

ALGORITMOS DE MACHINE LEARNING PROMOVEM REDUÇÃO DE CUSTOS OPERACIONAIS EM EXPERIMENTOS FLORESTAIS

**Gustavo Alves de Melo, Helen Vitaline Santos, Thiago Henrique Nogueira,
Maria Luiza Alves Santana**

Universidade Federal de Viçosa, Campus Rio Paranaíba (UFV-CRP)
Rodovia BR 230 KM 7, Rio Paranaíba - MG, 38810-000

gustavo.a.melo@ufv.br, helen.castro@ufv.br, thiagoh.nogueira@ufv.br, maria.santana1@ufv.br

Maria Gabriela Mendonça Peixoto, Marcelo Carneiro Gonçalves

Universidade Federal de Brasília (UnB)
Brasília, DF, 70910-900

mgabriela.unb@gmail.com, marcelo.goncalves@unb.br

RESUMO

Este estudo aplicou redes neurais artificiais para estimar alturas de árvores em experimentos com clones e espaçamentos de plantio comercial, buscando substituir medições completas e reduzir custos. O experimento incluiu 84 parcelas com 2.677 árvores, cujos dados de altura e circunferência à altura do peito foram coletados. Simulações reduziram amostras em cerca de 10% por vez, até alcançar 14,5% das alturas medidas, com o restante estimado por RNA. As árvores foram estratificadas por classes de diâmetro à altura do peito, exigindo ao menos uma altura observada por classe em cada parcela. As variáveis utilizadas incluíram material genético, DAP, DAP médio e máximo, Dg, altura média da parcela e área por planta. Os resultados demonstraram que mais de 97% dos desvios ficaram entre -10% e 10%, validando a precisão do método. Além disso, observou-se uma redução de até 40% no custo operacional com a adoção das estimativas via RNA.

PALAVRAS CHAVE. Silvicultura, Eucalipto, Inteligência Artificial, Machine Learning, Redes Neurais Artificiais.

Tópicos: IA- PO e IA, OA – Outras Aplicações em PO.

ABSTRACT

This study applied artificial neural networks to estimate tree heights in experiments with clones and commercial planting spacings, seeking to replace complete measurements and reduce costs. The experiment included 84 plots with 2,677 trees, whose height and circumference data at breast height were collected. Simulations reduced samples by approximately 10% at a time, until reaching 14.5% of the measured heights, with the remainder estimated by ANN. Trees were stratified by diameter classes at breast height, requiring at least one observed height per class in each plot. The variables used included genetic material, DBH, average and maximum DBH, Dg, average plot height, and area per plant. The results demonstrated that more than 97% of the deviations were between -10% and 10%, validating the accuracy of the method. In addition, a reduction of up to 40% in operational costs was observed with the adoption of ANN estimates.

KEYWORDS. Forestry. Eucalyptus. Artificial Intelligence. Machine Learning. Artificial Neural Networks.

Topics: IA- PO and IA. OA – Other Applications in PO.

1. Introdução

Os plantios florestais para fins industriais têm sido amplamente difundidos no país desde a década de 60 quando iniciaram os incentivos fiscais para culturas como pinus e eucalipto. Atualmente o setor responde por 1,0% do PIB nacional, sendo os estados de Minas Gerais, São Paulo e Mato Grosso do Sul responsáveis por 60,8% do maciço florestal de eucalipto - espécie de maior cultivo - do país [Ibá 2021]. As condições climáticas do Brasil são responsáveis pelo potencial produtivo da silvicultura no país. Mas a evolução de produtividade alcançada é decorrente da geração de novos clones, tecnologias e melhorias operacionais desenvolvidas desde 1970 [Lafetá 2012, Miranda et al. 2022].

A silvicultura promove o avanço da economia sustentável no país, através do manejo adequado de florestas e conservação dos recursos naturais [Skudnik e Jevšenak 2022]. Essa relação com o ambiente é essencial para a manutenção da biodiversidade, da qualidade do solo e regularidade do ciclo hidrológico [Gollob et al. 2018]. A captura de carbono também é viabilizada pelo setor, estabelecendo conexões entre países e uma política de baixo impacto ambiental. A realização de plantios florestais é uma prática atual e necessária para a manutenção do combate a mudanças climáticas no mundo [Ogana e Gorgoso-Varela 2020].

A integração de tecnologias digitais em plantios florestais é uma prática que pode acarretar a maior eficiência e redução de custos no setor [Özçelik et al. 2018; Miranda et al. 2022]. Plataformas digitais podem, por exemplo, centralizar informações e fornecer insights em tempo real para gestores sobre o inventário florestal, colheita e transporte. Satélites podem auxiliar no monitoramento on-time de florestas para prevenção e controle de áreas afetadas por incêndios e desmatamentos [Skudnik e Jevšenak 2022]. Nesse sentido, Redes Neurais Artificiais (RNAs) podem ser utilizadas no campo da visão computacional para reconhecimento de imagens em crimes ambientais, bem como na predição de custos e outros indicadores florestais [Ogana e Gorgoso-Varela 2020].

Anteriormente à implementação de novas técnicas de manejo em uma cultura florestal, são realizados testes alternativos com o intuito de identificar aquele com melhor retorno biológico, agrônômico e econômico [Duarte 1996]. E para mensuração dos resultados dos testes, são realizados os inventários florestais onde são mensurados a circunferência à altura do peito (CAP) e altura total das árvores (Ht), podendo ser realizado de forma amostral (parcelas amostrais) ou em forma de censo.

