

FILIPPE MONTEIRO ALMEIDA

ESTIMAÇÃO DE ALTURA DE ÁRVORES EM TESTES CLONAIIS E DE
PROGÊNIES UTILIZANDO REDES NEURAIIS ARTIFICIAIS.

Monografia apresentada ao
Departamento de Engenharia Florestal
da Universidade Federal de Viçosa,
como parte das exigências do curso de
graduação em Engenharia Florestal.

VIÇOSA
MINAS GERAIS - BRASIL
JUNHO – 2015

FILIPPE MONTEIRO ALMEIDA

ESTIMAÇÃO DE ALTURA DE ÁRVORES EM TESTES CLONAIS E DE
PROGÊNIES UTILIZANDO REDES NEURAIS ARTIFICIAIS.

Monografia apresentada ao
Departamento de Engenharia Florestal da
Universidade Federal de Viçosa, como
parte das exigências do Curso de
Graduação em Engenharia Florestal.

Aprovada: 20 junho de 2015

Helio Garcia Leite
(Orientador)

VIÇOSA
MINAS GERAIS – BRASIL
JUNHO - 2015

AGRADECIMENTOS

A Deus.

Aos meus pais, César e Maria José, e a minha irmã Clarissa, pela dedicação, esforço e compreensão durante toda esta trajetória.

A minha namorada Kamilla, pelo companheirismo, amor e apoio nestes anos.

Ao professor Helio Garcia Leite, pelo conhecimento transmitido, pela oportunidade de realizar este trabalho e por ser um grande exemplo profissional e pessoal.

Ao Departamento de Engenharia Florestal e a Universidade Federal de Viçosa por toda a estrutura disponibilizada.

Aos amigos de Viçosa, em especial aos companheiros de república, Diego Ferreira, Gabriel Junqueira, Diego Vieira e Guilherme Diniz que são a minha segunda família.

A todos que contribuíram direta ou indiretamente, com a realização deste trabalho.

BIOGRAFIA

Nasceu em Visconde do Rio Branco, MG, em 4 de novembro de 1987, filho de César Cardoso Almeida e Maria José Monteiro Almeida. Estudou em Visconde do Rio Branco, MG durante o ensino fundamental, e em Ubá, MG durante o ensino médio.

Ingressou na Universidade Federal de Viçosa, no curso de Engenharia Florestal no ano de 2009, concluiu-o no primeiro semestre letivo de 2015.

SUMÁRIO

AGRADECIMENTOS.....	ii
BIOGRAFIA	iii
SUMÁRIO	iv
RESUMO	v
1. INTRODUÇÃO	7
2. OBJETIVOS	10
3 – MATERIAL E MÉTODOS.....	11
3.1- Descrição dos dados	11
3.2 Redes Neurais Artificiais	14
4 - RESULTADOS	16
5 – DISCUSSÃO E CONCLUSÕES	24
6 - REFERÊNCIAS BIBLIOGRÁFICAS	26

RESUMO

ALMEIDA, Filipe Monteiro. Monografia de graduação. Universidade Federal de Viçosa, junho de 2015. **Estimação de altura de árvores de eucalipto em testes clonais e de progênies utilizando inteligência computacional.**
Orientador: Helio Garcia Leite.

O manejo de florestas equiâneas requer conhecimentos de três elementos essenciais: a classificação de terras, prescrição de tratamentos silviculturais e a predição (prognose) do crescimento e da produção. Este último elemento é, basicamente, a descrição da quantidade de madeira esperada nos cortes parciais e no corte final. Porém, antes de construir curvas de índices de local e de ajustar modelos de crescimento e produção, é necessário totalizar parcelas permanentes e isto requer dados de diâmetro a altura do peito (obtido por medição) e de altura total (ht) de árvores individuais (obtida por medição ou estimação). Há diversas formas para obter a altura, para tal podem ser utilizados instrumentos como os hipsômetros, ou modelos estatísticos, denominados de relações hipsométricas, que são expressões que relacionam a altura com o *dap* (diâmetro à 1,3 m de altura). Expressando corretamente essa relação através dos modelos de regressão, pode-se estimar a altura das árvores de um povoamento medindo apenas o seu *dap*. Uma abordagem para a modelagem da relação hipsométrica, consiste na aplicação de redes neurais artificiais (RNA), que são sistemas computacionais paralelos,

