



COMPARAÇÃO PREDITIVA DE MODELOS HIPSOMÉTRICOS EM PLANTIO DE EUCALIPTO: EQUAÇÃO DE REGRESSÃO E REDES NEURAS ARTIFICIAIS

Gabriel Fernandes Bueno¹; Emanuel Arnoni Costa²

¹Acadêmico do Curso de Engenharia Florestal, Universidade Federal de Uberlândia, campus Monte Carmelo, MG, Brasil;

²Prof. Dr. do Curso de Engenharia Florestal, Universidade Federal de Uberlândia, campus Monte Carmelo, MG, Brasil;

¹gabrielfbueno@outlook.com; ²emanuelarnonicost@hotmail.com

Recebido em: 15/05/2020 – Aprovado em: 15/06/2020 – Publicado em: 30/06/2020

DOI: 10.18677/EnciBio_2020B58

RESUMO

Para uma melhor gestão dos plantios florestais no país, se faz necessário quantificar variáveis dendrométricas das árvores, essas obtidas durante a execução de inventários florestais. A altura é uma das variáveis mais importantes, devido a sua obtenção demandar tempo e elevado custo, normalmente são amostradas algumas árvores das parcelas, e posteriormente, são ajustados modelos hipsométricos para auxiliar na quantificação volumétrica. Nesse sentido, este estudo buscou comparar as estimativas de modelos hipsométricos desenvolvidos por técnicas de Modelos Lineares Generalizados (MLG) e Redes Neurais Artificiais (RNA) pré-selecionadas em plantio de Eucalipto. Diferentes quantidades de pares de altura-diâmetro (30, 60, 90, 120 e 150) foram testados para verificar a eficiência das técnicas. O ajuste e a precisão das estimativas foram avaliados pela raiz quadrada do erro quadrático médio (RMSE), média do erro absoluto (MAE) e distribuição gráfica dos resíduos. As previsões obtidas por RNA apresentaram melhor capacidade de generalização em amostras maiores que 30. As duas técnicas foram eficazes para prever a altura do plantio de Eucalipto, havendo pequena diferença entre ambas.

PALAVRAS-CHAVE: biometria florestal, inventário florestal, relação hipsométrica.

PREDICTIVE COMPARISON OF HIPSOMETRIC MODELS IN EUCALYPTUS PLANTING: REGRESSION EQUATION AND ARTIFICIAL NEURAL NETWORKS

ABSTRACT

To management of forest plantations in the country, it is necessary quantify dendrometric variable of trees, those obtained during forest inventory execution. The

height is one of most important variables, due your obtention demands time and a high cost, usually some trees are sampled in the plot, and posteriorly, hipsometric models are adjusted to help in volumetric quantification. In this sense, this study sought compare the hipsometric model's estimation developed by Generalized Linear Models (GLMs) technique and pre-selected Artificial Neural Networks (ANNs) in a Eucalyptus planting. Different quantities of height-diameter pairs (30, 60, 90, 120) were tested to verify the efficiency of the technique. The adjust and the precision of the estimates were availed by mean root square error (RMSE), mean of absolute error (MAE) and graphic residue distribution. The predictions obtained by ANN has better described the generalization capacity in samples bigger than 30. The both techniques were effective to predict the Eucalyptus planting height, having a little difference between them.

KEYWORDS: forest biometrics, forest inventory, hipsometric relationship.

INTRODUÇÃO

O território brasileiro possui condições climáticas que favorecem o desenvolvimento das atividades florestais. O setor florestal do país possui uma grande representatividade e importância mundial, sendo evidenciado nas exportações, em 2015, aproximadamente 6,1% eram oriundas de produtos florestais, representando cerca de 3,5% do Produto Interno Bruto do Brasil (CORONEL, 2019).

Na silvicultura, para tomar decisões e estudar a viabilidade econômica do plantio, é necessário o conhecimento do potencial produtivo da área e a quantidade do estoque de madeira disponível, tais informações podem ser obtidas mediante o Inventário Florestal (IF) (BINOTI et al., 2018). No IF, é obtido o volume de madeira, este pode ser estimado por equações que necessitam como variáveis independentes o diâmetro e/ou altura das árvores (SANTOS et al., 2019).