Em um inventário florestal, normalmente são medidos os CAPs de todas as árvores de dentro da parcela e altura de alguns indivíduos. As demais alturas são estimadas por modelos hipsométricos que correlacionam o diâmetro e altura. As equações resultantes são aplicadas às demais árvores [Campos e Leite 2013]. Técnica alternativa à modelagem hipsométrica é a utilização de redes neurais artificiais para estimação das alturas não mensuradas nas parcelas e redução de coleta dessa variável [Binoti et al. 2012]. As redes neurais artificiais têm apresentado desempenho superior aos modelos de regressão, pois são capazes de generalizar o conhecimento assimilado por um conjunto de dados apresentados. As redes neurais artificiais podem ser aplicadas a outro conjunto de dados desconhecido [Gorgens et al. 2009], face às suas próprias características de tolerância a falhas e ruídos, adaptabilidade dos pesos das conexões às modificações do ambiente, analogia neurobiológica, resolução de problemas complexos e habilidade de aprendizagem [Binoti et al. 2010; Binoti 2010].

Trabalhos correlatos demonstram excelentes resultados alcançados através da utilização de RNAs em estimativas florestais, tais como estimativas de altura total [Binoti et al. 2013a; Binoti et al. 2013b; Özçelik et al. 2013], volume [Gorgens et al. 2009; Diamantopoulou e Milios 2010; Özçelik et al. 2010; Binoti et al. 2014], prognose da produção [Binoti 2010; Martins et al. 2015], estimação da eficiência nutricional de folhas de eucalipto [Lafetá 2012] e crescimento e a produção [Alcântara 2015], entre outras aplicações.

Tendo em vista a acurácia das estimativas e redução dessas medições em parcelas de inventário florestal, empresas do segmento florestal vêm utilizando técnicas de redes neurais artificiais para estimar as alturas das árvores. Mas em experimentos de pesquisa ainda é usual que

se colem as alturas de todos os indivíduos inseridos nos tratamentos, fator esse que apresenta elevados custos tanto financeiros quanto de tempo nas medições. Buscando a redução dessas medições os estudos de Santos (2017), Miranda et al. (2022), and Skudnik e Jevšenak (2022) apresentaram boa acurácia na utilização de modelos de machine learning para estimar as alturas de árvores em experimentos florestais. No entanto, são estudos que se dedicam a comparação metodológica e não avançam suas discussões na perspectiva da análise de viabilidade econômica e avaliação dos custos de oportunidade.

Sendo assim, este estudo tem como objetivo testar a aplicabilidade das redes neurais artificiais na estimação da altura em experimentos de florestas de eucalipto. Este estudo apresenta implicações como a redução da quantidade de alturas mensuradas em campo, mantendo a acurácia e precisão das estimativas. Também contribui para a redução do tempo e custos relativos à medição de 100% das alturas em parcelas experimentais. Na seção de discussão, este estudo apresenta a validação para a redução de custos do experimento florestal em questão.

2. Método

2.1. Dados

Os dados utilizados neste estudo foram provenientes de medições de inventários florestais, conduzidos em povoamentos clonais de eucalipto, localizados no município de Aparecida do Taboado, região leste do Estado do Mato Grosso do Sul, Brasil. O talhão no qual foi conduzido o experimento possui 7,94 ha, seu plantio foi realizado em novembro de 2019 e está inserido em uma fazenda com cerca de 980 ha de plantio de eucalipto, pertencente a uma empresa do seguimento florestal.

O experimento em questão foi instalado no objetivo de testar o comportamento de diferentes clones em modais diferentes de espaçamentos. O experimento foi instalado no delineamento de blocos casualizados seguindo o arranjo fatorial 4 clones x 6 espaçamentos, com 3 repetições por tratamento. No total foram instaladas 84 parcelas, sendo cada uma composta por cerca de 36 covas das quais foram medidos a circunferência a altura do peito de todas as plantas e altura total das plantas vivas que não estivessem inclinadas. Sendo A, B, C e D os diferentes materiais genéticos testados.

As variáveis independentes e dependente utilizadas neste estudo foram listadas na Tabela 1.

Table 1 – Independent and dependent variables of the model.

Indicator	Unit	Classification	Description
Mgen	Categoric	Input	Genetic material
CAP	Numeric	Input	Circumference at breast height
DAP	Numeric	Input	Diameter at breast height
DAPmed	Numeric	Input	Diameter at average breast height
DAPmax	Numeric	Input	Diameter at maximum breast height
Dg	Numeric	Input	Root mean square diameter
Area	Numeric	Input	Area per plant
Ht	Numeric	Output	Average plot height

Source: Authors (2025).

As RNAs treinadas foram do tipo perceptron de múltiplas camadas (MPL), em que as duas camadas (intermediário e saída) são ponderadas por pesos sinápticos e processam dados, apenas a camada de entrada recebe dados (Haykin, 2001).

Foram utilizadas variáveis categóricas e quantitativas como parâmetros de entrada:

- Categórica: Material Genético.
- Quantitativas: DAP, DAP médio e máximo da parcela, diâmetro quadrático médio (Dg), Altura média da parcela, Área por planta.

O DAP foi obtido por:

$$DAP = \frac{CAP}{\pi} \quad (1)$$

onde, CAP é a circunferência a altura do peito (1,3 metros).

O Dg foi obtido por:

$$Dg = \sqrt{\frac{\sum DAP^2}{n}} \quad (2)$$

onde, n é o número de amostras.

2.2. Redes Neurais Artificiais

Para treinamento das redes foi utilizado o software Neuro4, o algoritmo Resilient Propagation [RPROP+] para todas as predições, função de ativação sigmoideal e 3.000 ciclos ou erro médio de 0,0001 como parâmetro do critério de parada. Esses parâmetros foram testados e definidos com base em trabalhos anteriores da estimativa da altura das árvores de eucalipto em parcelas de inventário florestal [Silva 2012].

Foram treinadas 5 redes e a seleção da melhor foi realizada com base nos seguintes critérios: coeficiente de correlação entre as alturas observadas e estimadas, dispersão de resíduos, frequência de erros percentuais e resíduo quadrado médio do erro.

O coeficiente de correlação foi obtido por:

$$r = \frac{cov(Hi \times Hoi)}{\sqrt{s^2(Hi) \times s^2(Hoi)}} \quad (3)$$

onde s² – variância; cov – covariância; Hi - é a altura observada na i-ésima observação e Hoi - é a altura estimada pela RNA na i-ésima observação.

