

## Prognose do crescimento e produção de *Corymbia citriodora* empregando redes neurais artificiais

Valdir Carlos Lima de Andrade<sup>1\*</sup> Amanda Martins Cardoso<sup>1</sup> Daniel Henrique Breda Binotti<sup>2</sup>

<sup>1</sup> Universidade Federal do Tocantins (UFT), Campus Gurupi, Rua Badejós, Lote 7, CEP: 77402-970, Gurupi, TO, Brasil

<sup>2</sup> Eldorado Brasil Celulose SA, Três Lagoas, MS, Brasil

### Original Article

\*Corresponding author:  
vclandrade@uft.edu.br

**Palavras-chave:**  
Mensuração Florestal

Cerrado

Índice de sítio

**Keywords:**  
Forest measurement

Savanna

Site index

Received in  
2021/08/08

Accepted on  
2022/05/06

Published in  
2022/06/30



DOI:  
<http://dx.doi.org/10.34062/af.s.v9i2.12829>



**RESUMO:** Por conta da importância de se aplicarem refinamentos às técnicas de prognose, a aplicação de Inteligência Artificial, como por exemplo as Redes Neurais Artificiais (RNA), se constituiu de uma alternativa vantajosa à modelagem do crescimento e produção florestal. Nesse sentido, se desenvolveu este trabalho com o objetivo avaliar o emprego de RNA na prognose do crescimento e produção madeireira comparando-se com a análise de regressão. Os dados foram coletados em um plantio de *Corymbia citriodora* por meio de um inventário florestal contínuo feito nas idades de 42, 54 e 66 meses. Na avaliação dos resultados obtidos, em uma validação com dados dependentes, adotou-se os critérios estatísticos: média dos desvios percentuais, raiz quadrada do erro médio, correlação e soma dos quadrados dos resíduos, além da análise gráfica da distribuição de resíduos. Incluiu-se, também nesta avaliação, a interpretação biológica das tendências de crescimento e produção florestal. Em uma etapa final de avaliação, procedeu-se a validação cruzada com o emprego do teste de qui-quadrado ao nível de 5% de significância. Concluiu-se que a prognose realizada por meio de RNA resultou em um melhor nível de acurácia que o emprego da análise de regressão.

### Growth and yield prognosis of *Corymbia citriodora* using artificial neural networks

**ABSTRACT:** Because of the importance of applying refinements to prediction techniques, the application of Artificial Intelligence, such as Artificial Neural Networks (ANN), has become an advantageous alternative for modeling forest growth and production. In this sense, this work was developed with the objective of evaluating the use of ANN in wood growth and production prediction, comparing it with regression analysis. Data were collected from a *Corymbia citriodora* plantation through a continuous forest inventory at ages of 42, 54, and 66 months. In the evaluation of the results obtained, in a validation with dependent data, the following statistical criteria were adopted: mean of the percentage deviations, square root of the mean error, correlation, and sum of squares of the residues, in addition to the graphic analysis of the residue distribution. The biological interpretation of growth and forest production trends was also included in this evaluation. In a final step, cross-validation was performed using the chi-square test at 5% significance level. It was concluded that the prediction performed using ANN resulted in a better level of accuracy than the use of regression analysis.

## Introdução

O *Corymbia citriodora*, por se caracterizar com tronco ereto e casca lisa, de folhas se destacando devido ao forte odor de citronela apresentando, em sua maioria, indivíduos de médio a grande porte, é ideal para produzir diferentes usos madeireiros, tais como: serraria, móveis, carvão vegetal, mourões e postes, além de atender demandas de óleos essenciais como citronelal (Vitti e Brito 2003; Reis et al. 2013).

Diante disso, previsões futuras e confiáveis da produção de madeira, também são necessárias em plantios com *C. citriodora*, haja vista que os trabalhos brasileiros neste tema não consideram esta espécie. Motivos disso, se pode enumerar a falta de interesse empresarial do setor que foca somente em clones de eucalipto e os plantios com *C. citriodora*, que se constituem de pequenas áreas, principalmente, feitos por pequenos e médios proprietários rurais (Reis et al. 2013; Andrade et al. 2019).

O cenário apresentado acima, justifica que estudos sejam desenvolvidos para averiguar metodologias que melhor descrevam a produção florestal que, neste caso, podem ser representados por meio de modelos estatísticos, denominados: Modelos de Crescimento e Produção, ou, Modelos de Prognose Florestal. Tais modelos, baseados em dados de crescimento obtidos pelo seu monitoramento em um determinado período de tempo, empregam a análise de regressão considerando o espaçamento de plantio, espécie e a capacidade produtiva (Couto e Bastos 1989; Campos e Leite 2013).

Em contrapartida a isso, o uso da inteligência artificial vem ganhando destaque à este fim, notadamente, com o emprego de Redes Neurais Artificiais (RNA). As RNA's se consistem de um conjunto de neurônios artificiais que funcionam de forma parecida com os neurônios encontrados no cérebro humano. Estes, podem ser caracterizados como modelos simplificados dos neurônios biológicos, capazes de processar as informações recebidas e ponderá-las por peso sináptico resultando em uma única resposta (Silva et al. 2009; Binoti et al. 2013).

Por conta da importância de refinamentos na modelagem do crescimento e produção florestal, a aplicação de RNA pode se constituir de uma alternativa vantajosa com este objetivo. Neste sentido, se observa o seu emprego na área florestal apresentando resultados satisfatórios e eficazes, se comparados com a análise de regressão (Binoti et al. 2013 e 2015; Campos et al. 2016; Reis et al. 2018).

Diante deste contexto, se justificam estudos sobre a prognose do crescimento e produção madeireira de *C. Citriodora*, porque irá contribuir sobremaneira no preenchimento da

grande lacuna existente de informações sobre plantios com esta espécie com enfoque na manutenção do seu potencial produtivo. Portanto, o presente estudo teve como objetivo avaliar o emprego de RNA na modelagem do crescimento e produção de madeira de *C. citriodora*, frente ao emprego de equações de regressão.

