender, type and actual speed. And as continuous variables: the dbh (diameter measured at 1.30 m of soil surface height), total tree height, age and number of trees per hectare. The training of RNA was performed to estimate the total volume of trees (output). To generate estimates of the study variables, we used the free system NeuroForest 3.0. For comparison purposes, it was also adjusted nonlinear volumetric model Schumacher and Hall, applied as a layer genus, species, rotation, spacing and age of the data element. The evaluation of artificial and Schumacher and Hall neural network model was based on the correlation coefficients between observed and estimated volume, the square root mean percentage error on the graphical analysis of the percentage errors of the dispersion according to the DAP and the frequency histogram of the percentage errors. RNA were selected that showed higher correlation coefficients and lower RMSE, with the waste scatter plots and waste histogram without bias and with more accurate estimates (higher incidence estimates around 0% error). The application of artificial neural networks presented satisfactory results, demonstrating the ability of RNA to estimate the amount of different species of trees at different growth conditions. Additionally the approach is more practical in relation to the estimated regression model, since a single RNA is able to estimate the volume to different layers, can be an effective tool to be adopted for commercial forest inventory.

**Key words:** Forest inventory, forest management, artificial neural networks.

## 1INTRODUÇÃO

O sucesso de uma atividade florestal requer gerenciamento eficaz, garantindo tomadas de decisões direcionadas, baseadas no conhecimento de informações técnicas. Para a tomada de decisões é importante conhecer a estrutura de custos e preços, bem como estimar produções futuras no horizonte de planejamento (SCOLFORO, 1998).

Com base no conhecimento da capacidade produtiva de um local é possível promover intervenções nos plantios e auxiliar nas tomadas de decisões estratégicas, como detecção de excedente ou escassez de madeira em determinado período, bem como a necessidade de aquisição ou venda de terras. Contudo, para que estas decisões sejam tomadas corretamente, é essencial que os elementos básicos que as influenciem representem fielmente a realidade do povoamento florestal. Logo, para obtenção de estimativas de produção do povoamento, devem ser empregadas técnicas eficientes e aprimoradas.

O procedimento mais comum para se obter o estoque de madeira em campo é a utilização de equações de volume baseadas em relações entre o volume da árvore e variáveis facilmente coletadas em campo, como diâmetro a 1,30 m de altura da superfície do solo (dap) e altura total das árvores (CLUTTER et al., 1983; CAMPOS; LEITE, 2013). Tais equações são utilizadas para totalizar parcela de inventário e, no final, obter estimativas de volume por hectare.

Segundo Campos e Leite (2013), a fim de se obter maior exatidão nas estimativas de volume de parcelas de inventário florestal, é ideal que sejam utilizadas equações específicas por espécie, espaçamento, idade e regime de corte. Conforme Guimarães e Leite (1996), as vezes são necessárias de 100 a 150 árvores para que cada equação ajustada consiga a precisão requerida. Com isso, muitas vezes, é utilizada apenas uma equação para toda população, o que reflete na qualidade das estimativas. Isto é muito comum no caso de povoamentos de clones de eucalipto, onde é praticamente impossível obter equações específicas para todos os clones.

Logo, há a necessidade de novas técnicas que consigam obter estimativas acuradas de volume de forma generalizada, isto é, um método que possa produzir estimativas levando em conta a variedade de possibilidades de crescimento, como material genético, idade, qualidade do local, espaçamento, entre outras. Neste

sentido, as redes neurais artificiais (RNA) são utilizadas para o estudo de sistemas complexos, com capacidade de generalizar o conhecimento assimilado para um conjunto de dados desconhecidos a partir de um conjunto de informações que lhe é fornecido, capacidade de modelar diversas variáveis e suas relações; capacidade de modelagem com variáveis categóricas (qualitativas), além das numéricas (quantitativas); e analogia neurobiológica (HAYKIN, 2001). As RNA possuem a capacidade de modelagem baseadas em variáveis qualitativas (categóricas) e quantitativas, tais como as levantadas em inventários florestais.

Diante da necessidade de obter novas ferramentas com a finalidade de aumentar a confiança e a praticidade das estimações utilizadas em inventários florestais, este trabalho teve por objetivo analisar a capacidade de uma única rede neural artificial (RNA) em estimar o volume de árvores de diferentes espécies em diferentes condições de crescimento (ciclo, espaçamento, rotação e idade).

## 2 MATERIAL E MÉTODOS

### 2.1 DESCRIÇÃO DA ÁREA DE ESTUDO E COLETA DE DADOS

Para realização deste estudo foram utilizados dados de 611 árvores amostra, abatidas e cubadas, em uma fazenda pertencente a uma empresa florestal na região do Triângulo Mineiro, em Minas Gerais. Com área de 22.624 hectares, a fazenda possui plantios de pinus (*Pinus caribaea var.hondurensis* e *Pinus oocarpa*) e eucalipto (*Eucalyptus grandis*, do híbrido *Eucalyptus grandis* x *Eucalyptus urophylla* e *Eucalyptus spp*), em diferentes idades, ciclos e espaçamentos de plantio (Tabelas 1 e 2).

Tabela 1 – Proporção da área de plantio de acordo com gênero e classe de idade.

Gênero		Classe de idade (anos)						Total	
		2,0 - 3,0	3,0 - 4,0	4,0 - 5,0	5,0 - 6,0	6,0 - 7,0	7,0 - 8,0		8,0 - 9,0
Eucalipto	Área (ha)	5.117	6.679	1.839	3.104	3.319	2.092	22.149	
	% do Total	23%	30%	8%	14%	15%	9%	98%	
Pinus	Área (ha)						225	250	475
	% do Total						1%	1%	2%
Total	Área (ha)	5.117	6.679	1.839	3.104	3.319	2.318	250	22.624
	% do Total	23%	30%	8%	14%	15%	10%	1%	100%

Tabela 2 – Frequência de árvores cubadas por gênero.

Gênero	Classe de idade (anos)					Total
	3,0 - 4,0	4,0 - 5,0	6,0 - 7,0	7,0 - 8,0	8,0 - 9,0	
Eucalipto	292	38	173			503
Pinus				59	49	108
Total	292	38	173	59	49	611

As árvores foram cubadas nas posições de 0,0; 0,3; 0,7; 1,3; 2,0 m e assim por diante, a cada 1,0 m, até o diâmetro comercial de 4 cm no fuste da árvore. Os volumes das seções foram obtidos com emprego da fórmula de Smalian.

### 2.2 REDES NEURAS ARTIFICIAIS

O treinamento das redes neurais foi realizado visando estimar o volume total das árvores (saída), utilizando como variáveis de entrada informações cadastrais comumente coletadas em inventário de florestas comerciais, além do dap e da altura total das árvores.

Foram utilizadas como variáveis de entrada qualitativas o gênero (dois), a espécie (cinco) e a rotação atual (duas). Como variáveis de entrada quantitativas dap (cm), a altura total das árvores (m), a idade (meses) e o número de árvores por hectare. As estatísticas descritivas dos dados utilizados e a distribuição de frequência por classe de dap e por classe de altura encontram-se nas Tabelas 3 e 4, respectivamente.

Tabela 3 – Estatísticas descritivas das variáveis contínuas utilizadas para treinamento das RNA por estrato.

Variável	Estrato	Estatísticas descritivas					Estrato	Estatísticas descritivas				
		Mínimo	Máximo	Média	Mediana	Desv. Pad.		Mínimo	Máximo	Média	Mediana	Desv. Pad.
<b>Idade (meses)</b>	1	6,42	6,42	6,42	6,42	0,00	6	3,67	3,67	3,67	3,67	0,00
<b>dap (cm)</b>		4,10	23,20	14,14	14,15	5,09		4,15	20,00	12,06	12,05	4,60
<b>N (arv./ha)</b>		1116,07	1116,07	1116,07	1116,07	0,00		1666,67	1666,67	1666,67	1666,67	0,00
<b>Ht (m)</b>		8,40	34,50	23,16	24,20	6,70		9,40	22,70	17,61	18,35	3,49
<b>Volume (m<sup>3</sup>cc)</b>		8,66E-06	3,42E-03	1,21E-03	1,36E-03	1,00E-03		7,85E-06	1,87E-04	6,60E-05	5,01E-05	4,98E-05
<b>Idade (meses)</b>	2	5,42	6,92	6,37	6,83	0,66	7	3,33	3,50	3,41	3,42	0,04
<b>dap (cm)</b>		6,78	21,29	14,40	14,83	4,59		4,10	16,23	10,67	11,14	3,30
<b>N (arv./ha)</b>		1116,07	1116,07	1116,07	1116,07	0,00		1111,11	1111,11	1111,11	1111,11	0,00
<b>Ht (m)</b>		13,73	29,02	23,17	24,68	4,51		9,20	23,00	16,74	16,90	3,48
<b>Volume (m<sup>3</sup>cc)</b>		3,17E-06	2,72E-04	6,33E-05	4,80E-05	6,03E-05		1,83E-08	2,49E-04	6,14E-05	4,12E-05	5,69E-05
<b>Idade (meses)</b>	3	3,33	3,92	3,75	3,83	0,16	8	7,67	8,42	7,99	7,83	0,36
<b>dap (cm)</b>		4,10	18,78	11,54	11,97	4,28		7,00	24,19	15,37	15,28	5,20
<b>N (arv./ha)</b>		1754,39	1754,39	1754,39	1754,39	0,00		1661,13	1661,13	1661,13	1661,13	0,00
<b>Ht (m)</b>		8,40	24,67	18,33	19,11	4,44		8,50	19,84	14,88	15,12	2,66
<b>Volume (m<sup>3</sup>cc)</b>		1,31E-08	1,88E-04	3,46E-05	2,36E-05	4,12E-05		4,19E-07	1,85E-04	4,50E-05	2,86E-05	4,40E-05
<b>Idade (meses)</b>	4	3,60	4,13	3,94	4,00	0,20	9	7,50	8,67	8,11	8,13	0,56
<b>dap (cm)</b>		4,15	18,62	11,59	11,89	4,18		6,49	24,51	15,40	15,12	5,31
<b>N (arv./ha)</b>		1666,67	1666,67	1666,67	1666,67	0,00		1661,13	1661,13	1661,13	1661,13	0,00
<b>Ht (m)</b>		9,70	26,65	19,26	20,79	4,59		8,30	20,30	15,52	15,57	3,08
<b>Volume (m<sup>3</sup>cc)</b>		2,36E-08	1,06E-04	2,26E-05	1,62E-05	2,36E-05		3,96E-07	1,59E-04	3,23E-05	1,88E-05	4,06E-05

Variável	Estrato	Estatísticas descritivas					Estrato	Estatísticas descritivas				
		Mínimo	Máximo	Média	Mediana	Desv. Pad.		Mínimo	Máximo	Média	Mediana	Desv. Pad.
<b>Idade (meses)</b>		3,08	3,58	3,49	3,58	0,18						
<b>dap (cm)</b>		4,10	18,68	12,42	12,53	4,14						
<b>N (arv./ha)</b>	5	1754,39	1754,39	1754,39	1754,39	0,00						
<b>Ht (m)</b>		9,40	23,40	16,99	16,88	3,70						
<b>Volume (m<sup>3</sup>cc)</b>		1,31E-08	2,76E-04	4,08E-05	3,13E-05	4,55E-05						

em que: *dap*= diâmetro medido à 1,30 m de altura; *N* = número de árvores por hectares; *Ht* = altura total das árvores em metros e; *V* = volume das árvores calculado pelo método de *Smalian*.

Tabela 4 – Frequência de árvores observada de classe de altura (Ht) por classe de diâmetro medido à 1,30 m de altura da superfície do solo (dap).

