

ESTIMATIVA DA ALTURA DE EUCALIPTO POR MEIO DE REGRESSÃO NÃO LINEAR E REDES NEURAS ARTIFICIAIS

Diogo Guido Streck VENDRUSCOLO¹
Ronaldo DRESCHER¹
Hudson Santos SOUZA¹
Jhonny Pinto Vieira Mendes MOURA¹
Fernanda Meyer Dotto MAMORÉ¹
Tiago Altobelle da Silva SIQUEIRA¹

- RESUMO: Neste trabalho foi avaliada a modelagem por regressão não linear e por redes neurais artificiais para a estimativa da altura de árvores de eucaliptos. Os povoamentos estão localizados no município de Itiquira, MT. Os dados foram obtidos de 23 parcelas medidas aos quatro anos. O banco de dados foi dividido em dois conjuntos, um para o ajuste do modelo de regressão e treinamento das redes (70%) e o outro para validação da regressão e validação das redes treinadas (30%). O modelo de regressão não linear empregado foi o de Gompertz e as redes do tipo *perceptron* de múltiplas camadas (MLP). A avaliação da precisão das estimativas foi pelo coeficiente de correlação múltipla entre as alturas observadas e estimadas, raiz quadrada do erro médio em percentagem e a análises gráficas. Ambas as técnicas avaliadas são eficientes para a predição da altura de árvores. No entanto, as redes neurais apresentaram critérios estatísticos levemente superiores em relação à regressão.
- PALAVRAS-CHAVE: Povoamento florestal; inventário florestal; predição.

1 Introdução

O estabelecimento de plantios comerciais com eucalipto é crescente em Mato Grosso, juntamente com a demanda de madeira por parte das indústrias que utilizam dessa matéria prima. Além disso, favorece a redução da pressão sobre as áreas nativas, o que minimiza os impactos ao meio ambiente.

Para que as áreas de reflorestamento sejam conduzidas com sucesso, é imprescindível a realização de inventários florestais contínuos. Nos levantamentos realizados em povoamentos florestais equiâneos, uma das variáveis de maior interesse é o volume. Essa é a variável de maior importância para o conhecimento do potencial disponível em um povoamento florestal (THOMAS et al., 2006). Dentre os métodos de se avaliar o volume de árvores, é muito comum o uso de equações volumétricas de dupla

¹Universidade Federal de Mato Grosso - UFMT, Campus Cuiabá, Departamento de Engenharia Florestal, CEP: 78060-900, Cuiabá, Mato Grosso, Brasil. E-mail: diogoguido@hotmail.com; ronaldodrescher@gmail.com; hudson.ssh@hotmail.com; jhonnyvieiramendes@gmail.com; fernandandotto@hotmail.com; tiagosika@gmail.com.

entrada, cujo volume é obtido ao se relacionar o diâmetro a 1,3 m de altura (DAP) e a altura (Ht) das árvores (MIRANDA et al., 2014).

No entanto, a medição de alturas em povoamentos florestais é uma atividade onerosa, uma vez que, em comparação com a medição do diâmetro, sua obtenção não é fácil. Com isso, nos inventários florestais é utilizada uma ferramenta que ajuda na economia de tempo e capital, são os modelos baseados em relações hipsométricas (MENDONÇA et al., 2015).

O uso de equações para estimação da altura é bastante usual, visto que durante a medição direta alguns problemas podem ocorrer, como falta de visibilidade do topo da árvore em povoamentos densos, bem como a ocorrência de ventos, sobretudo em plantios de eucalipto (MENDONÇA et al., 2011; BINOTI et al., 2013b).

Uma alternativa promissora para a modelagem da relação hipsométrica consiste no uso de redes neurais artificiais – RNA (BINOTI et al., 2013a). Essas redes são sistemas computacionais paralelos constituídos por unidades de processamento simples, também denominadas neurônios artificiais ou nodos, conectadas entre si de maneira específica para desempenhar determinada tarefa (KOVÁCS, 1996; BRAGA et al., 2000; HAYKIN, 2001).

Redes neurais artificiais, considerada um termo raro há cerca de três décadas atrás na literatura científica, representa atualmente uma promissora área de pesquisa multidisciplinar (KOVÁCS, 1996; SILVA et al., 2010), e constituem puramente uma teoria para o estudo de diversos fenômenos, inclusive em manejo e mensuração florestal.

A utilização de RNA na ciência florestal brasileira é recente, no entanto, tem sido cada vez mais frequente a utilização dessa técnica para estimação de diversos parâmetros florestais, e muitas vezes com resultados melhores do que aqueles obtidos pelo emprego de regressão. Estudos comprovam a eficiência de RNA para situações como: estimação de volume (GORGENS et al., 2009; ÖZÇELİK et al., 2010; BINOTI et al., 2014), altura (BINOTI et al., 2013a; ÖZÇELİK et al., 2013), afilamento (LEITE et al., 2011), crescimento e produção (CASTRO et al., 2013; BINOTI et al., 2015).

Uma das grandes vantagens do uso de RNA, é que elas possibilitam a utilização de variáveis dendrométricas, edáficas, climáticas, regiões, entre outras (HAYKIN, 2001; BINOTI, 2010).

