



Estimativa da altura de árvores de *Tectona grandis* L.f. utilizando regressão e redes neurais artificiais

Diogo Guido Streck VENDRUSCOLO¹, Arthur Guilherme Schirmbeck CHAVES², Reginaldo Antonio MEDEIROS²,
Raiane Scandiane da SILVA³, Hudson Santos SOUZA¹, Ronaldo DRESCHER¹, Hélio Garcia LEITE⁴

¹ Departamento de Engenharia Florestal, Universidade Federal de Mato Grosso, Cuiabá, Mato Grosso, Brasil.

² Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso, Cáceres, Mato Grosso, Brasil.

³ Departamento de Agronomia, Universidade do Estado de Mato Grosso, Cáceres, Mato Grosso, Brasil.

⁴ Departamento de Engenharia Florestal, Universidade Federal de Viçosa, Viçosa, Minas Gerais, Brasil.

* E-mail: diogoguido@hotmail.com

Recebido em maio/2016; Aceito em setembro/2016.

RESUMO: O objetivo deste estudo foi avaliar a modelagem por regressão e por redes neurais artificiais na estimativa da altura total de árvores de teca em diferentes espaçamentos em Cáceres, MT. A base de dados foi proveniente da medição do *dap* por meio de censo florestal. Posteriormente, estes foram agrupados em classes de diâmetro, com amplitude de 5 cm. Foi medida a altura total (*h*) de 20% dos indivíduos em cada espaçamento e classe de diâmetro. Para estimativa da altura total por regressão foram utilizados modelos não lineares e lineares, enquanto que para a estimativa por redes neurais artificiais foram testadas redes do tipo *Multilayer Perceptron*. Na modelagem por regressão, os modelos não lineares foram superiores aos lineares, com destaque para o modelo de Gompertz. As duas técnicas foram eficientes na estimativa da altura total de *Tectona grandis*, no entanto, a modelagem por redes neurais artificiais apresentou erro inferior a 10% em todos os espaçamentos analisados.

Palavras-chave: Teca, identidade de modelos, inteligência artificial.

Height estimative of *Tectona grandis* L. f. trees using regression and artificial neural networks

ABSTRACT: The aim of this study was to evaluate the modeling regression and artificial neural networks to estimate the total of teak trees in different spacings in Cáceres, MT, Brazil. The database was derived from the measurement of *dbh* by forest census. Subsequently, these were grouped into classes of diameter, with an amplitude of 5 cm. Was measured the overall height (*h*) of 20% of subjects in each spacing, and diameter class. To estimate the total height per regression were used nonlinear and linear models, while for the estimated by artificial neural networks of the type were tested Multilayer Perceptron. In regression modeling, the non-linear models were superior to linear, highlighting the Gompertz model. Both techniques were efficient for estimates the total teak height, however, through the modeling for artificial neural network, the error values were lower than 10% in all evaluated spacings.

Keywords: Teak, identity models, artificial intelligence.

1. INTRODUÇÃO

No manejo florestal, gerar equações e métodos confiáveis para estimar a altura de povoamentos florestais, é tarefa de extrema importância. Sua medição ou estimação é muito utilizada para o cálculo do volume, de incrementos em altura e, em determinadas situações, pode servir como indicadora da qualidade produtiva de um local (SILVA et al., 2012).

Uma das alternativas para a estimação da altura tem sido o uso de modelos hipsométricos. Neste caso, algumas árvores de parcelas de inventário são medidas, sendo a altura das demais estimadas por modelos de regressão em função de outras variáveis, como o diâmetro a 1,3 m de altura (*dap*) (SCOLFORO, 2005; CAMPOS; LEITE, 2013).

Na literatura florestal, são encontrados diversos modelos para estimação da altura total de árvores, muitos deles,

podendo ser utilizados em várias espécies. Estudos voltados, a modelagem, procedimentos e equipamentos para a mensuração da altura de árvores são importantes, devido esta variável ser considerada um componente significativo no custo do inventário florestal (CAMPOS; LEITE, 2013; BINOTI et al., 2013b). A relação hipsométrica depende de fatores ambientais e de características do povoamento, como: capacidade produtiva, idade, genótipo e espaçamento do plantio (CURTIS, 1967). A densidade afeta de modo significativo o crescimento das árvores, levando-as a competição pelos fatores de crescimento, como luz, água e nutrientes do solo. Nas árvores dominantes a altura é pouco afetada pelo espaçamento inicial, e enquanto nas dominadas a influência é bastante acentuada (PRODAN et al., 1997; SCOLFORO, 2005).

O emprego de modelos hipsométricos que consideram todos os fatores ambientais e do povoamento não é comum. Há certa

predominância de modelos simples, como aqueles divulgados em Stoffels; Soest (1953) e Curtis (1967). Esses modelos se caracterizam por serem eficientes e de fácil aplicação, no caso em que a base de dados é bem estratificada, o que nem sempre é possível. O uso de modelos não lineares com fundamentação biológica também pode ser utilizado em relações hipsométricas, apresentando-se em muitos casos superiores aos modelos lineares por serem mais flexíveis (BATISTA et al., 2001).

Uma alternativa eficiente e que tem se destacado em relação aos modelos de regressão, é o emprego de redes neurais artificiais (RNA) (SILVA et al., 2009; BINOTI et al., 2013a, b; MIGUEL et al., 2016). No entanto, os principais trabalhos com redes neurais artificiais, na área florestal foram realizados com espécies do gênero *Eucalyptus* spp., sendo escassos, trabalhos com outras espécies, como a teca (*Tectona grandis* L.f.).