O Resíduo Quadrático Médio do Erro foi obtido por:

$$RQME = \sqrt{\frac{\sum_{i=1}^n (Hi - Hoi)^2}{n}} \quad (4)$$

onde Hi - é a altura observada na i-ésima observação, Hoi - é a altura estimada pela RNA na i-ésima observação e n é o número total de observações.

A simulação da redução de amostras foi realizada por parcela. Os dados utilizados para treinamento e generalização foram somente de árvores normais do plantio. Árvores classificadas com injúrias, bifurcadas, mortas, quebradas, não foram consideradas para a estimativa das alturas, pois o crescimento delas pode ser comprometido por essas situações adversas as quais essas árvores foram submetidas.

Além disso, os dados foram distribuídos em classes diamétricas de 3 cm, de forma que cada parcela continha pelo menos uma amostra observada por classe de diâmetro para estimativa das demais. A redução das amostras observadas se deu de forma gradativa com decréscimo de cerca de 10% por simulação e a escolha das amostras de treinamento seguiu o sentido de caminamento de medição dentro da parcela respeitando a classe diamétrica e número mínimo de planta/classe.

Por meio da Tabela 2 é possível observar a quantidade de alturas observadas utilizadas para treinamento das RNAs para a estimativa das demais, distribuídas nas respectivas classes diamétricas.

Table 2. Distribution of the number of heights used by the proposed sample reduction across the diameter classes.

DAP class (cm)	100% heights	91.1% heights	80.6% heights	70.5% heights	60.8% heights	52.7% heights	41.4% heights	32.6% heights	22.9% heights	14.5% heights
<3	4	4	4	4	4	4	4	4	4	4
3-6	49	49	44	38	38	38	33	33	33	33
6-9	131	128	115	90	83	80	69	64	59	59
9-12	904	822	722	639	543	469	364	281	185	107
12-15	1.544	1.392	1.233	1.085	930	791	614	467	311	163
15-18	45	45	39	32	30	30	24	24	22	22
Total	2.677	2.440	2.157	1.888	1.628	1.412	1.108	873	614	388

Source: Authors (2025).

3. Resultados

As características das redes selecionadas para cada redução amostral proposta no trabalho podem ser observadas por meio da Tabela 3 que apresentam os percentuais de dados utilizados para treinamento e validação em cada simulação, as bias (desvio do valor real), RQME, a variância e a correlação (%).

Tabela 3. Estatísticas descritivas das redes selecionadas

RNNs	Data type	% Data	Output	Bias	RQME	Variance	Correlation
RNA 3	Training	91.1%	Ht	-6.986E-04	0.5944	0.3534	94.8%
RNA 3	Validation	8.9%	Ht	1.730E-02	0.5942	0.3543	88.6%
RNA 3	Training	80.6%	Ht	1.698E-04	0.5892	0.3473	94.9%
RNA 3	Validation	19.4%	Ht	3.086E-02	0.5880	0.3455	92.9%
RNA 1	Training	70.5%	Ht	3.672E-04	0.5801	0.3367	95.1%
RNA 1	Validation	29.5%	Ht	-1.398E-02	0.6126	0.3755	93.3%
RNA 3	Training	60.8%	Ht	-1.842E-03	0.5999	0.3601	95.1%
RNA 3	Validation	39.2%	Ht	-7.980E-03	0.6060	0.3676	92.7%
RNA 4	Training	52.7%	Ht	-8.958E-04	0.6077	0.3695	95.4%
RNA 4	Validation	47.3%	Ht	-2.399E-02	0.5847	0.3415	92.8%
RNA 2	Training	41.4%	Ht	-1.686E-03	0.5846	0.3421	96.1%
RNA 2	Validation	58.6%	Ht	-2.371E-02	0.6105	0.3724	92.4%
RNA 1	Training	32.6%	Ht	-4.093E-04	0.5946	0.3539	96.5%
RNA 1	Validation	67.4%	Ht	-1.634E-02	0.6093	0.3712	92.1%
RNA 1	Training	22.9%	Ht	-9.481E-04	0.6066	0.3686	97.1%
RNA 1	Validation	77.1%	Ht	-1.619E-02	0.6088	0.3706	91.9%
RNA 3	Training	14.5%	Ht	1.010E-03	0.6362	0.4058	97.6%
RNA 3	Validation	85.5%	Ht	-1.707E-02	0.6098	0.3717	91.6%

Source: Authors (2025).

Em todas as simulações os valores de correlação tanto para treinamento quanto para validação se apresentaram estatisticamente confiáveis com valores superiores a 88% e a variância entorno da média abaixo de 0,41. Com o aumento dos dados direcionados para treinamento da rede, foi possível observar uma melhora no parâmetro estatístico de correlação.

A Tabela 4 apresenta o arranjo do experimento com os diferentes clones e espaçamentos testados, as médias das alturas totais de todas as árvores mensuradas e os coeficientes de variação considerando toda a população com alturas observadas e a gradativa redução para estimativa por meio das RNAs. Dessa forma também é possível observar que é pequena a diferença entre os tratamentos quando comparada todas as plantas que tiveram as alturas medidas com as que tiveram as alturas estimadas, sendo a maior variação de 1% do coeficiente de variação dentro da mesma parcela, evidenciando também a acurácia e precisão das estimativas de altura geradas pelas RNAs.


Table 4. Mean heights and coefficient of variation by treatment.

