



ACURÁCIA DE MODELOS VOLUMÉTRICOS E REDES NEURAIAS ARTIFICIAIS NA PREDIÇÃO DO VOLUME DE *Tectona grandis* Linn. f.

Ruan Felipe Lima Caldeira¹, Eder Pereira Miguel¹, Mario Lima dos Santos¹, Hallefy Junio
de Souza¹, Kennedy Nunes Oliveira¹

1 Universidade de Brasília, Brasília, DF, Brasil. E-mail: ruanflc1@gmail.com; edermiguel@unb.br; mariolimaeng@gmail.com; hallefyj.souza@gmail.com; kennedynuneso@gmail.com
Autor correspondente: Ruan Felipe Lima Caldeira. E-mail: ruanflc1@gmail.com.

RESUMO

Este estudo buscou comparar o desempenho das estimativas de volume de teca por meio de modelos volumétricos e Redes Neurais Artificiais (RNA) em um povoamento clonal na Amazônia Oriental. Foram cubadas 149 árvores pelo método de Hohenadl. A precisão do ajuste dos modelos volumétricos e das RNAs treinadas foi avaliada pelo erro padrão absoluto e percentual (S_{yx} e S_{yx} %), coeficiente de correlação (r) e análise gráfica de resíduos. A acurácia da RNA e do modelo volumétrico mais precisos, frente o volume verdadeiro, foram comparados pelo teste de Kruskal-Wallis e como estatística complementar se usou a diferença agregada. Os modelos e as redes apresentaram medidas acuradas, dos quais o modelo de Takata e a RNA n° 4 alcançaram uma correlação de 0,991 e erro menor que 7,5 %. Embora a rede tenha tido ligeira superioridade, o teste de Kruskal-Wallis não indicou diferença significativa entre o volume estimado pelas diferentes categorias frente ao volume real, sendo ambos capazes de gerar estimativas acuradas.

Palavras-chave: Inteligência artificial; modelagem; regressão; Teca

ACCURACY OF VOLUMETRIC MODELS AND ARTIFICIAL NEURAL NETWORK ARE IN VOLUME'S PREDICTION OF *Tectona grandis* Linn.f.

ABSTRACT

This study aimed to compare the performance of estimates of teak's volume made by volumetric models and Artificial Neural Networks (ANN) for a clonal stand in the East Amazon. 149 trees were measured by Hohenadl's method. The precision of the adjustment of the volumetric models and the trained ANN was evaluated through the absolute and relative standard error (S_{yx} and S_{yx} %), the correlation coefficient (r) and the graphical analysis of residuals. The accuracy of the most precise ANN and model, with regard to the real volume, were contrasted by means of the Kruskal-Wallis test and the aggregated difference. Both models and networks presented accurate measures, from which the Takata model and ANN n° 4 presented correlation equal to 0.991 and standard error lower than 7.5 %. Although the ANN showed slightly better measures, the Kruskal-Wallis test did not find significant difference between them when they have been faced with the real volume, both being able to predict accurately teak's volume.

Key words: Artificial intelligence; modeling; regression; Teak

ASSOCIAÇÃO BRASILEIRA DE MENSURAÇÃO FLORESTAL



INTRODUÇÃO

A *Tectona grandis* Linn.f. (teca) é uma espécie asiática que vem conquistando espaço no mercado brasileiro. Ela foi introduzida no país em 1968, adaptando-se bem às condições naturais oferecidas pelo país, tendo alcançado hoje alta produtividade. Tem cerca de 94 mil hectares de terras destinadas ao seu plantio, concentradas na Amazônia e no Mato Grosso. Sua madeira, conhecida por sua elevada durabilidade, resistência ao ataque de xilófagos e beleza, possui grande demanda internacional e sendo uma das mais valiosas do mundo (Kollert; & Walotek, 2015).