Classedap (cm)	Classe Ht (m)						Total
	7-12	12-17	17-22	22-27	27-32	32-37	
<b>4-6</b>	30	11					<b>41</b>
<b>6-8</b>	16	50					<b>66</b>
<b>8-10</b>	4	53	10				<b>67</b>
<b>10-12</b>	3	35	47	5			<b>90</b>
<b>12-14</b>	1	21	50	12	2		<b>86</b>
<b>14-16</b>		11	36	32	6		<b>85</b>
<b>16-18</b>		5	22	39	7	1	<b>74</b>
<b>18-20</b>		7	12	12	12	4	<b>47</b>
<b>20-22</b>		3	10	2	12	6	<b>33</b>
<b>22-24</b>		2	6		6	2	<b>16</b>
<b>24-26</b>		1	5				<b>6</b>
<b>Total Geral</b>	<b>54</b>	<b>199</b>	<b>198</b>	<b>102</b>	<b>45</b>	<b>13</b>	<b>611</b>

A Figura 1 evidencia as tendências de crescimento encontradas para os plantios de pinus e eucalipto, conforme as relações entre dap e altura; dap e volume; e altura e volume.

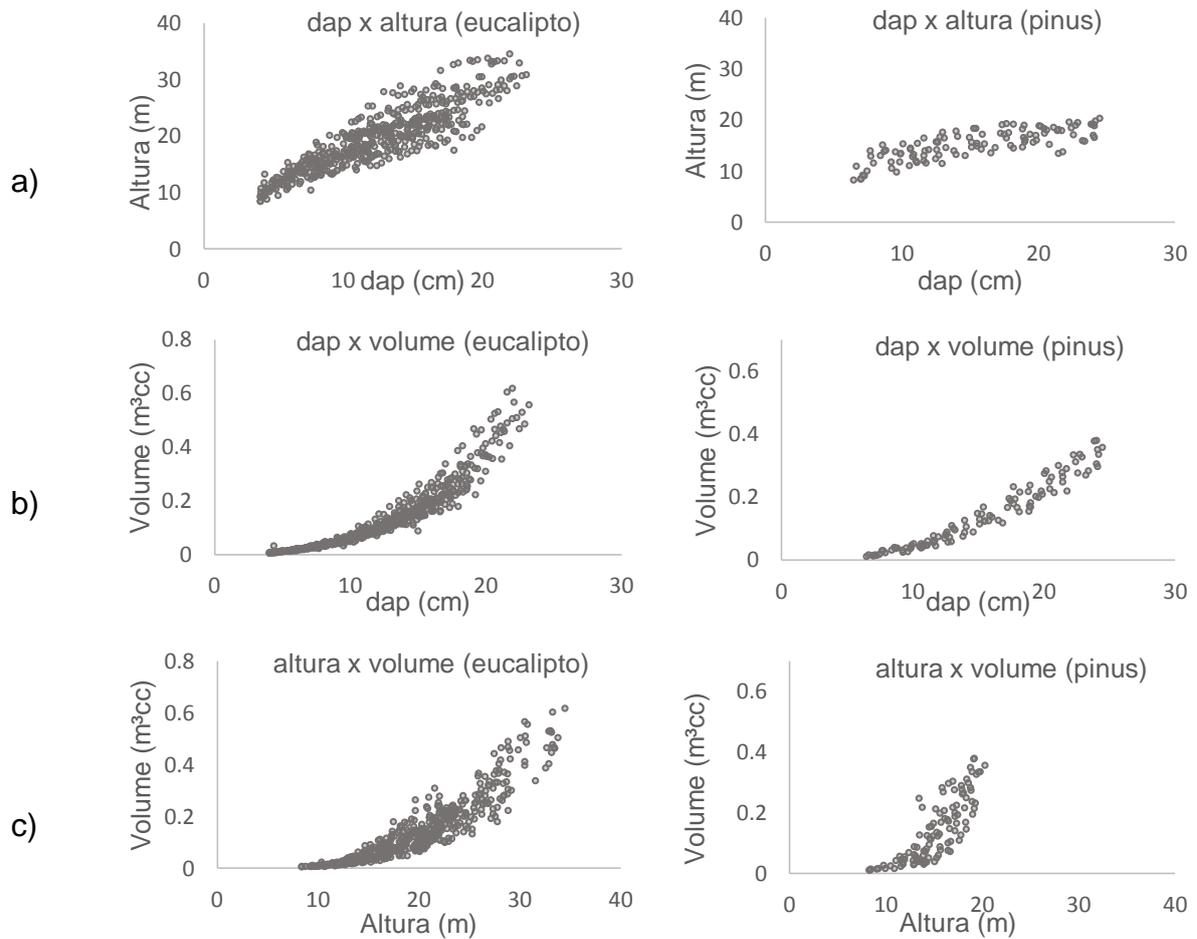


Figura 1 – Relações entre dap e altura das árvores cubadas, de pinus e eucalipto (a); dap e volume das árvores cubadas, de pinus e eucalipto (b); e entre altura e volume das árvores cubadas, de pinus e eucalipto (c).

As variáveis contínuas foram normalizadas linearmente no intervalo de 0 a 1, e as variáveis categóricas foram normalizadas utilizando a metodologia 1-de-N (GOLDSCHMIDT; PASSOS, 2005; HEATON, 2011).

O número de neurônios na camada de entrada variou de acordo com o tipo (qualitativa ou quantitativa) e o número de variáveis de entrada consideradas. No caso deste trabalho, considerou-se um neurônio para cada variável quantitativa e um neurônio para cada classe de cada variável qualitativa. O número de neurônios na camada oculta variou entre 4 e 12 neurônios (com incremento a cada dois neurônios). A camada de saída foi constituída por um neurônio, sendo este referente ao volume total da árvore. Como funções de ativação da camada oculta e de saída foram testadas as funções tangente hiperbólica, logística e sigmoide.

As Redes Neurais Artificiais testadas foram do tipo *MultilayerPerceptron* (MLP), e os algoritmos de treinamento testados foram o *errorbackpropagation* e o *resilientpropagation* (HAYKIN, 2001). Para o algoritmo *errorbackpropagation* foram testadas variações no valor da taxa de aprendizado e no parâmetro *momentum*, variando o primeiro nos valores de 0,001 e 0,0001 e o segundo em 0,005 e 0,0005. Além das variações testadas, foram analisadas as estratégias de auto ajuste destes parâmetros, em que no processo de ajuste os valores dos parâmetros são reduzidos ao longo da evolução do algoritmo. Já para o algoritmo *resilientpropagation* foi utilizada a variação RPROP+ (HEATON, 2011).

Como critério de parada dos treinamentos das RNA foi utilizado o número total de 15.000 ciclos ou erro quadrático médio inferior a 0,1%. Os pesos iniciais de todas as redes foram gerados de forma aleatória. Para cada combinação avaliada foram treinadas cinco redes, sendo selecionada a melhor destas em termos dos critérios de avaliação, para posterior comparação entre as combinações. Para o treinamento e aplicação das RNA foi utilizado o sistema livre NeuroForest 3.0 (<http://neuroforest.ucoz.com/>).

Uma das hipóteses deste trabalho é a de que as redes neurais podem ser uma alternativa viável quando comparada aos modelos de regressão tradicionalmente empregados pelas empresas florestais em seus inventários. Nesse sentido, a título de comparação, foi utilizado o modelo volumétrico de Schumacher e Hall na sua forma não-linear, comumente adotado pelas empresas para estimação do volume em plantios comerciais. Para ajuste deste modelo formaram-se nove estratos levando-se em conta: gênero, espécie, rotação, espaçamento e classe de idade.

a) Schumacher e Hall (1933)

$$V_i = \beta_0 dap_i^{\beta_1} Ht_i^{\beta_2} + \varepsilon_i \quad (1)$$

em que:

$V_i$ : volume (m<sup>3</sup>) da i-ésima árvore;

$dap_i$ : diâmetro medido à 1,30 m de altura (cm) da i-ésima árvore;

$Ht_i$ : altura total (m) da i-ésima árvore; e

$\beta_i$ : parâmetros do modelo, para  $i = 1, 2$ ;

$\varepsilon_i$ : erro aleatório referente à estimativa da i-ésima árvore.

A avaliação das redes neurais artificiais foi feita com base no coeficiente de correlação entre os volumes observados e estimados (expressão 3), a raiz quadrada do erro médio (RMSE - *Root Mean Square Error*) (expressão 4) e análise gráfica da dispersão dos erros percentuais (expressão 2) em função do dap e do histograma de frequência percentual dos erros percentuais. Foi escolhida a RNA que apresentou maior coeficiente de correlação e menor RMSE, gráficos de dispersão com ausência de tendência e histogramas de resíduos com maior ocorrência dos desvios em torno de zero.

$$erro(\%) = \frac{\hat{Y}_i - Y_i}{Y_i} \cdot 100 \quad (2)$$

em que:

$Y_i$ : volume total observado da i-ésima árvore; e

$\hat{Y}_i$ : volume total estimado da i-ésima árvore.

$$r_{\hat{y}y} = \frac{cov(\hat{Y}_i, Y_i)}{\sqrt{s^2(\hat{Y}_i) s^2(Y_i)}} \quad (3)$$

em que:

$s^2$ : variância e;

$cov$ : covariância.

$$RMSE(\%) = \frac{100}{\bar{Y}} \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad (4)$$

em que:

$\bar{Y}$ : média dos volumes totais observados e;

$n$ : número total de árvores.

### 3 RESULTADOS E DISCUSSÃO

Foram ajustadas nove equações para o modelo de Schumacher e Hall, isto é, uma para cada estrato, sendo os seus parâmetros estimados apresentados na Tabela 5. Foi selecionada a melhor RNA de todas as combinações geradas, tomando-se como base o RMSE (%), o coeficiente de correlação linear e a análise gráfica dos resíduos.

