

Estimativa da altura de árvores de eucalipto desbastado em sistema agrossilvipastoril com rede neural artificial¹

Sebastião Pires de Moraes Neto², Karina Pulrolnik², Lourival Vilela²

Resumo: Uma abordagem alternativa para modelar relações hipsométricas envolve a aplicação de redes neurais artificiais (RNAs). O objetivo geral deste trabalho foi verificar a viabilidade da utilização de rede neural artificial (RNA) para estimativa da altura total de árvores de *Eucalyptus urophylla* x *Eucalyptus grandis* em sistema agrossilvipastoril e comparar seu desempenho em relação à modelo de regressão hipsométrico genérico. Para a estimativa da altura total das árvores, pela RNA e pelo modelo de regressão, utilizou-se a variável diâmetro à altura do peito (DAP) e idade das árvores e, para sua avaliação, usou-se o coeficiente de correlação, gráfico de dispersão dos erros percentuais, histograma de frequência dos erros percentuais, raiz quadrada do erro médio percentual, raiz quadrada do erro médio, viés e normalidade dos erros percentuais. A utilização do algoritmo de Levenberg-Marquardt e da arquitetura de quatro camadas intermediárias de 10 neurônios em cada uma das camadas, na RNA, proporcionou estimativa de boa acurácia e foi superior ao modelo de regressão hipsométrico.

Palavras-chave: *Eucalyptus urophylla* x *Eucalyptus grandis*; Integração-lavoura-pecuária-floresta; Relação hipsométrica; Mensuração florestal.

Estimation of the height of thinned eucalyptus trees in agrosilvopastoral system with artificial neural network

Abstract: An alternative approach for modeling hypsometric relationships involves the application of artificial neural networks (ANNs). The general objective of this work was to verify the feasibility of using an artificial neural network (ANN) to estimate the total height of *Eucalyptus urophylla* x *Eucalyptus grandis* trees in an agrosilvopastoral system and compare its performance in relation to the generic hypsometric regression model. For the estimation of the total height of the trees, by the ANN and by the regression model, the variable diameter at breast height (DBH) and age of the trees were used and, for its evaluation, the correlation coefficient, graph of dispersion of percentage errors, histogram of the frequency of percentage errors, root mean square error percentage, root mean square error, bias and normality of the percentage errors. The use of the Levenberg-Marquardt algorithm and the architecture of four intermediate layers of 10 neurons in each one of the layers, in the ANN, provided an estimate of good accuracy and was superior to the hypsometric regression model.

Keywords: *Eucalyptus urophylla* x *Eucalyptus grandis*; Crop-livestock-forest integration; Hypsometric relationship; Forest measurement.

¹Submetido em 28/06/2022;

²Embrapa Cerrados, Planaltina, DF, Brasil; E-mail: sebastiao.moraes@embrapa.br (Autor correspondente) - ORCID: <https://orcid.org/0000-0003-0900-3825>; karina.pulrolnik@embrapa.br - ORCID: <https://orcid.org/0000-0003-0359-5401>; lourival.vilela@embrapa.br - ORCID: <https://orcid.org/0000-0003-1261-0124>

1 Introdução

A determinação do estoque de madeira de uma propriedade, de maneira mais precisa possível, é importante no gerenciamento da empresa, como no caso de processamento para fabricação de produtos manufaturados de madeira. Portanto, para isso, deve-se estimar o volume de madeira, que na prática, necessita de medições de altura e diâmetro do tronco.

Quando as áreas a serem medidas são especialmente grandes, a determinação da altura das árvores é o processo mais oneroso, pelo tempo gasto ser bem maior do que a medição do diâmetro à altura do peito (DAP). Então, para facilitar esse processo, podem ser utilizadas equações matemáticas de relações hipsométricas, normalmente em função do diâmetro à altura do peito e idade das plantas (Barros et al., 2002, Oliveira et al., 2015) ou a utilização de redes neurais artificiais, as quais também são utilizadas para estimativa de variáveis dendrométricas tanto de mudas como de árvores, assim como volume e massa seca e, até para reconhecimento de padrões de crescimento de diferentes espécies de eucalipto, usando variáveis espectrais (Binoti et al., 2013, 2014, 2017, Vieira et al., 2018, Fernandes et al., 2019, Silva et al., 2020, Oliveira et al., 2021, Soares et al., 2021).