Entretanto, a mensuração da altura de cada árvore demanda muito tempo, o que resulta em um elevado custo na execução do trabalho, além dos possíveis erros de medição associados, potencializados por uma condição climática adversa, como fortes ventos ou pela obstrução da visão do operador, em razão da inclinação do terreno ou sobreposição da copa de outras árvores (SHARMA et al., 2019).

Com o intuito de otimizar o processo e os custos em IF, normalmente é realizado a medição de todos os diâmetros das árvores da parcela e a altura de apenas um grupo de árvores, sendo as demais alturas estimadas por equações hipsométricas (MACPHEE et al., 2018). A relação entre a altura e o diâmetro das árvores é denominada de "Relação Hipsométrica - RH", esta pode ser influenciada pela espécie, idade, sítio, entre outros fatores; esses quando não controlados durante a modelagem podem gerar erros de superestimação ou subestimação das alturas das árvores (KEARSLEY et al., 2017).

Há diversos modelos estatísticos que podem ser usados para descrever a RH de árvores, tais como o de Curtis, Parabólico, Scolforo, entre outros (RIBEIRO et al., 2010). É recomendado durante o ajuste de equações hipsométricas, em casos de assimetria para a variável dependente e que não deseje realizar a sua transformação, o uso de técnicas de Modelos Lineares Generalizados (MLG) (HESS et al., 2015). Os MLG proporcionam um ganho de performance na predição do modelo, uma vez que possui maior flexibilidade na distribuição da variável

dependente (WEBER et al., 2018). Uma outra forma de estimar a altura é utilizando Redes Neurais Artificiais (RNA) (VENDRUSCOLO et al., 2015).

As RNA simulam o sistema nervoso biológico através do acúmulo de conhecimento provindo de estruturas computacionais, sua eficiência e adaptabilidade a torna uma ferramenta importante para análise de dados (TKÁČ; VERNER, 2016). Embora, seja um assunto recente na Ciência Florestal, alguns autores aplicaram RNA para estimativa de volume (ÇATAL; SAPLIOĞLU, 2018; SANQUETTA et al., 2018), densidade básica da madeira (LEITE et al., 2016) e a altura total (MARTINS et al., 2020).

Face o exposto, o objetivo do presente estudo foi comparar as estimativas de modelos hipsométricos, desenvolvido por técnicas de Modelos Lineares Generalizados (MLG) e Redes Neurais Artificiais (RNA) pré-selecionadas em um plantio de Eucalipto.

MATERIAL E MÉTODOS

Caracterização da área

O presente estudo foi conduzido em um talhão com plantio de 84 meses *Eucalyptus saligna* Smith. cujo espaçamento é 3,0 × 2,0 m, situado no município de Rosário do Sul, RS. Segundo a classificação de Köppen, o clima da região é subtropical do tipo Cfa, com altitude de 145,3 m, temperatura média anual de 18,0 °C e precipitação acumulada anual de 1820 mm (ALVARES et al., 2013).

Levantamento dos dados

Para a obtenção de pares de dados de diâmetros e alturas, foi utilizado o hipsômetro Vertex III para mensuração da altura total da árvore (h) e a Suta para a medição do diâmetro à 1,30 m do solo (d). As amostragens foram divididas em grupos de 30, 60, 90, 120 e 150 árvores.

Modelo Linear Generalizado (MLG)

Para descrição da relação hipsométrica utilizou o seguinte MLG ajustado (Equação 1), cuja variável dependente foi avaliada por meio da distribuição Gamma e função de ligação (F.L) do tipo identidade [μ], obtido em pesquisa desenvolvida e a ser publicada pelos autores do presente estudo.

$$h = 43,8180 - 336,8670 \times 1/d \quad (1)$$

Em que: h = altura total, em m; d = diâmetro à altura do peito, em cm. As estatísticas de qualidade de ajuste da equação foram: coeficiente de determinação ($R^2 = 0,37$) e raiz do erro médio quadrático (RMSE = 1,64 m).

