

Revista Brasileira de Ciências Agrárias

ISSN: 1981-1160

editorgeral@agraria.pro.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 prognose da produção de povoamentos
clonais de eucalipto

Revista Brasileira de Ciências Agrárias, vol. 10, núm. 4, 2015, pp. 532-537

Universidade Federal Rural de Pernambuco

Pernambuco, Brasil

Disponível em: <http://www.redalyc.org/articulo.oa?id=119043229008>

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

Configuração de redes neurais artificiais para prognose da produção de povoamentos clonais 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; danielhbbinoti@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 estudo foi definir configurações adequadas de Redes Neurais Artificiais (RNA) para prognose da produção florestal de plantios de eucalipto em nível de povoamento. Os dados foram obtidos a partir de inventários florestais contínuos e foram avaliadas diferentes configurações de RNA referentes ao número de neurônios na camada oculta, funções de ativação, número de ciclos e algoritmos de aprendizagem com os seus parâmetros. O treinamento das redes foi realizado no sistema Neuroforest. A avaliação das estimativas foi realizada 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. Obteve-se resultados satisfatórios com configurações simples de RNA, contendo apenas 03 neurônios na camada oculta. Todas as funções de ativação testadas (tangente hiperbólica, sigmoidal, identidade, log, linear e seno) podem ser utilizadas. O treinamento das RNA pode ser feito com 500 ciclos. Os algoritmos Resilient Propagation, Scaled Conjugate Gradient, Quick Propagation são eficientes para fins de prognose florestal. A prognose da produção de povoamentos clonais de eucalipto pode ser modelada por meio de diversas configurações de RNA.

Palavras-chave: crescimento e produção, inteligência artificial, neuroforest

Configuration of artificial neural network for prognosis the production of eucalyptus clonal stands

ABSTRACT

The objective of this study was to define appropriate configurations of Artificial Neural Networks (ANN) for prognosis of forest production of eucalyptus plantations at the stand level. Data were obtained from continuous forest inventory and were evaluated different settings of ANN for the number of neurons in the hidden layer activation function, number of cycles and learning algorithms with their parameters. The training of network was held at Neuroforest system. The evaluation of the estimates was performed using the correlation coefficient between observed and estimated values, the root mean square error (RMSE%) and graphical analysis of waste. Satisfactory results are obtained with simple configurations of ANN containing only 03 neurons in the hidden layer. All activation functions tested (hyperbolic tangent, sigmoid, identity, log, linear, sine) may be used. The training of RNA may be made with 500 cycles. The algorithms Resilient Propagation, Scaled Conjugate Gradient and Quick Propagation are efficient for the modeling of forest prognosis. The prognosis of production of eucalyptus clonal stands may be modeled using several ANN configurations.

Key words: growth and yield, artificial intelligence, neuroforest

Introdução

O gerenciamento adequado dos plantios florestais visa à produção contínua e eficiente de madeira. Questões relacionadas a quando, onde, como e quanto será a colheita dos produtos florestais são de primordial importância para planejar o abastecimento de indústrias e empresas florestais. No entanto, as informações relacionadas à produção fornecidas nos inventários florestais são associadas a um determinado instante no tempo. Isto implica a necessidade de estudos sobre crescimento e produção para avaliar o estoque atual, a produtividade do estoque em crescimento e a produção esperada em um determinado período no futuro (Oliveira et al., 2009).

Assim, a prognose da produção florestal é um dos três elementos principais do manejo, pois as decisões decorrentes do manejo florestal são influenciadas em grande parte pelas condições futura dos recursos.

O termo prognose refere-se a predição ou projeção do crescimento e da produção, ou seja, refere-se a descrição numérica do estoque futuro de crescimento e, ou colheita da madeira a partir de informações atuais (Binoti, 2010; Campos & Leite, 2013). Deste modo, é possível estimar a quantia de madeira que poderá ser retirada periodicamente para o suprimento adequado da indústria/empresa florestal.