Trat	Espaç	Ht_100%		Ht_91.1%		Ht_80.6%		Ht_70.5%		Ht_60.8%		Ht_52.7%		Ht_41.4%		Ht_32.6%		Ht_22.9%		Ht_14.5%	
		Mean	CV (%)	Mean	CV (%)	Mean	CV (%)	Mean	CV (%)	Mean	CV (%)	Mean	CV (%)	Mean	CV (%)	Mean	CV (%)	Mean	CV (%)	Mean	CV (%)
B	3.4x2.0	15.99	28.3%	15.99	28.2%	15.98	28.2%	15.95	28.1%	15.97	28.2%	15.91	28.1%	15.97	28.1%	15.95	28.3%	16.03	28.2%	15.91	28.2%
B	3.4x2.3	17.40	14.5%	17.44	14.4%	17.45	14.4%	17.43	14.2%	17.45	14.1%	17.42	14.0%	17.54	14.1%	17.50	14.5%	17.57	14.3%	17.51	14.3%
B	3.4x2.6	15.88	20.0%	15.81	20.1%	15.81	20.0%	15.77	20.1%	15.74	20.1%	15.75	20.0%	15.62	20.0%	15.71	19.9%	15.67	19.9%	15.88	19.8%
B	3.4x2.9	17.03	13.2%	17.02	13.1%	17.03	13.1%	17.03	13.2%	17.01	13.1%	16.99	13.0%	17.02	13.0%	17.00	13.0%	16.98	13.0%	17.11	13.0%
B	3.4x3.2	17.72	11.3%	17.76	11.3%	17.78	11.0%	17.76	11.0%	17.79	10.9%	17.82	10.9%	17.76	10.9%	17.72	10.9%	17.78	10.9%	17.77	10.9%
B	3.4x3.5	17.96	10.6%	17.97	10.6%	17.98	10.6%	18.01	10.5%	18.00	10.5%	17.95	10.5%	17.99	10.5%	18.00	10.5%	18.00	10.5%	18.00	10.6%
C	3.4x2.0	15.00	30.5%	15.01	30.5%	14.98	30.5%	14.97	30.5%	14.96	30.4%	14.97	30.4%	14.99	30.5%	15.00	30.3%	15.05	30.4%	15.10	30.4%
C	3.4x2.3	16.14	17.3%	16.14	17.3%	16.12	17.2%	16.12	17.2%	16.15	17.2%	16.16	17.1%	16.11	16.9%	16.09	16.9%	16.10	16.9%	16.13	16.9%
C	3.4x2.6	15.17	12.0%	15.19	12.0%	15.19	12.0%	15.16	11.9%	15.17	11.9%	15.19	11.7%	15.20	12.1%	15.16	12.2%	15.11	12.0%	15.11	12.0%
C	3.4x2.9	15.72	8.2%	15.74	8.3%	15.75	8.2%	15.73	8.5%	15.74	8.4%	15.71	8.4%	15.77	8.5%	15.78	8.6%	15.77	8.8%	15.74	8.5%
C	3.4x3.2	16.46	8.7%	16.47	8.7%	16.46	8.7%	16.45	8.6%	16.45	8.5%	16.40	8.4%	16.39	8.5%	16.37	8.3%	16.28	8.3%	16.40	8.0%
C	3.4x3.5	16.75	14.7%	16.75	14.7%	16.78	14.7%	16.81	14.5%	16.78	14.4%	16.75	14.5%	16.70	14.4%	16.67	14.3%	16.68	14.4%	16.58	14.2%
D	3.4x2.0	16.59	24.5%	16.55	24.4%	16.49	24.4%	16.42	24.3%	16.39	24.3%	16.38	24.3%	16.37	24.2%	16.38	24.4%	16.36	23.9%	16.43	24.2%
D	3.4x2.3	16.21	30.0%	16.18	29.9%	16.18	29.9%	16.18	29.9%	16.17	29.9%	16.16	29.9%	16.20	30.1%	16.29	29.9%	16.13	30.1%	16.27	30.0%
D	3.4x2.6	16.99	8.4%	16.96	8.4%	16.92	8.4%	16.82	8.6%	16.81	8.6%	16.84	8.3%	16.78	8.2%	16.89	8.4%	16.82	8.3%	16.69	8.4%
D	3.4x2.9	15.89	27.8%	15.88	27.7%	15.87	27.7%	15.89	27.6%	15.89	27.6%	15.87	27.6%	15.87	27.6%	15.85	27.6%	15.84	27.6%	15.82	27.7%
D	3.4x3.2	16.26	27.0%	16.29	27.0%	16.30	27.0%	16.30	27.0%	16.30	27.0%	16.27	26.9%	16.32	27.0%	16.32	27.0%	16.28	26.9%	16.29	26.9%
D	3.4x3.5	18.08	14.6%	18.09	14.6%	18.12	14.6%	18.13	14.6%	18.16	14.5%	18.15	14.5%	18.20	14.5%	18.22	14.5%	18.24	14.5%	18.16	14.4%
A	3.4x2.0	17.91	20.8%	17.89	20.8%	17.88	20.8%	17.86	20.7%	17.80	20.7%	17.85	20.8%	17.92	20.8%	17.93	20.7%	18.00	20.7%	17.98	20.7%
A	3.4x2.3	17.35	27.0%	17.36	27.0%	17.37	27.0%	17.33	26.9%	17.35	26.9%	17.36	26.9%	17.41	26.9%	17.35	26.8%	17.31	26.8%	17.41	26.9%
A	3.4x2.6	17.33	15.5%	17.32	15.5%	17.27	15.4%	17.24	15.3%	17.19	15.4%	17.19	15.2%	17.15	14.9%	17.07	15.2%	17.17	15.3%	17.23	15.4%
A	3.4x2.9	17.53	19.9%	17.55	19.9%	17.58	20.0%	17.59	20.0%	17.60	20.0%	17.61	20.0%	17.52	19.9%	17.53	19.9%	17.59	19.9%	17.60	19.9%
A	3.4x3.2	15.70	35.4%	15.71	35.4%	15.71	35.4%	15.72	35.4%	15.74	35.4%	15.75	35.3%	15.74	35.4%	15.65	35.3%	15.64	35.3%	15.56	35.3%
A	3.4x3.5	16.98	31.3%	16.98	31.3%	17.02	31.3%	17.03	31.2%	17.07	31.2%	17.04	31.2%	17.05	31.2%	17.10	31.1%	17.06	31.2%	17.02	31.1%

Source: Authors (2025).

