



Revista Brasileira de Ciências Agrárias

ISSN: 1981-1160

agrarias.prppg@ufrpe.br

Universidade Federal Rural de

Pernambuco

Brasil

dos Reis Martins, Emília; Marques da Silva Binoti, Mayra Luiza; Garcia Leite, Hélio; Breda Binoti, Daniel Henrique; Campos Dutra, Gleyce

Configuração de redes neurais artificiais para estimação do afilamento do fuste de árvores de eucalipto

Revista Brasileira de Ciências Agrárias, vol. 11, núm. 1, 2016, pp. 33-38

Universidade Federal Rural de Pernambuco

Pernambuco, Brasil

Disponível em: <http://www.redalyc.org/articulo.oa?id=119045655006>

- Como citar este artigo
- Número completo
- Mais artigos
- Home da revista no Redalyc

redalyc.org

Sistema de Informação Científica

Rede de Revistas Científicas da América Latina, Caribe, Espanha e Portugal

Projeto acadêmico sem fins lucrativos desenvolvido no âmbito da iniciativa Acesso Aberto

Configuração de redes neurais artificiais para estimação do afilamento do fuste de árvores de eucalipto

Emília dos Reis Martins¹, Mayra Luiza Marques da Silva Binoti², Hélio Garcia Leite³, Daniel Henrique Breda Binoti⁴, Gleyce Campos Dutra⁵

¹ 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

² 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;

³ 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

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

⁵ 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 deste trabalho foi definir configurações adequadas de Redes Neurais Artificiais (RNA) para modelagem do afilamento do fuste (*taper*) de árvores de eucalipto. Foram utilizados dados de cubagem de povoamentos de eucalipto localizados no sul da Bahia. Várias configurações de RNA foram avaliadas diferindo em relação ao número de neurônios na camada oculta, função de ativação, número de ciclos e algoritmos de aprendizagem com os seus parâmetros. As RNA foram treinadas no sistema Neuroforest, e as estimativas foram avaliadas por meio do coeficiente de correlação entre os valores observados e estimados, a raiz quadrada do erro quadrático médio (RMSE%), e análise gráfica de resíduos. Configurações simples, com apenas 04 neurônios ocultos, propiciaram resultados satisfatórios. Todas as funções de ativação testadas (tangente hiperbólica, sigmoideal, identidade, log, linear e seno) podem ser utilizadas, sendo que as funções linear e identidade são apropriadas para a camada de saída das RNA. O treinamento das RNA pode ser feito com 2000 ciclos. Os algoritmos Resilient Propagation e Quick Propagation são eficientes para aplicações de *taper*. Diversas configurações de RNA podem ser utilizadas para aplicações de *taper*.

Palavras-chave: inteligência artificial, multiprodutos, neuroforest

Configuration of artificial neural network for estimation of taper of trees eucalyptus

ABSTRACT

The aim of this work was to define appropriate configurations of Artificial Neural Networks (ANN) to model the *taper* of eucalyptus trees. were used cubage data of eucalyptus plantations located in southern Bahia. Several ANN configurations were evaluated differing in the number of neurons in the hidden layer, activation function, number of cycles and learning algorithms with their parameters. ANN were trained in Neuroforest system, and estimates were evaluated using the correlation coefficient between observed and estimated values, the root mean square error (RMSE%) and graphical analysis of waste. Simple configurations, with only 04 hidden neurons, have provided satisfactory results. All activation functions tested (hyperbolic tangent, sigmoid, identity, log, linear, sine) may be used, wherein functions linear and identities are appropriate for the output layer of the ANN. The training of ANN may be done with 2000 cycles. The algorithms Resilient Propagation and Quick Propagation are efficient to applications of *taper*. Several ANN configurations may be used to applications of *taper*.