constituídos de unidades de processamento simples, conectados entre si de forma a desempenhar determinada tarefa. A eficiência do emprego de redes neurais artificiais para estimação da altura em inventário florestal já foi confirmada em diversos estudos, porém na área da pesquisa não há registros de utilização desta técnica, sendo comum a medição da altura de todas as árvores nas parcelas experimentais. O objetivo deste trabalho foi testar a aplicabilidade de RNA na estimação da altura em testes clonais e de progênies, considerando *dap*, idade, tratamento e bloco como variáveis de entrada. Foram utilizados 8.329 dados de teste clonal, coletados em seis idades, divididos em 6 blocos e 5 repetições, e 36.793 dados para o teste de progênie, coletados em 5 idades e divididos em 10 blocos e 5 repetições. Foi treinada uma rede para cada tipo de teste, o banco de dados foi separado em dois conjuntos, o primeiro formado pelas árvores 1 e 2 de cada repetição, destinado ao treinamento das redes, e o segundo grupo, formado pelas árvores 3, 4 e 5, com a finalidade de aplicar e validar as redes treinadas. Os resultados demonstram que as redes podem ser usadas na estimação da altura das árvores submetidas aos mais diversos tratamentos das parcelas experimentais sem que haja perda da exatidão e precisão das estimativas.

1. INTRODUÇÃO

A altura é uma importante característica da árvore, obtida por medição ou estimação que juntamente com o diâmetro medido a 1,3 m de altura (*dap*), serve para computar o volume de árvores individuais, a produção por unidade de área e, em conexão com a idade, determinar a qualidade de um local para a produção de madeira (SOARES et al., 2011).

Enquanto o *dap* é facilmente medido em árvores em pé, a altura muitas vezes é estimada empregando equações ajustadas a dados de algumas medições de *dap* e altura total (*Ht*) feitas em algumas árvores. Isto é comum no caso da condução de inventários florestais, onde são utilizados modelos hipsométricos. O emprego desses modelos resulta em redução do custo do inventário com relação à medida de 100% das alturas, porém, pode resultar em baixa exatidão dependendo da eficiência da amostragem e da qualidade do ajustamento dos modelos empregados (SOARES et al., 2011). No inventário são utilizados desde modelos simples, $H = f(dap)$, até modelos em nível de povoamento, $H = f(dap, Idade, Capacidade\ Produtiva)$ (CAMPOS E LEITE, 2013). Já em pesquisa (experimentos), é usual medir o *dap* e a altura de todas as árvores de cada tratamento e repetição. Em certos tipos de pesquisa isto resulta em enormes quantidades de alturas medidas. Exemplos são os testes clonais e os de progênies.

Uma desvantagem da utilização da relação hipsométrica é o fato dela ser afetada por fatores ambientais e características do povoamento, como:

regime de corte, capacidade produtiva, idade, genótipo, tipo de solo, radiação solar, relevo. Isto implica na necessidade de uma prévia estratificação em face dessas características e variáveis, o que nem sempre é possível ou factível. Em certos casos os modelos $H = f(dap)$ são ajustados em nível de parcela, sendo necessário medir ao menos cerca de 10 alturas em cada parcela, o que pode ser inviável em termos de custo, tornando-se praticamente inviável em alguns locais.

De acordo com BINOTI (2013), uma abordagem para a modelagem da relação hipsométrica, consiste na aplicação de redes neurais artificiais (RNAs). As RNAs são sistemas computacionais paralelos, constituídos de unidades de processamento simples, conectados entre si de forma a desempenhar determinada tarefa. São constituídos por simplificações dos neurônios biológicos que processam a informação através de pesos sinápticos, fornecendo uma ou mais saídas. Os neurônios estão dispostos em uma ou mais camadas paralelas e são interligados por um grande número de conexões, formando a rede. Tais conexões são associadas a pesos que armazenam o conhecimento representado pela rede e ponderam a entrada recebida por cada neurônio, (Braga et al., 2000),

Utilizando de um conjunto de exemplos apresentados, as RNAs são capazes de assimilar as características de entrada e generalizar o aprendizado quando novos dados forem apresentados (BINOTI, 2012).