Os sistemas de integração-lavoura-pecuária-floresta (ILPF) ou agrossilvipastoris, em geral, proporcionam maiores ganhos ambientais e econômicos do que o monocultivo de culturas agrícolas, florestais e criação de animais. Os arranjos florestais dentro desse sistema podem ser de uma ou várias espécies, espaçamento dentro e entre renques e número de fileiras em cada renque. Até o momento, a espécie mais utilizada é o eucalipto com o híbrido *Eucalyptus urophylla* x *Eucalyptus grandis* sendo um dos mais promissores. Este híbrido apresenta boa produtividade na região do Cerrado e sua madeira pode ser empregada para diversos usos como fabricação de papel, celulose, lenha, carvão vegetal, serraria em geral, construção civil, móveis, pontaletes, laminação, chapas compensadas e postes (Carvalho e Nahuz, 2004, Gonçalves et al., 2010, Arruda et al., 2013).

Os sistemas agrossilvipastoris brasileiros, em geral, apresentam peculiaridades, como plantio em diferentes condições climáticas e de solo; espaçamento entre plantas e entre renques; tratos

culturais como adubação, desrama e desbaste; e manejo de culturas intercalares e gramíneas. Por esses motivos e, a dúvida se equações matemáticas podem superar ou não o emprego de redes neurais artificiais nas predições de estoque de madeira, justifica-se a elaboração deste trabalho.

O presente trabalho teve como objetivo analisar a viabilidade da aplicação de rede neural artificial para estimativa de altura de *Eucalyptus urophylla* x *Eucalyptus grandis* em sistema agrossilvipastoril e comparar com modelo de regressão hipsométrico genérico.

2 Material e Métodos

O trabalho foi desenvolvido com dados de um experimento de integração lavoura-pecuária-floresta (ILPF) implantado entre os meses de janeiro e fevereiro de 2009 na Embrapa Cerrados, em Planaltina, DF (15°36'S e 47°42'W; 980 m de altitude) em área anteriormente ocupada com pastagens de *Brachiaria brizantha* (Hochst. ex A.Rich.) Stapf cv. Marandu; *B. brizantha* consorciada com *Stylosanthes guianensis* (Aubl.) Sw. e com *B. brizantha* consorciada com *Leucaena leucocephala* (Lam.) de Wit. Detalhes do manejo da área experimental foram descritos em Moraes Neto et al. (2020).

O clima da região é Aw (classificação de Köppen). As precipitações mensais e temperaturas médias mensais mínimas e máximas (média mensal de 10 anos de experimento – 2009 a 2018) estão apresentadas na Figura 1. O solo é caracterizado como Latossolo Vermelho, com textura argilosa. As características químicas do solo estão apresentadas na Tabela 1.

O desenho experimental consistiu em blocos ao acaso, com três repetições, e cinco tratamentos os quais incluíam variações dos sistemas e das culturas plantadas (Tabela 2). No presente estudo, foi utilizado somente o sistema com o híbrido *Eucalyptus urophylla* x *Eucalyptus grandis*, o qual foi plantado em renques de duas linhas, em um espaçamento de 2 x 2 entre as plantas, e distância entre renques de 22 m. Cada unidade experimental (um bloco e um tratamento) possuía em média 1,2 ha, pois, especialmente nos tratamentos com árvores, algumas unidades experimentais tinham diferentes números de parcelas.

