

Comitê de redes neurais artificiais para estimação do volume individual de árvores de *Eucalyptus*

Daniel Dantas^{1*}, Taiana Guimarães Arriel¹, Natalino Calegario¹, Wilian Soares Lacerda²

Resumo

Com o avanço de programas computacionais e a difusão da Inteligência Computacional, as redes neurais artificiais (RNA) têm sido utilizadas como alternativa para a modelagem e prognose da produção florestal. Objetivou-se com este trabalho avaliar o desempenho de uma rede neural artificial e um comitê de redes neurais artificiais na estimação do volume individual de árvores de eucalipto. Foram utilizados dados de povoamentos de *Eucalyptus* spp., oriundos de nove clones, distribuídos em 28 talhões. As RNA foram obtidas por meio de dez sessões de treinamento e, em cada sessão, foi retida a melhor. As redes foram do tipo *Multilayer Perceptron*, com 1 camada oculta. O número de neurônios na camada oculta foi definido de forma automatizada pelo *software Statisticae* foi utilizado o algoritmo *back propagation*. A função de ativação utilizada foi a logística; taxa de aprendizagem de 0,001 e o termo de momentum 0,5. Como resultado, foi observado que a utilização do comitê conseguiu reduzir o erro relativo médio das dez RNA, que passou de, em média, 4,30% para 1,49%. As estimativas de volume obtidas pelo comitê de redes neurais artificiais apresentaram erro relativo médio inferior ao apresentado pelas estimativas de volume da melhor rede isolada, que foi de 1,73%. O comitê de RNA se mostra aplicável aos processos de estimação de volume individual de fustes, apresentando bom desempenho.

Palavras-chave: inteligência computacional; modelagem e prognose; produção florestal.

Artificial neural networks committee in the estimation of the individual volume of *Eucalyptus* trees

Abstract

With the advancement of computer programs and the diffusion of Computational Intelligence, artificial neural networks (ANNs) have been used as an alternative for the modeling and prognosis of forest production. The objective of this work was to evaluate the performance of an artificial neural network and a committee of artificial neural networks in the estimation of the individual *Eucalyptus* trees volume. Data from *Eucalyptus* spp. stands were used, from nine clones distributed in 28 plots. ANNs were obtained through ten training sessions and in each session was retained the best one. The networks were of the Multilayer Perceptron type, with 1 hidden layer. The number of neurons in the hidden layer was defined in an automated way by the Statistica software and the back propagation algorithm was used. The activation function used was logistics; learning rate of 0.001 and the term momentum 0.5. As a result, it was observed that the use of the committee managed to reduce the average relative error of the ten ANNs, which changed from an average of 4.30% to 1.49%. The volume estimates obtained by artificial neural networks committee presented an average relative error lower than that presented by the volume estimates for the best isolated network, which was 1.73%. The ANNs committee is shown to be applicable to the processes of estimation of individual volume of shafts, presenting good performance.

Keywords: Computational intelligence; modeling and prognosis; forest production.

¹Departamento de Ciências Florestais, Universidade Federal de Lavras, Lavras - MG, Brasil, Campus Universitário, Caixa Postal 3037.

²Departamento de Ciência da Computação, Universidade Federal de Lavras, Lavras-MG, Brasil, Campus Universitário, Caixa Postal 3037.

*Autor para correspondência: dantasdaniel12@yahoo.com.br

Introdução

Uma das informações de maior importância para o conhecimento do potencial de uma floresta, em uma dada região, é a variável volume, sendo imprescindível a sua quantificação acurada no planejamento do manejo de florestas. O volume individual serve como ponto de partida para a avaliação do conteúdo de madeira em um povoamento florestal (Cordeiro et al., 2015) e fornece subsídios para as decisões relacionadas a tratamentos silviculturais, colheita e transporte da madeira. Sendo assim, é fundamental que a obtenção do volume total ou em determinadas partes do tronco de árvores seja realizada corretamente, representando a população amostrada.