A partir da Figura 1 é possível observar a boa acurácia das Redes Neurais Artificiais em estimar alturas em experimentos florestais. As dispersões dos erros ficaram bem distribuídos entre -30% e 30%.


Figure 1. Dispersion of percentage errors (y) of estimated and observed data as a function of DAP (x).



Source: Authors (2025).

Na análise de dispersão das alturas observadas (x) e estimadas (y) (Figura 2) há uma concentração dos dados próximos à reta central (1x1) com alguns poucos dados onde as estimativas tiveram menor precisão, mesmo com a redução gradativa das amostras observadas é possível observar a similaridade em todos os testes realizados.

Figure 2. Scatter plot of observed (x) and estimated (y) height data.



Source: Authors (2025).

4. Discussão

O setor florestal contribui para a economia global, bem-estar social e sustentabilidade ambiental no mundo. Em países que possuem maior cobertura florestal como Brasil, Canadá, Suécia, Finlândia e Indonésia o setor tem participação ativa no Produto Interno Bruto. O manejo florestal é responsável pela geração de empregos diretos e indiretos, desde o plantio até a fabricação de subprodutos da madeira. Neste sentido, é interessante destacar o impacto deste setor em áreas como construção civil, indústria de embalagens e produção de energia. Trata-se de um setor amplo que viabiliza práticas de baixo impacto ao meio ambiente.

No âmbito social, o setor florestal atua na geração de empregos para populações vulneráveis, alavancando o desenvolvimento regional de comunidades rurais. Acentua-se aqui a geração de renda paralela aos movimentos de inclusão social, educação e conscientização para o engajamento da população em práticas sustentáveis. Nesse sentido, é fundamental que ocorra a integração entre empresas, sociedade civil e governos para que avanços econômicos sejam alcançados com mínimo impacto ambiental.

A produção de eucalipto em experimentos florestais tem sido uma alternativa para o setor no que tange os aspectos de produção sustentável da madeira. O eucalipto é uma espécie de rápido crescimento e alto índice de produtividade. Assim, trata-se de uma alternativa benéfica para o aumento da captura de carbono e mitigação de mudanças climáticas. A aplicação diversificada do eucalipto é um aspecto vantajoso, pois pode ser utilizado na fabricação de papel, celulose, madeira sólida, e na produção de energia renovável e óleos essenciais por exemplo. Além disso, o incentivo destas práticas florestais sustentáveis promove a redução da pressão sobre áreas de preservação ambiental.

No entanto, experimentos florestais com o eucalipto apresentam altos custos operacionais que dificultam a expansão destas práticas sustentáveis. Custos relacionados a aquisição de terras, instalação de infraestrutura, implementação tecnológica, manutenções e coleta de dados são alguns exemplos de custos inerentes ao processo. Há também os custos com mão de obra que impactam diretamente em todas as etapas de produção do eucalipto. Isso ocorre pois é necessária mão de obra qualificada para a realização do plantio, medições, coleta e análise de dados.

Para tanto, o uso de tecnologias digitais no setor florestal é uma alternativa eficaz para a redução de custos operacionais em experimentos florestais. Nesse âmbito, modelos de machine learning têm sido amplamente difundidos para a predição da altura de árvores, substituindo as etapas de medição e coleta de dados. Skudnik e Jevšenak (2022) compararam o desempenho de modelos de efeitos mistos e modelos de altura-diâmetro baseados em redes neurais artificiais. Já Miranda et al. (2022) propôs um modelo baseado na interação de algoritmos genéticos – para seleção de variáveis - e floresta aleatória – para predição de alturas individuais de árvores. Ambos os estudos apresentaram êxito em seus resultados, comprovando a superioridade de modelos de machine learning em relação às práticas convencionais. No entanto, são estudos que carecem de uma análise mais detalhada sobre o percentual de redução de custos alcançado.

As variáveis consideradas no presente estudo foram: Circunferência na altura do peito, material genético, diâmetro na altura do peito, diâmetro na altura média do peito, diâmetro na altura máxima do peito, diâmetro quadrático médio, e área por planta – variáveis independentes – e altura média da parcela – variável dependente. A Circunferência na altura do peito (CAP) é a medida da circunferência da árvore a uma altura padrão de 1,30 metros do solo. É uma variável comumente utilizada para o cálculo do volume de madeira e biomassa da árvore.

O material genético é uma variável importante para a geração de insights sobre a taxa de crescimento das árvores, resistência a pragas e doenças, adaptabilidade ao clima e solo, e qualidade da madeira. A variável Diâmetro na altura do peito (DAP) é calculada mediante a coleta da Circunferência na altura do peito e auxilia na estimação da produtividade dos talhões. As variáveis Diâmetro na altura média do peito, Diâmetro na altura máxima do peito, e Diâmetro quadrático médio são medidas complementares ao DAP, que auxiliam na estimativa mais precisa do volume em casos de árvores com troncos irregulares. A área por planta corresponde ao espaço ocupado por cada árvore no plantio e reflete a densidade da cobertura florestal ideal para a maior produtividade e qualidade da madeira. Por fim, a variável Altura média da parcela corresponde à média das alturas das árvores em uma parcela experimental. Nela considera-se a medida desde a base do tronco até o topo da árvore.

Os resultados da Figura 1 revelaram que a dispersão dos erros percentuais dos dados estimados em relação aos dados observados como função do DAP variam em sua maioria - cerca de 97% - no intervalo de -10% à 10%. Isso indica uma boa capacidade de previsão do modelo utilizado, mesmo em áreas de grande variabilidade de sítio como experimentos florestais. De

acordo com Campos e Leite (2013) uma boa forma de analisar os resíduos é por meio de histogramas, pois com grande número de observações somente gráficos de dispersão podem levar ao risco de má interpretação, uma vez que ocorrem diversos pontos sobrepostos no gráfico.