A prognose em nível de povoamento é caracterizada por não explicar diretamente a variação do tamanho das árvores dentro do povoamento, ou seja, o volume estimado é dado em unidade de área, sendo que as estimativas do crescimento e, ou produção se dão a partir de características em nível de povoamento, tais como idade, área basal, índice de local, etc. (Campos & Leite, 2013). Como exemplos podem ser citados os modelos de Buckman (1962) e Clutter (1963).

Apesar da existência de vários modelos, muitas vezes o desempenho da prognose é limitado devido a restrições no banco de dados (Diamantopoulou, 2010). Outra limitação à modelagem é a continua inserção de novos clones nos plantios e a consequente exclusão de clones antigos, ocasionando o descarte de alguns dados. Além disso, pode-se destacar que diferentes modelos podem ser capazes de ajustar um mesmo banco de dados, cabendo ao manejador fazer a escolha assertiva com base em características como a qualidade do ajuste, consistência, flexibilidade, capacidade de generalização.

Alternativa interessante para a prognose da produção florestal é a modelagem por Redes Neurais Artificiais (RNA). As RNA podem ser definidas como modelos matemáticos compostos de unidades simples de processamento denominadas de neurônios artificiais, que são associadas a forças de conexão (pesos sinápticos) e armazenam o conhecimento adquirido do meio externo para disponibilizá-lo em aplicações semelhantes com dados desconhecidos (generalização) (Haykin, 2001; Braga et al., 2007).

A abordagem por RNA é muito atraente, pois esta técnica permite com facilidade a inclusão de variáveis na modelagem, o que não ocorre com modelos tradicionais de regressão. Deste modo, a inclusão de variáveis qualitativas, que retratam as condições ambientais, pode ser uma boa opção para modelagem com restrições no banco de dados.

Binoti (2010) utilizou RNA para fins de prognose em nível de povoamento e de árvore individual e constatou que as RNA são capazes de realizar a prognose da produção volumétrica em ambos os casos. Além disso, vários autores utilizaram RNA para prever estoques de produção de culturas agronômicas e obtiveram excelentes resultados (Fortin et al., 2010; Ahmadi et al., 2014; Rad et al., 2015). Esses resultados demonstram o potencial das RNA para projetar produções futura, bem como sua eficiência na aproximação de funções quando comparadas aos modelos de regressão tradicionais, como já foi demonstrado em diversas aplicações da ciência florestal (Silva et al., 2009; Binoti, 2010; Diamantopoulou & Milius, 2010; Leite et al., 2010; Özcelik et al., 2010; Rodrigues et al., 2010; Soares et al., 2011; Diamantopoulou, 2012; Binoti et al., 2013; Özcelik et al., 2013; Binoti et al., 2014).

Entretanto, as RNA possuem diversos algoritmos de aprendizagem, e podem ser estruturadas de diferentes formas levando-se em conta a quantidade de camadas e neurônios presentes na rede, bem como o tipo de função de ativação dos neurônios e os parâmetros específicos dos algoritmos de aprendizagem. Esses fatores estão diretamente relacionados a qualidade da resposta gerada pela rede, e por este motivo, a escolha de uma rede apta para solucionar um determinado problema pode demandar muito tempo devido ao número elevado de combinações possíveis dos atributos da RNA, uma vez que a definição da configuração adequada da RNA geralmente é feita de maneira empírica, através de tentativa e erro (Haykin, 2001; Braga et al., 2007; Artero, 2009).

Tendo em vista a importância da modelagem do crescimento e produção de povoamentos florestais, o potencial das RNA para esta aplicação e a dificuldade de definir RNA apropriadas diante das inúmeras possibilidades de combinação dos seus atributos, o objetivo do presente trabalho foi definir configurações adequadas de RNA para a prognose da produção florestal de plantios de eucalipto em nível de povoamento.

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.