Key words: artificial intelligence, multiproducts, neuroforest

Introdução

A obtenção de multiprodutos da madeira é uma alternativa atraente para o planejamento florestal, por resultar em um melhor aproveitamento da produção, maximização de lucros do empreendimento e redução do impacto gerado diante de oscilações do mercado sobre determinado produto (Carvalho & Nahuz, 2001; Soares et al., 2003). Entretanto, para obtenção de diferentes produtos a partir do mesmo fuste, é essencial conhecer de maneira efetiva o afilamento do fuste (*taper*), pois este tem efeito direto sobre a conversão do fuste em produtos da madeira.

Nesse sentido, as funções de *taper* são comumente utilizadas para quantificação dos sortimentos dos povoamentos florestais. O termo *taper* refere-se ao afilamento natural do fuste de uma árvore e os modelos propostos para sua modelagem descrevem o diâmetro em qualquer altura da árvore, desde que haja uma regularidade definida na mudança do diâmetro. Consequentemente, é possível também estimar a altura e o volume em diferentes partes do tronco (Soares et al., 2006; Campos & Leite, 2013).

Vários pesquisadores têm empreendido esforços com o intuito de obter modelos que descrevam com exatidão o perfil do fuste de árvores (Kozak et al.; 1969; Demaerschaik, 1972; Ormerod, 1973; Pires & Calegário, 2007).

No entanto, alguns problemas podem ser detectados nos modelos de *taper*. Como exemplo, pode ser citada a dificuldade de descrever precisamente toda a extensão do fuste devido às diferentes formas geométricas que o tronco se assemelha ao longo de um mesmo fuste. Além disso, equações que descrevem satisfatoriamente o afilamento do fuste podem resultar em baixa exatidão para altura e volume (Campos & Leite, 2013).

Soares et al. (2004) também afirmaram que um mesmo modelo de *taper* pode proporcionar estimativas precisas para um determinado conjunto de dados, e imprecisas para outros dados, pois a forma do fuste pode variar entre espécies e essa variação também pode ocorrer para a mesma espécie, de acordo com os tratamentos silviculturais aplicados e outros fatores que interferem na interação entre o genótipo e o ambiente.

Diante da dificuldade de descrever corretamente o afilamento do fuste e da dificuldade do ajuste de muitos modelos, muitos pesquisadores buscam novas modelagens e métodos para estimativas de *taper*. Leite et al. (2010), ao aplicarem Redes Neurais Artificiais (RNA), encontraram resultados mais eficientes na estimação de diâmetros de árvores de *Tectona grandis* quando comparadas às estimativas obtidas pelo modelo de Kozak. Assim, eles demonstraram que a utilização de RNA é uma abordagem promissora para descrever a forma do fuste.

Uma das características que torna atraente a utilização de RNA em estimativas florestais é a habilidade de detectar implicitamente relações não lineares dos dados (Özçelik et al., 2010). Pires & Calegário (2007) compararam modelos de regressão lineares e não lineares para *taper* e concluíram que a modelagem não linear apresentou melhores resultados por apresentar características desejáveis, como interpretação dos parâmetros, parcimônia e melhor extrapolação dos dados.

Entretanto, esses mesmos autores comentaram que, muitas vezes, os modelos não lineares são preteridos em relação aos modelos lineares devido a dificuldade de ajuste e convergência.

As RNA são capazes de ajustar dados com relações não lineares sem especificar previamente um modelo, diferindo da abordagem por regressão. Além disso, a modelagem através de RNA permite a inclusão de variáveis qualitativas com facilidade, sendo esta uma vantagem para estimativas de *taper*, pois a forma do fuste varia em função de aspectos genéticos e ambientais, e a inclusão de tais variáveis em modelos de regressão nem sempre é fácil ou possível.

Entretanto, para que uma RNA apresente desempenho satisfatório é necessário escolher adequadamente os atributos da rede. Existem vários algoritmos de aprendizagem desenvolvidos para o treinamento de RNA, e também é necessário definir o número de camadas da rede, o número de neurônios das camadas ocultas, as funções de ativação das camadas ocultas e de saída, e os parâmetros específicos que compõe cada algoritmo.