Diante da importância comercial que a madeira de teca tem, é imprescindível uma quantificação acurada de seu volume. São usados no Brasil, em maior frequência, os modelos volumétricos, sendo o modelo de Schumacher-Hall o que tem apresentado os resultados mais precisos na estimativa de teca (Cerqueira *et al.*, 2017). As Redes Neurais Artificiais são uma alternativa ao uso de modelos de regressão usuais, fornecendo estimativas precisas do volume de madeira (Gorgens *et al.*, 2009; Miguel *et al.*, 2016). Existem muitos estudos que exploraram o uso de RNAs nas estimativas de volume para os gêneros *Pinus* e *Eucalyptus*, no entanto, poucos estudos foram desenvolvidos para teca (Tavares Júnior, 2021).

Diante do exposto, levantou-se a seguinte questão: o uso de RNAs permite gerar estimativas mais precisas que os modelos volumétricos? Para responder tal pergunta, testou-se a hipótese de que as Redes apresentam indicadores de precisão semelhante os modelos, logo, não existem diferença significativa entre volume estimado pelas duas ferramentas. Com isto, este trabalho teve como objetivo avaliar e comparar o desempenho de modelos volumétricos e de RNAs na predição do volume individual de árvores de teca.

MATERIAL E MÉTODOS

O presente estudo foi realizado em plantios clonais de teca (833,03 ha), localizado no município de Capitão Poço, Estado do Pará (Figura 1), em área pertencente à Fazenda São Luiz, do grupo Tietê Agrícola Ltda.

Os dados utilizados neste estudo são oriundos de um inventário florestal contínuo medidas nos anos de 2012 a 2022, composto pelo processo de amostragem sistemático, com 72 parcelas permanentes de 500 m² de área. As informações de diâmetros a 1,30m do solo (D) e altura total (H) foram obtidas com fita diamétrica e Vertex, respectivamente. Foram cubadas 149 árvores pelo método relativo de Hohenadl com 10 seções. Foram selecionadas aleatoriamente 70 % (149 árvores) para o treinamento das redes neurais e dos modelos volumétricos e 30 % para a validação dos resultados, submetidas a um teste de equivalência de bootstrap, que consiste em repetidas reamostragem com recombinações para gerar a distribuição amostral dos parâmetros.

Foram escolhidos quatro modelos volumétricos: um modelo linear de dupla entrada (Spurr), um modelo não linear de simples entrada (Berkhout) e dois modelos lineares de dupla entrada

VI Encontro Brasileiro de Mensuração Florestal

(Schumacher & Hall e Takata). Os ajustes de regressão foram processados utilizando o software *R Studios* com o algoritmo de Levenberg–Marquardt da função “nlsLM”, do pacote ‘minpack.lm’.

