

## Configuração de redes neurais artificiais para estimação da altura total de árvores de eucalipto

Emília dos Reis Martins<sup>1</sup>, Mayra Luiza Marques da Silva Binoti<sup>2</sup>, Hélio Garcia Leite<sup>3</sup>, Daniel Henrique Breda Binoti<sup>4</sup>, Gleyce Campos Dutra<sup>5</sup>

<sup>1</sup> Universidade Federal dos Vales do Jequitinhonha e Mucuri, Programa de Pós-Graduação em Ciência Florestal, Rodovia MGT 367, Km 583, nº 5000, Alto da Jacuba, CEP 39100-000, Diamantina-MG, Brasil. E-mail: emilia.rmartins@yahoo.com.br

<sup>2</sup> Universidade Federal do Espírito Santo, Departamento de Ciências Florestais e da Madeira, Av. Governador Lindemberg, 316, Centro, CEP 29550-000, Jerônimo Monteiro-ES, Brasil. E-mail: mayrabinoti@gmail.com; danielhbbinoti@gmail.com

<sup>3</sup> Universidade Federal de Viçosa, Departamento de Engenharia Florestal, Avenida Purdue, s/n, Edifício Reinaldo de Jesus Araújo, Campus Universitário, CEP 36570-900, Viçosa-MG, Brasil. E-mail: hgleite@gmail.com

<sup>4</sup> Bolsista de Pós-Doutorado FAPES/UFES – Departamento de Ciências Florestais e da Madeira, Av. Governador Lindemberg, 316, Centro, CEP 29550-000, Jerônimo MonteiroES, Brasil. E-mail: danielhbbinoti@gmail.com

<sup>5</sup> Universidade Federal dos Vales do Jequitinhonha e Mucuri, Departamento de Engenharia Florestal, Rodovia MGT 367, Km 583, nº 5000, Alto da Jacuba, CEP 39100-000, Diamantina-MG, Brasil. E-mail: gleycedutra@yahoo.com.br

### RESUMO

O objetivo do presente trabalho foi definir configurações adequadas de Redes Neurais Artificiais (RNA) para a obtenção da altura total de árvores de eucalipto. Os dados utilizados foram provenientes de inventários florestais contínuos em povoamentos com idades entre 21 a 137 meses, localizados no sul da Bahia. As configurações de RNA testadas variaram em relação ao número de neurônios na camada oculta, função de ativação, número de ciclos e algoritmos de aprendizagem com seus parâmetros. Os testes foram realizados no sistema Neuroforest e as estimativas foram avaliadas pelo coeficiente de correlação, raiz quadrada do erro quadrático médio (RMSE%) e análise gráfica de resíduos. A estimação da altura de árvores pode ser feita por meio de diversas configurações de RNA, utilizando os algoritmos de aprendizagem Resilient Propagation, Quick Propagation e Scaled Conjugate Gradient, com o número de neurônios ocultos variando entre 03 e 08 para o algoritmo Quick Propagation e 13 e 20 para o algoritmo Scaled Conjugate Gradient. As funções de ativação tangente hiperbólica, sigmóide, log e seno são apropriadas para as camadas ocultas e de saída, e as funções linear e identidade se mostraram apropriadas apenas para a camada de saída. Dois mil ciclos são suficientes para o treinamento das RNA.

**Palavras-chave:** inteligência artificial, neuroforest, relações hipsométricas

## *Configuration of artificial neural networks for estimation of total height of eucalyptus trees*

### ABSTRACT

The aim of this study was to define appropriate configurations of Artificial Neural Networks (ANN) to obtain the total height of eucalyptus trees. The data used came from continuous forest inventories in stands aged 21-137 months located in southern Bahia. The ANN configurations tested varied according to the number of neurons in the hidden layer, activation function, number of cycles and learning algorithms with their parameters. The tests were performed in Neuroforest system and the estimates were evaluated using the correlation coefficient, the root mean square error (RMSE%), and graphical analysis of residues. The estimation of the height of trees may be made by various ANN configurations using the learning algorithms Resilient Propagation, Quick Propagation and Scaled Conjugate Gradient, with number of hidden neurons varying between 03 and 08 for the Quick Propagation algorithm and 13 and 20 to Scaled Conjugate Gradient algorithm. The activation functions hyperbolic tangent, sigmoid, log and sine are suitable for the hidden and output layers, and functions linear and identity proved suitable only for the output layer. Two thousand cycles are sufficient for the training of ANN.

**Key words:** artificial intelligence, neuroforest, hypsometric relations

## Introdução

A altura total é uma variável essencial para os levantamentos florestais e serve como entrada para equações de volume, altura dominante e de *taper* em povoamentos equiâneos. Assim, quanto mais precisas forem tais estimativas, menor será o erro acrescido na determinação da produção florestal. Entretanto, com o objetivo de reduzir tempo e custos são mensuradas apenas a altura de algumas árvores nas parcelas de inventário florestal. As demais alturas são obtidas através de modelos de relação hipsométrica ou Redes Neurais Artificiais (RNA).

