



MARCOS ANTONIO ISAAC JÚNIOR

**PERFIL LONGITUDINAL DO FUSTE DE
CEDRO AUSTRALIANO (*Toona ciliata* M. Roem.)
ESTIMADO POR MEIO DE MODELOS NÃO
LINEARES E REDES NEURAIS ARTIFICIAIS**

LAVRAS – MG

2014

MARCOS ANTONIO ISAAC JÚNIOR

**PERFIL LONGITUDINAL DO FUSTE DE CEDRO AUSTRALIANO
(*Toona ciliata* M. Roem.) ESTIMADO POR MEIO DE MODELOS NÃO
LINEARES E REDES NEURAIIS ARTIFICIAIS**

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

Orientador

Dr. Natalino Calegario

LAVRAS – MG

2014

**Ficha Catalográfica Elaborada pela Coordenadoria de Produtos e
Serviços da Biblioteca Universitária da UFLA**

Isaac Júnior, Marcos Antonio.

Perfil longitudinal do fuste de cedro australiano (*Toona ciliata*
M. Roem.) estimado por modelos não lineares e redes neurais
artificiais / Marcos Antonio Isaac Júnior. – Lavras : UFLA, 2014.
93p. : il.

Dissertação (mestrado) – Universidade Federal de Lavras, 2014.
Orientador: Natalino Calegario.
Bibliografia.

1.RNAs. 2. Função de afilamento. 3. Cedro australiano. I.
Universidade Federal de Lavras. II. Título.

CDD – 634.9756

MARCOS ANTONIO ISAAC JÚNIOR

**PERFIL LONGITUDINAL DO FUSTE DE CEDRO AUSTRALIANO
(*Toona ciliata* M. Roem.) ESTIMADO POR MEIO DE MODELOS NÃO
LINEARES E REDES NEURAS ARTIFICIAIS**

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

APROVADA em 25 de fevereiro de 2014.

Dr. Paulo Fernando Trugilho UFLA

Dr. Antônio Carlos Ferraz Filho UFLA

Dr. Natalino Calegario
Orientador

LAVRAS – MG

2014

Dedico a todas as pessoas que me apoiaram até este momento da minha vida, em especial, aos meus avós, Florisvaldo e Aparecida (in memoriam), que me deram conselhos e sempre estiveram ao meu lado para realizar meus sonhos e objetivos.

Aos meus pais, Marcos e Vanda, por me incentivarem a continuar e a enfrentar as dificuldades e quem sempre ajudaram na minha formação de vida. Quero agradecer, também, aos meus irmãos, Victor, Lucas e Sarah, e minha sobrinha, Maria Eduarda, que, mesmo sendo boa a diferença entre nós, saibam que nunca os esqueço e, em especial, à minha irmã Melissa que está sempre presente na minha vida. Agradeço, também, à Rai e ao Edson por me apoiarem a continuar nesta nova fase de vida que são meus estudos. Aos meus tios Paulo, Celso, Vanderlei, Flávio, Monteiro, Valdir e Cássia. Aos meus primos, Andréia e Augusto e a todos da minha família que me ajudaram na minha formação.

DEDICO

AGRADECIMENTOS

À Universidade Federal de Lavras (UFLA), ao Departamento de Engenharia Florestal e ao Programa de Pós-graduação em Engenharia Florestal. Ao Conselho Nacional de Pesquisa (CNPq), ao apoio pela concessão de bolsa de estudo, e à Fundação de Amparo à Pesquisa de Minas Gerais (FAPEMIG), pelo auxílio ao financiamento da pesquisa.

Aos professores, especialmente, Ana Carolina, Lucas e José Márcio, e funcionários, em especial à Francisca, que me receberam e apoiaram nesta etapa da minha vida. Ao meu orientador, Natalino Calegario por me apoiar para minha formação e desenvolver minha dissertação.

Quero, também, agradecer aos educadores que se tornaram amigos e pessoas que me ajudaram no entendimento melhor da vida, estes sempre estarão presentes nas minhas lembranças, Jana, Elder, Moises, Marco Amaro, Marcos, Kusdra, Evandro, Simone, Edmilson, Zenóbio e Tarcísio.

Aos companheiros de trabalho e amizades que fiz nesta etapa Janice, Ernani, Elliezer, André Farias, Paulo, Fran, Lorena, André, Sarita, Amanda, Joyce, Geisi, Túlio, Ailton, Felipe, Juninho, Eduardo, Vinicius, Mirian, Alexandre, Renata, Pedro, Thiza, Allan, Paulo, Paulo (Terrinha), Tatiane, Ezequiel e Josina. E, em especial, aos meus amigos e irmãos Raimundo, Renato, Cledson, Juscélia e Francesca.

E agradecer a Deus por me dar forças para continuar realizando meus sonhos.

“Deixe o futuro dizer a verdade, e avaliar cada um de acordo com seus trabalhos e suas conquistas.”

Nikola Tesla

RESUMO

Com a crescente demanda pelo uso da madeira de cedro australiano (*Toona ciliata* **M. Roem.**), verifica-se a necessidade compreender o perfil longitudinal do fuste e o seu volume individual com a aplicação de novos métodos. Nos últimos anos, vêm sendo utilizadas técnicas que permitem as estimativas da altura, do raio e do volume de árvores com RNAs em vez do método tradicional de regressão. Os dados para a realização deste trabalho foram provenientes de 72 árvores de cedro australiano, pertencentes à empresa Bela Vista Florestal, localizada no município de Campo Belo – MG. O presente estudo objetivou modelar o perfil longitudinal do fuste do cedro australiano (*Toona ciliata* M. Roem.) utilizando modelos não lineares e Redes Neurais Artificiais (RNAs). Realizou-se o ajuste das funções de afilamentos e a função de Garay foi a que melhor estimou a altura, considerando todo o conjunto de dados. Posteriormente, ajustou-se a função de Garay para estimativa da altura, raio e volume individual das árvores, a fim de comparar com as RNAs. Os dados de treino foram divididos em cinco grupos: 90%, 70%, 50%, 30% e 10% e avaliou-se por meio dos dados de testes. De acordo com as análises estatísticas, as RNAs apresentaram resultados satisfatórios da raiz do erro quadrático para todo o conjunto de testes em relação ao método da regressão. Ao analisar os resíduos, observaram-se resultados satisfatórios para o método de RNAs. Desta forma, considera-se que é possível o uso de RNAs para representar o perfil longitudinal do fuste e a estimativa do volume individual das árvores de cedro australiano.

Palavras-chave: RNAs. Função de afilamento. Cedro australiano.

ABSTRACT

With the increasing demand for the use of Australian cedar wood (*Toona ciliata* **M. Roem**), we verify the need to understand the longitudinal profile of the stem as well as its individual volume by means of applying new methods. In recent years, techniques which allow the estimative of height, radius and volume of the trees with ANNs rather than with the traditional regression method have been used. The data to perform this work derived from 72 Australian cedar trees, belonging to the Bela Vista Florestal company, located in the municipality of Campo Belo, Minas Gerais, Brazil. This study aimed at modeling the longitudinal profile of the stem of Australian cedar (*Toona ciliata* M. Roem.) using non-linear models and Artificial Neural Networks (ANNs). The taper function adjustments were performed and the Garay function best estimated the height, considering the entire data set. Following, the Garay function was adjusted to estimate height, radius and individual volume of the trees. In order to compare the ANNs, the training data were divided into five groups: 90%, 70%, 50%, 30% and 10%, and were evaluated using the test data. According to statistical analyses, the ANNs presented satisfactory results for square root error for the entire set of tests in relation to the regression method. When analyzing the residue, satisfactory results were observed for the ANNs method. Thus, it is considered possible the use of ANNs to represent the longitudinal profile of the stem and the estimate of the individual volume of the Australian cedar trees.

Keywords: ANNs. Taper function. Australian cedar.

LISTA DE FIGURAS

Figura 1	Cedro australiano. a) Árvore de cedro australiano (<i>Toona ciliata</i>); b) Estrutura foliar e frutos da <i>Toona ciliata</i> 18
Figura 2	Formas geométrica nas seções do fuste da árvore 22
Figura 3	Sólidos de revolução descrição da forma da árvore..... 23
Figura 4	Constituição de um neurônio 33
Figura 5	Representação de um neurônio artificial..... 34
Figura 6	Obtenção das imagens do cedro australiano. a) Mesa estática fotográfica. b) Disco de cedro australiano. 43
Figura 7	Mensuração das seções transversais pelo <i>software</i> ImageJ. a) Disco de cedro australiano; b) Obtenção da escala em <i>pixel/cm</i> ; c) Seleção dos parâmetros a serem mensurados; d) Delimitação do perímetro da seção do cedro australiano 44
Figura 8	Reconstituição do perfil do cedro australiano das 72 árvores cubadas. Em que: rm_{ij} = raio médio da <i>i</i> -ésima árvore na <i>j</i> -ésima posição (cm); h_{ij} = altura da <i>i</i> -ésima árvore na <i>j</i> -ésima posição (m) 52
Figura 9	Gráficos de resíduos e valores de h_{ij} estimados <i>versus</i> valores de h_{ij} observados. a) Função Logística de 3 parâmetros na <i>i</i> -ésima árvore e na <i>j</i> -ésima seção; b) Função do tipo-Weibull na <i>i</i> -ésima árvore e na <i>j</i> -ésima seção; b) Função de Garay na <i>i</i> -ésima árvore e na <i>j</i> -ésima seção..... 55

Figura 10	Gráficos dos resíduos e das h_{ij} estimadas <i>versus</i> h_{ij} observadas para as funções de afilamento. a) Função Logística de 3 parâmetros na i-ésima árvore e na j-ésima seção; b) Função Logística de 4 parâmetros na i-ésima árvore e na j-ésima seção; c) Função do tipo-Weibull na i-ésima árvore e na j-ésima seção; e c) Função de Garay na i-ésima árvore e na j-ésima seção.....	59
Figura 11	Representação dos perfis pela curva média das h_{ij} observadas e estimadas na i-ésima árvore e na j-ésima seção	62
Figura 12	Gráficos dos resíduos e das h_{ij} estimadas <i>versus</i> h_{ij} para os dados de testes na i-ésima árvore e na j-ésima seção observada ao longo do fuste nas árvores de cedro australiano por meio das RNAs e da Função de Garay	69
Figura 13	Perfil longitudinal médio para o cedro australiano por meio das RNAs e pela função de Garay. a - 10%; b - 30%; c - 50%; d - 70%; e - 90% dos dados de testes; h_{ij} obs. - altura observada ao longo do fuste na i-ésima árvore e na j-ésima seção.....	72
Figura 14	Gráficos dos resíduos e dos rm_{ij} estimados <i>versus</i> rm_{ij} observados na i-ésima árvore e na j-ésima seção ao longo do fuste nas árvores de cedro australiano por meio das RNA e da função de Garay.....	78
Figura 15	Vol_i estimados <i>versus</i> vol_i observados na i-ésima árvore obtidos considerando a estimativa do raio médio pelas RNAs e pela função de Garay aplicando o método de Smalian para o cedro australiano	82

LISTA DE TABELAS

Tabela 1	Número de árvores por classe de diâmetro	49
Tabela 2	Resultados dos ajustes das funções de afilamentos sem a inclusão de covariantes	53
Tabela 3	Resultados dos ajustes das funções de afilamentos com a inclusão de covariantes	56
Tabela 4	Critérios de seleção para as funções de afilamento com a inclusão de covariantes	63
Tabela 5	Valores encontrados para os dados de treinamento para os respectivos dados de testes e estatística para h_{ij} e rm_{ij}	64
Tabela 6	Resultados do ajuste da função de Garay parâmetros com a inclusão de covariantes	66
Tabela 7	Estatísticas obtidas com o ajuste da função de Garay	76

SUMÁRIO

1	INTRODUÇÃO	13
2	OBJETIVOS	16
2.1	Objetivo Geral	16
2.2	Objetivos Específicos	16
3	REVISÃO DE LITERATURA	17
3.1	Cedro australiano	17
3.2	Biometria florestal	20
3.3	Inventário florestal	26
3.4	Forma da árvore	28
3.4.1	Fator de forma	28
3.4.2	Quociente de forma	28
3.5	Função de afilamento	29
3.6	Redes Neurais Artificiais - RNAs	32
3.6.1	Aplicação no setor florestal	40
4	MATERIAL E MÉTODOS	42
4.1	Descrição da área de estudo e coleta dos dados	42
4.2	Processamento dos dados	43
4.3	Funções de afilamento	45
4.4	Crítérios para a seleção das funções de afilamento	47
4.5	Redes Neurais Artificiais (RNAs)	49
5	RESULTADOS E DISCUSSÃO	52
5.1	Funções de afilamento	52
5.2	Redes Neurais Artificiais	63
5.3	Estimativa do volume total para as RNAs	81
6	CONCLUSÃO	85
	REFERÊNCIAS	86

1 INTRODUÇÃO

Nas últimas décadas muitas espécies vêm se destacando no setor florestal pelas características específicas e favoráveis para determinados fins e, com isso, têm sido exploradas em larga escala. A crescente demanda por madeira exige cada vez mais um manejo eficaz e preciso das áreas de florestas plantadas. Tal exigência não é somente para garantir um controle econômico, mas também de cunho sócio-ambiental, para a geração de empregos, conservação e preservação florestal.

Além do eucalipto (*Eucalyptus* sp.) e pinus (*Pinus* sp.), outras espécies, também, têm se mostrado interessantes, como o cedro australiano (*Toona ciliata* M. Roem.) que possui diversas aplicações desde o uso na fabricação de móveis até a produção de compensados e outros fins. A produção em larga escala favorece investimentos e desenvolvimento de tecnologias específicas, para a espécie cedro australiano, todavia a produção de produtos oriundos de sua madeira, ainda, é incipiente e carece de informações quanto ao seu manejo florestal.

Com o aumento da demanda por madeiras, empresas florestais têm verificado um aumento do mercado interno e externo para a madeira serrada de cedro australiano. Além disso, essa espécie por ser exótica, igual ao eucalipto, encontrou condições favoráveis para o seu desenvolvimento no Brasil (MURAKAMI, 2008). Outro aspecto importante é a similaridade da sua madeira com a do cedro (*Cedrela odorata* e *Cedrela fissilis*), possuindo qualidades semelhantes e utilizadas para o mesmo uso madeireiro (MURAKAMI, 2008).

Em razão dos poucos estudos com a espécie de cedro australiano, verifica-se a importância de se saber o volume do fuste com precisão. Para isto uma técnica utilizada é a análise do perfil longitudinal ao longo do fuste que consegue, além de avaliar o afilamento, a estimativa do volume.

Estudos para modelar o perfil da árvore vêm sendo desenvolvidos desde o século XIX e o primeiro registro a modelar o tronco, por meio de modelos estatísticos, data de 1903, desenvolvido por Höjer (PIRES; CALEGARIO, 2007).

Trabalhos com o auxílio de técnicas como a modelagem estatística vêm sendo empregados para o conhecimento do afilamento do fuste. No setor florestal, o uso das funções de afilamento permite a verificação da redução do diâmetro com o aumento da altura, seguindo uma tendência natural das espécies, podendo ser formulada por meio de funções que representem a disposição da variação do diâmetro ao longo do fuste (PEREIRA et al., 2005).

Considerando que as aplicações das funções de afilamentos sejam antigas, o seu uso é recente e intensificado em virtude dos avanços da informática (SOUZA, 2009). O desenvolvimento dessas tecnologias auxilia a realização de cálculos mais elaborados para funções de afilamento. Isso permite o ganho de tempo e custo, além de maior precisão nas funções. Com o avanço dessas tecnologias, modelos não lineares vêm sendo empregados com maior frequência no setor florestal. Para esse uso cabem ressaltar os estudos feitos por Pires e Calegario (2007), Carvalho (2011), Holer et al. (2010) e Leite et al. (2011b), utilizando modelos não lineares biológicos que procuram representar o desenvolvimento da árvore.

Estes modelos, ainda, possuem as características de apresentarem parcimônia, interpretação dos parâmetros e generalização (PIRES; CALEGARIO, 2007) que garantem confiança ao analisar os resultados obtidos das árvores de interesse. Outra consideração a respeito das funções de afilamento é o uso da integral que permite a obtenção do volume da árvore.

Além dos modelos não lineares biológicos, estudos vêm sendo realizados com Redes Neurais Artificiais (RNAs) e aplicados ao setor florestal por diversos pesquisadores: Diamantopoulou (2005), Gorgens et al. (2009),

Leite et al. (2011a), Binoti, Binoti e Leite (2013), Özçelik (2013) e entre outros. Estes pesquisadores têm alcançado resultados satisfatórios para tomadas de decisões no setor florestal.

Com a aplicação das RNAs, como método para estimação do volume das árvores, observou-se uma redução no levantamento de dados quantitativos em campo como diâmetro à altura do peito (DAP) e altura total (HT) das árvores. Isto vem possibilitar o menor custo na realização do inventário florestal e, conseqüentemente, obter no processo final um ganho líquido na receita da empresa.

Compreender o comportamento do perfil ao longo do fuste é de extrema importância, pois permite o entendimento de como determinar o melhor aproveitamento da madeira. Para isto, espera-se que o emprego de técnicas como modelos não lineares biológicos e as RNAs permitam a representação do perfil longitudinal da árvore e a estimação do volume com mais precisão.

2 OBJETIVOS

2.1 Objetivo Geral

Modelar o perfil longitudinal do fuste do cedro australiano (*Toona ciliata* M. Roem.) utilizando modelos não lineares e Redes Neurais Artificiais (RNAs).

2.2 Objetivos Específicos

- a) Avaliar, por meio dos modelos não lineares, os ajustes para as estimativas das alturas com a inclusão das covariáveis.
- b) Estimar por meio das RNAs a altura e raio médio a fim de verificar a representação do perfil longitudinal da árvore e estimar o volume total da árvore.
- c) Comparar com o modelo não linear e avaliar qual o método que obtém as melhores estimativas para as variáveis em estudo, altura e raio médio ao longo do fuste e o volume total da árvore.

3 REVISÃO DE LITERATURA

3.1 Cedro australiano

O cedro australiano (*Toona ciliata* M. Roem. Figura 1A) foi introduzido no Brasil no ano de 1970 (VILELA; STEHLING, 2011), é nativo da Índia, Paquistão, China e Austrália. Apresenta características parecidas com os cedros (*Cedrella fissilis* e *Cedrella odorata*) e com o mogno (*Swietenia macrophilla*), do Brasil (SOUZA; BARROSO; CARNEIRO, 2010).

É uma espécie considerada de grande porte com altura entre 30 m a 40 m e diâmetro à altura do peito podendo ser maior que 1,0 m (BYGRAVE; BYGRAVE, 2005). Geralmente possui um tronco retilíneo, as folhas são alternadas, pecioladas e paripenadas (Figura 1B), com floração nos meses de setembro a novembro, tendo flores masculinas e femininas. Sua frutificação (Figura 1B) ocorre de dezembro a março e possui sementes aladas. Às vezes, incide da antecipação da floração e frutificação em um mês (SOUZA; BARROSO; CARNEIRO, 2010).



Figura 1 Cedro australiano. a) Árvore de cedro australiano (*Toona ciliata*); b) Estrutura foliar e frutos da *Toona ciliata*

Fonte: Murakami, 2008.

O cedro australiano apresenta um melhor crescimento em locais com precipitação em torno de 1.000 mm, temperatura variando entre 20 °C e 26 °C (LAMPRECHT, 1990; SOUZA; BARROSO; CARNEIRO, 2010) e locais com altitudes de até 1.700 m (SOUZA; BARROSO; CARNEIRO, 2010). Verifica-se, também, a sobrevivência da espécie em temperaturas abaixo de 0 °C (LAMPRECHT, 1990; MURAKAMI, 2008).