As variáveis quantitativas foram: idade atual e futura (I1 e I2) (meses), área basal (B) em $m^2 \text{ ha}^{-1}$, altura dominante (Hd) em m, site (S) em m, volume atual e futuro (V1 e V2) em $m^3 \text{ ha}^{-1}$, precipitação (P) (mm). As variáveis qualitativas foram: projeto, clone, tipo de solo, espaçamento, relevo e textura. O número de classes das variáveis qualitativas foram 4, 9, 15, 6, 3 e 7, respectivamente. O volume futuro (V2) ($m^3 \text{ ha}^{-1}$) corresponde a variável de saída utilizada para o treinamento das RNA. As principais características descritivas das variáveis quantitativas estão apresentadas na Tabela 1.

Redes Neurais Artificiais

O número total de neurônios na camada de entrada foi igual a 52, sendo um neurônio para cada variável quantitativa e um para cada classe de variável qualitativa. As redes foram

Tabela 1. Análise descritiva das variáveis quantitativas utilizadas na configuração de Redes Neurais Artificiais para prognose da produção florestal de plantios de eucalipto em nível de povoamento no sul da Bahia

	Mínimo	Máximo	Média	Desvio-Padrão
Idade (meses)	21	137	65	±28
Precipitação (mm)	1179,49	1573,02	1414,42	±91,29
Altura dominante (m)	7,6	36,8	23,8	±6,1
Site (m)	14,9	37,6	27,8	±2,8
Área Basal ($m^2 ha^{-1}$)	1,1	45,4	17,5	±6,8
Volume ($m^3 ha^{-1}$)	12,1	1111,7	390,2	±210,4

constituídas com uma única camada oculta contendo até 48 neurônios ocultos. As camadas de saída das redes foram compostas de apenas um neurônio, pois a saída desejada corresponde apenas a uma variável (V2).

As funções de ativação utilizadas nas camadas ocultas e de saída foram: 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, a cada 0,001; e os valores do parâmetro momentum variaram de 0 a 1, a cada 0,0005. A taxa de aprendizagem utilizada para o algoritmo Manhattan Update Rule foi apenas 0,00001, pois este algoritmo necessita, por definição, de pequenas taxas de aprendizagem. O algoritmo Quick Propagation é sensível a altas taxas de aprendizagem, por isso utilizou-se taxas com valores baixos e altos, variando de 0,1 a 10,0 (a cada 0,1).

Os algoritmos Scaled Conjugate Gradient, Levenberg Marquardt apresentam apenas um tipo de configuração, pois não dependem de valores de parâmetros de treinamento. Para o algoritmo Resilient Propagation foram utilizadas as suas quatro variações básicas: RPROP+, RPROP-, iRPROP+, iPROP.

Para o treinamento das RNA utilizando a metaheurística Algoritmo Genético, que trata-se de um algoritmo inspirado em mecanismos de evolução natural e de genética, os parâmetros utilizados foram: valores de população variando de 50 a 1000 com intervalos de 50; valores de mutação com variações entre 0,1 e 0,5 a cada 0,1; e valores de cruzamento variando entre 0,05 a 0,70 a cada 0,05. A combinação desses parâmetros resultou em 114 configurações para o Algoritmo Genético.

Outra metaheurística utilizada para o treinamento foi a Simulated Annealing. Este algoritmo baseia-se em processos de recozimentos de sólidos utilizados em metalúrgicas, que consiste em um resfriamento térmico que inicia-se pela elevação de um metal a altas temperaturas, seguido pela diminuição gradativa e lenta da sua temperatura, até atingir o estado sólido e energia mínima. Os principais parâmetros deste algoritmo são o número de ciclos e os valores mínimos e máximos de temperatura, sendo que o número de ciclos variou de 100 a 1000 (a cada 100), com temperatura mínima igual a dois e temperatura máxima igual a 10.

O critério de parada do treinamento foi o número total de ciclos, com valores variando de 500 a 3000 (a cada 100), ou erro quadrático médio inferior a 1%, sendo que o treinamento foi finalizado ao atingir um destes critérios.

Foram analisadas 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. Para cada combinação foram geradas 100 RNA, sendo que os pesos iniciais de cada rede foram gerados aleatoriamente pelo software utilizado.