## Material e Métodos

### Coleta de dados

Os dados foram coletados em 80,9 ha de um plantio seminal de *Corymbia citriodora*, implantado no espaçamento inicial de 3 x 2 m e localizado próximo ao município de Gurupi, Tocantins. Nesta região, o clima, segundo a classificação de Köppen, é do tipo Aw, tropical com estação seca, tendo temperatura mínima média anual em torno de 21 °C e máxima média anual de 34 °C, além de média pluviométrica em torno de 1.288 mm/ano (Andrade et al. 2019).

Por meio de um inventário florestal contínuo (IFC), foram mensuradas oito parcelas retangulares de 720 m<sup>2</sup>, nas idades de 44, 55 e 66 meses. Houve, então, uma representatividade aproximada de 10 ha por parcela, ou seja: em média, se utilizou uma intensidade amostral de 1 parcela à cada 10 ha que foram distribuídas pelo procedimento sistemático.

### Obtenção de índices de sítio

A classificação da capacidade produtiva foi feita por meio do método da curva guia empregando-se o modelo estatístico Md.1, abaixo apresentado com a seguinte conformação:

$$\ln(Hd) = b_0 + b_1 \left(\frac{1}{I}\right) + (\varepsilon) \quad (\text{Md.1})$$

Em que: Ln= logaritmo neperiano, Hd= altura dominante (m),  $b_0$  e  $b_1$ = coeficientes de regressão a serem estimados, I= idade (meses),  $\varepsilon$ = erro do modelo.

O ajuste do modelo de regressão linear simples Md.1, empregando-se o método dos mínimos quadrados ordinários, resultou na estimativa da equação:  $(\widehat{\ln Hd}) = \widehat{b}_0 + \widehat{b}_1 \left(\frac{1}{I}\right)$ , que, após proceder ao uso da variável de interesse Hd, gerou-se a seguinte equação Eq.1:

$$\widehat{Hd} = e^{[\widehat{b}_0 + \widehat{b}_1 \left(\frac{1}{I}\right)]} \quad (\text{Eq.1})$$

Em que:  $\widehat{Hd}$ = altura dominante estimada (m), e= inverso de Ln,  $\widehat{b}_0$  e  $\widehat{b}_1$ = coeficientes de regressão já estimados, demais já foram definidos.

Ao aplicar o método da curva guia considerando-se uma idade índice de 60 meses (I60), a partir de Eq.1 se obtêm a equação Eq.2 para emprego na determinação dos limites das

classes de produtividade, ou, de índices de sítio (Scolforo 2006; Campos e Leite 2013; Husch et al. 2013), que foi denominado: método de classificação de índice de sítio 1 (S1). A equação Eq.2 obtida é a seguinte:

$$\widehat{Hd} = e^{\left[\ln(S) + \widehat{b}_0 + \widehat{b}_1 \left(\frac{1}{I_1} - \frac{1}{I_2}\right)\right]} \quad (\text{Eq.2})$$

Em que: S= índice de sítio, ou *site*, demais já foram definidos.

Quanto ao emprego de RNA, inicialmente, por meio do Software NeuroForest versão 3.2 (Neuroforest 2018), foi feito o treinamento tendo Hd como variável de saída e idade a variável de entrada. Com isso, utilizando-se os mesmos dados obtidos com a RNA treinada, graficamente em I60, se obteve um valor central de Hd para orientar as curvas de índice de sítio, em cujo método foi denominado: método de classificação do índice de sítio 2 (S2).

Em um outro procedimento, agora aplicando a RNA treinada, se obteve um valor de Hd em I60 para orientar as curvas de índice de sítio, em cujo método foi denominado: método de classificação de índice de sítio 3 (S3).

Os valores de Hd, obtidos nos métodos S2 ( $Hd_{RNA S2}$ ) e S3 ( $Hd_{RNA S3}$ ), foram utilizados para definir as classes de sítio em diferentes idades por meio da proporção destes com os limites inferiores e superiores das classes de sítio. Isto é, foram aplicadas as equações Eq.3 e Eq.4, quais sejam as seguintes:

$$HdC_i = \left(\frac{LC_i}{Hd_{RNA S2}}\right) (Hd_{RNA I}) \quad (\text{Eq.3})$$

$$HdC_i = \left(\frac{LC_i}{Hd_{RNA S3}}\right) (Hd_{RNA I}) \quad (\text{Eq.4})$$

Em que:  $HdC_i$ = altura dominante da *i*-ésima classe,  $LC_i$ =limite da *i*-ésima classe em I60,  $Hd_{RNA S2}$  e  $Hd_{RNA S3}$ = altura dominante obtida pela aplicação dos métodos S2 e S3, respectivamente,  $Hd_{RNA I}$ = altura dominante obtida pela aplicação da RNA treinada nas idades de 42, 54 e 66 meses.

#### Prognose volumétrica

Após obter a variável índice de sítio, ou *site*, com a aplicação das equações Eq.2, Eq.3 e Eq.4, foram ajustados os seguintes modelos de prognose do crescimento e produção florestal (Md.2, Md.3 e Md.4):

$$\ln(v) = b_0 + b_1 \left(\frac{1}{I}\right) + \ln(\epsilon) \quad (\text{Md.2})$$

$$\ln(v) = b_0 + b_1 \left(\frac{1}{I_S}\right) + \ln(\epsilon) \quad (\text{Md.3})$$

$$\ln(V_2) = b_0 + b_1 \left(\frac{1}{I_2}\right) + b_2(S)$$

$$+ b_3 \ln(G_2) + \ln(\epsilon) \quad (\text{Md.4a})$$

$$\ln(G_2) = \ln(G_1) \left(\frac{1}{I_2}\right) + b_1 \left(1 - \frac{1}{I_2}\right) + b_2(S) \left(1 - \frac{1}{I_2}\right) + \ln(\epsilon) \quad (\text{Md.4b})$$

Em que:  $v$ = volume ( $m^3 ha^{-1}$ ),  $I_1$ = idade presente (meses),  $I_2$ = idade futura (meses),  $G_1$ = área basal em  $I_1$  ( $m^2 ha^{-1}$ ),  $G_2$ =área basal em  $I_2$  ( $m^2 ha^{-1}$ ),  $V_2$ = volume de madeira em  $I_2$  ( $m^3 ha^{-1}$ ), S= site,  $b_0$  à  $b_2$ = coeficientes a serem estimados, demais já foram definidos anteriormente.

