





USO DE REDES NEURAS ARTIFICIAIS NA PREDIÇÃO DE VOLUME DE *Pterogyne nitens* Tul.

Thaís Chaves Almeida¹, Patrícia Anjos Bittencourt Barreto-Garcia¹, Fabiano Rodrigues
Pereira², Rebeca Malta Veríssimo¹

1 Universidade Estadual do Sudoeste da Bahia, Vitória da Conquista, BA, Brasil. E-mail: florestal.thais@gmail.com; patriciabarroto@uesb.edu.br; rebeca.malta@hotmail.com

2 Universidade Federal de Lavras, Lavras, MG, Brasil. E-mail: fabiano.engflo@gmail.com

Autora correspondente: Thaís Chaves Almeida. E-mail: florestal.thais@gmail.com

RESUMO

A quantificação do volume de madeira das árvores é comumente realizada por meio de métodos indiretos, destacando-se o ajuste de modelos por regressão e redes neurais artificiais (RNA). Embora os modelos de regressão sejam os mais difundidos, as RNA têm se mostrado mais eficientes na predição de volume, podendo gerar resultados mais precisos em espécies perfilhadas. Por este motivo, o objetivo deste trabalho foi analisar três modelos de RNA e selecionar o de melhor desempenho na predição de volume de *Pterogyne nitens*. Os dados foram obtidos em um plantio puro de *P. nitens*, localizado na área experimental da Universidade Estadual do Sudoeste da Bahia, em Vitória da Conquista, Bahia. Utilizou-se dados de diâmetro à altura do peito e altura como *inputs* fixos das redes e número de fustes e diâmetro à nível de 0,1 m do solo na variação dos *inputs* das outras redes, a fim de verificar se haveria melhoria da predição de volume ao acrescentar variáveis. Os critérios utilizados para escolha da melhor rede foram: raiz do erro quadrático médio, erro médio absoluto, viés e eficiência do modelo, além da distribuição gráfica dos resíduos. Apesar de todas as redes apresentarem valores satisfatórios, a rede 3 apresentou melhores resultados.

Palavras-chave: Equação da rede neural artificial; mensuração florestal; número de fustes

USE OF ARTIFICIAL NEURAL NETWORKS IN VOLUME PREDICTION OF *Pterogyne nitens* Tul.

ABSTRACT

The quantification of tree wood volume is commonly performed by means of indirect methods, with emphasis on the adjustment of models by regression and artificial neural networks (ANN). Although regression models are the most widespread, ANNs have proven to be more efficient in predicting volume and can generate more accurate results in tillered species. For this reason, the objective of this work was to analyze three ANN models and select the one with the best performance in predicting the volume of Pterogyne nitens. Data were obtained from a pure plantation of P. nitens, located in the experimental area of the State University of Southwest Bahia, in Vitória da Conquista, Bahia. Diameter at breast height and height data were used as fixed inputs of the nets and number of stems and diameter at the level of 0.1 m from the ground in the variation of the inputs of the other nets, in order to verify if there would be improvement in the prediction of volume by adding variables. The criteria used to choose the best network were: root mean square error, mean absolute error, bias, model efficiency, in addition to the graphical distribution of residuals. Although all networks presented satisfactory values, network 3 presented better results.

Key words: Artificial neural network equation; forest measurement; number of stems

ASSOCIAÇÃO BRASILEIRA DE MENSURAÇÃO FLORESTAL



INTRODUÇÃO

A alta demanda por produtos florestais madeireiros e não-madeireiros tem promovido a expansão de áreas de florestas plantadas por todo o mundo. Devido suas características edafoclimáticas favoráveis e alto nível tecnológico em silvicultura e manejo florestal, o Brasil destaca-se no mercado mundial de florestas plantadas, tanto de espécies nativas quanto exóticas (Rabelo *et al.*, 2020).

Popularmente conhecida como amendoim-bravo ou madeira-nova, *Pterogyne nitens* é uma espécie nativa brasileira que possui um grande potencial de cultivo no Nordeste do país, uma vez que apresenta boa adaptabilidade na região e rápido crescimento (Figueiredo *et al.*, 2018). Apesar de sua importância econômica, ainda há poucos estudos dendrométricos sobre a espécie, que apresenta fustes tortuosos e perfilhados (Aragão *et al.*, 2015). Isso torna a sua mensuração de volume dificultada e onerosa, fazendo-se necessário o desenvolvimento de métodos que permitam a obtenção de estimativas de forma prática e confiável e, como consequência, um melhor entendimento do potencial produtivo da espécie.

A quantificação do volume de madeira das árvores é comumente realizada por meio de métodos indiretos, através de ajustes de modelos e fatores de forma. Os parâmetros utilizados no ajuste de modelos podem ser estimados por regressão e inteligência artificial, como Redes Neurais Artificiais (RNA).