A definição inadequada destes atributos pode ocasionar muitos problemas, como o overfitting, evento em que a rede memoriza todos os exemplos apresentados no processo de aprendizagem, mas não é capaz de realizar boas generalizações para dados desconhecidos. Outro problema é o underfitting, em que a rede não extrai as informações necessárias para a solução do problema. Além disso, a rede pode não convergir, ou apresentar respostas ruins (Haykin, 2001; Braga et al., 2007).

Entretanto, o processo de escolha da configuração adequada da RNA pode demandar muito tempo devido à enorme quantidade de combinações possíveis dos atributos da rede, e normalmente essa escolha é feita através de tentativa e erro (Russel & Norvig, 2004; Artero, 2009). Dentro deste contexto, o objetivo deste trabalho foi definir configurações adequadas de RNA para modelagem do afilamento do fuste de árvores em povoamentos de clones de eucalipto.

Material e Métodos

Dados

Foram utilizados dados de inventários florestais contínuos realizados em povoamentos clonais de eucalipto, localizados no sul da Bahia, em uma área de aproximadamente 2000 ha.

As variáveis quantitativas foram: diâmetro mensurado a 1,30 m de altura (dap) em cm, altura total (Ht) em m, altura em diferentes posições no fuste (Hi) em m, e idade (I) em anos. As variáveis qualitativas foram: projeto, clone, espaçamento e uma variável binária para discriminar diâmetro com ou sem casca (TX). O número de classes das variáveis qualitativas foram 8, 4, 2 e 2, respectivamente. O diâmetro em diferentes posições no fuste (Di) (cm) 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 75% dos dados) e um para a extrapolação dos dados a partir das redes treinadas (generalização) (aproximadamente 25%).

Tabela 1. Análise descritiva das variáveis quantitativas

	Mínimo	Máximo	Média	Desvio-Padrão
dap (cm)	6,05	27,53	16,34	±5,20
Ht (m)	11,08	35,98	25,51	±5,78
Hi (m)	0,00	32,00	8,67	±7,96
I (anos)	3	7	5	±1
Di (cm)	4,14	33,10	12,61	±5,48

dap = diâmetro a 1,3 m de altura; Ht = altura total; Hi = altura em diferentes posições no fuste; I = idade; Di = diâmetro em diferentes posições no fuste

Redes neurais artificiais

O número total de neurônios na camada de entrada foi igual a 21, que corresponde a um neurônio para cada variável quantitativa e para cada classe de variável qualitativa. Todas as redes foram compostas com uma única camada oculta contendo até 20 neurônios ocultos, e a camada de saída das redes foi constituída de apenas um neurônio, que corresponde a variável de saída desejada (Di).

Foram utilizadas diferentes funções de ativação nas camadas ocultas e de saída, sendo: linear, identidade, log, tangente hiperbólica, seno e sigmoide. O treinamento das redes foi realizado utilizando 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; 0,1; 0,5; 1, totalizando 112 combinações possíveis para o algoritmo Error Backpropagation. 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.

Foram utilizadas as quatro variações básicas do algoritmo Resilient Propagation, sendo: RPROP+, RPROP-, iRPROP+, iPROP. Os algoritmos Scaled Conjugate Gradient e Levenberg Marquardt apresentam apenas uma configuração, pois independem de valores de parâmetros de treinamento.

Os parâmetros utilizados para o algoritmo baseado na metaheurística Simulated Annealing são o número de ciclos e as temperaturas mínima e máxima. Este algoritmo é inspirado em processos térmicos de resfriamento de materiais a altas temperaturas, que são caracterizados pela diminuição gradual da temperatura até atingir o ponto de solidificação e energia mínima. O número de ciclos variou de 100 a 1000 (a cada 100), e as temperaturas mínima e máxima foram 2 e 10, respectivamente.

