

**INSTITUTO FEDERAL DE MINAS GERAIS
CAMPUS SÃO JOÃO EVANGELISTA
ISRAEL BALBATAHAM SILVA E BARBOSA**

**MODELOS DE SCHUMACHER E HALL E INTELIGÊNCIA ARTIFICIAL
PARA ESTIMATIVA DO VOLUME DE ÁRVORES DE EUCALIPTO.**

**SÃO JOÃO EVANGELISTA – MG
2021**

ISRAEL BALBATAHAM SILVA E BARBOSA

**MODELOS DE SCHUMACHER E HALL E INTELIGÊNCIA ARTIFICIAL PARA
ESTIMATIVA DO VOLUME DE ÁRVORES DE EUCALIPTO.**

Trabalho de conclusão de curso apresentado ao Instituto Federal de Minas Gerais – Campus São João Evangelista, como exigência parcial para obtenção do título de Bacharel em Engenharia Florestal.

Orientador: Prof Dr Bruno de Oliveira Lafetá

**SÃO JOÃO EVANGELISTA
2021**

FICHA CATALOGRÁFICA

B238m Barbosa, Israel Balbataham Silva e

Modelos de *schumacher e hall* e inteligência artificial para estimativa do volume de árvores de eucalipto. / Israel Balbataham Silva e Barbosa. - São João Evangelista: IFMG, 2021.

27fl.;il.

Orientador: Dr.Bruno de Oliveira Lafetá.

Trabalho de Conclusão de Curso (Bacharelado em Engenharia Florestal) – Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais – Campus São João Evangelista, 2021.

1. Máquinas. 2. Vetor de suporte. 3. Modelagem. 4. *Random forest*. I. Barbosa, Israel Balbataham Silva e. II. Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais – Campus São João Evangelista. III. Título.

CDD 634.97342

ISRAEL BALBATAHAM SILVA E BARBOSA

MODELOS DE SCHUMACHER E HALL E INTELIGÊNCIA ARTIFICIAL PARA ESTIMATIVA DO VOLUME DE ÁRVORES DE EUCALIPTO.

Trabalho de conclusão de curso apresentado ao Instituto Federal de Minas Gerais – Campus São João Evangelista, como exigência parcial para obtenção do título de Bacharel em Engenharia Florestal.

Aprovada em 11/03/2021

BANCA EXAMINADORA



Prof. Dr. Bruno de Oliveira Lafetá (Orientador)
Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais – *Campus* São João Evangelista

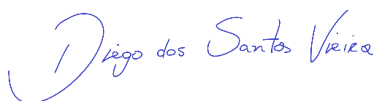


Prof. Me. Ivan Costa Ilhéu Fontan (Coorientador)
Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais – *Campus* São João Evangelista

Tamires Mousslech
Andrade Penido

Assinado de forma digital por
Tamires Mousslech Andrade
Penido

Ma. Tamires Mousslech Andrade Penido
Universidade Federal dos Vales do Jequitinhonha e Mucuri – *Campus* Diamantina



Dr. Diego dos Santos Vieira
Universidade Federal dos Vales do Jequitinhonha e Mucuri – *Campus* Diamantina

*À Deus, aos meus pais, irmão, família, amigos e a todos que acreditaram e confiaram em mim, **dedico** este trabalho com todo amor e carinho.*

AGRADECIMENTOS

Inicialmente agradeço a Deus por me proporcionar tamanha conquista e me guiar em momentos de decisão e indecisão, me fortalecendo nas situações onde precisava de sabedoria. Aos meus pais Adalton e Cecília que me deram apoio, amor e compreensão por todo esse período e garantiram que nada me faltasse para continuar essa jornada e adquirir essa importante conquista, assim como minha irmã Isabel por fazer parte desse caminho sempre ao meu lado me apoiando em tudo. Ao meu irmão Isaac pelo companheirismo, amizade, apoio e suporte em todas as etapas do curso, estando comigo tanto em casa quanto em sala, batalhando juntos para conseguir superar obstáculos e adquirir méritos ao longo da formação.

Agradeço aos meus amigos Vinícius, Igor, Guilherme, Júnior Vitor, Sarah, Rosiane e Isaac por todos os momentos difíceis, desafiadores, bons e engraçado é claro. Que todos os dias de luta que tivemos se transformem em dias de glória.

Agradeço ao Prof Bruno Oliveira Lafetá pelo auxílio, amizade e aprendizado necessários para a conclusão dessa importante etapa e pela contribuição ao longo do curso me ajudando a refinar meus conhecimentos. Aos amigos que fizeram parte dessa jornada e que serão lembrados sempre como peças fundamentais na minha caminhada. Agradeço a Empresa Florestal pelo fornecimento dos dados utilizados na elaboração desse trabalho.

Por fim, agradeço ao Instituto Federal de Minas Gerais pela oportunidade e pelos conhecimentos adquiridos ao longo de todos esses anos e a todos que de alguma maneira, direta ou indiretamente, contribuíram para essa conquista.

Serei eternamente grato!