Desse modo, pesquisas sobre redes neurais artificiais são de grande utilidade no meio florestal, visto que a técnica apresenta bons resultados em diversos ramos das ciências. Assim, o objetivo deste trabalho foi avaliar a modelagem por regressão não linear e por redes neurais artificiais para a predição da altura de árvores de eucalipto em povoamentos situados na região sudeste de Mato Grosso.

2 Material e métodos

2.1 Localização e descrição do experimento

Os dados do estudo provêm de um inventário florestal realizado em povoamentos de eucalipto localizado em três fazendas (I, II e III) no município de Itiquira, região sudeste de Mato Grosso. De acordo com a classificação climática de Köppen a região possui clima tropical do tipo Aw (tropical com estação seca). A altitude varia de 200 a 300 m, a

precipitação média entre 1600 e 1900 mm e a temperatura média varia entre 22 a 24 °C (ALVARES et al., 2013).

Os povoamentos foram implantados em 2009 em espaçamento de 3x3 m. Os dados foram obtidos de 23 parcelas medidas aos quatro anos de idade, sendo que os povoamentos das fazendas I e III são provenientes de material clonal e da fazenda II é de origem seminal.

As parcelas foram distribuídas de maneira aleatória, com uma intensidade de amostral de aproximadamente, uma parcela a cada três hectares. As parcelas foram circulares, com área de 400 m², sendo medidos os diâmetros a 1,3 m de altura com casca (DAP) e a altura total (Ht) de todas as árvores da parcela. As principais características das variáveis dendrométricas dos povoamentos estão apresentadas na Tabela 1.

Tabela 1 - Estatística descritiva do diâmetro a 1,3 m de altura (DAP - cm) e da altura total (Ht - m) dos povoamentos de eucalipto no município de Itiquira, MT

Fazenda	Variáveis	Mínimo	Média	Máximo	Desvio padrão	CV (%)
I	DAP	5,5	13,7	20,0	3,36	24,60
	Ht	10,5	20,3	25,4	3,11	15,28
II	DAP	2,0	14,3	27,9	4,93	34,47
	Ht	4,4	17,9	29,8	4,01	22,42
III	DAP	3,6	12,8	17,6	2,19	17,10
	Ht	8,0	18,7	23,9	2,44	13,03

CV = coeficiente de variação.

Após a obtenção do banco de dados, os mesmos foram divididos em dois conjuntos, um para o ajuste do modelo de regressão e treinamento das redes (70%) e o outro para validação da regressão e das redes treinadas (30%). Segundo Binoti et al. (2015), o procedimento de validação deve ser aplicado para verificar a capacidade de uma rede neural produzir saídas adequadas para entradas que não estavam presentes durante o treinamento.

2.2 Estimativa da altura por regressão

Para gerar as estimativas das alturas por regressão, foi ajustado o modelo não linear de Gompertz (Equação 1). O modelo foi ajustado, utilizando o programa *CurveExpert* versão 1.4 (HYAMS, 1993).

$$Ht = \phi_1 \left[e^{-e^{\phi_2 - \phi_3 DAP}} \right] + \varepsilon \quad (1)$$

em que: Ht = altura total (m); DAP = diâmetro a 1,3 m de altura (cm); ϕ_1 , ϕ_2 e ϕ_3 = parâmetros do modelo; e ε = erro aleatório, sendo $\varepsilon \sim N(0, \sigma^2)$.

Optou-se por este modelo, devido ser considerado simples, popular e de fácil utilização, além de apresentar grande poder explicativo para os mais diversos usos e ramos da ciência. No meio florestal o modelo de Gompertz é amplamente aplicado para descrever o crescimento de diversas variáveis dendrométricas de árvores (LIAO et al., 2003; CALEGARIO et al., 2005; PÓDÓR et al., 2014) e também é utilizado em relações hipsométricas (BATISTA et al., 2001; MORAES NETO et al., 2010; ARAÚJO, 2015).

2.3 Estimativa da altura por redes neurais artificiais

Redes neurais artificiais (RNA) é um sistema computacional paralelo constituído de várias unidades de processamento simples, conectadas entre si, que calculam determinadas funções matemáticas (normalmente não-lineares) (KOVÁCS, 1996; HAYKIN, 2001). Tais unidades são dispostas em uma ou mais camadas e interligadas por um grande número de conexões, geralmente unidirecionais (BRAGA et al., 2000). Na maioria dos modelos estas conexões estão associadas a pesos, os quais armazenam o conhecimento representado no modelo e servem para ponderar a entrada recebida por cada neurônio da rede. O funcionamento destas redes é inspirado em uma estrutura física concebida pela natureza: o cérebro humano (BRAGA et al., 2000; HAYKIN, 2001).