Também, se realizou a prognose volumétrica empregando RNA tendo como variáveis de entrada a idade e o sítio obtido por RNA (S2 ou S3), tendo como variável de saída o volume, sendo denominado: RNAIS. Para efeito de comparação, similar ao modelo Md.2, também se realizou a prognose volumétrica empregando-se RNA tendo como variável de entrada apenas a idade e a variável de saída o volume, sendo denominado: RNAI.

#### Avaliação do índice de sítio e da prognose volumétrica

A aplicação das equações Eq.2, Eq.3 e Eq.4, gerou os índices de sítios em cada uma das oito parcelas de IFC. Dentre estas, se ressalta que as equações Eq.3 e Eq.4 foram avaliadas em separado para decisão entre os métodos S2 e S3 (RNA) e, posteriormente, comparar com o método S1 (equação de regressão - Eq.2).

Como critérios de avaliação, em uma validação com dados dependentes, se adotou o coeficiente de determinação e o erro padrão residual obtidos no ajuste do modelo Md.3, porque se verifica uma diferença apenas no sítio utilizado S1, S2 e S3, já que o volume totalizado nas parcelas de IFC ( $m^3 ha^{-1}$ ) e as idades 42, 54 e 66 meses se constituem dos mesmos valores, respectivamente.

Decidido pelo método de *site* com aplicação de RNA (S2 ou S3), além de S1, procedeu-se a avaliação da prognose volumétrica empregando-se as equações geradas a partir do ajuste dos modelos Md.2 e Md.3, incluindo-se também RNA. Para isso, se realizou uma validação com dados dependentes adotando-se os critérios estatísticos: média dos desvios percentuais (MDP), raiz quadrada do erro médio (RQEM), correlação (*r*) e soma dos quadrados dos resíduos (SQR), como se observa em: (Binoti et al. 2015; Campos et al. 2016; Reis et al. 2018). Neste caso, ressalta-se que todos os ajustes foram feitos empregando-se o software R For Windows (R CORE TEAM, 2015).

Uma análise gráfica da distribuição de resíduos foi feita para se averiguar as tendências das estimativas volumétricas obtidas. Também, foi feita a análise da interpretação biológica do

crescimento e produção madeireira providos pelas equações geradas a partir dos modelos Md.2 e Md.3 e providos pelo emprego de RNA.

A prognose volumétrica também foi avaliada com o emprego do modelo de Clutter (1963), representado pelo ajuste dos modelos 4a e 4b. Nesta oportunidade, se realizou uma validação cruzada utilizando-se dois bancos de dados diferentes com 4 parcelas cada para ajuste e aplicação e *vice-versa*. Para esta análise, adotou-se o teste qui-quadrado ao nível de 0,05 de significância empregando-se a equação Eq.5, que é a seguinte:

$$Q_c^2 = \sum_{i=0}^n \frac{(V_R - V_{Pg})^2}{V_{Pg}} \quad \text{Eq.5.}$$

Em que:  $Q_c^2$  = estatística de qui-quadrado calculada ao nível de 5% de significância,  $V_R$  = volume real ( $m^3ha^{-1}$ ),  $V_{Pg}$  = volume prognosticado ( $m^3ha^{-1}$ ).

Nos casos em que o teste qui-quadrado foi significativo, se calculou a exatidão empregando-se a equação Eq.6, que é a seguinte:

$$Ex = \pm \sqrt{\left[ \left( \frac{196^2}{Q^2 n} \right) (Q_c^2) \right]} \quad \text{Eq.6}$$

Em que:  $Ex$  = exatidão obtida pelo teste de qui-quadrado ao nível de 95% de probabilidade,  $Q^2 n$  = qui-quadrado tabelado ao nível de 5% de significância.

**Resultados e Discussão**

*Método da curva guia utilizando regressão:*

O ajuste do modelo Md.1, resultou na estimativa da equação Eq.7, a qual é a seguinte:

$$\widehat{Hd} = e^{[3,18311 - 34,12189(\frac{1}{I})]} \quad \text{(Eq.7);}$$

com  $R^2_{aj} = 0,575$  e  $EPR = 11,01$  %.

Em que:  $R^2_{aj}$  = coeficiente de determinação ajustado,  $EPR$  = erro padrão residual, demais já foram definidos.  $R^2_{aj}$  e  $EPR$  foram recalculados com base em  $Hd$  real e  $\widehat{Hd}$ .

Aplicando-se o método da curva guia (Scolforo, 2006; Campos e Leite, 2013; Husch et al. 2013), ao igualar na equação Eq.7 à altura dominante com o *site* e a idade à I60, se obteve uma outra equação (Eq.8) para definir os limites das classes de produtividade, que é a seguinte:

$$\widehat{Hd} = e^{[\ln(S) + 34,12189(\frac{1}{60} - \frac{1}{I})]} \quad \text{(Eq.8)}$$

A análise da altura dominante em I60, permitiu identificar uma amplitude total entre 11,0 m a 16,0 m. Com isso, se pôde definir duas classes de produtividade com 2,5 m de amplitude cada, sendo de 11,0 m a 13,5 m a classe I, com  $SI = 12,25$  m e de 13,5 m a 16,0 m a classe II, com  $SII = 14,75$  m. Nessa situação identificada S1, foi empregada a Eq.8 para definir os limites de cada classe fazendo S igual a 11,0 m, 13,5 m e 16,0 m para as idades I de 42, 54 e 66 meses, respectivamente (Scolforo 2006).

*Método da curva guia utilizando RNA:*

O emprego de RNA, na identificação de índices de sítio, foi feito por meio dos métodos S2 e S3, representados pelas equações Eq.3 e Eq.4, respectivamente. Assim, inicialmente por meio da análise gráfica em I60, obteve-se os valores de  $Hd_{RNA S2} = 13,35$  m e  $Hd_{RNA S3} = 13,17$  m.

Tabela 1. Equações obtidas para emprego dos métodos de classificação de índices de sítio S2 e S3.