As RNAs foram definidas por Braga et al. (2000) como sistemas paralelos constituídos por unidades de processamento simples, também denominadas neurônios artificiais ou nodos, conectadas entre si de maneira específica para desempenhar determinada função matemática (geralmente não linear). Os neurônios artificiais são modelos matemáticos simplificados dos neurônios biológicos e processam as informações recebidas e ponderadas por pesos sinápticos, fornecendo uma única saída (BRAGA et al., 2000).

Segundo Binoti (2010) a estimativa da altura de povoamentos florestais por RNA se enquadra na tarefa de aprendizagem denominada aproximação de funções. Essa tarefa consiste em treinar uma rede neural que aproxime a função desconhecida $f(x)$, que descreve o mapeamento dos pares de entrada-saída $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ de um conjunto de n exemplos de treinamento.

O objetivo deste estudo foi avaliar e comparar a modelagem por regressão e por redes neurais artificiais como métodos de estimativa da altura total de árvores de *Tectona grandis* em diferentes espaçamentos, no município de Cáceres, MT, Brasil.

2. MATERIAL E MÉTODOS

2.1. Localização e descrição do experimento

Os dados para este estudo foram obtidos de um experimento com *Tectona grandis* L.f. instalado em 1998, no Instituto Federal de Mato Grosso, campus Olegário Baldo, circunscrito sob as coordenadas geográficas 57°40'51" W e 16°11'42" S (Figura 1).

O clima da região, segundo Köppen, é Aw (Savanas tropicais com verão úmido e inverno seco), ou seja, clima tropical chuvoso, em que a temperatura média anual varia entre 23 e 25°C, com oscilação de temperatura no ano inferior a 5°C. O índice pluviométrico médio é de 1.277 mm, com máxima de 1.698 mm e mínima de 843 mm, porém, com uma nítida estação seca (w), apresentando déficit hídrico entre abril e dezembro. O relevo é plano e o solo classificado como Latossolo Vermelho-Amarelo Distrófico (EMBRAPA, 2006).

O experimento foi em blocos ao acaso com três repetições e quatro espaçamentos de plantio (tratamentos), sendo: 3×2 m, 4×2 m, 5×2 m e 6×2 m. As parcelas experimentais constam de sete linhas de árvores e 32 covas por linha, no entanto, foram consideradas como úteis apenas cinco fileiras de 30 covas, com objetivo de evitar o efeito de borda. O plantio até 16 anos, idade de avaliação, não recebeu desbastes, apenas desramas na fase inicial, aos 9, 14 e 22 meses.

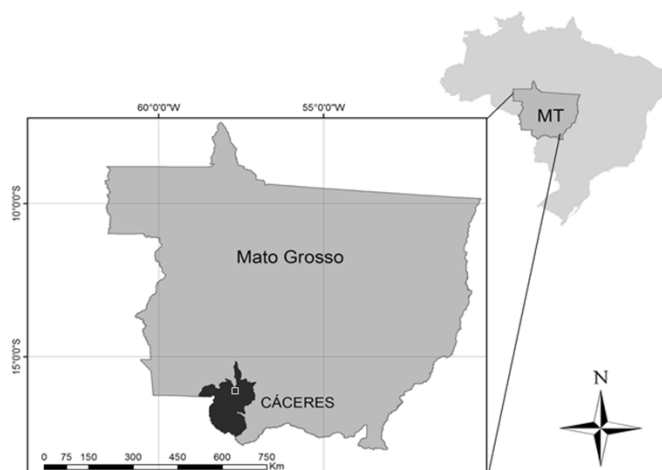


Figura 1. Localização dos povoamentos de *Tectona grandis*. Adaptado de Silva et al. (2016).

Figure 1. Location of stands of *Tectona grandis*. Adapted from Silva et al. (2016).

2.2. Coleta de dados

Foi mensurado o diâmetro com casca a 1,3 m de altura (*dap*) de todos os indivíduos nas parcelas, os quais foram separados em classes diâométricas com amplitude de 5 cm. Posteriormente foi medida a altura total (*h*) de 20% dos indivíduos de cada parcela, utilizando nível de Abney, de acordo com a distribuição diamétrica, em cada espaçamento. Um resumo da estatística descritiva do *dap* e *h* das árvores amostradas estão na Tabela 1.

Tabela 1. Estatísticas descritivas das variáveis diâmetro (*dap*) e altura total (*h*) de *Tectona grandis* em diferentes espaçamentos, aos 16 anos de idade, em Cáceres, MT.

Table 1. Descriptive statistics of the variables diameter (*dbh*) and total height (*h*) of *Tectona grandis* in different spacing, at 16 years of age, in Cáceres, MT.

Trat.	Variável	Mín.	Méd.	Máx.	D.P
3×2 m	<i>dap</i> (cm)	6,0	15,9	22,6	3,2
	<i>h</i> (m)	7,1	14,6	18,0	2,0
4×2 m	<i>dap</i> (cm)	7,8	17,4	25,8	4,2
	<i>h</i> (m)	7,4	14,9	20,8	2,8
5×2 m	<i>dap</i> (cm)	7,4	18,8	27,7	4,2
	<i>h</i> (m)	9,2	15,2	19,4	2,4
6×2 m	<i>dap</i> (cm)	7,6	19,8	29,3	4,2
	<i>h</i> (m)	8,9	15,5	20,1	1,5

Trat. = tratamento; Mín. = mínimo; Méd. = média; Máx. = máximo e D.P. = desvio padrão.