Segundo Haykin (2001), uma RNA pode ser constituída por uma ou mais camadas. Cada camada pode conter um ou mais neurônios (unidades de processamento simples). A camada de entrada só recebe os valores (quantitativos ou qualitativos) das variáveis fornecidas e as transmite para a camada intermediária. A camada intermediária ou oculta e a camada de saída mapeiam o conhecimento, processamento as informações, com seus neurônios também chamados de nós de computação. Um nó de computação k recebe os sinais de entrada (x_i) e pondera-os com pesos (w_{ki}); uma soma é obtida por adição das entradas multiplicado por seus respectivos pesos e adicionando um sinal preconizado (b_k). O resultado dessa soma (v_k) atua através de uma função de ativação [$f(v_k)$] e fornece a saída do neurônio (y_k). Um exemplo de uma rede neural e um neurônio artificial é mostrado na Figura 1.

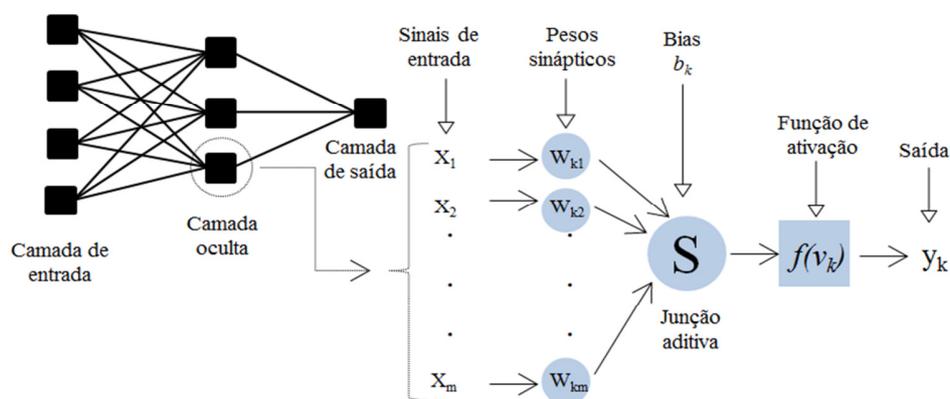


Figura 1 - Estrutura de uma rede neural e um neurônio artificial (adaptado: HAYKIN, 2001).

O treinamento de uma RNA inicia pela apresentação dos dados (variáveis de entrada e saída) a uma arquitetura pré-estabelecida ou não (depende do software). O processo de treinamento inicia com valores aleatórios dos pesos e com base nestes valores a primeira saída é comparada com o respectivo valor real da primeira observação. A diferença entre a saída estimada pela rede e o valor real gera um sinal de erro que calibra o ajuste de pesos iniciando assim um novo ciclo, a fim de aproximar a saída do resultado desejado, ou seja, de minimizar o erro (HAYKIN, 2001).

Matematicamente um modelo básico de neurônio artificial pode ser descrito pela seguinte expressão:

$$y_k = \varphi(v_k), \quad (2)$$

em que: y_k = saída do neurônio artificial; φ = função de ativação; v_k = resultado do combinador linear, assim representado:

$$v_k = \sum_0^m x_m w_m, \quad (3)$$

em que: v_k = combinador linear; x_m é o número de entradas; e w_m é o peso para cada entrada de m .

A estimativa da altura foi realizada de acordo com Binoti (2012), pelo treinamento de redes do tipo *perceptron* de múltiplas camadas, comumente conhecidas como MLP (*Multilayer Perceptron*), que conforme Hornik et al. (1989) possui capacidade universal de aproximação de funções. As variáveis numéricas foram normalizadas linearmente em intervalos de 0 a 1, e as variáveis categóricas passaram por uma transformação chamada de codificação, ou seja, cada variável recebe um código numérico que possibilite o cálculo do neurônio artificial.

Para configuração, treinamento e validação das RNAs, utilizou-se o software *NeuroFlorest* 3.2, que permite a utilização de somente uma camada oculta, mas segundo o “teorema da aproximação universal”, apenas uma camada oculta é suficiente para uma rede MLP realizar a aproximação de qualquer função contínua (CYBENKO, 1989).

Foram treinadas quatro RNAs, com três neurônios na camada de entrada, três na camada oculta e um na camada de saída, formando a seguinte arquitetura: 3-3-1. As entradas numéricas utilizadas foram: diâmetro à altura do peito (DAP); diâmetro máximo (DAP_{max}) e como variável categórica (não numérica) utilizou-se as três fazendas (I, II e III).

No software *NeuroFlorest*, o processo de determinação do número de neurônios na camada oculta é definido pelo usuário, sendo assim, foi considerado que um número excessivo de neurônios pode acarretar a memorização dos dados de treinamento, processo conhecido como *overfitting*. 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; SILVA et al., 2010). Dessa forma, o mais indicado é optar por configurações simples (BINOTI et al., 2014; LEAL et al., 2015).

Foi utilizado o tipo de treinamento *Resilient Propagation* RPROP⁺, com função de ativação sigmoideal na camada oculta e de saída (Equação 4). A escolha dessa função se deu por ser a mais comum na construção de redes neurais artificiais (CORNE et al., 2004; BINOTI, 2010). O algoritmo de treinamento *Resilient Propagation*, descrito por Riedmiller e Braun (1993), representa uma variante do algoritmo *backpropagation* (retropropagação do erro), e tem como vantagem a facilidade de calcular e adquirir aprendizagem sobre determinado problema, pelo fato de seu ajuste de pesos dependerem mais do sinal dos gradientes de erro, além de ser mais eficiente e recomendado para RNAs do tipo *Multilayer Perceptron* (RIEDMILLER; BRAUN, 1993).

$$\varphi(v) = \frac{1}{1 + \exp^{\phi u}} \quad (4)$$

em que: φ = função de ativação sigmoide; ϕ = estimativa do parâmetro que determina inclinação da função sigmoide; u = potencial de ativação da função.