Para um bom crescimento são necessários solos aluviais, ricos em nutrientes (especialmente cálcio) que apresentam boa drenagem, e que sejam profundos e eutróficos (LAMPRECHT, 1990; SOUZA; BARROSO; CARNEIRO, 2010). Em solos argilosos, compactados ou arenosos pobres em nutrientes, ácidos e encharcados, a sobrevivência fica comprometida

(LAMPRECHT, 1990; MURAKAMI, 2008; SOUZA; BARROSO; CARNEIRO, 2010).

A propagação do cedro australiano ocorre por sementes, isto acaba sendo um problema para o cultivo da espécie que é de grande porte, o que dificulta a coleta dos frutos que são pequenos e apresentam sementes aladas, outro fator limitante (SOUZA; BARROSO; CARNEIRO, 2010). Em virtude da crescente demanda pelo cultivo de cedro australiano, trabalhos vêm sendo realizados para melhorar o seu cultivo e uma alternativa que vem demonstrando ser viável é a produção de mudas clonais, por meio de miniestacas derivadas das minicepas (SOUZA; BARROSO; CARNEIRO, 2010). Porém a maioria das mudas comercializadas, ainda, é originária de sementes. A produção é realizada em tubetes ou sacos plásticos, alocados em viveiros sombreados. Por causa da pouca informação da espécie, é necessário realizar um acompanhamento mais criterioso da produção (SOUZA; BARROSO; CARNEIRO, 2010).

Para o plantio, os espaçamentos mais usuais têm sido de 2 x 2 m e 3 x 2 m, com a realização de desbastes no segundo ano em plantios com maior densidade e, posteriormente, em anos subsequentes (SOUZA; BARROSO; CARNEIRO, 2010).

Murakami (2008) constatou que o cedro australiano pode ser implantado em sistemas agroflorestais, como o café, e Souza, Barroso e Carneiro (2010) testaram a implantação com outras culturas, como banana, palmeira real, coqueiro, leguminosas herbáceas e cacau.

O cedro australiano tem demonstrado resistência ao ataque *Hypsipyla grandella*, que ataca as espécies nativas de cedro e mogno. A manutenção do plantio geralmente é baixa, ocorrendo adubações de nitrogênio e potássio nos dois primeiros anos e monitoramento para o controle de pragas (SOUZA; BARROSO; CARNEIRO, 2010), além dos tratamentos silviculturais que são diferenciados conforme o espaçamento adotado.

A madeira do cedro australiano é caracterizada com albarno róseo-branco, ou amarelo-pálido-marrom, e o cerne, marrom pálido. Sua madeira, em geral, apresenta coloração vermelho-escuro, marrom ou tijolo, nos primeiros anos e, em outras fases, castanho-avermelhado. Possui uma madeira brilhante e cerne resistente a desgastes (WORLD AGROFORESTRY CENTRE, 2012). Nisgoski et al. (2011) relatam que o cedro australiano apresenta cerne e albarno distintos, além de apresentar anéis de crescimento nítidos.

A espécie possui facilidade para armazenamento, secagem e processamento da madeira (SOUZA; BARROSO; CARNEIRO, 2010). A madeira tem diversas aplicações, desde o uso para indústria moveleira até para instrumentos musicais, molduras, painéis, compensados, portas, janelas, construção naval e aeronáutica (LAMPRECHT, 1990).

Murakami (2008) realizou um estudo e verificou que aos 15 anos de idade, o cedro australiano possui um cultivo médio por hectare de 250 m³ a 390 m³, com o valor da madeira em R\$ 850,00 m⁻³. O mesmo autor constatou que em plantios existentes no Brasil, o incremento médio anual (IMA) chegou a ser de 20 a 30 m³.ha⁻¹.ano⁻¹.

Trabalhos relacionados ao manejo do cedro australiano vêm sendo realizados no Brasil, no município de Adrianópolis (PR), e que auxiliam nas tomadas de decisões, tais como melhor seleção das árvores e a realização de tratamentos silviculturais para obtenção de um melhor rendimento por hectare (RICKEN et al., 2011).

3.2 Biometria florestal

A realização da mensuração florestal de forma consistente é de fundamental importância para a silvicultura. No setor florestal, a medição dos indivíduos arbóreos pode ser feita de forma indireta ou direta. Quando realizada

de forma indireta, é necessário o envolvimento de medidas geométricas e trigonométricas para determinação da altura (HUSCH et al., 1982) e para obtenção dos diâmetros são possíveis o uso de *softwares* que possibilitam a análise completa do tronco. Caso seja realizada de forma direta, esta deve ser feita assumindo um padrão de medição, isto é, qual a unidade de medida será usada (HUSCH; MILLER; BEERS, 1982).

A árvore apresenta variações nas formas ao longo do fuste, isso dificulta a definição do ponto de transição entre os sólidos existentes na árvore (LOUREIRO et al., 2012). A forma da árvore é influenciada pelos seguintes fatores: espécie, sítio, tratamentos silviculturais, idade, aspectos genéticos, dentre outros (AVERY; BURKHART, 1994; MACHADO; FIGUEIREDO FILHO, 2009).

Para a realização do cálculo do volume, existem técnicas como o seccionamento do fuste e cubagem rigorosa, para diminuir os efeitos destas variações, que, posteriormente, são somadas para obtenção do volume total da árvore (LOUREIRO et al., 2012).

Estudos referentes à forma do tronco buscam descrever o perfil da árvore por meio de modelos estatísticos e procuram, assim, estimar o volume da árvore, com base no diâmetro à altura do peito (DAP) e na altura total (ANUCHIN, 1970; HUSCH; MILLER; BEERS, 1982; FINGER, 1992).

Para representar as formas da árvore, são utilizados modelos dendrométricos (paraboloide, neiloide, cilindro e cone) que visam analisar as cubagens utilizando recursos estatísticos comparando-os com os sólidos geométricos de revolução. Estes são conhecidos como protótipos dendrométricos ou sólidos padrões, que se assemelham às formas do tronco ou a partes seccionais (ANUCHIN, 1970; HUSCH; MILLER; BEERS, 1982; FINGER, 1992).

O fuste da árvore pode assumir formas geométricas, representando sólidos de revolução, cilindro, fuste de neiloide, fuste de parabolóide e cone e podem ocorrer ao mesmo tempo (HUSCH; MILLER; BEERS, 1982). Conforme Figueiredo Filho et al. (1996), determinar os pontos de transição destes sólidos não é fácil, porém determinam a definição de procedimentos estatísticos na descrição da forma do fuste.

Os sólidos de revolução são gerados, quando ocorre a rotação de formas geométricas em torno do seu eixo (Figura 2): cilindro - ocorre rotação de um retângulo em torno de um lado; cone - por meio de um triângulo retângulo; esfera - é em torno do semicírculo de diâmetro; e o parabolóide - é por meio de um polinômio de segundo grau em torno do seu eixo (HUSCH; MILLER; BEERS, 1982).

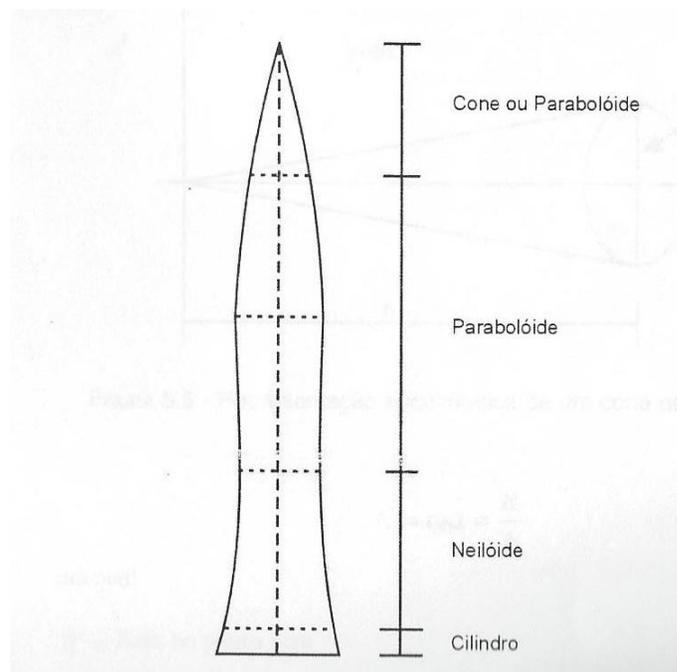


Figura 2 Formas geométrica nas seções do fuste da árvore

Fonte: Husch et al. (1982).

Para espécies de coníferas, o fuste da árvore pode, frequentemente, assumir a forma de neiloide, parabolóide, cilindro ou cone (Figura 3). Estes são obtidos pela rotação da curva, de forma geral $y = k$ em torno do seu eixo x , a forma do expoente muda conforme a equação, diferente do sólido gerado. Quando r é igual a 1, obtêm-se a forma de um parabolóide, 2 um cone, 3 um neiloide e quando é 0 um cilindro. Normalmente as árvores de coníferas estão entre um cone e uma parabolóide (HUSCH; MILLER; BEERS, 1982). As espécies folhosas podem assumir as mesmas formas em seu tronco que as coníferas (MACHADO; FIGUEIREDO FILHO, 2009).

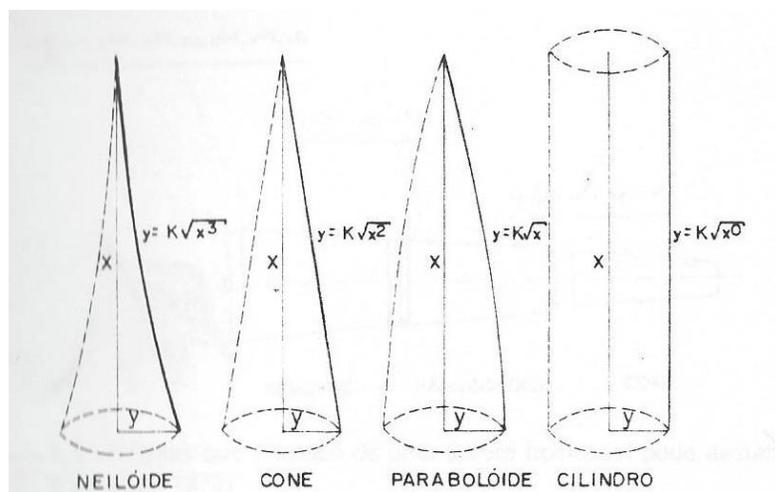


Figura 3 Sólidos de revolução descrição da forma da árvore

Fonte: Husch, Miller e Beers (1982).

Husch, Miller e Beers (1982) consideram que se a equação $y = k$ pode representar o perfil longitudinal do fuste, pode-se obter o volume dos sólidos de revolução por seção e/ou total da árvore por meio da integração (equação 1).

$$v = \pi \int_a^b y^2 dx \quad (1)$$

O corpo de revolução assume que em todas as seções do fuste sobre um plano perpendicular ao seu eixo longitudinal assume ser um círculo. Porém, estudos mostram que as seções da árvore diferem de círculos (ANUCHIN, 1970), mas para a realização dos cálculos, tem-se aceitado que o diâmetro possui forma circular (HUSCH; MILLER; BEERS, 1982; MACHADO; FIGUEIREDO FILHO, 2009).

Em razão da dificuldade na obtenção do volume da árvore, por meio do índice da geratriz da parabolóide, procura-se obter o volume real da árvore ou das seções pelo deslocamento da água ou xilômetro (MACHADO, FIGUEIREDO FILHO, 2009). Outros procedimentos são adotados para as estimativas do volume real, como a cubagem rigorosa, que implica na divisão do fuste da árvore em “n” seções, conforme o afinamento do fuste. Este procedimento leva em consideração a medição dos diâmetros ao longo do fuste e permite a obtenção dos diâmetros da árvore de forma absoluta e relativa ou a combinação de ambos (MACHADO; FIGUEIREDO FILHO, 2009).

As fórmulas, utilizadas para realização da mensuração das várias seções do fuste, são a de Smalian, Huber e Newton (HUSCH; MILLER; BEERS, 1982; MACHADO; FIGUEIREDO FILHO, 2009) e relativa a de Hohenald (MACHADO; FIGUEIREDO FILHO, 2009), equações 2,3,4 e 5, respectivamente.

a) Smalian

$$v = \frac{1}{2} (g_b + g_t) \quad (2)$$

Em que: v – volume; g_b – área transversal na base da seção; g_t – área transversal no topo da seção; l – comprimento da seção.

b) Huber

$$v = g_m l \quad (3)$$

Em que: v – volume; g_m – área transversal no meio da seção; l – comprimento da seção.

c) Newton

$$v = \frac{1}{6} (g_b + 4g_m + g_t)l \quad (4)$$

Em que: v - volume; g_b – área transversal na base da seção; g_m – área transversal no meio da seção; g_t – área transversal no topo da seção; l – comprimento da seção.

d) Hohenadl

Este é um método relativo em que o fuste é dividido em seções de iguais comprimentos, considerando a altura total da árvore, mensurando os diâmetros ou circunferências no centro de cada seção e o volume da ponta não é calculado como se fosse um cone (MACHADO; FIGUEIREDO FILHO, 2009). Na equação 5 observa-se o fuste dividido em 5 seções.

$$v = \frac{h}{5} (g_{0,1} + g_{0,3} + g_{0,5} + g_{0,7} + g_{0,9})l \quad (5)$$

Em que: v – volume; $g_{0,i}$ – diâmetros medidos a 10%, 30%, 50%, 70% e 90% de (h); l – comprimento da seção.

Existem outros métodos de cubagem, tais como: método da FAO, Pressler, acumulação de altura ou de Grosenbaugh, seccional padrão, afilamento constante (*taper-step*), amostragem centroide, sobreposição de seções de Bailey e Hossfeld (MACHADO; FIGUEIREDO FILHO, 2009).

A utilização de modelos estatísticos para a representação do perfil da árvore auxilia na tomada de decisão quanto aos padrões de corte. Com isso é possível saber a quantidade de produtos e, automaticamente, os resíduos do material lenhoso. Além disso, permite verificar quais tratamentos silviculturais adotar, tais como os desbastes e as desramas, que estão relacionados ao tipo de forma da árvore (PEREIRA et al., 2005).

3.3 Inventário florestal

O gerenciamento de uma floresta é importante para tomadas de decisões, o qual implica não somente nas ações atuais, mas também no planejamento futuro e de como irá estabelecer as diretrizes básicas do manejo florestal em um determinado período de tempo (STIRN, 1990; CASTEDO-DORADO; DIEGUEZ-ARANDA; ALVAREZ-GONZALEZ 2007; SEVILLANO-MARCO; FERNANDEZ-MANSO; CASTEDO-DORADO 2009; MEHTÄTALO et al., 2011).

O inventário florestal é realizado com o propósito da obtenção de informações qualitativas e quantitativas das florestas em uma determinada área para que se consiga explorar essas florestas de forma planejada (PÉLICO NETO; BRENA, 1997). Com as inovações tecnológicas, o inventário torna-se

cada vez mais criterioso e permite, além da obtenção do volume, a extração de mais informações para que se possa trabalhar com multiprodutos (PÉLICO NETO; BRENA, 1997).

Para a realização de um bom inventário florestal, é indispensável a coleta de características como diâmetro à altura do peito (DAP) e altura dominante (DIÉGUEZ-ARANDA et al., 2006; NEWTON; AMPONSAH, 2007; HEIDARSSON; PUKKALA, 2011), entre outras como a altura codominante. A coleta destas variáveis possibilitará o ajuste de modelos estatísticos e a análise do comportamento da floresta.

Para a elaboração de modelos, é necessário utilizar parcelas permanentes ou análise completa do tronco. A diferença do primeiro para o segundo é que nas parcelas permanentes são realizadas medições ao longo do tempo (HU; OSCAR, 2010; MENG; HUANG, 2010), ou seja, as parcelas permanentes permitem o acompanhamento periódico do desenvolvimento dos indivíduos arbóreos ao longo do tempo. O inconveniente deste método é o alto custo da manutenção e da coleta de dados (TONINI; SCHNEIDER; FINGER, 2006).

A análise completa de tronco (anatro) é realizada por meio da coleta de discos das árvores, em que realizam medições dos anéis de crescimento e, assim, obtêm os diâmetros dos discos (MACHADO et al., 2013). Para isso seleciona as árvores dominantes, pois essa representa melhor o sítio florestal. A anatro é questionada, uma vez que podem ocorrer mudanças na representação da árvore dominante, em virtude da competição entre os indivíduos presentes na área, seja por nutrientes, luz e/ou outros fatores (HU; OSCAR, 2010).

A altura dominante tem demonstrado ser a variável que melhor indica o desenvolvimento do crescimento da árvore, definindo, assim, os melhores locais para os plantios florestais (VARGAS-LARRETA et al., 2009).

3.4 Forma da árvore

No início do século XIX, estudos já eram realizados para avaliar a relação do volume do fuste com o volume do cilindro. Dentre as mais estudadas foram o fator de forma e o quociente de forma.

3.4.1 Fator de forma

No início do século XIX, estudos já eram realizados para avaliar a relação do volume do fuste com o volume do cilindro. Esta comparação resultou em um coeficiente denominado fator de forma (ANUCHIN, 1970; AVERY; BURKHART, 1994).

O fator de forma é a terceira variável para a determinação volumétrica e a razão dos seus volumes está diretamente relacionada com a altura. Cabe ressaltar que árvores geometricamente parecidas, mas com alturas diferentes, acarretará fator de forma diferente (FINGER, 1992). Conforme o valor do fator de forma se aproxima de 1, mais cilíndrica é a árvore (HUSCH; MILLER; BEERS, 1982; FINGER, 1992).

$$f_{1,3} = \frac{V_{\text{real}}}{V_{\text{cilindro}}} \quad (6)$$

3.4.2 Quociente de forma

Outra forma de saber a relação do fuste com a de um cilindro é pelo quociente de forma. Este é a razão de dois diâmetros, diferente do fator de forma que é a razão entre os volumes. O quociente de forma tem a mesma função do fator de forma, que é utilizado para redução do volume do cilindro. Porém, não tem a mesma precisão (HUSCH; MILLER; BEERS, 1982; FINGER, 1992). A

equação 7 mostra o modelo do quociente de forma normal, mas existem outros quocientes de forma como o absoluto e o de Girard.

$$Q = \frac{d(1/2 h)}{DAP} \quad (7)$$

Em que: $d(1/2 h)$ – é valor do diâmetro na metade da altura da árvore;
DAP – diâmetro à altura do peito a 1,30 m.

3.5 Função de afilamento

A função de afilamento é um instrumento importante para a avaliação biológica e econômica de um maciço florestal, pois permite uma análise do povoamento florestal de forma quantitativa, isto é, avalia quanto ele produzirá de toras e os seus respectivos volumes (SOUZA, 2009).

As funções de afilamento são precisas e podem ser obtidas por meio da integração. Estas têm maior flexibilidade para cálculos de volume, pois permitem a estimação de altura comercial e seus diâmetros ao longo do fuste na árvore (AVERY; BURKHART, 1994). Na descrição do perfil das árvores, quando utilizadas as funções de afilamentos, usam-se, geralmente, as variáveis DAP e altura total (LEITE et al., 2006; KUBLIN; AUGUSTIN; LAPPI, 2008; NUNES; TOME; TOME, 2010).

Segundo Pereira et al. (2005), a forma do fuste pode ser associada ao afilamento, que é a redução do diâmetro com o aumento da altura, seguindo uma tendência natural das espécies, podendo ser formulada por meio de modelos estatísticos que representam a disposição da variação do diâmetro ao longo do fuste.