As relações hipsométricas referem-se à relação da altura das árvores com o dap (diâmetro a 1,30 m de altura). O dap pode ser considerado uma variável de fácil obtenção, porém, o mesmo não ocorre com a altura, pois esta variável é obtida por meio de uma operação onerosa e sujeita a erros de medição (Husch et al., 2003).

A predição da altura das árvores com relações hipsométricas geralmente se dá com o emprego de modelos de regressão linear ou não linear. O ajuste dos modelos lineares é geralmente mais simples. Entretanto, Batista et al. (2001), ponderam que modelos não lineares apresentam superioridade em termos de estabilidade devido a fundamentação biológica dos mesmos, sendo também menos susceptíveis a presença de viés.

Vários fatores podem afetar as relações hipsométricas, tais como idade, capacidade produtiva, densidade do povoamento (Curtis, 1967; Fang & Bailey, 1998; Silva et al., 2007; Campos & Leite, 2013). Além disso, muitas vezes, a relação hipsométrica não é uma relação dendrométrica muito forte, devido a alta variabilidade das alturas para uma mesma classe de diâmetro. Nesses casos, a inclusão de variáveis qualitativas nos modelos hipsométricos é de grande importância para a obtenção de estimativas que se aproximem ao máximo da realidade. Entretanto, adicionar variáveis categóricas em modelos de regressão nem sempre resulta em ganho de exatidão, uma vez que a inclusão dessas requer representatividade para todos os níveis das variáveis qualitativas na amostra, o que nem sempre é possível.

O emprego de RNA é uma alternativa interessante para estimar a altura das árvores em povoamentos florestais. As RNA são assim denominadas porque o seu funcionamento se assemelha ao do cérebro humano em alguns aspectos, e podem ser definidas como modelos matemáticos constituídos de unidades de processamento simples denominadas neurônios artificiais, que estão dispostas em camadas. Estas unidades estão associadas a forças de conexão, conhecidas como pesos sinápticos, que armazenam o conhecimento adquirido e ponderam a entrada recebida por cada neurônio. O conhecimento adquirido é disponibilizado para aplicação do mesmo tipo de problema em outros dados, sendo este processo denominado de generalização (Haykin, 2001; Braga et al., 2007).

As RNA detectam relações não lineares entre a variável de saída e as variáveis de entrada durante o processo de aprendizagem, permitindo ainda, a inclusão de variáveis qualitativas com eficiência, sendo esta uma vantagem em relação aos clássicos modelos de regressão.

Vários trabalhos demonstram os excelentes resultados alcançados através da utilização de RNA em estimativas florestais, tais como estimativas de volume (Gorgens et al., 2009; Diamantopoulou & Milios, 2010; Özçelik et al., 2010; Rodrigues et al., 2010; Binoti et al., 2014), altura total (Diamantopoulou, 2012; Binoti et al., 2013a; Binoti et al., 2013b; Özçelik et al., 2013), afilamento do fuste (Leite et al., 2010; Soares et al., 2011), prognose da produção (Binoti, 2010; Martins et al., 2015).

Para predição da altura total, Özçelik et al. (2013) testaram a utilização de RNA em árvores de zimbro da Criméia e comprovaram o potencial da abordagem por RNA. Em árvores de eucalipto, Binoti et al. (2013b) utilizaram RNA e obtiveram excelentes resultados com vantagens operacionais e redução de custos nos inventários florestais.

Apesar dos excelentes resultados obtidos com o emprego de RNA, o desempenho das redes depende da escolha adequada do número de camadas e de neurônios, da função de ativação, do algoritmo de aprendizagem e de seus parâmetros. Esta escolha tem efeito direto na qualidade do processo de aprendizagem e, conseqüentemente, na resposta gerada pela rede para uma determinada tarefa. Deste modo, a definição da melhor configuração de uma rede para um determinado problema é um processo de tentativa e erro, sendo necessário alterar os parâmetros quando a rede não apresenta um bom desempenho (Artero, 2009). Assim, a escolha de uma RNA apropriada pode demandar muito tempo, devido ao número elevado de combinações possíveis dos parâmetros da rede (Braga et al., 2007; Aertsen et al., 2010; Özçelik et al., 2013).

Tendo em vista a importância da estimação da altura das árvores para o planejamento florestal, o potencial das RNA para esta aplicação e a dificuldade de definir atributos adequados para a rede, conforme o problema, o objetivo do presente trabalho foi definir configurações adequadas de RNA para a obtenção da altura total de árvores de povoamentos de eucalipto.

## Material e Métodos

### Dados

Os dados utilizados neste estudo foram provenientes de inventários florestais contínuos realizados em povoamentos de clones de eucalipto localizados no sul da Bahia, em uma área de aproximadamente 2000 ha. Foram utilizados 27.174 pares de dados para o processamento das RNA.

