

Redes neurais artificiais e regressão na estimativa da altura em povoamento experimental misto e equiâneo

Ernandes Macedo da Cunha Neto^{1*}, Jade Crystinne Franco Bezerra¹, Juliane dos Santos Andrade¹, Almir Lima do Mar¹, Monica Martins Vaz¹, Jonas Elias Castro da Rocha¹, Marcio Roberto da Silva Melo¹, Gustavo Antônio Ruffeil Alves¹

Resumo

O objetivo deste trabalho foi estimar a altura de um povoamento experimental misto através de redes neurais artificiais e regressão linear. O estudo foi realizado em um povoamento experimental misto e equiâneo localizado no município de Paragominas-PA. Nesse povoamento foi realizado o inventário de todas as árvores, no qual há duas espécies, uma delas é um clone de eucalipto e a outra é o Paricá. Foram ajustados oito modelos hipsométricos e treinadas 240 redes neurais artificiais (RNAs) com diferentes configurações. As variáveis de entrada das RNAs foram DAP, classe diamétrica e espécie. Selecionaram-se as melhores configurações RNAs e modelos hipsométricos com base no método de valor ponderado. A raiz quadrada do erro médio (RQME) apresentou melhores resultados nas RNAs do que nos modelos de regressão, denotando que os modelos de regressão possuem maior tendenciosidade. O bias foi satisfatório, denotando que o algoritmo é equilibrado e eficaz. Apesar dos altos valores de RQME, os modelos hipsométricos, assim como as RNAs obtiveram coeficiente de variação com baixa dispersão. Quanto ao coeficiente de correlação e ao R^2_{aj} , nota-se que as RNAs foram superiores em relação aos modelos hipsométricos. Ao analisar graficamente os resíduos dos estimadores, nota-se que as RNAs apresentaram homocedasticidade entre os dados, diferentemente dos modelos hipsométricos. As redes neurais artificiais e os modelos de regressão são formas viáveis para estimar da altura de um povoamento misto e equiâneo. As RNAs mostraram-se mais acuradas na estimação da altura total do povoamento misto e equiâneo, sendo o uso de variáveis categóricas um dos grandes destaques dessa técnica.

Palavras-chave: Eucalipto; inventário florestal; modelos hipsométricos; Paricá.

Artificial neural networks and regression in the estimation of height in mixed experimental reforestation

Abstract

The aim of this study was to estimate the height of mixed species afforestation through artificial neural networks and linear regression. The study was made out in an experimental mixed species reforestation located in Paragominas-PA, where, the inventory of all the trees was carried out. There are two species, one of them is a eucalyptus clone and the other is Paricá. Eight hypsometric models and 240 trained artificial neural networks (ANN) were adjusted with different configurations. The ANN input variables were DBH, diametric class and species. The best RNA configurations and hypsometric models were selected based on the considerate value method. The RMSE presented better results in RNA than in the regression models, denoting that the regression models have greater tendentiousness. The bias was satisfactory, showing that the algorithm is balanced and effective. Despite the high values of RMSE, the hypsometric models, as well as the ANN obtained coefficient of variation with low dispersion. About the correlation coefficient and R^2_{aj} , it is noted that the ANN were higher in relation to hypsometric models. When analyzing graphically residues of estimators, it was noted that the ANN had homoscedasticity of the data, differently from the hypsometric models. Artificial neural networks and regression models are viable to estimate the height of a mixed and same age reforestation. The ANN were more accurate in estimating the total height of the mixed and same age reforestation, being the use of categorical variables one of the great highlights of this technique.

Keywords: Eucalyptus; forest inventory; hypsometric models; Paricá.

¹Universidade Federal Rural da Amazônia. Campus Paragominas, PA - 256, s/nº - Nova Conquista - CEP 68625-970 - Paragominas - PA, Brasil.

*Autor para Correspondência: netomacedo878@gmail.com

Introdução

O inventário florestal é uma operação imprescindível para controle do volume de madeira em campo, podendo indicar a produtividade de determinados locais. Contudo, esta atividade demanda altos custos para a empresa detentora do povoamento, dessa forma, tornou-se comum o emprego de métodos alternativos de mensuração das árvores para que o tempo de coleta seja reduzido. Uma prática usual é a estimativa da altura dos indivíduos do plantio, uma vez que a altura das árvores é uma variável de difícil acesso e sujeita a erros ([Thiersch et al., 2013](#)). Assim, geralmente mensura-se a altura de algumas árvores para alimentar o banco de dados, enquanto as demais são estimadas por modelos de regressão, com base na relação entre o diâmetro e a altura das árvores (hipsométrica).

O ajuste de modelos de regressão para estimação da altura em povoamentos florestais é uma técnica evoluída e disseminada no Brasil, através de modelos lineares e não lineares ([Sanquetta et al., 2014](#)). Entretanto, um dos grandes obstáculos do ajuste destes modelos é a estratificação do banco de dados que será modelado, assim como a exatidão da variável dependente, pois, a relação hipsométrica é influenciada por vários elementos, tais como, espécie, idade, sítio, entre outros ([Machado et al., 2008](#); [Vendruscolo et al., 2015a](#)).

Além disso, na maioria das vezes a relação hipsométrica não possui uma correlação forte, ocasionando estimativas pouco acuradas, de forma que uma alternativa para obtenção de estimativas confiáveis é a inserção de variáveis qualitativas aos modelos de regressão, o que nem sempre é possível, dessa forma, uma opção é aplicar redes neurais artificiais (RNAs) na estimativa dessas alturas ([Martins et al., 2016a](#)).

Haykin (2001) e Braga et al. (2007) definem as RNA como modelos matemáticos paralelos, formados por unidades menores de processamento simples, conhecidos como neurônios artificiais, que estão dispostos em camadas de entrada, oculta e de saída. As RNA possuem capacidade de armazenar o conhecimento e aplicar ao banco de dados, além de detectar as relações não lineares entre a variável de saída e as variáveis de entrada durante o processo de aprendizagem, favorecendo o emprego de variáveis qualitativas com eficácia ([Martins et al., 2016a](#)).