As funções de afilamento têm demonstrado aceitação no setor florestal brasileiro, pois auxiliam nas tomadas de decisão quanto à informação de estoques de madeira na realização do inventário florestal (RIOS, 1997).

Em trabalhos com multiprodutos, os inventários florestais precisam ser mais detalhados a fim de determinar o planejamento florestal (SOUZA, 2009). Por isso, as indústrias, que trabalham com multiprodutos, necessitam de volumes precisos para diâmetros pré-definidos (LEITE et al., 2006; MENDONÇA et al., 2007; NUNES; TOME; TOME, 2010; FONWEBAN et al., 2011; SILVA; CORTE; SANQUETTA, 2011).

Nunes, Tome e Tome (2010) realizaram um trabalho com o pinheiro bravo (*Pinus pinaster* Ait.) e afirmaram que o ajuste da função de afilamento garante uma representatividade do volume total e parcial, possibilitando ser representada para outras espécies.

Esta modelagem auxilia na tomada de decisões e permite uma melhor compreensão dos recursos naturais do setor florestal (CALAMA et al., 2008; HRITONENKO et al., 2008). Compreender a natureza e representá-la por meio de modelos é extrair o máximo de informação do objeto em observação (EMILIANO, 2009).

Ratkowsky (1983) relata que os modelos biológicos com curvas de crescimento são difundidos nas áreas da biologia, agricultura, engenharia e economia. Estes modelos têm uma curva que inicia em alguns pontos fixos e vai aumentando sua taxa de crescimento monotonicamente até chegar a um ponto de inflexão, após isso, o ritmo de crescimento diminui para aproximar assintoticamente de algum valor final.

Inúmeras funções estatísticas foram propostas para modelar curvas biológicas. Entre estes estão Gompertz, logístico, Richards (1959), Morgan-Mercer-Flodin (1975) e o modelo derivado da distribuição de Weibull (1951), designado de modelo tipo-Weibull (RATKOWSKY, 1983).

Modelos não lineares têm mostrado resultados satisfatórios quanto à predição do crescimento em altura e na produção de volumes em plantios equiâneos (SOUZA, 2009), além de evitar excesso de parâmetros, facilitando a interpretação dos mesmos, o que garante uma confiabilidade ao trabalhar com outros dados (PIRES; CALEGARIO, 2007).

Modelos sigmoidais permitem a visualização de pontos de inflexão, bem como verificar as relações biológicas dos dados observados (SOUZA, 2009). O modelo de Garay (1979) é derivado de Chapman-Richards, esse modelo permite representar o perfil do fuste e, com isso gera uma curva sigmoide (RIOS, 1997).

O modelo sigmoidal Logístico apresenta fácil interpretabilidade biológica de seus parâmetros e os mesmos apresentam ajustes com o perfil da árvore facilitando, assim, a sua interpretação com as análises da estimativa (CALEGARIO, 2002).

Holer et al. (2010), quando representou o perfil de *Pinus oocarpa* por funções de afilamento, constataram que o modelo Logístico modificado obteve ótima precisão dos valores e avaliaram que o uso de um modelo não linear representa melhor a estabilidade dentro e fora dos dados coletados, retratando o crescimento biológico.

De acordo com Carvalho (2010), o modelo sigmoidal Logístico de três parâmetros é um modelo biológico de crescimento que representa o ponto de inflexão sendo a taxa de máximo crescimento, a assíntota considera o crescimento máximo médio e o ponto de escala. O modelo Logístico se apresenta adequado para um conjunto de dados vegetativos, exibindo uma baixa variância residual, solução consistente in loco e uma baixa curvatura intrínseca (RATKOWSKY, 1983).

Em outros modelos como de Gompertz e de Weibull foram possíveis os ajustes das funções de afilamentos, pois antes era difícil o ajuste e a convergência destes modelos (PIRES; CALEGARIO, 2007).

O modelo de Gompertz é muito utilizado na modelagem econométrica, esse ao contrário do modelo Logístico, possui uma assimetria sobre seu ponto de inflexão e apresenta uma curvatura aceitável intrínseca para sua solução, porém não garante a representação do crescimento vegetativo (RATKOWSKY, 1983). O trabalho realizado por Pires e Calegario (2007), relata que o modelo de Gompertz demonstrou melhor resultado no erro-padrão residual para descrição do perfil da árvore.

O modelo tipo-Weibull com 4 parâmetros apresenta um comportamento satisfatório, quando comparado com os outros modelos, pois os parâmetros alfa e beta possuem um comportamento inicialmente linear (RATKOWSKY, 1983).

3.6 Redes Neurais Artificiais - RNAs

Além da regressão, vêm sendo aplicadas para estimação do afilamento do fuste as RNAs. Essas surgiram no intuito de representar o cérebro humano, que é o órgão que processa informações oriundas do ambiente de forma organizada, por meio dos neurônios, na tentativa de simular a sua complexidade e facilidade de se adaptar (HAYKIN, 2001; BRAGA; CARVALHO; LUDEMIR, 2011).

Os trabalhos com RNAs iniciaram no início do século XX, precisamente no ano de 1943, quando o psiquiatra e neuroanatomista McCulloch e o matemático Pitts trabalharam em conjunto para descrever o sistema nervoso humano por meio da modelagem matemática (HAYKIN, 2001; BRAGA; CARVALHO; LUDEMIR,).

Para isto eles observaram como o neurônio biológico (Figura 4) é constituído e, considerando este conhecimento, adaptaram, por meio da modelagem matemática, as seguintes partes do neurônio: os dendritos, responsáveis pelos estímulos nervosos; o corpo da célula, responsável pelos

processos metabólicos e, onde impulsos são processados e gerados novos impulsos; e o axônio pelo qual os impulsos são enviados. Com isto procuraram reproduzir artificialmente o neurônio.

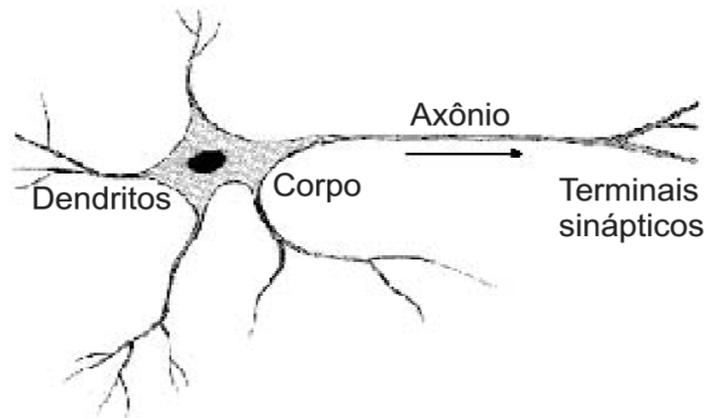


Figura 4 Constituição de um neurônio

Fonte: Ferneda, E. Redes neurais e sua aplicação em sistemas de recuperação de informação.

A Figura 5 representa um neurônio artificial no qual possui a entrada (x_m) sinapses, que estão conectados a seus pesos (w_m). As sinapses são multiplicadas por seus pesos que indicam a importância da sinapse na saída. O valor do peso sináptico no neurônio artificial pode assumir em um intervalo valores negativos ou positivos. Após, é realizada a soma ponderada que é obtida dos valores das sinapses multiplicados pelos seus respectivos pesos. Posteriormente, passa pela função de ativação que restringe a amplitude de saída do neurônio e aplica a não linearidade ao modelo. A amplitude da saída do neurônio é compreendida em um intervalo fechado de 0 a 1 ou -1 e 1. A função de ativação, geralmente, é representada por uma função do tipo tangente hiperbólica, sigmoidal, semilinear ou limiar. O desvio (bias) tem a função de

aumentar ou diminuir a influência dos valores das entradas (HAYKIN, 2001; BRAGA; CARVALHO; LUDEMIR,).

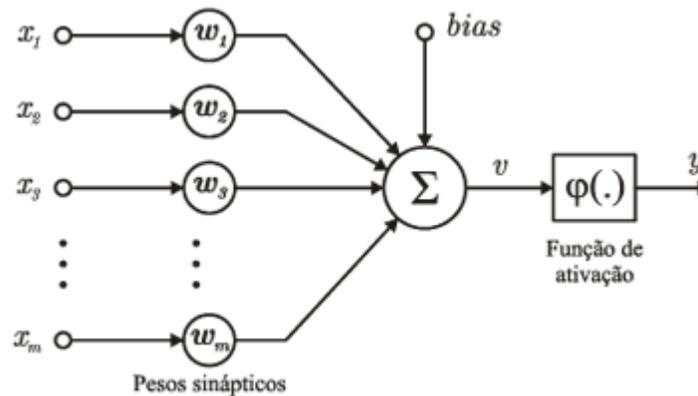


Figura 5 Representação de um neurônio artificial

Fonte: Moreto e Rolim, Análise automática de oscilografias em sistemas elétricos de potência.

Atualmente as RNAs diferem quanto à sua arquitetura, isto é, dependendo da aplicação das RNAs podem assumir diferentes tipos. Considerando estruturas simples, os ajustes de conexões entre os neurônios podem ser de uma única camada alimentada para frente. Podem apresentar multicamadas, isto é, possuir camada(s) intermediária(s), alimentada(s) para frente. E possuir estruturas conhecidas como redes recorrentes que possuem conexões com os neurônios posteriores, que permitem um melhor desempenho computacional para as redes (HAYKIN, 2001; BRAGA; CARVALHO; LUDEMIR,).

Para que as RNAs aprendam, é preciso definir um algoritmo de aprendizado que seja capaz de generalizar o que foi aprendido pelas redes. Conforme Souza (2013), a forma para avaliar o aprendizado da rede é analisar o erro quadrático médio e verificar se ocorreu redução dos erros e com isto dar

prosseguimento ao aprendizado. O erro quadrático médio é determinado por meio da saída desejada e do valor obtido pela RNA.

Os aprendizados nas RNAs podem ser: supervisionado, mostra qual o caminho a seguir na rede, isto é, minimiza o erro de resposta e procura reforçar as ações executadas de maneira correta; não-supervisionado, não tem conhecimento do ambiente externo, são oferecidas condições para as análises do ambiente e os melhores resultados obtidos por competição na saída são selecionados e atualizados, pode ocorrer a ligação de unidades de entradas e saída, como também as últimas entre si e por conexões laterais inibitórias (HAYKIN, 2001; BRAGA; CARVALHO; LUDEMIR,). E, ainda, pode ser por reforço, que se baseia se a saída está correta ou não.

O algoritmo mais usual no caso de aprendizagem supervisionado é o *backpropagation* (propagação do erro). Este algoritmo se baseia na correção do erro que é obtido pela diferença da saída desejada pela resposta da saída atual da rede (BRAGA; CARVALHO; LUDEMIR,). O algoritmo *backpropagation* consiste em duas etapas: primeiro, a propagação para frente em que os dados de entrada são fornecidos aos nós (neurônios) sensoriais e com isto é propagado para frente, camada de entrada até a camada de saída, e um valor de saída real é obtido pela rede e nesta etapa os pesos são mantidos fixos (HAYKIN, 2001). Por isso o algoritmo *backpropagation* responde como determinar a influência do erro nas camadas intermediárias da rede.

Na segunda etapa os pesos sinápticos são ajustados e corrigidos conforme a regra de correção do erro. Esta correção produz um sinal que é propagado para trás e com isso os pesos sinápticos são atualizados e a resposta originada pela rede é ajustada para que se aproxime o mais possível da resposta desejada (HAYKIN, 2001).

A seguir, por meio das equações são mostradas as etapas para os ajustes das RNAs pelo algoritmo *backpropagation*. O modelo matemático é bem

difundido com o uso deste algoritmo, por isso, serão mostradas de forma simplificada as etapas para este algoritmo.

Geralmente as construções das RNAs possuem a função ativação logística (8). Esta função diferente da função de ativação limiar que apresenta saídas 0 ou 1, trabalha em um intervalo contínuo entre 0 e 1 que acaba por apresentar um comportamento linear e não-linear. Outra característica importante da função de ativação sigmoide é ser diferenciável (HAYKIN, 2001).

$$f_j[u_j(t)] = \frac{1}{1 + \exp(-pu_j)} \quad (8)$$

Em que: $f_j[u_j(t)]$ – função de ativação sigmoide no j-ésimo neurônio da camada de saída no instante t; u_j - soma ponderada dos sinais que produz um nível de atividade no j-ésimo neurônio da camada de saída no instante t; t-ésimo padrão de treinamento apresentado à rede; p - é o parâmetro de inclinação.

Ao realizar a derivada da função logística, essa atinge seu valor máximo dos pesos sinápticos na saída da rede neural de 0,5 e seus valores mínimos dos pesos sinápticos são modificados entre o intervalo de 0 e 1 (HAYKIN, 2001). Por apresentar o valor do peso sináptico da rede proporcional à derivada da função logística, os sinais no meio do intervalo são modificados mais intensamente (HAYKIN, 2001).

Conforme Haykin (2001), adaptado, inicia-se com a verificação da linearidade e a saturação da função de ativação sigmoide. Depois realiza o treinamento do conjunto de dados para toda a rede.

- a) Fase *forward* - $x(n)$, vetor de entrada e $d(n)$, o vetor de saída. Cálculo do campo local induzido $u_j^l(t)$ para o neurônio j na camada l é:

$$u_j(t) = \sum_{i=0}^{m_0} w_{ji}^{(l)}(t) y_i^{(l-1)}(t) \quad (9)$$

Em que: $y_i^{(l-1)}(t)$ é o sinal (função) de saída do neurônio i na camada anterior $l - 1$ na iteração t ; $w_{ji}^{(l)}$ é o peso sináptico do neurônio j da camada l , que é alimentado pelo neurônio i da camada $l - 1$. Para $i = 0$, temos $y_0^{(l-1)}(t) = +1$ e $w_{j0}^{(l)} = b_j^{(l)}$ é bias aplicado ao neurônio j camada l .

Em seguida assume o uso de uma função sigmoide, o sinal de saída do neurônio j na camada l :

$$y_j^{(l-1)}(t) = f_j[u_j(t)] \quad (10)$$

Em que: $y_i^{(l-1)}(t)$ é o sinal (função) de saída do neurônio i na camada anterior $l - 1$ na iteração t ; $f_j[u_j(t)]$ – função de ativação sigmoide no j -ésimo neurônio da camada de saída no instante t ;

Posteriormente calcula-se o sinal de erro:

$$e_j(t) = d_j(t) - y_j(t)$$

Em que: $d(t)$ é o j -ésimo elemento do vetor resposta desejada.

- a) Fase *backward* - depois de calculado o erro na última camada, inicia-se a segunda fase, etapa *backward*, que consiste na atualização dos pesos (11).

Calculo dos δ s nos gradientes locais da rede

$$\delta_j(t) = f_j'[u_j(t)] * [d_j(t) - y_j(t)] \quad (11)$$

Em que: $\delta_j(t)$ - erro da rede no j-ésimo neurônio da camada de saída no instante t; t-ésimo padrão de treinamento apresentado à rede; $f_j'[u_j(t)]$ – derivada da função de ativação sigmoideal no j-ésimo neurônio da camada de saída no instante t; d_j - saída desejada no j-ésimo neurônio da camada de saída no instante t; y_j - saída obtida no j-ésimo neurônio da camada de saída no instante t.

Atualização dos pesos

$$w_{ji}(t+1) = w_{ji}(t) - \alpha * \delta_j(t) * x_i(t) \quad (12)$$

Em que: w_{ji} - pesos no j-ésimo neurônio no instante t e na i-ésima camada na arquitetura da rede; t-ésimo padrão de treinamento apresentado à rede; α - taxa de aprendizagem; $\delta_j(t)$ - erro da rede no j-ésimo neurônio da camada de saída no instante t; $x_i(t)$ - vetor resultante da saída da camada anterior na i-ésima camada na arquitetura da rede.

Em seguida, é/são calculado(s) o(s) erro(s) na(s) camada intermediária(s), com base na camada de saída e, novamente, são atualizados os pesos.

$$\delta_j(t) = f'_j[u_j(t)] * \sum_k [\delta_j(t) * W_{ki}] \quad (13)$$

Em que: $\delta_j(t)$ - erro da rede no j-ésimo neurônio da camada de saída no instante t; $f'_j[u_j(t)]$ - derivada da função de ativação sigmoidal no j-ésimo neurônio da camada de saída no instante t; w_{ki} - pesos no k - número de neurônios conectados a seguir do atual e na i-ésima camada na arquitetura da rede.

Caso utilize o termo *momentum*, visualiza-se na equação 14 como ficará a atualização dos pesos. O uso deste coeficiente possibilita evitar os mínimos locais e auxilia no tempo de processo no treinamento.

$$w_{ji}(t+1) = w_{ji}(t) - \alpha * \delta_j(t) * x_i(t) * \eta * [w_{ji}(t) - w_{ji}(t-1)] \quad (14)$$

Em que: w_{ji} - pesos no j-ésimo neurônio no instante t e na i-ésima camada na arquitetura da rede; t-ésimo padrão de treinamento apresentado à rede; α - taxa de aprendizagem; $\delta_j(t)$ - erro da rede no j-ésimo neurônio da camada de saída no instante t; $x_i(t)$ - vetor resultante da saída da camada anterior na i-ésima camada na arquitetura da rede; η - termo *momentum*.

Para avaliar o desempenho de uma rede, são verificados alguns critérios de parada como o erro quadrático médio que verifica se o erro de uma época (iteração) para outra atinja um valor pequeno e a validação cruzada em que são

formados dois conjuntos o de treinamento e o de validação. Espera-se, assim, que o ajuste obtido pela rede consiga determinar um mínimo global ou um mínimo local mais próximo, isto é, a resposta da saída desejada.

Uma das dificuldades a respeito das RNAs é a determinação dos números de neurônios na camada intermediária ou oculta. Um número de neurônios artificiais pode ajudar no mapeamento não linear da rede, mas pode causar o sobre ajuste (*overfitting*) dos dados caso exista a presença de ruídos na base de dados e o contrário causa subajuste (*underfitting*) que, ainda, pode ocorrer quando se interrompe o treinamento na rede.

As RNAs têm mostrado uma capacidade de generalização, quando realizado o treinamento dos dados, mesmo que apresentem ruídos. As RNAs têm sido aplicadas para reconhecimento de padrões, classificação, ajustes, otimização, agrupamento, previsão e controle.

3.6.1 Aplicação no setor florestal

Trabalhos realizados com as RNAs mostraram-se eficientes na estimativa de volumes para plantações florestais. Por isso, as RNAs têm sido utilizadas para estimar variáveis da árvore como: altura, DAP, entre outros (DIAMANTOPOULOU, 2005; GÖRGENS, 2006; SOARES et al., 2011). Estes modelos matemáticos, baseados em redes biológicas, têm demonstrado ser mais precisos que os modelos de regressão (GÖRGENS, 2006; LEITE et al., 2011a).

Modelos estatísticos precisam de uma grande quantidade de variáveis de entrada para poderem realizar as análises sobre o povoamento florestal e com isso gerar informações. As RNAs possuem a vantagem de que, mesmo com uma base de dados incompleta, podem ser realizadas análises, para poder ter uma melhor compreensão das estimativas das variáveis em estudo (GÖRGENS,

2006; LEITE et al., 2011a), além de apresentar adaptabilidade, capacidade de generalização, auto-aprendizagem, vantagens a falha e a ruídos .

Soares (2012) verificou que, ao prever os diâmetros por meio das RNAs, considerando a altura total e o diâmetro comercial, conseguiu resultados satisfatórios para a realização do inventário florestal. Permitindo a redução do custo e do tempo para conclusão do inventário de forma significativa, além de ser menos suscetível a erro humano.