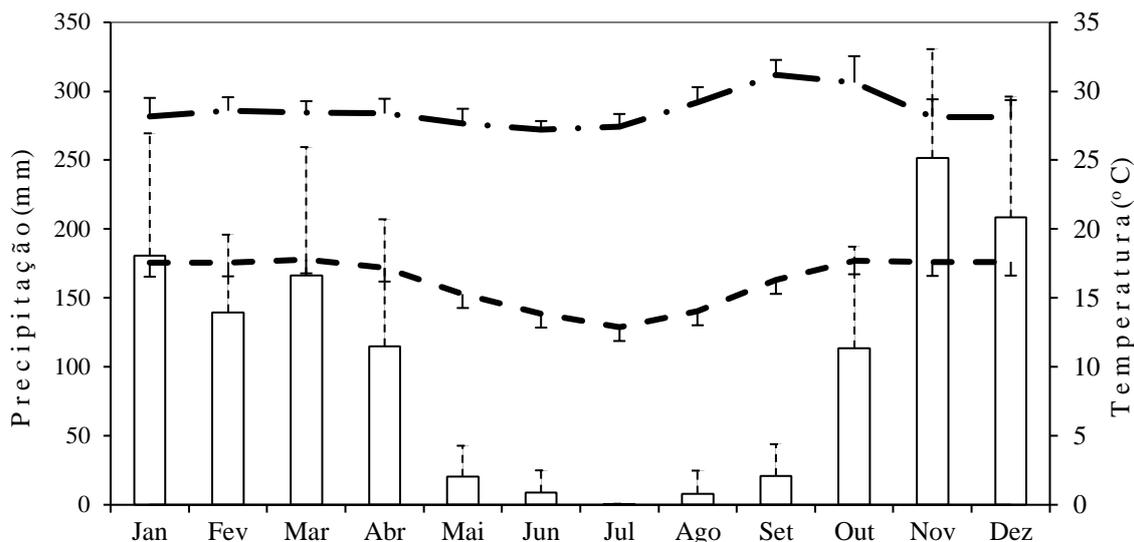


Figura 1 Precipitação (barras), temperatura média mínima (linha tracejada), temperatura média máxima (linha traço ponto), média de 10 anos (2009 a 2018) de experimento para cada mês. As linhas verticais representam o desvio padrão para cada parâmetro.

Tabela 1 Características químicas (fertilidade) do solo da área do experimento realizada antes de sua instalação

Prof. (cm)	pH H ₂ O	P --- mg L ⁻¹	K ⁺ ---	Al ³⁺ -----	Ca ²⁺ -----	Mg ²⁺ -----	H ⁺ +Al ³⁺ -----	CTC	V %	CO g kg ⁻¹
0-20	5,55	0,48	67,24	0,14	1,45	0,86	4,41	6,90	35,70	16,59
20-40	5,47	0,64	33,44	0,23	0,96	0,57	4,19	5,81	27,37	13,46

Prof. = profundidade; CTC (Capacidade de troca catiônica) = Ca + Mg + (K/391) + (H⁺+Al³⁺); V% = (saturação por bases) = [(Ca+Mg+(K/391)) / CTC] x 100; CO = carbono orgânico. Fonte: Pulrolnik et al. (2010).

Tabela 2 Relação dos tratamentos experimentais (sistemas) implantados na Embrapa Cerrados, Planaltina-DF

Trat.	Sistema				Espaçamento (m)		Número de linhas do renque	Densidade (árvores/ha)
	Ano 1	Ano 2	Ano3	Ano 4	Entre árvores	Entre renques		
1	L	L	L	P	-	-	-	sem árvore
2	L + Eu	L + Eu	L + Eu	P + Eu	2 x 2	22	2	417
3	L + Eu	L + Eu	L + Eu	P + Eu	2 x 2	12	2	715
4	L + Ec	L + Ec	L + Ec	P + Ec	2 x 2	22	7	1.030
5	L + N	L + N	L + N	P + N	4 x 4	12	2	313

Trat. – Tratamentos; L – Lavoura de grãos; P – Pastagem consorciada; Eu – *Eucalyptus urophylla* x *Eucalyptus grandis*; Ec – *Eucalyptus cloeziana*; N – Espécies nativas arbóreas. Fonte: Pulrolnik et al. (2010).