Vendruscolo et al. (2015) utilizou RNAs para estimar altura de povoamentos florestais em três fazendas do estado do Mato Grosso e obteve valores de 89% e 88% de coeficiente de correlação para as bases de treinamento e validação, respectivamente, valores próximos aos encontrados no presente trabalho. Ainda de acordo com os resultados apresentados na Tabela 4, observa-se que em modelos com maior proporção de dados para treinamento há um menor erro e maior correlação. Assim, pode-se inferir que quanto maior o conjunto de dados de treinamento, maior será a capacidade de aprendizado e predição do modelo. Além disso, os resultados em geral apresentaram bias próximos a zero o que indica que estes modelos não apresentaram fortes tendências de sub ou superestimação.

Os valores das alturas médias e coeficientes de variação por tratamento (Tabela 5) indicaram que a altura média (Ht) tende a aumentar com o espaçamento. Assim, maiores espaçamentos podem favorecer o crescimento das plantas. Além disso, o coeficiente de variação (CV) é maior em espaçamentos menores, sugerindo maior heterogeneidade entre plantas nestes casos. No que se refere à capacidade de generalização dos modelos de redes neurais testados, estes apresentaram bom desempenho mesmo com conjuntos de treinamento reduzidos (Figura 4).

Neste sentido, este estudo avança para a etapa de validação em que foi desenvolvida uma análise de custo para mensuração do percentual de redução de custos caso seja implementado o modelo de predição baseado em redes neurais artificiais. Para análise de custos do projeto foram considerados os custos de pessoal: salário, encargos sociais e benefícios dos colaboradores; custos com alimentação: café da manhã e almoço; custos com deslocamento: locação de veículo, impostos, combustível, rastreadores veiculares, serviços de manutenção e franquia de seguro (Tabela 5).

Table 5. Economic evaluation of sample reductions in height collections in forest experiments.

Description	Qtd/day	Value/Snack		BRL/day	
Breakfast	3	BRL	11.00	BRL	33
Lunch	3	BRL	13.90	BRL	42
Total meals				BRL	75
Teams number	Qtd	SAL+BEM+ENC		BRL/day	
Measurement Assistant	2	BRL	3.196	BRL	213
Supervisor	1	BRL	13.770	BRL	459
Teams number				BRL	213
Description	Qtde	BRL/month		BRL/day	
Licensing+ IPVA	1	BRL	141.07	BRL	5
Fuel	1	BRL	1.350.00	BRL	45
Trackers	1	BRL	120.00	BRL	4
Maintenance - Services - Leased Vehicle	1	BRL	300.00	BRL	10
Vehicle Rental - Pick-up Teams	1	BRL	4.900.00	BRL	163
Leased Vehicle Insurance Excess Teams	1	BRL	100.00	BRL	3
Total Vehicles				BRL	230

Source: Authors (2025).

Nas atividades de medição desse experimento foi considerado uma equipe com 2 colaboradores (auxiliares de mensuração florestal) e um supervisor para direcionar as demandas e processar os dados de campo. Para medir o experimento completo, todas as alturas das plantas normais e todos os CAPs, foram gastos 7 dias de trabalho de uma equipe. Sendo assim, para estimar o tempo gasto para medir o experimento considerando as reduções de coletas de alturas

propostas, foi adotado que o tempo gasto para medir uma altura é o mesmo de medir 5 CAPs, conforme observação das atividades de campo. Outro ponto relevante foi com relação às horas gastas pelo supervisor, sendo que para as equipes medirem 100% das alturas e CAPs o tempo dispendido pelo supervisor em escritório será menor que quando usadas as RNAs para estimar alturas. Considerou-se 1 dia de escritório para medição de 100% das alturas e 2 dias usando a estimativa por meio de RNAs.

Além disso, através da tabela 6 é possível observar a quantidade de dias estimados para medir o experimento, considerando as reduções de mensuração de altura propostas, e os custos totais de mão de obra, alimentação e transporte.

Table 6. Costs of labor, food and travel.

% Height	1Ht/5CAP	Days	Workforce	Food	Vehicle	Cost	% Reduction
100	18225	7	BRL 1.950.30	BRL 522.90	BRL 1.612.58	BRL 4.085.78	0.0%
91.1	17040	7	BRL 2.409.30	BRL 522.90	BRL 1.612.58	BRL 4.544.78	-11.2%
80.6	15625	6	BRL 2.196.25	BRL 448.20	BRL 1.382.21	BRL 4.026.67	1.4%
70.5	14280	5	BRL 1.983.21	BRL 373.50	BRL 1.151.84	BRL 3.508.56	14.1%
60.8	12980	5	BRL 1.983.21	BRL 373.50	BRL 1.151.84	BRL 3.508.56	14.1%
52.7	11900	5	BRL 1.983.21	BRL 373.50	BRL 1.151.84	BRL 3.508.56	14.1%
41.4	10380	4	BRL 1.770.17	BRL 298.80	BRL 921.48	BRL 2.990.44	26.8%
32.6	9205	4	BRL 1.770.17	BRL 298.80	BRL 921.48	BRL 2.990.44	26.8%
22.9	7910	3	BRL 1.557.13	BRL 224.10	BRL 691.11	BRL 2.472.33	39.5%
14.5	6780	3	BRL 1.557.13	BRL 224.10	BRL 691.11	BRL 2.472.33	39.5%

Source: Authors (2025).

Conforme os resultados apresentados pela análise de custos (Tabela 6), alguns insights podem ser construídos para gestores. Neste âmbito, quanto menor for o percentual de alturas mensuradas maior será a redução do custo operacional, podendo alcançar uma redução de 39,5% para o cenário em que 14,5% das alturas foram mensuradas. Neste caso, há uma redução do número de dias de trabalho da equipe, de 7 para 3 dias, o que sugere maior otimização de recursos e ganho de eficiência. Os custos com transporte apresentaram a maior redução proporcional, revelando menor dependência logística conforme a altura reduz.