Os modelos de regressão, embora sejam os mais utilizados, expressam limitações na estimativa de volume de espécies perfilhadas, exigindo ajustes específicos de acordo com a condição do povoamento. As RNA, por sua vez, têm mostrado mais eficiência na predição de altura e volume das árvores, devido a complexa relação entre os atributos das florestas (Binoti *et al.*, 2013). Apesar disso, as RNA ainda são pouco exploradas na mensuração florestal brasileira.

Diante do exposto, o presente trabalho teve como objetivo analisar três modelos de RNA para a predição de volume de *Pterogyne nitens* Tul.

MATERIAL E MÉTODOS

Os dados foram obtidos em um plantio puro de *Pterogyne nitens*, localizado no campo experimental da Universidade Estadual do Sudoeste da Bahia (UESB), *Campus* de Vitória da Conquista, Bahia. O povoamento possui cerca de 14 anos de idade, com área aproximada de 1,0 ha e espaçamento 3 x 3 m.

O clima da região é classificado como Cwb, tropical de altitude, conforme Köppen, considerado ameno devido a altitude média de 840 m. A precipitação de 850 mm anuais (Barbosa *et al.*, 2017) está distribuída entre os meses de novembro a março. A temperatura média anual é de 25°C. Segundo Sousa Neto *et al.* (2018), o solo da área de estudo é classificado como Latossolo Amarelo Distrófico.

VI Encontro Brasileiro de Mensuração Florestal

Foram medidos todos os diâmetros à nível de 0,1 m do solo ($D_{NS_{0,1}}$) das árvores do plantio para caracterização da distribuição diamétrica. Após isso, realizou-se a cubagem rigorosa de 108 árvores, selecionadas de forma proporcional às frequências das classes diamétricas da população.

No momento da cubagem, com o auxílio de uma suta e uma fita métrica, foram medidos os diâmetros com casca e as alturas de cada fuste nas seções 0,1 m, 0,3 m, 0,5 m, 0,7 m, 1,3 m e 2 m do nível do solo e, a partir dessa posição, os diâmetros foram medidos em intervalos de um metro até a altura onde se encontrava o diâmetro mínimo de 4 cm.

No processamento inicial dos dados, calculou-se o diâmetro equivalente (D_e) (Equação 1), a partir do diâmetro a 1,30m do solo (D) das árvores com mais de um fuste, e considerou-se a altura do maior fuste como altura total (H). Além disso, foi calculado o volume total de cada árvore pelo método de Smalian e, em seguida, os dados foram separados em duas bases, sendo a maior proporção dos dados empregada para treino (70%) e a menor para teste (30%).

$$D_e = \sqrt{\sum D_n^2} \quad (1)$$

De posse dos 70% dos dados, foram ajustadas três RNAs, tendo como variável de saída o volume total. As variáveis de entrada foram D e H fixas nas três redes, com a inclusão do número de fustes (NF) na segunda rede e NF e diâmetro a 0,1m do solo ($D_{0,1}$) na terceira rede. Além disso, as redes foram treinadas com apenas uma camada oculta, com o número de neurônios correspondentes ao número de *inputs* ($RNA1 = 2$, $RNA2 = 3$, $RNA3 = 4$), utilizando o algoritmo *resilient backpropagation* e a função de ativação logística.

Após o ajuste das RNAs, estas foram utilizadas para a predição do volume com as duas bases de dados e então foram aplicados os critérios estatísticos para a escolha da melhor rede. Os critérios considerados foram: raiz do erro quadrático médio (RMSE), erro médio absoluto (MAPE), viés (BIAS) e eficiência do modelo (EF), além da análise da dispersão dos resíduos (Vanclay, 1994; Binoti *et al.* 2015; Peng *et al.*, 2022).

RESULTADOS E DISCUSSÃO

Na Tabela 1 está apresentada a estatística descritiva das variáveis utilizadas como entrada e saída das redes neurais. As árvores apresentavam de um a cinco perfilhos, com $D_{0,1}$ e D variando de 5,5 cm a 22,0 cm e 4,0 cm a 15,0 cm, respectivamente, para a base de treino e 5,5 cm a 19,0 cm e 4,0 cm a 16,0 cm para a base de teste. As médias de altura e volume foram aproximadamente 6,0 m e 0,0200 m³ para as duas bases.