Rede Neural Artificial (RNA)

Foi usado uma RNA do tipo *Multilayer Perceptron* (MLP) treinada com a arquitetura: 1-3-1 (Figura 1), obtida no estudo desenvolvido por Bueno et al. (2020). O número de neurônios na camada oculta foi definido através do método de FletcherGloss (SILVA; SPATTI; FLAUZINO, 2010), dado pela expressão 2:

$$2 \times k^{0,5} + N_2 \leq N_1 \leq 2 \times k + 1 \quad (2)$$

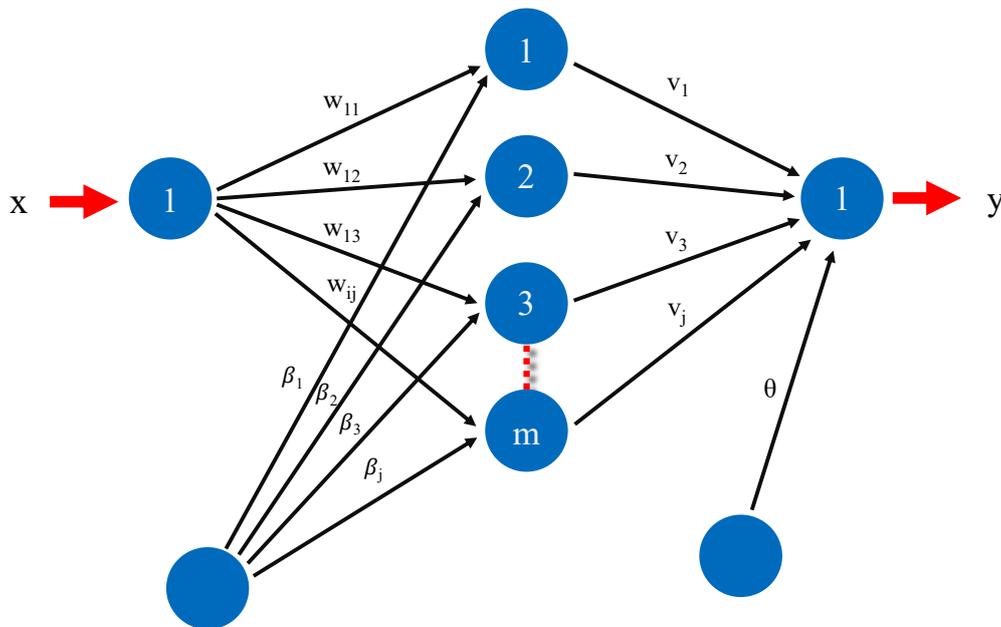
Em que: k : número de entradas de rede; N_1 : o número de neurônios na camada oculta; N_2 : o número de neurônios na camada de saída.

A expressão matemática de saída (3) da MLP é a seguinte:

$$Y = g \left(\theta + \sum_{j=1}^m v_j \left[\sum_{i=1}^n f(w_{ij} X_i + \beta_j) \right] \right) \quad (3)$$

Em que: Y = estimativa do valor da variável dependente; X_i = valor de entrada da i -ésima variável independente; w_{ij} = peso de conexão entre o i -ésimo neurônio de entrada e o j -ésimo neurônio da camada oculta; β_j = valor de desvio do j -ésimo neurônio da camada oculta; v_j = peso de conexão entre o j -ésimo neurônio da camada oculta e o neurônio de saída; θ = valor de desvio do neurônio de saída; $f(\cdot)$ = função de ativação da camada oculta; $g(\cdot)$ = função de ativação da saída.

FIGURA 1. Arquitetura da rede MLP utilizada para descrever a relação hipsométrica das árvores de Eucalipto.



Fonte: Autores

Na camada de entrada (X_i), utilizou a variável diâmetro à altura do peito (d), em cm; e a altura total (h), em m; como camada de saída (Y), em ambas as camadas se aplicou a função de ativação sigmoideal. Os parâmetros da RNA usada são apresentados na Tabela 1.

TABELA 1. Parâmetros da RNA usada para descrever a relação hipsométrica em árvores de Eucalipto.

Tipo	Simbologia	Parâmetros
Pesos	w11	217,91808094
	w12	-0,01318889
	w13	131,62961776
Bias	β_1	-83,46815647
	β_2	0,30172634
	β_3	94,29799189
Pesos de conexão	v1	0,46921149
	v2	-530,87459483
	v3	128,29366567
Erro	θ	175,78292695

Em que: w_{11} , w_{12} , w_{13} = pesos; β_1 , β_2 , β_3 = bias; v_1 , v_2 , v_3 = pesos de conexão; θ = erro. As estatísticas de qualidade do treinamento da rede foram: coeficiente de determinação ($R^2 = 0,63$) e raiz do erro médio quadrático (RMSE = 1,43 m).