As configurações pré-selecionadas de RNA para análise foram avaliadas através da média e desvio-padrão dos erros médios quadráticos do treinamento das RNA geradas para cada configuração. Os testes foram realizados através do sistema NeuroForest, desenvolvido por Daniel H. B. Binoti, Mayra Luiza M. da S. Binoti e Hélio G. Leite, disponível gratuitamente no endereço eletrônico <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)

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

em que:

x' - valor normalizado

x_{\min} e x_{\max} - valores mínimo e máximo da variável, respectivamente

a - limite inferior da normalização (0)

b - limite superior da normalização (1)

Para as variáveis qualitativas utiliza-se a metodologia 1-de-N, que consiste em uma representação binária dos dados.

Avaliação das estimativas

A avaliação da prognose desempenhada pelas RNA foi realizada utilizando os seguintes critérios: coeficiente de correlação (r_{yy}) entre os valores observados e estimados do volume futuro (Eq. 2), a raiz quadrada do erro quadrático médio (RMSE%) (Eq. 3), e análise gráfica de resíduos.

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

em que:

s^2 - variância

cov - covariância

y - volume futuro observado

\hat{y} - volume futuro estimado

O coeficiente de correlação pode ser utilizado como um apontador relativo do grau de ajustamento para modelos não lineares, sendo que possui amplitude entre -1 e 1, e quanto mais próximo de 1 melhor pode ser considerado o ajuste dos dados.

O RMSE% mede o desempenho global do ajuste, e segundo Campos & Leite (2013), quanto menores as estimativas do RMSE%, mais confiável é o modelo ajustado.

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

em que:

n - valor total dos dados

\bar{y} - média dos valores observados

Os erros de tendência que não são detectados por estatísticas que medem a precisão, podem ser visualizados através da análise gráfica de resíduos (Campos & Leite, 2013). A avaliação residual consistiu na dispersão dos erros percentuais em relação aos valores observados (Eq. 4).

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

Resultados e Discussão

O total de configurações de RNA treinadas foi igual a $2,49 \cdot 10^{11}$. Ressalta-se que as RNA testadas foram executadas através de um script contendo todas as configurações. Em razão do extenso número de redes treinadas foram avaliadas apenas as configurações que apresentaram erro médio quadrático inferior a 1%.

Os valores atribuídos aos pesos iniciais para o processo de treinamento das RNA foram aleatórios. Tais valores estão relacionados com o processo de busca, uma vez que eles interferem no tempo e na qualidade do treinamento (Carvalho, 2014), além de definir a região do espaço de solução que será explorada. Entretanto, a análise da média e do desvio-padrão do erro das redes treinadas para cada configuração, indicou que as redes avaliadas não sofreram forte influência do valor dos pesos, uma vez que o desvio-padrão foi relativamente baixo para a maioria das configurações testadas. Assim, pode-se ressaltar que a qualidade do ajuste de uma RNA está fortemente relacionada à escolha adequada dos elementos que formam a configuração da rede.

As redes treinadas com os algoritmos Levenberg Marquadt Algorithm, Simulated Annealing, Manhattan Update Rule e Algoritmos Genéticos não apresentaram resultados satisfatórios, sendo que algumas dessas configurações não convergiram ou apresentaram resultados extremamente tendenciosos. Esses resultados aliados aos resultados encontrados por Binoti et al. (2014), que também utilizaram estes algoritmos para estimativas de volume de povoamentos florestais, indicam que tais algoritmos podem não ser apropriados para algumas estimativas florestais como prognose florestal e estimação volumétrica.

Os algoritmos Quick Propagation, Resilient Propagation e Scaled Conjugate Gradient apresentaram bom desempenho para o treinamento das RNA. Estes algoritmos apresentaram resultados satisfatórios para as redes treinadas com no mínimo 03 neurônios na camada oculta. Binoti et al. (2014) encontraram resultados semelhantes para os algoritmos Quick Propagation e Resilient Propagation na estimativa do volume

de árvores de eucalipto, mas não encontraram configurações de RNA adequadas utilizando o algoritmo Scaled Conjugate Gradient. Esses resultados demonstram que um algoritmo de aprendizagem pode ocasionar um excelente treinamento para uma determinada aplicação e ser ineficaz para outro tipo de aplicação, fazendo-se necessária a definição adequada de configurações de RNA para cada tipo de problema.