Para a inclusão dos dados na modelagem das RNA houve a diferenciação entre variáveis quantitativas e categóricas. As variáveis quantitativas foram: diâmetro a 1,30 m de altura (dap), altura dominante ( $h_{100}$ ), e idade (I). As variáveis categóricas foram: projeto, clone, tipo de solo, espaçamento e relevo. O número de classes das variáveis categóricas foram 4, 6, 15, 6 e 3, respectivamente. A altura total (h) corresponde a variável de saída utilizada para o treinamento das RNA. As principais características descritivas das variáveis quantitativas estão apresentadas na Tabela 1.

Os dados foram divididos aleatoriamente em dois conjuntos, sendo um para o treinamento das redes (aproximadamente

**Tabela 1.** Análise descritiva das variáveis quantitativas

	Mínimo	Máximo	Média	Desvio-padrão
Idade (meses)	21	137	72	±31
dap (cm)	5,1	33,4	15,5	±4,2
Altura dominante (m)	7,6	39,0	26,2	±6,5
Altura total (m)	6,5	38,9	23,6	±5,9

60% dos dados) e um para a extrapolação dos dados a partir das redes treinadas (generalização) (aproximadamente 40%).

### Redes neurais artificiais

A metodologia empregada neste trabalho para a definição de configurações de RNA apropriadas para estimação da altura de árvores é similar a metodologia utilizada no trabalho de Martins et al. (2016).

O número total de neurônios na camada de entrada foi igual a 38, sendo um neurônio para cada variável quantitativa e um para cada classe de variável categórica. As redes foram constituídas com uma única camada oculta contendo até 20 neurônios ocultos. As camadas de saída das redes foram compostas de apenas um neurônio, pois a saída desejada corresponde apenas a uma variável (altura total).

As funções de ativação utilizadas nas camadas ocultas e de saída foram: linear, log, tangente hiperbólica, seno, sigmóide e identidade. Para o treinamento das redes utilizou-se os seguintes algoritmos: Error Backpropagation, Resilient Propagation, Manhattan Update Rule, Scaled Conjugate Gradient, Levenberg Marquardt, Quick Propagation, Simulated Annealing e Algoritmos Genéticos.

As taxas de aprendizagem para o algoritmo Error Backpropagation variaram entre 0,001 e 1, sendo: 0,001; 0,003; 0,005; 0,007; 0,009; 0,01; 0,03; 0,05; 0,07; 0,09; 0,1; 0,3; 0,5; 0,7; 0,9; 1; e os valores do parâmetro momentum foram: 0; 0,0005; 0,001; 0,05; 0,01; 0,05; 0,1; 0,5; 1. O algoritmo Manhattan Update Rule necessita, por definição, de pequenas taxas de aprendizagem, portanto restringiu-se a apenas uma: 0,0001. O algoritmo Quick Propagation é sensível a altas taxas de aprendizagem, por isso utilizou-se taxas com valores baixos e altos: 0,1; 0,3; 0,5; 0,7; 1; 2; 3; 4; 5; 6; 7; 8; 9; 10.

Para o algoritmo Resilient Propagation foram utilizadas as suas quatro variações básicas: RPROP+, RPROP-, iRPROP+, iPROP. Os algoritmos Scaled Conjugate Gradient e Levenberg Marquardt independem de valores de parâmetros de treinamento, apresentando apenas uma configuração.

Para o algoritmo baseado na metaheurística Simulated Annealing, que é derivado de processos de recozimento de sólidos em metalúrgicas, o número de ciclos variou de 100 a 1000 com intervalos de 100, a temperatura mínima foi igual a 2 e a temperatura máxima igual a 10.

Outra metaheurística utilizada para o treinamento das RNA foi o Algoritmo Genético. Este algoritmo é inspirado em mecanismos de evolução natural e de genética. Os parâmetros utilizados para o treinamento com Algoritmos Genéticos foram: valores de população variando de 100 a 700 com intervalos de 100; valores de mutação com variações entre 0,1 e 0,4 a cada 0,1; e valores de cruzamento variando entre 0,1 a 0,6 a cada 0,2.

O critério de parada do treinamento foi o número total de ciclos, com valores variando de 500 a 2000 (a cada 500), ou erro quadrático médio inferior a 1%, sendo que o treinamento foi finalizado ao atingir um destes critérios.

Todas as combinações possíveis entre o número de neurônios na camada oculta, função de ativação nas camadas oculta e de saída, número de ciclos de treinamento e parâmetros dos algoritmos foram analisadas. Para cada combinação foram geradas 10 RNA. A escolha preliminar de configurações adequadas se deu através da análise da média e desvio-padrão dos erros médios quadráticos do treinamento das RNA geradas para cada configuração.