Para o Algoritmo Genético, que consiste em uma metaheurística inspirada em processos de seleção natural e genética, os parâmetros utilizados foram: valores de população variando de 100 a 700 (a cada 100); valores de mutação entre 0,1 e 0,4 (a cada 0,1); e valores de cruzamento entre 0,1 e 0,6 (a cada 0,2).

O treinamento de cada rede foi finalizado ao completar o número de ciclos, que variou de 500 a 2000 (a cada 500), ou atingir o erro quadrático médio com valor inferior a 1%.

As combinações possíveis entre o número de neurônios na camada oculta, as funções de ativação, o número de

ciclos de treinamento e os parâmetros dos algoritmos foram analisadas, sendo que para cada combinação foram geradas 10 RNA.

A análise da média e desvio-padrão dos erros médios quadráticos, obtidos a partir do treinamento das RNA para cada configuração, foi utilizada para pré-selecionar configurações adequadas. Utilizou-se o sistema NeuroForest, desenvolvido para realizar os testes e disponível gratuitamente em <http://neuroforest.ucoz.com/>. A versão utilizada foi alterada pelos próprios autores para rodar scripts contendo diferentes configurações de RNA.

Este sistema utiliza a normalização linear dos dados com intervalos de 0 a 1 (Eq. 1), 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).

Para as variáveis qualitativas é utilizada a metodologia 1-de-N que consiste em uma representação binária dos dados.

Obtenção do volume

O volume individual das árvores foi calculado utilizando os diâmetros observados e os diâmetros estimados pelas RNA através da fórmula de Smalian (Eq. 2), sendo:

$$V_{\text{seção}} = \left(\frac{g_{\text{base}} + g_{\text{topo}}}{2} \right) \times L \quad (2)$$

em que: V – volume; g – área seccional; L – comprimento da seção.

Através do somatório do volume de todas as árvores utilizadas no treinamento, foram obtidos os volumes totais real e estimado.

Avaliação das estimativas

As estimativas do diâmetro (Di) geradas pelas RNA e do volume das árvores (V) foram avaliadas por meio da análise do coeficiente de correlação (r_{yy}) entre os valores observados e estimados (Eq. 3), a raiz quadrada do erro quadrático médio (RMSE%) (Eq. 4), e análise gráfica de resíduos, sendo:

$$r_{yy} = \frac{\text{cov}(\hat{y})}{\sqrt{s^2(y)s^2(\hat{y})}} \quad (3)$$

em que: s^2 – variância; cov – covariância; y – Di ou V observado e \hat{y} – Di ou V estimado.

O coeficiente de correlação é um indicador relativo do grau de ajustamento para modelos não lineares, com amplitude entre -1 e 1, e quanto mais próximo de 1 melhor é o ajuste.

O RMSE% é utilizado para medir o desempenho global do ajuste, e quanto menores as estimativas do RMSE%, mais confiável é o modelo ajustado (Campos & Leite, 2013), sendo:

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

em que: n – valor total dos dados; e y – média dos valores observados.

Os erros de tendência, que não foram encontrados utilizando estatísticas responsáveis por medir a precisão, podem ser facilmente visualizados através da análise gráfica de resíduos (Campos & Leite, 2013), que consistiu na dispersão dos erros percentuais em relação aos valores observados (Eq. 5), sendo:

$$\text{erro}(\%) = 100 \times \frac{(\hat{y} - y)}{y} \quad (5)$$

Resultados e Discussão

Foram testadas 1,2 10^6 RNA diferentes. Ressalta-se que as RNA testadas foram executadas através de um script contendo todas as configurações. As configurações que apresentaram erro médio quadrático superior a 1% não foram avaliadas, devido a grande quantidade de RNA treinadas.

As configurações testadas com os algoritmos Scaled Conjugate Gradient, Levenberg Marquadt Algorithm, Simulated Annealing, Manhattan Update Rule e Algoritmos Genéticos não apresentaram resultados satisfatórios. Algumas redes treinadas com estes algoritmos não convergiram, outras não atingiram o erro mínimo especificado ou apresentaram resultados que não condizem com a realidade. Estes resultados são semelhantes aos encontrados por Binoti et al. (2014), que também testaram configurações de RNA com estes algoritmos para estimação do volume total de árvores de eucalipto, e indicam que tais algoritmos podem não ser apropriados para algumas das estimativas florestais.