Este estudo demonstra que a inserção de tecnologias digitais no setor florestal, através de modelos de machine learning, podem reduzir custos operacionais em experimentos florestais. As implicações políticas deste estudo sugerem a realização de incentivos governamentais à inserção de técnicas de inteligência artificial em manejos florestais. Parcerias público-privadas podem ser realizadas para a integração de pequenos e médios produtores, subsidiando treinamento a classes vulneráveis e fortalecendo a economia sustentável nestas regiões. Também pode haver a padronização destes modelos e regulamentação, com normas e diretrizes específicas para a aplicação da inteligência artificial no setor florestal. Por fim, este estudo pode contribuir na formulação de políticas em prol da minimização de mudanças climáticas, fornecendo dados de alta precisão sobre inventários florestais para estimativa dos estoques de carbono em florestas plantadas.

5. Conclusão

Este estudo teve sua análise pautada na aplicação da técnica de redes neurais artificiais para estimar a altura em experimentos de clone e espaçamento de plantio comercial de árvores em substituição ao que atualmente é feito por meio de medição de todas as alturas. O estudo obteve êxito em sua análise, indicando uma economia de até 39,5% nos custos operacionais no setor florestal.

As contribuições teóricas deste estudo relacionam-se ao avanço metodológico proporcionado pela aplicação de modelos de machine learning no setor florestal; a validação de técnicas de redução amostral que demonstra a confiabilidade de métodos estatísticos para a redução da coleta de dados; e a consideração de pelo menos uma amostra observada por classe em cada parcela como estratégia de aumento da precisão. Já as contribuições práticas do estudo relacionam-se a redução de custos operacionais, aumento da eficiência na construção de

inventários florestais, fortalecimento do manejo florestal de precisão, e promoção da sustentabilidade.

O uso dessa metodologia permite a redução das medições e a redução expressiva nos custos dessa atividade. Apesar dos resultados obtidos neste estudo serem bastante favoráveis, é necessário a realização de mais pesquisas nessa linha em áreas experimentais em diferentes regiões do país e com diferentes tratamentos.

Referências

AKYÜZ, Ilker. Future projection and the sales of industrial wood in Turkey: artificial neural networks. *Turkish Journal of Agriculture and Forestry*, v. 43, n. 3, p. 368-377, 2019.

ALCÂNTARA AEM. Redes neurais artificiais para prognose do crescimento e da produção de povoamentos de eucalipto em Minas Gerais [tese]. Viçosa: Universidade Federal de Viçosa; 2015.

ALINSATO, A. S.; ALAKONON, C. B. Determinants of Productive Efficiency of Public Service: What Effect of the Interaction of Corruption Control and Average Wage? *Theoretical Economics Letters*, v. 11, n. 6, p. 1055–1066, 2021.

BAYAT, Mahmoud et al. Application of artificial neural networks for predicting tree survival and mortality in the Hyrcanian forest of Iran. *Computers and Electronics in Agriculture*, v. 164, p. 104929, 2019.

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

BINOTI D, Binoti MDS, Leite H, Silva A. Redução dos custos em inventário de povoamentos equiâneos utilizando redes neurais artificiais. *Agraria*. 2012;8 (1):125-9.

BINOTI, M. L. M. da S.; Binoti, D. H. B.; Leite, H. G. Aplicação de redes neurais para estimação da altura de povoamentos equiâneos de eucalipto. *Revista Árvore*, v.37, n.4, p.639-645, 2013a.

BINOTI, D. H. B.; Binoti, M. L. M. da S.; Leite, H. G.; Silva, A. Redução dos custos em inventário de povoamentos equiâneos. *Revista Brasileira Ciências Agrárias*, v.8, n.1, p.125-129, 2013b.

BINOTI, D. H. B.; Binoti, M. L. M. da S.; Leite, H. G. Configuração de redes neurais para estimação do volume de madeira. *Ciência da Madeira*, v.5, n.1, p.59-67, 2014.

CAMPOS, JCC, Leite HG. Mensuração florestal: perguntas e respostas. 4. ed. Viçosa: Editora UFV; 2013.

CARRER, M. J.; SOUZA FILHO, H. M. de. Economias de Escala e Eficiência Econômica na Produção de Laranja no Estado de São Paulo. *Revista de Economia e Sociologia Rural*, v. 54, p. 51–70, 2016.

COELLI, T. (Org.). *An Introduction to Efficiency and Productivity Analysis*. 2nd. ed. New York: Springer, 2005.

COELLI, T.; RAO, D. S. P.; BATTESE, G. E. *An Introduction to Efficiency and Productivity Analysis*. Boston, MA: Springer US, 1998. Disponível em: <<http://link.springer.com/10.1007/978-1-4615-5493-6>>. Acesso em: 11 dez. 2022.

DEBREU, G. The Coefficient of Resource Utilization. *Econometrica*, v. 19, n. 3, p. 273–292, 1951.

DIAMANTOPOULOU, Maria J. Artificial neural networks as an alternative tool in pine bark volume estimation. *Computers and electronics in agriculture*, v. 48, n. 3, p. 235-244, 2005.

DIAMANTOPOULOU, M. J. Assessing a reliable modeling approach of features of trees through neural network models for sustainable forests. *Sustainable Computing: Informatics and Systems*, v.2, n.4, p.190-197, 2012.

DIAMANTOPOULOU, M. J.; Milios, E. Modelling total volume of dominant pine trees in reforestations via multivariate analysis and artificial neural networks models. *Biosystems Engineering*, v.105, n.3, p.306-315, 2010.

DUARTE, J. B.; Princípios sobre delineamento em experimentação agrícola, Universidade Federal de Goiás, 1996.

FARRELL, M. J. The Measurement of Productive Efficiency. *Journal of the Royal Statistical Society. Series A (General)*, v. 120, n. 3, p. 253–290, 1957.

GOLLOB, Christoph et al. A Flexible Height–Diameter Model for Tree Height Imputation on Forest Inventory Sample Plots Using Repeated Measures from the Past. *Forests*, v. 9, n. 6, p. 368, 2018.