Os testes foram realizados no sistema NeuroForest, sendo que a versão utilizada foi alterada pelos próprios autores para rodar scripts contendo diferentes configurações de RNA. Este sistema utiliza a normalização linear das variáveis numéricas (Eq. 1) para impedir tendências nas estimativas influenciadas por variáveis com valores maiores, sendo:

$$x' = \frac{(x - x_{\min})(b - a)}{(x_{\max} - x_{\min})} + a \quad (1)$$

em que:

$x'$  - valor normalizado;  $x_{\min}$  e  $x_{\max}$  - valores mínimo e máximo da variável, respectivamente;  $a$  - limite inferior da normalização (0); e  $b$  - limite superior da normalização (1).

As variáveis categóricas são submetidas a codificação do tipo 1-de-N (representação binária), em que cada código tem o comprimento equivalente ao número de classes de uma determinada variável categórica, sendo que a classe representada recebe o valor 1 e para as demais é atribuída o valor 0. Para exemplificar, o número de classes da variável projeto é igual a 04 (A, B, C e D). De acordo com a metodologia 1-de-N, a classe A receberá a codificação 1000; a classe B corresponderá a 0100; e assim sucessivamente.

### Avaliação das estimativas

As estimativas das alturas totais geradas pelas RNA foram avaliadas utilizando-se os seguintes critérios: coeficiente de correlação ( $r_{\hat{y}y}$ ) entre os valores observados e estimados da altura (Eq. 2), raiz quadrada do erro quadrático médio expressa em percentagem da média (RMSE%) (Eq. 3), e análise gráfica de resíduos.

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

em que  $s^2$  - variância; cov - covariância;  $y$  - altura total observada e  $\hat{y}$  - altura total estimada pela RNA.

O coeficiente de correlação tem amplitude entre -1 e 1, e serve como um indicador relativo do grau de ajustamento para modelos não lineares, quanto mais próximo de 1 melhor é o ajuste. O RMSE% mede o desempenho global do ajuste. Quanto menores as estimativas do RMSE%, mais confiável é o modelo ajustado (Campos & Leite, 2013), sendo:

$$\text{RMSE}(\%) = \frac{100}{\bar{y}} \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (3)$$

em que  $n$  – valor total dos dados; e  $\bar{y}$  – média dos valores observados.

A análise gráfica de resíduos permite detectar erros de tendência que não foram encontrados pelas estatísticas que medem a precisão (Campos & Leite, 2013). A avaliação residual consistiu na dispersão dos erros percentuais em relação aos valores observados (Eq. 4), sendo:

$$\text{erro}(\%) = 100 \times \frac{(\hat{y} - y)}{y} \quad (4)$$

## Resultados e Discussão

O número de configurações de RNA testadas foi igual a 1,2 10<sup>6</sup>. Ressalta-se que as RNA testadas foram executadas através de um script contendo todas as configurações. Entretanto, foram avaliadas apenas as configurações que apresentaram erro médio quadrático inferior a 1%, devido ao extenso número de redes treinadas.

Não foram encontrados resultados satisfatórios utilizando-se os algoritmos Levenberg Marquadt Algorithm, Simulated Annealing, Manhattan Update Rule e Algoritmos Genéticos, sendo que a maioria das configurações testadas não convergiu, e algumas das estimativas apresentaram valores negativos, não seguindo a representação da realidade. Binoti et al. (2014), também não encontraram resultados satisfatórios com estes algoritmos para estimação do volume de árvores de eucalipto. Isso indica que esses algoritmos podem não ser apropriados para algumas das estimativas florestais que envolvam aproximação de função.

Os resultados obtidos com o algoritmo Error Backpropagation apresentaram tendenciosidade nas árvores menores. Entretanto, as redes que proporcionaram menor tendenciosidade no ajuste possuíam ao menos 05 neurônios da camada oculta, taxas de aprendizagem pequenas (iguais ou menores que 0,001) e o parâmetro momentum menor que 0,01. Binoti et al. (2013a) utilizaram redes de múltiplas camadas treinadas com o algoritmo Error Backpropagation para estimação da altura total de árvores de povoamentos clonais de eucalipto, localizados na mesma área deste estudo, e encontraram excelentes estimativas. A divergência entre os resultados encontrados por estes autores e as estimativas tendenciosas obtidas no presente trabalho pode ser explicada pelo fato do algoritmo Error Backpropagation apresentar muita sensibilidade em relação aos pesos iniciais gerados aleatoriamente (Özçelik et al., 2010). Assim, pode-se inferir que este algoritmo é apropriado para estimação de altura, mas a avaliação de um maior número de RNA na busca por configurações ideais pode ser necessária.