As redes neurais tem apresentado desempenho superior aos modelos de regressão devido a diversos fatores, como: estrutura distribuída em camadas; habilidade de aprender e generalizar, que as tornam capazes de resolverem problemas complexos; tolerância à falhas e ruídos; podem modelar diversas variáveis e suas relações não lineares; (BINOTI, 2013).

A eficiência do emprego de RNA no setor florestal já foi confirmado em diversos estudos, como no mapeamento da biomassa de florestas naturais (SCHOENINGER, et al 2009), na classificação de imagens de satélite (ANDRADE, 2003), estimação do volume de cerne em árvores de Teca (SOUZA, 2014), na redução dos custos do inventário (BINOTI 2010), na estimação de volume e afilamento de árvores de eucalipto (SILVA, 2013), estimação da eficiência nutricional das folhas de eucalipto (LAFETÁ, 2012) entre outras aplicações. Por outro lado, na área de pesquisa ainda não há registros de uso desta técnica, sendo comum a medição da altura de todas as árvores nas parcelas experimentais. Isto resulta em quantidade excessiva de medições e custo elevado.

A estimação da altura em inventários florestais com emprego de RNAs tem resultado em redução no custo desta atividade. Reduções de 10 a 25% no custo marginal do inventário tem sido observado em algumas empresas. Essas

reduções têm sido mencionadas por engenheiro florestais e administradores em reuniões técnicas (Helio Garcia Leite, Informação pessoal).

2. OBJETIVOS

O objetivo deste estudo foi avaliar a eficiência de dois modelos de rede neural artificial para a estimação da altura de árvores em testes clonais e em testes de progênies. Também foi objetivo avaliar o ganho de tempo e custo ao empregar a técnica, em relação a medição de 100% das alturas nas parcelas experimentais.

3 – MATERIAL E MÉTODOS

3.1- Descrição dos dados

Os dados utilizados neste estudo foram obtidos de testes clonais e testes de progênies conduzidos por uma empresa florestal, com eucalipto, envolvendo uma rotação de seis anos e 5 anos respectivamente. Foi medida a altura de 8.329 árvores em testes clonais e 36.794 em testes de progênies, em idades de 2 a 6 anos.

No teste clonal foram avaliados 105 clones, com 5 árvores por parcela, em 6 blocos, em 5 ocasiões (idade de 2 a 6 anos) e nos testes de progênies foram avaliadas 222 famílias, com 10 árvores por parcela, em 10 blocos e 4 ocasiões (idades de 2 a 5 anos). As estatísticas descritivas são apresentadas nas tabelas 1 e 2.

TABELA 1 – Diâmetro e altura de árvores em testes clonais com eucalipto (105 clones), em diferentes idades.