Todavia, o bom desempenho das RNAs depende da configuração adequada, ou seja, do número de camadas e de neurônios, da função de ativação, do algoritmo de aprendizagem, entre outros fatores, sendo que para determinar a melhor configuração de uma rede, deve-se testar os parâmetros e alterá-los quando a RNA não proporcionar um bom resultado ([Artero, 2009](#); [Aertsen et al., 2010](#); [Özçelik et al., 2013](#)). Diante do exposto, objetivou-se com este trabalho estimar a altura de um povoamento experimental misto e equiâneo através de redes neurais artificiais e regressão linear.

Material e métodos

Caracterização da área de estudo

O estudo foi realizado em um povoamento experimental misto e equiâneo localizado nas dependências da Universidade Federal Rural da Amazônia, campus Paragominas - PA, situada às margens da Rodovia PA-256, no km 06. O município (Figura 1) o qual o povoamento está inserido possui clima do tipo "Aw", de acordo com a classificação de Koppén, com temperatura média anual de 26°C ([Alvares et al., 2013](#)).

Nesse povoamento foi realizado o inventário de todas as árvores, no qual há duas espécies, uma delas é um clone de eucalipto híbrido de *Eucalyptus grandis* W. Hill ex Maiden x *Eucalyptus urophylla* S.T. Blake e a outra é o Paricá (*Schizolobium parahyba* var *amazonicum* Huber ex Ducke Barneby), ambas as espécies possuem 4 anos de idade e estão sob espaçamento 3 m X 3 m. Os indivíduos deste plantio foram mensurados quanto à circunferência a altura do peito (CAP) utilizando fita centimétrica e a altura total, com auxílio do clinômetro da marca Haglöf.

Os dados coletados em campo foram sistematizados no software *Microsoft Office Excel* versão 2013, nos quais indivíduos foram separados em cinco classes (Tabela 1), para maior precisão da divisão destes para o ajuste e validação tanto dos modelos hipsométricos quanto das RNAs, de modo a retirar 30% do banco de dados para a validação e 70% para o ajuste dos modelos e treinamento das RNA, não havendo separação das espécies durante este processo.

Ajuste dos modelos de regressão

Foram ajustados oito modelos hipsométricos (Tabela 2) no software R, versão 3.3.0 (R Core Team, 2017). Optou-se por estes modelos, devido ao fato de que esses são alguns dos mais difundidos na literatura e utilizados em diversos trabalhos, tais como, [Pereira et al. \(2014\)](#); [Sanquetta et al. \(2015\)](#); [Souza et al. \(2017\)](#).

Treinamento das redes neurais artificiais

As RNAs treinadas foram do tipo *Multilayer Perceptron*, com utilizado o algoritmo de aprendizagem do tipo *Resilient Propagation* RPROP⁺. Tal configuração foi utilizada, devido seu bom desempenho quando aplicada as ciências florestais, como por exemplo, na estimação de diâmetro ([Martins et al., 2016b](#)), volume ([Binoti et al., 2014](#)) e redução de custos em inventários florestais ([Binoti et al., 2013a](#)).

Figura 1 – Localização do município de Paragominas – PA, no qual foi realizado a estimativa da altura do povoamento experimental misto e equiâneo