Os algoritmos Resilient Propagation e Quick Propagation apresentaram bom desempenho para RNA com no mínimo 03 neurônios na camada oculta. Entretanto, redes com mais de 08

neurônios na camada oculta apresentaram perda de precisão quando aplicados em dados desconhecidos (generalização). O algoritmo Scaled Gradient, não apresentou bons resultados com poucos neurônios na camada oculta. Foram observados resultados satisfatórios para redes treinadas com 13 neurônios. Contudo, redes treinadas com 20 neurônios não demonstraram bom desempenho na generalização.

O algoritmo Quick Propagation apresentou bom desempenho com taxas de aprendizagem a partir de 01. Isso se deve ao fato que este algoritmo permite altas taxas de aprendizagem sem ocasionar instabilidade à rede em algumas aplicações (Haykin, 2001). Entretanto, taxas de aprendizagem superiores a 07 diminuíram a precisão das estimativas.

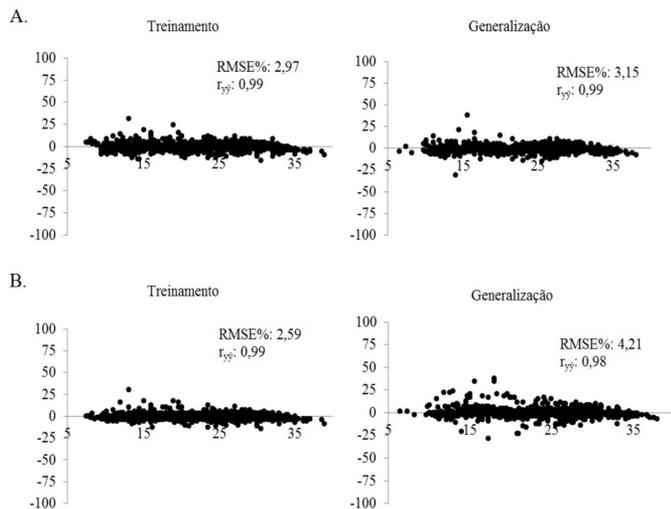
Não houve diferenças entre as quatro variações básicas do algoritmo Resilient Propagation: RPROP+, RPROP-, iRPROP+, iPROP-, o que indica que todas as variações deste algoritmo podem ser utilizadas para estimação da altura total de árvores de eucalipto.

Foram encontradas RNA satisfatórias com todas as funções de ativação utilizadas. Entretanto, observou-se que as funções de ativação linear e identidade apresentaram bom desempenho quando utilizadas apenas na camada de saída. Provavelmente isto está relacionado com a relação de não linearidade na modelagem da altura, sendo necessária a utilização de funções não lineares para o aprendizado adequado da rede. Haykin (2001) comenta que a utilização de funções lineares na camada oculta faz com que a rede seja equivalente a uma rede de uma única camada, pois transformações lineares sucessivas podem ser consideradas como uma única transformação linear.

Com relação ao número de ciclos, verificou-se que 500 ciclos são suficientes para o treinamento das redes. No entanto, redes com maior número de neurônios ou com taxas de aprendizagem pequenas podem necessitar um número maior de ciclos, pois de acordo com Haykin (2001), o número de ciclos é influenciado por parâmetros do algoritmo. Cabe salientar, que o número de ciclos consiste em um dos critérios de parada para uma RNA e afeta o tempo de busca da rede. Um número elevado de ciclos pode ocasionar o overfitting (a rede memoriza os dados, mas não é capaz de extrapolar o conhecimento para dados desconhecidos) e aumentar o tempo de busca. Entretanto, um número reduzido de ciclos pode ocasionar um underfitting (a rede não é treinada o suficiente para resolver uma determinada tarefa). Observou-se também que 2000 ciclos foram capazes de treinar redes com vários neurônios sem causar overfitting.

As configurações mais simples de RNA são preferíveis em relação a configurações mais complexas, pois embora a habilidade das RNA de extrair características intrínsecas entre a variável de saída e variáveis de entrada esteja relacionada com o número de neurônios ocultos, um número excessivo de neurônios pode fazer com que a rede faça uma extrapolação ruim mesmo se o ajuste feito com os dados de treinamento for muito bom (overfitting).

Na Figura 1 é exemplificado o desempenho de duas RNA distintas na estimação da altura de árvores de eucalipto e demonstra que a rede treinada com poucos neurônios, teve um bom desempenho para a extrapolação de dados desconhecidos



**Figura 1.** Gráficos de dispersão de resíduos (eixo x: altura total observada (m); eixo y: resíduos percentuais). A. Configuração da RNA: algoritmo Quick Propagation, 3 neurônios camada oculta, taxa de aprendizagem igual a 1, função de ativação dos neurônios ocultos e de saída: tangente hiperbólica. B. Configuração da RNA: algoritmo Resilient Propagation, variação iRPROP+, 12 neurônios na camada oculta, função de ativação dos neurônios ocultos e de saída: tangente hiperbólica

(generalização) (Figura 1A). Entretanto, a rede treinada com 12 neurônios, embora tenha apresentado um bom desempenho no treinamento, proporcionou menor precisão na extrapolação de dados desconhecidos (Figura 1B), apresentando tendenciosidade.