Análises estatísticas

As estatísticas de qualidade utilizadas para avaliar a performance da MLG e da RNA para as diferentes amostragens de pares de diâmetro e altura (30, 60, 90, 120 e 150 árvores mensuradas) foram:

i) raiz quadrada do erro quadrático médio (RQEM):

$$RQEM = \sqrt{n^{-1} \sum_{i=1}^n (h_i - \hat{h}_i)^2} \quad (4)$$

ii) média do erro absoluto (MAE)

$$MAE = \frac{1}{N} \sum_{i=1}^n (h_i - \hat{h}_i) \quad (5)$$

Em que: = altura observada, em m; = altura estimada, em m; n = número de observações.

Para caracterizar os dados para diferentes grupos de amostras de pares de diâmetros-alturas foi baseado na estatística descritiva. Com o intuito de testar possíveis diferenças estatísticas entre as técnicas de MLG e RNA que descrevem a relação hipsométrica foi usado o teste t pareado (95% de probabilidade). As análises estatísticas foram realizadas utilizando o software R (R CORE TEAM, 2020).

RESULTADOS

Para avaliar a performance da predição dos MLG e RNA foi usado diferentes amostragens (N), com 30, 60, 90, 120 e 150 pares de dados de diâmetro-altura em árvores de Eucalipto (Tabela 2).

TABELA 2. Estatística descritiva de diferentes amostragens para descrever a relação hipsométrica em árvores de Eucalipto.

Variável	N	Mínimo	Média	Mediana	Moda	Máximo	CV%
d	30	15,8	19,0	19,1	19,3	21,4	6,9
h		21,8	25,8	26,2	24,8	30,0	8,3
d	60	15,8	19,0	19,1	19,3	21,5	6,8
h		19,7	25,7	25,8	24,8	30,0	7,7
d	90	15,8	19,0	19,1	19,3	21,6	6,7
h		19,7	25,7	25,7	25,3	30,0	7,3
d	120	15,8	19,1	19,1	18,6	21,8	6,7
h		19,7	25,8	25,8	25,3	30,1	7,1
d	150	15,8	19,1	19,1	18,6	22,1	6,7
h		19,7	25,7	25,8	25,3	30,1	7,0

Em que: N = tamanho da amostra; CV% = coeficiente de variação.

Os pares de dados apresentam tanto para altura como diâmetro, média, moda e mediana, caracterizando uma distribuição normal dos dados em todas as amostragens.