Também não foram encontradas RNA apropriadas para as configurações testadas com o algoritmo Error Backpropagation. Este algoritmo é considerado um dos mais populares para redes de múltiplas camadas e tem fornecido excelentes resultados para diversas aplicações (Gorgens et al., 2009; Silva et al., 2009; Binoti, 2010; Özçelik et al., 2010; Binoti, 2012; Soares et al.; 2012). Contudo, Özçelik et al. (2010) destacam que redes treinadas com o algoritmo de aprendizagem Error Backpropagation são muito sensíveis aos pesos iniciais gerados aleatoriamente, o que justifica a utilização de algoritmos que não possuem este problema e podem proporcionar uma quantidade maior de RNA adequadas para solucionar um dado problema.

Além disso, Haykin (2001) comenta que algumas configurações de RNA com parâmetros muito semelhantes podem resultar em resultados completamente diferentes. Deste modo, considerando o bom desempenho do algoritmo Error Backpropagation para diferentes problemas e a sensibilidade do mesmo quanto a sua parametrização, pode-se inferir que existe a possibilidade de encontrar resultados satisfatórios para modelagem do afilamento de árvores de eucalipto com o algoritmo Error Backpropagation se forem utilizadas configurações distintas das utilizadas no presente estudo, ou com pesos iniciais diferentes.

Os algoritmos Quick Propagation e Resilient Propagation se mostraram eficientes para estimativas de *taper*, sendo que as configurações adequadas apresentaram no mínimo 04 neurônios ocultos.

O número de neurônios ocultos está diretamente relacionado com a capacidade da RNA detectar relações não lineares implícitas entre os dados e extrair estatísticas de ordem elevada (Haykin, 2001). Entretanto, ressalta-se que o excesso de neurônios pode levar a memorização dos dados apresentados a RNA no treinamento, resultando na perda de capacidade de extrapolação em dados desconhecidos pela rede (overfitting). Para evitar este problema, Bullinaria (2014) recomenda a utilização de menos neurônios no treinamento. Assim, é importante escolher configurações mais simples em detrimento de configurações complexas para obtenção de resultados adequados.

Para o algoritmo Quick Propagation, as taxas de aprendizagem consideradas apropriadas para o treinamento das RNA variaram de 01 a 04. Este algoritmo permite a utilização de altas taxas de aprendizagem sem ocasionar instabilidade no sistema (Braga et al, 2007; Binoti et al., 2014). Contudo, taxas muito elevadas podem levar a resultados ruins e até mesmo a não convergência do algoritmo, uma vez que a taxa de aprendizagem define o tamanho do passo que será dado em uma determinada direção do espaço de soluções (Kovacs, 1996).

Todas as variações do algoritmo Resilient Propagation (RPROP+, iRPROP+, RPROP, iPROP-) podem ser utilizadas para estimação de *taper*. Binoti et al. (2014) também encontraram resultados similares para estimação do volume de árvores de eucalipto. Estes resultados representam uma vantagem para a utilização deste algoritmo nas estimativas florestais, pois a escolha da configuração se torna mais simples quando comparada com a escolha da configuração de alguns algoritmos, uma vez que é necessário definir apenas o número de neurônios ocultos e a função de ativação.

Os melhores resultados foram obtidos utilizando a função de ativação tangente hiperbólica. Schoeninger (2006) comenta que geralmente esta função apresenta os melhores resultados para o treinamento de RNA devido a sua capacidade de convergir rapidamente. No entanto, encontrou-se configurações satisfatórias utilizando todas as funções de ativação. Cabe ressaltar que houve perda de precisão com a utilização das funções de ativação identidade e linear na camada oculta. De acordo com Haykin (2001), o emprego de funções não lineares na camada oculta equivale a utilização de uma rede linear de uma única camada.