Segundo Braga et al. (2000) existem vários métodos para a determinação do momento em que o treinamento de uma rede neural deve ser encerrado. Estes métodos são chamados de critérios de parada, e os mais utilizados são: 1) encerrar o treinamento após N de ciclos; 2) encerrar o treinamento após o erro quadrático médio ficar abaixo de uma constante α ; 3) encerrar o treinamento quando a porcentagem de classificações corretas estiver acima de uma constante α ; 4) combinação dos métodos anteriores. Deve-se considerar que o número exagerado de ciclos pode levar a rede à perda do poder de generalização (*overfitting*). Também, com pequeno número de ciclos a rede pode não chegar ao seu melhor desempenho (*underfitting*)

Dessa forma, como critério de parada do treinamento das redes, utilizou-se: o número total de ciclos igual a 3.000, ou o erro quadrático médio inferior a 1%, conforme Leal et al. (2015). Portanto, finalizou-se o treinamento quando um dos critérios foi atingido.

2.4 Avaliação das estimativas obtidas por regressão e por redes neurais

A avaliação da precisão das estimativas foi pelas seguintes estatísticas: coeficiente de correlação múltipla entre as alturas observadas e estimadas ($r_{h\hat{h}}$), raiz quadrada do erro médio em percentagem (RQEM%) e a análise gráfica da dispersão dos resíduos (E%), obtidas pelas Equações 5, 6 e 7, respectivamente.

$$r_{h\hat{h}} = \frac{\text{cov}(h, \hat{h})}{\sqrt{S^2(h)S^2(\hat{h})}} \quad (5)$$

$$RQEM\% = \frac{100}{\bar{h}} \sqrt{\frac{\sum_{i=1}^n (h_i - \hat{h}_i)^2}{n}} \quad (6)$$

$$E\% = \left(\frac{h_i - \hat{h}_i}{h_i} \right) 100 \quad (7)$$

em que: cov = covariância; h = altura observada; \hat{h} = altura estimada; S^2 = variância; \bar{h} = média das alturas observadas; n = número de casos.

O $r_{h\hat{h}}$ indica a relação entre a altura observada e a altura estimada. Embora esse indicador estatístico não permita inferir, diretamente, sobre igualdade das unidades entre valores observados e estimados (CAMPOS; LEITE, 2013), a correlação indica o grau de associação entre valores observados e estimados que, em associação com a análise de resíduos, permite inferir sobre a qualidade da estimação. Quanto mais próxima de 1, maior a correlação entre as variáveis (BINOTI et al., 2015).

A RQEM avalia a diferença quadrática média entre os valores observados e os valores estimados (BINOTI et al., 2015). Quanto menor o RQEM, melhor a precisão da

estimativa (MEHTÄTALO et al., 2006), e a análise gráfica dos resíduos consistiu na verificação estatística da dispersão dos erros (E) percentuais em relação aos valores observados e estimados.

O modelo de regressão e as redes foram avaliados quanto à eficiência, por meio do teste t, ao nível de 95% de probabilidade, comparando valores observados e valores estimados no conjunto de validação.

3 Resultados e discussão

Os coeficientes das equações de relação hipsométrica ajustadas para as três fazendas a partir do modelo de Gompertz estão apresentados na Tabela 2. O coeficiente de correlação entre os valores observados e estimados ($r_{h\hat{h}}$) foi de 0,893 para o conjunto de ajuste e 0,887 para a validação. O valor de RQEM obtido no ajuste e na validação foi de 9,46% e 9,57% respectivamente. As estimativas apresentaram valores estimados estatisticamente iguais aos observados pelo teste t, denotando que o modelo empregado é eficiente para estimativa da variável dependente (Ht) em função da variável independente (DAP).

Tabela 2 - Parâmetros e estatísticas de ajuste do modelo de Gompertz empregado para estimativa da altura de árvores de eucalipto no município de Itiquira, MT

Faz.	ϕ_1	ϕ_2	ϕ_3	Ajuste		Validação		Teste t (<i>p-value</i>)
				$r_{h\hat{h}}$	RQEM%	$r_{h\hat{h}}$	RQEM%	
I	25,449	0,8626	0,1833					
II	24,710	0,5612	0,1268	0,893	9,46	0,887	9,57	0,254 ^{ns}
III	26,480	0,6059	0,1316					

Faz. = fazenda; ϕ_1 , ϕ_2 e ϕ_3 = coeficiente de regressão; $r_{h\hat{h}}$ = correlação entre as alturas observadas e estimadas; RQEM% = raiz quadrada do erro médio em percentagem; ^{ns} = não significativo ao nível de 95% de probabilidade.