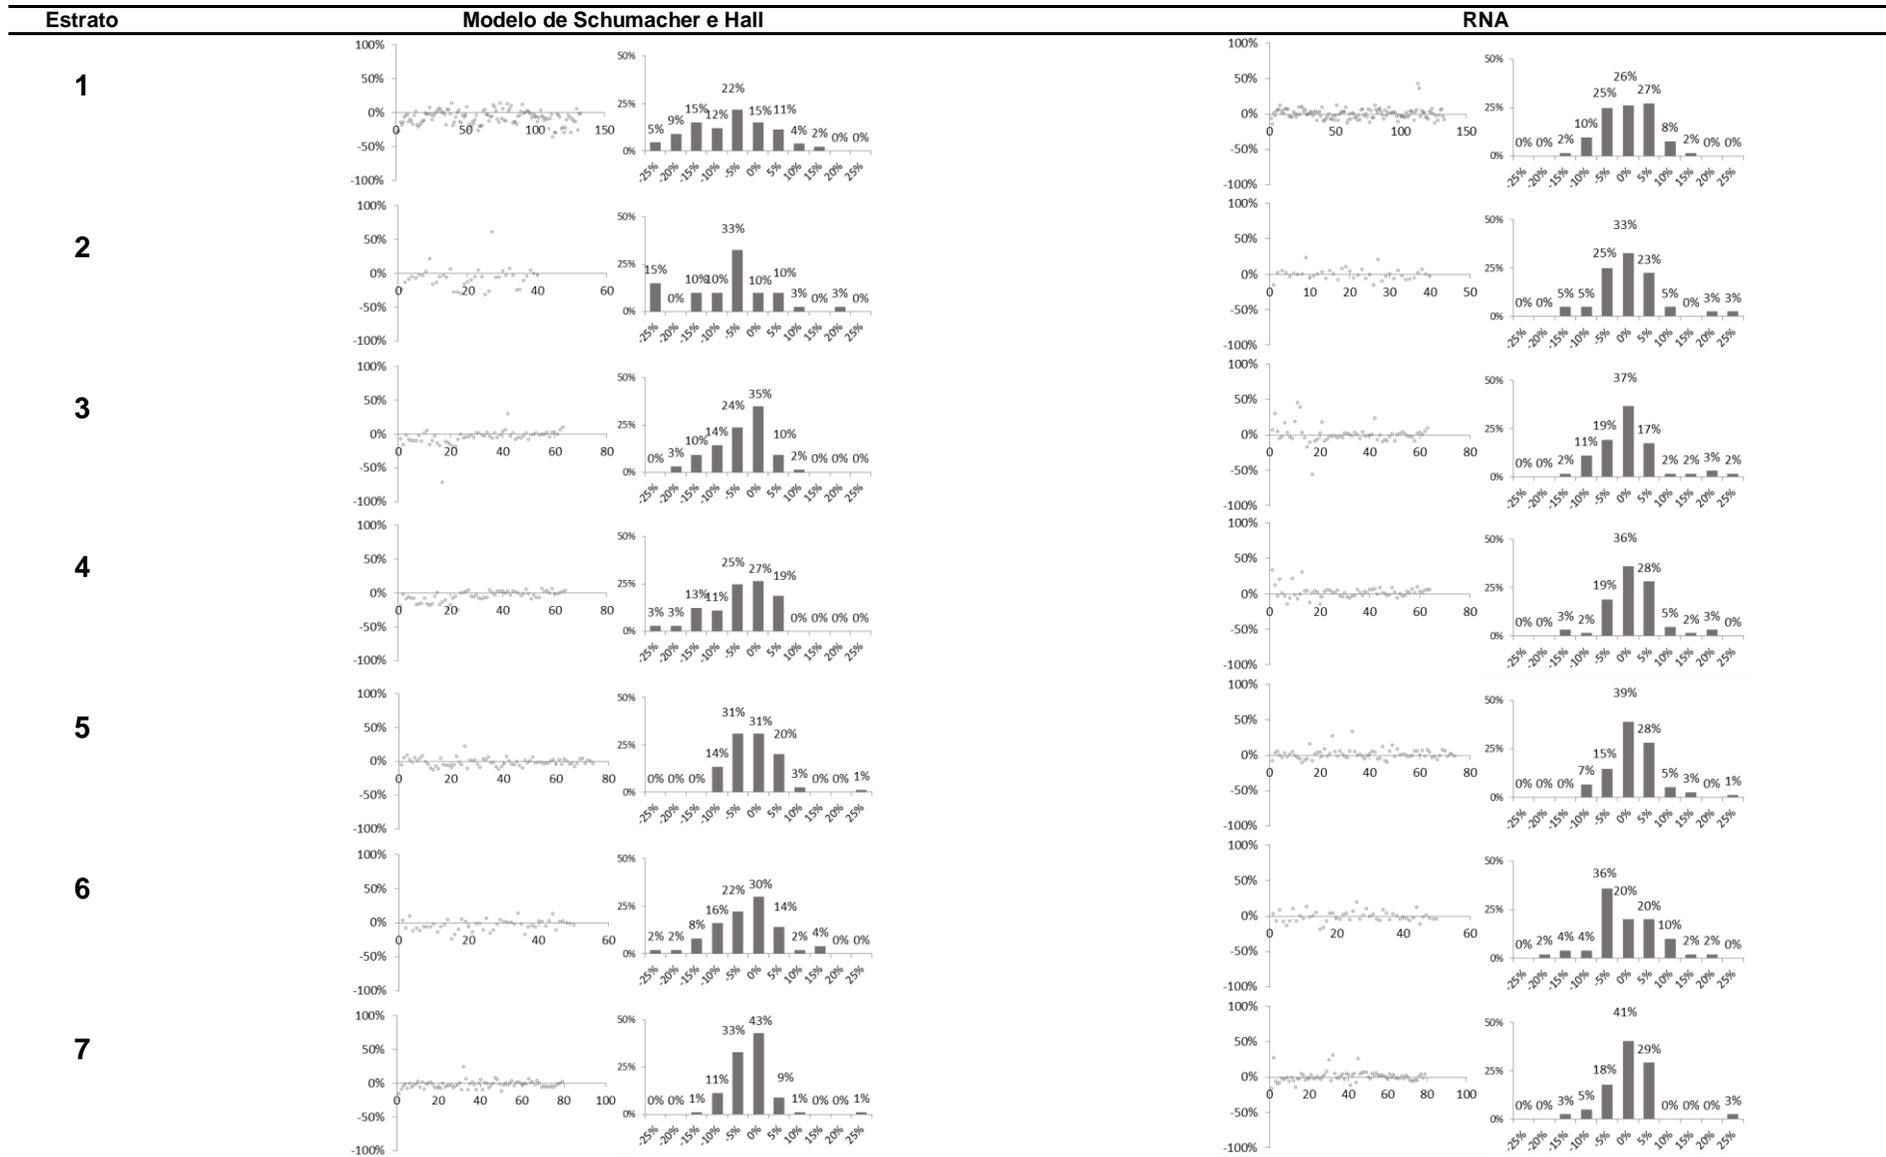
Tabela 5 – Estimativa do modelo de Schumacher e Hall ajustado para cada estrato.

Estrato	Parâmetros		
	$\hat{\beta}_0$	$\hat{\beta}_1$	$\hat{\beta}_2$
1	0,000022	1,596476	1,484211
2	0,000018	1,964232	1,224327
3	0,000027	1,677477	1,345860
4	0,000011	1,553560	1,733495
5	0,000098	1,835162	0,789713
6	0,000040	1,876084	1,076580
7	0,000054	1,839156	0,995471
8	0,000035	1,771181	1,212678
9	0,000035	1,949653	1,035711

As estatísticas de precisão do modelo de Schumacher e Hall ajustado para cada estrato e das RNA selecionadas com melhor capacidade em estimar os volumes de árvores de pinus e eucalipto são apresentadas na Tabela 6 e, os gráficos utilizados para análise visual dos resíduos, na Figura 2.

Tabela 6 – Estatísticas dos ajustes do modelo de Schumacher e Hall e da RNA, por estrato.

Estatísticas	Estratos										
	1	2	3	4	5	6	7	8	9	Geral	
Schumacher e Hall	$r_{\hat{y}y}$ (%)	99,5	99,4	99,6	99,7	99,7	99,5	99,7	99,3	98,9	99,5
	RMSE (%)	8,8	8,1	6,8	6,1	5,5	7,6	5,0	9,4	13,9	9,1
RNA	$r_{\hat{y}y}$ (%)	99,6	99,7	99,6	99,8	99,6	99,6	99,8	99,5	99,5	99,6
	RMSE (%)	7,4	5,7	6,3	5,0	6,2	7,7	4,5	7,4	7,6	7,2



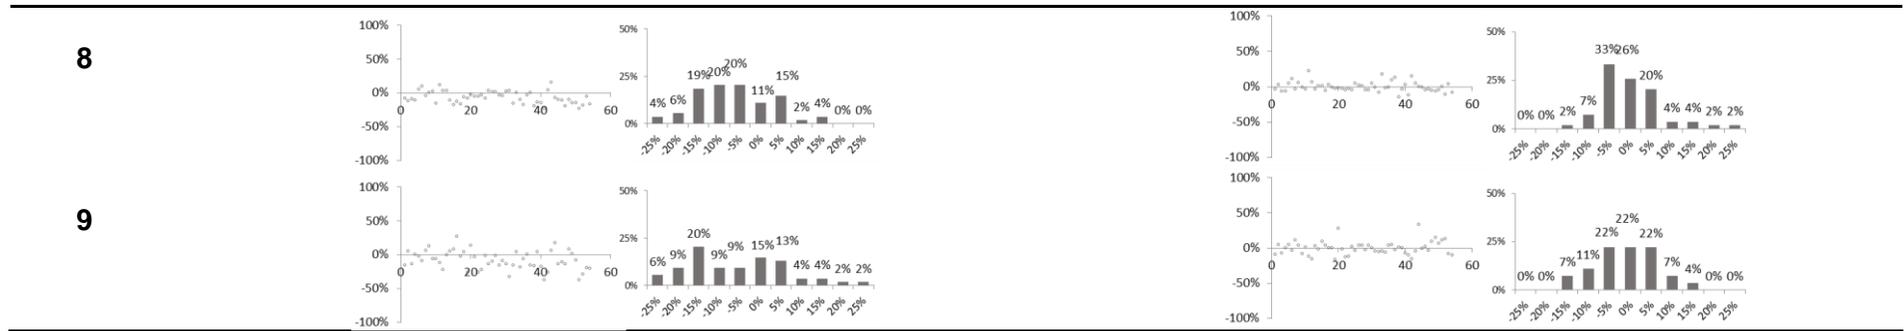


Figura 2 – Dispersão dos erros percentuais em função dos valores observados do dap e histograma de frequência percentual dos erros percentuais por estrato para as estimativas do volume de árvores pelas metodologias testadas.

Ao observar as estatísticas apresentadas para o modelo de Schumacher e Hall considerando todos os estratos, nota-se  $r_{\hat{y}y} = 99,5\%$  e  $RMSE = 9,1\%$ , para análise geral, evidenciando bom ajuste do modelo. Ao observar os gráficos por estrato, os erros percentuais apresentaram-se bem distribuídos com pequena tendência em subestimar volumes para a maioria dos estratos.

De acordo com as estatísticas da RNA selecionada,  $r_{\hat{y}y} = 99,6\%$  e  $RMSE = 7,2\%$ , esta ferramenta demonstrou ser eficaz e eficiente em estimar o volume de árvores de pinus e eucalipto, com oito neurônios na camada oculta. Ao analisar visualmente os gráficos por estrato, é possível notar predominância de gráficos sem tendências de superestimar ou subestimar o volume, com frequência de distribuição dos erros percentuais tendendo à distribuição normal.

Resultados satisfatórios foram encontrados com configurações de apenas 6 ou 8 neurônios na camada oculta, evidenciando que não são necessárias estruturas mais complexas para estimação do volume de árvores. Provavelmente, este resultado pode estar relacionado ao número de neurônios na camada oculta representar a não linearidade entre os dados e, para este caso, não houve necessidade de grande complexidade da estrutura da rede para extrair a relação entre as variáveis utilizadas e o volume das árvores (HAYKIN, 2001).

Braga et al. (2007) e Bullinaria (2010) recomendam configurações mais simples para aplicações de RNA, sempre que apresentarem resultados satisfatórios, evitando ocorrência de *overfitting* facilitando o processo de busca e otimização da configuração para determinada tarefa.

Tanto o algoritmo *errorbackpropagation* quanto o algoritmo *Resilientpropagation* demonstraram desempenho satisfatórios em estimar o volume de árvores de pinus e eucalipto. O algoritmo *errorbackpropagation* demonstrou melhor desempenho das estimativas configurando os parâmetros de taxa de aprendizagem e *momentum* em 0,0001 e 0,0005, respectivamente.

As funções tangente hiperbólica, logística e sigmoideal, nas camadas de entrada e de saída foram eficientes. Notou-se que, em alguns casos, ao utilizar a função tangente hiperbólica na camada de saída a RNA estimou volumes negativos. Tal fato se deve à normalização das variáveis numéricas ter sido realizada entre 0 e 1, enquanto a função tangente hiperbólica resulta em valores entre -1 e 1.