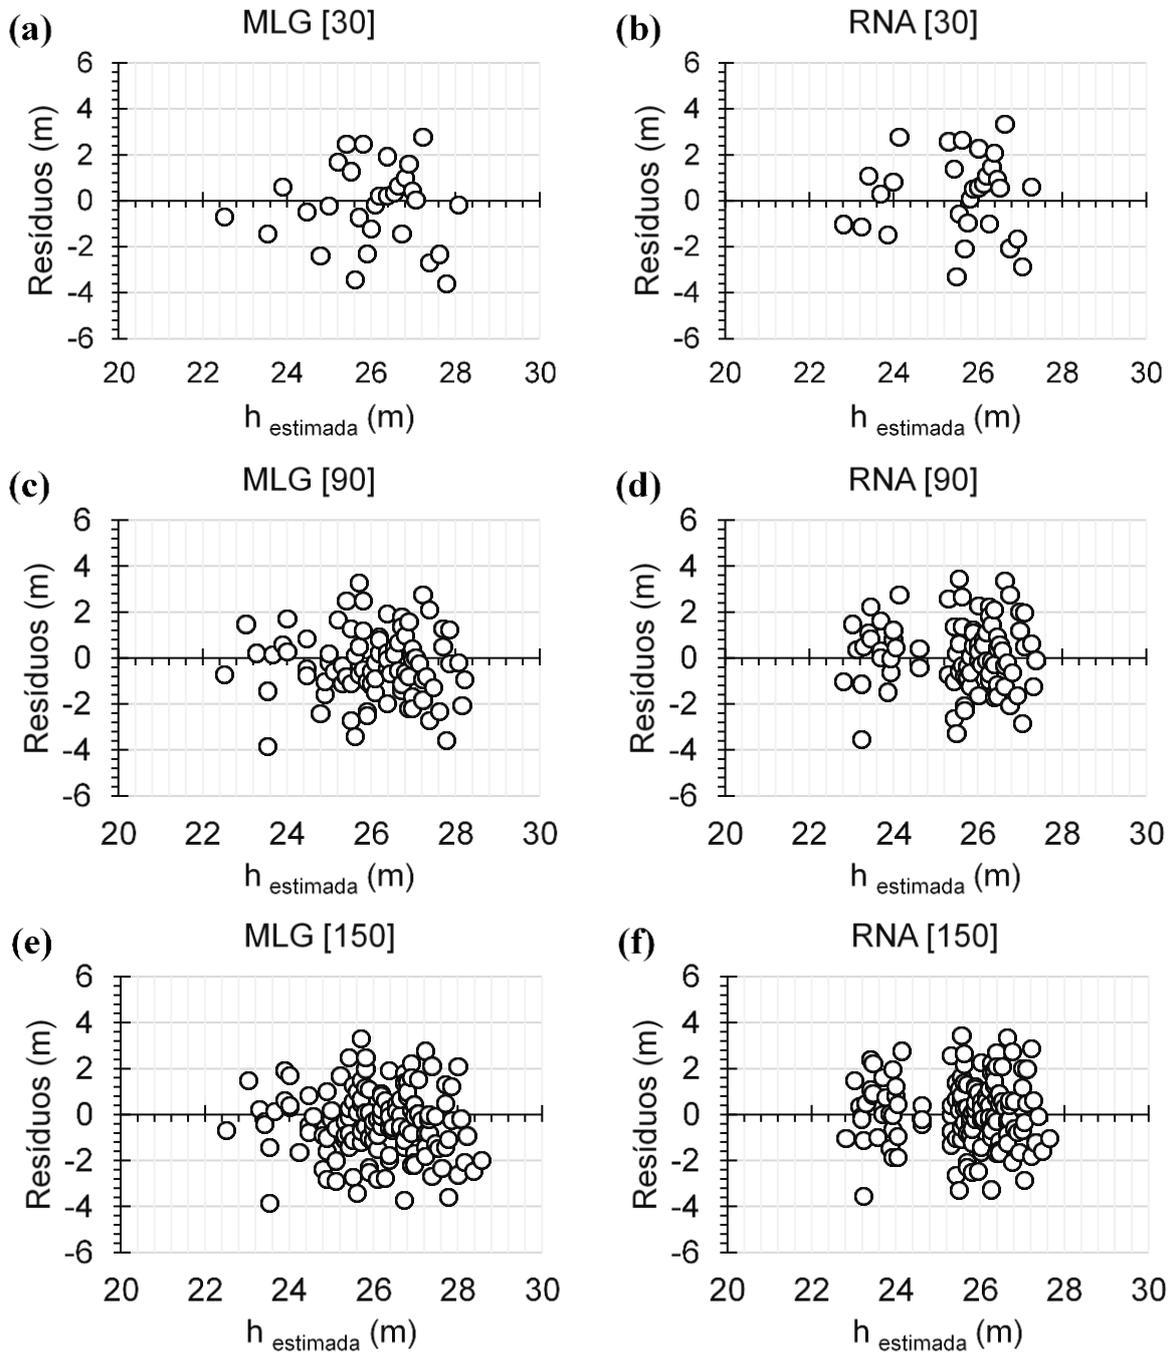
De forma geral, em ambos os tamanhos de amostras (30, 60, 90, 120 e 150) e métodos de predição de altura avaliados (MLG e RNA), observou-se uma tendência maior de erro para amostras menores em relação as maiores segundo as estatísticas de qualidade (Tabela 3).

As amostragens com N = 30 árvores indicaram um RMSE de (1,71 m e 1,73 m) e MAE de (1,37 e 1,47), para predições usando MLG e RNA, respectivamente (Tabela 3). Com N = 120 árvores, o MLG obteve a melhor performance, apresentando RMSE de 1,44 m e MAE 1,15. Usando RNA a amostragem com N = 150 árvores atingiu o melhor desempenho com valor de RMSE de 1,41 m e MAE de 1,11.

Segundo o Teste t, as estimativas da RNA não diferem estatisticamente dos valores observados, visto que suas probabilidades são superiores a significância de 0,05, o mesmo não ocorre com o MLG que para amostragens com 90 e 150 pares de dados, os valores estimados diferem estatisticamente dos valores observados.