Por meio da dispersão dos resíduos, foi observado que tanto no ajuste quanto na validação o comportamento da equação foi semelhante, com valores distribuídos adequadamente, porém com uma leve tendência de superestimação para os menores DAPs e subestimação para os maiores DAPs (Figura 2).

Os histogramas de frequência dos erros apresentaram uma distribuição adequada, com as maiores frequência nas classes próximas a -10% e 10% de erro. De acordo com Campos e Leite (2013) a avaliação dos resíduos em forma de histogramas é um tipo de análise interessante, pois quando há um grande número de observações, somente os gráficos de dispersão podem levar ao risco de má interpretação, uma vez que ocorrem diversos pontos sobrepostos no gráfico.

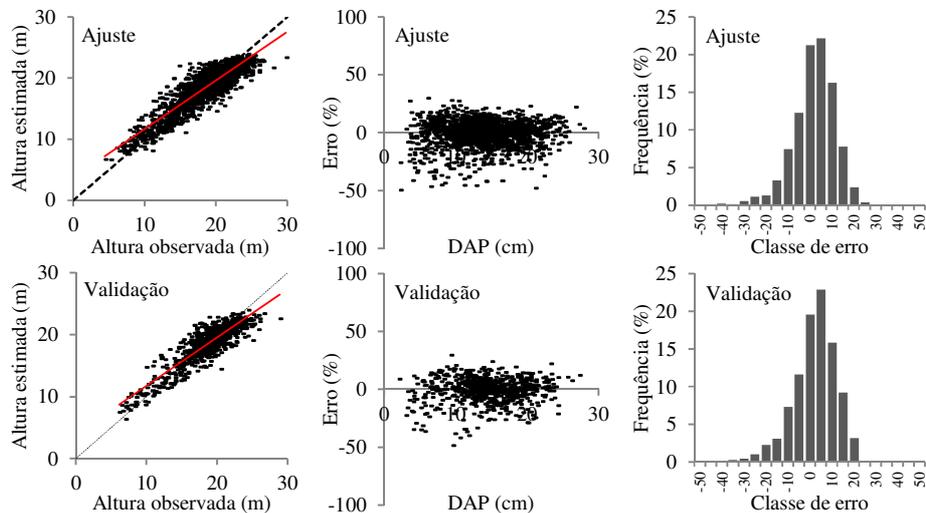


Figura 2 - Altura observada versus estimada, resíduos e histograma de frequência dos erros para as estimativas obtidas pelo modelo de Gompertz.

Resultados semelhantes em que o modelo de Gompertz apresenta estimativas satisfatórias em relações hipsométricas foram obtidos por Moraes Neto et al. (2010), para eucaliptos no Distrito Federal; Vendruscolo et al. (2015) para eucaliptos em Mato Grosso e Araújo (2015) para *Calycophyllum spruceanum* (Benth) no Amapá e Pará. Modelos não lineares apresentam características favoráveis para relações hipsométricas devido a sua fundamentação biológica e maior flexibilidade de ajuste aos dados (BATISTA et al., 2001; HESS et al., 2014).

As quatro redes treinadas apresentaram estatísticas de precisão semelhantes, tanto em correlação quanto em RQEM% no treinamento e na validação (Tabela 3).

Tabela 3 - Estatísticas de precisão das redes neurais artificiais (RNA) treinadas para estimativa da altura de árvores de eucalipto no município de Itiquira, MT

Faz.	RNA	Treino		Validação		Teste t (p-value)
		$r_{h\hat{h}}$	RQEM%	$r_{h\hat{h}}$	RQEM%	
I, II e III	1	0,895	9,34	0,889	9,47	0,244 ^{ns}
	2	0,895	9,37	0,889	9,51	0,260 ^{ns}
	3	0,894	9,38	0,889	9,49	0,229 ^{ns}
	4	0,895	9,35	0,889	9,50	0,296 ^{ns}

Faz. = fazenda; $r_{h\hat{h}}$ = correlação entre as alturas observadas e estimadas; RQEM% = raiz quadrada do erro médio em percentagem; ns = não significativo ao nível de 95% de probabilidade.

Os valores observados e estimados foram estatisticamente iguais pelo teste t, mostrando a precisão das estimativas pelas quatro RNA. Entretanto, a RNA 1 foi

ligeiramente superior no treino em relação as demais com o maior valor de $r_{h\hat{h}}$ (9,34) e menor valor de RQEM (9,34%), além de na validação também apresentar o menor valor de RQEM (9,47%). Assim, para a RNA 1 também foram avaliados os gráficos da altura observada versus estimadas, resíduos e histogramas de frequência de erros (Figura 3).