O fato das RNAs possuírem a capacidade de generalizar, mesmo com ruídos e falhas em seus dados, tem mostrado ser eficiente quando aplicada ao uso de dados não utilizados no treinamento (LEITE et al., 2011a). Um problema das RNAs é a falta de justificativa nos resultados, sendo a definição da sua arquitetura de forma empírica (LEITE et al., 2011a). Porém vários pesquisadores como Diamantopoulou (2006), Görgens (2006), Leite et al. (2011a), Soares et al. (2012), Özçelik et al. (2013) e Souza (2013) têm obtidos resultados satisfatórios quando empregado o uso das RNAs no setor florestal para a estimativas da altura total, volume, predição de diâmetros e afilamento da árvore.

4 MATERIAL E MÉTODOS

4.1 Descrição da área de estudo e coleta dos dados

A área de estudo está localizada na fazenda Bela Vista, rodovia Fernão Dias (BR 381), município de Campo Belo, Minas Gerais, com latitude 20°53'58.89"S e longitude 45°17'33.04"W. O clima da fazenda Bela Vista, de acordo com a classificação de Köppen, é Cwa, temperado úmido com inverno seco e verão chuvoso, temperatura para o mês mais quente de 22°C, precipitação pluviométrica média de 1.250 mm e altitude máxima de 1.146 m.

Os plantios de cedro australiano (*Toona ciliata*) existentes na fazenda são oriundos de sementes, progênies e clones. Em pesquisas anteriores, utilizaram-se 5 progênies provenientes do estado de *Queensland* e de três regiões distintas, duas com altitude de 40 m e precipitação de 2.091 mm e a outra com altitude de 300 m e precipitação de 1.873 mm.

Os dados utilizados para a realização do presente estudo foi proveniente de outras pesquisas. Conforme Alves (2013), a área de estudo foi dividida em três blocos casualizados, com três repetições. As unidades amostrais estavam dispostas em 4 linhas x 4 plantas (16 plantas), com espaçamento de 3 x 3 metros. A seleção das árvores foi conforme o conceito de Hart, ou seja, 100 árvores mais altas por hectare. Assim, fez-se a seleção das árvores e a mensuração do DAP e altura total e, posteriormente, fez-se a cubagem rigorosa destrutiva, em que retiraram discos com 4 cm de espessura nas seguintes posições: 0,15 m; 0,7 m; 1,3 m; 50%, 70% e 90% da altura total. Foram cubadas 72 árvores com idade de 5 anos.

4.2 Processamento dos dados

A obtenção das imagens e a mensuração dos discos, após a secagem natural, foram realizadas em duas etapas. A primeira etapa consistiu em fotografar os discos originários das árvores cubadas em campo. Para isto, utilizou-se uma máquina fotográfica, com resolução de 13 *megapixels*, fixada em uma mesa estática fotográfica (Figura 6a). Os discos foram posicionados em nível na mesa (Figura 6b). Com exceção dos discos das pontas, esses não foram possíveis por serem pequenos. As imagens dos discos foram salvas em formato *jpeg*.

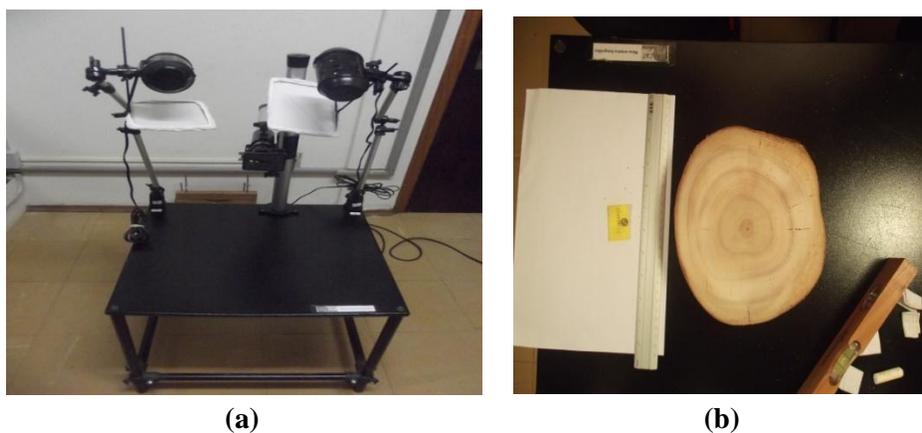


Figura 6 Obtenção das imagens do cedro australiano. a) Mesa estática fotográfica. b) Disco de cedro australiano.

Fonte: Geisi Azevedo.

A segunda etapa consistiu na mensuração dos discos com o uso do *software* ImageJ versão 1.47V (RASBAND, 2007). Conforme Machado et al. (2013), a mensuração da análise completa do tronco pode ser realizada por meio de *softwares*. O *software* ImageJ apresenta ser adequado para o tratamento de imagens e análise quantitativa das imagens (DIAS, 2008). A escala foi

determinada com o auxílio das imagens dos discos com a régua graduada em centímetros e realizada a transformação *pixels/cm* (Figura 7a e 7b). O perímetro, a área e os diâmetros máximo e mínimo de cada seção transversal foram obtidos pelo *software* ImageJ (Figura 7c e 7d).



Figura 7 Mensuração das seções transversais pelo *software* ImageJ. a) Disco de cedro australiano; b) Obtenção da escala em *pixel/cm*; c) Seleção dos parâmetros a serem mensurados; d) Delimitação do perímetro da seção do cedro australiano

O volume total com casca foi calculado pelo método de Smalian, considerando a área obtida pelo *software* ImageJ, a fim de comparar, posteriormente, com o volume total estimado obtido pelo método de Smalian para as funções de afilamento.

4.3 Funções de afilamento

As funções de afilamento utilizadas foram: a logística de três parâmetros, a logística de quatro parâmetros, de tipo-Weibull e a de Garay. Estudos realizados com funções não lineares no setor florestal propiciam uma análise do comportamento do afilamento do fuste da árvore (PIRES; CALEGARIO, 2007; SOUZA et al., 2008; SOUZA et al., 2009; HOLER et al., 2010). Foi realizado um ajuste sem adição de covariáveis e posteriormente com a inclusão das covariáveis $DAPm_i$, H_i e \overline{HDC}_i e avaliado a precisão das funções.

As funções de afilamento foram citadas para representar o perfil longitudinal das árvores. As funções foram ajustadas com o uso do *software* R i386 2.15.0 (R CORE TEAM, 2012). Os pacotes utilizados foram *nlme*, que permitem a realização da decomposição dos parâmetros das funções e *selfStart*, que auxilia nas estimativas iniciais em modelos não lineares (PINHEIRO; BATES, 2000).

a) Função logística de três parâmetros

Na equação 15, o parâmetro (φ_1) é a assíntota horizontal superior, que representa o valor médio máximo da variável independente (h_{ij}); o parâmetro (φ_2) é o ponto de inflexão da curva, em que o valor do rm_{ij} é $\varphi_1/2$ e representa a taxa de crescimento; e o parâmetro (φ_3) é a escala, que representa a distância do

rm_{ij} entre o ponto de inflexão e o ponto em que a resposta é, aproximadamente, $0,73\varphi_1$.

$$h_{ij} = \frac{\varphi_1}{1 + \exp [(\varphi_2 - rm_{ij})/\varphi_3]} + \varepsilon_{ij} \quad (15)$$

Em que: h_{ij} = altura da i -ésima árvore na j -ésima posição do fuste (m); rm_{ij} = raio médio da i -ésima árvore na j -ésima posição do fuste (cm); φ_{is} = parâmetros da regressão; ε_{ij} = erro aleatório.

b) Função logística de quatro parâmetros

Na equação 16, o parâmetro (φ_1) é a assíntota horizontal superior quando rm_{ij} tende a zero; o parâmetro (φ_2) é assíntota horizontal inferior quando o rm_{ij} tende ao infinito positivo; o parâmetro (φ_3) é o ponto de inflexão, que representa a variável resposta de $(\varphi_1 - \varphi_2)/2$; e o parâmetro (φ_4) é a escala, que ocorre com 73% da diferença entre o primeiro e o segundo parâmetros $0,73(\varphi_1 - \varphi_2)$.

$$h_{ij} = \varphi_1 + \frac{\varphi_2 - \varphi_1}{1 + \exp [(\varphi_3 - rm_{ij})/\varphi_4]} + \varepsilon_{ij} \quad (16)$$

Em que: h_{ij} = altura da i -ésima árvore na j -ésima posição do fuste (m); rm_{ij} = raio médio da i -ésima árvore na j -ésima posição do fuste (cm); φ_{is} = parâmetros da regressão; ε_{ij} = erro aleatório.

c) Função tipo-Weibull

Na equação 17, o parâmetro (φ_1) é a assíntota horizontal superior; o parâmetro (φ_2) é o ponto de inflexão; o parâmetro (φ_3) é o logaritmo natural da taxa constante; e o parâmetro (φ_4) é a potência do rm_{ij} .

$$h_{ij} = \varphi_1 - \varphi_2 \exp(-\exp(\varphi_3) rm_{ij}^{\varphi_4}) + \varepsilon_{ij} \quad (18)$$

Em que: h_{ij} = altura da i-ésima árvore na j-ésima posição do fuste (m);
 rm_{ij} = raio médio da i-ésima árvore na j-ésima posição do fuste (cm);
 φ_{is} = parâmetros da regressão; ε_{ij} = erro aleatório.

d) Função Garay

$$h_{ij} = HT_i \left(\left(-\exp \left((rm_{ij} - DAPm_i \varphi_1) (DAPm_i \varphi_1 \varphi_2)^{-1} \right) - 1 \right) \varphi_3 \right)^{1/\varphi_4} + \varepsilon_{ij} \quad (19)$$

Em que: h_{ij} = altura da i-ésima árvore na j-ésima posição do fuste (m);
 rm_{ij} = raio médio da i-ésima árvore na j-ésima posição do fuste (cm); HT_i =
 Altura total da i-ésima árvore; $DAPm_i$ = Diâmetro à altura do peito da i-ésima
 árvore; φ_{is} = parâmetros da regressão; ε_{ij} = erro aleatório.

4.4 Critérios para a seleção das funções de afilamento

A seleção das funções de afilamento foi realizada pelos seguintes critérios: erro padrão residual (S_{xy}), critério de informação de Akaike (CIA) e

critério de informação Bayesiano (CIB). Além disso, fez-se análise gráfica dos resíduos e o gráfico de valores estimados *versus* valores observados.

a) Erro padrão residual

$$S_{xy} = \sqrt{\frac{\sum_{i=1}^n (y - \hat{y})^2}{n - p}} \quad (20)$$

Em que: S_{xy} - erro padrão residual (unidade de medida referente à variável dependente); y - valor observado; \hat{y} - valor estimado; n - número de observações; p - número de parâmetros.

a) Critério de informação de Akaike (CIA) e critério de informação Bayesiano (CIB)

Esses critérios auxiliam na seleção da função mais parcimoniosa, pois penalizam as funções com parâmetros em excesso.

$$CIA = -2 \ln (MV) + 2 p \quad (21)$$

$$CIB = -2 \ln (MV) + p \ln (n) \quad (22)$$

Em que: CIA – Critério de informação de Akaike; CIB – Critério de informação Bayesiano; MV - máxima verossimilhança; p – número de parâmetros do modelo; n – número de observações.

4.5 Redes Neurais Artificiais (RNAs)

Para realizar o treinamento e os testes das RNAs, as árvores foram divididas em classes de diâmetros com amplitude de 3,5 cm (Tabela 1).

Tabela 1 Número de árvores por classe de diâmetro

Classe	Intervalos de classe			Frequência
	LI	Valor central	LS	
I	8,0	9,8	11,5	3
II	11,5	13,3	15,0	13
III	15,0	16,8	18,5	38
IV	18,5	20,3	22,0	16
V	22,0	23,8	25,5	2

De acordo com a Tabela 1, a frequência das classes I e V foram 3 e 2 árvores, respectivamente. Em virtude da baixa frequência observada nas classes, essas árvores foram incluídas nas classes II e IV, respectivamente.

Para o treinamento das RNAs, foram selecionadas 10%, 30%, 50%, 70% e 90% das árvores. As seleções das árvores foram realizadas de forma aleatória, representando, proporcionalmente, a frequência das classes diamétricas. Os indivíduos que não foram selecionados para o treinamento das RNAs foram utilizados nos testes de RNAs (90%, 70%, 50%, 30% e 10% das árvores).

A etapa de pré-processamento não foi necessária, uma vez que o *software Weka versão 3.7.10* (WEKA THE UNIVERSITY OF WAIKATO, 2013) realizava, automaticamente, a normalização dos dados para o processamento. Esse *software* é gratuito e possui uma biblioteca destinada ao uso e aplicação das RNAs e é bem difundida a aplicação de mineração de dados.

Para a obtenção das variáveis altura e raio médio por meio de RNAs, utilizou-se a rede Perceptron de Múltiplas Camadas (MLP) *feedforward*. A

arquitetura da rede foi definida da seguinte forma: camada de entrada, composta pelas variáveis, individual e combinadas, altura em diversas seções da árvore (h_{ij}), diâmetro à altura do peito médio ($DAPm_i$), altura total (H_i) e altura média dominante e codominante (\overline{HDC}_i); camada(s) oculta(s), definida(s) de forma que começava com 1 neurônio e aumentar de forma gradativa até 15 neurônios, quando não se obtinham resultados satisfatórios, acrescentava-se um múltiplo de 5 neurônios ou aumentava em mais uma camada oculta e repetia o processo; camada de saída, composta pelas variáveis individuais, raios médios em diversas alturas, alturas em relação aos raios médios e o volume total por árvore.

O algoritmo de treinamento, utilizado nas RNAs para o ajuste de afilamento e obtenção do volume total, foi o algoritmo *backpropagation* com *momentum*. Os melhores resultados, obtidos pelos ajustes das RNAs para as variáveis, são quando os pesos relativos dos nós conseguem aproximar dos valores desejados para as variáveis em estudo, nesse caso, o afilamento. Os valores utilizados, para taxa de aprendizagem, termo de *momentum* e número de iterações (épocas), variaram conforme a percentagem dos dados de treinamento.

A seleção da melhor arquitetura das RNAs para o conjunto de treinamento foi de acordo com a Raiz do Erro Quadrado Médio (RMSE%) (Equação 23). Além disso, fez-se a análise gráfica dos resíduos e os gráficos dos valores observados *versus* valores estimados.

$$\text{RMSE \%} = \sqrt{\frac{\sum_{i=1}^n (y_i^a - y_i^e)^2}{n}} \cdot \frac{100}{\bar{y}} \quad (23)$$

Em que: n - número de observações; \bar{y} - média dos valores observados; a - vetor de valores observados; e - vetor de valores estimados.

Fez-se a comparação da função de afilamento que melhor apresentou precisão para as estimadas de altura. A fim de comparar, fizeram-se novos ajustes para a função de afilamento com os dados de treinamento utilizados nas RNAs. A função de afilamento de Garay (equação 19) foi a que melhor obteve os resultados do ajuste para a altura. Com isso, foi realizado um novo ajuste para as variáveis altura (equação 19) e raio médio (equação 24) e, em seguida, realizada a inclusão das covariáveis $DAPm_i$, H_i e \overline{HDC}_i .

$$rm_{ij} = DAPm_i \varphi_1 \left(1 + \varphi_2 \ln \left(1 - \varphi_3 h_{ij}^{\varphi_4} H_i^{-\varphi_4} \right) \right) + \varepsilon_{ij} \quad (24)$$

Em que: h_{ij} = altura da i-ésima árvore na j-ésima posição do fuste (m); rm_{ij} = raio médio da i-ésima árvore na j-ésima posição do fuste (cm); HT_i = Altura total da i-ésima árvore; $DAPm_i$ = Diâmetro à altura do peito da i-ésima árvore; φ'_s = parâmetros da regressão; ε_{ij} = erro aleatório.

Para obtenção do volume por meio das RNAs e da função de afilamento de Garay (1979), foi utilizado o método de Smalian (LEITE et al., 2006). Para isso, utilizaram-se os resultados dos raios médios obtidos para conjunto de dados de testes e comparou-se com os volumes adotados como padrão.

As estimativas da h_{ij} e rm_{ij} das RNAs e da função de afilamento foram avaliadas pela RMSE%, pela análise gráfica dos resíduos e pelos gráficos dos valores estimados versus valores observados. O volume total individual foi analisado pela análise dos gráficos dos valores estimados versus valores observados.

5 RESULTADOS E DISCUSSÃO

5.1 Funções de afilamento

Após a obtenção dos diâmetros, o raio médio foi calculado e foi feita a reconstituição do perfil longitudinal de cada árvore (Figura 8).

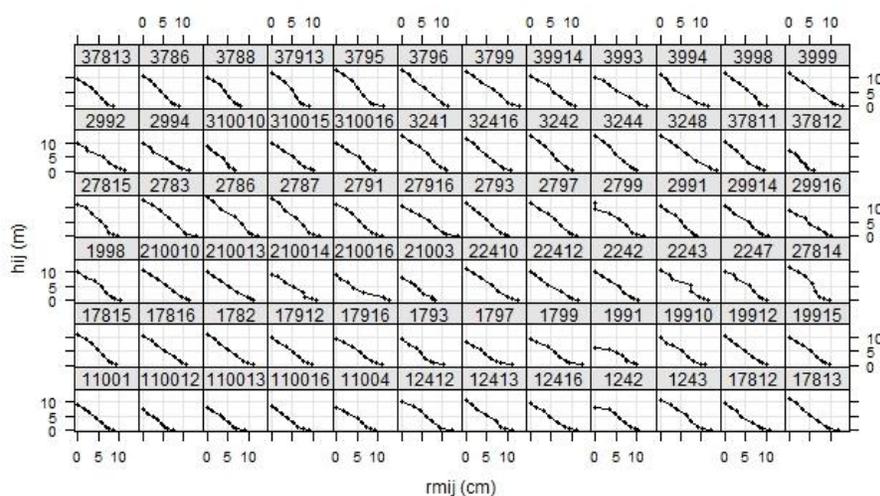


Figura 8 Reconstituição do perfil do cedro australiano das 72 árvores cubadas.

Em que: rm_{ij} = raio médio da i -ésima árvore na j -ésima posição (cm);

h_{ij} = altura da i -ésima árvore na j -ésima posição (m)

As estatísticas de ajustes das funções Logística de 3 parâmetros, Logística de 4 parâmetros, do tipo-Weibull e de Garay, sem adição de covariáveis, estão apresentadas na Tabela 2. A função Logística de 4 parâmetros apresentou o parâmetro ϕ_2 não significativo, por isso não foi analisada graficamente. A função do tipo-Weibull apresentou o intercepto (ϕ_1) não significativo, porém, esse parâmetro não foi eliminado porque não interfere na

análise. As funções de afilamento testadas apresentaram valores de erro padrão residuais semelhantes, com exceção da função de afilamento de Garay que obteve um erro padrão residual de 9,65%. Este resultado, provavelmente, foi melhor em relação aos demais resultados, pois apresenta na função as covariáveis H_i e $DAPm_i$.