RNA	LI = 11 m	LIi = 13,5 m	LS = 16 m
S2	$Hd_{11} = \left(\frac{11,00}{13,35}\right) (Hd_{RNAi})$ eq.9	$Hd_{13,5} = \left(\frac{13,50}{13,35}\right) (Hd_{RNAi})$ eq.10	$Hd_{16} = \left(\frac{16,00}{13,35}\right) (Hd_{RNAi})$ eq.11
S3	$Hd_{11} = \left(\frac{11,00}{13,17}\right) (Hd_{RNAi})$ eq.12	$Hd_{13,5} = \left(\frac{13,50}{13,17}\right) (Hd_{RNAi})$ eq.13	$Hd_{16} = \left(\frac{16,00}{13,17}\right) (Hd_{RNAi})$ eq.14

LI= limite inferior, LIi= limite intermediário, LS= limite superior, RNA= redes neurais artificiais,  $Hd_{11}$ ,  $Hd_{13,5}$  e  $Hd_{16}$ = altura dominante limite para as classes de *site*: 12,25 m e 14,75 m,  $Hd_{RNAi}$ = altura dominante obtida pela aplicação da RNA nas i-ésima idade em meses.

Tabela 2. Limites de classes de produtividade para diferentes idades obtidos pelos métodos de classificação de índices de sítio S1, S2 e S3.

I	Método S1 – Regressão			Método S2 – RNA			Método S3 – RNA		
	Hd11	Hd13,5	Hd16	Hd11	Hd13,5	Hd16	Hd11	Hd13,5	Hd16
42	8,62	10,58	12,54	9,22	11,31	13,41	9,34	11,47	13,59
54	10,33	12,67	15,02	9,95	12,21	14,47	10,08	12,37	14,66
66	11,58	14,22	16,85	12,03	14,76	17,49	12,19	14,96	17,73

I= idade (mês), método S1= emprego da equação Eq.8, método S2= emprego das equações eq.9 a eq.11, método S3= emprego das equações eq.12 a eq.14,  $Hd_{11}$ ,  $Hd_{13,5}$  e  $Hd_{16}$ = limite de classes de altura dominante em I60.

A aplicação dos valores de  $Hd_{RNA S2}$  e  $Hd_{RNA S3}$  nas equações Eq.3 e Eq.4, para cada limite das classes de sítio em I60 de 11,0 m, 13,5 m e 16,0 m, permitiram gerar as equações

apresentadas na Tabela 1. Tais equações, Eq.9 a Eq.11 e Eq.12 a Eq.14 (RNA), juntamente com a equação Eq.8 (regressão), permitiram gerar as classes de *site* apresentadas na Tabela 2.

*Análise dos índices de sítio obtidos por regressão e RNA:*

O emprego dos métodos de classificação de índices de sítio S1 (regressão), S2 e S3 (RNA) nas oito parcelas de IFC, resultou na sua classificação com os índices de sítios 12,25 m e 14,75 m (Tabela 2). Em seguida, para cada classificação S1, S2 e S3, obteve-se as equações de produção volumétrica Eq.15, Eq.16 e Eq.17, quais sejam as seguintes:

$$\hat{v} = e^{[4,86710 - 977,641(\frac{1}{IS1})]} \quad (\text{Eq.15});$$

com  $R^2_{aj} = 0,514$  e  $EPR = 28,98\%$ .

$$\hat{v} = e^{[4,93079 - 1023,190(\frac{1}{IS2})]} \quad (\text{Eq.16});$$

com  $R^2_{aj} = 0,562$  e  $EPR = 27,52\%$ .

$$\hat{v} = e^{[4,70009 - 819,379(\frac{1}{IS3})]} \quad (\text{Eq.17});$$

com  $R^2_{aj} = 0,372$  e  $EPR = 32,96\%$ .

Em que:  $\hat{v}$  = volume prognosticado ( $m^3ha^{-1}$ ), S1, S2 e S3 = métodos de índices de sítio (Tabela 2),  $R^2_{aj}$  e  $EPR$  neste caso foram recalculados com base em  $v$  real e  $\hat{v}$ , demais já foram definidos anteriormente.

As equações Eq.16 e Eq.17 foram geradas apenas para se decidir sobre a classificação da produtividade entre S2 e S3 (RNA) e depois comparar com S1 empregando-se a equação Eq.15 (regressão). Nestas equações, há uma diferença apenas no site gerado pelos métodos S1, S2 e S3, já que as variáveis volume e idade são as mesmas.

Na análise das equações Eq.16 e Eq.17, se observa que o emprego de S3, para representar o efeito do local (*site*), foi pior que S2, o qual apresentou melhor resultado de  $R^2_{aj}$  (0,562 *versus* 0,372) e de  $EPR$  (27,52% *versus* 32,96%). Portanto, o emprego de RNA na classificação da produtividade definindo o *site*, é mais apropriado seguir os procedimentos concernentes à S2 do que S3. Neste caso, também se observa que S2 foi superior ao S1, o qual representa a metodologia usual com emprego de equações de regressão.

*Análise da prognose da produção volumétrica obtida por regressão e RNA:*

A decisão pelo emprego de RNA, para obter índices de sítio por meio de S2, levou à obtenção do volume empregando RNA tendo como variáveis de entrada a idade e o *site* obtido por S2, sendo denominado:  $vRNAIS2$ . Para efeito de comparação, também se empregou a RNA tendo como variável de entrada apenas a idade, sendo denominado:  $vRNAI$ .

Ampliando a comparação com uso de  $vRNAIS2$  e  $vRNAI$ , inclui-se o emprego da equação Eq.15 que utilizou o *site* obtido por S1, sendo denominado:  $vRegIS1$ . Também, a partir

do ajuste do modelo Md.2, denominado:  $vRegI$ , obteve-se a seguinte equação de produção eq.18:

$$\hat{v} = e^{[4,67588 - 61,37312(\frac{1}{I})]} \quad (\text{Eq.18});$$

com  $R^2_{aj} = 0,327$  e  $EPR = 34,11\%$ .

Em que:  $\hat{v}$ ,  $e$ ,  $I$ ,  $R^2_{aj}$  e  $EPR$  já foram definidos.