RESUMO

O objetivo foi avaliar a estimativa volumétrica de árvores de eucalipto em diferentes arranjos espaciais de plantio, empregando o ajuste do modelo de Schumacher e Hall e inteligência artificial. O experimento foi instalado em blocos ao acaso, com três blocos. Os tratamentos foram constituídos pelos seguintes arranjos espaciais: T1 – $3,0 \times 0,5\text{m}$; T2 – $3,0 \times 1,0\text{m}$; T3 – $3,0 \times 1,5\text{m}$; T4 – $3,0 \times 2,0\text{m}$ e T5 – $3,0 \times 3,0\text{m}$. Aos 101 meses de idade, foram abatidas 198 árvores para a cubagem rigorosa. Foram testadas as seguintes técnicas de modelagem: T1) Regressão não linear - modelo de Schumacher e Hall; T2) Regressão linear – modelo de Schumacher e Hall linearizado; T3) Random forest e; T4) Máquinas vetor de suporte (MVS). As técnicas T2, T3 com dupla entrada (DAP e altura) e T4 com tripla entrada (DAP, altura e espaçamento entre planta) foram as únicas técnicas cujos resíduos padronizados tiveram distribuição homocedástica. A implementação da MVS de base radial com tripla entrada exibiu o melhor desempenho preditivo volumétrico de árvores em diferentes arranjos espaciais. Conclui-se que o uso das técnicas T2, T3 e T4 com função Kernel de base radial permite a obtenção de estimativas precisas do volume comercial com casca de árvores eucalipto.

Palavras-chave: Máquinas vetor de suporte, Modelagem, Random forest, Regressão.

ABSTRACT

This work aimed to evaluate volumetric estimate of eucalypt trees in different plant spacings, using the adjustment of Schumacher and Hall volumetric model and artificial intelligence. The experiment was installed in random blocks, with three blocks. Treatments consisted of the following plant spacings: T1 - 3.0×0.5 m; T2 - 3.0×1.0 m; T3 - 3.0×1.5 m; T4 - 3.0×2.0 m and T5 - 3.0×3.0 m. At 101 months of age, 198 trees were felled for rigorous cubing. The following modeling techniques were tested: T1) Non-linear regression - Schumacher and Hall model; T2) Linear regression - Schumacher Hall linearized model; T3) Random forest and; T4) Support vector machines (SVM). The techniques T2, T3 with double entry (DBH and height) and T4 with triple entry (DBH, height and spacing between plants) were the only techniques whose standardized residues had homoscedastic distribution. The implementation of the radial base MVS with triple entry showed the best volumetric predictive performance of trees in different plant spacings. It is concluded that the use of T2, T3 and T4 (with radial based Kernel function) techniques allows to obtain accurate estimates of the commercial volume with bark of eucalypt trees.

Keywords: Support vector machines, Modeling, Random forest, Regression.

SUMÁRIO

1 INTRODUÇÃO	10
2 MATERIAL E MÉTODOS	Erro!
Indicador não definido.2	
2.1 CARACTERIZAÇÃO EXPERIMENTAL	Erro!
Indicador não definido.2	
2.2 MÉTODOS DE MODELAGEM E AVALIAÇÃO	Erro!
Indicador não definido.4	
3 RESULTADOS	Erro!
Indicador não definido.5	
4 DISCUSSÃO	Erro!
Indicador não definido.20	
5 CONCLUSÕES	Erro!
Indicador não definido.2	
REFERÊNCIAS	24

1 INTRODUÇÃO

O volume de madeira pode ser estimado pela aplicação de modelos matemáticos conhecidos no meio florestal como modelos volumétricos (MIGUEL et al., 2014). Essa variável constitui uma das informações de maior importância para o conhecimento do potencial de um povoamento florestal e, por meio da sua estimativa por modelos matemáticos, fornece subsídios para a avaliação do estoque de madeira e a análise do potencial produtivo das florestas. (MACHADO et al., 2002; THOMAS et al., 2006).

Os modelos volumétricos consistem no método de uso mais recorrente na estimativa de volumes individuais ou até mesmo do estoque em florestais (ANDRADE et al., 2019). O uso de modelos permite a representação simplificada dos atributos das espécies, em diferentes condições e das mudanças destes atributos, ao longo dos anos de desenvolvimento da floresta. Portanto a confiabilidade das informações está diretamente relacionada à consistência e acurácia na coleta dos dados e à escolha adequada dos modelos. (ALVES, J. de A., 2018).

No que se refere às análises quantitativas, a obtenção da variável volume no meio florestal está associada a modelos ajustados de regressão, podendo ser linear (simples ou múltipla) ou não linear (LEITE; REZENDE, 2010).

As principais diferenças entre os dois modelos estão relacionadas às suas formulações. No caso linear, a partir de um conjunto de observações, busca-se o modelo que melhor explique a relação, se existir alguma, entre as variáveis inerentes a um dado fenômeno. Já no caso não-linear, na maioria das vezes, as formulações de possíveis modelos são baseadas em considerações teóricas inerentes ao fenômeno que se tem interesse modelar.