Com o avanço de programas computacionais e a difusão da Inteligência Computacional, as redes neurais artificiais (RNAs) têm sido utilizadas como alternativa aos modelos hipsométricos e volumétricos, para a modelagem e prognose da produção florestal. Segundo Braga et al. (2007), uma rede neural artificial é um processador constituído de unidades de processamento simples (neurônios artificiais), baseado em neurônios encontrados no cérebro humano, que calculam determinadas funções. Essas unidades estão distribuídas em camadas e conectadas entre si por pesos que armazenam o conhecimento experimental e ponderam as entradas de cada unidade. Com isso, o conhecimento adquirido torna-se disponível para uso. As características que mais chamam a atenção nas RNAs são a capacidade de aprender e a de generalizar o conhecimento assimilado para um conjunto de dados desconhecidos. Outra característica interessante das RNAs é a capacidade de extrair informações não explícitas de um conjunto de dados que lhe são fornecidos como exemplos (Bishop, 1995; Silva et al., 2010; Choudhury et al., 2012; Ozsahine Murat, 2018).

Segundo Oliveira et al. (2010), o uso de comitês de redes neurais artificiais agrega e combina o conhecimento adquirido, tendo por objetivo atingir um resultado final hipoteticamente melhor que o obtido por qualquer rede neural especialista separadamente. O uso de comitês de redes neurais artificiais tem sido estudado em diversas áreas como engenharia de sistemas e computação (Nascimento e Coelho, 2009); medicina (Santos et al., 2006; Botelho et al., 2010); ciências econômicas (Bialoskorski Neto et al., 2006), dentre outras. Porém, a utilização desses comitês ainda é pouco difundida na área florestal e, principalmente, para solução de problemas de regressão.

Devido à importância do conhecimento e da estimação do volume individual de fustes para melhor gerenciar e manejar populações florestais, são necessários estudos que forneçam subsídios para o manejador no processamento de dados de inventário florestal de forma mais otimizada e eficiente, incluindo a utilização de redes neurais artificiais. Assim, o objetivo principal deste trabalho foi avaliar o desempenho da utilização

de redes neurais artificiais e de um comitê de redes neurais artificiais para estimação do volume individual de árvores de eucalipto.

Materiais e métodos

Os dados utilizados neste estudo foram provenientes de medições realizadas por meio de cubagem, em inventários florestais realizados nos anos de 2013 e 2014, com árvores de idades entre 4 e 11 anos, compostos por 4 projetos e 9 clones de *Eucalyptus* spp. A amostragem foi feita em 2.500 árvores. Em cada árvore foram medidos o DAP (diâmetro a 1,30 m de altura da base da árvore, em centímetros); o diâmetro em diversas alturas das árvores; a Ht (altura total, em metros); e, posteriormente, foram calculados os volumes individuais pelo método de Smalian (Campos; Leite, 2009).

Visando à obtenção de redes neurais artificiais para estimação do volume total das árvores, procedeu-se ao seu treinamento. Esse procedimento consiste no ajuste de seus pesos, por meio de um algoritmo de aprendizagem que busca identificar algum padrão nos dados fornecidos, e tem por objetivo gerar uma rede que desempenhe a tarefa de interesse (Binoti et al., 2014). O treinamento foi realizado no software *Statistica* v.10 (Statsoft, 2014), por meio da ferramenta *Statistica Neural Networks (SNN)*. Todas as redes utilizadas foram do tipo *Multilayer Perceptron*, com 1 camada oculta. A escolha do número de neurônios na camada oculta da rede foi feita de forma automatizada pela ferramenta *SNN*, que testa diversas quantidades de neurônios, e o algoritmo utilizado foi o *back propagation*. A função de ativação utilizada foi a logística (ou sigmoideal) com um intervalo de 0 a 0,9. A taxa de aprendizado foi definida como 0,001 e o termo momentum como 0,5.