Para determinação da relação hipsométrica foram utilizados o modelo de regressão hipsométrico genérico utilizados por Caldeira et al. (2002) e Barros et al. (2002) e, o modelo de rede neural (usando a função de ajuste “fitnet” do Matlab, versão R2019a) empregou o algoritmo de treinamento de Levenberg Marquardt, após ter sido testados os algoritmos BFGS Quasi-

Newton, resilient backpropagation, scaled conjugate gradient, conjugate gradient with Powell/Beale restarts, Fletcher-Powell conjugate gradient, Polak-Ribière conjugate gradient, one step secant, variable learning rate e bayesian regularization, todos possuindo o algoritmo backpropagation, que ajusta os erros através dos pesos, em seu movimento de retropropagação da

saída para a entrada dos dados (Mathworks, 2022a,b). O algoritmo backpropagation procura achar iterativamente a mínima diferença entre as saídas desejadas e as saídas obtidas pela rede neural, com o mínimo de erro. Dessa forma, ajustando os pesos entre as camadas através da retropropagação do erro encontrado em cada iteração (Haykin, 1996, Rumerlhart et al., 1986 apud Matsunaga, 2012). Utilizou-se em todos os testes 1.000 ciclos ou épocas, 25 checagens de validação e quadrado médio do erro de 0,0001. Nos outros parâmetros de treinamento empregou-se o padrão (default) para cada algoritmo de treinamento. O algoritmo Levenberg-Marquardt combina as melhores características do método do gradiente descendente e o método de Gauss-Newton, o qual proporciona maior velocidade de convergência em relação ao erro do algoritmo backpropagation (Hagan e Menhaj, 1996 apud Vieira et al., 2018)

O modelo genérico extraído de Caldeira et al. (2002) empregado foi:

$$\log H = b_0 + \frac{b_1}{DAP} + \frac{b_2}{I} + \frac{b_3}{DAP * I}$$

Em que: H =altura total em metros; DAP =diâmetro à altura do peito em cm; I =idade em anos; b_i =parâmetros da regressão; \log =logaritmo na base dez.

Quanto a Rede Neural Artificial (RNA), do tipo Multilayer Perceptron (MLP), utilizou-se duas variáveis de entrada (DAP e idade) e uma de saída (altura total). As camadas ocultas ou intermediárias foram constituídas por quatro camadas com dez neurônios cada e, utilizou-se a função de ativação tangente hiperbólica. Na camada de saída, usou-se a função de ativação linear, sendo que a arquitetura ficou assim 2-10-10-10-1, a qual foi replicada 30 vezes (30 redes). As alturas estimadas foram a média das 30 redes. As variáveis foram coletadas aos 6,5, 7,5, 8,5 e 9,5 anos, após desbaste de aproximadamente 48% do povoamento aos 5,5 anos e, foi utilizado como amostra 400 árvores que, após excluir dados discrepantes (outliers), ficou um total de 384 árvores.

Os dados, originalmente dispostos na planilha Excel, foram codificados para a linguagem Matlab através dos comandos do *readtable*. As estimativas dos modelos RNA e

modelo genérico (coeficientes calculados no Proc model do SAS) foram avaliadas com base nos coeficientes de correlação, viés, raiz quadrada do erro médio percentual e não percentual, bem como na análise gráfica dos erros percentuais e histograma de erros percentuais. Adicionou-se curva normal a distribuição dos erros percentuais nos dois modelos e verificou-se sua normalidade pelo teste de Kolmogorov-Smirnov (Proc univariate do SAS).

As fórmulas exibidas na sequência foram baseadas em Casas et al. (2022):

- Coeficiente de correlação:

$$r_{y\hat{y}} = \frac{\sum_{i=1}^n (Y_i - \bar{Y})(\hat{Y}_i - \hat{Y}_m)}{\sqrt{[\sum_{i=1}^n (Y_i - \bar{Y})^2] [\sum_{i=1}^n (\hat{Y}_i - \hat{Y}_m)^2]}}$$

- Viés:

$$V = \frac{\sum_{i=1}^n Y_i - \sum_{i=1}^n \hat{Y}_i}{n}$$

- Raiz quadrada do erro médio percentual:

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

- Raiz quadrada do erro médio:

$$RQEM = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}}$$

Em que: Y_i = variável dependente observada, \hat{Y}_i = variável dependente estimada, \bar{Y} = média da variável dependente observada, \hat{Y}_m = média da variável dependente estimada e n = número de observações.

3 Resultados e Discussão

Verifica-se na Tabela 3, em relação aos parâmetros estatísticos relativos as estimativas de altura total nos dois modelos estudados, que o coeficiente de correlação entre altura observada e estimada foi superior no modelo de rede neural artificial (RNA), o viés e a raiz quadrada do erro médio percentual (RQEM%) e RQEM foram inferiores na RNA e, constatou-se normalidade, pelo teste de Kolmogorov-Smirnov, na RNA e não normalidade no modelo genérico.