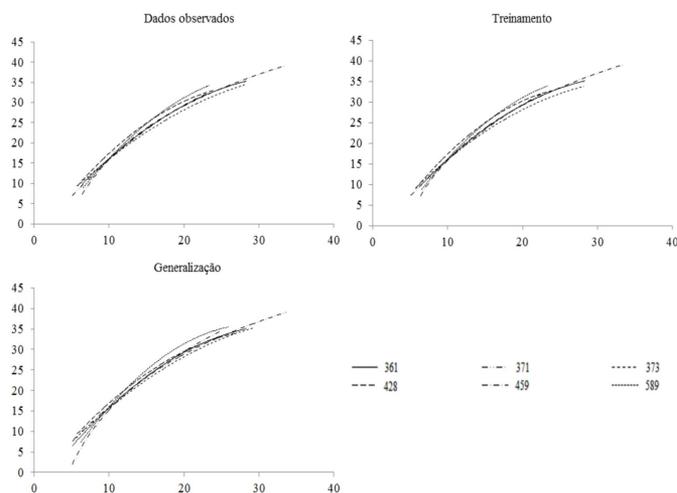
Alguns autores buscaram explicar a relação entre o número de neurônios ocultos e o número de neurônios das camadas de entrada e saída. Russel & Norvig (2004), afirmaram que o número de neurônios ocultos cresce exponencialmente com o número de neurônios na camada de entrada e, segundo Artero (2009), o número de neurônios na camada oculta é comumente definido por meio da média geométrica entre os números de neurônios nas camadas de entrada e saída. Entretanto, os resultados deste estudo demonstram que relações não lineares relativamente simples como estimativa de altura de árvore ou de estimativas volumétrica, como demonstrado por Binoti et al. (2014), podem ser solucionados com poucos neurônios na camada oculta. Assim, é interessante que tais configurações de RNA sejam utilizadas em detrimento de configurações com um número maior de neurônios ocultos, para que o processo de busca seja facilitado e não ocorra o “sobreajuste” das redes (overfitting), ocasionando a memorização dos dados e, conseqüentemente, uma extrapolação inadequada (Bullinaria, 2014).

Os resultados encontrados demonstram a importância em se definir configurações adequadas de RNA, pois aplicações diferentes podem necessitar de configurações distintas para a obtenção de desempenhos satisfatórios. Como exemplos, podem ser citados os algoritmos que não geraram resultados satisfatórios para a presente aplicação de altura de eucalipto, mas que podem ser utilizados com excelência em aplicações distintas ou aplicações semelhantes em situações diferentes. Além disso, o número de neurônios e os parâmetros adequados variam conforme a situação (Maeda et al., 2009; Özçelik et al., 2013; Binoti et al., 2014).

Os resultados demonstram ainda que as RNA com configurações que apresentaram bom desempenho para estimativa das alturas, também são capazes de detectar comportamentos diferentes de acordo com características qualitativas do povoamento, sendo que esta habilidade torna as RNA atrativas frente as técnicas tradicionais. A Figura 2 exemplifica a habilidade de estratificação de uma única RNA.

Na Figura 2 se observa que a relação hipsométrica apresentou tendência distinta para os materiais genéticos utilizados, sendo que a RNA é capaz de detectar essas diferenças utilizando apenas uma única rede. Binoti (2010) utilizou redes neurais artificiais para prognose da produção volumétrica de eucalipto e constatou que uma RNA é capaz de modelar a tendência de crescimento para cada clone utilizado. Estes resultados confirmam as vantagens operacionais das RNA em relação aos modelos tradicionais, pois elas são capazes de extrair relações diferentes em uma única modelagem através da inclusão de variáveis categóricas, que muitas vezes não podem ser incluídas em modelos tradicionais de regressão, o que torna necessário uma estratificação prévia e o ajuste de equações por estrato, o que pode ser verificado em diversos trabalhos (Andrade et al. 2006; Oliveira et al., 2009; David et al., 2014).

Assim, essa característica das RNA torna possível a redução do tempo gasto com ajustes e avaliações de modelos hipsométricos para cada estrato. Outra vantagem é que o emprego de RNA requer amostras para treinamento de tamanho relativamente reduzido.



**Figura 2.** Gráficos da curva de altura (m) em função do dap (cm) para diferentes materiais genéticos. Configuração da rede utilizada: Algoritmo Quick Propagation, 3 neurônios na camada oculta, taxa de aprendizagem igual a 1, função de ativação tangente hiperbólica

## Conclusões

A estimativa da altura das árvores de povoamentos de eucalipto pode ser realizada por meio de diversas configurações de redes neurais artificiais.