Quando se faz uma análise mais detalhada por estrato, é possível notar maior acurácia das estimativas obtidas pelas RNA em relação ao modelo de regressão, com estimativas mais precisas e exatas em estimar o volume de árvores. É importante evidenciar que as estimativas feitas utilizando o modelo de regressão foram baseadas em nove equações volumétricas, sendo uma para cada estrato proposto. Esta estratificação requer maior quantidade de amostras para cada estrato a fim de obter ajustes satisfatórios das equações. Porém, devido ao alto custo desta amostragem, nem sempre é realizada a estratificação.

O uso de RNA para estimação de volume permite ganho de tempo ao evitar a definição dos estratos, os ajustes e avaliações de modelos volumétricos por estrato. A utilização de RNA também pode gerar redução de custos em estimar volume de árvores ao possibilitar a redução do número de árvores cubadas para determinação do volume sem perda de acurácia (BINOTI, 2012).

Binoti et al. (2014), visando avaliar diferentes configurações do treinamento de Redes Neurais Artificiais (RNA) para estimar o volume de árvores, concluíram que a estimação do volume de árvores por meio de RNA pode ser feita com diferentes configurações, variando o número de neurônios na camada oculta, as funções de ativação, os algoritmos e os parâmetros de treinamento. Ainda evidenciaram que simples configurações, com apenas um neurônio na camada oculta, podem ser utilizadas com eficiência para estimação do volume de árvores.

Silva et al. (2009) avaliaram o ajuste do modelo volumétrico de Schumacher e Hall, bem como a aplicação de redes neurais artificiais para estimação do volume de madeira de eucalipto em função do diâmetro, altura total e clone. Concluíram que as redes neurais artificiais apresentaram boa adequação ao problema, sendo recomendadas para previsão volumétrica da produção de florestas plantadas.

Gorgenset al. (2009) obteve resultados semelhantes ao analisar diferentes estruturas de RNA a fim de estimar o volume de árvores de diferentes locais de crescimento e diferentes espécies. Concluíram que a modelagem por redes neurais foi viável, pois sua capacidade de generalização e conectividade permitiu que se utilizasse apenas uma rede para realizar a predição de volume dessas árvores.

Os resultados encontrados neste trabalho trazem ganhos aos profissionais e as empresas florestais, solucionando um desafio cotidiano, baseado em dados representativos da realidade, com ganho em eficiência e eficácia. A aplicação das

RNA foi capaz de estimar o volume de um plantio florestal heterogêneo, aumentando a acurácia das estimativas obtidas em relação a um método comumente utilizado.

#### **4CONCLUSÃO**

De acordo com os resultados do estudo, concluiu-se que foi possível estimar, de modo eficiente e com exatidão satisfatória, o volume de árvores de diferentes espécies, em diferentes condições de crescimento, utilizando apenas uma rede neural artificial.

Redes neurais artificiais simples, com seis a oito neurônios na camada oculta, podem ser utilizadas para estimação do volume de árvores de diferentes gêneros e espécies com exatidão.

## 5 REFERÊNCIAS

- AKINDELE, S. O.; LEMAY, V. M. Development of tree volume equations for common timber species in the tropical rain forest area of Nigeria. **Forest Ecology and Management**, v.226, n.1-3, p.41-48, 2006.
- BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G. Configuração de redes neurais artificiais para estimação do volume de árvores. **Ciência da Madeira**, v.5, n.1, p.58-67, 2014.
- BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G. Redução dos custos em inventário de povoamentos equiâneos. **Agrária - Revista Brasileira de Ciências Agrárias**, v.8, n.1, p.125-129, 2013b.
- BINOTI, D. H. B.; BINOTI, M. L. M.; LEITE, H. G.; SILVA, A. A. L.; SANTOS, A. C. A. Modelagem da distribuição diamétrica em povoamentos de eucalipto submetidos a desbaste utilizando autômatos celulares. **Revista Árvore**, v.36, n.5, p. 931-940, 2012.
- BINOTI, D. H. B.; BINOTI, M. L. M.; LEITE, H. G.; SILVA, A. A. L.; SANTOS, A. C. A. Modelagem da distribuição de diâmetros utilizando autômatos celulares e redes neurais artificiais. **Cerne**, v.19, n.4, p. 677-685, 2013c.
- BINOTI, M. L. M. DA S. **Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto**. 2010. 54f. 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**. 2012. 130f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2012.
- BINOTI, M. L. M. S.; BINOTI, D. H. B.; LEITE, H. G. Aplicação de redes neurais artificiais para estimação da altura de povoamentos equiâneos de eucalipto. **Revista Árvore**, v.37, n.4, p. 639-645, 2013a.
- BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDEMIR, T. B. **Redes neurais artificiais: teoria e aplicação**. Rio de Janeiro: Editora LTC, 2007. 262p.
- BULLINARIA, J. A. **Introduction to Neural Computation**. Notas de aula. Disponível em: <http://www.cs.bham.ac.uk/~jxb/inc.html>. 2010.
- CLUTTER, J. L.; FORTSON, J. C.; PIENAAR, L. V.; BRISTER, R. G. H.; BAILEY, R. L. **Timber management: a quantitative approach**. New York: John Willey e Sons, 1983. 333 p.
- CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal: perguntas e respostas**. 3. ed. rev. e ampl. Viçosa: UFV, 2009. 548 p.
- DIAMANTOPOULOU, M.; MILIOS, E. Modelling total volume of dominant pine trees in reforestation via multivariate analysis and artificial neural network models. **Biosystems Engineering**, v.105, p.306-315, 2010.

DIAMANTOPOULOU, M. J. Tree-bole volume estimation on standing pine trees using Cascade Correlation Artificial Neural Network Models. **Agricultural Engineering International: The CIGR E Journal**, VIII, 2006.

DIAMANTOPOULOU, M. J. Predicting fir trees stem diameters using Artificial Neural Network models. **Southern African Forestry Journal**, v. 205, n. 1, p. 39–44, nov. 2005a.

DIAMANTOPOULOU, M. J. Artificial neural networks as an alternative tool in pine bark volume estimation. **Computers and electronics in agriculture**, v. 10, p. 235-244, 2005b.

GOLDSCHMIDT, R. R., PASSOS, E. **Data Mining: Um Guia Prático**. 1. ed. Rio de Janeiro: Campos, 2005. 261p.

GÖRGENS, E. B.; LEITE, H. G.; GLERIANI, J. M.; SOARES, C. P. B., CEOLIN, A. Influência da arquitetura na estimativa de volume de árvores individuais por meio de redes neurais artificiais. **Revista Árvore**, v.38, n.2, p. 289-295, 2014.

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

GORGENS, E. **Estimação do volume de árvores utilizando redes neurais artificiais**. Viçosa, MG: UFV, 2006. 84 p. Dissertação (Mestrado em Ciência Florestal) Universidade Federal de Viçosa, Viçosa, 2006.

GUIMARÃES, D. P.; LEITE, H. G. Influência do número de árvores na determinação de equação volumétrica para *Eucalyptus grandis*. **Scientia Forestalis**, n.50, p. 37-42, 1996.

HAYKIN, S. **Redes Neurais: princípios e prática**. Porto Alegre, 2001. 900 p.

HEATON, J. **Programming Neural Networks with Encog3 in Java**. 2 ed. Heaton Research, Inc. 2011. 226 p.

LEDUC, D. J.; MATNEY, T. G.; BELLI, K. L.; JR., V. C. B. Book, Online. Predicting diameter distributions of longleaf pine plantations **U.S. Dept. of Agriculture, Forest Service, Southern Research Station, Asheville**, 18 p, 2001.

LEITE, H. G.; SILVA, M. L. M.; BINOTI, D. H. B.; FARDIN, L.; TAKIZAWA, F. H. Estimation of inside-bark diameter and heartwood diameter for *Tectonagrandis* Linn. trees using artificial neural networks. **European Journal of Forest Research**, v.130, n.2, p.263-269, 2011.

SCHUMACHER, F. X.; HALL, F. S. Logarithmic expression of timber-tree volume. **Journal of Agricultural Research**, v.47, n.9, p719-734, 1933.

SCOLFORO, J. R. MAESTRI, R.; O manejo de florestas plantadas. In: SCOLFORO, J. R. S.; **Manejo Florestal**. Lavras: UFLA/FAEPE, 1998. 438 p.

SILVA, M. L. M.; BINOTI, D. H. B.; GLERIANE, J. M.; LEITE, H. G. Ajuste do modelo de Schumacher e Hall e aplicações de redes neurais artificiais para estimar volume de árvores de Eucalipto. **Revista Árvore**, v. 33, n. 6, p. 1133-1139, 2009.

### CAPÍTULO III – DESCRIÇÃO DO PERFIL DO TRONCO DE ÁRVORES EM PLANTIOS DE DIFERENTES ESPÉCIES POR MEIO DE REDES NEURAIAS ARTIFICIAIS

#### RESUMO

O objetivo deste trabalho foi analisar a capacidade de uma rede neural artificial (RNA) em descrever o perfil do fuste de árvores de diferentes gêneros e espécies em diferentes condições de crescimento. Para este estudo foram utilizados dados de 611 árvores cubadas em uma fazenda pertencente a uma empresa florestal na região do Triângulo Mineiro, em Minas Gerais. Com área de 22.624 hectares, a fazenda possui plantios de pinus e eucalipto, em diferentes idades, ciclos e espaçamentos. Para treinamento das RNA utilizou-se como variáveis de entrada qualitativas: gênero, espécie e rotação atual e como variáveis quantitativas: dap (diâmetro medido a 1,30 m de altura da superfície do solo), altura em que foram coletados os diâmetros ao longo do fuste ( $h$ ), altura total, idade e número de árvores por hectare. A variável de saída consistiu no diâmetro estimado para a altura  $h$ . As redes neurais artificiais testadas foram do tipo *Multilayer Perceptron* (MLP), com os algoritmos *errorbackpropagation* e *resilientpropagation*. Como critério de parada dos treinamentos foi utilizado o número de 15.000 ciclos ou erro quadrático médio inferior a 0,1%. O processamento foi feito no sistema computacional *NeuroForest*. Com o intuito de se avaliar o desempenho das estimativas obtidas por meio de Redes Neurais em termos de acurácia, foram ajustadas equações, empregando-se análise de regressão, para descrever o perfil do tronco, levando-se em conta cada estrato, isto é, as combinações de gênero, espécie e rotação. Tanto para as Redes Neurais quanto para as equações de regressão, a avaliação da acurácia foi realizada com base no coeficiente de correlação entre os diâmetros observados e estimados ao longo do fuste, a raiz quadrada do erro quadrático médio percentual (RMSE) e análise gráfica da dispersão dos erros percentuais em função dap, histograma de frequência percentual dos erros percentuais e do perfil do fuste por estrato. Assim, foram selecionadas as RNA com maiores coeficientes de correlação e menores RMSE, com os gráficos de dispersão dos erros percentuais sem tendenciosidade, histograma de resíduos com maior ocorrência de estimativas em torno de zero e maior capacidade em descrever o perfil do fuste. A utilização de RNA para descrever o afilamento do fuste permitiu ganho de tempo ao evitar a estratificação, ajustes e avaliações de modelos de afilamento por estrato. A utilização de apenas uma RNA para descrever o perfil do fuste de árvores de diferentes espécies foi eficiente e demonstrou maior praticidade em relação às equações de regressão ajustadas.