Foram realizadas 10 sessões de treinamento, tendo o volume como variável dependente e, como variáveis independentes, as variáveis contínuas: DAP, Ht e idade e as variáveis categóricas: clone e espaçamento, incluídas de forma nominal. Os clones foram identificados por seus nomes e foi atribuída uma letra para cada espaçamento, com o intuito de proporcionar à RNA a possibilidade de diferir os diferentes extratos que compõem o plantio. Em cada sessão foram treinadas 10.000 redes neurais artificiais pelo software, sendo que, ao final da sessão, foi feito o rastreamento e restauração da melhor rede com base nos desempenhos nas fases de treinamento, teste e validação. A cada época a ordem de apresentação dos dados à rede foi alterada, sendo 600 o número máximo de épocas no treinamento de cada rede. A condição de parada do treinamento foi a mínima melhoria do erro nas fases de treinamento, teste e validação ou o número máximo de épocas. Os valores iniciais dos pesos foram definidos de forma aleatória pela ferramenta *SNN*.

Os dados foram divididos em dois grupos, sendo 50% para treinamento das redes e 50% para generalização. Dentre os dados destinados ao treinamento da rede, 60% foram utilizados na fase de treino, em que são ajustados os pesos das conexões; 20% na fase de validação e 20% na fase de teste da rede, para avaliar a performance da rede com dados que não foram previamente utilizados na fase de treino. A validação cruzada foi utilizada como método de reamostragem dos dados, o que implica que a cada k épocas, os conjuntos de dados de treino, teste e validação eram trocados de forma automatizada pelo software.

Ao final das 10 sessões de treinamento, as dez melhores redes foram salvas e utilizadas para estimação do volume individual das árvores que compunham o banco de dados destinado à generalização das RNA obtidas. Essas árvores já possuíam o volume observado, mas não haviam sido utilizadas nas fases de treinamento, teste e validação.

Um comitê de RNA consiste na utilização de um conjunto de RNA, com arquiteturas diferentes ou pesos diferentes atribuídos às variáveis, para resolução de um problema (Oliveira *et al.*, 2010). Assim, para cada observação do conjunto destinado para generalização, calculou-se a média aritmética dos volumes estimados pelas dez redes neurais artificiais obtidas e, com o intuito de comparar o desempenho da utilização de uma RNA ou de um comitê de RNA, compararam-se as estimativas de volume pelo comitê e pela melhor RNA com os valores observados, com base nos valores de erro relativo médio (ERM) (Equação 1; em que: ERM: erro relativo médio (%); Vobs: volume observado (m^3) e Vest: volume estimado (m^3)), gráficos de dispersão dos resíduos e coeficientes de correlação. Foram calculados o *bias* (Equação 2); em que: número de amostras; Vobs: volume observado (m^3) e Vest: volume estimado (m^3)), que captura a ideia de erro sistemático para uma dada amostra, e a raiz do erro quadrático médio (REQM) (Equação 3; em que: REQM: raiz do erro quadrático médio (%); Vobs: volume observado (m^3); Vest: volume estimado (m^3); n: número de amostras e Vmed: média dos volumes observados (m^3)), que mostra a dimensão do erro de uma determinada estimativa (Siipilehto, 2000; Leite *et al.*, 2002).

$$ERM (\%) = \frac{(Vobs - Vest)}{Vobs} * 100 \text{ (Eq. 1)}$$

$$bldv = 100 * \frac{1}{n} * \sum_{i=1}^n \left[\frac{(Vob - Vest)}{Vobs} \right] \text{ (Eq. 2)}$$

$$REQM = \left[\sqrt{\frac{\sum_{i=1}^n (Vobs - Vest)^2}{n}} / Vmed \right] * 100 \text{ (Eq. 3)}$$

O teste F de Graybill (Graybill, 1976) (Equação 4), para comparação entre as previsões da rede e do comitê e os valores reais, utiliza os coeficientes gerados pela equação (5). Em que: $\hat{\beta}_0$; $\hat{\beta}_1$: parâmetros estimados do modelo (5); y : variável observada; x : parâmetros do modelo; \hat{y} : variável estimada; ε : erro aleatório.