Os algoritmos de aprendizagem Resilient Propagation, Quick Propagation e Scaled Conjugate Gradient são eficientes para estimativa da altura total de árvores de eucalipto.

Configurações simples de redes neurais artificiais com apenas três neurônios ocultos são eficientes para a estimativa

da altura de árvores e devem ser preferidas em detrimento de configurações complexas.

## Literatura Citada

- Aertsen, W.; Kint, V.; van Orshoven, J.; Özkan, K.; Muys, B. Comparison and ranking of different modelling techniques for prediction of site index in Mediterranean mountain forest. *Ecological Modelling*, v.221, n.8, p.1119–1130, 2010. <<http://dx.doi.org/10.1016/j.ecolmodel.2010.01.007>>.
- Andrade, V. C. L. de; Calegario, N.; Scolforo, J. R. S. Análise de algumas alternativas para obter o coeficiente angular da reta no método da altura relativa. *Ciência Florestal*, v.16, n.3, p.303-317, 2006. <<http://dx.doi.org/10.5902/198050981910>>.
- Artero, A. O. Inteligência artificial: teoria e prática. 1 ed. São Paulo: Editora Livraria da Física, 2009. 230 p.
- Batista, J. L. F.; Couto, H. T. Z.; Marquesini, M. Desempenho de modelos de relações hipsométricas: estudo em três tipos de florestas. *Scientia Forestalis*, n.60, p.149-163, 2001. <<http://www.ipef.br/publicacoes/scientia/nr60/cap12.pdf>>. 28 Jan. 2015.
- Binoti, D. H. B.; Binoti, M. L. M. da S.; Leite, H. G. Configuração de redes neurais para estimação do volume de madeira. *Ciência da Madeira*, v.5, n.1, p.59-67, 2014. <<http://dx.doi.org/10.12953/2177-6830.v05n01a06>>.
- Binoti, D. H. B.; Binoti, M. L. M. da S.; Leite, H. G.; Silva, A. Redução dos custos em inventário de povoamentos equiâneos. *Revista Brasileira Ciências Agrárias*, v.8, n.1, p.125-129, 2013b. <<http://dx.doi.org/10.5039/agraria.v8i1a2209>>.
- Binoti, M. L. M. da S. Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto. Viçosa: Universidade Federal de Viçosa. 2010. 54p. Dissertação Mestrado.
- Binoti, M. L. M. da S.; Binoti, D. H. B.; Leite, H. G. Aplicação de redes neurais para estimação da altura de povoamentos equiâneos de eucalipto. *Revista Árvore*, v.37, n.4, p.639-645, 2013a. <<http://dx.doi.org/10.1590/S0100-67622013000400007>>.
- Braga, A. de P.; Carvalho, A. C. P. de L. F. de; Ludemir, T. B. Redes neurais artificiais: teoria e aplicações. 2.ed. Rio de Janeiro: LTC, 2007. 226p.
- Bullinaria, J. A. Introduction to neural computation. <<http://www.cs.bham.ac.uk/~jxb/inc.html>>. 19 Nov. 2014.
- Campos, J. C. C.; Leite, H. G. Mensuração florestal: perguntas e respostas. 4.ed. Viçosa: UFV, 2013. 605p.
- Curtis, R.O. Height-diameter and height-diameter-age equations for second growth Douglas-fir. *Forest Science*, v.13, n.4, p.365-375, 1967.
- David, H. C.; Marinheski Filho, A.; Pelissari, A. L.; Netto, S. P.; Araújo, E. J. G. de; Baum, L. Critérios de estratificação para o ajuste de funções de afilamento em fustes de pinus. *Pesquisa Florestal Brasileira*, v.34, n.79, p.197-206, 2014. <<http://dx.doi.org/10.4336/2014.pfb.34.79.659>>.
- Diamantopoulou, M. J. Assessing a reliable modeling approach of features of trees through neural network models for sustainable forests. *Sustainable Computing: Informatics and Systems*, v.2, n.4, p.190-197, 2012. <<http://dx.doi.org/10.1016/j.suscom.2012.10.002>>.
- Diamantopoulou, M. J.; Milios, E. Modelling total volume of dominant pine trees in reforestations via multivariate analysis and artificial neural networks models. *Biosystems Engineering*, v.105, n.3, p.306-315, 2010. <<http://dx.doi.org/10.1016/j.biosystemseng.2009.11.010>>.
- Fang, Z.; Bailey, R. L. Height-diameter models for tropical forests on Hainan Island in Southern China. *Forest Ecology and Management*, v.110, n.1-3, p.315-327, 1998. <[http://dx.doi.org/10.1016/S0378-1127\(98\)00297-7](http://dx.doi.org/10.1016/S0378-1127(98)00297-7)>.
- Gorgens, E. B.; Leite, H. G.; Santos, H. N.; Gleriani, J. M. Estimação do volume de árvores utilizando redes neurais artificiais. *Revista Árvore*, v.33, n.6, p.1141-1147, 2009. <<http://dx.doi.org/10.1590/S0100-67622009000600016>>.
- Haykin, S. Redes neurais: princípios e prática. 2.ed. Porto Alegre: Bookman, 2001. 900p.
- Husch, B.; Beers, T. W.; Kershaw Jr., J. A. Forest Mensuration, 4.ed. New Jersey: John Wiley & Sons, 2003. 456 p.
- Leite, H. G.; Silva, M. L. M. da; Binoti, D. H. B.; Fardin, L.; Takizawa, F. H. Estimation of inside-bark diameter and heartwood diameter for *Tectona grandis* Linn. trees using artificial neural networks. *European Journal of Forest Research*, v.130, n.2, p.263-269, 2010. <<http://dx.doi.org/10.1007/s10342-010-0427-7>>.
- Maeda, E. E.; Formaggio, A. R.; Shimabukuro, Y. E.; Arcoverde, G. F. B.; Hansen, M. C. Predicting forest fire in the brazilian amazon using MODIS imagery and artificial neural networks. *International Journal of Applied Earth Observation and Geoinformation*, v.11, n.4, p.265-272, 2009. <<http://dx.doi.org/10.1016/j.jag.2009.03.003>>.
- Martins, E. dos R. M.; Binoti, M. L. M. da S.; Leite, H. G.; Binoti, D. H. B.; Dutra, G. C. Configuração de redes neurais artificiais para prognose da produção de povoamentos clonais de eucalipto. *Revista Brasileira de Ciências Agrárias*, v.10, n.4, p.532-537, 2015. <<http://dx.doi.org/10.5039/agraria.v10i4a5350>>.
- Martins, E. dos R. M.; Binoti, M. L. M. da S.; Leite, H. G.; Binoti, D. H. B.; Dutra, G. C. Configuração de redes neurais artificiais para estimação do afilamento do fuste de árvores de eucalipto. *Revista Brasileira de Ciências Agrárias*, v.11, n.1, p.33-38, 2016. <<http://dx.doi.org/10.5039/agraria.v11i1a5354>>.
- Neuroforest. Sistema Neuroforest. <<http://neuroforest.ucoz.com>>. 15 Mai. 2013.
- Oliveira, M. L. R. de O.; Leite, H. G.; Garcia, S. L. R.; Campos, J. C. C.; Soares, C. P. B.; Santana, R. C. Estimação do volume de árvores de clones de eucalipto pelo método da similaridade de perfis. *Revista Árvore*, v.33, n.1, p.133-141, 2009. <<http://dx.doi.org/10.1590/S0100-67622009000100014>>.
- Özçelik, R.; Diamantopoulou, M. J. Brooks, J. R.; Wiant Jr, H. Estimating tree bole volume using artificial neural network models for four species in Turkey. *Journal of Environmental Management*, v.91, n.3, p.742–753, 2010. <<http://dx.doi.org/10.1016/j.jenvman.2009.10.002>>.