Tabela 2 Resultados dos ajustes das funções de afilamentos sem a inclusão de covariantes

Parâmetro	Valor	Erro Padrão	Valor-t	Valor-p
Logístico de 3 parâmetros - $S_{yx} = 27,80\%$				
φ_1	11,696711	0,3691791	31,68302	< 0,0000
φ_2	4,221459	0,1923203	21,95015	< 0,0000
φ_3	-2,176036	0,1058219	-20,56318	< 0,0000
Logístico de 4 parâmetros - $S_{yx} = 27,73\%$				
φ_1	12,277700	0,6170848	19,896291	< 0,0000
φ_2	-0,420827	0,2874880	-1,463808	0,1438
φ_3	4,328025	0,2498048	17,325629	< 0,0000
φ_4	2,577522	0,2485282	10,371143	< 0,0000
Weibull - $S_{yx} = 27,87\%$				
φ_1	-0,662822	0,3987308	-1,662329	0,0970
φ_2	-10,893424	0,4572746	-23,822497	< 0,0000
φ_3	-2,939582	0,1395095	-21,070835	< 0,0000
φ_4	1,600162	0,0969553	16,504125	< 0,0000
Garay - $S_{yx} = 9,65\%$				
φ_1	0,6161022	0,01300151	47,387	< 0,0000
φ_2	0,7485743	0,12433485	6,02063	< 0,0000
φ_3	0,7415583	0,05912635	12,5419	< 0,0000
φ_4	0,5972976	0,07256131	8,23163	< 0,0000

Os gráficos dos resíduos e dos valores de h_{ij} estimados *versus* observados das funções Logística de 3 parâmetros e do tipo-Weibull, sem adição de covariáveis, estão apresentados na Figura 9a e 9b, respectivamente. De acordo com os gráficos, as h_{ij} foram superestimadas, praticamente, em todo o perfil longitudinal da árvore. A função tipo-Weibull apresentou estimativas negativas da h_{ij} na base.

No gráfico dos resíduos para a função de Garay observou-se uma distribuição uniforme ao longo do eixo e uma pequena superestimativa para as h_{ij} próximo a H_i .

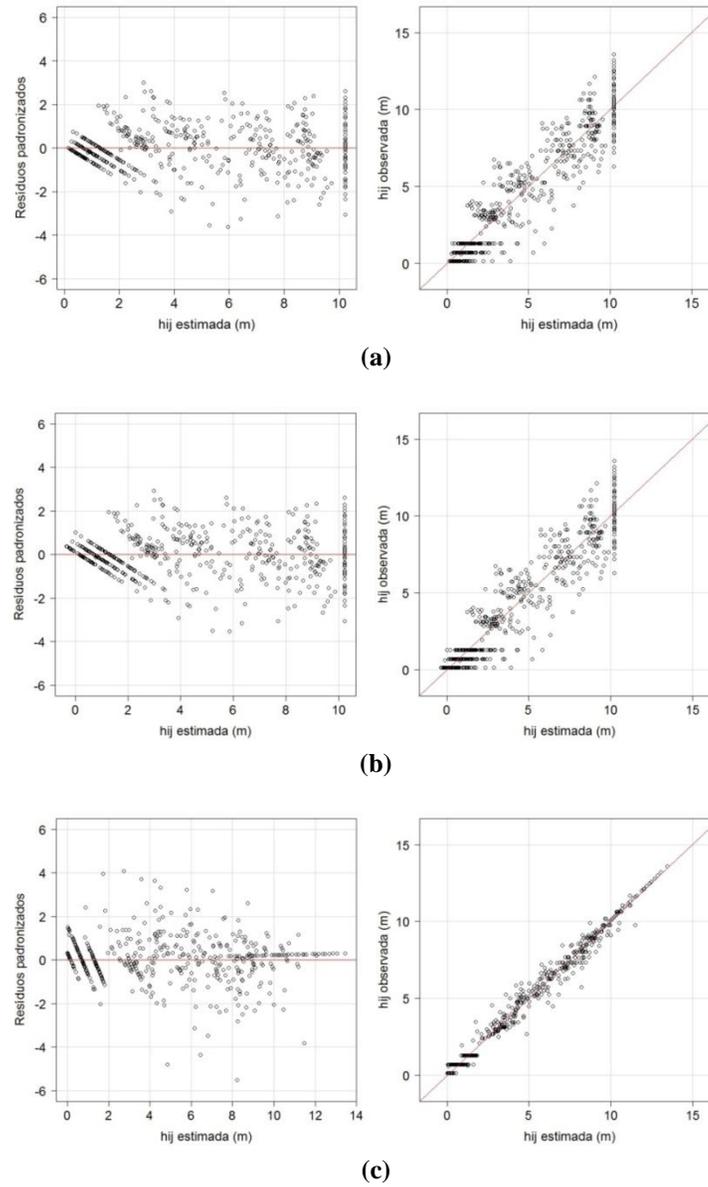


Figura 9 Gráficos de resíduos e valores de h_{ij} estimados *versus* valores de h_{ij} observados. a) Função Logística de 3 parâmetros na i -ésima árvore e na j -ésima seção; b) Função do tipo-Weibull na i -ésima árvore e na j -ésima seção; b) Função de Garay na i -ésima árvore e na j -ésima seção

Após a inclusão das covariáveis ($DAPm_i$, H_i e \overline{HDC}_i), por meio da decomposição de parâmetros, nas funções de afilamento testadas, as funções Logística de 3 parâmetros, Logística de 4 parâmetros, do tipo-Weibull e de Garay apresentaram melhores resultados para o erro padrão residual em relação às equações sem adição das covariáveis (Tabela 3). As funções ajustadas com inclusão de covariáveis obtiveram alguns interceptos não significativos, os quais não foram retirados por não interferirem nos resultados.

A função de Garay apresentou maior precisão que as demais funções ajustadas, com erro padrão residual de 0,3791 m (8,17%) (Tabela 3). As funções Logística de 3 parâmetros, Logística de 4 parâmetros e de tipo-Weibull apresentaram um erro padrão residual de 0,5155 m (11,13%), 0,4435 m (9,58%) e 0,4911 m (10,61%), respectivamente (Tabela 3).

Tabela 3 Resultados dos ajustes das funções de afilamentos com a inclusão de covariantes

Parâmetro	Valor	Erro Padrão	Valor-t	Valor-p
Logístico de 3 parâmetros - $S_{yx} = 11,13\%$				
φ_{10} (intercepto)	1,2952547	0,4409394	2,937489	0,0034
φ_{10} (H_i)	0,9236962	0,0419815	22,002474	< 0,0000
φ_{20} (intercepto)	0,0257957	0,2937834	0,087805	0,9301
φ_{21} ($DAPm_i$)	0,214136	0,010487	20,419244	< 0,0000
φ_{22} (\overline{HDC}_i)	0,1077549	0,0244476	4,407592	< 0,0000
φ_{30} (intercepto)	-0,548333	0,1881768	-2,913925	0,0037
φ_{31} ($DAPm_i$)	-0,130858	0,0094589	-13,834354	< 0,0000
φ_{32} (H_i)	0,0771615	0,0195081	3,955352	< 0,0001

“Tabela 3, continua”

Parâmetro	Valor	Erro Padrão	Valor-t	Valor-p
Logístico de 4 parâmetros - $S_{yx} = 9,58\%$				
φ_{10} (intercepto)	-0,113984	0,3927799	-0,290198	0,7718
φ_{11} (H_i)	11,851932	0,0442092	26,808729	< 0,0000
φ_{20} (intercepto)	16,864369	0,3169619	5,320631	< 0,0000
φ_{21} (H_i)	-0,3148346	0,037143	-8,476279	< 0,0000
φ_{30} (intercepto)	-0,1022767	0,2551462	-0,400855	0,6887
φ_{31} ($DAPm_i$)	0,2328985	0,0095692	24,338246	< 0,0000
φ_{32} (\overline{HDC}_i)	0,1033842	0,0208433	4,960061	< 0,0000
φ_{40} (intercepto)	-0,1814575	0,1392722	-1,302898	0,1931
φ_{41} ($DAPm_i$)	0,1757331	0,0106218	16,544634	< 0,0000
Weibull - $S_{yx} = 10,61\%$				
φ_{10} (intercepto)	1,398216	0,4635681	3,016204	0,0027
φ_{11} (H_i)	-0,3861384	0,0612116	-6,308256	< 0,0000
φ_{20} (intercepto)	0,5002665	0,6431987	0,777779	0,4370
φ_{21} ($DAPm_i$)	0,0476445	0,017752	2,683894	0,0075
φ_{22} (H_i)	-1,360537	0,0793879	-1,713783	< 0,0000
φ_{30} (intercepto)	-0,6288972	0,2855726	-2,202232	0,0281
φ_{31} ($DAPm_i$)	-0,0817957	0,0037986	-21,533384	< 0,0000
φ_{32} (\overline{HDC}_i)	-0,1025017	0,0255196	-4,016588	< 0,0001
φ_{40} (intercepto)	10,837331	0,1471407	7,365284	< 0,0000
φ_{41} (\overline{HDC}_i)	0,0406368	0,012988	3,128802	0,0018
Garay - $S_{yx} = 8,19\%$				
φ_{10} (intercepto)	0,7043	0,0361	19,522	< 0,0000
φ_{11} ($DAPm_i$)	0,0083	0,0015	5,5085	< 0,0000
φ_{12} (H_i)	-0,021	0,0032	-6,637	< 0,0000
φ_{20} (intercepto)	0,5253	0,1624	3,2335	0,0013
φ_{21} (H_i)	0,1255	0,0093	13,544	< 0,0000
φ_{22} (\overline{HDC}_i)	-0,101	0,0176	-5,731	< 0,0000

“Tabela 3, conclusão”

Parâmetro	Valor	Erro Padrão	Valor-t	Valor-p
Garay - $S_{yx} = 8,19\%$				
φ_{30} (intercepto)	0,8479	0,0785	10,805	< 0,0000
φ_{31} (H_i)	-0,059	0,0037	-15,86	< 0,0000
φ_{32} (\overline{HDC}_i)	0,0475	0,0084	5,6897	< 0,0000
φ_{40} (intercepto)	0,5171	0,1265	4,0896	< 0,0000
φ_{41} ($DAPm_i$)	-0,033	0,0033	-9,879	< 0,0000
φ_{42} (H_i)	0,0872	0,0095	9,1684	< 0,0000
φ_{43} (\overline{HDC}_i)	-0,028	0,009	-3,107	0.0020

Analisar apenas as estatísticas de ajustes não é suficiente, pois estas podem não representar o comportamento do perfil longitudinal da árvore, por isso, é necessário realizar a análise gráfica dos resíduos. Mesmo as funções apresentando uma boa medida de precisão isso não garante que elas consigam descrever o perfil longitudinal do fuste.

Por meio da análise gráfica dos resíduos, a função Logística de 3 parâmetros apresentou ora superestimativas ora subestimativas para os valores de h_{ij} ao longo do perfil longitudinal da árvore (Figura 10a). Quanto às funções Logística de 4 parâmetros e do tipo-Weibull, observam-se melhores estimativas das h_{ij} ao longo do perfil longitudinal e em relação as $h_{ij} = H_i$ (Figura 10b e 10c). A função Logística de 4 parâmetros apresentou uma melhor distribuição dos resíduos em comparação à função do tipo-Weibull.

As funções Logística de 4 parâmetros e do tipo-Weibull estimaram h_{ij} negativas na base, sendo mais acentuado para a função do tipo-Weibull. Em relação à função Logística de 3 parâmetros, essa não apresentou h_{ij} negativos na base, mas superestimou as h_{ij} abaixo do $DAPm_i$.

Em relação aos ajustes das funções Logística de 4 parâmetros, Logística de 3 parâmetros e do tipo-Weibull, na função de Garay observa-se melhor

estimativa de h_{ij} na base e na H_i e uma pequena subestimativa entre o intervalo de 2 m e 6 m.

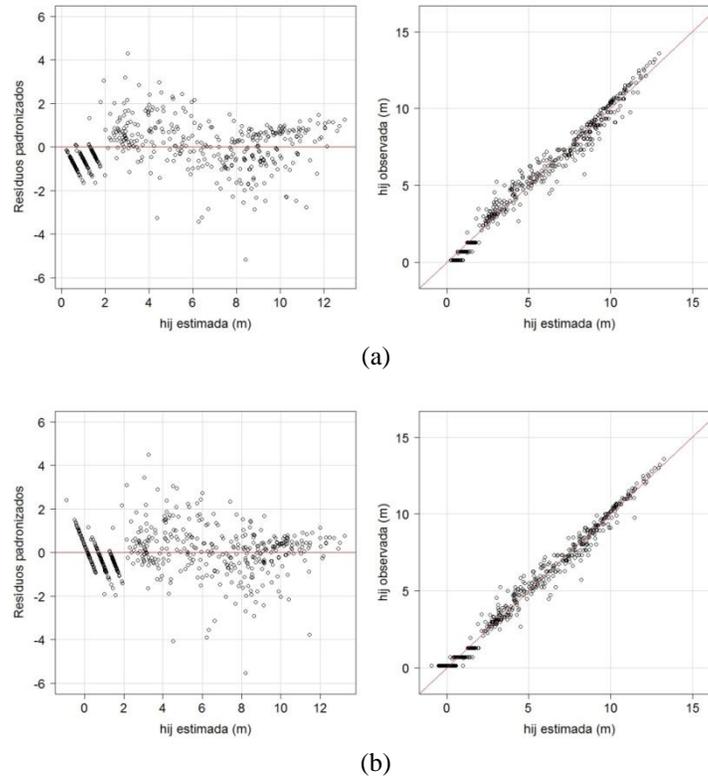
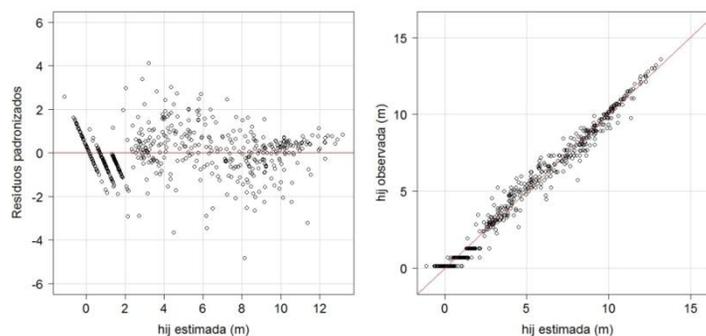


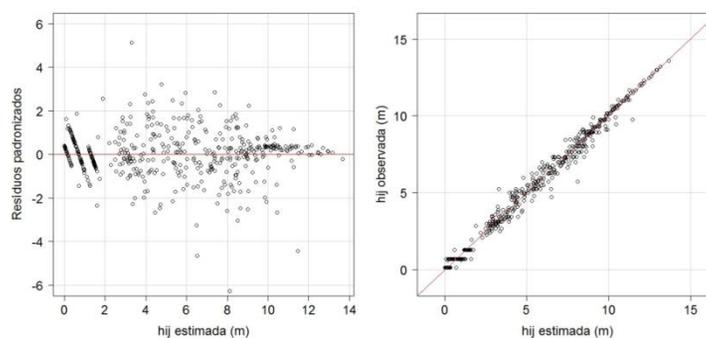
Figura 10 Gráficos dos resíduos e das h_{ij} estimadas *versus* h_{ij} observadas para as funções de afilamento. a) Função Logística de 3 parâmetros na i -ésima árvore e na j -ésima seção; b) Função Logística de 4 parâmetros na i -ésima árvore e na j -ésima seção; c) Função do tipo-Weibull na i -ésima árvore e na j -ésima seção; e c) Função de Garay na i -ésima árvore e na j -ésima seção

(...continua...)

“Figura 10, conclusão”



(c)



(d)

O gráfico do perfil (Figura 11), para curva média da altura, obtido pelas funções estudadas foi mais bem representado pela função de Garay. As funções Logística de 3 parâmetros, Logística de 4 parâmetros e do tipo-Weibull não conseguiram estimar a curva média da altura no intervalo entre 2 m e 9 m, aproximadamente e a função Logística de 3 parâmetros não consegue representar o perfil na base do fuste.

Pires e Calegario (2007) comentaram da importância de analisar o perfil longitudinal para avaliar a precisão dos ajustes das funções. Em trabalho

realizado para representação do perfil para a espécie de *Pinus oocarpa* foi obtido um melhor resultado para o modelo Logístico modificado (HOLER et al., 2010).

Ao comparar o modelo de Shöepfer e Garay, Souza (2013) verificou que a descrição dos perfis representados pelo primeiro modelo apresentou sinuosidades mais acentuadas que o segundo modelo. O modelo não linear de Garay representou melhor as variações ao longo do fuste.

Ao representar o perfil do pinus pelo modelo de potências fracionárias de Hradetzky obteve-se uma boa precisão para o perfil da árvore média considerando o diâmetro (SILVA; CORTE; SANQUETTA, 2011). Yoshitani Junior et al. (2012) obtiveram um bom resultado para o modelo de Hradetzky ao representarem o perfil longitudinal do fuste pela variável do diâmetro.

Ao considerar o perfil representado pela altura, o modelo de potências fracionárias obteve o melhor resultado (QUEIROZ, 2006). O polinômio de quinto grau representou melhor o perfil para o diâmetro em relação ao modelo de Kozad para o pinus (YOSHITANI JUNIOR, 2009).

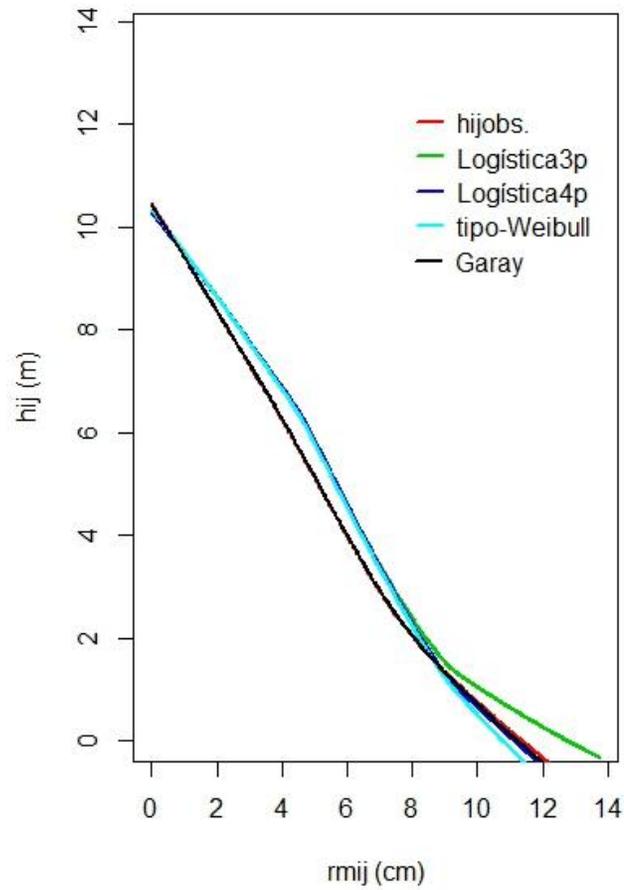


Figura 11 Representação dos perfis pela curva média das h_{ij} observadas e estimadas na i -ésima árvore e na j -ésima seção

De acordo com a Tabela 4, a função Logística de 4 parâmetros apresentou menores valores de AIC e BIC e obteve uma melhor precisão para as estimativas de h_{ij} .

Tabela 4 Critérios de seleção para as funções de afilamento com a inclusão de covariantes

Função	AIC	BIC
Logística 3 parâmetros	880,8803	920,0852
Logística 4 parâmetros	708,9220	752,4831
tipo-Weibull	827,2641	875,1813
Garay	532,0438	593,0293

Em que: AIC = Critério de informação de Akaike; BIC = Critério de informação Bayesiano

Ao avaliar os gráficos dos resíduos em diferentes tratamentos em plantio de eucalipto para as funções de Garay e Shöepfer, Souza (2013) verificou uma maior dispersão dos diâmetro/DAP próximo à base nos fustes. Esse mesmo autor comenta que nessa região a variação no diâmetro é brusca em relação às outras seções do fuste. Souza et al. (2008) relataram que a base do fuste apresenta maior deformação.