$$F (H_0) = \frac{\left(\begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \end{bmatrix} - \begin{bmatrix} 0 \\ 1 \end{bmatrix} \right)' \begin{bmatrix} n & \sum x \\ \sum x & \sum x^2 \end{bmatrix}^{-1} \left(\begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \end{bmatrix} - \begin{bmatrix} 0 \\ 1 \end{bmatrix} \right)}{2 * QM_{Res}} \text{ (Eq. 4)}$$

$$Y = \beta_0 + \beta_1 x + \varepsilon \text{ (Eq. 5)}$$

Resultados e discussão

O número de neurônios nas camadas intermediárias das 10 redes neurais artificiais obtidas com as sessões de treinamento variou entre 8 e 17. A descrição e as estatísticas das redes neurais obtidas, geradas pelo software ao final dos treinamentos, do tipo *Multilayer Perceptron (MLP)* e do comitê de redes são apresentadas na Tabela 1.

De forma geral, os valores das medidas de erro observados nas fases de treinamento, teste e validação foram inferiores a 0,0068 m^3 , o que demonstra a eficiência das redes neurais artificiais em detectar padrões de comportamento a partir dos dados que lhes foram apresentados. Os coeficientes de correlação entre os volumes estimados pelas redes e os valores observados, utilizados na fase de teste, apresentaram-se acima de 0,95. Valores semelhantes de coeficientes de correlação foram observados por Binoti *et al.* (2013) e Cordeiro *et al.* (2015) em estudos sobre a eficiência de redes neurais artificiais na estimação de altura e volume total de árvores, respectivamente. A média de erro médio absoluto (EMA) entre todas as RNA foi de 0,0136. A rede com o melhor desempenho no treinamento com EMA de 0,0014 foi a rede 10, cuja arquitetura é 5-10:1, ou seja, 5 variáveis de entrada, 10 neurônios na camada escondida e um neurônio na camada de saída. A rede com o maior EMA, 0,0343, foi a rede 1, que possui a mesma arquitetura. A diferença entre essas duas redes está nos pesos e na importância atribuída a cada variável pelo software. A melhor rede definiu como mais importante a variável DAP, enquanto a pior, dentre as dez, atribuiu essa maior importância à altura. Leal *et al.* (2015), em trabalho para estimação de volume total de árvores por redes neurais, obtiveram desempenho de redes neurais na predição volumétrica de fustes com resultados superiores aos advindos de equações de regressão, atestando assim a eficiência das redes na estimação de caracteres dendrométricos.

Tabela 1 – Medidas estatísticas utilizadas para verificar a qualidade do ajuste das redes neurais selecionadas em cada sessão de treinamento

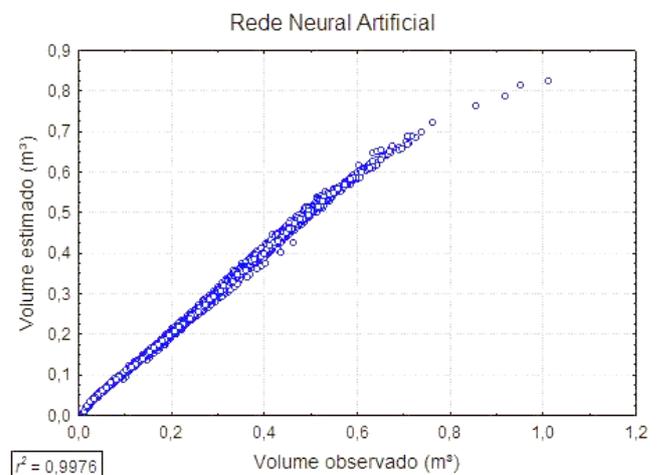
NR	Arq (e-n-s)	ERRO						R
		TRE	VAL	TES	ERM	DP	EMA	
1	5-10:1	0,0040	0,0047	0,0038	3,14	0,0577	0,0343	0,95
2	5-9:1	0,0058	0,0049	0,0053	-0,11	0,0066	0,0046	0,99
3	5-12:1	0,0040	0,0048	0,0040	-1,80	0,0344	0,0191	0,96
4	5-11:1	0,0064	0,0052	0,0068	-1,53	0,0319	0,0197	0,97
5	5-15:1	0,0040	0,0033	0,0025	-0,94	0,0233	0,0129	0,98
6	5-17:1	0,0048	0,0033	0,0032	-1,07	0,0316	0,0156	0,97
7	5-15:1	0,0047	0,0030	0,0027	0,41	0,0090	0,0054	0,99
8	5-13:1	0,0031	0,0020	0,0032	-1,67	0,0376	0,0182	0,96
9	5-8:1	0,0047	0,0051	0,0040	0,16	0,0075	0,0046	0,99
10	5-10:1	0,0025	0,0017	0,0028	0,03	0,0019	0,0014	0,99
Comitê	-	0,0044	0,0038	0,0038	1,08	0,0242	0,0136	0,99