Para o algoritmo Quick Propagation, as configurações que apresentaram bom desempenho foram treinadas com taxas de aprendizagem a partir de 0,1 até 5,0. De acordo com Braga et al. (2007) e Binoti et al. (2014), o algoritmo Quick Propagation permite a utilização de altas taxas de aprendizagem sem ocasionar instabilidade no sistema.

Entretanto, foi observado que as redes treinadas com poucos neurônios apresentaram bom desempenho com taxas de aprendizagem mais baixas, enquanto as redes que foram treinadas com um número maior de neurônios foram capazes de tolerar taxas mais altas. Essa relação pode ser explicada pelo papel que o número de neurônios e a taxa de aprendizagem assumem no treinamento das RNA. De acordo com Haykin (2001), os neurônios ocultos são capazes de extrair estatísticas de ordem elevada. Assim, um número maior de neurônios ocultos pode tornar a rede mais robusta e melhorar o seu desempenho. A taxa de aprendizagem está relacionada com o controle da velocidade de atualização dos pesos durante o treinamento (Artero, 2009; Carvalho, 2014), sendo que quanto menor a taxa de aprendizagem, mais explorado será o espaço de soluções, fazendo com que a rede tenha maior chance de encontrar uma boa resposta, mesmo com poucos neurônios ocultos. Porém, cabe ressaltar que taxas muito pequenas podem tornar o processo de aprendizagem lento. A utilização de taxas de aprendizagem maiores que 5,0 ocasionou resultados tendenciosos e algumas configurações não convergiram.

Não houve diferenças entre as quatro variações do algoritmo Resilient Propagation: RPROP+, RPROP-, iRPROP+ e iPROP+. Isto indica que todas estas variações podem ser utilizadas no treinamento de RNA para fins de prognose florestal.

Para o algoritmo Error Backpropagation, as melhores configurações encontradas possuíam no mínimo três neurônios ocultos, taxa de aprendizagem igual a 0,001 e valores de momentum inferiores a 0,01. Entretanto, foi observado que este algoritmo é mais sensível às variações dos seus parâmetros, quando comparado aos algoritmos Quick Propagation, Resilient Propagation e Scaled Conjugate Gradient. Deste modo, a utilização do algoritmo Error Backpropagation para fins de prognose florestal apresenta desvantagem em relação aos algoritmos citados anteriormente, devido a maior dificuldade para encontrar configurações adequadas. Contudo, ressalta-se que este algoritmo também pode apresentar bons resultados para esta aplicação, conforme demonstrado por Binoti (2010).

Todas as funções de ativação testadas apresentaram bom desempenho para o treinamento das RNA. Em relação ao número de ciclos, verificou-se que apenas 500 ciclos foram suficientes para o treinamento das redes. A definição da quantidade de ciclos para o treinamento é importante, pois assim como o número de neurônios ocultos, o número de ciclos