Tabela 3 Parâmetros estatísticos relativos as estimativas de altura total nos dois modelos em relação as alturas observadas de dados coletados dos 5,5 a 8,5 anos das árvores de eucalipto

Modelos	Coefficiente de correlação	Viés	Raiz quadrada do erro médio % (RQEM%)	Raiz quadrada do erro médio (RQEM)	Normalidade* (Pr>D)
Genérico	0,59	0,0628	7,22	2,15	0,0413
Rede Neural Artificial	0,74	-0,0138	5,97	1,78	0,0803

*Teste de Kolmogorov-Smirnov.

Binoti et al. (2017) observaram em relação a estimativa de altura em povoamentos variando de 1,8 anos a 11,4 anos que a utilização de rede neural artificial (RNA) apresentou RQEM% médio dos tratamentos utilizados de 5,03%. Silva et al. (2020) estudaram a estimativa de altura de *Eucalyptus urophylla x Eucalyptus grandis* em sistema agrossilvipastoril, nas idades entre 5,5 a 8,0 anos, em que se comparou o modelo hipsométrico de Campos et al. (1984) (logarítmico) com o modelo RNA. Verificou-se no modelo hipsométrico um RQEM% de 8,96% e viés de 0,10, enquanto no modelo RNA, constatou-se RMSE% de 5,32% e viés de 0,085. Vieira et al. (2018) estudaram a prognose de altura e diâmetro de dados coletados em inventários anuais do híbrido *Eucalyptus urophylla x Eucalyptus grandis*, em que o modelo de Pienar e Shiver (1981) foi comparado com RNA. Observou-se que o RQEM do modelo hipsométrico do RNA foi 1,43 e o de Pienar e Shiver foi 1,66. No presente estudo o modelo de RNA apresentou RQEM% de 5,97%, viés de -0,0138 e RQEM de 1,78, mostrando que os resultados foram similares aos trabalhos citados e, por apresentarem baixos valores, tiveram boa acurácia.

Observa-se na Figura 2, nos dois modelos, que os erros percentuais nos gráficos de dispersão em relação a altura total estimada estão distribuídos de forma aleatória em torno do zero, contudo, na rede neural artificial (RNA) a distribuição está

mais homogênea e aderente em torno do zero, em que a maioria dos dados está compreendido entre -10 e 10 %. Nos gráficos de barras a amplitude dos erros do modelo RNA é menor e se aproxima mais de uma curva normal do que o modelo genérico, confirmado pelo teste de normalidade de Kolmogorov-Smirnov (Tabela 3). A normalidade dos erros ou resíduos pode indicar uma maior acurácia nas estimativas de altura das árvores (Santos et al., 2017). Souza et al. (2021), utilizando RNA, observaram no conjunto de dados da dispersão dos erros entre as alturas observadas e estimadas de *Eucalyptus globulus* Labill. e *Acacia mearnsii* De Wild. entre as idades de 1 a 8 anos de idade, que a maioria dos dados ficou compreendido entre -10 e 10%, de maneira similar ao presente trabalho.

Os motivos que mostraram que o uso de rede artificial ter sido superior ao modelo de regressão, pode ser a sua capacidade de aprender, generalizar e modelar variáveis categóricas (qualitativas) e contínuas (quantitativas). Este método pode ser usado como uma alternativa para resolver problemas complexos quando os dados não atendem as suposições estatísticas para análise de regressão (Casas et al., 2022), assim como normalidade, homocedasticidade, multicolinearidade (Gujarati e Porter 2011) e dados discrepantes ou ruidosos (noisy data), o que é comum em povoamentos de baixa densidade (Silva et al., 2020), como o sistema agrossilvipastoril do presente trabalho.