NR: Número da rede neural; Arq: Arquitetura da rede neural; e: número de variáveis de entrada; n: número de neurônios na camada escondida; s: número de saídas da rede; TRE: treinamento; VAL: validação; TES: teste; ERM: erro relativo médio (%); DP: desvio padrão; EMA: erro médio absoluto (Vobs-Vest); r: coeficiente de correlação.

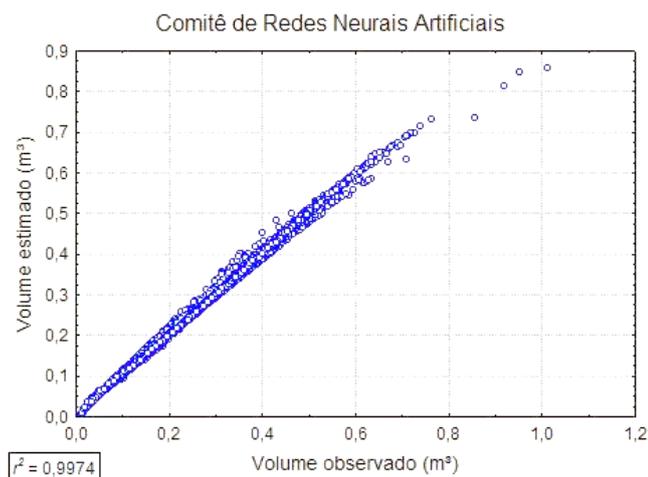
Considerando a utilização das redes neurais artificiais para a estimação da variável volume em um conjunto de dados ainda desconhecido pelas mesmas, verificou-se desempenho satisfatório, visto que todas apresentaram erros relativos médios (ERM) inferiores a 10%, usualmente requerido no processamento de inventários florestais. O ERM verificado entre todas as 10 redes foi de 4,30%. A rede com o melhor desempenho na generalização foi a mesma com o melhor desempenho no treinamento, com um ERM de 1,73%, sendo composta por 10 neurônios na camada intermediária. Já a rede com o pior desempenho na generalização (ERM de 7,49%) foi a rede 3, composta por 12 neurônios na camada intermediária, não sendo a mesma com o pior desempenho no treinamento.

A utilização do comitê conseguiu reduzir o ERM para 1,49%. As estimativas de volume obtidas pelo comitê de RNA apresentaram ERM inferior ao apresentado pelas estimativas de volume pela melhor RNA obtida, que foi de 1,73%. No entanto, pelo teste F de Graybill, as estimativas, da rede e do comitê, não apresentaram diferença estatística com relação aos valores observados a um nível de significância de 5% ($8,56E-07$ e $5,79E-05$, respectivamente). Os gráficos de correlação entre os valores estimados e observados pela melhor rede e pelo comitê são apresentados na Figura 1.