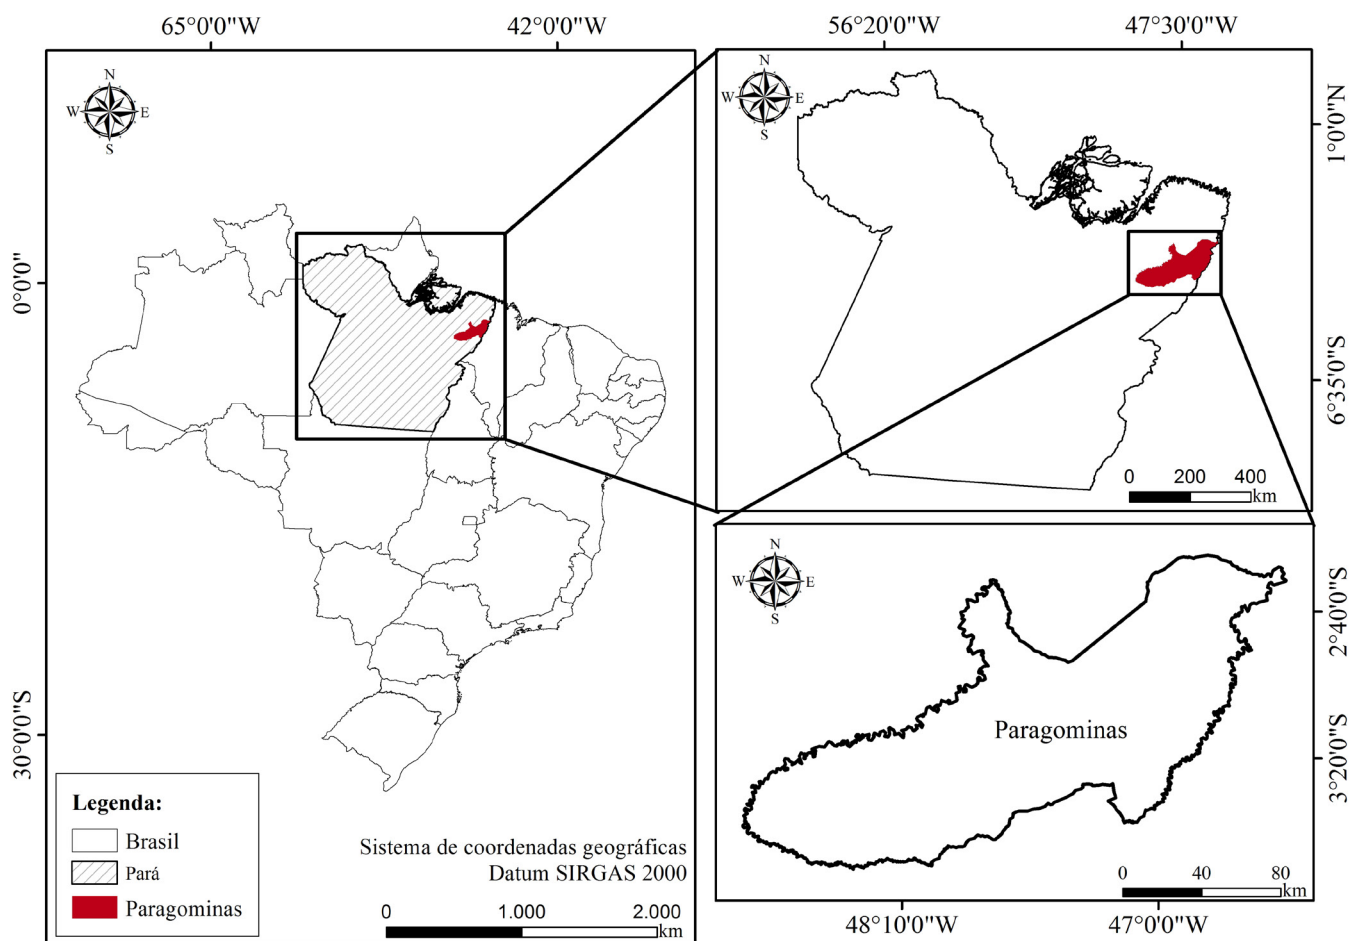


Tabela 1 – Classes diamétricas das respectivas espécies do povoamento experimental misto e equiâneo, no município de Paragominas - PA

Espécie	Classe	Limite Inferior (cm)	Média (cm)	Limite Superior (cm)
Paricá	I	1,11	2,49	3,87
	II	3,87	5,26	6,64
	III	6,64	8,03	9,42
	IV	9,42	10,80	12,19
	V	12,19	13,57	14,96
Eucalipto	I	4,62	5,56	6,50
	II	6,50	7,44	8,38
	III	8,38	9,32	10,25
	IV	10,25	11,19	12,13
	V	12,13	13,07	14,01

Entretanto, não há uma definição de arquitetura ideal para obter bons resultados com as RNA, logo há necessidade de testar diversas configurações para selecionar aquela de melhor adequação aos dados (Gorgens et al., 2014). Diante disso, treinou-se redes com diferentes

arquitecturas e funções de ativação (Tabela 3), com base nos resultados de Binoti (2010) e Martins et al. (2016b), nos quais as melhores funções de ativação foram as do tipo tangente hiperbólica e sigmoidal.

Tabela 2 – Modelos de regressão linear aplicados na estimativa da altura do povoamento experimental misto e equiâneo, no município de Paragominas - PA

Modelo	Equação
Linear Simples	$Ht_i = \beta_0 + \beta_1 DAP_i + \varepsilon_i$
Azevedo <i>et al.</i> (1999)	$Ht_i = \beta_0 + \beta_1 DAP_i^2 + \varepsilon_i$
Henricksem (1950)	$Ht_i = \beta_0 + \beta_1 \ln(DAP_i) + \varepsilon_i$
Trorey (1932)	$Ht_i = \beta_0 + \beta_1 * DAP + \beta_2 * DAP_i^2 + \varepsilon_i$
Hiperbolico	$DAP_i / \sqrt{h_i} = \beta_0 + \beta_1 DAP_i + \varepsilon_i$
Curtis (1967)	$\ln(Ht_i) = \beta_0 + \beta_1 (1/DAP_i) + \varepsilon_i$
Stoffles e Soest (1953)	$\ln(Ht_i) = \beta_0 + \beta_1 \ln(DAP_i) + \varepsilon_i$
Naslund	$\sqrt{DAP_i^2 / (h_i - 1,3)} = \beta_0 + \beta_1 DAP_i + \varepsilon_i$

Tabela 3 – Configurações e arquitetura das 240 RNA treinadas na estimativa da altura do povoamento experimental misto e equiâneo, no município de Paragominas - PA

RNA	CE	CO	CS	FA na CO e CS
1 a 10	5	3	1	
11 a 20	5	4	1	
21 a 30	5	5	1	Sigmoidal/ Sigmoidal
31 a 40	5	6	1	
41 a 50	5	7	1	
51 a 60	5	8	1	
61 a 70	5	3	1	
71 a 80	5	4	1	
81 a 90	5	5	1	Tangente hiperbólica/Sigmoidal
91 a 100	5	6	1	
101 a 110	5	7	1	
111 a 120	5	8	1	
121 a 130	5	3	1	
131 a 140	5	4	1	
141 a 150	5	5	1	Tangente hiperbólica/Tangente hiperbólica
151 a 160	5	6	1	
161 a 170	5	7	1	
171 a 180	5	8	1	
181 a 190	5	3	1	
191 a 200	5	4	1	
201 a 210	5	5	1	Sigmoidal/Tangente hiperbólica
211 a 220	5	6	1	
221 a 230	5	7	1	
231 a 240	5	8	1	

Em que: CE: camada de entrada; CO: camada oculta; CS: camada de saída; FA: Função de ativação da rede.

As redes foram treinadas no *software* Neuro versão 4.06, no qual o critério de parada do treinamento das redes foi 3000 ciclos ou o erro quadrático médio inferior a 1%, assim como propôs Leal *et al.* (2015) em seu trabalho. Adicionalmente, a variável de entrada quantitativa foi o DAP, enquanto que a classe diamétrica e espécie foram as variáveis de entrada qualitativas. Por fim, a variável de saída foi a altura dos indivíduos. Além disso, ainda com base no estudo de Martins *et al.* (2016b), definiu-se que a quantidade de neurônios na camada oculta teria entre três e oito neurônios, compondo 240 diferentes configurações de RNA.