Ao comparar as equações Eq.18 ( $vRegI$ ) e Eq.15 ( $vRegIS1$ ), se observa que o emprego do índice de sítio se pronunciou necessário devido aos resultados de  $R^2_{aj}$  (0,327 *versus* 0,514) e  $EPR$  (34,11% *versus* 28,98%) serem bem melhores no ajuste com a inclusão desta variável associada à idade, na forma:  $\frac{1}{IS1}$ . Também, apesar de os resultados de  $R^2_{aj}$  e  $EPR$  mostrar indícios sobre a superioridade de RNA ( $vRNAIS2$  - Eq.16) frente à regressão ( $vRegIS1$  - Eq.15), se depreendeu ser necessário, na comparação da produção prognosticada incluindo-se RNA ( $vRNAI$  e  $vRNAIS2$ ), considerar outros critérios estatísticos de análise, quais sejam: MDP, RQEM,  $r$  e SQR.

Na Tabela 3, se observam resultados bem melhores para  $vRNAI$  em comparação com  $vRegI$ , sendo obtidos valores reduzidos em cerca de 9,14% para RQEM e 18,29% para SQR, o que se evidencia um indicativo de  $vRNAI$  ser melhor que  $vRegI$  para prognosticar a produção volumétrica. Apenas para MDP é que  $vRegI$  foi melhor com uma redução de 14,65%.

Tabela 3. Resultados dos critérios estatísticos adotados na avaliação da prognose volumétrica empregando-se regressão e RNA.

CE	$vRegI$	$vRNAI$	$vRegIS1$	$vRNAIS2$
MDP	5,36	6,28	3,36	3,56
RQEM	32,66	29,52	27,75	21,16
$r$	0,592	0,671	0,727	0,847
SQR	3.253,2	2.658,3	2.348,5	1.366,0

CE= critério estatístico, MDP=média dos desvios percentuais (%), RQEM= raiz quadrada do erro médio (%),  $r$ = correlação entre volume real e prognosticado, SQR= soma de quadrados dos resíduos,  $vRegI$  e  $vRegIS1$ = prognose do volume obtida por meio das equações 18 e 15, respectivamente,  $vRNAI$  e  $vRNAIS2$ = prognose do volume obtida empregando-se RNA.

Quanto ao critério  $r$ , houve para  $vRNAI$  um aumento de 13,34% em relação do valor obtido por  $vRegI$ . Como, quanto maior o valor de  $r$  melhor é a equação utilizada, então há indícios de haver um melhor nível de relacionamento entre o volume real e o volume prognosticado por  $vRNAI$  do que prognosticado por  $vRegI$ . Portanto, nesta comparação inicial entre  $vRNAI$  e  $vRegI$ , se verifica haver uma superioridade da prognose feita por meio de RNA frente o uso de equações de regressão, se considerado apenas volume e idade.

Ao se analisar o volume em relação da idade e do *site*, se observa que o uso de  $vRNAIS2$

se mostrou superior ao uso de vRegIS1 na prognose da produção volumétrica em  $m^3ha^{-1}$ , os quais, são também bem superior às demais prognoses feitas por meio de vRNAI e vRegI, respectivamente.

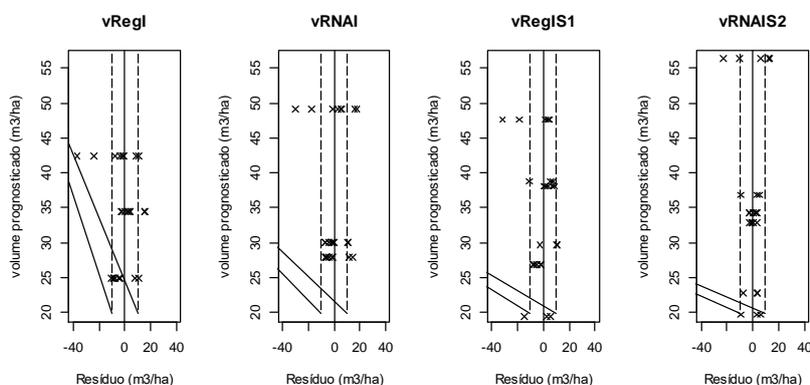
De maneira geral, vRNAIS2 resultou nos melhores valores dos critérios estatísticos de análise, principalmente, com RQEM de 21,16% que foi 23,75% inferior ao valor de 27,75% obtido por vRegIS1. Resultados, também expressivos no critério  $r$ , com o valor 0,847 sendo 16,51% superior ao obtido pelo vRegIS1 de 0,727. Já, quanto à SQR de 1.366,0, obteve-se um valor 41,84% inferior ao obtido por vRegIS1 (2.348,5).

Os resultados de MDP, RQEM,  $r$  e SQR, qualificam favoravelmente o emprego de RNA na prognose volumétrica, aqui representado por vRNAIS2 mesmo MDP ter sido 5,95% superior à

vRegIS1. Portanto, confirmando os indícios já detectados pelos critérios de  $R^2_{aj}$  e EPR, se evidencia uma importante superioridade do emprego de RNA na prognose da produção frente ao emprego da regressão (Eq.15).

A análise da Figura 1 confirma o que foi detectado na análise da Tabela 3. Observa-se que houve uma expressiva distribuição homogênea e equilibrada para vRNAIS2, com menor quantidade de resíduos fora de  $\pm 10 m^3ha^{-1}$  em relação do volume prognosticado (Figura 1.A), sendo de 12,5% (vRNAIS2) contra 25,0% (vRegI), 33,3% (vRNAI) e 25,0% (vRegIS1), respectivamente. Também, houve menor quantidade de resíduos fora de  $\pm 15\%$  em relação da idade (Figura 1.B), sendo de 45,8% (vRNAIS2) contra 54,2% (vRegI), 54,2% (vRNAI) e 62,5% (vRegIS1).