Bloco	Idade	Diâmetro (cm)			Altura (m)		
		Mínimo	Médio	Máximo	Mínimo	Médio	Máximo
1	2	4,0	8,6	11,4	6,5	11,3	14,0
	3	8,0	11,9	15,7	14,5	18,6	20,5
	4	4,2	12,5	17,0	4,0	19,5	32,0
	5	8,0	13,7	19,0	16,0	23,0	27,0
	6	4,0	14,4	21,1	8,0	25,0	31,0
2	2	4,0	8,6	11,7	5,0	11,2	13,0
	4	4,6	12,6	18,7	7,0	18,7	24,0
	5	9,0	14,7	18,0	18,5	23,8	27,0
3	6	4,6	14,6	23,1	9,0	24,0	31,0
	2	4,0	8,5	12,1	7,0	10,9	13,0
	3	10,2	12,3	15,0	18,0	18,7	20,0
	4	4,6	12,4	19,2	8,5	19,3	23,0
4	5	11,2	14,7	18,5	21,0	23,9	27,0
	6	4,6	14,3	24,1	10,0	23,9	30,0
	2	4,0	8,6	12,2	7,0	11,1	13,0
	3	11,5	13,2	16,3	17,0	19,0	20,0
5	4	4,7	12,5	18,9	7,0	19,4	23,0
	5	9,2	16,5	24,0	16,0	24,0	27,5
	6	5,2	14,5	24,4	8,5	22,6	30,5
	2	4,0	8,4	11,3	6,0	10,8	13,0
6	4	4,5	12,4	17,5	9,0	19,1	23,0
	5	13,9	16,4	20,4	23,0	24,3	26,0
	6	4,6	14,4	22,8	10,0	24,3	29,0
6	2	4,0	8,7	11,9	7,0	11,3	13,5
	4	4,9	12,8	19,8	8,5	19,0	23,0
	5	8,4	14,8	17,7	17,0	24,0	26,0
	6	5,3	15,0	25,5	8,5	24,0	30,0

TABELA 2 – Diâmetro e altura de árvores em testes de progênies de eucalipto (222 famílias), em diferentes idades.

Bloco	Idade	Diâmetro (cm)			Altura (m)		
		Mínimo	Médio	Máximo	Mínimo	Médio	Máximo
1	2	4,0	9,1	14,4	4,5	11,3	14,5
	3	4,0	12,4	19,0	6,0	18,1	22,0
	4	4,1	13,7	22,5	6,5	21,6	27,5
	5	4,0	14,9	25,6	4,5	23,4	31,0
2	2	4,0	8,8	13,2	3,5	11,0	14,5
	3	4,0	11,9	18,6	5,0	17,2	24,0
	4	4,0	13,2	21,8	5,5	20,1	28,0
3	5	4,1	14,2	24,5	7,5	23,2	32,0
	2	4,0	9,0	14,6	2,5	11,4	16,0
	3	4,0	12,1	18,9	5,5	17,7	23,0
4	4	4,0	13,3	21,8	6,0	21,2	28,0
	5	4,1	14,5	25,0	6,5	23,0	31,5
	2	4,0	9,1	13,3	2,5	11,2	14,0
5	3	4,0	12,3	18,8	5,0	18,1	23,5
	4	4,0	13,5	22,3	3,5	20,7	27,0
	5	4,0	14,4	24,8	3,0	23,0	31,0
6	2	4,0	9,3	13,8	4,0	11,3	14,0
	3	4,0	12,3	19,0	3,0	17,3	23,5
	4	4,0	13,7	22,8	4,0	22,0	29,5
7	5	4,1	14,8	25,4	4,5	24,2	31,5
	2	4,0	9,2	14,1	2,0	11,0	14,5
	3	4,0	12,5	19,5	5,0	17,6	23,0
8	4	4,1	13,5	22,4	5,5	22,0	29,0
	5	4,1	14,5	26,0	6,0	23,5	31,5
	2	4,0	9,1	14,5	4,5	11,6	15,0
9	3	4,0	12,0	19,7	5,0	17,1	23,0
	4	4,0	13,0	22,0	4,5	21,8	31,5
	5	4,1	14,1	25,5	7,5	23,5	31,0
10	2	4,0	9,2	14,3	4,0	11,5	16,0
	3	4,0	12,0	18,8	5,0	16,8	23,5
	4	4,1	13,0	22,1	5,5	21,1	27,5
10	5	4,1	14,0	26,8	6,5	22,3	32,0
	2	4,0	9,2	14,1	4,5	11,9	17,0
	3	4,0	11,9	24,0	5,0	17,3	28,0
10	4	4,0	13,0	24,5	7,5	21,6	29,0
	5	4,2	14,2	27,7	7,0	24,5	32,0
	2	4,0	9,4	14,7	4,0	11,5	15,5
10	3	4,0	12,3	20,1	4,5	18,2	24,0
	4	4,0	13,4	23,6	5,0	21,5	28,0
	5	4,0	14,3	26,6	7,0	22,9	33,0

O banco de dados do teste clonal foi dividido em dois conjuntos de dados, sendo um para treinamento e outro para a validação das redes neurais. Para o treino foram separadas as árvores 1 e 2 de cada repetição de cada clone, ficando as demais (3, 4 e 5) para validação. No teste de progênie o treino das RNAs foi feito também com dados das duas primeiras árvores de cada uma das dez repetições, ficando as demais (8 árvores) para validação da RNA. Desta forma, a redução simulada na quantidade de alturas medidas é de 60% no teste clonal (2 árvores em 5) e de 80% no teste de progênie (2 árvores em 10).