VI Encontro Brasileiro de Mensuração Florestal

Tabela 1. Estatística descritiva dos dados de treino e teste

VARIÁVEIS	TREINO					TESTE				
	Min	Média	Máx	S	CV%	Min	Média	Máx	S	CV%
NF	1,0	1,6	5,0	0,8	53,0	1,0	1,4	5,0	0,8	60,6
D _{0,1}	5,5	10,8	22,0	3,5	32,1	5,5	10,8	19,0	3,4	31,9
DAP	4,0	7,6	15,0	2,6	34,1	4,0	7,6	16,0	3,1	40,6
H	2,6	6,0	9,6	1,2	20,1	3,5	6,0	10,1	1,4	22,6
V	0,0031	0,0200	0,0779	0,0149	84,8	0,0035	0,0200	0,1037	0,0204	103,6

Em que: NF = número de fustes; D_{0,1} = diâmetro a 0,1 m do solo (cm); D = diâmetro à 1,3 m do solo (cm); H = altura total (m); V = volume (m³); Min = valores mínimos; Max = valores máximos; S = desvio padrão; CV = coeficiente de variação.

As três redes apresentaram estatísticas favoráveis para a predição do volume de *Pterogyne nitens* (Tabela 2). Observando o *ranking*, a RNA3 apresentou o melhor resultado ao considerar as duas bases utilizadas e todos os critérios aplicados, enquanto a RNA1 apresentou resultados menos adequados quando comparada às outras redes, por apresentar maiores valores de erro (RMSE = 0,0073 e MAPE = 21,86) e uma menor eficiência (EF = 0,8244). Além disso, foi possível observar que, com a inclusão das variáveis de entrada NF e D_{0,1}, houve uma redução de 22,08 % e 34,98 % no RMSE e MAPE, respectivamente, e um aumento de 5,64 % na eficiência da RNA, resultando em uma maior precisão dos valores preditos para o povoamento em estudo. Leite *et al.* (2022) também observou que a combinação de diferentes variáveis, além das tradicionais, como entrada na RNA, melhorou as predições de atributos florestais. Adicionalmente, de acordo com Araújo (2015), as RNA possuem a vantagem de serem flexíveis e permitirem a inserção de mais variáveis explicativas simultaneamente.

Tabela 2. Critérios estatísticos para escolha da melhor rede

Modelo	Treino				Teste				Ranking Geral
	RMSE	MAPE	EF	BIAS	RMSE	MAPE	EF	BIAS	
RNA1	0,00308	11,43279	0,95137	0,00001	0,00726	21,85599	0,82443	0,00352	3,00000
RNA2	0,00254	9,63189	0,96586	-0,00001	0,00620	19,07436	0,85983	0,00256	1,85328
RNA3	0,00199	7,78856	0,97834	0,00001	0,00565	14,21033	0,87097	0,00161	1,00000

Em que: RMSE = raiz do erro quadrático médio; MAPE = erro médio absoluto; EF = eficiência do modelo; BIAS = viés

As três RNAs analisadas apresentaram uma distribuição uniforme dos resíduos ao longo das predições (Figura 1), indicando uma boa confiabilidade do método utilizado. Além disso, concordando com os resultados anteriores, foi possível observar um desempenho superior da RNA3, uma vez que os resíduos estão mais próximos de zero e mais bem distribuídos em relação aos valores preditos.




Figura 1. Dispersão dos resíduos dos volumes preditos em relação ao volume real

Os parâmetros obtidos por meio do ajuste dos pesos da RNA3 podem ser verificados na Tabela 3 e podem ser utilizados de forma similar ao proposto por Dantas *et al.* (2021) para aplicação prática.

Tabela 3. Parâmetros estimados ($\hat{\beta}_i$) para cada neurônio (N_i) da camada escondida e da camada de saída da RNA3

	$\hat{\beta}_0$	$\hat{\beta}_1$	$\hat{\beta}_2$	$\hat{\beta}_3$	$\hat{\beta}_4$
RNA	0,0184	-0,8943	1,8502	-0,5814	1,4609
N₁	-0,7714	-0,1858	-0,8858	-0,2026	0,6365
N₂	-1,8530	-1,3960	-0,6289	-0,9312	0,6564
N₃	6,4120	0,2876	-7,6499	-2,3490	1,5208
N₄	-0,3359	0,5525	0,5949	0,4826	-0,1318

CONCLUSÃO

A inclusão das variáveis de entrada número de fustes e diâmetro a 0,1 m do solo, além das variáveis tradicionais (diâmetro a 1,3 m do solo e altura), levaram a uma melhora no desempenho da rede neural artificial para a predição do volume total de *Pterogyne nitens*.