**Figura 1.A – Resíduos em relação do volume prognosticado**



**Figura 1.B – Resíduos em relação da idade**

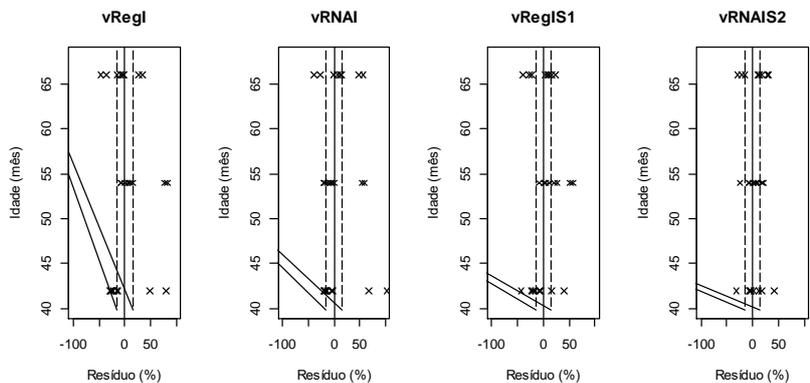


Figura 1. Distribuição de resíduos para quatro métodos de prognose da produção volumétrica. vRegI= emprego da equação Eq.18, vRegIS1= emprego da equação Eq.15 com site obtido pelo método S1, vRNAI= emprego de RNA com v e idade, vRNAIS2= emprego de RNA com volume, idade e site obtido pelo método S2.

Por outro lado, do ponto de vista biológico (Figura 2), a idade técnica de colheita (ITC) em meses ocorre em: 68 (vRegI), 83 (vRNAI), 86 (vRegIS1) e 96 (vRNAIS2) para  $S=12,25$  e 72 (vRegIS1) e 80 (vRNAIS2) para  $S=14,75$ . Desses resultados, apesar de ocorrerem valores bem diferentes para cada método, é possível verificar prognoses biologicamente dentro do esperado, porque a ITC ocorreu mais cedo em locais mais

produtivos e mais tarde em local menos produtivos, como é o caso de vRegIS1 e vRNAIS2 para  $S=14,75$  e  $S=12,25$ .

Embora tenha ocorrido curvas de crescimento um pouco fora do esperado com emprego de vRNAI e vRNAIS2 (Figura 2), não se deve descartar esta opção de fazer prognose da produção florestal. Em hipótese, se pode atribuir esse resultado ao fato de não ter iniciado o IFC em

idades inferiores a 44 meses e, também, ao fato de severas colheitas de folhas que foram feitas ao longo do tempo para extração de óleos essenciais, prejudicando o crescimento das árvores e, por conseguinte, da manutenção de uma curva dentro do que se espera em plantios florestais. Se observa que a aceleração do crescimento ocorreu a partir de 55 meses para RNA e abaixo de 42 meses para regressão, aproximadamente (Figura 3).

Diante disso, considerando-se uma análise estatística e biológica, se pôde ver que o emprego

de RNA na prognose do crescimento e produção tem um potencial importante de aplicação, que merece destaque em estudos com esta finalidade a fim de melhorar a confiabilidade de previsões futuras de produção florestal, base para obter respostas às questões: quanto ao que?, como?, onde?, porque? e quando? formar plantios comerciais, colher madeira e, ou, adotar sistemas de manejo florestal com fins técnico, econômico, ambiental e social, dentre outros objetivos visados em plantios florestais (Couto e Bastos 1989).

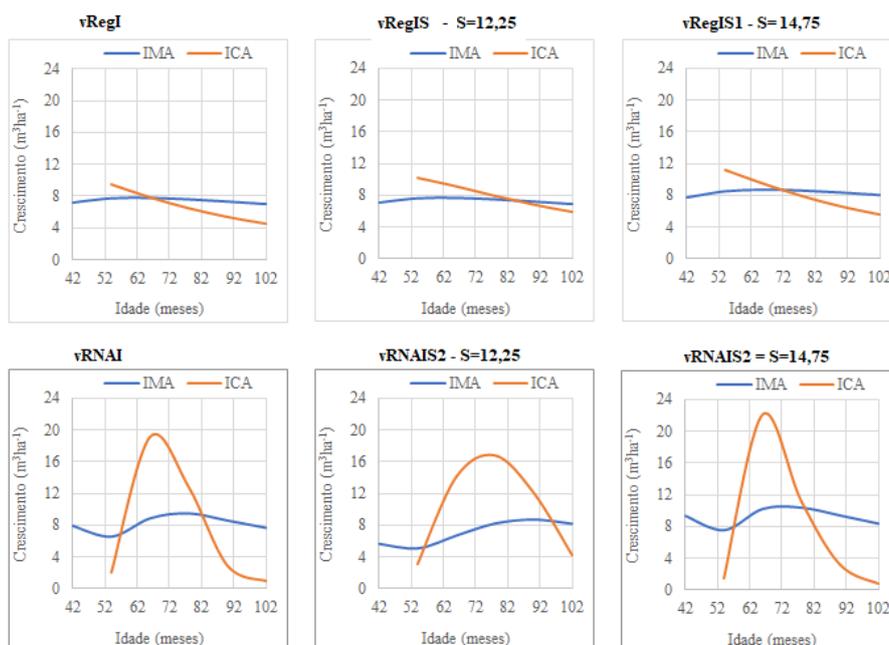


Figura 2. Crescimento de *C. citriodora* obtido por diferentes métodos de quantificação. IMA e ICA= incrementos médio e corrente anuais, respectivamente, S= índice de sítio, vRegI= emprego da equação Eq.18, vRegIS1= emprego da equação Eq.15 com site obtido pelo método S1, vRNAI= emprego de RNA com idade, vRNAIS2= emprego de RNA com idade e site obtido pelo método S2.