3.2 Redes Neurais Artificiais

As redes treinadas foram do tipo multilayer *perceptrons* (MLP), com uma camada oculta. As variáveis da camada de entrada para rede foram: idade, genótipo, bloco e *dap*. O algoritmo de treinamento das redes foi do tipo *Resilient Propagation* (RPROP+), que realiza uma adaptação das atualizações de peso de acordo com o comportamento da função de erro (RIEDMILLER E BRAUN, 1993). O critério de parada do treinamento foi o parâmetro: número de ciclos igual a 3000 ou erro médio igual a 0,0001. Foi feita a normalização dos dados numéricos para 0 a 1, isto foi feito para que valores discrepantes não influenciassem nas estimativas, a função de ativação foi do tipo sigmoideal e a variável de saída foi a altura total.

O programa utilizado para configuração, treinamento, validação e aplicação das redes neurais foi o NeuroForest 3.3, disponibilizado gratuitamente no site <http://neuroforest.ucoz.com/>.

Foram treinadas, uma rede para teste clonal e outra para teste de progênie. As variáveis da camada entrada das redes foram: genótipo (105 clones, ou 222 famílias), bloco, idade e diâmetro a 1,3 metros de altura (*dap*).

As melhores redes foram selecionadas com base nas estatísticas de validação, analisando os seguintes critérios: coeficiente de correlação entre as alturas observadas e estimadas e raiz quadrada do erro quadrático médio (RQEM%). Além disso, foi feita a análise do histograma de frequência dos erros percentuais, com base na dispersão dos erros percentuais (resíduos) em relação aos valores observados, sendo:

$$resíduo = \frac{(\hat{y} - y)}{y} \times 100$$

Em que:

y = Altura total observada da árvore i ;

\hat{y} = Altura total estimada para árvore i ;

A correlação entre as alturas observadas e estimadas ($r_{y\hat{y}}$) indica a força e a direção da relação entre as duas variáveis. Quanto mais próxima de 1, maior a correlação entre as variáveis. Embora não seja possível concluir sobre a qualidade de uma rede apenas com esta informação, ela é útil para saber o grau de associação entre os valores estimados e observados. (BINOTI, 2010).

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

Em que:

s^2 = variância;

cov = covariância;

A raiz quadrada do erro quadrático médio (RQEM%) avalia a diferença quadrática média entre os valores observados e os valores estimados. Quanto menor o RQEM, melhor a precisão da estimativa (BINOTI, 2010).

$$RQEM (\%) = \frac{100}{\bar{y}} \times \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y)^2}{n}}$$

em que:

y_i = Altura total observada da árvore i ;

\hat{y}_i = Altura total estimada para árvore i ;

\bar{y} = Altura média observada;

n = número total de observações;

4 - RESULTADOS

As estatísticas da raiz quadrada do erro quadrático médio (RQEM%) e da correlação entre as alturas observadas e estimadas ($r_{y\hat{y}}$) são apresentadas na tabela 3.

TABELA 3 - Estatísticas das redes treinadas e aplicadas aos dados de teste clonal e do teste de progênes.

Tipo	Treinamento		Validação	
	RQEM (%)	$r_{y\hat{y}}$	RQEM (%)	$r_{y\hat{y}}$
Teste Clonal	3,88	0,9927	6,09	0,9822
	3.286 dados		5.043 dados	
Teste de progênes	6,98	0,9778	8,47	0,9674
	7.359 dados		29.435 dados	

RQEM(%) = Raiz quadrada do erro quadrático médio; $r_{y\hat{y}}$ = correlação entre alturas observadas e estimadas.