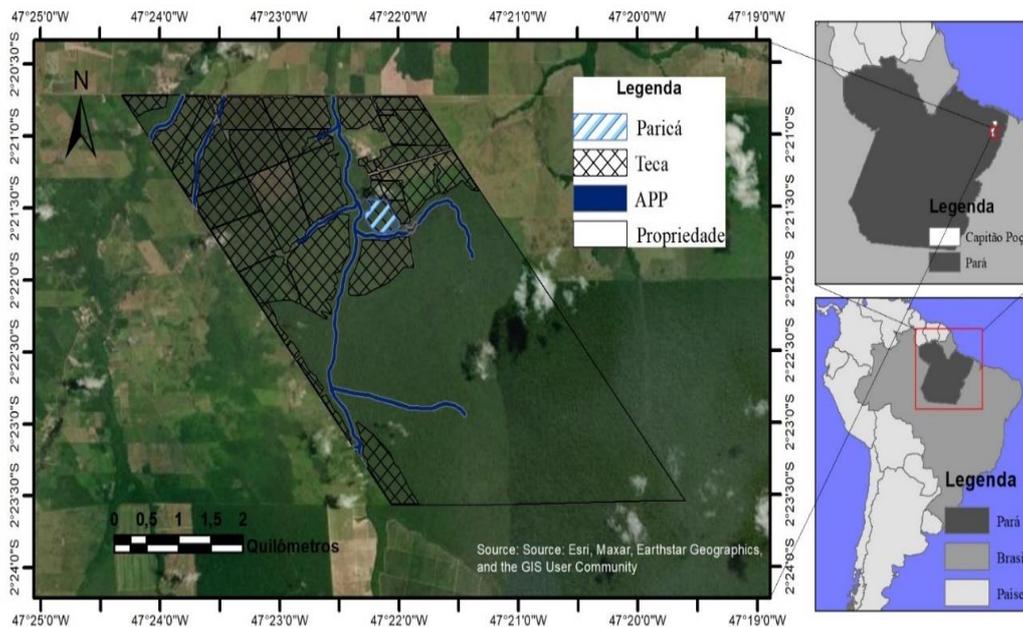


Figura 1. Localização dos talhões de teca e de paricá, e da APP (Área de Preservação Permanente) no município de Capitão Poço, PA

Foi aplicado um treinamento supervisionado de 20 Redes neurais no software Statistica 14.0.1, sendo usado o algoritmo quase-Newton de Broyden-Fletcher-Goldfarb-Shanno (BFGS). As redes treinadas possuem arquitetura do tipo Perceptron de Múltiplas Camadas (MLP) em que a camada de entrada foi constituída pelas variáveis D e H, uma camada oculta por n neurônios e uma camada de saída por um neurônio, o volume da árvore (v).

Para a avaliação e seleção das equações e das Redes Neurais, adotou-se os seguintes critérios: 1) menor erro padrão absoluto (S_{yx}) e relativo ($S_{yx}\%$); 2) maior coeficiente de correlação entre os valores observados e estimados (r); 3) análise gráfica dos resíduos; 4) menor critério de informação de Akaike (apenas os modelos). Foram avaliados pelos testes de Shapiro-Wilk e de Bartlett, respectivamente, a normalidade dos resíduos e a homogeneidade das variâncias. Aplicou-se o teste não paramétrico de Kruskal-Wallis ao nível de 95% de probabilidade, comparando o volume real com o estimado pela rede e modelo de regressão mais acurados. No caso de identificação de diferenças significativas entre a RNA e o modelo volumétrico, o teste de médias de Tukey será aplicado.

Por fim, visando analisar a acurácia dos volumes predito pela melhor RNA e o melhor modelo volumétrico selecionado, foi feito o cálculo da Diferença Agregada em porcentagem (%). A Diferença Agregada é dada pela diferença entre a soma dos valores observados e estimados de volume e indica o quanto as estimativas distaram ao todo dos valores observados.

RESULTADOS E DISCUSSÃO

Os modelos apresentaram valores de r variando de 0,980 a 0,991, enquanto o erro padrão variou de 7,4 a 10,9 %, errando em média $0,03 \text{ m}^3$, havendo pouca discrepância entre as equações ajustadas. O modelo de Takata teve as maior correlação e menor erro padrão, assim como, o menor valor para o critério de Akaike entre os modelos (Tabela 1).

Tabela 1. Coeficientes e medidas de precisão do modelo de Takata e RNA n° 4

| | Coeficientes | Arquitetura | r | S_{yx} | AIC | f(x) oculta | f(x) saída |
|----------|---|-------------|-------|----------|---------|-------------|------------|
| Takata | $b_0 = 18,155,59 *$ $b_1 = 385,25 *$ | - | 0,991 | 7,404 | -484,21 | - | - |
| RNA n° 4 | - | MLP 2-3-1 | 0,991 | 7,277 | - | Exponencial | Logística |

Em que: b_i = parâmetros dos modelos; r = coeficiente de correlação; S_{yx} = erro padrão relativo; AIC = critério de Akaike; * = significativo a 1 %; f(x) oculta = função de ativação da camada oculta; f(x) saída = função de ativação da camada saída

De modo geral, as estimativas dos modelos demonstraram uma tendência a superestimar valores de volume inferiores a $0,25 \text{ m}^3$. Já ao se observar os histogramas e o gráfico de dispersão de resíduos, nota-se que Takata teve distribuição mais homogênea de resíduos num intervalo de $0 \pm 10 \%$ (Figura 2). Tais pontos fazem com que o modelo de Takata seja o mais adequado na estimativa do volume, corroborando com o trabalho de Souza *et al.* (2022) que, trabalhando com teça nesse mesmo povoamento, indicou seu melhor desempenho, com um erro padrão de 5,77 % e correlação de 0,994. Volume (m^3)