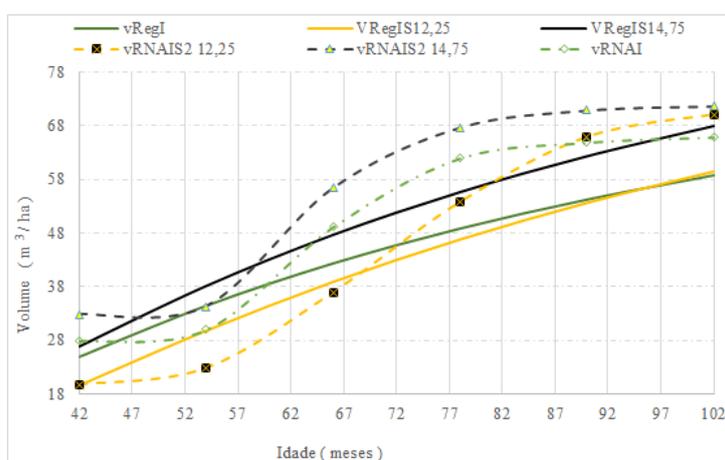


Figura 3. Produção de *C. citriodora* obtido por diferentes métodos de quantificação. vRegI= emprego da equação Eq.18, vRegIS1= emprego da equação Eq.15 com site obtido pelo método S1, vRNAI= emprego de RNA com idade, vRNAIS2= emprego de RNA com idade e site obtido pelo método S2.

*Análise da prognose com validação cruzada:*

Na validação cruzada, empregando-se dois bancos de dados diferentes contendo quatro

parcelas cada uma em três diferentes idades, avaliou-se as prognoses obtidas pelo ajuste dos modelos Md.2 (vRegI), Md.3 (vRegIS1) e Md.4a

e Md.4b (Clutter,1963), além da RNA treinada com idade e S2 (vRNAIS2). Os resultados (Tabela 4), estatisticamente, permitem evidenciar superioridade de RNA devido ao teste qui-quadrado ser não significativo ao nível de 5%.

Dentre os modelos Md.2 e Md.3 (regressão), se observam resultados muito parecidos de exatidão pelo teste de qui-quadrado,

demonstrando que o índice de sítio não caracterizou diferenças na produtividade geradas por regressão. O contrário se obteve no emprego de vRNAIS2, onde se identificou haver influência da produtividade devido à superioridade frente à RNAI que, também, foi superior à regressão (Tabelas 3 e 4).

Tabela 4 – Resultados obtidos por regressão e redes neurais artificiais em uma validação cruzada.

Prognose	$b_0$	$b_1$	$b_2$	$b_3$	$Q_c^2$	Ex (%)
BD1 Md.2	4,9489	-72,5494			23,75*	2,15
BD2 Md.2	4,4028	-50,1968			87,71*	4,14
BD1 Md.3	4,7097	-815,6993			31,32*	2,47
BD2 Md.3	4,0891	-459,3474			94,88*	4,30
BD1 Md.4 <sup>a</sup>	1,6897		0,1378	2,031	37,24*	<b>2,70</b>
BD2 Md.4 <sup>a</sup>	1,5812	-41,2219	0,0249	1,267	42,55*	<b>2,88</b>
BD1 Md.4b		3,1370	-0,0071			
BD2 Md.4b		3,1954	-0,0283			
BD1 RNA					10,36 <sup>ns</sup>	0,00
BD2 RNA					17,88 <sup>ns</sup>	0,00

Md= número do modelo ajustado onde BD1 e BD2 são banco de dados 1 e 2, respectivamente, RNA= redes neurais artificiais (RNAIS2),  $b_0$  à  $b_3$ = coeficientes estimados,  $Q_c^2$ =valor calculado do qui-quadrado, \* e ns= significativo e não significativo ao nível de 5% para um qui-quadrado tabelado de 19,68 com 11 graus de liberdade, Ex= exatidão ao nível de 95% de probabilidade.

Outro fato, é o emprego de regressão por meio do modelo de Clutter (Md.4a e Md.4b), que foi bem superior aos modelos Md.2 e Md.3 com melhor nível de exatidão, sendo inferior à  $\pm 3\%$  ao nível de 95% de probabilidade pelo teste de qui-quadrado. Resultado que caracteriza uma situação de excelência na predição, uma vez que a tolerância pode chegar até  $\pm 10\%$  de erro em dependência do tipo de plantio a que se refere o resultado de predição. Assim, constata-se que o erro médio de  $\pm 2,79\%$  previsto com o modelo de Clutter (Tabela 4), está em um nível ideal de erros cometidos na prognose volumétrica, sendo bem próximo de  $\pm 0,0\%$ .

Em trabalhos com emprego do modelo de Clutter, se observam erros de -13,65%, -7,99% e de  $\pm 7,13\%$  (Oliveira et al. 2009; Pereira et al. 2016) que, apesar de se tratar dos critérios estatísticos RQEM de predição (Pereira et al. 2016) e MDP de estimação (Oliveira et al. 2009), gerando resultados diferentes à exatidão obtida pelo qui-quadrado, permitem dimensionar os erros cometidos na prognose volumétrica dando base às inferências dos valores previstos destes.

Ao se considerar RQEM, se obteve um valor de  $\pm 32,91\%$ , variação de erros de predição bem maior que  $\pm 7,13\%$  obtido por Pereira et al. (2016). Como contribuição a esta grande diferença, se pode incluir o fato de se tratar de um plantio seminal com *C. citriodora*; enquanto que o trabalho em referência, se trata de um plantio clonal de eucalipto. Também, se trata de um cenário com início do IFC

em idades acima de 40 meses e de severas colheitas de folhas que foram feitas ao longo do tempo para extração de óleos essenciais prejudicando o crescimento das árvores.

Notadamente, Oliveira et al. (2009), avaliando a prognose do volume de madeira empregando cinco alternativas de emprego da regressão em uma grande área florestal de 46.748,06 ha, implantada com 37 diferentes clones inventariados pela distribuição de 4.325 parcelas permanentes, obtiveram destaque com um erro médio de -2,15% para uma prognose com modelagem diferente do modelo de Clutter, variando-se entre -12,63% à +1,03%. Neste cenário, se averigua que o erro médio de  $\pm 2,79\%$  cometido com o modelo de Clutter (Tabela 4), está bem próximo do erro médio obtido por Oliveira et al. (2009). Isso permite deduzir que o emprego da referida alternativa de Oliveira et al. (2009), poderia resultar em um melhor nível de exatidão se aproximando do que se obteve com RNA.