De acordo com Schneider et al. (2009), a análise de regressão tem sido usada com ênfase na solução de grande parte dos problemas florestais, especialmente quando se pretende obter estimativas de parâmetros da floresta, utilizando-se de relações biométricas que possibilitam obter valores estimados de forma indireta através de equações de regressão. Na Ciência Florestal, muitos estudos já foram conduzidos visando à modelagem da variável volume em se tratando de florestas plantadas com o gênero *Eucalyptus* podendo enfatizar as contribuições de (AZEVEDO et al., 2011; OLIVEIRA et al., 2009; SILVA et al.; 2009).

O emprego de modelos de regressão para estimar o volume de povoamentos florestais possui como vantagem ser uma técnica de baixo custo e quando aplicado corretamente gera estimativas bem acuradas (CAMPOS; LEITE, 2009).

Existem vários modelos que visam expressar o volume da madeira em função do diâmetro e da altura, dentre eles, o modelo proposto por Schumacher e Hall (1933) é vastamente difundido na área florestal, devido às suas propriedades estatísticas que quase sempre resultam em estimativas não tendenciosas (LEITE; ANDRADE, 2002; CAMPOS; LEITE, 2006). De acordo com um estudo publicado por Silva et al. (2009), o ajuste do modelo de Schumacher e Hall (1933) pode ser usado na sua forma linear, com boa representabilidade e sem apresentar tendenciosidade quando aplicado na estimação do volume de árvores de eucalipto. Segundo Soares et al. (2011) Para facilitar o ajuste e corrigir problemas estatísticos relacionados a pressuposições básicas da regressão, o modelo de Schumacher e Hall normalmente é ajustado na sua forma linear por logaritmo neperiano. Araújo et al. (2016), concluíram que o modelo de Schumacher e Hall foi o que melhor se ajustou para a estimação do volume de eucalipto em relação a outros modelos comparados.

Com o intuito de reduzir os custos e proporcionalmente aumentar a exatidão das estimativas (CAMPOS; LEITE, 2009; BINOTI, 2012), múltiplas ferramentas e diferentes formas de metodologias têm sido introduzidas na área florestal. Dentre essas ferramentas de inteligência computacional (IC), as técnicas de Redes Neurais Artificiais (RNA), Máquinas Vetor de Suporte (MVS) e também Random Forest, têm despertado interesse na área florestal (BINOTI, 2012).

As Máquinas Vetor de Suporte - MSV (Support Vector Machine - SVM), desenvolvidas inicialmente por Vapnik (1995), constituem uma técnica de Aprendizado de Máquina baseada nos princípios da Teoria de Aprendizado Estático (TAE). Esta teoria estabelece as condições matemáticas essenciais que permitem a escolha de um classificador com boa generalização, ou seja, com bom desempenho para os conjuntos de treinamento e teste (SMOLA; SCHOLKOPF, 2004). Máquinas Vetor de Suporte (MVS) são um conjunto de técnicas simples em sua base conceitual e com capacidade de resolução de problemas reais extremamente complexos.

Em um estudo conduzido por Cordeiro (2015), foi obtido que as Máquinas Vetor de Suporte (MVS) fornecem resultados satisfatórios para estimar volumes de florestas plantadas de *Acacia mangium* após obter resultados de estimativas volumétricas de

Acacia mangium usando modelo de Schumacher e Hall, para comparar as técnicas redes neurais e Máquinas Vetor de Suporte em que foram utilizados dados de cubagens de 31 indivíduos com idades entre 14 e 17 anos.

Em uma série de artigos e relatórios técnicos, Breiman (1996, 2000, 2001, 2004) demonstrou que ganhos substanciais na classificação e precisão de regressão podem ser alcançados usando conjuntos de árvores, onde cada árvore do conjunto é cultivada de acordo com um parâmetro aleatório. As previsões finais são obtidas agregando sobre o conjunto. Como os constituintes básicos do conjunto são preditores estruturados em árvore, e uma vez que cada uma dessas árvores é construída usando uma injeção de aleatoriedade, esses procedimentos são chamados de “florestas aleatórias” (Random Forests).

Random Forests surgiram como competidoras sérias para métodos de ponta, como o Boosting (Freund; Shapire, 1996) e Máquinas Vetor de Suporte (Taylor; Cristianini, 2004). Eles são rápidos e fáceis de implementar, produzem previsões altamente precisas e pode lidar com um número muito grande de variáveis de entrada sem sobreajuste. Na verdade, eles são considerados uma das mais precisas técnicas de aprendizagem de uso geral disponíveis. A pesquisa de Genuer et al. (2008) pode fornecer o leitor com orientações práticas e um bom ponto de partida para a compreensão do método.

Mediante exposto, as seguintes hipóteses foram testadas: i) O ajuste do modelo de Schumacher e Hall nas formas não linear e linear possuem desempenhos preditivos similares entre si? ii) A técnicas de Random forest e MVS fornecem estimativas mais precisas que a modelagem por Schumacher e Hall? O objetivo do presente trabalho foi avaliar a estimativa volumétrica de árvores de eucalipto em diferentes arranjos espaciais de plantio, empregando o ajuste do modelo de Schumacher e Hall, random forest e máquinas vetor de suporte.