REFERÊNCIAS BIBLIOGRÁFICAS

- Aragão, M. A.; Barreto-Garcia, P. A. B.; Paula, A.; Carvalho, F. F.; Fraga, M. P. Modelos de altura para *Pterogyne nitens* Tul. em plantio puro no Sudoeste da Bahia. **Enciclopédia Biosfera**, v. 11, n. 21, p.1340-1351, 2015. Disponível em: <https://www.conhecer.org.br/enciclop/2015b/agrarias/Modelos%20de%20altura.pdf>. Acesso em: 12 Jun. 2023.
- Araújo, B. H. P. **Modelagem da altura, volume e afilamento do fuste de *Calycophyllum spruceanum* Benth. empregando regressão e redes neurais artificiais**. 2015. 52 f. Dissertação (Mestrado em Ciências de Florestas Tropicais) – Instituto Nacional de Pesquisas da Amazônia, Manaus, 2015. Disponível em: <https://repositorio.inpa.gov.br/handle/1/5093>. 14 Jun 2023.
- Barbosa, V.; Barreto-Garcia, P. A. B.; Gama-Rodrigues, E.; Paula, A. Biomassa, carbono e nitrogênio na serapilheira acumulada de florestas plantadas e nativa. **Floresta e Ambiente**, v. 24, e024215, 2017. <https://doi.org/10.1590/2179-8087.024315>.
- 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://doi.org/10.1590/S0100-67622013000400007>.
- Binoti, M. L. M. S.; Leite, H. G.; Binoti, D. H. B.; Gleriani, J. M. Prognose em nível de povoamento de clones de eucalipto empregando redes neurais artificiais. **Cerne**, v. 21, n. 1, p.97-105, 2015. <https://doi.org/10.1590/01047760201521011153>.
- Dantas, D.; Terra, M. C. N. S.; Schorr, L. P. B.; Calegario, N. Machine learning for carbon stock prediction in a tropical forest in Southeastern Brazil. **Bosque**, v. 42, n. 1, p.131-140, 2021. <https://doi.org/10.4067/S0717-92002021000100131>.

VI Encontro Brasileiro de Mensuração Florestal

- Figueiredo, M. E. O.; Júnior, D. L.; Pereira, A. K. S.; Carneiro, A. C. O.; Silva, C. M. S. Potencial da madeira de *Pterogyne nitens* Tul. (Madeira-nova) para produção de carvão vegetal. **Ciência Florestal**, v.28, n.1, p.420-431, 2018. <https://doi.org/10.5902/1980509831620>.
- Leite, M. V. S.; Cabacinha, C. D.; Assis, A. L. Classificação da capacidade produtiva com alturas de árvores dominantes estimadas por RNA. **Ciência Florestal**, v. 32, p. 1552-1574, 2022. <https://doi.org/10.5902/1980509867120>.
- Miguel, E. P.; Rezenda, A. V.; Leal, F. A.; Matricardi, E. A. T.; Vale, A. T. do; Pereira, R. S. Redes neurais artificiais para a modelagem do volume de madeira e biomassa do cerradão com dados de satélite. **Pesquisa Agropecuária Brasileira**, v. 50, n. 9, p.829-839, 2015. <http://doi.org/10.1590/S0100-204X2015000900012>.
- Peng, P. H.; Kuo, C. H.; Wei, C.H.; Hsieh, Y. T.; Chen, J. C. The Relationship between Breast Height Form Factor and Form Quotient of *Liquidambar formosana* in the Eastern Part of Taiwan. **Forests**, v. 13, n. 7, e1111, 2022. <https://doi.org/10.3390/f13071111>
- Rabelo, L. K. L.; Maestri, M. P.; Aquino, M. G. C.; Baumann, S. S. R. T.; Santa Brígida, C. A. Cenário das árvores plantadas no Brasil. **Biodiversidade**, v. 19, n. 3, p.170-179, 2020. Disponível em: <https://periodicoscientificos.ufmt.br/ojs/index.php/biodiversidade/article/view/10825>. 14 Jun 2023.
- Silva, M. C.; Silva, F. C. S.; Souza, I. V.; Duarte, V. B. R.; Ataíde, Y.; Coelho, M. C. B. Aplicação de redes neurais artificiais na cultura do mogno (*Khaya* spp. e *Swietenia* spp.). **Journal of Biotechnology and Biodiversity**, v. 8, n. 1, p.17–23, 2020. <https://doi.org/10.20873/jbb.uft.cemaf.v8n1.csilva>.
- Sousa Neto, E. N.; Paula, A. D.; Tagliaferre, C.; Barreto-Garcia, P. A. B.; Longue Júnior, D. Performance assessment of methodologies for vertical stratification in native forests. **Ciência Florestal**, v. 28, n. 4, p. 1583-1591, 2018. <https://doi.org/10.5902/1980509835106>.
- Valente, E. O.; Valente, G. F. S. Simulação de redes neurais artificiais para estimativa de volume de madeira florestal a partir do DAP. **Brazilian Journal of Animal and Environmental Research**, v. 4, n. 3, p.3748-3757, 2021. <https://doi.org/10.34188/bjaerv4n3-080>.
- Vanclay, J. K. **Modelling forest growth and yield: applications to mixed tropical forests**. Wallingford: CAB International, 1994. 330p.