- Özçelik, R.; Diamantopoulou, M. J.; Crecente-Campo, F.; Eler, U. Estimating *Crimean juniper* tree height using nonlinear regression and artificial neural network models. *Forest Ecology and Management*, v.306, p.52–60, 2013. <<http://dx.doi.org/10.1016/j.foreco.2013.06.009>>.
- Rodrigues, E. F.; Oliveira, T. R.; Madruga, M. R.; Silveira, A. M. Um método para determinar o volume comercial do *Schizolobium amazonicum* (Huber) Ducke utilizando redes neurais artificiais. *Revista Brasileira de Biometria*, v.28, n.1, p.16-23, 2010. <[http://jaguar.fcav.unesp.br/RME/fasciculos/v28/v28\\_n1/A2\\_Eraldo.pdf](http://jaguar.fcav.unesp.br/RME/fasciculos/v28/v28_n1/A2_Eraldo.pdf)>. 26 Fev. 2015.
- Russel, S. J.; Norvig, P. *Inteligência artificial*. 2.ed. Rio de Janeiro: Elsevier, 2004. 1021p.
- Silva, G. F.; Xavier, A. C.; Rodrigues, F. L.; Paternelli, L. A. Análise da influência de diferentes tamanhos e composições de amostras no ajuste de uma relação hipsométrica para *Eucalyptus grandis*. *Revista Árvore*, v.31, n.4, p.685-694, 2007. <<http://dx.doi.org/10.1590/S0100-67622007000400013>>.
- Soares, F. A. A. M. N.; Flôres, E. D.; Cabacinha, C. D.; Carrijo, G. A.; Veiga, A. C. P. Recursive diameter prediction and volume calculation of eucalyptus trees using multilayer perceptron networks. *Computers and Eletronics in Agriculture*, v.78, n.1, p.19-27, 2011. <<http://dx.doi.org/10.1016/j.compag.2011.05.008>>.