Os valores de $r_{y\hat{y}}$ próximo de 1 indicam alta correlação entre as alturas observadas e estimadas. O baixo valor do RQEM(%) mostra uma boa exatidão das estimativas de altura da RNA. Nas figuras 1 a 12 são apresentados gráficos de histograma de correlação dos resíduos e da relação entre alturas observadas e estimadas. Esses gráficos servem para verificar se há alguma tendenciosidade nas estimativas. No histograma é possível verificar se os resíduos têm normalidade.

Treinamento Teste Clonal




FIGURA 1 – Percentagem de casos (árvores) eixo y, por classe de erro percentual (eixo x), definido por $100(\hat{H}-H)/H$, sendo H e \hat{H} alturas observadas e estimadas, utilizando os dados de treinamento do teste clonal.

Validação Teste Clonal




FIGURA 2 - Percentagem de casos (árvores) eixo y, por classe de erro percentual (eixo x), definido por $100(\hat{H}-H)/H$, sendo H e \hat{H} alturas observadas e estimadas, utilizando os dados de validação do teste clonal.

Treinamento Teste Clonal




FIGURA 3 - Distribuição dos erros percentuais $100(\hat{H}-H)/H$ (eixo y) em relação às alturas observadas (eixo x) para o treinamento no teste clonal.

Validação Teste Clonal




FIGURA 4 - Distribuição dos erros percentuais $100(\hat{H}-H)/H$ (eixo y) em relação às alturas observadas (eixo x) para a validação no teste clonal.

Treinoamento Teste Clonal




FIGURA 5 – Alturas estimadas pela rede neural (eixo y) em relação às alturas correspondentes observadas no banco de dados (eixo x) de treinamento do teste clonal.

Validação Teste Clonal




FIGURA 6 - Alturas estimadas pela rede neural (eixo y) em relação às alturas correspondentes observadas no banco de dados (eixo x) de validação do teste clonal.

Treinoamento Teste de Progênies




FIGURA 7 - Percentagem de casos (árvores) eixo y, por classe de erro percentual (eixo x), definido por $100(\hat{H}-H)/H$, sendo H e \hat{H} alturas observadas e estimadas, utilizando os dados de treinoamento do teste de progênies.

Validação Teste de Progênies




FIGURA 8 - Percentagem de casos (árvores) eixo y, por classe de erro percentual (eixo x), definido por $100(\hat{H}-H)/H$, sendo H e \hat{H} alturas observadas e estimadas, utilizando os dados de validação do teste de progênies.

Treinamento Teste de Progenies




FIGURA 9 - Distribuição dos erros percentuais $100(\hat{H}-H)/H$ (eixo y) em relação as alturas observadas (eixo x) para o treinamento em teste de progênies.

Validação Teste de Progenies




FIGURA 10 - Distribuição dos erros percentuais $100(\hat{H}-H)/H$ (eixo y) em relação as alturas observadas (eixo x) para a validação no teste de progênies.

Treino Teste de Progênes




FIGURA 11 - Alturas estimadas pela rede neural (eixo y) em relação às alturas correspondentes observadas no banco de dados (eixo x) de treinamento do teste de progênes.

Validação Teste de Progênes




FIGURA 12 - Distribuição das alturas observadas (eixo y) em função das alturas estimadas pela rede (eixo x) para a validação em teste de progênes.

Na tabela 4 são apresentadas estatísticas descritivas para a altura no teste clonal, considerando duas situações: utilizando sempre as cinco alturas observadas para cada genótipo em cada idade e outra utilizando as duas alturas observadas (arquivo de treinamento) juntamente com as três alturas estimadas na validação, para cada genótipo e idade. Na tabela 5 constam as estatísticas para o caso do teste de progênes, seguindo a mesma metodologia, ou seja, considerando todas as alturas observadas e considerando juntamente as alturas estimadas obtidas no treino e na validação.

TABELA 4 – Estatísticas descritivas para as duas situações em teste clonal.