Avaliação das estimativas por regressão e redes neurais artificiais

Para avaliação de ambas as formas de estimação, utilizaram-se as seguintes medidas de precisão do ajustamento: raiz quadrada do erro médio (RQME), erro padrão da estimativa (S_{yx}) e coeficiente de variação (CV) baseado no método proposto por Garcia (1989). Além disso, exclusivamente para as RNA também foi avaliado o coeficiente de correlação múltipla (r) e o bias (bk), enquanto que nos modelos de regressão foi aplicado o teste de Fisher (FCAL) e o coeficiente de determinação ajustado (R^2_{aj}). Estas medidas de precisão foram obtidas pelas equações 1, 2, 3, 4, 5, 6 e 7, respectivamente.

$$RQME = \frac{100}{\bar{H}} \sqrt{\frac{\sum_{i=1}^n (H_i - \hat{H}_i)^2}{n}} \quad \text{Eq. 1}$$

$$r_{H\hat{H}} = \frac{\text{cov}(H, \hat{H})}{\sqrt{s^2(H)s^2(\hat{H})}} \quad \text{Eq. 2}$$

$$S_{yx} = \sqrt{\frac{\sum_{i=1}^n (H_i - \hat{H}_i)^2}{n - p}} \quad \text{Eq. 3}$$

$$CV = \frac{s}{\bar{H}} * 100 \quad \text{Eq. 4}$$

$$bk = \frac{\sum_{i=1}^n (\hat{H}_i - H_i)}{n} \quad \text{Eq. 5}$$

$$F_{cal} = \frac{Q_m \text{ regressão}}{Q_m \text{ resíduo}} \quad \text{Eq. 6}$$

$$R^2_{aj} = 1 - (1 - R^2) \times \frac{n-1}{n-p} \quad \text{Eq. 7}$$

Em que: $\sum_{i=1}^n$ = somatório; H_i = altura observada; \hat{H}_i = altura prevista; n = número de amostras; \bar{H} = média das alturas; cov = covariância; s^2 = variância; s = desvio padrão; Q_m = quadrado médio; R^2 = coeficiente de determinação; p = número de coeficientes do modelo.

Posteriormente, de acordo com o valor obtido para cada parâmetro, foi realizado um *ranking*, seguindo o método, descrito por Thaines *et al.* (2010), pelo qual são atribuídas pontuações a cada uma destas medidas de precisão. Assim, o peso 1 foi atribuído para o modelo/rede mais eficiente em determinado parâmetro, enquanto que o peso 2 será designado para o segundo modelo/rede mais eficiente neste parâmetro, e assim sucessivamente de acordo com a eficiência. Ao término desse processo soma-se todos os pesos e os quatro modelos/redes com menor soma dos pesos é selecionado. Após esse processo, aqueles selecionados serão avaliados quanto a tendenciosidade de estimação, por meio da análise gráfica da dispersão dos resíduos (Eq. 8) em função das alturas observadas em campo.

$$E(\%) = \frac{H_i - \hat{H}_i}{H_i} * 100 \quad \text{Eq. 8}$$

Por fim, aplicou-se o teste t, ao nível de 95% de probabilidade, comparando valores observados e valores estimados no conjunto de validação para os dois métodos de estimação.

Resultados e discussão

Ao todo foram mensuradas 319 árvores, divididas entre 157 pertencentes ao Paricá e 162 de Eucalipto. Desse total, 96 indivíduos foram aleatoriamente destinados a validação, o restante foi usado no ajuste das regressões e treinamento das RNA. Foram selecionadas as RNA 3, 31, 152 e 58, enquanto que os modelos que melhor se ajustaram ao povoamento foram Stoffles e soest (1953), Henricksem (1950), Curtis (1967) e Hiperbólico (Tabela 4).

Das RNAs selecionadas, apenas a 152 possui ambas as funções de ativação do tipo tangente hiperbólica, enquanto as demais eram do tipo sigmoidal. Nota-se que combinações de diferentes funções de ativação não foram eficazes. Quanto à arquitetura, a RNA 3 possui o número mínimo de neurônios na camada oculta, enquanto que a RNA 58 apresenta o número máximo. As RNAs 31 e 152 são compostas por 6 neurônios na camada oculta. Tais resultados corroboram com os encontrados por Binoti *et al.* (2013b) e Martins *et al.* (2016a) que encontraram RNA eficazes com configuração similar.

A RQME apresentou melhores resultados nas RNAs, denotando que os modelos de regressão possuem maior tendenciosidade. Binoti *et al.* (2013a) reportaram RNAs com valores de RQME inferiores a 2%, correspondendo aos resultados encontrados neste estudo. O bias foi satisfatório, denotando que o algoritmo é equilibrado (não tendencioso) e eficaz.

Tabela 4 – Medidas de precisão dos melhores estimadores na estimativa da altura do povoamento experimental misto e equiâneo, no município de Paragominas - PA