Em relação ao número de ciclos, foi observado que 500 ciclos foram suficientes para o treinamento das RNA. Entretanto, configurações com um número mais elevado de neurônios ocultos podem necessitar de uma quantidade maior de ciclos para que o treinamento seja eficiente. Bullinaria (2014) não recomenda a utilização de um número excessivo de ciclos, para evitar o overfitting. Contudo, observou-se que a quantia de 2000 ciclos foi suficiente para treinar todas as RNA testadas sem prejuízo da qualidade do ajuste ou da generalização.

A RNA treinada com o algoritmo de aprendizagem Resilient Propagation (RPROP+), 05 neurônios ocultos e função de ativação tangente hiperbólica nas camadas oculta e de saída, foi selecionada para exemplificar o desempenho do treinamento e generalização de redes neurais na modelagem de *taper*. Na Figura 1 é demonstrada a atuação da RNA na estimação dos diâmetros e também o efeito do ajuste para determinação do volume.

A análise do RMSE%, da correlação e dos gráficos de dispersão dos resíduos (Figura 1) confirma que redes neurais artificiais podem ser utilizadas para modelagem dos diâmetros ao longo do fuste de árvores de eucalipto (Figura 1A). Estes resultados podem ser comparados a resultados obtidos em outros estudos, como os encontrados por Müller et al. (2014). Os resíduos da estimativa dos diâmetros obtidos neste estudo através de RNA foram melhor distribuídos do que a variação residual encontrada por Müller et al. (2014), que utilizaram diferentes funções de afilamento para *Eucalyptus grandis*. Resultados semelhantes ao deste estudo foram encontrados por Miguel et al. (2011), que também utilizaram diferentes funções de *taper* para *Eucalyptus urophylla*.

Ressalta-se, que os dados modelados por estes autores correspondiam a apenas um tipo de material genético e mesmo espaçamento, enquanto a RNA é capaz de modelar ao mesmo tempo diferentes materiais genéticos distribuídos em plantios com espaçamentos distintos.

Na Figura 1B também é demonstrado que não houve tendência na dispersão residual do volume calculado através da fórmula de Smalian com os diâmetros estimados pela RNA. O volume total observado para os dados de treinamento foi igual a 202,54 m³ e o volume total calculado a partir das estimativas do treinamento foi igual a 202,16 m³. Para os dados utilizados na generalização, o volume total observado e calculado a partir das estimativas de *taper* foi igual a 122,08 m³ e 122,24 m³, respectivamente. Estes resultados indicam que o volume calculado a partir dos diâmetros estimados pela RNA é compatível com a realidade.

O perfil médio das árvores, considerando os diâmetros médios reais e estimados, é apresentado na Figura 2, e

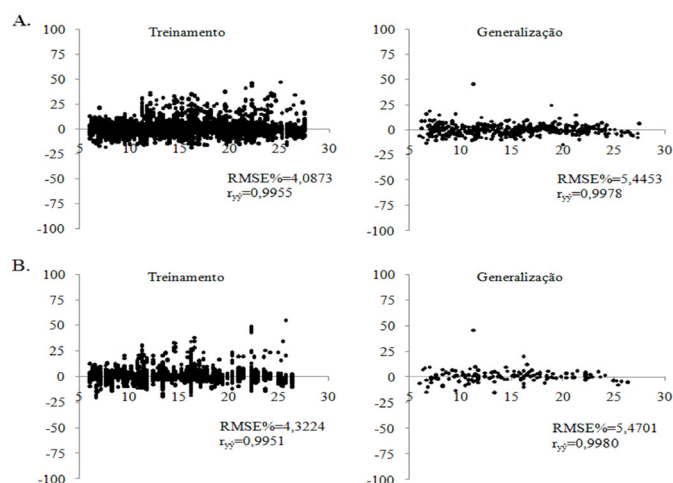


Figura 1. Dispersão dos erros percentuais do treinamento e generalização da RNA para estimativas dos diâmetros (cm) e volume (m³) de árvores de eucalipto. A. Eixo X: dap (cm); eixo Y: resíduos percentuais dos diâmetros. B. Eixo X: dap (cm); eixo Y: resíduos percentuais do volume