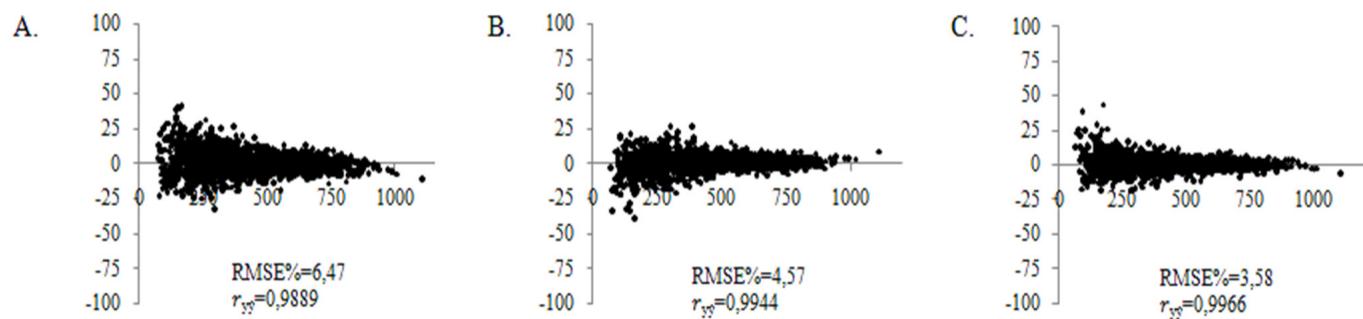


Figura 1. Gráficos de dispersão de resíduos (eixo x: volume futuro observado (m^3/ha); eixo y: resíduos percentuais). Configuração básica das RNA: algoritmo de treinamento Scaled Conjugate Gradient, função de ativação dos neurônios ocultos e de saída: tangente hiperbólica. A: RNA com 4,0 neurônios ocultos; B: RNA com 8,0 neurônios ocultos; C: RNA com 20,0 neurônios ocultos

está diretamente relacionado com a possibilidade de ocorrência dos problemas denominados underfitting e overfitting. Assim, poucos ciclos podem resultar em um treinamento insuficiente para o processo de aprendizagem (underfitting) e o excesso de ciclos pode ocasionar a memorização dos dados de treinamento e baixa capacidade de generalização (overfitting) (Bullinaria, 2014).

Na Figura 1 é exemplificado o desempenho do treinamento de três RNA com configurações semelhantes, divergindo apenas na quantidade de neurônios da camada oculta. A análise de resíduos, do RMSE% e da correlação demonstram que houve uma ligeira melhora no treinamento com 8,0 neurônios ocultos (Figura 1B) em relação ao treinamento com 4,0 neurônios ocultos (Figura 1A). Entretanto, não houve muita diferença em termos de qualidade do ajuste para as configurações com 8,0 e 20,0 neurônios ocultos (Figura 1C).

Diante desses resultados, cabe ressaltar que as redes neurais com configurações mais simples devem ser preferidas, desde que sejam capazes de realizar um treinamento adequado para os dados, para evitar o overfitting e para otimizar o tempo do treinamento, uma vez que o tempo de treinamento está relacionado com a complexidade da rede. Além disso, um número menor de neurônios facilita o processo de busca e de otimização para um determinado problema (Bullinaria, 2014).

Binoti (2010) encontrou redes neurais adequadas para projetar o volume de povoamentos florestais com configurações simples (em relação ao número de neurônios ocultos). Neste mesmo trabalho, o autor também comprovou a eficiência da aplicação de redes neurais para fins de prognose através dos excelentes resultados encontrados no treinamento e generalização, ressaltou que a dispersão de resíduos se mostrou apropriada quando comparada a resultados encontrados por Oliveira et al. (2009) para a mesma área, e evidenciou a capacidade de estratificação das RNA, demonstrando que uma única rede é capaz de modelar a tendência de diferentes materiais genéticos.

A habilidade de estratificação das RNA já foi comprovada para esta e para outras aplicações da área florestal (Silva et al., 2009; Binoti, 2010; Leite et al., 2010; Gorgens et al., 2014), caracterizando uma grande vantagem operacional frente aos clássicos modelos de regressão comumente utilizados.

A aptidão das RNA para resolução de problemas florestais corrobora a necessidade da definição de configurações adequadas de RNA para a utilização da técnica. Os resultados

encontrados neste trabalho demonstram que embora a modelagem por RNA seja promissora, o manejador deve ser criterioso na escolha de configurações adequadas para não incorrer em erros de ajustes oriundos da utilização inadequada de algoritmos ou outros elementos essenciais para o treinamento das redes.

Além disso, os resultados aqui apresentados também fornecem subsídios para a utilização de RNA para fins de prognose florestal, indicando configurações com maior afinidade para esta aplicação.

Conclusões

A prognose da produção de povoamentos clonais de eucalipto pode ser modelada através de diversas configurações de redes neurais artificiais.

Os algoritmos de aprendizagem Resilient Propagation, Quick Propagation e Scaled Conjugate Gradient são eficientes para modelagem do crescimento e produção de povoamentos de eucalipto. Os algoritmos 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 03 neurônios ocultos, podem ser utilizadas para fins de prognose da produção florestal.