2 MATERIAL E MÉTODOS

2.1 Caracterização experimental

O experimento foi instalado no município de Itamarandiba – MG em dezembro de 2002, utilizando-se um híbrido de *Eucalyptus grandis* W. Hill ex Maiden x *E. camaldulensis* Dehnh. O clima predominante na região é do tipo Cwa, segundo o sistema internacional de Köppen (KÖPPEN, 1936), com invernos amenos e secos e verões

quentes e chuvosos. As médias anuais de temperatura e precipitação durante a rotação foram de 20,2° C (médias variando de 16,6°C em julho a 22,3°C em fevereiro) e 1.062 mm (médias variando de 3 mm em agosto a 255 mm em dezembro), respectivamente (INMET, 2021).

O local de plantio se encontra em área de Latossolo Vermelho, relevo plano e a 1.097 m de altitude. O delineamento experimental foi em blocos ao acaso, com três blocos. Os tratamentos foram constituídos pelos seguintes arranjos espaciais de plantio: 3,0 × 0,5m (1,5 m²); 3,0 × 1,0m (3,0 m²); 3,0 × 1,5m (4,5 m²); 3,0 × 2,0m (6,0 m²) e 3,0 × 3,0m (9,0 m²), 3m foi a distância fixa entre linhas de plantio. Cada unidade experimental foi definida por seis linhas com 28 árvores, totalizando 168 indivíduos, dos quais 48 foram mensurados, por ter sido adotada uma bordadura dupla.

Aos 101 meses de idade, foram abatidas 198 árvores para a cubagem rigorosa, distribuídas em classes diamétricas conforme a Tabela 1. Obtiveram-se as informações de diâmetro com casca a 1,30 m do solo (DAP, cm) e altura total (H, m) com auxílio de suta e trena, respectivamente. Os cálculos de volume comercial com casca (V, m³) das seções de fuste se basearam na fórmula de Smalian, sendo mensurados os diâmetros nas seguintes posições: 0,10; 0,30; 0,70; 1,00; 1,30 e 2,00 m, e a partir deste ponto, em intervalos regulares de 1,0 m até a posição com diâmetro de 2 cm.

Tabela 1. Distribuição de frequência das árvores abatidas aos 101 meses de idade para cubagem em povoamentos de eucaliptos com diferentes arranjos espaciais de plantio, em Itamarandiba-MG.

Arranjos espaciais	Centro de classe - DAP (cm)						Total
	5,5	8,5	11,5	14,5	17,5	20,5	
3,0 × 0,5m	15	14	9	-	-	-	38
3,0 × 1,0m	4	13	12	8	-	-	37
3,0 × 1,5m	3	11	10	16	5	-	45
3,0 × 2,0m	-	6	14	14	6	-	40
3,0 × 3,0m	-	-	7	12	15	4	38
Total	22	44	52	50	26	4	198

Os dados foram divididos aleatoriamente em grupos de parametrização (70% das amostras) e de validação (30% das amostras), mutuamente exclusivos (método holdout) e adotando critério randômico de amostragem sem reposição. Nessa divisão, todos os arranjos espaciais e classes de DAP foram contempladas com árvores em ambos os

grupos. Os pontos que extrapolaram a tendência geral dos dados não foram eliminados das análises estatísticas a fim de se verificar a capacidade das técnicas em lidar com outliers ou ruídos.

2.2 Métodos de modelagem e avaliação

Foram testadas as seguintes técnicas de modelagem para a estimativa volumétrica das árvores de eucalipto: T1) Regressão não linear; T2) Regressão linear; T3) Random forest e; T4) Máquinas vetor de suporte. As modelagens volumétricas foram realizadas para todo o conjunto de dados do grupo de parametrização (generalistas), isto é, sem estratificação.

Na fase exploratória dos dados, verificou-se que a inclusão da variável explicativa espaçamento entre plantas (m) não contribuiu estatisticamente ($p > 0,05$ pelo teste t) na modelagem via regressão (T1 e T2), sendo removida dos respectivos ajustes. As médias de fator de forma foram de $0,47 \pm 0,0452$ para o arranjo de $3,0 \times 0,5\text{m}$, de $0,46 \pm 0,0403$ para o $3,0 \times 1,0\text{ m}$, de $0,47 \pm 0,0362$ para o $3,0 \times 1,5\text{ m}$, de $0,47 \pm 0,0326$ para o $3,0 \times 2,0\text{ m}$ e de $0,46 \pm 0,0284$ para o $3,0 \times 3,0\text{ m}$.

A análise de regressão não linear foi realizada pelo método iterativo de Levenberg-Marquardt, pacote R “minpack.lm” (ELZHOV et al., 2016). O modelo volumétrico adotado foi proposto por Schumacher e Hall (1933), em sua forma não linear, sendo:

$$V = \beta_0 DAP^{\beta_1} H^{\beta_2} \varepsilon$$

Em que: β_0 , β_1 e β_2 são parâmetros do modelo e ε é o erro aleatório.