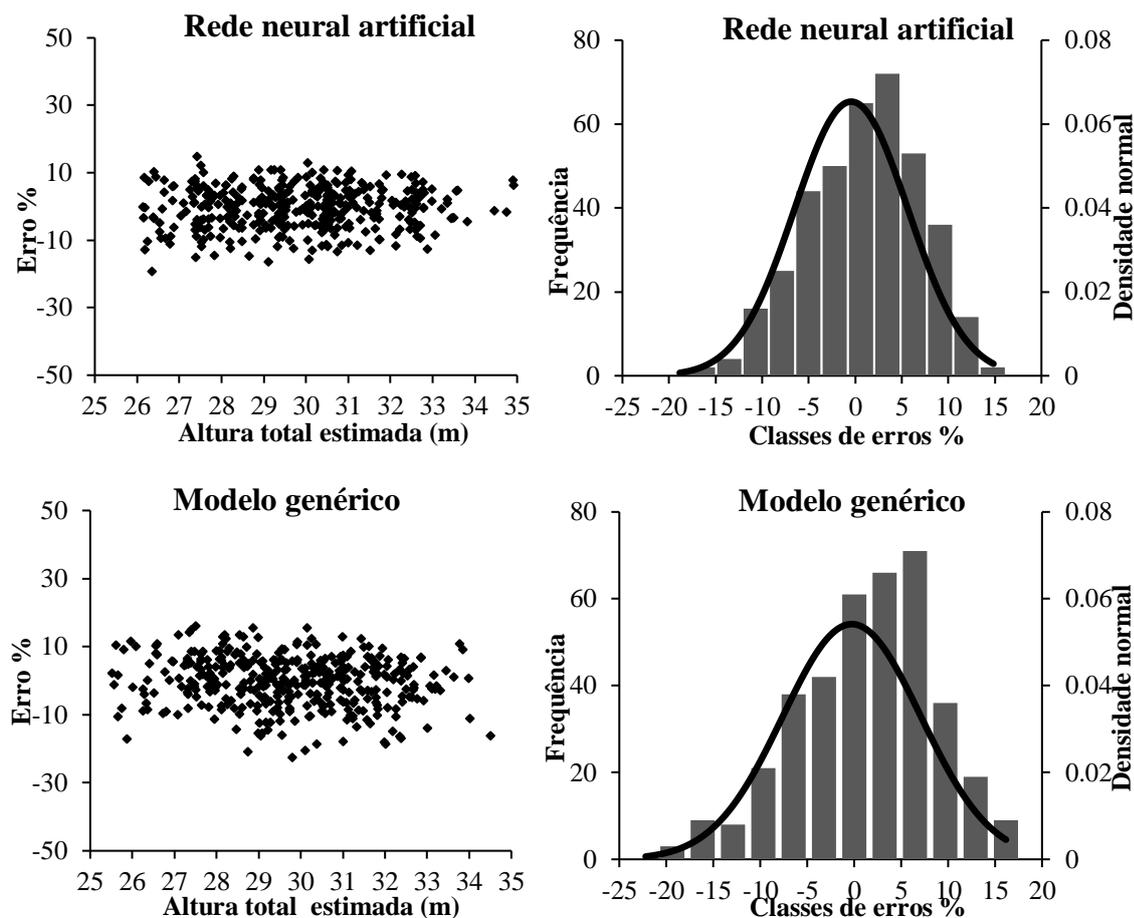


Figura 2 Erros percentuais em função da altura total estimada e frequência dos erros e densidade normal em função das classes de erros percentuais nos modelos de rede neural artificial (RNA) e modelo de regressão hipsométrico genérico.

4 Conclusão

O modelo de rede neural artificial utilizando algoritmo de treinamento de Levenberg-Maquardt e função de ativação tangente hiperbólica, nas camadas intermediárias, proporcionou uma maior acurácia na estimativa de altura do que o modelo de regressão hipsométrico genérico, mostrando ser viável sua aplicação na mensuração e manejo florestal.