2.3. Modelagem da altura total utilizando regressão

Para estimativa da *h* nos diferentes espaçamentos foram utilizados três modelos sigmoidais: Logística (Modelo 1), Gompertz (Modelo 2) e Richards (Modelo 3) e dois modelos lineares logarítmicos: Curtis (Modelo 4) e Stoffels & Soest (Modelo 5).

$$h = \frac{\beta_0}{1 + \beta_1 e^{-\beta_2 dap}} + e_i \quad (\text{Modelo 1})$$

$$h = \beta_0 e^{-e^{-\beta_1 - \beta_2 dap}} + e_i \quad (\text{Modelo 2})$$

$$h = \frac{\beta_0}{(1 + e^{\beta_1 - \beta_2 dap})^{\frac{1}{d}}} + e_i \quad (\text{Modelo 3})$$

$$\ln(h) = \beta_0 + \beta_1 \frac{1}{dap} + e_i \quad (\text{Modelo 4})$$

$$\ln(h) = \beta_0 + \beta_1 \ln(dap) + e_i \quad (\text{Modelo 5})$$

em que:

- \ln - logaritmo neperiano;
- h - altura total (m);
- dap - diâmetro a 1,30 m de altura (cm);
- β_i - parâmetros do modelo; e,
- e_i - erro aleatório, sendo $e_i = N(0, \sigma^2)$.

A exatidão das estimativas foi avaliada pelas estatísticas: coeficiente de correlação linear simples entre as alturas observadas e estimadas (r_{hh}) (Equação 1), raiz quadrada do erro quadrático médio em porcentagem (RQEM_%) (Equação 2), análise gráfica dos resíduos (Equação 3) e histogramas de frequência dos resíduos percentuais.

$$r_{hh} = \frac{\text{cov}(h_i, \hat{h}_i)}{\sqrt{S^2(h_i)S^2(\hat{h}_i)}} \quad (1)$$

$$\text{RQEM}_{\%} = \frac{100}{\bar{h}} \sqrt{\frac{\sum_{i=1}^n (h_i - \hat{h}_i)^2}{n}} \quad (2)$$

$$\text{Resíduo}_{\%} = \frac{h_i - \hat{h}_i}{h_i} \times 100 \quad (3)$$

em que:

- cov - covariância;
- h - altura observada;
- \hat{h} - altura estimada;
- S^2 - variância;
- \bar{h} - média das alturas observadas; e,
- n - número de observações.

Empregou-se o teste de identidade de modelos para verificar a igualdade de parâmetros das equações estimadas para cada tratamento, conforme Regazzi e Silva (2010).

2.4. Modelagem da altura utilizando RNA

A estimativa da altura foi realizada pelo treinamento de cinco redes. As RNA's foram do tipo *perceptrons* de múltiplas camadas, comumente conhecidas como MLP (*Multilayer Perceptron*), que segundo Hornik et al. (1989) possui grande potencial para a aproximação de funções. Essas redes apresentam uma camada de entrada que recebe as variáveis de entrada (diâmetro a 1,3 m de altura - dap , diâmetro máximo - d_{max} e espaçamentos - E) e transfere-as ponderadas por pesos sinápticos à camada intermediária ou oculta que aplica transformações matemáticas e transfere para a camada de saída que fornece a resposta, altura estimada (h). Mais detalhes sobre os fundamentos matemáticos envolvidos nas redes fogem do escopo do presente trabalho e podem ser obtidos em Braga et al. (2000) e Haykin (2001).

As variáveis numéricas foram normalizadas linearmente em intervalos de 0 a 1 (Equação 4), e as variáveis categóricas

passaram por codificação, ou seja, cada variável recebeu um código binário que possibilitasse o cálculo do neurônio artificial.

$$x_{\text{norm}} = \frac{(x - x_{\text{min}})(b - a)}{(x_{\text{max}} - x_{\text{min}})} + a \quad (4)$$

em que:

- x_{norm} - valor normalizado;
- x_{min} e x_{max} - valores mínimo e máximo da variável, respectivamente;
- a - limite inferior da normalização (0); e,
- b - limite superior da normalização (1).

Para a configuração e treinamento das RNAs utilizou-se o software NeuroForest 3.0. O tipo de treinamento foi o *Resilient Propagation* (RPROP⁺), com função de ativação sigmoideal (Equação 5) que é o tipo de função mais usual para construção de RNA (HAYKIN, 2001).

$$f(x) = \frac{1}{1 + e^{-\beta u}} \quad (5)$$

em que:

- f - função de ativação sigmoide;
- e - exponencial;
- β - parâmetro que determina a inclinação da função; e,
- u - potencial de ativação da função.

No software NeuroForest, o processo de determinação do número de neurônios na camada oculta é definido pelo usuário, sendo assim, foi utilizado o treinamento com três neurônios, considerado que um número excessivo pode acarretar a memorização dos dados de treinamento, processo conhecido como *overfitting* segundo Braga et al. (2000). Por outro lado, um pequeno número de neurônios na camada oculta pode não ser suficiente para a realização da tarefa desejada, fenômeno conhecido como *underfitting* (BRAGA et al., 2000). Dessa forma, o mais indicado é optar por configurações simples (BINOTTI et al., 2014).

Como critério de parada para o treinamento das redes, foi considerado o número total de ciclos igual a 3.000 ou erro quadrático médio inferior a 0,01, para evitar o número exagerado ou reduzido de ciclos. Desta forma, o treinamento foi finalizado quando um destes critérios foi atingido.