**Palavras-chave:** Inventário Florestal, Manejo Florestal, Redes Neurais Artificiais.

### CHAPTER III - DESCRIPTION PROFILE TRONDO TREES IN PLANTATIONS NETWORKS THROUGH DIFFERENT SPECIES ARTIFICIAL NEURAL

#### ABSTRACT

The objective of this study was to analyze the ability of an artificial neural network (ANN) to describe the profile of the trunk of trees of different genera and species in different growing conditions. For this study we used data of 611 trees scaled on a farm belonging to a forestry company in the TrianguloMineiro region, Minas Gerais. With 22.624 hectares, the farm has pine and eucalyptus plantations, at different ages, cycles and spacing. For training of RNA was used as qualitative input variables: gender, type and actual speed and how quantitative variables: dbh (diameter measured at 1.3 m of soil surface height), at which were collected diameters over the stem (h), total height, age and number of trees per hectare. The output variable consisted of the estimated diameter to the height h. The tested artificial neural networks were the kind Multilayer Perceptron (MLP) with error backpropagation algorithms and resilient propagation. As the training stopping criterion we used the number of 15,000 cycles or mean square error less than 0.1%. The processing was done in the computer system NeuroForest. In order to evaluate the performance of the estimates obtained by means of neural networks in terms of accuracy, equations were adjusted, using regression analysis to describe the stem profile, taking into account each stratum, i.e. gender combinations, species and rotation. So much for the Neural Networks and for the regression equations, evaluation of accuracy was based on the correlation coefficient between the observed and estimated diameters along the stem, the square root of the mean square percentage error (RMSE) and graphical analysis of dispersion of percentage errors in dap function, frequency histogram percentage of percentage errors and the shaft by stratum profile. Thus, the RNA were selected highest correlation coefficients and lower RMSE, with the scatter plots of percentage errors in an unbiased waste histogram with higher incidence estimates around zero and greater ability to describe the shaft profile. The use of RNA to describe taper-enabled savings in time to avoid stratification adjustments and reviews of taper models for each stratum. The use of only one RNA to describe the profile of the different species of trees bole was efficient and showed greater convenience compared to adjusted regression equations.

**Key words:** Forest inventory, forest management, artificial neural networks.

## 1INTRODUÇÃO

Historicamente, no Brasil, o mercado de madeira sólida é abastecido principalmente por produtos de florestas nativas, explorados, na maioria das vezes, de forma irregular. Diante disso, há a necessidade de substituição dessa matéria prima por madeira oriunda de floresta plantada, buscando reduzir o impacto sobre as florestas nativas e garantir o abastecimento constante desse mercado.

Para se ter um produto competitivo neste mercado, é necessário utilizar técnicas para aumentar a produção e a qualidade da madeira dos plantios florestais. Com isso, práticas como desbaste e desrama passaram a ser estudadas e aplicadas em plantios comerciais (SILVA, 1970; SOARES, 1970; CAMPOS, 1980; BERTOLOTTI et al., 1983; NOGUEIRA, 2001; NOGUEIRA, 2003; DIAS 2005; MONTE et al, 2009; LEITE et al., 2010 e BINOTI, 2010a). Aliado a estas técnicas de manejo, é indispensável a definição de estratégias ótimas para destinação destes produtos, maximizando o retorno econômico do investimento.

Com o intuito de definir estratégias representativas da realidade, convertendo árvores em multiprodutos, com aumento significativo da receita oriunda de um povoamento florestal, é preciso ter informações confiáveis do perfil dos fustes. A precisão das estimativas obtidas para descrever os perfis dos fustes é decisiva para o sucesso de um processo de otimização e tem sido objetivo de vários estudos (ASSIS et al., 2001; FISCHER et al., 2001; MENDONÇA et al., 2007; SOUZA et al., 2008; SOUZA, 2009; LEITE et al., 2011; CAMPOS et. al., 2013 e MÔRA et al., 2014).

É possível destacar diferentes modelos desenvolvidos buscando melhor desempenho das estimativas obtidas para descrever o perfil do fuste de forma fiel (KOZAK; MUNRO; SMITH, 1969; DEMAERSCHALK, 1972; ORMEROD, 1973; MAX; BURKHART, 1976; GARAY, 1979; BALDWIN, 1991; GARCIA; LEITE; YARED, 1993; LEITE; GARCIA, 2001 e PIRES; CALEGÁRIO, 2007).

Diante da necessidade de obtenção de novas ferramentas e metodologias com o objetivo de descrever o perfil do fuste, as redes neurais artificiais (RNA) possuem a capacidade de assimilar e modelar diversas variáveis e suas relações não lineares, com a possibilidade de utilizar variáveis qualitativas e quantitativas para melhor assimilação do conhecimento de forma análoga ao sistema neurobiológico (HAYKIN, 2001).

A eficiência da aplicação de RNA em plantios florestais vem sendo comprovada por diversos estudos realizados nos últimos anos, principalmente ligados à mensuração florestal. Nesta área podem ser citados os trabalhos sobre estimação de altura (BINOTI et al., 2013a; BINOTI et al., 2013b), estimação do volume de árvores (DIAMANTOPOULOU, 2006; GÖRGENS et al., 2009; SILVA et al., 2009; DIAMANTOPOULOU; MILIOS, 2010; BINOTI et al., 2014; GÖRGENS et al., 2014), modelagem em nível de povoamento (BINOTI, 2010b), modelagem em nível de árvores individuais (BINOTI, 2010b), modelagem por classe de diâmetro (LEDUC et al., 2001; BINOTI et al., 2010a; BINOTI et al., 2012; BINOTI et al., 2013c), modelagem do afilamento do fuste (DIAMANTOPOULOU, 2005a ; LEITE et al., 2011; SOARES, 2012) e quantificação de casca (DIAMANTOPOULOU, 2005b).

Diante do exposto, este trabalho possui o objetivo de analisar a capacidade de uma rede neural artificial (RNA) em descrever o perfil do fuste de árvores de diferentes gêneros e espécies, em distintas condições de crescimento.

## 2 MATERIAL E MÉTODOS

### 2.1 DESCRIÇÃO DA ÁREA E COLETA DE DADOS

Este estudo foi realizado com dados de uma fazenda pertencente a uma empresa florestal na região do Triângulo Mineiro, em Minas Gerais. A área de plantio é de 22.624 hectares, possuindo plantios de pinus (475 ha, 2% da área) e eucalipto (22.149, 98% da área), em diferentes idades, ciclos e espaçamentos de plantio (Tabelas 1). Foram utilizados dados de cubagem de 611 árvores-amostra (Tabela 2).

Tabela 1 – Proporção da área de plantio de acordo com gênero e classe de idade.

Gênero		Classe de Idade (anos)						Total	
		2,0 - 3,0	3,0 - 4,0	4,0 - 5,0	5,0 - 6,0	6,0 - 7,0	7,0 - 8,0		8,0 - 9,0
Eucalipto	Área (ha)	5.117	6.679	1.839	3.104	3.319	2.092	<b>22.149</b>	
	% do Total	23%	30%	8%	14%	15%	9%	<b>98%</b>	
Pinus	Área (ha)						225	250	<b>475</b>
	% do Total						1%	1%	<b>2%</b>
Total	Área (ha)	<b>5.117</b>	<b>6.679</b>	<b>1.839</b>	<b>3.104</b>	<b>3.319</b>	<b>2.318</b>	<b>250</b>	<b>22.624</b>
	% do Total	<b>23%</b>	<b>30%</b>	<b>8%</b>	<b>14%</b>	<b>15%</b>	<b>10%</b>	<b>1%</b>	<b>100%</b>

Tabela 2 – Frequência de árvores cubadas por gênero.

Gênero	Classe de idade (anos)					Total
	3,0 - 4,0	4,0 - 5,0	6,0 - 7,0	7,0 - 8,0	8,0 - 9,0	
Eucalipto	292	38	173			503
Pinus				59	49	108
<b>Total</b>	<b>292</b>	<b>38</b>	<b>173</b>	<b>59</b>	<b>49</b>	<b>611</b>

As árvores foram cubadas nas posições de 0,0; 0,3; 0,7; 1,3; 2,0m e, após essa alturaa cada 1,0 m até a altura comercial da árvore. O gráfico da Figura 1 evidencia o perfil do fuste observado no povoamento, correlacionando as razões  $d/dap$  e  $h/Ht$ .

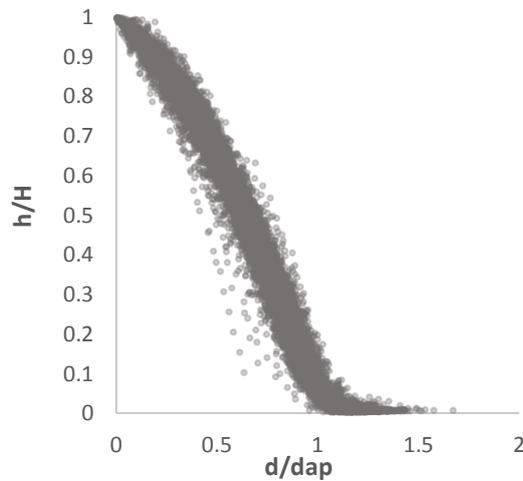


Figura 1 – Gráfico de perfil do fuste evidenciando a tendência entre as razões de posição onde foram coletados os diâmetros ao longo do fuste por altura total da árvore e diâmetro coletado ao longo do fuste por diâmetro à altura do peito (dap).

## 2.2 REDES NEURAIS ARTIFICIAIS

O treinamento das RNA foi realizado visando estimar o diâmetro ao longo do fuste (saída) em cm, utilizando como variáveis de entrada qualitativas o gênero (duas variáveis categóricas), a espécie (cinco variáveis categóricas) e a rotação atual (duas variáveis categóricas). As variáveis quantitativas foram o dap (diâmetro medido a 1,30 m de altura da superfície do solo) em cm, altura em que foram coletados os diâmetros ao longo do fuste (m), altura total das árvores (m), idade (meses) e número de árvores por hectare. As estatísticas descritivas das variáveis quantitativas por estrato são apresentadas na Tabela 3.

Tabela 3 – Estatísticas descritivas das variáveis contínuas amostradas e utilizadas para treinamento das redes neurais.

Variável	Estrato	Estatísticas descritivas					Estrato	Estatísticas descritivas				
		Mínimo	Máximo	Média	Mediana	Desv. Pad.		Mínimo	Máximo	Média	Mediana	Desv. Pad.
<b>Idade (meses)</b>	1	6,42	6,42	6,42	6,42	0,00	6	3,67	3,67	3,67	3,67	0,00
<b>dap (cm)</b>		6,00	20,50	14,63	14,30	4,04		4,15	17,60	11,26	11,80	3,71
<b>N (arv./ha)</b>		1116,07	1116,07	1116,07	1116,07	0,00		1666,67	1666,67	1666,67	1666,67	0,00
<b>Ht (m)</b>		11,10	29,10	21,97	22,10	4,93		9,40	21,90	16,94	17,40	2,97
<b>h (m)</b>		0,10	25,00	8,76	8,00	6,16		0,10	21,00	7,32	7,00	5,46
<b>d (cm)</b>		3,50	24,40	10,17	9,50	4,35		1,00	20,45	7,79	7,15	4,25
<b>Idade (meses)</b>	2	5,42	6,92	6,84	6,92	0,25	7	3,42	3,42	3,42	3,42	0,00
<b>dap (cm)</b>		6,78	21,17	14,81	15,60	4,42		4,10	13,60	9,45	9,55	2,78
<b>N (arv./ha)</b>		1116,07	1116,07	1116,07	1116,07	0,00		1111,11	1111,11	1111,11	1111,11	0,00
<b>Ht (m)</b>		13,73	29,02	23,93	25,48	4,30		9,20	18,90	14,96	15,10	2,29
<b>h (m)</b>		0,10	28,00	10,66	10,00	7,67		0,10	18,00	6,30	6,00	4,70
<b>d (cm)</b>		0,55	27,45	10,03	9,60	5,21		1,00	18,85	6,77	6,30	3,42
<b>Idade (meses)</b>	3	3,33	3,92	3,70	3,83	0,19	8	7,67	8,42	7,75	7,67	0,20
<b>dap (cm)</b>		4,10	17,41	10,73	9,45	4,56		7,48	24,13	17,57	18,94	4,73
<b>N (arv./ha)</b>		1754,39	1754,39	1754,39	1754,39	0,00		1661,13	1661,13	1661,13	1661,13	0,00
<b>Ht (m)</b>		8,40	24,36	17,65	16,90	4,87		10,00	18,90	15,99	16,76	2,25
<b>h (m)</b>		0,10	24,00	7,51	6,60	6,11		0,10	18,00	6,94	7,00	5,14
<b>d (cm)</b>		0,10	21,05	7,41	6,55	4,38		0,80	29,40	11,47	11,10	6,44
<b>Idade (meses)</b>	4	3,60	4,13	3,93	4,13	0,24	9	7,58	8,67	8,07	7,58	0,54
<b>dap (cm)</b>		4,15	16,55	9,76	8,75	3,72		6,68	24,51	17,47	18,84	4,75
<b>N (arv./ha)</b>		1666,67	1666,67	1666,67	1666,67	0,00		1661,13	1661,13	1661,13	1661,13	0,00
<b>Ht (m)</b>		9,70	23,40	17,18	16,50	4,19		10,92	20,30	16,83	16,70	2,20
<b>h (m)</b>		0,10	23,00	7,38	7,00	5,76		0,10	20,00	7,36	7,00	5,42
<b>d (cm)</b>		0,30	22,30	6,77	6,05	3,89		0,50	29,80	11,60	11,10	6,58