Em conformidade aos resultados deste trabalho, como detectado por Binotti et al. (2015), o emprego de RNA na prognose volumétrica resulta em um grande potencial de aplicabilidade. Também, neste mesmo contexto, Alcântara (2015), obteve um melhor nível de detalhamento da produtividade se comparado ao emprego de modelos de regressão.

Portanto, se pode inferir que o interesse no emprego de regressão ou de RNA, na prognose da produção madeireira em plantios florestais, deve levar em conta os objetivos e recursos de modelagem

disponíveis, porque, apesar de ambos disponibilizarem uma grande gama de técnicas de modelagem, a análise de regressão usufrui de sistemas de análise estatística elementar frente à RNA, a qual exige softwares com um nível de conhecimento mais aprofundado de programação.

### Conclusões

A comparação da prognose feita por diferentes técnicas de modelagem do crescimento e da produção (análise de regressão e RNA) permitiu concluir por uma evidência estatística, ao nível de 95% de probabilidade pelo teste de qui-quadrado, de que o emprego da inteligência artificial por meio de redes neurais artificiais pode gerar informações sobre crescimento e produção madeireira de *C. citriodora* com melhor nível de acurácia.

Dentre os métodos de regressão vRegI (eq.18), vRegIS1 (eq.15) e modelo de Clutter, se observou que este último deve ser preferido mesmo em pequenas áreas florestais, pois proporcionou o melhor nível de acurácia com uma exatidão inferior a  $\pm 3\%$  ao nível de 95% de probabilidade pelo teste de qui-quadrado.

Apesar dos resultados da prognose serem favoráveis ao emprego de RNA, se deve levar em conta que esta metodologia exige um certo nível de conhecimento acerca do software para a sua utilização. Por isso, se conclui que o emprego da técnica de regressão por meio do modelo de Clutter, se caracteriza ser uma boa opção, pois se evidenciou um ótimo nível de exatidão, sendo bem próximo ao obtido pelo emprego de RNA.

### Agradecimentos

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela concessão da bolsa de pesquisa em iniciação científica. Também, se estendem merecidos agradecimentos aos avaliadores deste artigo pela conduta imparcial e estritamente profissional adotada ao se posicionarem perante o conteúdo apresentado neste artigo científico, sugerindo alterações que muito contribuíram para um melhor contexto do assunto em enfoque.

### Referências

Alcântara AEM (2015) Redes neurais artificiais para prognose do crescimento e da produção de povoamentos de eucalipto em Minas Gerais. Tese, Universidade Federal de Viçosa. 43p.

Andrade VCL, Freitas BC, Terra DLCV, Carvalho SPC (2019) Modelos volumétricos avaliados para um plantio comercial de *Corymbia citriodora* no sul do Tocantins. *Revista Agrotecnologia*, 10(2): 84-99.

Binoti MLMS, Binoti DHB, Leite HG (2013) Aplicação de redes neurais artificiais para estimação

da altura de povoamentos equiâneos de eucalipto. *Revista Árvore*, 37(4): 639-645. doi: 10.1590/s0100-67622013000400007

Binoti MLMS, Leite HG, Binoti DHB, Gleriani JM (2015) Prognose em nível de povoamento de clones de eucalipto empregando redes neurais artificiais. *Cerne*, 21(1): 97 - 105. doi: 10.1590/01047760201521011153

Campos BPF, Silva GF, Binoti DHB, Mendonça AR, Leite HG (2016) Predição da altura total de árvores em plantios de diferentes espécies por meio de redes neurais artificiais. *Pesquisa Florestal Brasileira*, 36(88): 375 - 85. doi: 10.4336/2016.pf.b.36.88.1166

Campos JCC, Leite HG (2013) *Mensuração florestal: perguntas e respostas*. 4ª ed. Viçosa: Editora UFV. 605 p.

Couto HTZ, Bastos NLM (1989) Comparação de dois modelos de prognose de madeira de *Eucalyptus* para alto fuste e talhadia. *IPEF*, 41/42: 27-35.

Clutter JL (1963) Compatible growth and yield models for loblolly pine. *Forest Science*, 9(3): 354-371.

Husch B, Beers TW, Kershaw JR J.A (2003) *Forest mensuration*. 4ª ed. New Jersey: John Wiley & Sons. 443 p.

NEUROFOREST (2018) *Sistema Neuroforest*. Disponível em: <https://neuroforest.ucoz.com/news/neuroforest>. Acesso em: setembro.

Oliveira MLR, Leite HG, Nogueira GS, Campos JCC (2009) Modelagem e prognose em povoamentos não desbastados de clones de eucalipto. *Revista Árvore*, 33(5): 841-852.

Pereira JC, Dias PAS, Mergulhão RC, Thiersch CR, Faria LC (2016) Modelo de crescimento e produção de Clutter adicionado de uma variável latente para predição do volume em um plantio de *Eucalyptus urograndis* com variáveis correlacionadas espacialmente. *Scientia Forestalis*, 44(110): 393-403. doi: dx.doi.org/10.18671/scifor.v44n110.12

R CORE TEAM (2015) R: a language and environment for statistical computing. Vienna: R Foundation for Statistical Computing.

Reis CAF, Assis TF, Santos AM, Paludzyszyn-Filho E (2013) *Corymbia citriodora*: estado da arte de pesquisas no Brasil. Embrapa, Documentos 255.

Reis LP, Souza AL, Reis PCM, Mazzei L, Binoti DHB, Leite HG (2018) Prognose da distribuição diamétrica na Amazônia utilizando redes neurais artificiais e autômatos celulares. *Floresta*, 48(1): 93-102. doi: 10.5380/rf.v48i1.52748

Scolforo JRS (2006) *Biometria Florestal: modelos de crescimento e produção florestal*. Lavras: Editora UFLA/FAEPE. 393 p.

Silva MLM, Binoti DHB, Gleriani JM, Leite HG (2009) Ajuste do modelo de Schumacher e Hall e aplicações de redes neurais artificiais para estimar volume de árvores de Eucalipto. *Revista Árvore*, 33(6): 1133 - 1139. doi: 10.1590/S0100 - 67622009000600015

Vitti MAS, Brito JO (2003) *Óleo essencial de eucalipto*. (Documentos Florestais, 17), Piracicaba: ESALQ/USP. 30 p.