Taxas de aprendizagem variando entre 0,1 e 4,0 são eficientes para fins de prognose utilizando o algoritmo Quick Propagation.

As quatro variações básicas do algoritmo Resilient Propagation (RPROP+, RPROP-, iRPROP+, iPROP-) são apropriadas para prognose da produção de povoamentos clonais de eucalipto.

As funções de ativação tangente hiperbólica, sigmóide, log, seno, linear e identidade podem ser utilizadas para o treinamento de RNA em aplicações de prognose florestal em povoamentos de eucalipto.

Literatura Citada

- Ahmadi, S. H.; Sepaskhah, A. R.; Andersen, M. N.; Plauborg, F.; Jensen, F. Modeling root length density of field grown potatoes under different irrigation strategies and soil textures using artificial neural networks. *Field Crops Research*, v.162, p.99-107, 2014. <<http://dx.doi.org/10.1016/j.fcr.2013.12.008>>.

- Artero, A. O. Inteligência artificial: teoria 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, D. H. B.; Binoti, M. L. da S.; Leite, H. G.; Silva, A. Redução dos custos em inventário de povoamentos equiâneos. Revista Brasileira de Ciências Agrárias, v.8, n.1, p.125-129, 2013. <<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. 54 f. Dissertação Mestrado.
- 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.
- Buckman, R. E. Growth and yield of red pine in Minnesota. Washington, DC: USDA, 1962. 50p.
- 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. P. de L. F. de. Redes neurais artificiais. <<http://www.icmc.usp.br/~andre/research/neural/>>. 20 Nov. 2014.
- Clutter, J. L. Compatible growth and yield models for loblolly pine. Forest Science, v.9, n.3, p.354-371, 1963.
- 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. Filling gaps in diameter measurements on standing tree boles in the urban forest of Thessaloniki, Greece. Environmental Modelling & Software, v.25, n.12, p.1857-1865, 2010. <<http://dx.doi.org/10.1016/j.envsoft.2010.04.020>>.
- Diamantopoulou, M. J.; Miliotis, E. Modelling total volume of dominant pine trees in reforestation 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>>.
- Fortin, J. G.; Anctil, F.; Parent, L. A neural network experiment on the site-specific simulation of potato tuber growth in Eastern Canada. Computers and Electronics in Agriculture, v.73, n.2, p.126-132, 2010. <<http://dx.doi.org/10.1016/j.compag.2010.05.011>>.
- Gorgens, E. B.; Leite, H. G.; Gleriani, J. M.; Soares, C. P. B.; Ceolin, A. Influência da arquitetura na estimativa de volume de árvores individuais por meio de redes neurais artificiais. Revista Árvore, v.38, n.2, p.289-295, 2014. <<http://dx.doi.org/10.1590/S0100-67622014000200009>>.
- Haykin, S. Redes Neurais: princípios e prática. 2.ed. Porto Alegre: Bookman, 2001. 900p.
- 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>>.
- Oliveira, M. L. R. de; Leite, H. G.; Nogueira, G. S.; Campos, J. C. C. Modelagem e prognose em povoamentos não desbastados de clones de eucalipto. Revista Árvore, v.33, n.5, p.841-852, 2009. <<http://dx.doi.org/10.1590/S0100-67622009000500007>>.
- 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 networks models. Forest Ecology and Management, v.306, p.52-60, 2013. <<http://dx.doi.org/10.1016/j.foreco.2013.06.009>>.
- Rad, M. R. N.; Koohkan, S.; Fanaei, H. R.; Rad, M. R. P. Application of artificial neural networks to predict the final fruit weight and random forest to select important variables in native population of melon (*Cucumis melo* L.). Scientia Horticulturae, v.181, p.108-112, 2015. <<http://dx.doi.org/10.1016/j.scientia.2014.10.025>>.
- 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>. 26 Fev. 2015
- 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, 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 Electronics in Agriculture, v.78, n.1, p.19-27, 2011. <<http://dx.doi.org/10.1016/j.compag.2011.05.008>>.