Referências

Arruda, T. P. M.; Hein, P. R. G.; Fonseca, A. S.; Castro, J. P. Propriedades da madeira do híbrido *Eucalyptus grandis* x *Eucalyptus urophylla* para uso energético no Mato Grosso. **Revista de Ciências Agroambientais**, v. 11, n. 2, p.127–136, 2013. <http://repositorio.ufla.br/jspui/handle/1/45988>

Barros, D. A.; Machado, S. A.; Acerbi Júnior, F. W.; Scolforo, J. R. S. Comportamento de modelos hipsométrico tradicionais e genéricos para plantações de *Pinus oocarpa* em diferentes tratamentos. **Boletim de Pesquisa Florestal**, n. 45, p. 3–28, 2002. <https://ainfo.cnptia.embrapa.br/digital/bitstream/CNPF-2009-09/33608/1/pag3-28.pdf>

Binoti, D. H. B.; Binoti, M. L. M. 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. <https://periodicos.ufpel.edu.br/ojs2/index.php/cienciadamadeira/article/download/4067/3211>

Binoti, M. L. M. S., Binoti, D. H. B., Leite, H. G. Aplicação de redes neurais artificiais para estimação da altura de povoamentos equiâneos de eucalipto. **Revista Árvore**, v. 37, n. 4, p. 639–645, 2013. <https://www.locus.ufv.br/bitstream/123456789/15958/1/07.pdf>

- Binoti, H. B.; Duarte, P. J.; Silva, M. L. M.; Silva, G. F.; Leite, H. G.; Mendonça, A. R.; Andrade, V. C. L.; Veja, A. E. D. Estimation of height of eucalyptus trees with neuroevolution of augmenting topologies (NEAT). **Revista Árvore**, v. 41, n. 3, p. 1–8, 2017. <http://dx.doi.org/10.1590/1806-90882017000300014>
- Caldeira, M. V. W.; Schumacher, M. V.; Scheeren, L. W.; Barichello, L. R.; Watzlawich, L.F. Relação hipsométrica para *Acacia mearnsii* com diferentes idades. **Boletim de Pesquisa Florestal**, n. 45, p. 57–68, 2002. <https://pfb.cnpf.embrapa.br/pfb/index.php/pfb/article/view/1750/681>
- Campos, J. C. C.; Ribeiro, J.; Paula Neto, F. **Inventário florestal nacional**: reflorestamento, Minas Gerais. Brasília, DF: IBDF, 1984. 125 p.
- Carvalho, A. M.; Nahuz, M. A. R. Interferência na qualidade e rendimento de polpa celulósica de eucalipto devido ao uso múltiplo da madeira. **Cerne**, v. 10, n. 2, p. 242–256, 2004. <https://www.redalyc.org/pdf/744/74410208.pdf>
- Casas, G. G.; Fardin, L. P.; Silva, S.; Oliveira Neto, R. R.; Binoti, D. H. B.; Leite, R. V.; Domiciano, C. A. R.; Lopes, L. S. S.; Cruz, J. P.; Reis, T. L.; Leite, H. G. Improving yield projections from early ages in eucalypt plantations with the Clutter model and artificial neural networks. **Pertanika Journal of Science & Technology**, v. 30, n. 2, p. 1257–1272, 2022. [http://www.pertanika.upm.edu.my/resources/files/Pertanika%20PAPERS/JST%20Vol.%2030%20\(2\)%20Apr.%202022/22%20JST-3072-2021](http://www.pertanika.upm.edu.my/resources/files/Pertanika%20PAPERS/JST%20Vol.%2030%20(2)%20Apr.%202022/22%20JST-3072-2021)
- Fernandes, M. M.; Sousa, F. L.; Silva, J. P. M.; Araújo, E. F.; Fernandes, M. R. M.; Nóbrega, R. S. A. Redes Neurais Artificiais na estimação de variáveis biométricas de mudas de espécies florestais produzidas em diferentes substratos. **Revista de Ciências Agroveterinárias**, v. 18, n. 1, p. 47–58, 2019. <https://www.revistas.udesc.br/index.php/agroveterinaria/article/download/11414/pdf/49853>
- Gonçalves, F. G.; Oliveira, J. T. S.; Silva, G. F.; Nappo, M. E. Tomazelo Filho, M. Parâmetros dendrométricos e correlações com propriedades tecnológicas em um híbrido clonal de *Eucalyptus urophylla* x *Eucalyptus grandis*. **Revista Árvore**, v. 34, n. 5, p. 947–959, 2010. <https://doi.org/10.1590/S0100-67622010000500020>
- Gujarati, D. N.; Porter, D. C. **Econometria básica**. 5. ed. São Paulo: McGraw-Hill, 2011. 924p.
- Mathworks. **Fitnet** - Function fitting neural network. Versão R2022a. <https://www.mathworks.com/help/deeplearning/ref/fitnet.html;jsessionid=9103afc36cacac8be2eda0715c52>
- Mathworks. Train and Apply Multilayer Shallow Neural Networks. Versão R2022b. <https://www.mathworks.com/help/deeplearning/ug/train-and-apply-multilayer-neural-networks.html>
- Matsunaga, V. Y. Curso de redes neurais utilizando o MATLAB. Belém, PA, 2012. 20p. <https://www.muriloleal.com.br/visao/repositorio/centec/ea/ia/REDES%20NEURAIIS%20-%20APOSTILA.pdf>
- Moraes Neto, S. P. De; Pulrolnik, K.; Vilela, L.; Souza, K. W. De; Guimaraes Junior, R. **Estimativa do volume de madeira de eucalipto em sistema agrossilvipastoril**. Planaltina, DF: Embrapa Cerrados, 2020. 22p. (Embrapa Cerrados. Boletim de Pesquisa e Desenvolvimento, 354). <https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/1124566/1/Bolpd-354-Sebastiao-Neto.pdf>
- Oliveira, B. R.; Silva, A. A. P.; Teodoro, L. P. R.; Azevedo, G. B.; Azevedo, G. T. O. S.; Baio, F. H. R.; Lustosa Sobrinho, R.; Silva Júnior, C. A.; Teodoro, P. E. Eucalyptus growth recognition using machine learning methods and spectral variables. **Forest Ecology and Management** v. 497, 2021. <https://doi.org/10.1016/j.foreco.2021.119496>
- Oliveira, G. M. V.; Mello, J.M.; Altoé, T. F.; Scalon, J. D.; Scolforo, S. R. S.; Pires, J. V. Equações hipsométricas para *Eucalyptus* spp. não manejados em idade avançada com técnicas de inclusão de covariantes. **CERNE**, v. 21, n. 3, p. 483–492, 2015. <https://www.scielo.br/j/cerne/a/QQdwXpC8HPDf55DRcf4LYby/?format=pdf&lang=pt>
- Pulrolnik, K.; Vilela, L.; Moraes Neto, S. P. de; Marchão, R. L.; Guimarães Junior, R. **Desenvolvimento inicial de espécies arbóreas no sistema de integração lavoura-pecuária-floresta**. Planaltina, DF: Embrapa Cerrados, 2010. 17p. (Embrapa Cerrados. Boletim de Pesquisa e Desenvolvimento, 276). <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/75859/1/bolpd-276.pdf>
- Santos, A. C. A.; Almeida, F. M.; Souza, R. B.; Chaves, R.; Paiva, H. N.; Binoti, D. H. B.; Leite, H. G.; Farias, A. A. Estimation of eucalyptus tree height in clonal and progeny tests using artificial neural networks. **Revista Árvore**, v.