A exatidão das estimativas da rede foi avaliada empregando as mesmas utilizadas na modelagem por regressão. Para comparação das estimativas das h obtidas por regressão com as obtidas por RNA utilizou-se procedimento estatístico proposto por Leite; Oliveira (2002), sendo testada a seguinte hipótese: H_0 : A estimativa da altura obtida por regressão é igual à obtida por redes neurais artificiais, e H_1 : A estimativa da altura obtida por regressão é diferente à obtida por redes neurais artificiais. Em todas as análises estatísticas no presente estudo foi utilizado um nível de significância de 5%.

3. RESULTADOS

3.1. Modelagem da altura utilizando regressão

As equações ajustadas apresentaram ajustes satisfatórios e pouca variação quanto às estatísticas dentro de cada tratamento (Tabela 2). Observou-se que os modelos não-lineares (Equações

Tabela 2. Equações ajustadas e suas estatísticas de ajuste para estimativa da altura total de *Tectona grandis*, em diferentes espaçamentos em Cáceres, MT.

Table 2. Adjusted equations and their adjustment statistics for estimation of the total height of *Tectona grandis*, in different spacings in Cáceres, MT.

Trat.	Mod.	Equação	r_{hh}	RQEM%
3×2 m	1	$h = 18,7853/[1 + 3,4534 \exp(-0,15207 \text{ dap})]$	0,89	6,25
	2	$h = 196974 \exp[-\exp(0,6076 - 0,1107 \text{ dap})]$	0,89	6,21
	3	$h = 19,6802/[1 + \exp(-3,6670 - 0,1113 \text{ dap})]^{(1/0,0138)}$	0,89	6,21
	4	$\ln(h) = 3,1334 + (-7,4182)(1/\text{dap})$	0,89	6,33
	5	$\ln(h) = 0,9573 + 0,6140 \ln(\text{dap})$	0,88	6,35
4×2 m	1	$h = 19,6937/[1 + 5,4976 \exp(-0,1705 \text{ dap})]$	0,90	8,05
	2	$h = 20,4401 \exp[-\exp(0,9594 - 0,12699 \text{ dap})]$	0,90	7,97
	3	$h = 20,4352/[1 + \exp(-4,3766 - 0,1272 \text{ dap})]^{(1/0,0048)}$	0,90	7,97
	4	$\ln(h) = 3,3351 + (-10,579)(1/\text{dap})$	0,90	7,98
	5	$\ln(h) = 0,6596 + 0,7354 \ln(\text{dap})$	0,89	8,43
5×2 m	1	$h = 24,4525/[1 + 2,2392 \exp(-0,0724 \text{ dap})]$	0,73	10,5
	2	$h = 26,1057 \exp[-\exp(0,2850 - 0,0502 \text{ dap})]$	0,74	10,6
	3	$h = 26,0281/[1 + \exp(-2,9205 - 0,05101 \text{ dap})]^{(1/0,0400)}$	0,74	10,6
	4	$\ln(h) = 3,115 + (-6,894)(1/\text{dap})$	0,73	10,6
	5	$\ln(h) = 1,139 + 0,4812 \ln(\text{dap})$	0,73	10,5
6×2 m	1	$h = 18,03992/[1 + 3,2918 \exp(-0,15971 \text{ dap})]$	0,78	7,74
	2	$h = 18,3944 \exp[-\exp(0,64178 - 0,12762 \text{ dap})]$	0,78	7,75
	3	$h = 17,8037/[1 + \exp(2,4455 - 0,1907 \text{ dap})]^{(1/2,0103)}$	0,78	7,74
	4	$\ln(h) = 3,122 + (-7,289)(1/\text{dap})$	0,77	7,79
	5	$\ln(h) = 1,396 + 0,452 \ln(\text{dap})$	0,77	8,02

Trat. = tratamento; Mod = modelo; r_{hh} = coeficiente de correlação; RQEM = raiz quadrada do erro médio.

1, 2 e 3) apresentaram uma pequena superioridade em relação aos modelos lineares (4 e 5), na maioria dos casos, quando observado os critérios estatísticos (r_{hh} e RQEM%).

Embora todos os modelos tenham apresentado ajustes satisfatórios, verificou-se que as equações obtidas com o modelo de Gompertz (Modelo 2) apresentaram estatísticas de ajustes iguais ligeiramente superiores aos demais modelos. Dessa forma, o modelo de Gompertz foi selecionado para estimar as alturas da teca nos quatro espaçamentos avaliados.

Como o mesmo modelo foi selecionado para os quatro espaçamentos, testou-se a possibilidade do emprego de uma única equação, proveniente do modelo de Gompertz, para estimar as alturas da teca contemplando os diferentes tratamentos. Para isso, foi aplicado o teste de identidade de modelos (Tabela 3).

Verificou-se por meio do teste de identidade de modelos, que apenas nos espaçamentos 5×2 m e 6×2 m os parâmetros das equações ajustadas pelo modelo de Gompertz são estatisticamente iguais, implicando no uso de uma única equação para estimativa da altura nesses espaçamentos.

A equação proveniente do modelo ajustado (Equação 6) para os dois espaçamentos (5×2 m e 6×2 m) simultaneamente resultou em $r_{hh} = 0,75$ e RQEM= 11,01%.

Tabela 3. Teste de identidade aplicado ao modelo de Gompertz. Table 3. Identity test applied to the Gompertz model.