Estatísticas	RNA 3	RNA 31	RNA 152	RNA 58	Stoffles e Soest (1953)	Henricksem (1950)	Curtis (1967)	Hiperbólico
Bias	-0,00047	0,00118	-0,00162	-0,00053	-	-	-	-
RQME (%)	1,016	1,018	1,021	1,022	13,261	11,729	20,710	18,461
r/R ² aj.	0,9523	0,9522	0,9519	0,9518	0,8587	0,8907	0,8459	0,6560
Syx	0,16642	0,16640	0,16571	0,16637	0,31571	1,10419	0,32967	0,29818
CV	1,7930%	1,7928%	1,7853%	1,7924%	1,6060%	11,7753%	1,6770%	3,1798%
FCAL	-	-	-	-	1532,228	2054,5707	1384,4525	481,4589
VP	238	254	269	307	9	13	18	21
Pesos								
RNA/Modelo	H0	H1	H2	H3	H4	H5	H6	H7
3	1,354	0,001	-3,294	-	-	-	-	-
31	-2,565	1,448	0,517	0,381	-2,938	0,775	-	-
152	-0,493	0,145	0,554	1,007	0,274	-0,186	-	-
58	1,183	0,841	0,359	0,660	0,748	-1,733	-4,921	-0,872
Stoffles e Soest (1953)	-0,299*	1,067*	-	-	-	-	-	-
Henricksem (1950)	-10,963*	9,063*	-	-	-	-	-	-
Curtis (1967)	3,044*	-7,922*	-	-	-	-	-	-
Hiperbolico	1,640*	0,152*	-	-	-	-	-	-

Em que: VP = valor ponderado; RQME = raiz quadrada do erro médio; r = coeficiente de correlação múltipla; R²aj. = coeficiente de determinação ajustado; Syx = erro padrão da estimativa; CV = coeficiente de variação; Fcal = teste de Fisher; H = peso; * = significativo pelo teste t ao nível de 5% de probabilidade.

Apesar dos altos valores de RQME, os modelos de regressão, assim como as RNAs obtiveram coeficiente de variação com baixa dispersão, com exceção do modelo de Henricksem (1950), que teve dispersão moderada. Quanto ao erro padrão da estimativa, grande parte dos modelos de regressão ajustados apresentaram valores maiores do que os demonstrados pelas RNAs para este parâmetro, contudo, estes ainda são menores os Syx que Vedruscolo *et al.* (2015a) encontraram em seu estudo. O teste de Fisher foi significativo para todos os modelos, ratificando com os resultados que Cunha Neto *et al.* (2017a) reportaram, no qual o Fcal apresentou valores superiores a 1000 para este parâmetro.

Em relação ao coeficiente de correlação e ao R² aj., nota-se que as RNAs apresentaram valores acima de 0,95 para o parâmetro *r*, enquanto que o valor máximo do R² aj. foi 0,89, contudo, considerou-se satisfatório o resultado de ambos os estimadores, pois é comum que estes não ultrapassem 0,8 na estimativa de altura, devido à correlação altura/diâmetro não ser tão forte quanto à relação altura/volume, indicando elevado grau de explicação das variáveis dependentes pelas variáveis

independentes dos estimadores. Binoti *et al.* (2013b), também encontraram RNA com correlação superior a 0,9 na estimativa de altura de eucalipto, enquanto que os modelos de regressão estimados por Vedruscolo *et al.* (2017) apresentaram correlação maior que 0,80, ratificando os resultados encontrados nesse estudo. Entretanto, o modelo Hiperbólico o R²aj, não alcançou resultados tão bons quanto os outros modelos, divergindo dos resultados verificados por Souza *et al.* (2017) e Cunha Neto *et al.* (2017a) para este modelo.

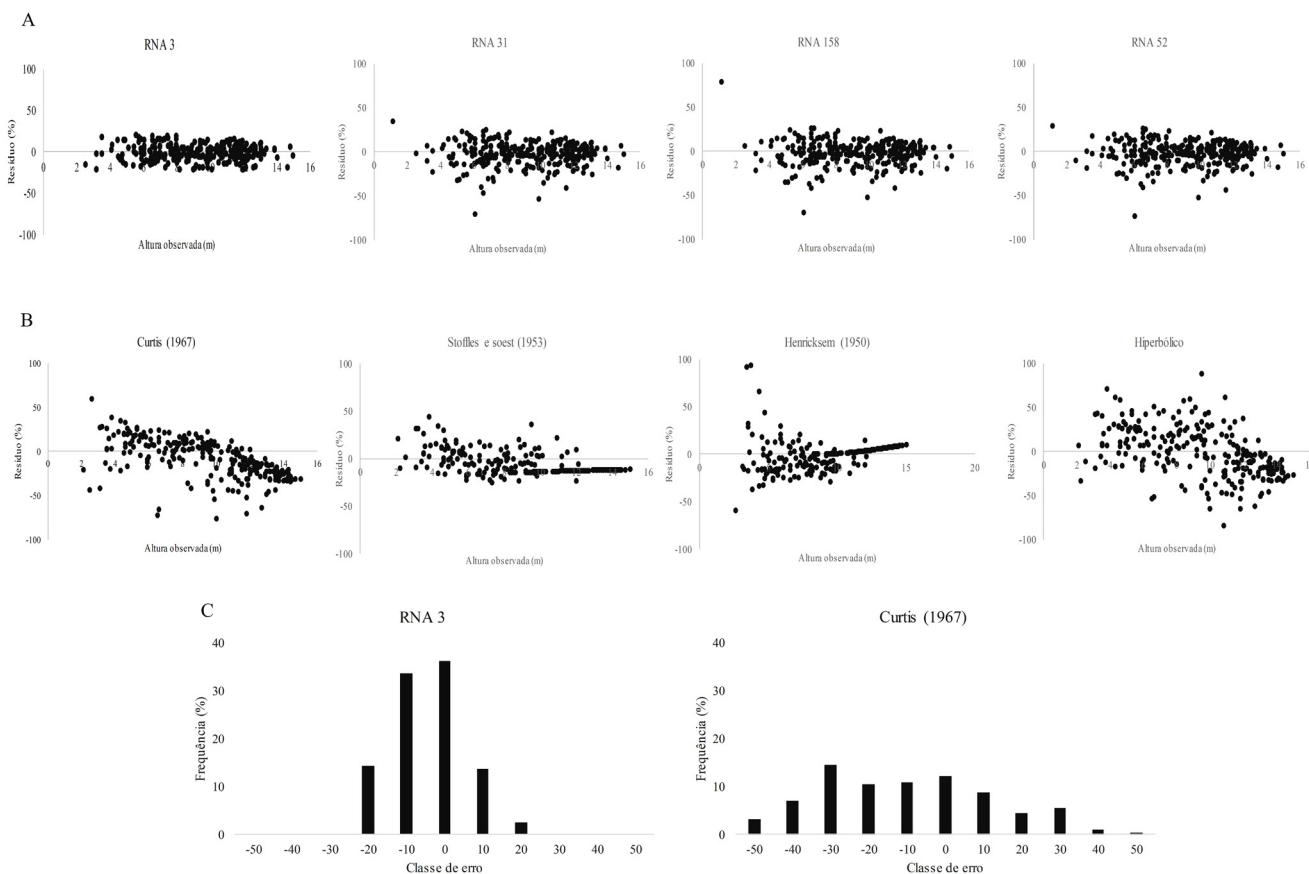
Ao analisar graficamente os resíduos dos estimadores, nota-se que os modelos hipsométricos (Figura 2b) possuem menor homocedasticidade entre os dados, de tal forma que para as RNA (Figura 2a) há uma melhor distribuição destes nas proximidades da reta média, com ênfase para a RNA 3, que apresentou melhor dispersão. Gorgens *et al.* (2014) e Cunha Neto *et al.* (2017b) também encontraram RNA com dispersão adequada dos resíduos e ressaltaram que valores próximos de zero são apresentados por redes que demonstram capacidade de estimar variáveis de interesse com acurácia.