Figura 1 – Volume observado versus volume estimado pela melhor rede e pelo comitê de redes neurais

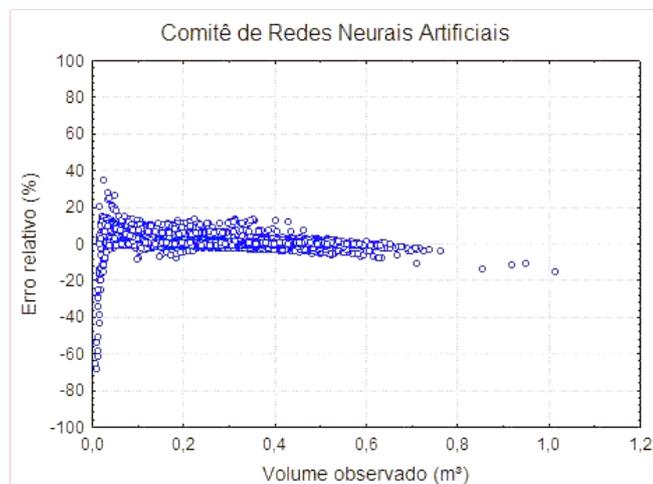


As redes neurais artificiais apresentaram desempenho satisfatório na estimação do volume individual das árvores estudadas. Os gráficos indicam uma forte correlação entre os valores estimados e observados, tanto pela melhor RNA, quanto pelo comitê de RNA. Os coeficientes de determinação foram altos para ambos, 0,9976 para a RNA e 0,9974 para o comitê, indicando que as estimativas estão, em grande parte, coincidentes com os valores desejados.



Os resíduos apresentaram-se concentrados próximos a zero, como é demonstrado pelo gráfico de sua dispersão na Figura 2. Verifica-se uma tendência de maiores erros, tanto de subestimação quanto superestimação, para os menores valores de volume, e de superestimação para os maiores, mas principalmente no comitê, em que se verifica um leve aumento na amplitude dos erros nos valores extremos de volume.

Figura 2 – Dispersão de resíduos obtidos para a melhor rede neural artificial e o comitê de redes na estimação de volume de árvores



Referências

- Bialoskorski Neto, S.; Nagano, M. S.; Moraes, M. B. C. 2006. Utilização de redes neurais artificiais para avaliação socioeconômica: uma aplicação em cooperativas. *Revista de Administração* 41: 59-68.
- Bishop, C. M. 1995. *Neural Networks for Pattern Recognition*. Oxford University Press, NY, USA.
- Binoti, M. L. M. S.; Binoti, D. H. B.; Leite, H. G. 2013. Aplicação de redes neurais artificiais para estimação da altura de povoamentos equiâneos de eucalipto. *Revista Árvore* 37: 639-645. Doi: <http://dx.doi.org/10.1590/S0100-67622013000400007>.

O REQM e o *bias* mostraram-se bastante próximos, considerando a rede neural artificial e o comitê. O REQM foi de 2,03% para a rede e 2,08% para o comitê. O *bias* foi de -0,03% para a rede e -0,18% para o comitê, indicando uma maior tendência de superestimação dos valores de volume pelo comitê.

Pode-se inferir, portanto, que o comitê de redes neurais artificiais permite redução dos erros relativos nas estimativas de volume e pode ser usado com o objetivo de melhoria na utilização de redes neurais artificiais para diversas aplicações. No entanto, no caso da utilização de um comitê de redes para aproximação de funções, como é o caso da estimação de volume, essa melhoria não foi tão expressiva se comparada com a utilização de uma única rede neural artificial. A utilização do comitê pode apresentar uma maior eficiência para problemas do tipo classificação, agrupamento e séries temporais. Além disso, deve-se considerar o aumento do custo computacional necessário para se obter um comitê de redes neurais artificiais, devido à necessidade de realização de vários treinamentos, sendo uma única rede neural artificial perfeitamente aplicável para a estimação do volume de árvores de eucalipto.

Conclusão

A utilização de um comitê de redes conseguiu reduzir o erro relativo médio das estimativas de volume, no entanto, a diferença de desempenho entre o comitê e uma única rede neural artificial não foi significativa. Assim, uma única rede neural artificial é perfeitamente aplicável ao problema, com desempenho satisfatório e menor custo operacional.

Agradecimentos

Os autores expressam seus agradecimentos aos professores envolvidos no trabalho, à CAPES e ao CNPq pelo auxílio financeiro e à Universidade Federal de Lavras pelo suporte científico.