<i>Estatísticas</i>	<i>Cinco alturas observadas</i>	<i>Dois alturas observadas e três estimadas pela RNA</i>
Média	18,0	18,0
Erro padrão	0,1	0,1
Mediana	19,0	19,0
Modo	11,5	11,5
Desvio padrão	5,8	5,8
Variância da amostra	34,0	33,8
Curtose	-1,2	-1,3
Assimetria	0,0	0,0
Intervalo	27,0	24,0
Mínimo	4,0	6,5
Máximo	31,0	30,5
Soma	149911,5	150211,5
Contagem	8329,0	8329,0
Nível de confiança (95,0%)	0,13	0,12

TABELA 5 - Estatísticas descritivas para as duas situações em teste de progênes.

<i>Estatísticas</i>	<i>Dez alturas observadas</i>	<i>Dois alturas observadas e oito estimadas pela RNA</i>
Média	18,4	18,4
Erro padrão	0,0	0,0
Mediana	19,0	18,9
Modo	12,0	12,0
Desvio padrão	6,1	6,1
Variância da amostra	37,7	36,9
Curtose	-1,1	-1,2
Assimetria	0,0	0,0
Intervalo	31,0	29,5
Mínimo	2,0	2,5
Máximo	33,0	32,0
Soma	676726,9	675428,0
Contagem	36793,0	36793,0
Nível de confiança (95,0%)	0,06	0,06

5 – DISCUSSÃO E CONCLUSÕES

Analisando os resultados apresentados nas figuras 1 a 12, verifica-se que os erros das estimativas das redes neurais variaram em aproximadamente $\pm 10\%$ na maioria dos casos. Os altos valores de correlação entre os dados e os baixos valores das raízes dos erros quadráticos médios (RQEM%) (Tabela 3), mostram que as redes estimam com exatidão as alturas nas parcelas experimentais. Esta margem de erro é satisfatória, principalmente para idade acima de 3 anos ou para as árvores maiores. Isto porque nas medidas da altura com a árvore em pé é aceito uma taxa de erro de 5% ou mais. Além disso, quando a altura é estimada por regressão a margem de erro é geralmente bem maior (CAMPOS e LEITE, 2013).

Como demonstrado nos histogramas das figuras 3 e 4, e das figuras 9 e 10, os erros são aleatoriamente positivos ou negativos, com sua média tendendo para zero. Na prática isto significa que ao efetuar a análise estatística do teste clonal e de progênies, sendo as inferências feitas com base nas médias, não deverá resultar em diferença significativa nos ranqueamentos feitos com as alturas observadas e com aquelas estimadas pela rede neural. De certa forma isto pode ser entendido intuitivamente nas tabelas 4 e 5.

Uma vez confirmada a eficiência das redes neurais artificiais para a estimação da altura em parcelas experimentais, é possível analisar o ganho de tempo ao se medir a altura de apenas duas árvores de cada parcela, de cada tratamento, ou seja, 40% dos dados (3.286 árvores) no teste clonal, e em

progênies, a medida desta duas árvores, representa 20% dos dados (7.359 árvores). Na prática, isto significa que no teste clonal 5.033 árvores (60% do total) e no teste progênies 29.435 (80% do total), tiveram suas alturas estimadas.

Em média um mensurador gasta um minuto para tomar a altura de uma árvore, sem contar o deslocamento, isso significa que ele deixou de gastar 5.033 minutos ou 84 horas ou 10,4 dias de trabalho (8 horas/dia) no tempo de medição das parcelas do teste clonal. Em progênie a economia de tempo é ainda maior, já que seriam economizados 29.435 minutos ou 490,6 horas ou 61,4 dias de trabalho (8 horas/dia). Esta economia de tempo e trabalho (tabela 6) pode resultar em redução nos custos da pesquisa, além de permitir a obtenção dos resultados mais rapidamente, em certas pesquisas a antecipação de resultados pode ser muito importante, e ao medir um menor número de alturas é possível reduzir o tempo total de coleta e análise dos dados.

TABELA 6 – Tempo gasto para medir as alturas do banco de dados; dias economizados com base numa jornada de trabalho de 8 horas por dia.