Ao avaliar a distribuição gráfica dos resíduos com N = 30 árvores, ambos os métodos (MLG e RNA) apresentaram amplitude de dispersão dos resíduos em torno de $\pm 4,0$ m (Figura 2a e 2b). Com N = 90 árvores houve uma sistematização maior da dispersão dos resíduos (Figura 2c e 2d), sendo com N = 150 árvores, as RNA obteve levemente uma menor dispersão dos mesmos (entre 22,0 à 28,0 m) para a $h_{estimada}$ no eixo das abcissas e maior porção de resíduos situados próximos ao valor de zero no eixo das ordenadas (Figura 2e e 2f).

FIGURA 2. Distribuição gráfica dos resíduos em função a altura estimada para diferentes amostragens (30, 90 e 150) usando técnicas de MLG e RNA em árvores de Eucalipto.



Fonte: Autores.

TABELA 3. Estatística de qualidade para a comparação da predição de altura usando técnicas de MLG e RNA em árvores de Eucalipto.

N	Tipo	RMSE (m)	MAE	Teste t [p-valor]
30	MLG [Gamma; F.L. = identidade]	1,71	1,37	0,5815
60		1,59	1,27	0,1471
90		1,47	1,17	0,0488
120		1,44	1,15	0,0425
150		1,46	1,16	0,0034
30	RNA ₂₂	1,73	1,47	0,3998
60		1,58	1,31	0,4661
90		1,46	1,16	0,3298
120		1,43	1,14	0,1318
150		1,41	1,11	0,3062

Em que: N = tamanho da amostra.

DISCUSSÃO

Pode-se evidenciar pelo Teste t, que para o MLG as amostras superiores ou iguais a 90 pares de dados tiveram as estimativas e os valores observados diferentes estatisticamente, já na RNA para todas as amostragens os valores estimados e observados foram estatisticamente iguais. Observa-se que conforme o aumento da amostragem na RNA e MLG resulta em uma melhor performance, verificado segundo os critérios estatísticos RMSE (m) e MAE e principalmente a menor amostragem com apenas 30 pares de dados obteve um desempenho inferior. Desta maneira nas condições do presente estudo uma amostragem maior tende a resultar em uma melhor performance para o MLG e RNA (Tabela 3).

O método de predição de altura utilizando o modelo linear generalizado foi satisfatório segundo as análises estatísticas de qualidade RMSE (m) e MAE. Embora os dados do presente estudo possuem uma distribuição normal, para estudo de dados que não possuem uma distribuição normal, potencializa o uso do MLG como evidenciado o estudo de Hess et al. (2015), desta maneira não havendo a necessidade de um conjunto de dados maior ao contrário de quando é utilizado modelos lineares tradicionais.

A rede neural artificial obteve uma boa performance para predição da altura, evidenciado pelas estatísticas de qualidade, fazendo com que tal método seja apto para tal finalidade, assim como nos trabalhos que utilizaram RNA, como o de Martins et al. (2020) para predição da altura de eucalipto, Vieira et al. (2018) prognose da altura e diâmetro de eucalipto e Santos et al. (2018) para estimação da altura de eucalipto, em ambos as RNA tiveram um boa performance. Assim como o MLG, a RNA obteve uma performance eficiente para predição da altura quando utilizado um menor conjunto de dados.

Ambos métodos, RNA e o MLG obtiveram uma performance satisfatória na predição da altura, entretanto, a RNA conforme apresentado nos critérios estatísticos apresentou uma leve superioridade em relação a MLG, principalmente em maiores amostragem.

Destaca-se que além capacidade de generalização da RNA, visto que, houve uma boa performance na predição para dados externos, pode-se utilizar variáveis qualitativas na camada de entrada, que embora não utilizado no presente estudo, tal funcionalidade pode agregar uma vantagem ainda superior na predição quando comparado a algum outro método, como no estudo de Vendrusculo et al. (2015), onde foi utilizado a variável local de plantio, obtendo resultados satisfatórios com a inserção desta variável qualitativa na RNA.

Em ambos os métodos de estimação de altura RNA e MLG (Figura 2), com 30 árvores na amostragem houve maior dispersão dos resíduos, havendo um declínio com o aumento da amostragem, com 90 e 150 indivíduos, destacando a superioridade de performance na predição quando se utiliza uma amostragem maior nas condições do presente estudo.