Variável	Estrato	Estatísticas descritivas					Estrato	Estatísticas descritivas				
		Mínimo	Máximo	Média	Mediana	Desv. Pad.		Mínimo	Máximo	Média	Mediana	Desv. Pad.
<b>Idade (meses)</b>		3,58	3,58	3,58	3,58	0,00						
<b>dap (cm)</b>		4,10	18,00	12,30	13,45	3,97						
<b>N (arv./ha)</b>		1754,39	1754,39	1754,39	1754,39	0,00						
<b>Ht (m)</b>	5	9,40	19,50	16,25	16,80	2,70						
<b>h (m)</b>		0,10	18,00	7,08	7,00	5,23						
<b>d (cm)</b>		1,00	22,45	8,32	7,55	4,68						

em que: dap= diâmetro medido a 1,30 m de altura (cm); *N* = número de árvores por hectares; *Ht* = altura total das árvores (m); *h* = altura em que foram coletados os diâmetros ao longo do fuste (m) e; *d* = diâmetro coletado ao longo do fuste (cm).

Para treinamento das RNA utilizou-se o sistema livre NeuroForest 3.0 (<http://neuroforest.ucoz.com/>).

As variáveis contínuas foram normalizadas linearmente no intervalo de 0 a 1 e as variáveis categóricas foram normalizadas utilizando a metodologia 1-de-N (GOLDSCHMIDT; PASSOS, 2005; HEATON, 2011).

O número de neurônios na camada de entrada variou de acordo com o tipo (qualitativa ou quantitativa) e o número de variáveis de entrada. Considerou-se um neurônio para cada variável quantitativa e um neurônio para cada classe de cada variável qualitativa. O número de neurônios na camada oculta variou entre o intervalo de 4 e 16 neurônios (com incremento a cada dois neurônios). A camada de saída foi constituída por um neurônio, sendo este referente ao diâmetro estimado para a altura  $h$ . Como funções de ativação da camada oculta e de saída foram testadas a função tangente hiperbólica, logística e sigmoide. Além disso, foram testadas as RNA do tipo *MultilayerPerceptron* (MLP), e os algoritmos de treinamento *errorbackpropagation* e *resilientpropagation* (Haykin, 2001). Para o algoritmo *errorbackpropagation*, foram analisadas variações no valor da taxa de aprendizado (0,001 e 0,0001) e no parâmetro *momentum* (0,005 e 0,0005). Além das variações testadas, foram analisadas as estratégias de auto ajuste destes parâmetros, nos quais o processo reduz os valores dos parâmetros ao longo da evolução do algoritmo. Já para o algoritmo *resilientpropagation* foi utilizada a variação RPROP+ (HEATON, 2011).

Como critério de parada dos treinamentos das RNA foi utilizado o número total de 15.000 ciclos ou erro quadrático médio inferior a 0,1%. Os pesos iniciais de todas as redes foram gerados de forma aleatória. Para cada combinação avaliada foram treinadas cinco redes, sendo selecionada a melhor destas, com base nos critérios de avaliação, para posterior comparação entre as combinações.

Com o intuito de se comparar alguns modelos de regressão comumente utilizados pelas empresas brasileiras para descrição do perfil do fuste em plantios comerciais com as Redes Neurais, foram selecionados os modelos de Kozak, Munro e Smith (1969), Demaerschalk (1972), Ormerod (1973) e Garay (1979). Para ajuste destes modelos, a base foi estratificada formando, com isso, nove estratos, buscando-se agrupar os dados de características mais homogêneas de acordo com gênero, espécie, rotação, espaçamento e classe de idade.

a) Kozak, Munro e Smith (1969)

$$\left(\frac{d}{dap}\right)^2 = \beta_1 + \beta_2 \left(\frac{h}{Ht}\right) + \beta_3 \left(\frac{h}{Ht}\right)^2 + \varepsilon \quad (1)$$

b) Demaerschalk (1972)

$$\left(\frac{d}{dap}\right)^2 = 10^{(2\beta_0)} dap^{(2\beta_1-2)} Ht^{(2\beta_2)} (Ht - h)^{(2\beta_3)} + \varepsilon \quad (2)$$

c) Ormerod (1973)

$$\frac{d}{dap} = \left(\frac{Ht-h}{Ht-1,3}\right)^{\beta_3} + \varepsilon \quad (3)$$

d) Garay (1979)

$$\frac{d}{dap} = \beta_0 (1 + \beta_1 \ln(1 - \beta_2 h^{\beta_3} Ht^{-\beta_3})) + \varepsilon \quad (4)$$

em que:

$d$  = diâmetro observado na altura  $h$  (cm);

$dap$  = diâmetro a 1,30 m de altura da superfície do solo (cm);

$\beta_i$  = parâmetro a ser estimado ( $i = 0, 1, 2$  e  $3$ );

$\varepsilon$  = erro aleatório;

$h$  = altura em que foram coletados os diâmetros ao longo dos fustes (m); e

$Ht$  = altura total (m).

### 2.3 AVALIAÇÃO DAS ESTIMATIVAS DAS REDES NEURAIS ARTIFICIAIS E DO MODELO DE REGRESSÃO

A avaliação das redes neurais artificiais, bem como dos modelos de afilamento, foi realizada com base nas estatísticas:

a) Coeficiente de correlação entre os diâmetros observados e estimados

$$r_{\hat{y}y} = \frac{\text{cov}(\hat{Y}_i, Y_i)}{\sqrt{S^2(\hat{Y}_i)S^2(Y_i)}} \quad (3)$$

em que:

$s^2$ : variância e;

cov: covariância.

b) raiz quadrada do erro médio (RMSE- *Root Mean Square Error*)

$$RMSE(\%) = \frac{100}{\bar{Y}} \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad (4)$$

em que:

$\bar{Y}$ : média dos diâmetros observados e;

n: número total de árvores.

Além destas estatísticas, foi realizada a análise gráfica da dispersão dos erros percentuais em função do dap e do histograma de frequência percentual dos erros percentuais.

$$\text{erro}(\%) = \frac{\hat{Y}_i - Y_i}{Y_i} \cdot 100 \quad (2)$$

em que:

$Y_i$ : diâmetro observado na altura h da i-ésima árvore; e

$\hat{Y}_i$ : diâmetro estimado na altura h da i-ésima árvore.

Foi escolhida a RNA que apresentou maior coeficiente de correlação e menor RMSE, e gráficos de dispersão sem tendenciosidade e histogramas e com maior ocorrência de estimativas em torno de zero.

### 3 RESULTADOS E DISCUSSÃO

Foram ajustadas nove equações, uma para cada estrato, para cada modelo de afilamento avaliado, sendo que o modelo de Garay foi o que apresentou os melhores resultados em termos de acurácia, isto é, maior coeficiente de correlação entre os diâmetros observados ao longo do fuste e os diâmetros estimados, melhor dispersão dos resíduos e histograma de frequência dos resíduos indicando maior proximidade dos valores observados e estimados. As estimativas dos parâmetros deste modelo são evidenciados na Tabela 4. Salienta-se que os modelos de Demaerschalk e Ormerod não obtiveram ajustes satisfatórios em descrever o perfil do fuste para os dados utilizados.