A estimativa dos parâmetros da técnica de regressão linear foi obtida pelo Método dos Mínimos Quadrados Ordinários, empregando aproximação linear do modelo de Schumacher e Hall, por transformação logarítmica:

$$\ln(V) = \beta_0 + \beta_1 \ln(DAP) + \beta_2 \ln(H) + \ln(\varepsilon)$$

As técnicas de modelagem por inteligência artificial fundamentadas no aprendizado supervisionado (T3 e T4) foram aplicadas em duas abordagens, uma para a estimativa volumétrica em função de DAP e altura e outra, com a inclusão, também, do espaçamento entre plantas (m) como variável explicativa. Realizou-se 100 parametrizações para a modelagem via random forest pelo pacote R “randomForest” (LIAW; WIENER, 2002) e o seu default (500 árvores). Dessas parametrizações,

selecionou-se uma com base nos desvios dos valores estimados e observados para as análises subsequentes.

A construção das máquinas de vetor por sua vez, se baseou no processo de aprendizado estatístico descrito em detalhes por Vapnik (1995) e Meyer et al. (2017). As MVS foram implementadas usando o pacote R “e1071” (MEYER et al., 2017) com parâmetro de custo igual a 1, gama de 0,33 e épsilon de 0,1. Para a parametrização das MVS, foram analisados quatro tipos de funções Kernel (linear, base radial, sigmoideal e polinomial). As funções Kernel são algoritmos que melhoram o poder computacional das máquinas de vetor, permitindo representar fenômenos de maior complexidade (LAFETÁ, 2020). Somente um tipo de função Kernel foi selecionada para compor as inspeções gráficas.

As seleções do método de modelagem e da função Kernel para compor as MVS para a estimativa volumétrica se basearam na Média dos Desvios Absolutos (MDA), Raiz Quadrada do Erro Médio (RQEM) e coeficiente de correlação de Pearson (r). A estimativas volumétricas da fase de validação foram comparadas com os correspondentes volumes observados utilizando-se o teste F de Graybill (GRAYBILL, 1976). Todas essas estatísticas foram calculadas por arranjo espacial e para todo o conjunto de dados. As análises gráficas consistiram na inspeção estatística da dispersão dos resíduos padronizados.

Para diagnóstico de efeito estatístico, empregou-se 1 e 5% de significância em todas as análises. Estas foram efetuadas com auxílio do software R versão 3.5.2 (R CORE TEAM, 2018).

3 RESULTADOS

Na fase de parametrização, as correlações do volume com DAP ($r = 0,9696$) e altura ($0,9033$) foram fortes e significativas ($p \leq 0,01$). Mesma tendência foi obtida na fase de validação, com correlações de $0,9756$ e $0,9091$ para o DAP e altura, respectivamente.

As informações sobre os coeficientes e a qualidade de ajuste do modelo de Schumacher e Hall (T1 e T2) para a estimativa volumétrica de árvores de eucalipto em diferentes arranjos espaciais se encontra na Tabela 2. Todos os coeficientes foram

significativos pelo teste t ($p \leq 0,01$). As duas técnicas de modelagem via regressão exibiram pouca variação entre si em relação às estatísticas MDA, RQEM e correlação.

Tabela 2. Coeficientes e qualidade de ajuste do modelo de Schumacher e Hall para a estimativa volumétrica de árvores em diferentes arranjos espaciais de plantio

Arranjos espaciais	---- Parametrização ----			----- Validação -----		
	MDA	RQEM	r	MDA	RQEM	r
Schumacher e Hall ($\beta_0 = 0,000011$; $\beta_1 = 1,591518$ e $\beta_2 = 1,697711$)						
3,0 × 0,5m	0,0035	0,0043	0,9936**	0,0028	0,0039	0,9985**
3,0 × 1,0m	0,0057	0,0077	0,9921**	0,0047	0,0058	0,9907**
3,0 × 1,5m	0,0054	0,0067	0,9973**	0,0057	0,0072	0,9963**
3,0 × 2,0m	0,0101	0,0149	0,9825**	0,0056	0,0068	0,9968**
3,0 × 3,0m	0,0097	0,0120	0,9894**	0,0121	0,0153	0,9839**
Geral	0,0069	0,0098	0,9947**	0,0062	0,0088	0,9963**
Schumacher e Hall linearizado ($\beta_0 = -10,278962$; $\beta_1 = 1,867520$ e $\beta_2 = 1,120418$)						
3,0 × 0,5m	0,0033	0,0042	0,9934**	0,0022	0,0037	0,9985**
3,0 × 1,0m	0,0056	0,0086	0,9905**	0,0034	0,0050	0,9923**
3,0 × 1,5m	0,0045	0,0061	0,9980**	0,0052	0,0072	0,9960**
3,0 × 2,0m	0,0103	0,0158	0,9806**	0,0063	0,0079	0,9967**
3,0 × 3,0m	0,0092	0,0129	0,9875**	0,0140	0,0187	0,9764**
Geral	0,0066	0,0104	0,9942**	0,0062	0,0100	0,9950**

** significativo a 1% de probabilidade pelo teste t. MDA = média dos desvios absolutos; RQEM = Raiz Quadrada do Erro Médio e; r = coeficiente de correlação de Pearson.

Dentre as técnicas de modelagem via inteligência artificial, a random forest e MVS de base radial tiveram os melhores desempenhos na estimativa volumétrica dos fustes em diferentes arranjos espaciais. Para ambas as técnicas, observou-se similaridade entre as estatísticas de qualidade preditiva das opções de incluir ou não o espaçamento entre plantas como variável explicativa (Tabelas 3 e 4).