Leite et al. (2006) relataram que a função de afilamento pode ser precisa para estimar as alturas, mas deficiente em estimar os diâmetros ou vice-versa. Estes autores, ainda, relatam que se a equação possui uma boa precisão da estimativa da variável diâmetro, possivelmente, irá estimar um bom volume.

5.2 Redes Neurais Artificiais

Por meio das RNAs foram realizados os treinamentos para 10%, 30%, 50%, 70% e 90% dos dados selecionados, aleatoriamente, para 72 árvores, em seguida, obtidos os resultados para o conjunto dos dados de testes. Com os dados de treinamento foram definidos a arquitetura da rede, número de iterações, taxa de aprendizagem e termo *momentum* (Tabela 5). As estatísticas dos dados

dos testes (média, desvio padrão da média e Raiz do Erro Quadrado Médio) são apresentadas na Tabela 5.

Tabela 5 Valores encontrados para os dados de treinamento para os respectivos dados de testes e estatística para h_{ij} e rm_{ij}

Treino (%)	Teste (%)	Arq.	It.	α	β	RMSE (%)	Méd.	Sd
h_{ij}								
90	10	4-4-10-1	1000	0,35	0,55	6,51	3,77	4,66
70	30	4-2-1	500	0,1	0,8	8,85	3,70	4,43
50	50	4-15-21-1	500	0,5	0,03	9,33	3,82	4,55
30	70	4-3-22-1	500	0,47	0,01	8,43	3,77	4,57
10	90	4-35-1	500	0,51	0,33	10,19	3,75	4,85
rm_{ij}								
90	10	4-15-1	1500	0,1	0,51	6,90	3,82	5,63
70	30	4-20-1	500	0,1	0,4	10,79	3,54	5,50
50	50	4-10-20-1	500	0,5	0,1	10,18	3,57	5,58
30	70	4-17-20-1	500	0,1	0,6	8,58	3,64	5,72
10	90	4-2-1	4000	0,45	0,55	12,02	3,81	5,83

Em que: Arq. – arquitetura da rede neural; It. – número de iterações; α - taxa de aprendizagem; β - termo *momentum*; Raiz do Erro Quadrado Médio (RMSE%); Méd. e Sd. são as médias e os desvios padrões da média, respectivamente, dos valores de testes.

As RNAs obtiveram uma arquitetura diferente, isto é, os números de camadas ocultas, de neurônios e iterações variaram conforme o conjunto de dados para o treinamento. Quanto maior o número de camadas ocultas e neurônios, maior é a complexidade da arquitetura das RNAs. Em trabalho realizado, para estimar a altura e o diâmetro em diversas seções de eucalipto por meio das RNAs, Souza (2013) obteve resultados apenas com uma camada oculta, sendo 9 e 10 neurônios para altura e diâmetro, respectivamente, realizado para 20% dos dados de validação.

As taxas de aprendizagem para a estimação das h_{ij} foram maiores para os dados de 10%, 70% e 90% de testes. Porém, para os termos *momentum* a estimação para os rm_{ij} foram maiores nos dados de 50%, 70% e 90% de testes. Os valores da média e do desvio padrão da média foram semelhantes para todo o conjunto de dados dos testes. De acordo com Souza (2013), a média e o desvio padrão da média são necessários, pois as RNAs são uma heurística, isto é, buscam a melhor convergência e não, necessariamente, retornam os mesmos valores de um mesmo ajuste.

A RMSE% foi mais precisa para as estimativas das h_{ij} e dos rm_{ij} para os dados dos testes de 10%. Ao observar 70% dos dados de teste, esses apresentaram resultados da RMSE% para as h_{ij} e rm_{ij} melhores que os dados de 30%. Com isso, percebe-se que uma maior quantidade de dados para treino não implica em um menor RMSE% dos dados de testes.

Os valores da RMSE% para as estimativas das h_{ij} e dos rm_{ij} pelas RNAs para todo o conjunto de teste foram inferiores aos valores encontrados por Souza (2013) para altura e diâmetro.

Leite et al. (2011a) obtiveram, por meio das RNAs, valores de RMSE% abaixo de 10,08% para a estimativa do diâmetro sem casca e do cerne ao longo do tronco para a espécie *Tectona grandis*.

Os valores dos parâmetros obtidos pelo ajuste da função de Garay com covariantes, para todo o conjunto de dados de treinamento, podem ser visualizados na Tabela 6. Os interceptos que não foram significativos foram mantidos por não interferirem nos resultados. Os valores dos resultados da RMSE% para o conjunto de testes encontram-se na tabela 6.

Tabela 6 Resultados do ajuste da função de Garay parâmetros com a inclusão de covariantes

Parâmetro	Valor	Erro Padrão	Valor-t	Valor-p
Teste - 10% - RMSE% = 6,48%				
φ_{10} (intercepto)	0,6690841	0,04163	16,0728	< 0,0000
φ_{11} ($DAPm_i$)	0,0088259	0,00177	4,98842	< 0,0000
φ_{12} (H_i)	-0,0185178	0,00362	-5,1156	< 0,0000
φ_{20} (intercepto)	-0,1655371	0,08706	-1,9014	0,0578
φ_{21} (H_i)	0,0853185	0,00958	8,90936	< 0,0000
φ_{30} (intercepto)	1,1809131	0,05534	21,3387	< 0,0000
φ_{31} (H_i)	-0,0408142	0,00378	-10,792	< 0,0000
φ_{40} (intercepto)	0,4276034	0,1602	2,66922	0,0078
φ_{41} ($DAPm_i$)	-0,031763	0,00417	-7,6246	< 0,0000
φ_{42} (H_i)	0,065517	0,0099	6,61721	< 0,0000
Teste - 30% - RMSE% = 10,89%				
φ_{10} (intercepto)	0,9236261	0,07969	11,5908	< 0,0000
φ_{11} (H_i)	-0,0261853	0,00638	-4,1012	< 0,0000
φ_{20} (intercepto)	-0,2055423	0,23828	-0,8626	0,3889
φ_{21} ($DAPm_i$)	0,0072876	0,00135	5,38593	< 0,0000
φ_{22} (H_i)	0,0650614	0,02143	3,03554	0,0026
φ_{30} (intercepto)	1,1971657	0,13175	9,08677	< 0,0000
φ_{31} (H_i)	-0,0362868	0,01108	-3,2759	0,0011
φ_{40} (intercepto)	-0,2975010	0,22873	-1,3007	0,1941
φ_{41} (H_i)	0,0737652	0,01896	3,8896	< 0,0001
Teste - 50% - RMSE% = 10,44%				
φ_{10} (intercepto)	0,9454798	0,11846	7,9812	< 0,0000
φ_{11} (H_i)	-0,028108	0,01021	-2,7536	0,0063
φ_{20} (intercepto)	-0,5137607	0,24378	-2,1075	0,0360
φ_{21} (H_i)	0,1055829	0,02268	4,65598	< 0,0000
φ_{30} (intercepto)	1,3873098	0,11875	11,6831	< 0,0000
φ_{31} (H_i)	-0,0541014	0,01087	-4,9773	< 0,0000
φ_{40} (intercepto)	-0,4081088	0,30928	-1,3195	0,1881

$\varphi_{41} (H_i)$ 0,0830724 0,02735 3,03783 0,0026
 “Tabela 6, conclusão”

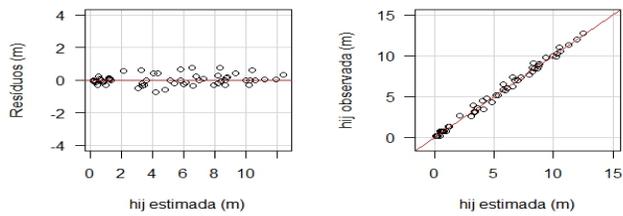
Parâmetro	Valor	Erro Padrão	Valor-t	Valor-p
Teste - 70% - RMSE% = 8,91%				
φ_{10} (intercepto)	0,6616533	0,06649	9,95079	< 0,0000
φ_{11} ($DAPm_i$)	0,0103804	0,00336	3,09367	< 0,0023
φ_{12} (H_i)	-0,0201733	0,00502	-4,0189	< 0,0001
φ_{20} (intercepto)	2,3619640	0,42487	5,55928	< 0,0000
φ_{21} (H_i)	-0,1394128	0,02532	-5,5069	< 0,0000
φ_{30} (intercepto)	0,0798091	0,07695	1,0372	0,3012
φ_{31} (H_i)	0,0573406	0,00593	9,66668	< 0,0000
φ_{40} (intercepto)	1,3551399	0,1898	7,13984	< 0,0000
φ_{41} ($DAPm_i$)	-0,0432356	0,00776	-5,5697	< 0,0000
Teste - 90% - RMSE% = 20,61%				
φ_{10} (intercepto)	0,6303882	0,13157	4,79133	< 0,0000
φ_{11} ($DAPm_i$)	0,0288326	0,01167	2,46977	< 0,0169
φ_{11} (H_i)	-0,0453603	0,01836	-2,4708	< 0,0169
φ_{20} (intercepto)	1,6586845	0,32416	5,11694	< 0,0000
φ_{21} ($DAPm_i$)	-0,1896582	0,03245	-5,8447	< 0,0000
φ_{21} (H_i)	0,2202834	0,03276	6,72515	< 0,0000
φ_{30} (intercepto)	0,3336135	0,11172	2,98622	< 0,0043
φ_{31} ($DAPm_i$)	0,0934339	0,01189	7,85755	< 0,0000
φ_{32} (H_i)	-0,0952786	0,0113	-8,4315	< 0,0000
φ_{33} (HDC_i)	-0,0154606	0,00452	-3,4177	< 0,0012
φ_{40} (intercepto)	1,0867980	0,34242	3,17386	< 0,0025
φ_{41} ($DAPm_i$)	-0,1353033	0,03045	-4,4441	< 0,0000
φ_{42} (H_i)	0,1668845	0,03201	5,21392	< 0,0000

As estimativas das h_{ij} das RMSE% foram menores para os dados de 10% de testes com o ajuste para a função de Garay. Resultados semelhantes foram encontrados para esses dados de teste por meio das RNAs. A RMSE% para as

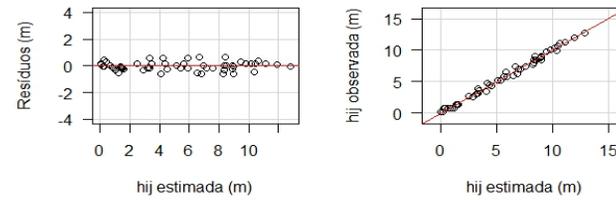
estimativas das h_{ij} foram menores por meio das RNAs para o conjunto de testes de 30%, 50%, 70% e 90% em relação à função de Garay.

Özçelik et al. (2013) compararam equação de Gompertz, usando a modelagem de efeito misto, e as RNAs obtiveram um melhor RMSE% para a estimativa da relação diâmetro *versus* altura por meio da equação de Gompertz. Porém, esses mesmos pesquisadores mencionaram que as RNAs apresentaram estimativas aceitáveis e que necessita apenas da variável DAP para explicar a relação hipsométrica, enquanto a equação de Gompertz utilizou além do DAP a variável da \overline{HDC} , que ocasionou um custo maior no inventário florestal. As RNAs demonstraram ser eficazes para descrição do afilamento quando comparado com o modelo linear Kozak (LEITE et al., 2011a).

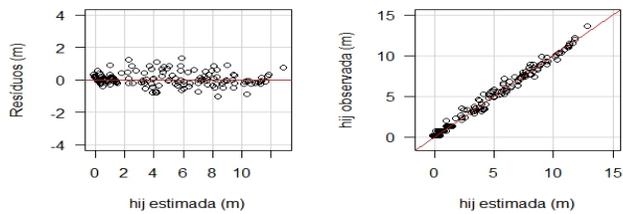
A análise gráfica dos resíduos e os gráficos das h_{ij} estimadas *versus* h_{ij} observadas, por meio das RNAs e da função de Garay, para o conjunto dos dados de testes de 10%, 30%, 50%, 70% e 90% são apresentados na Figura 12.



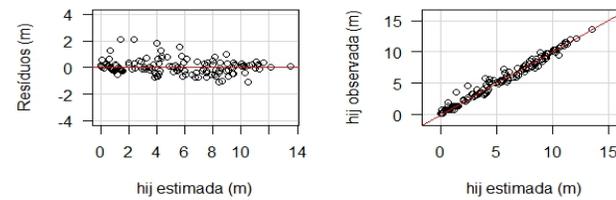
RNA – 10%



Garay – 10%



RNA – 30%

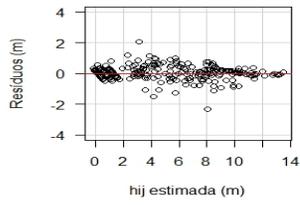


Garay – 30%

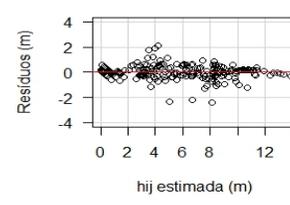
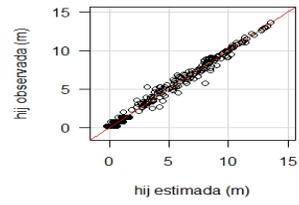
Figura 12 Gráficos dos resíduos e das h_{ij} estimadas *versus* h_{ij} para os dados de testes na i -ésima árvore e na j -ésima seção observada ao longo do fuste nas árvores de cedro australiano por meio das RNAs e da Função de Garay

(...continua...)

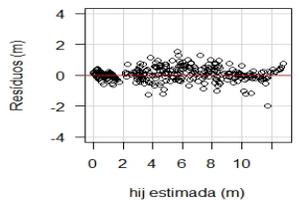
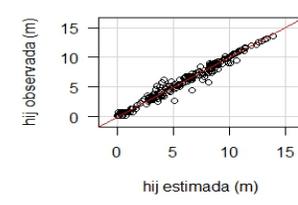
“Figura 12, conclusão”



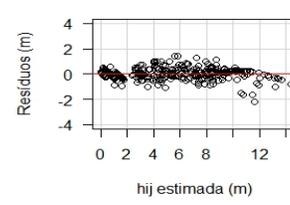
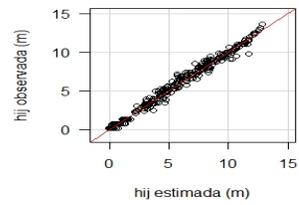
RNA – 50%



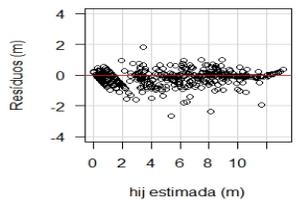
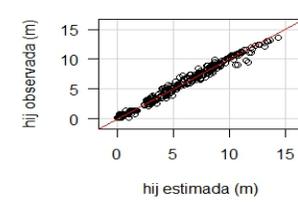
Garay – 50%



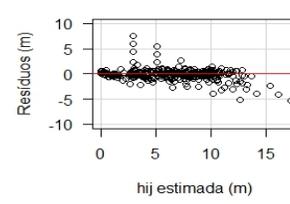
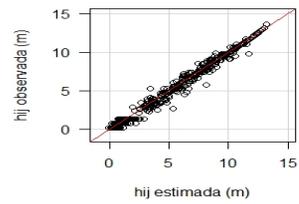
RNA – 70%



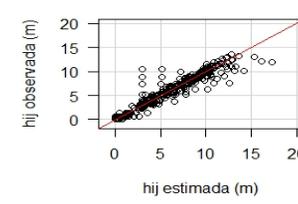
Garay – 70%



RNA – 90%



Garay – 90%



Os valores das h_{ij} estimadas *versus* h_{ij} observadas para as RNAs com 10% dos dados de teste apresentam uma pequena subestimativa, aproximadamente, no intervalo entre 6 m e 10 m e o mesmo não ocorre com a função de Garay. A estimativa de h_{ij} na base por meio da RNA com 10% dos de teste é melhor em relação à função de Garay.

Para os 30% dos dados de teste, verifica-se nos gráficos para as RNAs uma subestimativa nas $h_{ij} = H_i$ e em torno de 2 m de altura. Para a função de Garay observa-se nos gráficos valores h_{ij} subestimadas na base. Para os gráficos com 50% dos dados de teste, as RNAs superestimam as h_{ij} em torno de 4 m e apresentam valores negativos para h_{ij} na base. A função de Garay, ao comparar com o gráfico dos resíduos as RNAs, apresenta uma subestimativa de h_{ij} no intervalo entre 2 m e 6 m e uma superestimativas na $h_{ij} = H_i$.

Nos gráficos dos resíduos das RNAs em relação à função de Garay para 70% dados de testes observa-se que as h_{ij} mais dispersas ao eixo das abcissas, mesmo com o resultado da RMSE% melhor. As RNAs, ao contrário da função de Garay, apresentam maior subestimativa das h_{ij} no topo. A função de Garay mostra h_{ij} superestimados próximo a H_i .

Para 90% dos dados de teste, notam-se valores das h_{ij} superestimadas na base e subestimadas no topo para as RNAs. Para a função de Garay, observam-se valores de h_{ij} superestimados na H_i e subestimativas próximo ao $DAPm_i$.

Souza (2013), ao estimar a altura por meio das RNAs e da função de afilamento, verificou valores negativos na base para todos os tratamentos avaliados de eucalipto. Diferente de Souza (2013), as estimativas das alturas com as RNAs apresentaram melhores resultados. Mendonça et al. (2007), em trabalho realizado com eucaliptos, no sul da Bahia, verificaram que os erros da estimativa da altura em seções na base próxima ao DAP eram maiores.

A figura 13 mostra o perfil médio para a estimativa da altura por meio das RNAs e a função de Garay para todo o conjunto de testes, 10%, 30%, 50%, 70% e 90%.