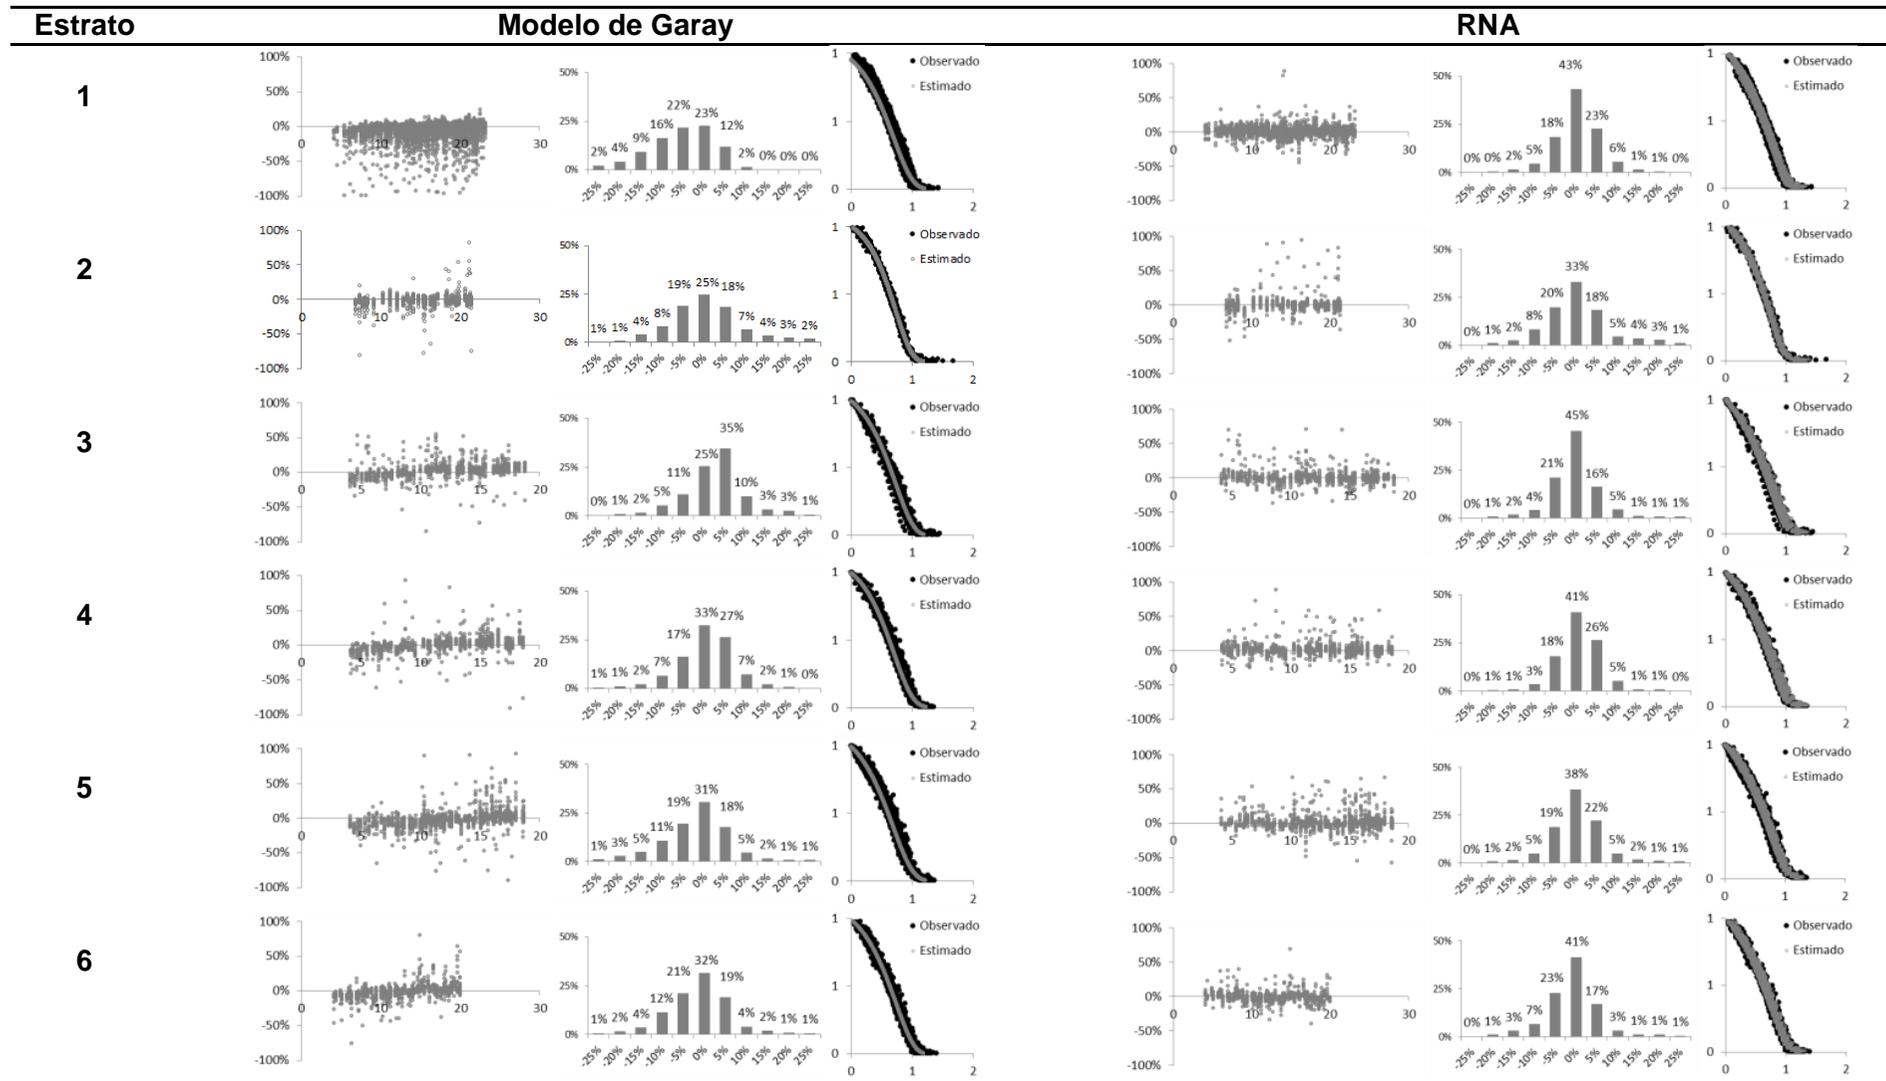
Tabela 4 – Parâmetros das equações dos modelos de afilamento de Garay ajustados para cada estrato.

Estrato	Modelo	Parâmetros			
		$\hat{\beta}_0$	$\hat{\beta}_1$	$\hat{\beta}_2$	$\hat{\beta}_3$
1	Garay	1,4126	0,2564	0,9865	0,1417
2	Garay	1,4462	0,2034	0,9927	0,0859
3	Garay	1,3638	0,2664	0,9781	0,1798
4	Garay	1,5709	0,2150	0,9909	0,0783
5	Garay	1,5063	0,2455	0,9839	0,1109
6	Garay	1,3299	0,2837	0,9724	0,2114
7	Garay	1,6503	0,1842	0,9967	0,0523
8	Garay	1,2543	0,3686	0,9310	0,2954
9	Garay	1,5490	0,2318	0,9875	0,0906

Na Tabela 5 são apresentadas as estatísticas da RNA e do modelo de afilamento selecionado com melhor capacidade de estimar os diâmetros ao longo dos fustes de árvores de pinus e eucalipto. Na Figura 1 são expostos os gráficos de dispersão dos resíduos e histograma de frequência dos resíduos.

Tabela 5 – Estatísticas dos ajustes do modelo de afilamento e das RNA, bem como descrições das configurações das RNA selecionadas.

Estatísticas	Estratos										
	1	2	3	4	5	6	7	8	9	Geral	
Garay	$r_{\hat{y}y}$ (%)	99,0	99,1	99,5	99,6	99,4	99,5	99,1	99,2	99,1	99,1
	RMSE (%)	9,6	7,1	6,9	6,0	6,3	6,1	7,2	7,4	7,9	7,9
RNA	$r_{\hat{y}y}$ (%)	99,5	99,5	99,7	99,7	99,6	99,6	99,4	99,4	99,4	99,5
	RMSE (%)	4,6	5,4	4,6	4,1	5,2	5,2	5,8	6,4	6,6	5,3



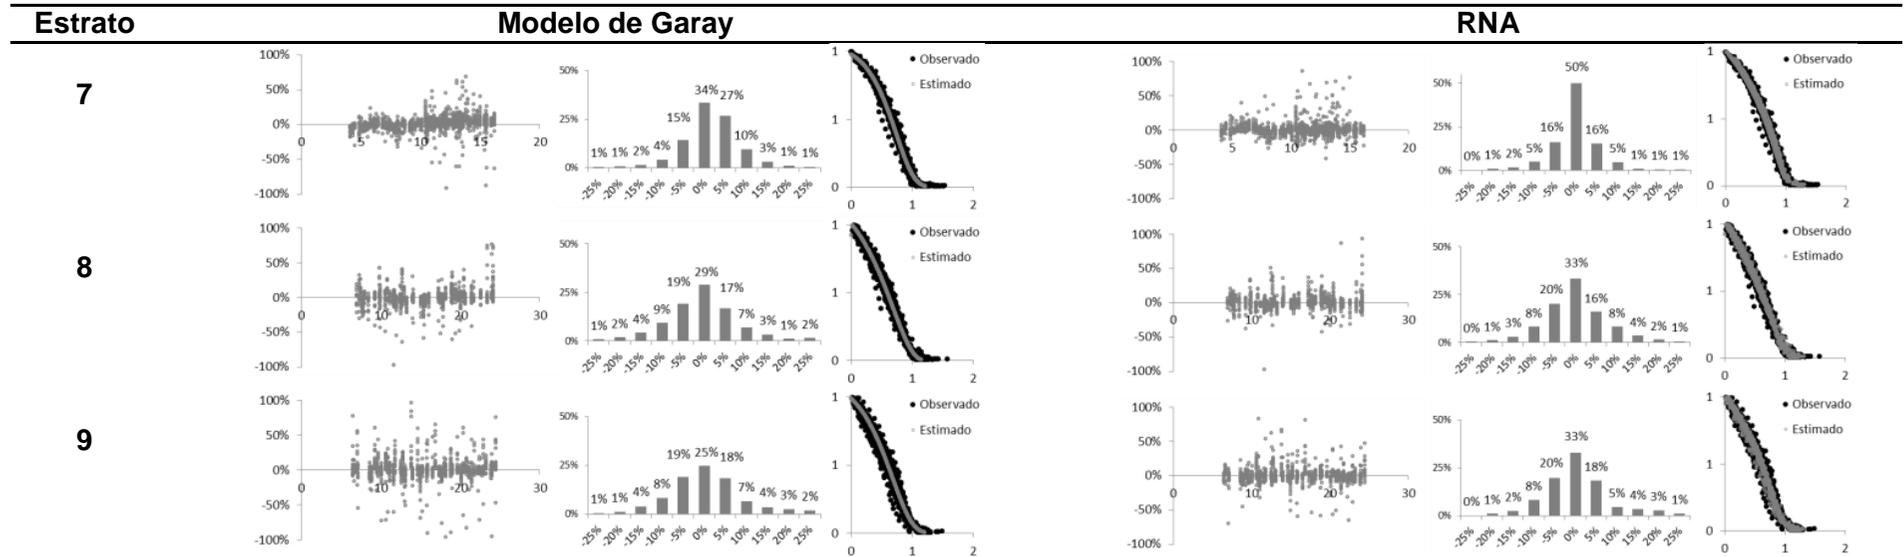


Figura 2 – Gráficos de dispersão dos resíduos em função do dap, histograma de frequência de resíduos e gráficos de perfil do fuste evidenciando o comportamento das estimativas e desvios encontrados entre diâmetro observado e estimado ao longo do fuste.

Com base nas estatísticas utilizadas para análise do desempenho dos modelos e os gráficos utilizados para análise visual do ajuste, o modelo de regressão de Garay obteve melhor desempenho em descrever o perfil do fuste, com  $r_{\hat{y}y} = 99,1\%$  e  $RMSE = 7,9\%$ . Ao analisar os gráficos por estrato, pode-se notar que o modelo de Garay demonstrou-se ligeiramente tendencioso em estimar os diâmetros ao longo do fuste para alguns estratos.

Ao analisar as estatísticas referentes aos diâmetros ao longo dos fustes estimados pela RNA selecionada, pode-se notar  $r_{\hat{y}y} = 99,5\%$  e  $RMSE = 5,3\%$ , com gráficos de dispersão de resíduos e histogramas de resíduos não tendenciosos, com capacidade de descrever o perfil do fuste de forma fidedigna.

Observam-se resultados satisfatórios em configurações de apenas seis ou oito neurônios na camada oculta, evidenciando que não são necessárias estruturas complexas para estimação do diâmetro ao longo do fuste. Isso pode estar relacionado ao número de neurônios na camada oculta, ligado à representação da não linearidade entre os dados (BINOTI, 2012) e, para este caso, não houve necessidade de grande complexidade da estrutura da rede para extrair a relação entre as variáveis utilizadas e o perfil do fuste.

Recomendam-se configurações mais simples para essa aplicação das RNA, evitando ocorrência de *overfittinge* facilitando o processo de busca e otimização da configuração para determinada tarefa (BRAGA et al., 2007; BULLINARIA, 2010).

O algoritmo *errorbackpropagation* obteve desempenho inferior ao algoritmo *Resilientpropagation* para estimar o diâmetro ao longo do fuste.

As três funções de ativação testadas (tangente hiperbólica, logística e sigmoidal) apresentaram resultados satisfatórios para estimação do diâmetro ao longo do fuste, tanto na camada oculta quanto na camada de saída. Notou-se que, em alguns casos, ao utilizar a função tangente hiperbólica na camada de saída, a RNA estimou volumes negativos.

Para o algoritmo *errorbackpropagation*, o melhor desempenho foi encontrado para a configuração dos parâmetros taxa de aprendizagem e *momentum* em 0,0001 e 0,0005, respectivamente, e quando se utilizou a estratégia de auto ajuste.

As estimativas obtidas por meio das equações de regressão ajustadas foram baseadas em nove equações de afilamento para cada modelo, sendo uma para

cada estrato. Esta estratificação requer maior quantidade de amostras para cada estrato a fim de obter ajustes satisfatórios das equações, o que nem sempre ocorre.