Combinações	QM RHo	QM Resíduo	F _{calculado} *
1, 2, 3 e 4	3,951	1,659	2,381*
1, 2 e 3	3,914	1,707	2,293*
1, 2 e 4	3,867	1,265	3,057*
1, 3 e 4	5,351	1,719	3,113*
2, 3 e 4	5,875	1,945	3,021*
1 e 2	2,531	1,145	2,864*
1 e 3	5,323	1,819	2,927*
1 e 4	4,293	1,155	3,717*
2 e 3	7,568	2,153	3,515*
2 e 4	33,96	1,497	22,69*
3 e 4	2,211	2,178	1,015 ^{ns}

1 = 3×2 m; 2 = 4×2 m; 3 = 5×2 m; 4 = 6×2 m; * = $p \leq 0,05$; ns = $p \geq 0,05$.

$$h = 19,604 \exp[-\exp(0,3681 - 0,097 \text{ dap})] \quad (6)$$

3.2. Modelagem da altura utilizando RNA

Para a avaliação das RNA's, considerou-se apenas a rede de melhor desempenho estatístico, dentre as cinco testadas. Foi observado de maneira geral que assim como na modelagem por regressão, nos espaçamentos mais adensados as estimativas da altura de teca foram mais exatas se comparadas aos espaçamentos mais amplos (Tabela 4).

Com base nas estatísticas obtidas pela RNA, foi observado que os valores do RQEM% foram todos inferiores a 10% em todos os espaçamentos avaliados. Avaliando os valores de r_{hh} observou-se semelhança aos obtidos por regressão.

Tabela 4. Características e desempenho estatístico das RNA's treinada para estimativa da altura total de *Tectona grandis*, em diferentes espaçamentos em Cáceres, MT.

Table 4. Characteristics and statistical performance of ANNs trained to estimate the total height of *Tectona grandis*, in different spacings in Cáceres, MT.

Trat.	Entrada	Saída	r_{hh}	RQEM%
3×2 m			0,90	6,08
4×2 m	dap, d_{max}	h	0,91	7,66
5×2 m	e E		0,77	9,98
6×2 m			0,79	7,69

Trat.= tratamento; dap = diâmetro a 1,3 m de altura (cm); d_{max} = diâmetro máximo (cm); E = espaçamento; h = altura total (m); r_{hh} = coeficiente de correlação; RQEM = raiz quadrada do erro médio.

3.3. Comparação entre a regressão e a RNA

Na análise gráfica dos resíduos, observou-se que os erros se distribuíram adequadamente, porém com maior amplitude nos espaçamentos mais amplos. Essa tendência erra esperada, pois nesses espaçamentos (5×2 e 6×2), as estatísticas de ajustes foram inferiores em relação aos mais adensados. Observou-se exatidão tanto para os modelos de regressão quanto para as estimativas por redes neurais, podendo as duas alternativas serem usadas para modelar a altura da teca em função do dap. Porém, a

diferença entre as estimativas das duas técnicas de modelagem tornou-se visível quando avaliado a dispersão das alturas observadas versus estimadas e os histogramas de frequência dos erros percentuais. Nesse tipo de análise foi verificado que as estimativas por RNA, apresentam maiores valores de correlação linear (r_{hh}) entre os valores observados e estimados, e

os histogramas de frequência dos erros apresentaram tendências mais evidentes com valores concentrados na classe 0 % de erro, se comparados com os modelos de regressão em todos os espaçamentos (Figura 2).

Através do procedimento estatístico proposto por Leite; Oliveira (2002) foi rejeitada a hipótese H_0 , pois verificou-se