GORGENS, E. B.; Leite, H. G.; Santos, H. N.; Gleriani, J. M. Estimação do volume de árvores utilizando redes neurais artificiais. *Revista Árvore*, v.33, n.6, p.1141-1147, 2009.

HAYKIN, S. *Redes neurais: princípios e prática*. 2. ed. Porto Alegre: Bookman; 2001.

HUONG, V. V. et al. The Impact of Formalization on Firm Productivity: An Application of the Fare-Primont Index. *VNU Journal Of Economics And Business*, v. 2, n. 5, p. 32–41, 2022.

IBÁ (2021). *Indústria Brasileira de Árvores. Relatório da IBÁ 2021, ano base 2020*

KOOPMANS, T. C. An Analysis of Production as an Efficient Combination of Activities. In T. C. Koopmans (Ed.) *Activity Analysis of Production and Allocation*, Cowles Commission for Research in Economics, Monograph No. 13. n. 13, p. 33–97, 1951.

KOŽUCH, Anna; CYWICKA, Dominika; ADAMOWICZ, Krzysztof. A comparison of artificial neural network and time series models for timber price forecasting. *Forests*, v. 14, n. 2, p. 177, 2023.

LAFETÁ, BO. Eficiência nutricional, área foliar e produtividade de plantações de eucalipto em diferentes espaçamentos estimados com redes neurais artificiais [dissertação]. Diamantina: Universidade Federal dos Vales do Jequitinhonha e Mucuri; 2012.

LEIBENSTEIN, H. Allocative Efficiency vs. “X-Efficiency”: Comment. *The American Economic Review*, v. 56, n. 3, p. 392–541, 1966.

LEITE, H. G.; Silva, M. L. M. da; Binoti, D. H. B.; Fardin, L.; Takizawa, F. H. Estimation of inside-bark diameter and heartwood diameter for *Tectona grandis* Linn. trees using artificial neural networks. *European Journal of Forest Research*, v.130, n.2, p.263-269, 2010.

MARTINS, E. dos R. M.; Binoti, M. L. M. da S.; Leite, H. G.; Binoti, D. H. B.; Dutra, G. C. Configuração de redes neurais artificiais para prognose da produção de povoamentos clonais de eucalipto. *Revista Brasileira de Ciências Agrárias*, v.10, n.4, p.532-537, 2015.

MENDONÇA, A.R. et al. Modelos hiposométricos e de crescimento em altura das árvores dominantes e codominantes para *Pinus caribaea* var. *hondurensis*. *Scientia Forestalis*, v.39, n.90, p.151-160, 2011.

MIRANDA, Evandro Nunes et al. Variable selection for estimating individual tree height using genetic algorithm and random forest. *Forest Ecology and Management*, v. 504, p. 119828, 2022.

OGANA, F. N.; GORGOSO-VARELA, J. J. A nonlinear mixed-effects tree height prediction model: Application to *Pinus pinaster* Ait in Northwest Spain. *Trees, Forests and People*, v. 1, p. 100003, 2020.

ÖZÇELİK, R.; Diamantopoulou, M. J. Brooks, J. R.; Wiant Jr, H. 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.

ÖZÇELİK, R.; Diamantopoulou, M. J.; Crecente-Campo, F.; Eler, U. Estimating Crimean juniper tree height using nonlinear regression and artificial neural network models. *Forest Ecology and Management*, v.306, p.52–60, 2013.

ÖZÇELİK, Ramazan et al. Predicting tree height from tree diameter and dominant height using mixed-effects and quantile regression models for two species in Turkey. *Forest ecology and management*, v. 419, p. 240-248, 2018.

PESSOTI, F. C.; PESSOTI, G. C. Os elementos constituintes do método de análise das escolas Clássica, Neoclássica e Novo-Clássica. *Cadernos de Ciências Sociais Aplicadas*, n. 24, p. 14, 2017.

RODRIGUES, E. F.; Oliveira, T. R.; Madruga, M. R.; Silveira, A. M. Um método para determinar o volume comercial do *Schizolobium amazonicum* (Huber) Ducke utilizando redes neurais artificiais. *Revista Brasileira de Biometria*, v.28, n.1, p.16-23, 2010.

SANTOS, A. C. A, Almeida, F. M., Souza, R. B, Chaves, R., Paiva, H. N., Binoti, D. H. B., Leite, H. G., Farias, A. A. Estimation of eucalyptus tree height in clonal and progeny tests using artificial neural networks, *Revista Árvore*, 2017.

SHAHI, Shashi K. et al. Artificial neural networks for demand forecasting of the Canadian forest products industry. *International Journal of Business Information Systems*, v. 47, n. 3, p. 295-323, 2024.

SILVA, MLMS. Emprego de redes neurais artificiais em mensuração e manejo florestal [dissertação]. Viçosa: Universidade Federal de Viçosa; 2012.

SKUDNIK, Mitja; JEVŠENAK, Jernej. Artificial neural networks as an alternative method to nonlinear mixed-effects models for tree height predictions. *Forest Ecology and Management*, v. 507, p. 120017, 2022.

SOARES, F. A. A. M. N.; Flôres, E. D.; Cabacinha, C. D.; Carrijo, G. A.; Veiga, A. C. P. Recursive diameter prediction and volume calculation of eucalyptus trees using multilayer perceptron networks. *Computers and Eletronics in Agriculture*, v.78, n.1, p.19-27, 2011.

TEN RAA, T. Debreu's Coefficient of Resource Utilization, the Solow Residual, and TFP: The Connection by Leontief Preferences. *Journal of Productivity Analysis*, v. 30, n. 3, p. 191–199, 2008.

VENDRUSCOLO, D.G.S. 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.

ZHAO, Qingxia et al. Comparison of machine learning algorithms for forest parameter estimations and application for forest quality assessments. *Forest Ecology and Management*, v. 434, p. 224-234, 2019.