Tabela 3. Estatísticas de qualidade preditiva das aproximações por inteligência artificial (máquinas de vetores de suporte – MSV e random forest) para a estimativa do volume de árvores de eucalipto a partir das variáveis DAP e altura

Arranjo Espacial	---- Parametrização ----			----- Validação -----		
	MDA	RQEM	r	MDA	RQEM	r
----- Random Forest -----						
3,0 × 0,5m	0,0039	0,0053	0,9911**	0,0084	0,0113	0,9979**
3,0 × 1,0m	0,0066	0,0093	0,9884**	0,0059	0,0076	0,9860**
3,0 × 1,5m	0,0056	0,0072	0,9969**	0,0085	0,0107	0,9912**

3,0 × 2,0m	0,0105	0,0171	0,9777**	0,0065	0,0078	0,9951**
3,0 × 3,0m	0,0134	0,0166	0,9789**	0,0215	0,0264	0,9655**
Geral	0,0079	0,0120	0,9921**	0,0102	0,0146	0,9903**
----- MVS – Kernel Linear -----						
3,0 × 0,5m	0,0156	0,0201	0,9718**	0,0172	0,0207	0,9634**
3,0 × 1,0m	0,0146	0,0228	0,9455**	0,0117	0,0173	0,9366**
3,0 × 1,5m	0,0106	0,0130	0,9913**	0,0147	0,0201	0,9736**
3,0 × 2,0m	0,0165	0,0225	0,9606**	0,0098	0,0120	0,9925**
3,0 × 3,0m	0,0191	0,0243	0,9700**	0,0274	0,0305	0,9332**
Geral	0,0151	0,0206	0,9766**	0,0162	0,0210	0,9787**
----- MVS – Kernel Radial -----						
3,0 × 0,5m	0,0060	0,0068	0,9921**	0,0072	0,0080	0,9970**
3,0 × 1,0m	0,0065	0,0079	0,9941**	0,0054	0,0072	0,9871**
3,0 × 1,5m	0,0050	0,0062	0,9979**	0,0064	0,0081	0,9952**
3,0 × 2,0m	0,0103	0,0148	0,9823**	0,0046	0,0064	0,9967**
3,0 × 3,0m	0,0092	0,0122	0,9888**	0,0118	0,0131	0,9893**
Geral	0,0073	0,0101	0,9947**	0,0071	0,0089	0,9965**
----- MVS – Kernel Sigmoidal -----						
3,0 × 0,5m	0,7819	0,9720	-0,7607**	0,7578	0,9548	-0,5492 ^{ns}
3,0 × 1,0m	0,4056	0,5014	0,2612 ^{ns}	0,4350	0,4985	-0,1596 ^{ns}
3,0 × 1,5m	0,4099	0,4939	-0,1450 ^{ns}	0,4710	0,6902	-0,0669 ^{ns}
3,0 × 2,0m	0,3705	0,4233	0,2669 ^{ns}	0,3014	0,3576	-0,1424 ^{ns}
3,0 × 3,0m	0,5329	0,6478	-0,7683**	0,5849	0,6936	-0,9166**
Geral	0,4946	0,6306	-0,2964**	0,5100	0,6701	-0,4319**
----- MVS – Kernel Polinomial -----						
3,0 × 0,5m	0,0377	0,0478	0,8394**	0,0386	0,0506	0,7180*
3,0 × 1,0m	0,0353	0,0427	0,7120**	0,0414	0,0467	0,6381*
3,0 × 1,5m	0,0429	0,0487	0,8637**	0,0569	0,0624	0,7395**
3,0 × 2,0m	0,0445	0,0547	0,7502**	0,0524	0,0598	0,7388**
3,0 × 3,0m	0,0594	0,0755	0,8358**	0,0948	0,1309	0,7924**
Geral	0,0440	0,0549	0,8286**	0,0568	0,0766	0,7805**

^{ns}, *, ** não significativo e significativo a 5 e 1% de probabilidade pelo teste t, respectivamente. MDA = média dos desvios absolutos; RQEM = Raiz Quadrada do Erro Médio e; r = coeficiente de correlação de Pearson.

Tabela 4. Estatísticas de qualidade preditiva das aproximações por inteligência artificial (máquinas de vetores de suporte – MSV e random forest) para a estimativa do volume de árvores de eucalipto a partir das variáveis DAP, altura e espaçamento entre plantas

Arranjo Espacial	---- Parametrização ----			----- Validação -----		
	MDA	RQEM	r	MDA	RQEM	r
----- Random Forest -----						
3,0 × 0,5m	0,0066	0,0087	0,9859**	0,0084	0,0113	0,9979**