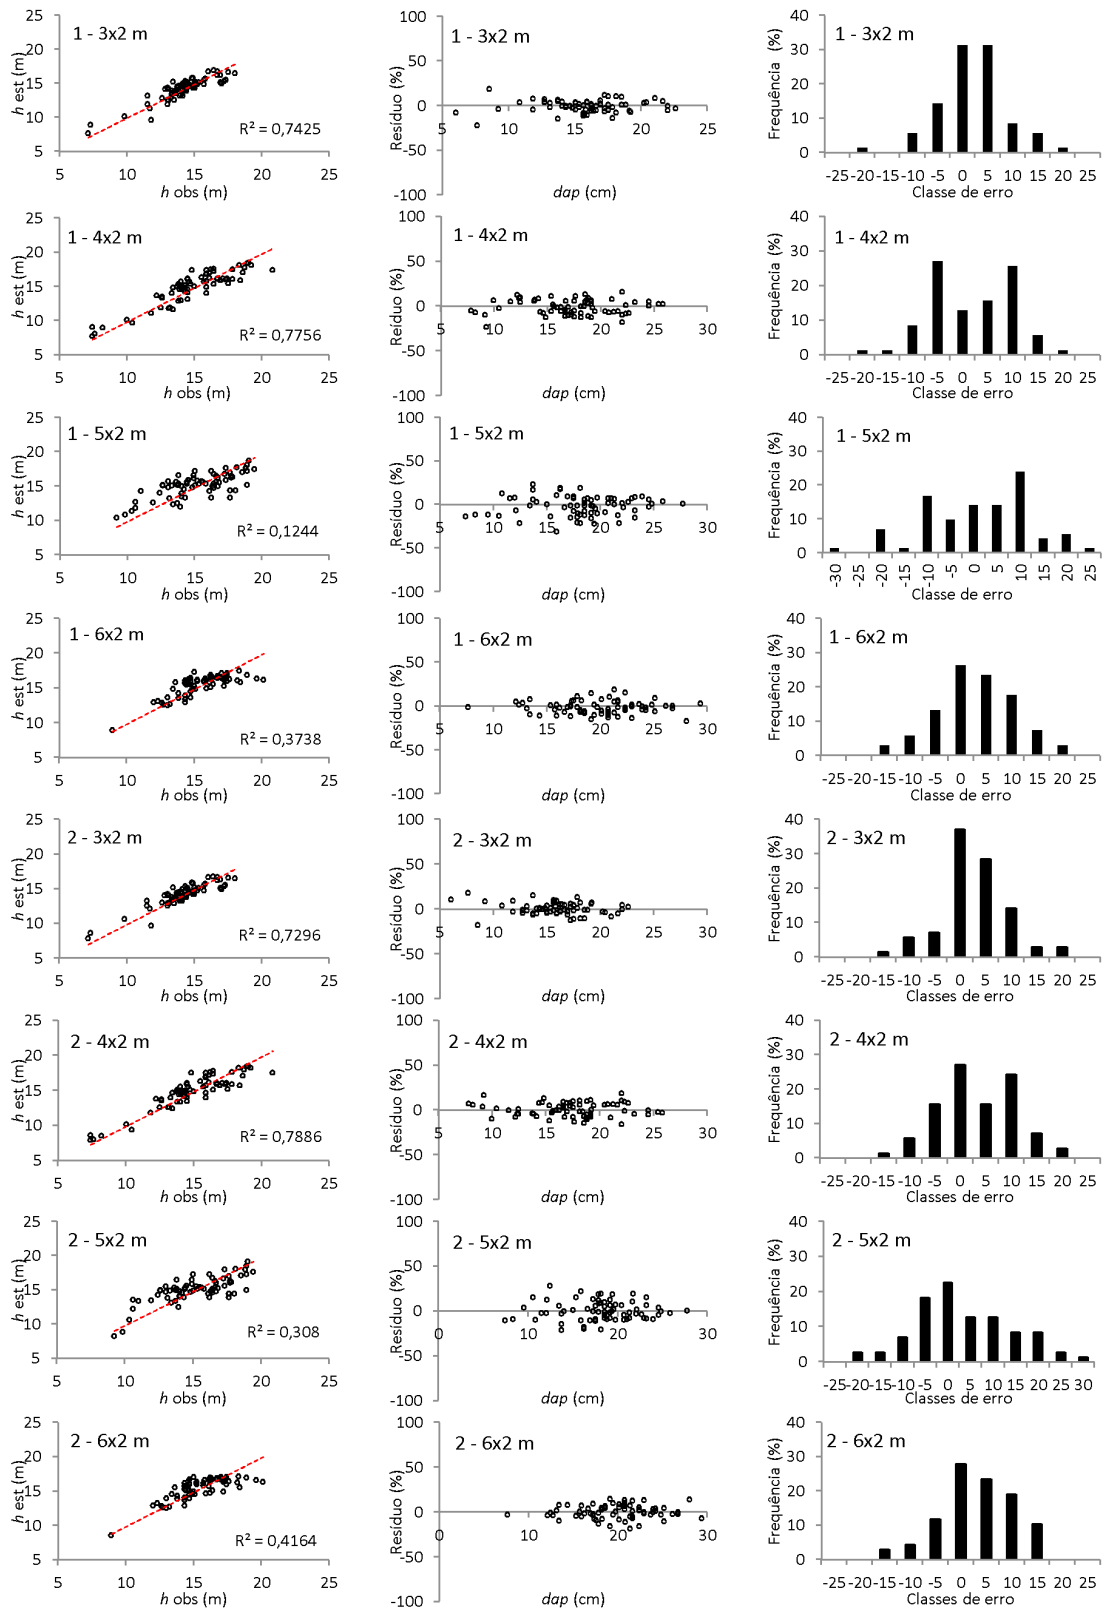


Figura 2. Alturas observada e estimada, distribuição gráfica dos resíduos e histogramas de frequência dos erros percentuais por regressão (1) e por redes neurais (2) para *Tectona grandis*, em diferentes espaçamentos, em Cáceres, MT.

Figure 2. Observed and estimated heights, graphical distribution of the residues and frequency histograms of percent errors by regression (1) and by neural networks (2) for *Tectona grandis*, in different spacing, in Cáceres, MT.

que as estimativas obtidas pela regressão foram estatisticamente diferentes das estimativas obtidas por redes neurais artificiais em todos os espaçamentos avaliados (Tabela 5).

Além disso, a modelagem por redes neurais, diferentemente da modelagem por regressão, permitiu que todos os espaçamentos de plantio fossem modelados por uma única rede, o que lhe confere uma vantagem.

Tabela 5. Comparativo entre altura estimada de *Tectona grandis* por regressão e redes neurais, utilizando do teste L&O. Table 5. Comparison between the estimated height of *Tectona grandis* by regression and neural networks using the L&O test.

Est.	3×2 m	4×2 m	5×2 m	6×2 m
F(Ho)	8,6666*	0,7424 ^{ns}	0,5299 ^{ns}	5,1031*
t(e)	0,5928 ^{ns}	0,4478 ^{ns}	0,5362 ^{ns}	0,5170 ^{ns}
r_{h_i, h_i}	$< (1 - \bar{e})$	$< (1 - \bar{e})$	$< (1 - \bar{e})$	$< (1 - \bar{e})$
Resul.	$h_i \neq h_i$	$h_i \neq h_i$	$h_i \neq h_i$	$h_i \neq h_i$

Est. Estatística; h_i = valores estimados por regressão e h_i = valores estimados por redes neurais.