- 41, n. 6, p. 1–7, 2017. <http://dx.doi.org/10.1590/1806-90882017000600002>
- Silva, S.; Oliveira Neto, S. N.; Leite, H. G.; Alcântara, A. E. M.; Oliveira Neto, R. R.; Souza, G. S. A. Productivity estimate using regression and artificial neural networks in small familiar areas with agrosilvopastoral systems. **Agroforest Systems**, v. 94, p. 2081–2097, 2020. <https://doi.org/10.1007/s10457-020-00526-1>
- Soares, G. M.; Silva, L. D.; Higa, A. R.; Simon, A. A.; São José, J. F. B. Artificial neural networks (ANN) for height estimation in a mixed-species plantation of *Eucalyptus globulus* Labill. and *Acacia mearnsii* De Wild. **Revista Árvore**, v. 45, p. 1–9, 2021. <http://dx.doi.org/10.1590/1806-908820210000012>
- Vieira, G. C.; Mendonça, A. R.; Silva, G. F.; Zanetti, S. S.; Silva, M. M.; Santos, A. R. Prognoses of diameter and height of trees of eucalyptus using artificial intelligence. **Science of the Total Environment**, v. 619–620, p.1473–1481, 2018. <https://www.sciencedirect.com/science/article/pii/S0048969717331960>