3,0 × 1,0m	0,0081	0,0100	0,9886**	0,0059	0,0076	0,9860**
3,0 × 1,5m	0,0074	0,0102	0,9947**	0,0085	0,0107	0,9912**
3,0 × 2,0m	0,0117	0,0177	0,9763**	0,0065	0,0078	0,9951**
3,0 × 3,0m	0,0165	0,0201	0,9753**	0,0215	0,0264	0,9655**
Geral	0,0100	0,0141	0,9898**	0,0102	0,0146	0,9903**
----- MVS – Kernel Linear -----						
3,0 × 0,5m	0,0156	0,0207	0,9720**	0,0171	0,0209	0,9642**
3,0 × 1,0m	0,0138	0,0218	0,9469**	0,0111	0,0163	0,9406**
3,0 × 1,5m	0,0106	0,0132	0,9913**	0,0149	0,0199	0,9731**
3,0 × 2,0m	0,0170	0,0226	0,9617**	0,0098	0,0124	0,9930**
3,0 × 3,0m	0,0191	0,0243	0,9711**	0,0274	0,0298	0,9351**
Geral	0,0150	0,0206	0,9766**	0,0161	0,0207	0,9793**
----- MVS – Kernel Radial -----						
3,0 × 0,5m	0,0045	0,0058	0,9907**	0,0044	0,0056	0,9972**
3,0 × 1,0m	0,0055	0,0070	0,9934**	0,0064	0,0081	0,9888**
3,0 × 1,5m	0,0059	0,0079	0,9965**	0,0097	0,0138	0,9860**
3,0 × 2,0m	0,0111	0,0154	0,9805**	0,0049	0,0063	0,9969**
3,0 × 3,0m	0,0096	0,0125	0,9886**	0,0108	0,0127	0,9898**
Geral	0,0073	0,0104	0,9942**	0,0072	0,0099	0,9952**
----- MVS – Kernel Sigmoidal -----						
3,0 × 0,5m	0,6837	0,8798	-0,9139**	0,7637	0,9170	-0,8987**
3,0 × 1,0m	0,2687	0,3393	0,1878 ^{ns}	0,2894	0,3447	-0,3518 ^{ns}
3,0 × 1,5m	0,2686	0,2977	0,6400**	0,4061	0,4564	0,4166 ^{ns}
3,0 × 2,0m	0,2429	0,2812	0,4923**	0,3091	0,3369	0,4637 ^{ns}
3,0 × 3,0m	0,6072	0,7327	-0,9830**	0,7115	0,8049	-0,9864**
Geral	0,4057	0,5528	-0,2974**	0,4959	0,6212	-0,4300**
----- MVS – Kernel Polinomial -----						
3,0 × 0,5m	0,0119	0,0211	0,9257**	0,0181	0,0242	0,9355**
3,0 × 1,0m	0,0233	0,0304	0,9344**	0,0371	0,0423	0,8414**
3,0 × 1,5m	0,0364	0,0417	0,8970**	0,0704	0,1028	0,6912*
3,0 × 2,0m	0,0465	0,0601	0,8227**	0,0568	0,0663	0,9261**
3,0 × 3,0m	0,0197	0,0275	0,9509**	0,0373	0,0551	0,8928**
Geral	0,0283	0,0393	0,9147**	0,0439	0,0639	0,8290**

^{ns}, *, ** não significativo e significativo a 5 e 1% de probabilidade pelo teste t, respectivamente. MDA = média dos desvios absolutos; RQEM = Raiz Quadrada do Erro Médio e; r = coeficiente de correlação de Pearson.

Por meio do teste F de Graybill, confirmou-se ausência de diferenças significativas ($p < 0,01$) entre as estimativas e observações volumétricas na fase de validação para as técnicas de modelagem T2, T3 com duas variáveis explicativas e T4 com três variáveis explicativas. Essas três técnicas de modelagem foram as únicas cujos resíduos padronizados foram distribuídos homocedasticamente (Figura 1). No entanto, a

modelagem via regressão apresentou maior dispersão de resíduos do que a aquela via inteligência artificial.