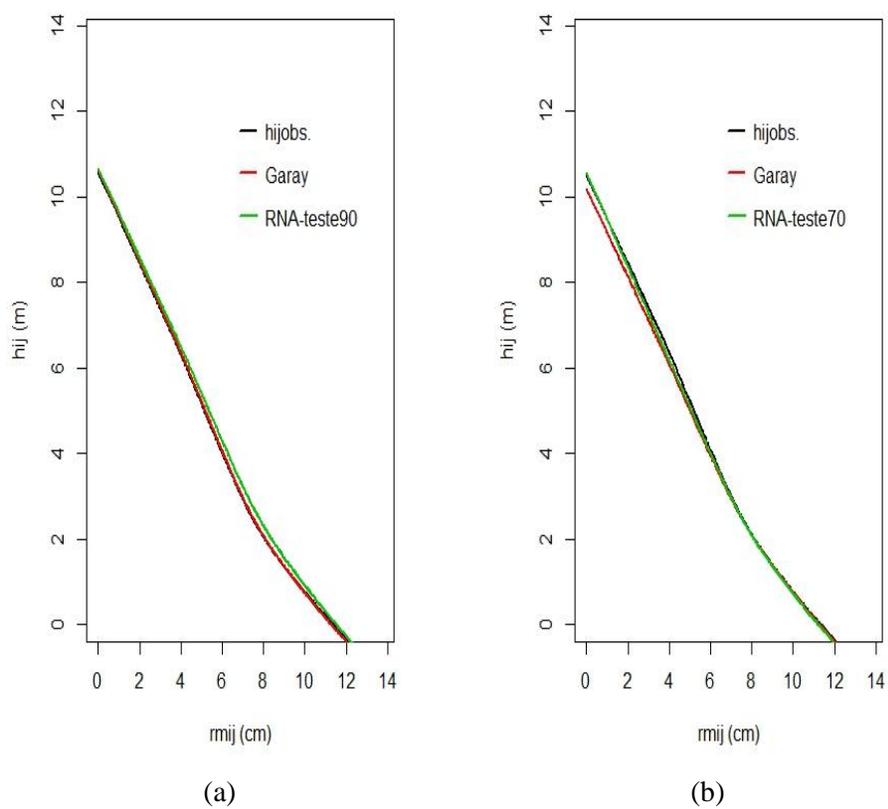
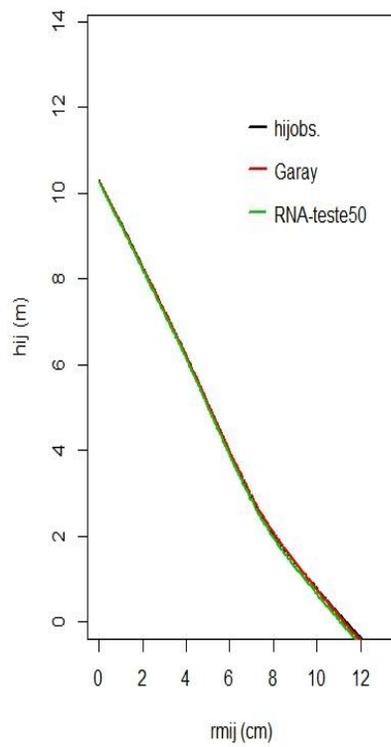


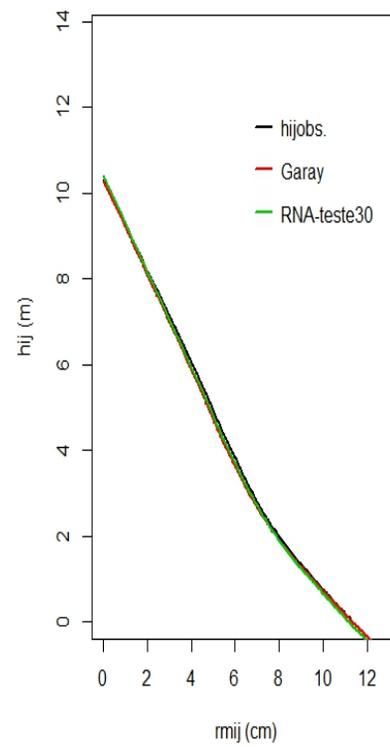
Figura 13 Perfil longitudinal médio para o cedro australiano por meio das RNAs e pela função de Garay. a - 10%; b - 30%; c - 50%; d - 70%; e - 90% dos dados de testes; h_{ij} obs. - altura observada ao longo do fuste na i -ésima árvore e na j -ésima seção

(...continua...)

“Figura 13, continua”



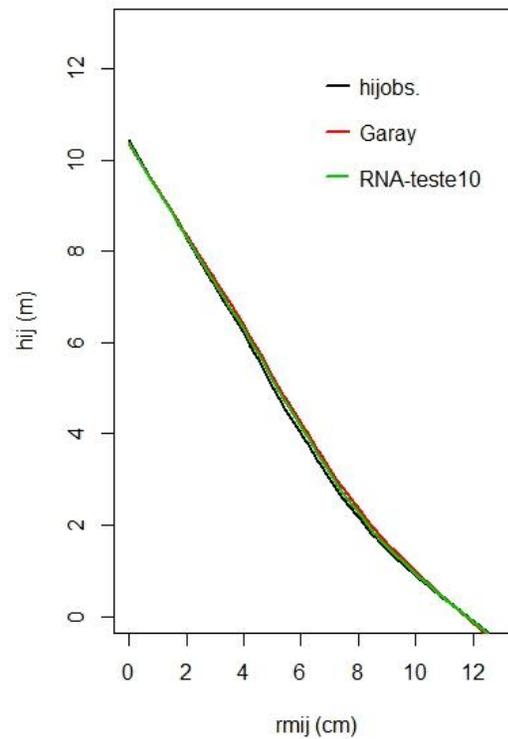
(c)



(d)

(...continua)

“Figura 13, conclusão”



(e)

Ao avaliar o perfil longitudinal médio para o cedro australiano, observou-se que as RNAs representaram melhor o perfil longitudinal, para os dados de 30%, 70% e 90% de teste, em relação à função de Garay que foi melhor para os dados de 10% de teste. Ao avaliar para os dados de 50% de teste verifica-se que as RNAs e a função de Garay são semelhantes. Nos gráficos, Figura 13, tanto as RNAs e a função de Garay conseguiram representar do perfil longitudinal médio.

A função de Garay representou melhor o perfil da árvore média ao estimar di/DAP na base que as RNAs e as RNAs apresentaram uma maior sinuosidade nessa região (SOUZA, 2013). O mesmo autor relata que os dois métodos conseguiram aproximar as formas do fuste, considerando da base ao topo: neiloide, cone e um parabolóide. Além, que a RNA conseguiu apresentar a forma para diferentes espaçamentos.

Ao representar o perfil da *Tectona grandis* em um plantio localizado no estado do Mato Grosso, ao estimar os diâmetros sem casca e do cerne, as RNAs não conseguiram estimar os menores diâmetros (LEITE et al., 2011b).

Na Tabela 7 encontram-se os valores dos parâmetros obtidos pelo ajuste da função de Garay com covariantes, para todo o conjunto de dados de treinamento. Valores não significativos foram mantidos por não interferirem nos resultados. As RMSE% obtidas para o conjunto de testes encontram-se na tabela 7.

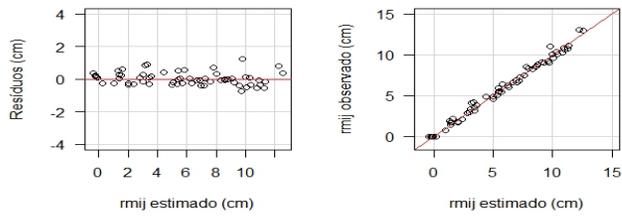
Tabela 7 Estatísticas obtidas com o ajuste da função de Garay

Parâmetro	Valor	Erro Padrão	Valor-t	Valor-p
Teste - 10% - RMSE% = 7,13%				
φ_{10} (intercepto)	0,8963891	0,04453	20,1299	< 0,0000
φ_{11} (H_i)	-0,0211036	0,00396	-5,3323	< 0,0000
φ_{20} (intercepto)	-0,3707579	0,07288	-5,0871	< 0,0000
φ_{21} (H_i)	0,099985	0,00824	12,1368	< 0,0000
φ_{30} (intercepto)	1,2835209	0,0301	42,6413	< 0,0000
φ_{31} (H_i)	-0,0487453	0,00346	-14,093	< 0,0000
φ_{40} (intercepto)	-0,1440194	0,09684	-1,4872	0,1376
φ_{41} (H_i)	0,0560809	0,00918	6,10896	< 0,0000
Teste - 30% - RMSE% = 10,27%				
φ_{10} (intercepto)	0,7250680	0,09191	7,88929	< 0,0000
φ_{11} (H_i)	-0,0255526	0,008	-3,1934	0,0015
φ_{12} (HDC $_i$)	0,0226782	0,01103	2,05626	0,0404
φ_{20} (intercepto)	1,2608366	0,2373	5,31319	< 0,0000
φ_{21} (HDC $_i$)	-0,0679252	0,02056	-3,3045	0,0010
φ_{30} (intercepto)	0,4529251	0,12407	3,6507	0,0003
φ_{31} (HDC $_i$)	0,0367712	0,01071	3,43267	0,0007
φ_{40} (intercepto)	0,6913380	0,21262	3,25159	0,0012
φ_{41} (H_i)	0,0186974	0,00947	1,97423	0,0490
φ_{42} (HDC $_i$)	-0,0503591	0,01955	-2,5753	0,0104
Teste - 50% - RMSE% = 9,60%				
φ_{10} (intercepto)	0,8286416	0,02981	27,8017	< 0,0000
φ_{11} (DAP m_i)	-0,0063158	0,00135	-4,6869	< 0,0000
φ_{20} (intercepto)	1,1691916	0,19842	5,89243	< 0,0000
φ_{21} (DAP m_i)	0,0017889	0,00077	2,32258	0,0209
φ_{22} (HDC $_i$)	-0,0657998	0,01573	-4,1824	< 0,0000
φ_{30} (intercepto)	0,4904904	0,10977	4,46855	< 0,0000
φ_{31} (HDC $_i$)	0,0350831	0,00861	4,07412	< 0,0001
φ_{40} (intercepto)	0,6596202	0,09725	6,78264	< 0,0000
φ_{41} (HDC $_i$)	-0,0323051	0,00778	-4,15	< 0,0000

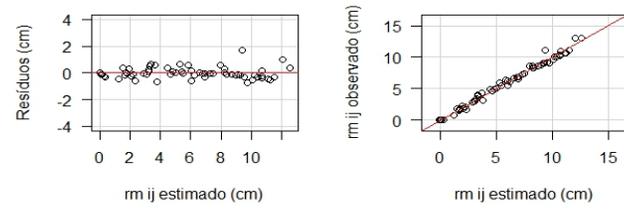
“Tabela 7, conclusão”

Parâmetro	Valor	Erro Padrão	Valor-t	Valor-p
Teste - 90% - RMSE% = 21,14%				
φ_{10} (intercepto)	1,3398914	0,25389	5,27745	< 0,0000
φ_{11} (H_i)	-0,1627071	0,05483	-2,9677	0,0045
φ_{12} (HDC $_i$)	0,0951480	0,03633	2,61892	0,0115
φ_{20} (intercepto)	-0,5294680	0,46015	-1,1506	0,2551
φ_{21} (H_i)	0,6576252	0,12892	5,10117	< 0,0000
φ_{22} (HDC $_i$)	-0,5075591	0,09048	-5,6099	< 0,0000
φ_{30} (intercepto)	1,3774194	0,21511	6,40345	< 0,0000
φ_{31} (H_i)	-0,3177030	0,05314	-5,9791	< 0,0000
φ_{32} (HDC $_i$)	0,2440137	0,03553	6,86813	< 0,0000
φ_{40} (intercepto)	-0,6610109	0,40596	-1,6283	0,1095
φ_{41} (H_i)	0,4094992	0,08921	4,59025	< 0,0000
φ_{42} (HDC $_i$)	-0,2875818	0,06109	-4,7075	< 0,0000

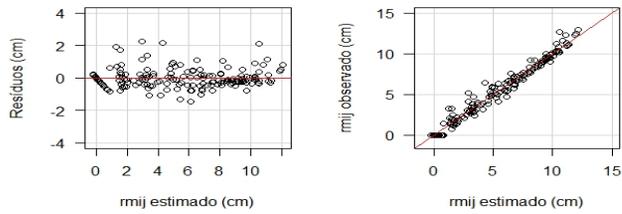
A análise gráfica dos resíduos e os gráficos dos rm_{ij} estimados *versus* rm_{ij} observados, por meio das RNAs e da função de Garay, para o conjunto dos dados de testes de 10%, 30%, 50%, 70% e 90% são apresentados na Figura 14. Com exceção dos dados de 70% para a função de Garay não foi possível o ajuste.



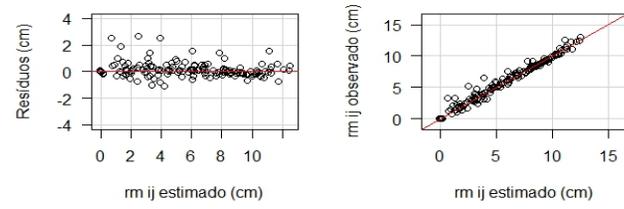
RNA – 10%



Garay – 10%



RNA – 30%

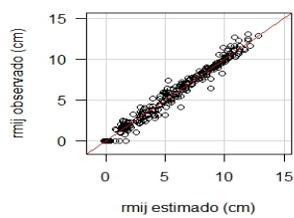
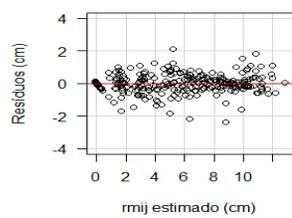


Logística de 4 parâmetros – 30%

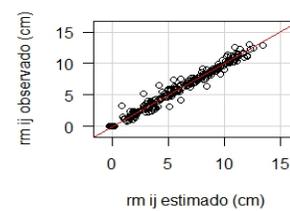
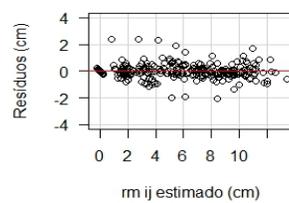
Figura 14 Gráficos dos resíduos e dos rm_{ij} estimados versus rm_{ij} observados na i -ésima árvore e na j -ésima seção ao longo do fuste nas árvores de cedro australiano por meio das RNA e da função de Garay

(...continua...)

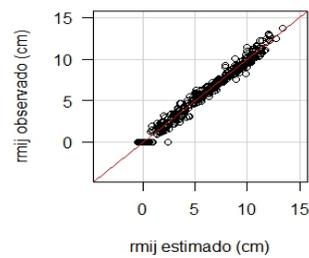
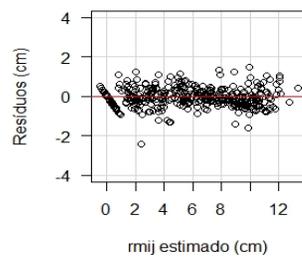
“Figura 14, continua”



RNA – 50%



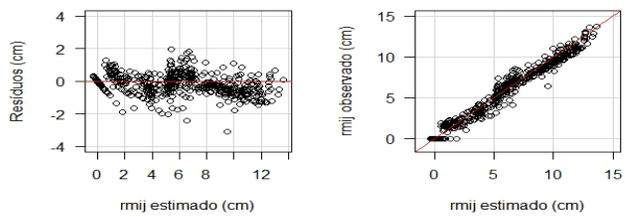
Garay – 50%



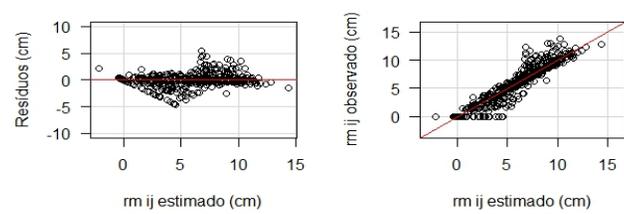
RNA – 70%

(...continua...)

“Figura 14, conclusão”



RNA – 90%



Garay– 90%

Para 10% dos dados de teste, os gráficos dos rm_{ij} estimados *versus* rm_{ij} observados foram semelhantes para as RNAs e para a função de Garay (Figura 16). Contudo, a função de Garay apresentou subestimativas na base mais acentuada em relação as RNAs. Para 30% dos dados de teste, as RNAs subestimaram os rm_{ij} na base e no intervalo de 2 cm a 4 cm (Figura 15). Para a função de Garay, observam-se subestimativas dos rm_{ij} acentuadas próximo a H_i .

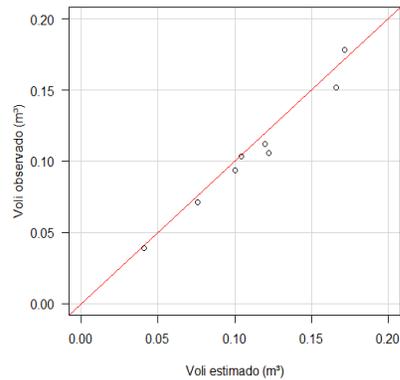
Para 50% dos dados de testes, verifica-se no gráfico dos resíduos para as RNAs, uma subestimativa na base e superestimativa na H_i . Para a função de Garay, observam-se valores negativos dos rm_{ij} no topo e subestimativa na base. Nos gráficos dos resíduos com 70% dos dados de teste observam-se para as RNAs praticamente a mesma distribuição.

Para os valores dos rm_{ij} estimados *versus* rm_{ij} observados para 90% dos dados de teste, apresentados na Figura 14, percebe-se que as RNAs obtiveram melhores estimativas em relação à função de Garay, pois esta apresentava ora subestimativa ora superestimativa.

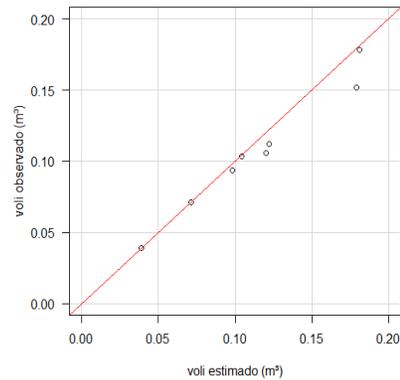
5.3 Estimativa do volume total para as RNAs

As estimativas obtidas para o raio médio por meio das RNAs e da função de Garay foram utilizadas para obtenção do volume total individual de cada árvore. O método aplicado para obtenção do volume total foi o de Smalian. Ao avaliar os gráficos dos valores estimados *versus* valores observados para obtenção do volume total das árvores de cedro australiano, percebe-se que a função de Garay em relação às RNAs apresenta melhores resultados, pois ao comparar os menores valores entre os volumes estimados e volumes observados verifica-se que estão próximos à reta (Figura 15). A função de Garay, por não conseguir parâmetros significativos aos dados de teste de 30% não apresentaram resultados do volume total. Ao observar os valores estimados *versus* valores

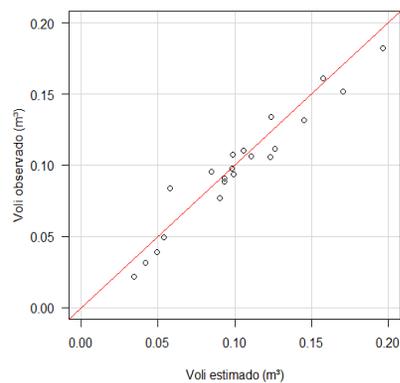
observados para as estimativas dos volumes maiores, as RNAs e a função de Garay são semelhantes.



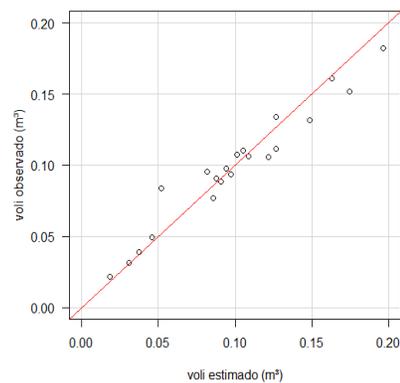
RNA – 10%



Garay – 10%



RNA – 30%

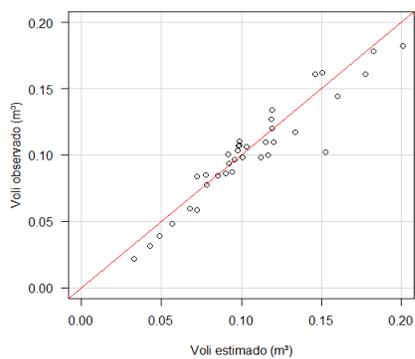


Garay – 30%

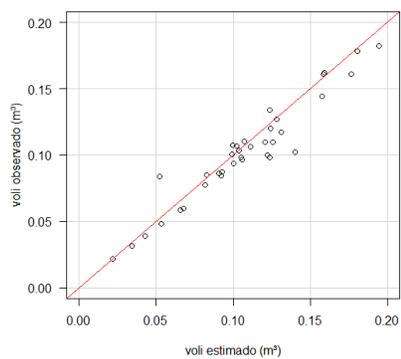
Figura 15 Vol_i estimados *versus* vol_i observados na i -ésima árvore obtidos considerando a estimativa do raio médio pelas RNAs e pela função de Garay aplicando o método de Smalian para o cedro australiano

(...continua...)