- Binoti, D. H. B.; Binoti, M. L. M. S.; Leite, H. G. 2014. Configuração de redes neurais artificiais para estimação do volume de árvores. *Brazilian Journal of Wood Science* 05: 58-67. Doi: <http://dx.doi.org/10.15210/cmadv5i1.4067>.

- Braga, A. P.; Carvalho, A. P. L. F.; Ludemir, T. B. 2007. *Redes neurais artificiais: teoria e aplicações*. Rio de Janeiro: LTC.

- Botelho, M. S. N.; Silva, V. B.; Arruda, L. S. Kuniyoshi, I. C.; Oliveira, L. L. R.; Oliveira, A. S. 2010. Caracterização da triagem auditiva neonatal da Clínica Limiar em Porto Velho, Rondônia. *Brazilian Journal of Otorhinolaryngology* 76: 605-610. Doi: <http://dx.doi.org/10.1590/S1808-86942010000500012>.

- Campos, J. C. C.; Leite, H. G. 2009. Mensuração florestal: perguntas e respostas. 3. ed. Viçosa: UFV.
- Choudhury, T. A.; Hosseinzadeh, N.; Berndt, C. C. 2012. Improving the generalization ability of an artificial neural network in predicting in flight particle characteristics of an atmospheric plasma spray process. *Journal of Thermal Spray Technology* 21: 935-949. Doi: <https://doi.org/10.1007/s11666-012-9775-9>.
- Cordeiro, M. A.; Oliveira, T. F.; Madruga, M. R.; Silveira, A. M. 2015. Estimativa do volume de Acaciamangium utilizando técnicas de redes neurais artificiais e máquinas vetor de suporte. *Pesquisa Florestal Brasileira* 35: 255-261. Doi: <https://doi.org/10.4336/2015.pfb.35.83.596>.
- Graybill, F. A. 1976. Theory and application of the linear model. Belmont, USA: Duxbury Press.
- Leal, F. A.; Miguel, E. P.; Matricardi, E. A. T.; Pereira, R. S. 2015. Redes neurais artificiais na estimativa de volume em um plantio de eucalipto em função de fotografias hemisféricas e número de árvores. *Revista Brasileira de Biometria* 33: 233-249.
- Leite, H. G.; Andrade, V. C. L. 2002. Um método para condução de inventários florestais sem o uso de equações volumétricas. *Revista Árvore* 26: 321-328. Doi: <http://dx.doi.org/10.1590/S0100-67622002000300007>.
- Nascimento, D. S. C.; Coelho, A. L. V. 2009. Bagging heterogêneo evolutivo: caracterização e análise comparativa com ensembles homogêneas de redes neurais RBF. *Anais do IX Simpósio Brasileiro de Automação Inteligente*. São Paulo 6.
- Oliveira, R. C.; Azevedo, N. I. A.; Silva Neto, A.; Biondi Neto, L. 2010. Aplicação de um comitê de redes neurais artificiais para a solução de problemas inversos em Transferência Radiativa. *Trends in Applied and Computational Mathematics* 11: 171-182.
- Ozsahin, S.; Murat, M. 2018. Prediction of equilibrium moisture content and specific gravity of heat treated wood by artificial neural networks. *European Journal of Wood and Wood Products* 76: 563-572. Doi: <https://doi.org/10.1007/s00107-017-1219-2>.
- Santos, W. P.; Souza, R. E., Silva, A. F. D., Portela, N. M., Santos Filho, P. B. 2006. Análise multiespectral de imagens cerebrais de ressonância magnética ponderadas em difusão usando lógica nebulosa e redes neurais para avaliação de danos causados pela doença de Alzheimer. In: *Anais do XI Congresso Brasileiro de Física Médica*.
- Siipilehto, J. 2000. A comparison of two parameter prediction methods for stand structure in Finland. *Silva Fennica* 34: 331-349.
- Silva, I. N.; Spatti, H. D.; Flauzino, R. A. 2010. *Redes neurais artificiais: para engenharia e ciências aplicadas*. São Paulo: Artliber.
- Statsoft, INC. 2014. *Statistica (data analysis software system)*, version 10. Disponível em: www.statsoft.com.