4. DISCUSSÃO

Nos espaçamentos mais amplos as estimativas da altura foram menos precisas em comparação com aquelas obtidas para os espaçamentos mais adensados, como também observado por Silva et al. (2016). Segundo Bartoszeck et al. (2004) constataram que em povoamentos mais adensados, a razão h/dap tende a ser maior, proporcionando estimativas mais precisas.

As estimativas da altura por regressão apresentaram estatísticas acuradas conforme já relatado por Drescher (2004), ao estudar a relação hipsométrica em povoamentos de *Tectona grandis* no estado de Mato Grosso, com idades entre 2 e 10 anos e Rossi et al. (2011), testando modelos hipsométricos para a mesma espécie em povoamentos com idades entre 1 e 5 anos e aos 26 anos, no estado do Pará. Contudo, nesses trabalhos não foram utilizados modelos não-lineares.

A superioridade dos modelos não lineares em relação aos lineares se deve a fundamentação biológica do modelo (BATISTA et al., 2001). Os modelos com realismo biológico são amplamente utilizados no meio florestal para modelar o crescimento de povoamentos florestais, e trabalhos comprovam a eficiência desses modelos, como o de Gompertz e o de Richards para relações hipsométricas (MORAES NETO et al., 2010; VENDRUSCOLO et al., 2015).

Em relação à eficiência do uso de RNA para obtenção de estimativas de variáveis dendrométricas de indivíduos em povoamentos florestais já é comprovada por diversos autores (GORGENS et al., 2009; BINOTI et al., 2013a, b; MIGUEL et al., 2016).

Binoti et al. (2013b), treinando redes neurais do tipo MLP e RBF para estimar a altura de povoamentos equiâneos de eucaliptos, obtiveram valores de r_{hh} superiores a 0,980 e RQEM inferiores a 5%. Castro (2011) verificou eficiência de redes neurais do tipo MLP para projeção de diâmetro e altura em florestas comerciais de eucalipto. As melhores redes apresentaram valores de coeficientes de correlação superiores a 0,980 e RQEM inferiores a 1%.

Vendruscolo et al. (2015), utilizando o modelo de Gompertz e redes neurais para estimação da altura total de árvores de *Eucalyptus* spp, concluíram que a modelagem por redes neurais foi perfeitamente viável, permitindo que se utilizasse

apenas uma rede para realizar a predição da altura das árvores em diferentes locais. Ainda, a utilização de RNA's demonstra potencial para estimação de outras variáveis como no estudo de Silva et al. (2009) testando o modelo de Schumacher e Hall e a técnica de inteligência artificial para estimar o volume de árvores de eucalipto, onde os autores concluem que as estimativas pelo modelo de regressão pode ser usado com acurácia, entretanto, a modelagem por RNA apresentou-se mais adequada ao problema.

A modelagem por redes neurais além de se mostrar uma técnica potencial para fins de manejo e mensuração florestal, também permite reduzir os custos de inventário florestal, devido a possibilidade da redução da intensidade amostral como relatado por Binoti et al. (2013a). Nesse caso, o próximo inventário pode ser feito só com a mensuração do *dap* do povoamento, variável que é mensurada facilmente no campo.

Estudos futuros devem ser conduzidos no sentido de testar diferentes arquiteturas de RNA's, já que a robustez e poder de aprendizado da técnica estão diretamente associados a uma adequada arquitetura da rede (BINOTI et al., 2014).

5. CONCLUSÕES

Na modelagem por regressão, os modelos não lineares foram superiores aos lineares para estimativa da altura, com destaque para o modelo de Gompertz.

As duas técnicas avaliadas são eficientes para estimativa da altura de árvores de *Tectona grandis*, porém, a técnica de redes neurais apresentou indicadores estatísticos superiores em relação à regressão, com erro de estimativa abaixo de 10%.

6. REFERÊNCIAS

- BARTOSZECK, A. C. P. S. et al. Dinâmica da relação hipsométrica em função da idade, do sítio e da densidade inicial de povoamentos de bracinga da região metropolitana de Curitiba, Paraná. **Revista Árvore**, Viçosa, v. 28, n. 4, p. 517-533, 2004. <http://dx.doi.org/10.1590/S0100-67622004000400006>
- BATISTA, J. L. F.; COUTO, H. T. Z.; MARQUESINI, M. Desempenho de modelos de relações hipsométricas: estudo em três tipos de floresta. **Scientia Forestalis**, Piracicaba, n. 16, p. 149-163, 2001.
- 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**, Pelotas, v. 5, n.1, p.58-67, 2014. <http://dx.doi.org/10.12953/2177-6830.v05n01a06>
- BINOTI, D. H. B.; BINOTI, M. L. M.; LEITE, H. G.; SILVA, A. Redução de custos em inventário de povoamentos equiâneos. **Agrária**, Recife, v. 8, n. 1, p. 125-129, 2013. <http://dx.doi.org/10.5039/agraria.v8i1a2209>
- BINOTI, M. L. M. S. **Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto**. 2010. 54 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa 2010.
- 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**, Viçosa, v. 37, n. 4, p. 639-645, 2013b. <http://dx.doi.org/10.1590/S0100-67622013000400007>
- BRAGA, A. P.; CARVALHO A. P. L. F.; LUDEMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. LTC - Livros Técnicos e Científicos Editora S.A., 2000. 262p.
- CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal: perguntas e respostas**. 4. ed. Viçosa: UFV, 2013. 605p.