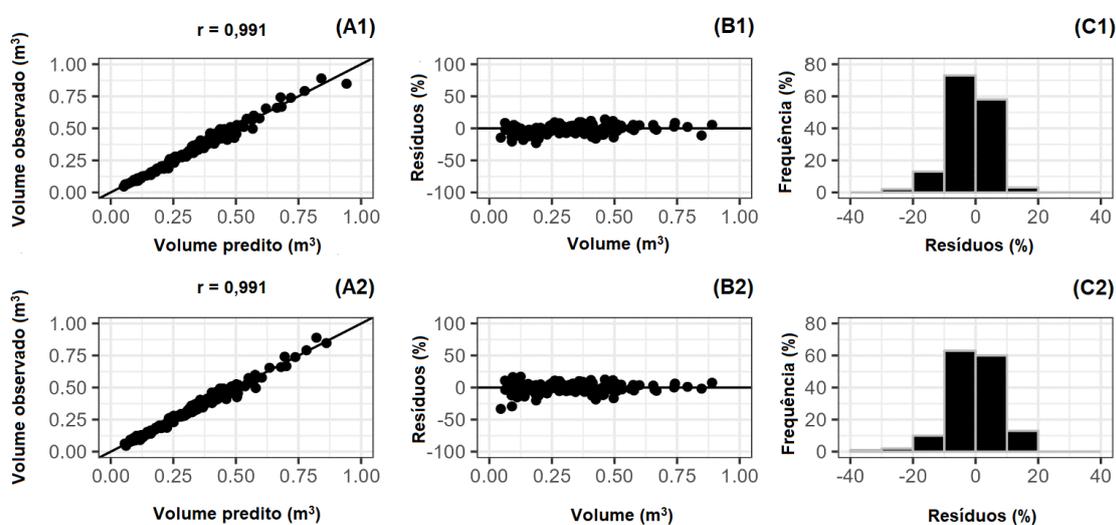


Figura 2. Relação entre observados x estimados (Ai), dispersão de resíduos (Bi) e distribuição de classes de resíduos (Ci) para volume previsto por redes neurais para um plantio clonal de teça. Em que i: 1 – Takata; 2 – RNA 4

As quatro Redes selecionadas apresentaram correlação e erro padrão com pouca variação, variando de 0,990 a 0,991, e de 7,277 a 7,892 %, respectivamente, indicando seu poder preditivo. O número de neurônios na camada oculta variou de 3 a 7. Dentre as funções de ativação, tanto nas camadas oculta quanto nas de saída, predominaram a escolha por funções exponenciais, havendo também funções logísticas e as tangenciais hiperbólicas. Semelhante aos modelos ajustados, todas as redes apresentaram uma leve tendência a superestimativas de volumes menores

VI Encontro Brasileiro de Mensuração Florestal

que 0,25 m³. A Rede nº 4 teve o menor erro padrão (Tabela 1) e a distribuição mais uniforme de resíduos, mesmo em volumes menores (Figura 1), sendo a selecionada para comparação.

O modelo de Takata e a Rede nº 4, que foram os mais acurados segundo os critérios de medidas de precisão, foram validados pelo teste de equivalência de *bootstrap* ($\epsilon=0,25$ e $\alpha = 0,05$, com 1000 repetições), sendo, em ambos os casos, apontada a não diferença estatística entre os valores observados e estimados, rejeitando-se a hipótese de dissimilaridade para os parâmetros.

Ao se comparar a Rede 4 e a equação ajustada de Takata, nota-se que não houve uma diferença tão discrepante, tendo ambos uma correlação de 0,991 e havendo uma ligeira superioridade da Rede quando comparados os erros padrões. Outro resultado que apontou uma ligeira vantagem para a Rede selecionada foi o teste da diferença agregada, que foi de 0,427 %, contra -0,438 % do modelo. Este padrão de superestimativas por modelos e subestimativas por redes foi encontrado por Miguel *et al.* (2015), trabalhando com árvores do Cerradão, sendo indicada diferentes tendências de estimativas por cada ferramenta.