A utilização de RNA para descrever o afilamento do fuste permite ganho de tempo com ao evitar a estratificação, ajustes e avaliações de modelos de afilamento por estrato. A possibilidade de redução do custo de inventário, reduzindo o número de árvores amostra para obtenção da altura e volume de árvores já foi comprovada por Binoti (2012). Logo, nota-se a possibilidade de reduzir o número de árvores amostra para descrever o afilamento do fuste com a mesma precisão.

#### **4CONCLUSÃO**

De acordo com os resultados expostos ao longo do trabalho, pode-se demonstrar que métodos de inteligência artificial, especialmente RNA, podem ser eficazes em descrever o perfil do fuste de árvores de diferentes espécies em diferentes condições de crescimento utilizando apenas uma RNA, com maior eficiência e praticidade em relação aos modelos de regressão tradicionalmente empregados por empresas florestais.

## 5 REFERÊNCIAS

- ASSIS, A.L.; SCOLFORO, J. R. S.; MELLO, J. M.; WEIMAR, F. A.; OLIVEIRA, A. D. Comparação de modelos polinomiais segmentados e não-segmentados na estimativa de diâmetros e volumes ao longo do fuste de *Pinus taeda*. **Cerne**, Lavras, v. 7, n. 1, p. 20-40, 2001.
- 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.
- BINOTI, D. H. B.; LEITE, H.G.; NOGUEIRA, G. S.; SILVA, M. L. M. DA; GARCIA, S. L. R.; CRUZ, J. P. DA. Uso da função Weibull de três parâmetros em um modelo de distribuição diamétrica para plantios de eucalipto submetidos a desbaste. **Revista Árvore**, v. 34, p. 147-156, 2010a.
- BINOTI, D. H. B.; BINOTI, M. L. M.; LEITE, H. G.; SILVA, A. A. L.; SANTOS, A. C. A. Modelagem da distribuição diamétrica em povoamentos de Eucalipto submetidos a desbaste utilizando autômatos celulares. **Revista Árvore**, v.36, n.5, p. 931-940, 2012.
- BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G. Redução dos custos em inventário de povoamentos equiâneos. **Agrária - Revista Brasileira de Ciências Agrárias**, v.8, n.1, p.125-129, 2013b.
- BINOTI, D. H. B.; BINOTI, M. L. M.; LEITE, H. G.; SILVA, A. A. L.; SANTOS, A. C. A. Modelagem da distribuição de diâmetros utilizando autômatos celulares e redes neurais artificiais. **Cerne**, v.19, n.4, p. 677-685, 2013c.
- BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G. Configuração de redes neurais artificiais para estimação do volume de árvores. **Ciência da Madeira** (Braz. J. Wood Sci.), v.5, n.1, p.58-67, 2014.
- BINOTI, M. L. M. DA S. **Redes neurais artificiais para prognose da produção de povoamentos não desbastados de Eucalipto**. 2010. 54f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2010b.
- BINOTI, M. L. M. S. **Emprego de redes neurais artificiais em mensuração e manejo florestal**. 2012. 130f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2012.
- BINOTI, M. L. M. S.; BINOTI, D. H. B.; LEITE, H. G. Aplicação de redes neurais artificiais para estimação da altura de povoamentos equiâneos de Eucalipto. **Revista Árvore**, v.37, n.4, p. 639-645, 2013a.
- BERTOLOTTI, G.; SIMÕES, J. W.; NICOLIELO, N.; GARNICA, J. B. Efeitos de diferentes métodos e intensidades de desbaste na produtividade de *Pinus caribaea* var. *hondurensis* Barr. et Golf. **IPEF**, Piracicaba, (24): 47-54, 1983.
- BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDEMIR, T. B. **Redes neurais artificiais: teoria e aplicação**. Rio de Janeiro: Editora LTC, 2007. 262p.
- BULLINARIA, J. A. **Introduction to Neural Computation**. Notas de aula. Disponível em: <http://www.cs.bham.ac.uk/~jxb/inc.html>. 2010.

- CAMPOS, J. C. C. Análise de crescimento e produção em plantações desbastadas. *Revista Árvore*, Viçosa, v. 4, n. 2, p. 157-169, 1980.
- CAMPOS, B. P. F.; BINOTI, D. H. B.; LOPES SILVA, M.; LEITE, H. G.; BINOTI, M. L. M. S. Conversão de árvores em multiprodutos da madeira utilizando programação inteira. **Revista Árvore**, Viçosa-MG, v.37, n.5, p.881-887, 2013.
- DEMAERSCHALK, J.P. Integrated systems for the estimation of tree taper and Volume. **Canadian Journal Forest Research**, Ottawa, v. 3, n. 90, p. 90-94, 1972.
- DIAMANTOPOULOU, M. J. Predicting fir trees stem diameters using Artificial Neural Network models. **Southern African Forestry Journal**, v. 205, n. 1, p. 39–44, nov. 2005a.
- DIAMANTOPOULOU, M. J. Artificial neural networks as an alternative tool in pine bark volume estimation. **Computers and electronics in agriculture**, v. 10, p. 235-244, 2005b.
- DIAMANTOPOULOU, M. J. Tree-Bole Volume Estimation on Standing Pine Trees Using Cascade Correlation Artificial Neural Network Models. **Agricultural Engineering International: The CIGR EJournal**, VIII, 2006.
- DIAMANTOPOULOU, M.; MILIOS, E. Modelling total volume of dominant pine trees in reforestations via multivariate analysis and artificial neural network models. **Biosystems Engineering**, v.105, p.306-315, 2010.
- DIAS, A. N. **Um modelo para gerenciamento de plantações de eucalipto submetidas a desbaste**. 2005. 135 p. Tese (Doutorado Ciência Florestal) – Universidade Federal de Viçosa, Viçosa.
- FISCHER, F.; SCOLFORO, J. R. S.; WEIMAR, F. A.; 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**, Santa Maria, v.11, n. 1, p.167-188, 2001.
- GARAY, L. **Tropical forest utilization system**. VIII. A taper model for entire stem profile including buttressing. Seattle: Coll. Forest Res., Inst. Forest Prod. Univ. Wash., 1979. 64 p. (Contrib. 36).
- GARCIA, S. L. R.; LEITE, H. G.; YARED, J. A. G. Análise do perfil do tronco de morotó (*Didymopanax morototoni*) em função do espaçamento. In: CONGRESSO FLORESTAL PANAMERICANO, 1., CONGRESSO FLORESTAL BRASILEIRO, 7., 1993, Curitiba. **Anais...** Curitiba: SBS/SBEF, 1993. p. 485-491.
- GOLDSCHMIDT, R. R., PASSOS, E. **Data Mining: Um Guia Prático**. 1. ed. Rio de Janeiro: Campos, 2005. 261p.
- GÖRGENS, E. B.; LEITE, H. G.; SANTOS, H. N.; GLERIANI, J. M. Estimção do volume de árvores utilizando redes neurais artificiais. **Revista Árvore**, v.33, n.6, p. 1141-1147, 2009.
- GÖRGENS, E. B.; LEITE, H. G.; GLERIANI, J. M.; SOARES, C. P. B., CEOLIN, A. Influência da arquitetura na estimativa de volume de árvores individuais por meio de redes neurais artificiais. **Revista Árvore**, v.38, n.2, p. 289-295, 2014.

- HAYKIN, S. **Redes Neurais: princípios e prática**. Porto Alegre, 2001.900 p.
- HEATON, J. **Programming Neural Networks with Encog3 in Java**. 2nd ed. Heaton Research, Inc. 2011.226 p.
- KOZAK, A.; MUNRO, D. D.; SMITH, J. G. H. Taper functions and their applications in forest inventory. **Forest Chronicle**, Ottawa, v.45, n.4, p.278-283, 1969.
- LEDUC, D. J.; MATNEY, T. G.; BELLI, K. L.; JR., V. C. B. Book, Online. Predicting diameter distributions of longleaf pine plantations **U.S. Dept. of Agriculture, Forest Service, Southern Research Station, Asheville**, 18 p, 2001.
- LEITE, H. G.; GARCIA, S. L. R. **Pesquisa e desenvolvimentos em inventário, mensurações e manejo florestal na CENIBRA**. Viçosa, MG: Sociedade de Investigações Florestais, 2001. 49 p. (Relatório Técnico, SIF).
- LEITE, H. G.; BINOTI, D. H. B.; GUIMARÃES, D. P.; SILVA, M. L. M.; GARCIA, L. G. R. Avaliação do ajuste das funções Weibull e hiperbólica a dados de povoamentos de eucalipto submetidos a desbaste. **Revista Árvore**, Viçosa, v. 34, n. 2, p. 305-311, 2010.
- LEITE, H. G.; SILVA, M. L. M.; BINOTI, D. H. B.; FARDIN, L.; TAKIZAWA, F. H. Estimation of inside-bark diameter and heartwood diameter for *Tectonagrandis* Linn. trees using artificial neural networks. **European Journal of Forest Research**, v.130, n.2, p.263-269, 2011.
- MAX, T. A., BURKHART, H. E. Segmented polynomial regression applied to taper equations. **Forest Science**, v. 22, n. 2, p. 283-289, 1976.
- MENDONÇA, A. R. de; SILVA, G. F. da; OLIVEIRA, J. T. da S.; NOGUEIRA, G. S. Avaliação de funções de afilamento visando a otimização de fustes de *Eucalyptus spp.* para multiprodutos. **Cerne**, Lavras, v. 13, n. 1, p. 71-82, jan./mar. 2007.
- MÔRA, R.; Silva, G. F. da; GONÇALVES, F. G.; SOARES, C. P. B.; CHICHORRO, J. F.; CURTO, R. A. Análise de diferentes formas de ajuste de funções de afilamento. **ScientiaForestalis**, Piracicaba, v. 42, n. 102, p. 237-249, 2014.
- NOGUEIRA, G. S., LEITE, H. G., CAMPOS, J. C. C.; SOUZA, A. L., COUTO, L. Determinação da idade técnica de desbaste em plantações de eucalipto utilizando o método dos ingressos percentuais. **ScientiaForestalis**, Piracicaba, n. 59, p. 51-59, 2001.
- NOGUEIRA, G. S. **Modelagem do crescimento e da produção de povoamentos de *Eucalyptus spp.* e de *Tectonagrandis* submetidas a desbaste**. Viçosa, MG: UFV, 2003. 126 p. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, 2003.
- ORMEROD, D. W. A simple bole model. **Forest Chronicle**, Toronto, v. 49, n. 3, p. 136-138, 1973.
- PIRES, L. M.; CALEGARIO, N. Ajuste de modelos estocásticos lineares e não-lineares para a descrição do perfil longitudinal de árvores. **RevistaÁrvore**, v. 31, n. 5, p. 845-852, set./out. 2007.

SILVA, J.C. da. Aspectos econômicos do desbaste em reflorestamento no Norte do Paraná. **Floresta**, Curitiba, v. 2, n. 3, p. 13-18, 1970.

SILVA, M. L. M.; BINOTI, D. H. B.; GLERIANE, J. M.; LEITE, H. G. Ajuste do modelo de Schumacher e Hall e aplicações de redes neurais artificiais para estimar volume de árvores de Eucalipto. **Revista Árvore**, v. 33, n. 6, p. 1133-1139, 2009.

SOARES, R. V. Desbastes em *Araucariaangustifolia* (Bert) O'Ktze. **Floresta**, Curitiba, v.2, n 3, p. 59-67, 1970.

SOARES, F. A. A. M. N.; FLÔRES, E. L.; CABACINHA, C. D.; CARRIJO, G. A.; VEIGA, A. C. P. Recursive diameter prediction for calculating merchantable volume of Eucalyptus clones without previous knowledge of total tree height using artificialneural networks. **AppliedSoft Computing**. 12(2012) 2030–2039.

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. **Ciência Rural**, Santa Maria, v.38, n.9, p.2506-2511, 2008.

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