CONCLUSÕES

O MLG e a RNA são técnicas mais flexíveis a serem empregadas na predição da altura de árvores de Eucalipto. Em amostragens maiores a RNA e o MLG obtiveram melhor performance na estimativa da altura quando comparado a menores amostragens. Segundo os critérios estatísticos de qualidade utilizados a RNA obteve performance levemente superior em relação ao MLG.

REFERÊNCIAS

ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; GONÇALVES, J. L. M.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2013. Disponível em: <<http://dx.doi.org/10.1127/0941-2948/2013/0507>>. doi:10.1127/0941-2948/2013/0507

BINOTI, D. H. B.; DUARTE, P. J.; SILVA, M. L. M.; SILVA, G. F.; LEITE, H. G. et al. Estimation of height of eucalyptus trees with neuroevolution of augmenting topologies (Neat). **Revista Árvore**, v. 41, n. 3, 2018. Disponível em: <<http://dx.doi.org/10.1590/1806-90882017000300014>>. doi:10.1590/180690882017000300014

BUENO G. F.; COSTA, E. A.; CRISTINA, A. N.; SOARES, A. A. V.; MIRANDA, R. O. V. et al. Efeito do número de neurônios na camada oculta para relações hipsométricas de eucalipto usando redes neurais artificiais. **BIOFIX Scientific Journal**. v. 5, n. 2, p. 222230, 2020. Disponível em: <http://dx.doi.org/10.5380/biofix.v5i2.71374>. doi:10.5380/biofix.v5i2.71374

ÇATAL, Y.; SAPLIOĞLU, K. Comparison of adaptive neuro-fuzzy inference system, artificial neural networks and non-linear regression for bark volume estimation in brutian pine (*Pinus brutia* ten.). **Applied Ecology and Environmental Research**, v. 16, n. 2, p. 2015–2027, 2018. Disponível em: <http://dx.doi.org/10.15666/aeer/1602_20152027>. doi:10.15666/aeer/1602_20152027

CORONEL, D. A. Padrão de especialização do comércio internacional do setor florestal brasileiro (1999 – 2015). **Revista UNEMAT de Contabilidade**, v.8, n.15, p. 72–89, 2019. Disponível em: <<http://dx.doi.org/10.30681/ruc.v8i15.3294>>. doi:10.30681/ruc.v8i15.3294

HESS, A. F.; CIANORSCHI, L.; SILVESTRE, R.; SCARIOT, R.; RICKEN, P. Aplicação dos modelos lineares generalizados para estimativa do crescimento em altura. **Pesquisa Florestal Brasileira**, v. 35, n. 84, p. 427, 2015. Disponível em: <<http://dx.doi.org/10.4336/2015.pfb.35.84.604>>. doi:10.4336/2015.pfb.35.84.604

KEARSLEY, E.; MOONEN, P. C.; HUFKENS, K.; DOETTERL, S.; LISINGO, J. et al. Model performance of tree height-diameter relationships in the central Congo Basin. **Annals of Forest Science**, v. 74, n. 1, 2017. Disponível em: <<http://dx.doi.org/10.1007/s13595-016-0611-0>>. doi:10.1007/s13595-016-0611-0

LEITE, H. G.; BINOTI, D. H. B.; OLIVEIRA NETO, R. R.; LOPES, P. F.; CASTRO, R. R. et al. Redes Neurais artificiais para a estimação da densidade básica da madeira. **Scientia Forestalis/Forest Sciences**, v. 44, n. 109, p. 149–154, 2016. Disponível em: <<http://dx.doi.org/10.18671/scifor.v44n109.14>>. doi:10.18671/scifor.v44n109.14

MACPHEE, C.; KERSHAW, J. A.; WEISKITTEL, A. R.; GOLDING, J.; LAVIGNE, M. B. Comparison of approaches for estimating individual tree height-diameter relationships in the Acadian forest region. **Forestry**, v. 91, n. 1, p. 132–146, 2018. Disponível em: <<http://dx.doi.org/10.1093/forestry/cpx039>>. doi:10.1093/forestry/cpx039

MARTINS, M. T.; MARANGON, G. P.; COSTA, E. A.; SILVEIRA, B. D.; CUBAS, R. et al. Estimação da altura de plantios florestais de eucalipto por regressão e redes neurais artificiais. **BIOFIX Scientific Journal**, v.5, n.1, p. 141–152, 2020. Disponível em: <<http://dx.doi.org/10.5380/biofix.v5i1.68839>>. doi:10.5380/biofix.v5i1.68839