Figura 2. Diâmetros médios reais e estimados pela RNA (D_i) em função da altura em diferentes partes do fuste (H_i)

demonstra que a diferença entre os valores reais e estimados é pequena, quase imperceptível para quase todo o perfil, o que corrobora com os fatos discutidos anteriormente.

Entretanto, percebe-se que houve uma oscilação maior do perfil para as árvores mais altas, o que pode ser justificado pelo fato de apenas algumas árvores atingem as maiores alturas, dificultando a modelagem.

Destaca-se ainda, que a utilização de RNA para modelagem de *taper* é uma alternativa muito promissora, pois não há necessidade de construir um modelo previamente especificado, assim como a modelagem por regressão, sendo esta uma grande vantagem operacional das RNA.

Conclusões

A modelagem de *taper* de árvores de eucalipto pode ser feita de maneira satisfatória utilizando diferentes configurações de redes neurais artificiais, variando o número de neurônios, as funções de ativação e parâmetros de treinamento.

Os algoritmos de aprendizagem Resilient Propagation e Quick Propagation são eficientes para a modelagem do afilamento de árvores de eucalipto, enquanto os algoritmos Scaled Conjugate Gradient, Levenberg Marquadt Algorithm, Simulated Annealing, Manhattan Update Rule e Algoritmos Genéticos não se mostraram apropriados para esta aplicação.

Redes neurais artificiais com configurações simples, contendo apenas 04 neurônios ocultos podem ser utilizadas em aplicações de *taper*.

Taxas de aprendizagem variando entre 01 e 04 são eficientes para modelagem do afilamento do fuste utilizando o algoritmo Quick Propagation.

As quatro variações básicas do algoritmo Resilient Propagation (RPROP+, RPROP-, iRPROP+, iPROP-) são apropriadas para aplicações de *taper*.

As funções de ativação tangente hiperbólica, sigmóide, log e seno podem ser utilizadas nas camadas ocultas e de saída. As funções linear e identidade não se mostraram apropriadas para a camada oculta.

Dois mil ciclos são suficientes para o treinamento das RNA para modelagem do afilamento do fuste.

Literatura Citada

Artero, A.O. Inteligência artificial: teórica e prática. 1.ed. São Paulo: Editora Livraria da Física, 2009. 230 p.