O resultado do teste de Bartlett (p-valor = 0,973) não indicou variâncias heterogêneas entre os grupos. Por outro lado, não ocorreu a normalidade dos dados, segundo o teste de Shapiro-Wilk (p-valor = 0,00035). Por esta razão, os valores observados e estimados foram levados para o teste não paramétrico de Kruskal-Wallis. Não foi encontrado pelo teste diferença significativa entre valor predito por eles e os volumes reais, apontado pelo $p = 0,986$, superior ao nível de 0,05, sendo os dois métodos igualmente válidos para estimar o volume de teca nas condições aqui citadas.

CONCLUSÃO

Dentre os modelos volumétricos de madeira de *T. grandis* avaliados, o modelo de Takata apresentou estatísticas de ajuste e precisão mais acuradas. Dentre as RNAs, usando diâmetro e altura como entradas, a Rede nº 4, de arquitetura MLP 2-3-1, foi a mais indicada na quantificação de madeira. Embora a Rede nº 4 tenha tido menor erro padrão que o modelo de Takata, o teste de Kruskal-Wallis não encontrou diferença significativa entre o volume estimado por eles e o volume observado.

REFERÊNCIAS BIBLIOGRÁFICAS

- Cerqueira, C. L.; Lisboa, G. S.; França, L. C. J.; Môra, R.; Marques, G. M.; Salles, T. T.; Brianezi, D. Modelagem da altura e volume de *Tectona grandis* L. F. na mesorregião Nordeste do Pará. **Nativa**, v. 5, n.7, p.606-611, 2017. Disponível em: <https://periodicoscientificos.ufmt.br/ojs/index.php/nativa/article/view/5037>. Acesso em: 15 Mar. 2023.
- Gorgens, E. B.; Leite, H. G.; Santos, H. N.; Gleriani, J. M. Estimação do volume de árvores utilizando redes neurais artificiais. **Revista Árvore**, v. 33, n. 6, p.1141–1147, 2009. <https://doi.org/10.1590/S0100-67622009000600016>.
- Kollert, W.; Walotek, P. J. **Global teak trade in the aftermath of Myanmar's log export ban**. Rome: FAO, 2015. 36 p. Disponível em: <https://www.fao.org/publications/card/en/c/900604da-befc-4b13-92bd-7336ab84f594>. Acesso em: 10 Mar. 2023.
- Miguel, E. P.; Mota, F. C. M.; Téó, S. J.; Nascimento, R. G. M.; Leal, F. A.; Pereira, R. S.; Rezende, A. V. Artificial intelligence tools in predicting the volume of trees within a forest stand. **African Journal of Agricultural Research**, v. 11, n. 21, p.1914–1923, 2016. <https://doi.org/10.5897/AJAR2016.11015>.

VI Encontro Brasileiro de Mensuração Florestal

Miguel, E. P.; Rezende, A. V.; Leal, F. A.; Matricardi, E. A. T.; Vale, A. T.; 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. <https://doi.org/10.1590/S0100-204X2015000900012>.

Souza, H. J.; Miguel, E. P.; Nascimento, R.G. M.; Cabacinha, C. D.; Rezende, A. V.; Santos, M. L. Thinning-response modifier term in growth models: An application on clonal *Tectona grandis* Linn F. stands at the amazonian region. **Forest Ecology and Management**, v. 511, e120109, 2022. <https://doi.org/10.1016/j.foreco.2022.120109>.

Tavares Júnior, I. S.; Souza, J. R. M.; Lopes, L. S. S.; Fardin, L. P.; Casas, G. G.; Oliveira Neto, R. R.; Leite, R. V.; Leite, H. G. Machine learning and regression models to predict multiple tree stem volumes for teak. **Southern Forests**, v. 83, n. 4, p.294–302, 2021. <https://doi.org/10.2989/20702620.2021.1994345>.