R CORE TEAM. R: A language and environment for statistical computing. **R Foundation for Statistical Computing**. Vienna, 2020. Disponível em: <https://www.Rproject.org/>

RIBEIRO, A.; FILHO, A. C. F.; MELLO, J. M.; FERREIRA, M. Z.; LISBOA, P. M. M. et al. Estratégias e metodologias de ajuste de modelos hipsométricos em plantios de *Eucalyptus* sp. **Cerne**, v. 16, n. 1, p. 22–31, 2010. Disponível em: <<http://dx.doi.org/10.1590/s0104-77602010000100003>>. doi:10.1590/s010477602010000100003

SANQUETTA, C. R.; PIVA, L. R. O.; WOJCIECHOWSKI, J.; CORTE, A. P. D.; SCHIKOWSKI, A. B. Volume estimation of *Cryptomeria japonica* logs in southern Brazil using artificial intelligence models. **Southern Forests**, v. 80, n. 1, p. 29–36, 2018. Disponível em: <<http://dx.doi.org/10.2989/20702620.2016.1263013>>. doi:10.2989/20702620.2016.1263013

SANTOS, A. C. A.; ALMEIDA, F. M.; SOUZA, R. B.; CHAVES, R.; PAIVA, H. N. et al. Estimation of Eucalyptus Tree Height in Clonal and Progeny Tests Using Artificial Neural Networks. **Revista Árvore**, v. 41, n. 6, 2018. Disponível em: <<http://dx.doi.org/10.1590/1806-90882017000600002>>. doi:10.1590/1806-90882017000600002

SANTOS, M. L.; RODRIGUES, R. P.; LIMA, M. D. R.; MARTINS, W. B. R.; COSTA, B. C. et al. Hypsometric models for a clonal plantation of *Tectona grandis* Linn F. subjected to selective thinning. **Revista Agro@Mambiente on-Line**, v. 13, p. 35, 2019. Disponível em: <<http://dx.doi.org/10.18227/1982-8470ragro.v13i0.5292>>. doi:10.18227/1982-8470ragro.v13i0.5292

SHARMA, R. P.; VACEK, Z.; VACEK, S.; KUČERA, M. Modelling individual tree height– diameter relationships for multi-layered and multi-species forests in central Europe. **Trees Structure and Function**, v. 33, n. 1, p. 103–119, 2019. Disponível em: <<http://dx.doi.org/10.1007/s00468-018-1762-4>>. doi:10.1007/s00468-018-1762-4

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais: Para Engenharia e Ciências Aplicadas**. São Paulo: ARTLIBER, 2010.

TKÁČ, M.; VERNER, R. Artificial neural networks in business: Two decades of research. **Applied Soft Computing Journal**, v. 38, p. 788–804, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.asoc.2015.09.040>>. doi:10.1016/j.asoc.2015.09.040

VENDRUSCOLO, D. G. S.; DRESCHER, R.; SOUZA, H. S.; MOURA, J. V. P. M.; MAMORÉ, F. M. D. et al. Estimativa da altura de eucalipto por meio de regressão não linear e redes neurais artificiais. **Revista Brasileira de Biometria**, v. 33, n. 4, p. 556– 569, 2015. Disponível em: <<http://dx.doi.org/10.13140/RG.2.1.1742.5684>>. doi:10.13140/RG.2.1.1742.5684

VIEIRA, G. C.; MENDONÇA, A. R.; SILVA, G. F.; ZANETTI, S. S.; SILVA, M. M. et al. Prognoses of diameter and height of trees of eucalyptus using artificial intelligence. **Science of the Total Environment**, v. 619–620, p. 1473–1481, 2018. Disponível em: <<http://dx.doi.org/10.1016/j.scitotenv.2017.11.138>>. doi:10.1016/j.scitotenv.2017.11.138

WEBER, V. P.; FINGER, C. A. G.; COSTA, E. A.; LORA, A. P.; LONGHI, R. V. Modelagem linear generalizada para descrever o incremento em área transversal de árvores individuais de imbuia. **Floresta**, v. 48, n.1, p. 123–132, 2018. Disponível em: <<http://dx.doi.org/10.5380/ufv.v48i1.54368>>. doi:10.5380/ufv.v48i1.54368