- Binoti, D.H.B.; Binoti, M.L. da S.; Leite, H.G. Configuração de redes neurais artificiais para estimação do volume de árvores. *Ciência da Madeira*, v.5, n.1, p.58-67, 2014. <<http://dx.doi.org/10.12953/2177-6830.v05n01a06>>.
- Binoti, M.L.M. da S. Emprego de redes neurais artificiais em mensuração e manejo florestal. Viçosa: Universidade Federal de Viçosa. 2012. 130 f. Tese Doutorado. <<http://www.bibliotecaflorestal.ufv.br/handle/123456789/9927>>. 17 Nov. 2014.
- 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. 54 f. Dissertação Mestrado. <<http://www.bibliotecaflorestal.ufv.br/handle/123456789/2865>>. 17 Nov. 2014.
- 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. 226 p.
- 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.
- Carvalho, A.M.; Nahuz, M.A.R. Valorização da madeira do híbrido *Eucalyptus grandis* x *urophylla* através da produção conjunta de madeira serrada em pequenas dimensões, celulose e lenha. *Scientia Forestalis*, n.59, p.61-76, 2001. <<http://www.ipef.br/publicacoes/scientia/nr59/cap05.pdf>>. 17 Nov. 2014.
- Demaerschaillk, J.P. Integrated systems for the estimations of tree *taper* and volume. *Canadian Journal of Forest Research*, v.3, n.1, p. 90-94, 1972.
- 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. 2ed. Porto Alegre: Bookman, 2001. 900p.
- Kovacs, Z.L. Redes neurais artificiais: fundamentos e aplicações. 2.ed. São Paulo: Colledium Cognition, 1996. 174p.
- Kozak, A.; Munro, D.D.; Smith, J.G.H. *Taper* functions and their applications in forest inventory. *Forestry Chronicle*, v.45, n.4, p.278-283, 1969.
- 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>>.
- Miguel, E.P.; Machado, S. do A.; Figueiredo Filho, A.; Arce, J.E. Modelos polinomiais para representar o perfil e o volume do fuste de *Eucalyptus urophylla* na região norte do estado de Goiás. *Revista Floresta*, v.41, n.2, p.355-368, 2011. <<http://dx.doi.org/10.5380/rf.v41i2.21883>>.
- Müller, M.D.; Salles, T.T.; Paciullo, D.S.C.; Brighenti, A.M.; Castro, R.T. de. Equações de altura, volume e afilamento para eucalipto e acacia estabelecidos em sistema silvipastoril. *Revista Floresta*, v.44, n.3, p.473-484, 2014. <<http://dx.doi.org/10.5380/rf.v44i3.33149>>.
- Ormerod, D.W. A simple bole model. *Forestry Chronicle*, v.49, n.3, p.136-138, 1973.
- 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>>.
- Pires, L.M.; Calegário, N. Ajuste de modelos estocásticos lineares e não-lineares para a descrição do perfil longitudinal de árvores. *Revista Árvore*, v.31, n.5, p.845-852, 2007. <<http://dx.doi.org/10.1590/S0100-67622007000500008>>.
- Russel, S.J.; Norvig, P. Inteligência artificial. 2.ed. Rio de Janeiro: Elsevier, 2004. 1021p.
- Schoeninger, E.R. Uso de redes neurais artificiais para mapeamento de biomassa e carbono orgânico no componente arbóreo de uma floresta ombrófila densa. Curitiba: Universidade Federal do Paraná. 2006. 130 p. Tese Doutorado. <<http://hdl.handle.net/1884/7884>>. 17 Nov. 2014.
- Silva, M.L.M.; Binoti, D.H.B.; Gleriani, J.M.; Leite, H.G. Ajuste do modelo de Schumacher e Hall e aplicação de redes neurais artificiais para estimar volume de árvores de eucalipto. *Revista Árvore*, v.33, n.6, p.1133-1139, 2009. <<http://dx.doi.org/10.1590/S0100-67622009000600015>>.
- Soares, C.P.B.; Paula Neto, F.; Souza, A.L. Dendrometria e inventário florestal. 1.ed. Viçosa: Editora UFV, 2006. 276p.
- Soares, F.A.A.M.N.; Flôres, E.D.; Cabacinha, C.D.; Carrijo, G.A.; Veiga, A.C.P. Recursive diameter prediction for calculating merchantable volume of *Eucalyptus* clones without previous knowledge of total tree height using artificial neural networks. *Applied Soft Computing*, v.12, n.8, p.2030-2039, 2012. <<http://dx.doi.org/10.1016/j.asoc.2012.02.018>>.
- Soares, T.H.; Carvalho, R.M.M.A.; Vale, A.B. do. Avaliação econômica de um povoamento de *Eucalyptus grandis* destinado a multiprodutos. *Revista Árvore*, v.27, n.5, p.689-694, 2003. <<http://dx.doi.org/10.1590/S0100-6762200300050001>>.
- Soares, T.S.; Leite, H.G.; Vale, A.B. do. Um modelo alternativo para a quantificação de multiprodutos em árvores individuais. *Revista Árvore*, v.28, n.6, p.875-882, 2004. <<http://dx.doi.org/10.1590/S0100-67622004000600012>>.