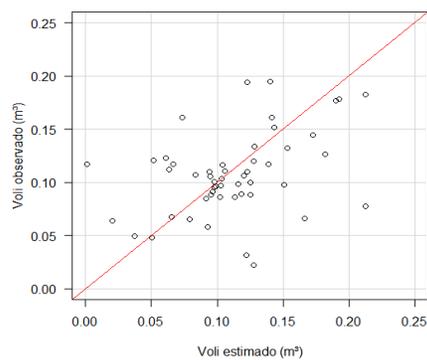
“Figura 15, conclusão”



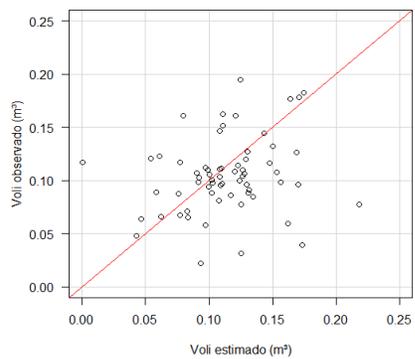
RNA – 50%



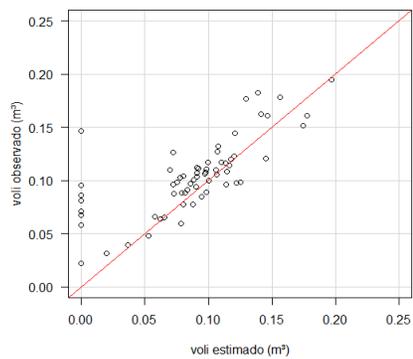
Garay – 50%



RNA – 70%



RNA – 90%



Garay – 90%

Görgens et al. (2009) obtiveram bons resultados ao estimar o volume total para árvores de eucalipto e teca para diferentes locais por meio das RNAs, pois reduziram o número de equações a serem ajustadas e conseguiram um bom resultado ao estimar o volume para as duas espécies.

Em trabalho realizado com a espécie de pinus para a estimativa do volume, ao comparar modelos de regressão não lineares e RNAs, essa última conseguiu ser superior ao estimar o volume total do fuste (DIAMANTOPOULOU, 2005).

Souza (2013), ao comparar as RNAs e a função de Garay, obteve melhor resultado ao estimar o volume total dos fustes de eucalipto por regressão, mas afirma que usar o modelo de regressão demandou mais tempo ao estimar o volume total para cada tratamento. Para o caso das RNAs, o mesmo autor conseguiu bons resultados estimando o volume para todos os tratamentos de uma única vez.

6 CONCLUSÃO

- a) Ao avaliar as estimativas para as h_{ij} verificou-se que a inclusão de covariantes melhorou os resultados do erro padrão residual e a análise gráfica dos resíduos;
- b) Por meio das RNAs foi possível estimar a h_{ij} , dos rm_{ij} e do volume total das árvores de cedro australiano e representar o perfil longitudinal;
- c) As RNAs obtiveram resultados melhores ou satisfatórios, quando comparado com a função de afilamento de Garay, para as estimativas das h_{ij} , dos rm_{ij} e do volume total;
- d) As RNAs podem ser utilizadas para as estimativas das h_{ij} , rm_{ij} e do volume total das árvores de cedro australiano.

REFERÊNCIAS

- ALVES, J. A. **Modelos biométricos florestais para *Toona ciliata* M. Roem. (Cedro australiano)**. 2013. 135 p. Dissertação (Mestrado em Engenharia Florestal) - Universidade Federal de Lavras, Lavras, 2013.
- ANUCHIN, N. P. **Forest mensuration**. 2. ed. Jerusalem: Israel Program for Scientific Translat, 1970.
- AVERY, T. E.; BURKHART, H. E. **Forest measurements**. 4. Ed. New York: McGraw-Hill, 1994.
- BINOTI, M. L. M. da S.; BINOTI, D. H. B.; LRITE, H. G. Aplicação de redes neurais artificiais para estimação de altura de povoamentos equiâneos de eucalipto. **Revista Árvore**, Viçosa, v. 37, n. 4, p. 639-645, 2013.
- BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. 2. ed. Rio de Janeiro: Livros Técnicos e Científicos, 2011.
- BYGRAVE, F.; BYGRAVE. P. **Growing Australian red cedar and other meliaceae species in plantation**. Barton: Rirdc, 2005.
- CALAMA, R. et al. Adapting a model for even-aged *Pinus pinea* L, stands to complex multi-aged structures. **Forest Ecology and Management**, Amsterdam, v. 256, n. 6, p. 1390-1399, 2008.
- CALEGARIO, N. **Modeling *Eucalyptus* stand growth based on linear and nonlinear mixed-effects models**. 2002. 121 p. Dissertation (Doctor of Philosophy) - University of Georgia in Partial Fulfillment, Georgia, 2002.
- CARVALHO, S. P. C. **Uma nova metodologia de avaliação do crescimento e da produção de *Eucalyptus* sp clonal para fins energéticos**. 2010. 103 p. Dissertação (Mestrado em Engenharia Florestal) - Universidade Federal de Lavras, Lavras, 2010.
- CARVALHO, S. P. et al. Modelos não lineares generalizados aplicados na predição da área basal e volume de *Eucalyptus* clonal. **Cerne**, Lavras, v. 17, n. 4, p. 541-548, out./dez. 2011.

- CASTEDO-DORADO, F.; DIEGUEZ-ARANDA, U.; ALVAREZ-GONZALEZ, J. G. A growth model for *Pinus radiata* D, don stands in north-western Spain, **Annals of Forest Science**, Paris, v. 64, n. 4, p. 453-465, June/July 2007.
- CRECENTE-CAMPO, F. et al. A generalized nonlinear mixed-effects height-diameter model for *Eucalyptus globulus* L, in northwestern Spain. **Forest Ecology and Management**, Amsterdam, v. 259, n. 5, p. 943-952, Feb. 2010.
- DIAMANTOPOULOU, M. J. Artificial neural networks as an alternative tool in pine bark volume estimation. **Computers and Electronics in Agriculture**, Oxford, v. 48, n. 3, p. 235-244, Sept. 2005.
- DIAS, F. C. **Uso do software Image J para análise quantitativa de imagens de microestruturas de materiais**. 2008. 145 p. Dissertação (Mestrado em Engenharia e Tecnologia Espaciais/Ciência e Tecnologia de Materiais e Sensores) - Instituto Nacional de Pesquisa Espacial, São José dos Campos, 2008.
- DIÉGUEZ-ARANDA, U. et al. Dynamic growth model for scots pine (*Pinus sylvestris* L.) plantations in Galicia (north-western Spain). **Ecological Modelling**, Amsterdam, v. 191, n. 2, p. 225-242, Jan. 2006.
- EMILIANO, P. C. **Fundamentos e aplicações dos critérios de informação: Akaike e Bayesiano**. 2009. 92 p. Dissertação (Mestrado em Estatística e Experimentação Agropecuária) - Universidade Federal de Lavras, Lavras, 2009.
- FERREIRA, M. Z. **Estudo de funções de afilamento para representar o perfil e o volume do fuste de *Pinus taeda* L.** 2004. 196 p. Dissertação (Mestrado em Engenharia Florestal) – Universidade Federal de Lavras, Lavras, 2004.
- FIGUEIREDO FILHO, A. et al. Taper equations for *Pinus taeda* plantations in Southern Brazil. **Forest Ecology and Management**, Amsterdam, v. 83, n. 1-2, p. 39-46, June 1996.
- FINGER, C. A. G. **Fundamentos de biometria florestal**. Santa Maria: Editora da UFSM, 1992.
- FONWEBAN, J. et al. Taper functions for scots pine (*Pinus sylvestris* L.) and sitka spruce (*Picea sitchensis* (Bong.) Carr.) in Northern Britain. **Forestry**, Oxford, v. 84, n. 1, p. 49-60, Jan. 2011.

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

GÖRGENS, E. B. et al. Estimação do volume de árvores utilizando redes neurais artificiais. **Revista Árvore**, Viçosa, v. 33, n. 6, p. 1141-1147, 2009.

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

HEIDARSSON, L.; PUKKALA, T. Taper functions for lodgepole pine (*Pinus contorta*) and Siberian larch (*Larix sibirica*) in Iceland. **Icelandic Agricultural Sciences**, Reykjavik, v. 24, p. 3-11, 2011.

HOLER, D. C. et al. Modelagem não linear do perfil longitudinal de fustes de *Pinus oocarpa*. **Cerne**, Lavras, v. 16, n. 2, p. 177-184, abr./jun. 2010.

HRITONENKO, N. et al. Maximum principle for a size-structured model of forest and carbon sequestration management. **Applied Mathematics Letters**, Oxford, v. 21, n. 10, p. 1090-1094, Out., 2008.

HU, Z.; OSCAR, G. A height-growth and site-index model for interior spruce in the sub-boreal spruce biogeoclimatic zone of British Columbia. **Canadian Journal of Forest Research-Revue Canadienne de Recherche Forestiere**, Ottawa, v. 40, n. 6, p. 1175-1183, June 2010.

HUSCH, B.; MILLER, C.; BEERS, T. W. **Forest mensuration**. 3. Ed. New York: John Wiley, 1982.

KUBLIN, E.; AUGUSTIN, N.; LAPPI, J. A flexible regression model for diameter prediction. **European Journal of Forest Research**, New York, v. 127, n. 5, p. 415-428, 2008.

LAMPRECHT, H. **Silvicultura nos trópicos**. Eschborn: Deutsche Gesellschaft für Technische Zusammen, 1990.

LEITE, H. G. et al. Estimation of inside-bark diameter and heartwood diameter for *Tectona grandis* Linn, trees using artificial neural networks. **European Journal of Forest Research**, New York, v. 130, n. 2, p. 263-269, Mar. 2011a.

LEITE, H. G. et al. Função de afilamento para *Virola surinamensis* (Roll.) Warb. **Revista Árvore**, Viçosa, v. 30, n. 1, p. 99-106, jan./fev. 2006.

LEITE, H. G. et al. Modelo de afilamento de cerne de *Tectona grandis* L, f. **Scientia Forestalis**, Piracicaba, v. 39, n. 89, p. 53-59, mar. 2011b.

LOUREIRO, G. H. et al. Avaliação de equações de afilamento em um plantio de *araucaria angustifolia* (bert.) O, Ktze utilizando o diâmetro como variável dependente. In: CONGRESSO FLORESTAL PARANAENSE, 4., Paraná. **Anais...** Paraná: Associação Paranaense de Empresas de Base Florestal, 2012.

MACHADO, S. A. et al. Comparação entre análise de tronco digital e convencional em árvores de *Mimosa scabrella* Bentham e *Pinus taeda* L. **Revista Árvore**, Viçosa, v. 37, n. 2, p. 329-337, 2013.

MACHADO, S. A.; FIGUEIREDO FILHO, A. **Dendrometria**. 2. ed. Paraná: Editora da Fupef, 2009.

MEHTÄTALO, L. et al. Combining a predicted diameter distribution with an estimate based on a small sample of diameters. **Canadian Journal of Forest Research-Revue Canadienne de Recherche Forestiere**, Ottawa, v. 41, n. 4, p. 750-762, Apr. 2011.

MENDONÇA, A. R. et al. Avaliação de funções de afilamento visando a otimização de fustes de *Eucalyptus* sp. para multiprodutos. **Cerne**, Lavras, v. 13, n. 1, p. 71-82, 2007.

MENG, S. X.; HUANG, S. Incorporating correlated error structures into mixed forest growth models: prediction and inference implications. **Canadian Journal of Forest Research-Revue Canadienne de Recherche Forestiere**, Ottawa, v. 40, n. 5, p. 977-990, May 2010.

MURAKAMI, C. H. G. Cedro australiano: valorização de espécies nobres. **Boletim Florestal**, Brasília, v. 7, n. 2, p. 1-6, fev. 2008.

NEWTON, P. F.; AMPONSAH, I. G. Comparative evaluation of five height–diameter models developed for black spruce and jack pine stand-types in terms of goodness-of-fit, lack-of-fit and predictive ability. **Forest Ecology and Management**, Amsterdam, v. 247, n. 1-3, p. 149-166, Aug. 2007.

NISGOSKI, S. et al. Anatomia da madeira de *Toona ciliata* características das fibras para produção de papel. **Floresta**, Curitiba, v. 41, n. 4, p. 717-728, out./dez. 2011.

NUNES, L.; TOME, J.; TOME, M. A system for compatible prediction of total and merchantable volumes allowing for different definitions of tree volume. **Canadian Journal of Forest Research-Revue Canadienne de Recherche Forestiere**, Ottawa, v. 40, n. 4, p. 747-760, Apr. 2010.

OLIVEIRA, J. T. S. Caracterização da madeira de sete espécies de eucaliptos para a construção civil: 1- avaliações dendrométricas das árvores. **Scientia Forestalis**, Piracicaba, n. 56, p. 113-124, dez. 1999.

ÖZÇELİK, R. et al. Estimating Crimean juniper tree height using nonlinear regression and artificial neural network models. **Forest and Ecology Management**, Amsterdam, v. 306, p. 52-60, Oct. 2013.

PELLICO NETTO, S.; BRENA, D. A. (Ed.). **Inventário florestal**. Curitiba: SBS, 1997.

PEREIRA, J. E. S. et al. Modelagem do volume do tronco do *Eucalyptus grandis* Hill ex Maiden. In: SIMPÓSIO DE ENGENHARIA DE PRODUÇÃO, 12., 2005, Bauru. **Anais...** Bauru: SIMPEP, 2005.

PINHEIRO, J. C.; BATES, D. M. **Mixed-effects models in s and s-plus**. New York: Springer-Verlag, 2000.

PIRES, L. M.; CALEGARIO, N. Ajuste de modelos estocásticos lineares e não-lineares para a descrição do perfil longitudinal de árvores. **Revista Árvore**, Viçosa, v. 31, N. 5, p. 845-852, set./out. 2007.

QUEIROZ, D. **Avaliação de funções de afilamento e sortimentos para *Mimosa scabrella* Benth em povoamentos nativos da região metropolitana de Curitiba/PR**. 2006. 134 p. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal do Paraná, Curitiba, 2006.

R CORE TEAM. **R: a language and environment for statistical computing**. Vienna: R Foundation for Statistical Computing, 2012.

RASBAND, W. ImageJ documentation. [S.l.: s.n], 2007. Disponível em: <<http://rsb.info.nih.gov/ij/docs/index.html>>. Acesso em: 27 jan. 2013.

RATKOWSKY, D. A. **Nonlinear regression modeling**. New York: Marcel Dekker, 1983.

- RIBEIRO, A. de O. et al. Variação da densidade básica da madeira de *Toona ciliata* Roem cultivada em diferentes localidades. **Scientia Forestalis**, Piracicaba, v. 39, n. 91, p. 359-366, set. 2011.
- RICKEN, P. et al. **Crescimento diamétrico de povoamento de *Toona ciliata* var, *australis* em Adrianópolis**, Colombo: Embrapa Florestas, 2011.
- RIOS, M. S. **A eficiência das funções polinomiais, da função Spline cúbica, e razões de volume para representar o perfil da árvore e estimar os sortimentos de *Pinus elliottii***, Lavras. 1997. 116 p. Dissertação (Mestrado em Engenharia Florestal) - Universidade Federal de Lavras, Lavras, 1997.
- SEVILLANO-MARCO, E.; FERNANDEZ-MANSO, A.; CASTEDO-DORADO, F. Development and applications of a growth model for *Pinus radiata* D, Don plantations in El Bierzo (Spain). **Investigacion Agraria-Sistemas y Recursos Forestales**, Madrid, v. 18, n. 1, p. 64-80, Apr. 2009.
- SILVA, F. da; CORTE, A. P. D.; SANQUETTA, C. R. Equações de afilamento para descrever o volume total do fuste de *Pinus caribaea* var, *hondurensis* na região do Triângulo Mineiro, **Scientia Forestalis**, Piracicaba, v. 39, n. 91, p. 367-376, set. 2011.
- SOARES, F. A. A. M. N. et al. Recursive diameter prediction and volume calculation of eucalyptus trees using multilayer perceptron networks. **Computers and Electronics in Agriculture**, Kidlington, v. 78, n. 1, p. 19-27, Aug. 2011.
- SOARES, F. A. A. M. N. et al. Recursive diameter prediction for calculating merchantable volume of *Eucalyptus* clones without previous knowledge of total tree height using artificial neural networks. **Applied Soft Computing**, Amsterdam, v. 12, n. 8, p. 2030-2039, Aug. 2012.
- SOUZA, C. A. M. et al. Modelos de afilamento para o sortimento do fuste de *Pinus taeda* L. **Ciência Rural**, Santa Maria, v. 38, n. 9, p. 2506-2511, dez. 2008.
- SOUZA, C. A. M. **Modelos de afilamento para *Pinus Taeda* L, ajustados segundo a forma do tronco e métodos de estratificação**. 2009. 120 p. Tese (Doutorado em Engenharia Florestal) - Universidade Federal de Santa Maria, Santa Maria, 2009.
- SOUZA, J. C. A. V.; BARROSO, D. G.; CARNEIRO, J. G. A. **Cedro australiano (*Toona ciliata*)**. Niterói: Programa Rio Rural, 2010.

SOUZA, R. R. **Estudo da forma do fuste de árvores de *Eucalyptus* sp. em diferentes densidades de plantio.** 2013. 66 p. Dissertação (Mestrado em Ciência Florestal) - Universidade Federal dos Vales do Jequitinhonha e Mucuri, Diamantina, 2013.

STIRN, L. Z. Adaptive dynamic model for optimal forest management. **Forest Ecology and Management**, Amsterdam, v. 31, n. 3, p. 167-188, Mar. 1990.

TONINI, H.; SCHNEIDER, P. R.; FINGER, C. A. G. Curvas de índice de sítio para povoamentos clonais de *Eucalyptus saligna* Smith para a depressão central e serra do sudeste, rio grande do sul. **Ciência Florestal**, Santa Maria, v. 16, n. 1, p. 27-43, 2006.

VARGAS-LARRETA, B. et al. A generalized height-diameter model with random coefficients for uneven-aged stands in El Salto, Durango (Mexico). **Forestry**, Oxford, v. 82, n. 4, p. 445-462, May 2009.

VILELA, E. S.; STEHLING, E. de C. **Recomendações de plantio para Cedro Australiano.** Campo Belo: Fazenda Bela Vista Florestal, 2011. Disponível em: <[http://www.belavista florestal.com.br/imagens/arquivos/recomedacoes_plantio_cedro_v1.0.pdf](http://www.belavistaflorestal.com.br/imagens/arquivos/recomedacoes_plantio_cedro_v1.0.pdf)>. Acesso em: 22 set. 2012.

WECA THE UNIVERSITY OF WAIKATO. **Weka 3:** data mining software in java. Oxford: Machine Learning Group, 2013. Disponível em: <<http://www.cs.waikato.ac.nz/ml/weka/>>. Acesso em: 05 set. 2013.

WORLD AGROFORESTRY CENTRE. **Agroforestry database:** a tree species reference and selection guide. [S.l.: s.n], 2012. Disponível em: <<http://www.worldagroforestrycentre.org/sea/Products/AFDbases/af/asp/SpeciesInfo.asp?SpI=1649#Identity>>. Acesso em: 28 out. 2012.

YOSHITANI JUNIOR, M. **Floresta avaliação biométrica e econômica de plantios de *Pinus taeda* L. Em Santa Catarina.** 2009. 115 p. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal do Paraná, Curitiba, 2009.