Percebe-se certa tendenciosidade nos modelos Stoffles e Soest (1953), assim como Henricksem (1950), além de uma dispersão altamente heterogênea no modelo hiperbólico, contradizendo [Cunha Neto et al. \(2017a\)](#), que definiu o modelo hiperbólico como o que melhor se ajustou ao povoamento de seu estudo, devido este apresentar uma dispersão adequada dos resíduos.

Diante disso, escolheu-se a RNA 3 e o modelo de Curtis (1967) para representar o povoamento, por

apresentarem melhor distribuição dos resíduos. Contudo, pelos histogramas de frequência dos erros (Figura 2c) é notório que as RNA apresentaram uma distribuição mais adequada dos resíduos, de modo que estes se concentraram entre as classes -20% e 20%. Tal análise faz-se necessária, pois evita que sejam realizadas interpretações errôneas do gráfico de dispersão dos resíduos (Campos; Leite, 2013).

Figura 2 – Dispersão dos resíduos dos melhores estimadores na estimativa da altura do povoamento experimental misto e equiâneo, no município de Paragominas - PA



Quando comparadas as estatísticas do treinamento e da validação, para ambas as técnicas, pode-se inferir que estas foram precisas, contudo, a RNA apresentou melhores resultados nos parâmetros o RQME e o r , inferindo que este método é preciso e sem tendenciosidade (Tabela 5). [Vendruscolo et al. \(2015b\)](#), bem como [Vendruscolo et al. \(2017\)](#) também encontraram estimativas de altura mais precisadas na aplicação de RNA em relação aos modelos de regressão. Tal fato é comprovado ao analisar as médias do povoamento e dos estimadores, de tal maneira que a média de altura observada no povoamento foi de 9,29 m, enquanto que as técnicas estimaram uma altura

média de 9,36 m e 8,57 m, respectivamente para a RNA 3 e modelo de Curtis (1967).

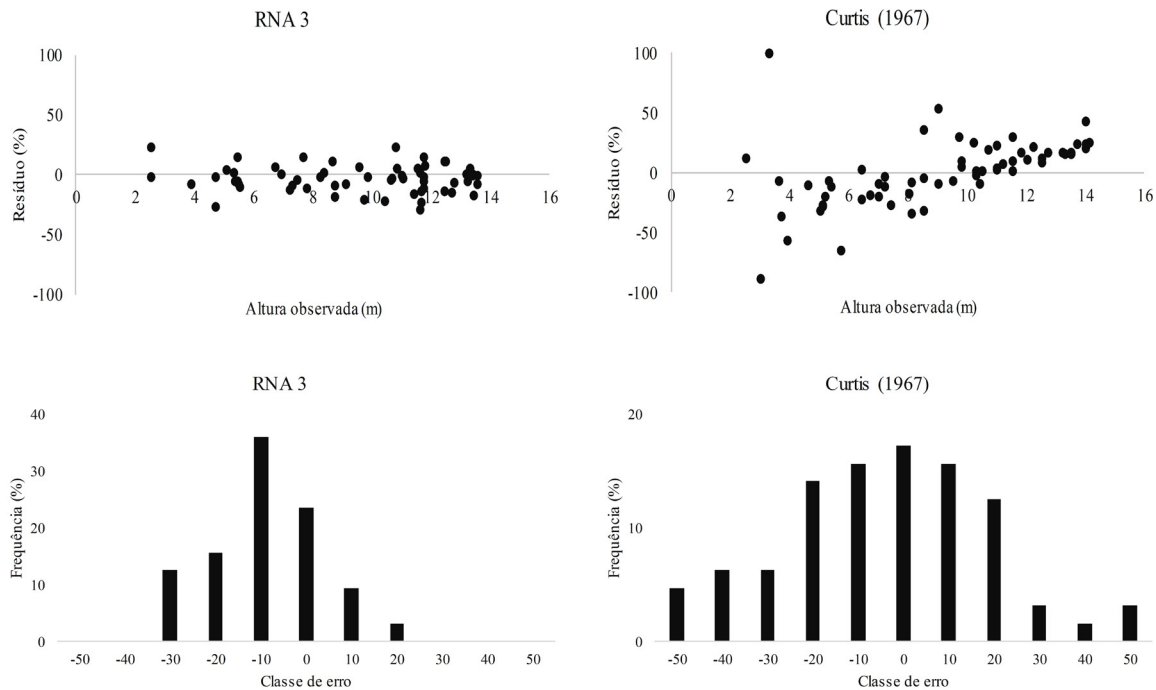
Apesar disso, pelo Teste t, não houve diferença significativa entre as alturas observadas e estimadas pelas duas técnicas, de tal forma que a RNA 3 superestimou a altura em média de 0,06 m e o modelo de Curtis subestimou a altura em 0,72 m. Assim, os gráficos de dispersão dos resíduos e os histogramas de frequência dos erros para a validação (Figura 3), comprovam que a RNA foi moderadamente superior ao modelo de regressão, além de mais precisa.