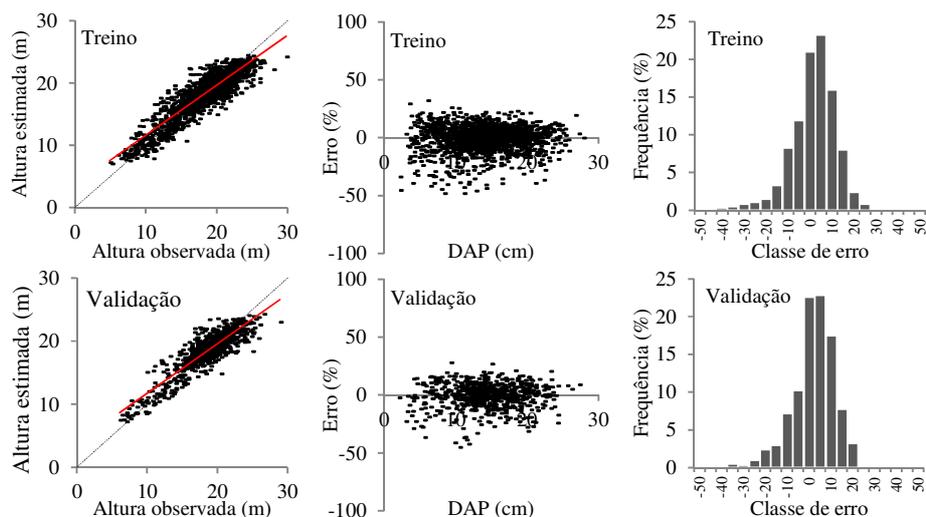


Figura 3 - Altura observada versus estimada, resíduos e histograma de frequência dos erros para estimativas obtidas pela RNA 1.

A RNA1 que obteve as melhores estatísticas de treino e validação, apresentou comportamento semelhante em relação as estimativas obtidas por regressão, diante dos valores observados versus estimados, distribuição dos resíduos em porcentagem e os histogramas de frequência dos erros para o conjunto de ajuste e validação. Assim, as duas técnicas são eficientes para estimação da altura de eucaliptos. No entanto, foi observado que os valores de $r_{h\hat{h}}$ e RQEM%, obtidos pela rede, tanto para o conjunto de treino quanto na validação foram superiores, em relação à regressão, indicando que as RNAs podem oferecer maior precisão. A Tabela 4 apresenta um resumo dos indicadores estatísticos das duas técnicas de modelagem utilizada.

Tabela 4 - Estatísticas de precisão obtidas pelo modelo de Gompertz e pela RNA 1, para estimativa da altura de árvores de eucalipto em Itiquira, MT.

Técnica	Treino		Validação	
	$r_{h\hat{h}}$	RQEM%	$r_{h\hat{h}}$	RQEM%
Gompertz	0,893	9,46	0,887	9,57
RNA 1	0,895	9,34	0,889	9,47

RNA = redes neurais artificiais; $r_{h\hat{h}}$ = correlação entre as alturas observadas e estimadas; RQEM% = raiz quadrada do erro médio em porcentagem; ns = não significativo ao nível de 95% de probabilidade.

Mesmo que as duas técnicas tenham apresentado indicadores estatísticos bastante semelhantes, vale ressaltar que diferentemente do modelo de regressão ajustado por fazenda, para o treinamento das redes não houve estratificação dos dados, sendo esse o grande diferencial das RNAs. A possibilidade de inserção de variáveis categóricas (não numéricas) no ajuste geraram resultados precisos, e sem tendenciosidade.

Binoti et al. (2014) também observou pouca variação entre as estimativas volumétricas para *Eucalyptus* spp. obtidas por RNAs e por regressão, mas apontaram a vantagem das RNAs pelo fato da inclusão de variáveis categóricas. No estudo, os autores ainda mencionam que uma rede pode explicar a variação volumétrica em relação a mais de 50 modelos volumétricos ajustados, visto que a base de dados utilizada era muito ampla, necessitando de estratificação para a aplicação do método convencional de regressão.

Outros estudos como os desenvolvidos por Binoti et al. (2013b) utilizando redes neurais artificiais para estimação da altura de povoamentos equiâneos de eucalipto, e mostram que a técnica foi altamente eficiente para tal problema. Özçelik et al. (2013), utilizando modelos de regressão não linear e redes neurais artificiais, para estimativa da altura de zimbro da Criméia, concluíram que a utilização de redes neurais é uma alternativa eficaz em relação a modelagem por regressão, devido a alta precisão das estimativas. Araújo (2015) avaliando a modelagem por regressão e redes neurais para estimativa da altura de *Calycophyllum spruceanum* afirma que as redes neurais artificiais resultam em estimativas tão precisas quanto os modelos tradicionais de regressão, e destaca a vantagem das RNA devido sua flexibilidade em relação a inserção de mais variáveis explicativas simultaneamente, como a idade do povoamento.

As curvas das alturas observadas e estimadas em função do DAP mostram o comportamento das estimativas obtidas pela regressão e pela RNA 1 (Figura 4). Nota-se a presença de três linhas de ajuste bem definidas, que compreendem as diferentes fazendas (I, II e III). Considerando que não houve estratificação dos dados é notório o potencial da utilização de redes neurais para estimativa da altura de árvores com inserção de variáveis categóricas. Além disso, do ponto de vista operacional, o método permite reduzir muito o tempo gasto com ajustes e avaliações de modelos de regressão principalmente em situações com muitos estratos.