- CASTRO, R. V. O. **Modelagem do crescimento em nível de árvores individuais e utilizando redes neurais e autômatos celulares**. 2011. 80 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2011.
- CURTIS, R. O. Height diameter and height diameter age equations for second growth Douglas-fir. **Forest Science**, Washington, v. 13, n. 4, p. 356-375, 1967.
- DRESCHER, R. **Crescimento e produção de *Tectona grandis* Linn. F., em povoamentos jovens de duas regiões do estado de Mato Grosso**. 2004. 133 f. Tese (Doutorado em Engenharia Florestal) - Universidade Federal de Santa Maria, Santa Maria, 2004.
- EMBRAPA – (Empresa Brasileira de Pesquisa Agropecuária). Centro Nacional de Pesquisa de Solos. **Sistema Brasileiro de Classificação de Solos**. 2. ed. Rio de Janeiro: Embrapa, 2006. 306 p.
- GORGENS, E. B.; LEITE, H. G.; SANTOS, H. N.; GLERIANI, J. N. Estimativa do volume de árvores utilizando redes neurais artificiais. **Revista Árvore**, Viçosa, v. 33, n. 6, p. 1141-1147, 2009. <http://dx.doi.org/10.1590/S0100-67622009000600016>
- HAYKIN, S. **Redes neurais: princípios e prática**. Porto Alegre: 2001. 900p.
- HORNİK, K.; STINCHCOMBE, M.; WHITE, H. Multilayer feed forward network are universal approximators. **Neural Networks**, Bandera, v. 2, n. 5, p. 359-366, 1989. [http://dx.doi.org/10.1016/0893-6080\(89\)90020-8](http://dx.doi.org/10.1016/0893-6080(89)90020-8)
- LEITE, H. G.; OLIVEIRA, F. H. T. Statistical procedure to test the identity of analytical methods. **Communications in Soil Science Plant Analysis**, New York, v. 33, n. 7, p. 1105-1118, 2002. <http://dx.doi.org/10.1081/CSS-120003875>
- MIGUEL, E. P.; MOTA, F. C. M.; TÊO, 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. <http://dx.doi.org/10.5897/AJAR2016.11015>
- MORAES NETO, S. P. de; PULROLNIK, K.; VILELA, L.; MUNHOZ, D. J. de M.; GUIMARÃES JUNIOR, R.; MARCHAO, R. L. Modelos hipsométricos para *Eucalyptus cloeziana* e *Eucalyptus urophylla* x *Eucalyptus grandis* em sistema agrosilvipastoril. **Boletim de Pesquisa e Desenvolvimento**, v. 286, 2010, 33p.
- PRODAN, M.; PETERS, R.; COX, F.; REAL, P. **Mensura forestal**. San José: IICA, 1997. 586 p.
- REGAZZI, A. J.; SILVA, C. H. O. Testes para verificar a igualdade de parâmetros e a identidade de modelos de regressão não-linear em dados de experimento com delineamento em blocos casualizados. **Revista Ceres**, Viçosa, v. 57, n. 3, p. 315-320, 2010. <http://dx.doi.org/10.1590/S0034-737X2010000300005>
- ROSSI, A. S.; DRESCHER, R.; PELISSARI, A. L.; LANSSANOVA, L. R. Relação hipsométrica e crescimento de *Tectona grandis* L.f. no município de Monte Dourado, Pará. **Scientia Forestalis**, Piracicaba, v. 39, p. 301-307, 2011.
- SILVA, G. F.; CURTO, R. de A.; SOARES, C. P. B.; PIASSI, L. de C. Avaliação de métodos de medição de altura em florestas naturais. **Revista Árvore**, Viçosa, v. 36, n. 2, p. 341-348, 2012. <http://dx.doi.org/10.1590/S0100-67622012000200015>
- SILVA, M. L. M.; BINOTI, D. H. B.; GLERIANI, J. M.; LEITE, H. G. Ajuste do modelo de Schumacher e Hall e aplicação de redes neurais artificiais para estimar volume de árvores de eucalipto. **Revista Árvore**, Viçosa, v. 33, n. 6, p. 1133-1139, 2009. <http://dx.doi.org/10.1590/S0100-67622009000600015>
- SILVA, R. S.; VENDRUSCOLO, D. G. S.; ROCHA, J. R. M. da; CHAVES, A. G. S.; SOUZA, H. S.; MOTTA, A. S. da. Desempenho silvicultural de *Tectona grandis* L. f. em diferentes espaçamentos em Cáceres, MT. **Floresta e Ambiente**, Seropédica, v. 23, n. 3, p. 397-405, 2016. <http://dx.doi.org/10.1590/2179-8087.143015>
- SCOLFORO, J. R. S. **Biometria florestal**: parte I: modelos de regressão linear e não linear; parte II: modelos para relação hipsométrica, volume, afilamento e peso de matéria seca. Lavras: UFLA/FAEPE, 2005. 352 p.
- STOFFELS, A.; SOEST, V. J. **The main problems in sample plots**. 3. height regression. *Ned Bosbouw tijdschr.* 25: 190-199. 1953. [English summary in *for. Abstr.* 15: 77.]
- VENDRUSCOLO, D. G. S.; DRESCHER, R.; SOUZA, H. S.; MOURA, J. P. V. M.; MAMORÉ, F. M. D.; SIQUEIRA, T. A. da S. Estimativa da altura de eucalipto por meio de regressão não linear e redes neurais artificiais. **Revista Brasileira de Biometria**, São Paulo, v. 33, n. 4, p. 556-569, 2015.