Tabela 5 – Resultados do treinamento e validação das duas técnicas de estimação selecionadas para prognose da altura total de um povoamento misto e equiâneo, no município de Paragominas-PA

Técnica	Treino				Validação				
	RQME (%)	$r/R^2aj.$	SYX	CV	RQME (%)	$r/R^2aj.$	SYX	CV	P-value
RNA 3	1,02	0,952	0,17	1,793%	1,15	0,941	0,37	3,988%	0,59 ^{ns}
Curtis (1967)	20,71	0,846	0,33	1,677%	22,90	0,938	0,76	4,290%	0,34 ^{ns}

Em que: RQME = raiz quadrada do erro médio; r = coeficiente de correlação múltipla; $R^2aj.$ = coeficiente de determinação ajustado; Syx = erro padrão da estimativa; CV = coeficiente de variação; ns = não significativo pelo teste t ao nível de 5% de probabilidade.

Figura 3 – Dispersão dos resíduos dos estimadores validados na estimativa da altura do povoamento experimental misto e equiâneo, no município de Paragominas - PA



Além disso, a possibilidade de inserção de variáveis categóricas já fornece a RNA um grande diferencial em relação aos modelos de regressão, pois isto permite que apenas uma RNA desempenhe a função de vários modelos de regressão, pois, devido à abrangência do banco de dados há necessidade de estratificá-los para o emprego do método convencional de regressão (Binoti *et al.*, 2014). Isto também foi constatado no estudo de Vendruscolo *et al.* (2015b), no qual os autores afirmam que as variáveis categóricas geram estimativas precisas e acuradas.

Conclusão

As redes neurais artificiais e os modelos hipso-métricos de regressão são formas viáveis para estimar da altura de um povoamento misto e equiâneo.

As RNAs mostraram-se mais acuradas na estimativa da altura total do povoamento misto e equiâneo, sendo o uso de variáveis categóricas um dos grandes destaques dessa técnica.

Referências

Aertsen, W.; Kint, V.; Van Orshoven, J.; Özkan, K.; Muys, B. 2010. Comparison and ranking of different modelling techniques for prediction of site index in Mediterranean mountain forest. *Ecological modelling* 221: 1119–1130. Doi: <http://dx.doi.org/10.1016/j.ecol-model.2010.01.007>.

Alvares, C. A.; Stape, J. L., Sentelhas, P. C., Moraes, G., Leonardo, J.; Sparovek, G. 2013. Köppen's climate classification map for Brazil. *Meteorologische zeitschrift* 22: 711-728. Doi: <https://dx.doi.org/10.1127/0941-2948/2013/0507>.

Artero, A. O. 2009. *Inteligência artificial: teoria e prática*. Editora Livraria da Física. São Paulo.

Binoti, M. L. M. da S. 2010. *Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto*. Viçosa: Universidade Federal de Viçosa, 54f. Dissertação Mestrado.