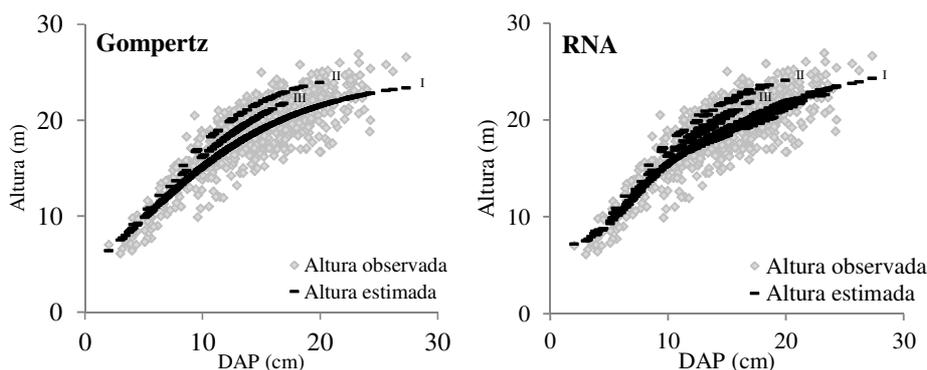


Figura 4 - Curvas hipsométricas obtidas por regressão e por redes neurais para povoamentos de eucalipto em Itiquira, MT.

Outro aspecto importante, porém não avaliado neste estudo, é a possibilidade de redução de custos no inventário florestal com a utilização de redes neurais. A exemplo disso, destaca-se o trabalho de Binoti et al. (2013a), que propuseram, construíram e validaram um modelo para estimar a altura de povoamentos equiâneos de eucalipto, visando redução dos custos do inventário florestal e concluíram que o uso das RNAs foi eficiente e permitiu reduzir o número de medições da variável altura, sem nenhum prejuízo a precisão requerida.

Conclusões

As duas técnicas avaliadas são eficientes para a predição da altura de árvores. No entanto, as RNAs apresentaram critérios estatísticos levemente superiores à modelagem por regressão.

As redes apresentam alto potencial para tal utilização, e uma de suas vantagens é a inserção de variáveis categóricas no treino.

Agradecimentos

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela concessão da bolsa de mestrado.

VENDRUSCOLO, D. G. S.; DRESCHER, R.; SOUZA, H. S.; MOURA, J. P. V. M.; MAMORÉ, F. M. D.; SIQUEIRA, T. A. S. Estimation of eucalyptus height by means of nonlinear regression and artificial neural networks. *Rev. Bras. Biom.*, São Paulo, v.33, n.4, p.556-569, 2015.

- **ABSTRACT:** *In this work was evaluated the nonlinear regression modeling and artificial neural networks to estimate the eucalyptus trees tall. The stands are located in Itiquira, MT. Data were obtained from 23 parcels measured at four years old. The database was divided into two sets, one for the adjustment of regression models and training the networks (70%) and the other to validate the regression and validating the trained networks (30%). The nonlinear regression model was used the Gompertz and the networks of the multilayer perceptron (MLP). The evaluation of the estimates accuracy was by the multiple correlation coefficient between the observed and estimated heights, square root of the average error in percentage and graphical analysis. Both evaluated techniques are effective for predicting the height of trees. However, neural networks statistical criteria showed slightly higher relative to the regression.*
- **KEYWORDS:** *Afforestation; forest inventory; prediction.*

Referências

ALVARES, C. A. et al. Köppen's climate classification map for Brazil. *Meteorologische Zeitschrift*, Stuttgart, v. 22, p. 1–18, 2013.

- ARAÚJO, B. H. P. de. *Modelagem da altura, volume e afilamento do fuste de Calycophyllum spruceanum Benth. empregando regressão e redes neurais artificiais*. 2015. 53f. Dissertação (Mestrado) - Instituto Nacional de Pesquisas da Amazônia, Manaus, 2015.
- BATISTA, J. L. F.; COUTO, H. T. Z.; MARQUESINI, M. Desempenho de modelos de relações hipsométricas: estudo em três tipos de floresta. *Scientia Florestalis*, 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.
- BINOTI, D. H. B. et al. Redução dos custos em inventário de povoamentos equiâneos. *Agrária*, Recife, v.8, p.125-129, 2013a.
- BINOTI, M. L. M. da S. *Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto*. 2010. 54f. Dissertação (Mestrado) Universidade Federal de Viçosa, Viçosa, 2010.
- BINOTI, M. L. M. da 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.
- BINOTI, M. L. M. da S. et al. Prognose em nível de povoamento de clones de eucalipto empregando redes neurais artificiais. *Revista Cerne*, Lavras, v. 21, n. 1, p. 97-105, 2015.
- BINOTI, M. L. M. S. *Emprego de redes neurais artificiais em mensuração e manejo florestal*. 2012. 130f. Tese (Doutorado) - Universidade Federal de Viçosa, Viçosa, 2012.
- 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.
- CALEGARIO, N. et al. Melhoria da qualidade de ajuste de modelos biométricos florestais pelo emprego da teoria dos modelos não lineares generalizados. *Scientia Forestalis*, Piracicaba, n. 69, p. 38-50, 2005.
- CAMPOS, J. C. C.; LEITE, H. G. *Mensuração florestal: perguntas e respostas*. 4.ed. Viçosa: UFV, 2013. 605p.
- CASTRO, R. V. O. et al. Individual Growth Model for Eucalyptus Stands in Brazil Using Artificial Neural Network. *ISRN Forestry*, v. 2013, p. 1-12, 2013.
- CYBENKO, G. V. Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals and Systems*, v. 2, n. 4, p. 303-314, 1989.
- HAYKIN, S. *Redes neurais: princípios e prática*. Porto Alegre: 2001. 900p.
- CORNE, S. A. et al. Predicting forest attributes in southeast Alaska using artificial neural networks. *Forest Science*, v. 50, n. 2, p. 259-276, 2004.
- GORGENS, E. B. et al. Estimação do volume de árvores utilizando redes neurais artificiais. *Revista Árvore*, Viçosa, v. 33, n. 6, p. 1141-1147, 2009.
- HESS, A. F.; BRAS, E. M.; THAINES, F.; MATTOS, P. P. Ajuste de relação hipsométrica para espécies da Floresta Amazônica. *Ambiência*, Guarapuava, v. 10, n. 1, p. 21-29, 2014.