Experimento	Tempo gasto (horas)			Dias de trabalho economizados (8h/dia)
	Treino	Validação	Total	
Teste Clonal	54,8 3.286 árvores	84 5.033 árvores	138,7	10,5
Teste de Progênies	122,7 7.359 árvores	490,6 29.435 árvores	613,3	61,4

Embora os resultados tenham sido altamente satisfatórios e terem permitidos concluir sobre a eficiência da RNA, outras abordagens de uso podem ser testadas, como por exemplo medir as alturas no anos pares das parcelas experimentais e estimar nos anos ímpares, ou ainda medir as alturas de alguns blocos e estimar a de outros, entre inúmeras metodologias à serem testadas.

Com base nos resultados deste estudo é possível concluir que redes neurais artificiais são eficientes para estimar a altura em testes clonais e de progênie, e com isto, é possível reduzir o tempo de medição das parcelas experimentais e conseqüentemente o custo da pesquisa, sem perda de exatidão e sem prejuízo para a análise dos dados do experimento.

6 - REFERÊNCIAS BIBLIOGRÁFICAS

ANDRADE, F. A. Integração de variáveis espectrais e forma na classificação de imagens de alta resolução utilizando redes neurais artificiais. **Boletim de Ciências Geodésicas**, v. 9, n. 1, 2003.

BINOTI, M. L. M. S. Aplicação de redes neurais artificiais para estimação de altura em povoamentos equiâneos de eucalipto. **Revista Árvore**, Viçosa -MG, v.37, n.4, p.639-645, 2013.

BINOTI, M. L. M. S.; BINOTI D. H. B; LEITE, H. G.; GARCIA, S. L. R.; FERREIRA, M. Z; RODE, R.; ARAUJO, A. A. L. Redes neurais artificiais para estimação do volume de árvores. **Revista Árvore**, v. 38, n. 2, p. 283-288, 2014.

BINOTI, M. L. M. S. **Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto**. 2010. 54f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, MG, 2010.

BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais: teorias e aplicações**. Rio de Janeiro: LTC editora, 2000. 262p.

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

FERREIRA, M. Melhoramento e a silvicultura intensiva clonal. **Scientia Florestalis**, n. 45, p. 22-30, 1992.

LAFETÁ, B. O. **Eficiência nutricional, área foliar e produtividade de plantações de eucalipto em diferentes espaçamentos estimados com redes neurais artificiais.** 76 p. 2012. Dissertação (Pós-Graduação em ciências florestais) – Universidade Federal dos Vales do Jequitinhonha e Mucuri, Diamantina.

LEITE, H. G.; BINOTI, D. H. B; BINOTI, M. L. M. S. **NeuroForest** versão 3.3 <<http://neuroforest.ucoz.com/>>

RIEDMILLER, M. AND BRAUN, H. A direct adaptive method for faster backpropation learning: the RPROP algorithm. **Proceedings of IEEE International Conference on Neural Networks** (San Francisco), Vol. 1, pp. 586-591. 1993.

SCHOENINGER, E. R; KOEHLER, H. S.; WATZLAWICK, L. F.; FILHO, P. C. O.; .Uso de redes neurais artificiais como uma alternativa para mapeamento de biomassa e carbono orgânico no componente arbóreo de florestas naturais. **AMBIÊNCIA**, v. 4, n. 3, p. 529-549, 2009.

SILVA, P. V. **Estimação do volume e afilamento do fuste de árvores de eucalipto utilizando redes neurais artificiais.** 27 p. 2013. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Florestal) – Universidade Federal de Viçosa, Viçosa.

SOARES, C. P. B.; NETO, F. P.; SOUZA, A. L.; **Dendrometria e inventário florestal. 2.ed.** Viçosa: Editora UFV, 2011. 272p.

SOUZA, R. B. **Estimação do volume do cerne de Tectona grandis Lf utilizando Redes Neurais Artificiais (RNA) e Taper.** 25 p. 2014. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Florestal) – Universidade Federal de Viçosa, Viçosa.