- Binoti, D. H. B.; Binoti, M. L. M.; Leite, H. G.; Silva, A. 2013a. Redução dos custos em inventário de povoamentos equiâneos. *Revista Brasileira de Ciências Agrárias* 8: 125-129. Doi: <https://dx.doi.org/10.5039/agraria.v8i1a2209>.
- Binoti, D. H. B.; Binoti, M. L. M. S.; Leite, H. G. 2014. Configuração de redes neurais artificiais para estimação do volume de árvores. *Ciência da madeira* 5: 58-67. Doi: <https://dx.doi.org/10.12953/2177-6830.v05n01a06>.
- Binoti, M. L. M. da S.; Binoti, D. H. B.; Leite, H. G. 2013b. Aplicação de redes neurais artificiais para estimação da altura de povoamentos equiâneos de eucalipto. *Revista Árvore* 37: 639-645. Doi: <http://dx.doi.org/10.1590/S0100-67622013000400007>.
- Braga, A. de P.; Carvalho, A. C. P. de L. F. de; Ludemir, T. B. 2007. *Redes neurais artificiais: teoria e aplicações*. Rio de Janeiro: Livros Técnicos e Científicos.
- Campos, J. C. C.; Leite, H.; G. 2013. *Mensuração Florestal: Perguntas e Respostas*. 4. ed. Editora UFV Viçosa, MG.
- Cunha Neto, E. M.; Cantão, B. P.; Callegari, D. M.; Gouveia, D. M.; Rocha, J. E. C. 2017b. Redes neurais artificiais na estimativa do volume individual de árvores de um híbrido de eucalipto, no município de Paragominas – Pará. In: II congresso internacional das ciências agrárias, 2017b. Instituto Internacional Despertando Vocações. Políticas Educacionais e Suas Interfaces: Desafios e Perspectivas na Construção de Sociedades Sustentáveis... Doi: <http://dx.doi.org/10.31692/2526-7701.iicointerpdvagro.2017.00118>.
- Cunha Neto, E. M.; Rocha, J. E. C.; Gouveia, D. M. 2017a. Estimação de altura total individual de eucalipto por meio de modelos hipsométricos no município de Paragominas – Pará. In: II congresso internacional das ciências agrárias, 2017a. Instituto Internacional Despertando Vocações. Políticas Educacionais e Suas Interfaces: Desafios e Perspectivas na Construção de Sociedades Sustentáveis. Doi: <http://dx.doi.org/10.31692/2526-7701.iicointerpdvagro.2017.00325>.
- Garcia, C. H. 1989. *Tabelas para classificação do coeficiente de variação*. Instituto de Pesquisas e Estudos Florestais [IPEF]. Piracicaba.
- Gorgens, E. B.; Leite, H. G.; Gleriani, J. M.; Soares, C. P. B.; Ceolin, A. 2014. Influência da arquitetura na estimativa de volume de árvores individuais por meio de redes neurais artificiais. *Revista Árvore* 38: 289-295. Doi: <http://dx.doi.org/10.1590/S0100-67622014000200009>.
- Haykin, S. 2001. *Redes neurais: princípios e prática*. 2. ed. Bookman. Porto Alegre.
- Leal, F. A.; Miguel, E. P.; Matricardi, E. A. T.; Pereira, R. S. 2015. Redes neurais artificiais na estimativa de volume em um plantio de eucalipto em função de fotografias hemisféricas e número de árvores. *Revista Brasileira de Biometria* 33: 233-249.
- Machado, S. A. Nascimento, R. G. M.; Augustynczyk, A. L. D.; Silva, L. C. R.; Figura, M. A.; Pereira, E. M.; Teo, S. J. 2008. Comportamento da relação hipsométrica de *Araucaria angustifolia* no capão da engenharia florestal da UFPR. *Pesquisa Florestal Brasileira* 56: 5-16.
- Martins, E. R.; Binoti, M. L. M. S.; Leite, H. G.; Binoti, D. H.; Dutra, G. C. 2016a. Configuração de redes neurais artificiais para estimação da altura total de árvores de eucalipto. *Revista Brasileira de Ciências Agrárias* 11: 117-123. Doi: <http://dx.doi.org/10.5039/agraria.v11i2a5373>.
- Martins, E. R.; Binoti, M. L. M. S.; Leite, H. G.; Binoti, D. H.; Dutra, G. C. 2016b. Configuração de redes neurais artificiais para estimação do afilamento do fuste de árvores de eucalipto. *Revista Brasileira de Ciências Agrárias* 11: 33-38. Doi: <http://dx.doi.org/10.5039/agraria.v11i1a5354>.
- Özçelik, R.; Diamantopoulou, M. J.; Crecente-Campo, F.; Eler, U. 2013. Estimating Crimean juniper tree height using nonlinear regression and artificial neural network models. *Forest Ecology and Management* 306: 52-60. Doi: <http://dx.doi.org/10.1016/j.foreco.2013.06.009>.
- Pereira, K. D.; Paixão, M. V. C.; Monteiro, C. W. B.; Laurido, F. T.; Ferreira, P. S. T. 2014. Ajuste de modelos hipsométricos para árvores de *Tectona grandis* L.f. no município de mojú, Pará. *Enciclopédia Biosfera* 10: 181-189.
- R CORE TEAM. R. 2017. *A language and environment for statistical computing*. Vienna: R Foundation for Statistical Computing.
- Sanquetta, C. R.; Corte, A. P. D.; Rodrigues, A. L.; Watzlawick, L. F. 2014. *Inventários Florestais: Planejamento e Execução*. 3. ed. Curitiba: Multi-Graphic.
- Sanquetta, M. N. I.; Sanquetta, C. R.; Mognon, F.; Corte, A. P. D.; Rodrigues, A. L.; Maas, G. B. C. 2015. Ajuste de equações hipsométricas para a estimação da altura total de indivíduos jovens de teca. *Científica* 43: 400-406. Doi: <http://dx.doi.org/10.15361/1984-5529.2015v-43n4p400-406>.
- Souza, A. S.; Santos, J. X.; Souza, D. V. 2017. Modelagem da relação hipsométrica para um povoamento do híbrido de eucalipto na Amazônia brasileira. *Biofix Scientific Journal* 2: 44-53. Doi: <http://dx.doi.org/10.5380/biofix.v2i1.51395>.
- Thaines, F.; Braz E. M.; Mattos, P. V.; Thaines, A. A. R. 2010. Equações para estimativa de volume de madeira para a região do Rio Ituxi, Lábrea, AM. *Pesquisa Florestal Brasileira* 30: 283-289. Doi: <http://dx.doi.org/10.4336/2010.pfb.30.64.283>.
- Thiersch, C. R.; Andrade, M. G.; Moreira, M. F. B.; Loibel, S. 2013. Estimativa da relação hipsométrica em clones de *Eucalyptus* sp. com o modelo de curtis ajustado por métodos bayesianos empíricos. *Revista Árvore* 37: 01-08. Doi: <http://dx.doi.org/10.1590/S0100-67622013000100001>.
- Vendruscolo, D. G. S.; Chaves, A. G. S.; Medeiros, R. A.; Silva, R. S.; Souza, H. S.; Drescher, R.; Leite, H. G. 2017. Estimativa da altura de árvores de *Tectona grandis* L.f. utilizando regressão e redes neurais artificiais. *Nativa* 5: 52-58. Doi: <http://dx.doi.org/10.5935/2318-7670.v05n01a09>.
- Vendruscolo, D. G. S.; Drescher, R.; Souza, H. S.; Moura, J. P. V. M.; Mamoré, F. M. D.; Siqueira, T. A. S. 2015b. Estimativa da altura de eucalipto por meio de regressão não linear e redes neurais artificiais. *Revista Brasileira de Biometria* 33: 556-569. Doi: <http://dx.doi.org/10.13140/RG.2.1.1742.5684>.
- Vendruscolo, D. G. S.; Drescher, R.; Souza, H. S. Silva, R. S. 2015a. Estratificação hipsométrica em plantios de eucaliptos na região sudeste de Mato Grosso. *Agrarian Academy* 2: 52-61. Doi: http://dx.doi.org/10.18677/Agrarian_Academy_005.