- HORNIK, K.; STINCHCOMBE, M.; WHITE, H. Multilayer feed forward network are universal approximators. *Neural Networks*, Bandera, v. 2, n. 5, p. 359-366, 1989.
- HYAMS, D. *CurvExpert 1.4*. Microsoft Corporation, 1993. Disponível em: <(www.curveexpert.net/curveexpert-basic>. Acesso em 05/2015.
- KOVÁCS, Z. L. *Redes neurais artificiais: fundamentos e aplicações*. 2.ed. São Paulo: Colledium Cognition, 1996. 174p.
- LEAL, F. A. et al. 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*, São Paulo, v. 33, n. 2, p. 233-249, 2015.
- LEITE, H. G. et al. Estimation of inside-bark diameter and heartwood diameter for *Tectonagrandis* Linn. trees using artificial neural networks. *European Journal of Forest Research*, Berlin, v. 130, n. 2, p. 263-269, 2011.
- LIAO, C. Y.; PODRÁZSKÝ, V. V.; LIU, G. B. Diameter and height growth analysis for individual White Pine trees in the area of Kostece nad Černými lesy. *Journal of Forest Science*, v. 49, p. 544-551, 2003.
- MEHTÄTALO, L.; MALTAMO, M.; KANGAS, A. The use of quantile trees in the prediction of the diameter distribution of a stand. *Silva Fennica*, Vantaa, v.40, n.3, p.501-516, 2006.
- MENDONÇA, A. R. et al. Modelos hipsométricos e de crescimento em altura das árvores dominantes e codominantes para *Pinus caribaea* var. *hondurensis*. *Scientia Forestalis*, Piracicaba, v. 39, n. 90, p. 151-160, 2011.
- MENDONÇA, A. R. et al. Modelos hipsométricos generalizados mistos na predição da altura de *Eucalyptus* sp. *Revista Cerne*, Lavras, v. 21, n. 1, p. 107-115, 2015.
- MIRANDA, R. O. V. et al. Estratificação hipsométrica em classes de sítio e de altura total em plantios clonais de eucaliptos. *Advances in Forestry Science*, Cuiabá, v. 1, n. 4, p. 113-119, 2014.
- MORAES NETO, S. P. et al. Modelos hipsométricos para *Eucalyptus cloesiana* e *Eucalyptus urofilia* x *Eucalyptus grandis* em sistema agrosilvipastoril. *Boletim de pesquisa e desenvolvimento*, v. 286, 2010.
- ÖZÇELİK, R. et al. Estimating Crimean juniper tree height using nonlinear regression and artificial neural network models. *Forest Ecology and Management*, Amsterdam, v. 306, p. 52-60, 2013.
- ÖZÇELİK, R. et al. Estimating tree bole volume using artificial neural network models for four species in Turkey. *Journal of Environmental Management*, v. 91, n. 3, p. 742-753, 2010.
- PÖDÖR, Z.; MANNINGER, M.; JEREB, L. Application of Sigmoid Models for Growth Investigations of Forest Trees. *Advanced Computational Methods for Knowledge Engineering*, v. 282, p. 353-364, 2014.
- RIEDMILLER, M.; BRAUN, H. A direct adaptive method for faster back propagation learning: The RPROP algorithm. In: *Neural Networks, 1993., IEEE International Conference on*. IEEE, 1993, p. 586-591.

SILVA, I. N. da; SPATTI, D. H.; FLAUZINO, R. A. *Redes Neurais Artificiais para engenharia e ciências aplicadas*. Artliber, 2010. 397 p.

THOMAS, C. et al. Comparação de equações volumétricas ajustadas com dados de cubagem e análise de tronco. *Ciência Florestal*, Santa Maria, v. 16, n. 3, p. 319-327, 2006.

VENDRUSCOLO, D. G. S. et al. Estratificação hipsométrica em plantios de eucaliptos na região sudeste de Mato Grosso. *Agrarian Academy*, Goiânia, v. 02, n. 03, p. 52-61, 2015.

Recebido em 17.07.2015

Aprovado após revisão em 01.10.2015