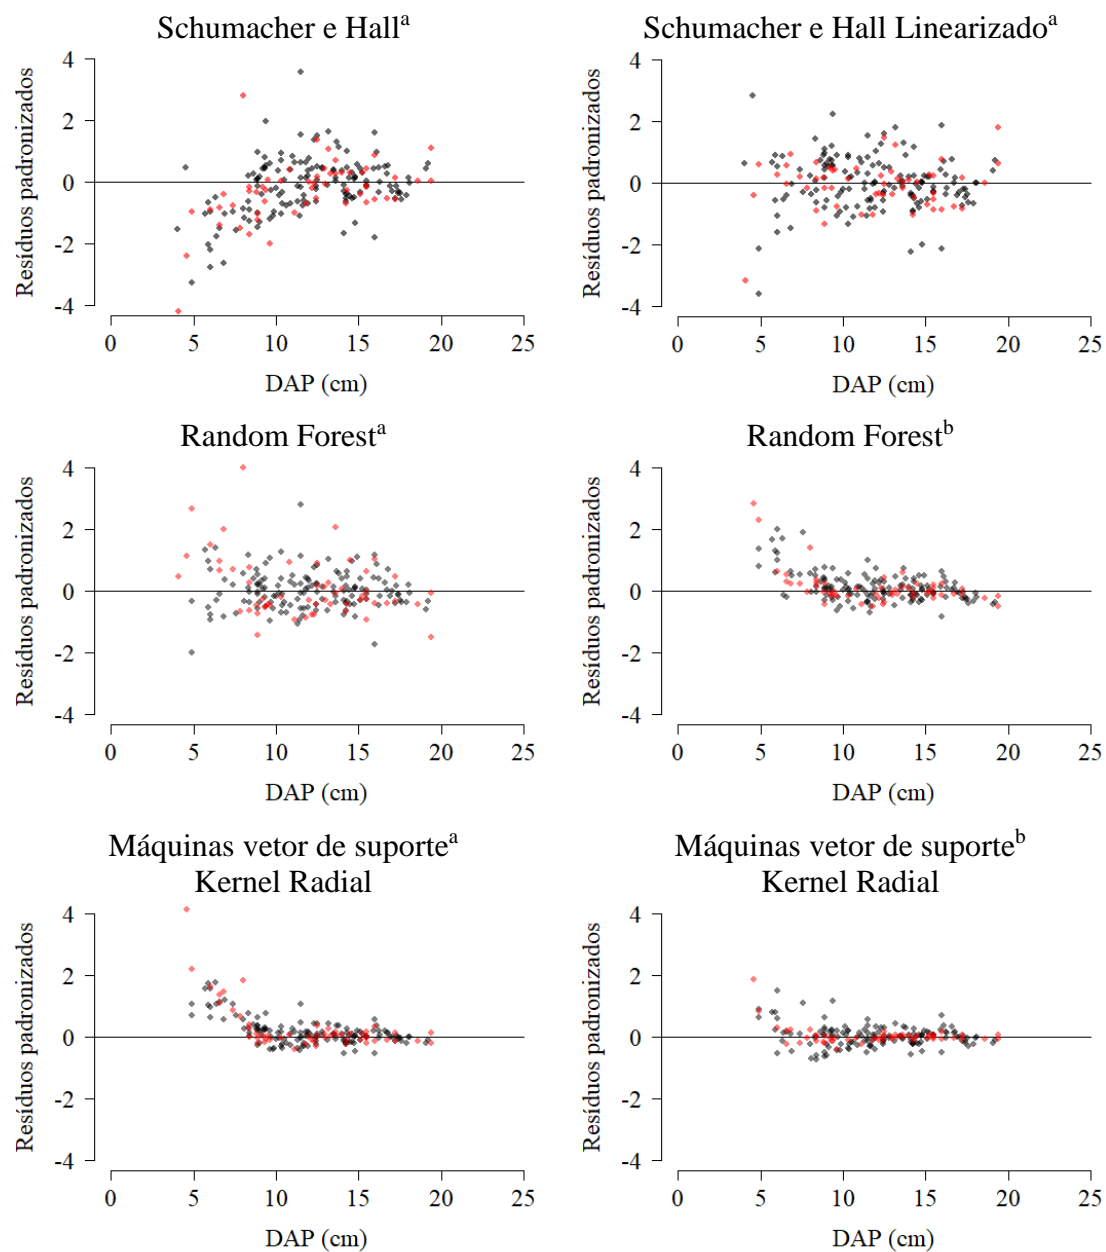


Figura 1. Gráficos de resíduos padronizados gerados a partir do ajuste do modelo de Schumacher e Hall (não linear e linearizado), random forest e máquinas de vetores de suporte com função Kernel de base radial. Grupos de parametrização e validação em preto e vermelho, respectivamente. ^aVolume estimado a partir de DAP e altura. ^bVolume estimado a partir de DAP, altura e espaçamento entre plantas.

Pela análise gráfica, a inclusão da variável explicativa espaçamento entre plantas contribuiu para a melhoria de qualidade preditiva via máquinas de vetor, concentrando

mais resíduos próximo ao eixo das abscissas e reduzindo a tendência de superestimava volumétrica nos menores diâmetros.

4 DISCUSSÃO

A análise simultânea de diferentes arranjos espaciais de plantio aumentou a amplitude de variação biométrica e contribuiu para a melhoria da qualidade preditiva das técnicas de modelagem, justificando o uso do método holdout de validação. No grupo de parametrização, os fustes de menor e maior DAP apresentaram 4,0 cm (altura de 10,2 m) e 19,2 cm (altura de 30,0 m) nos arranjos de $3,0 \times 0,5$ e $3,0 \times 0,3$ m, respectivamente. Na validação, as variações de DAP foram de 4,1 (altura de 10,2 m) a 19,4 cm (altura de 28,6 m) nos arranjos $3,0 \times 1,5$ e $3,0 \times 0,3$ m, nessa ordem.

A escolha do procedimento metodológico para a modelagem determina a precisão das estimativas volumétricas. As estatísticas de qualidade das fases de parametrização e validação foram similares entre si em todas as técnicas de modelagem (Tabelas 2, 3 e 4), indício de que não houve sobreparametrização dos dados (*overfitting*). Pela análise dessas estatísticas, não foi possível identificar com clareza a melhor técnica de modelagem. A análise gráfica da dispersão dos resíduos padronizados foi al para a discriminação do desempenho preditivo entre as técnicas testadas (Figura 1).

Os resíduos da equação de Schumacher e Hall (não linear) exibiu forte curvilinearidade, com perda em precisão caracterizada pela subestimativa de volume nos fustes de menor DAP. Por outro lado, a transformação logarítmica aplicada às variáveis do modelo foi útil para contornar a heterocedasticidade, assim como relatado por Campos et al. (1985) e Silva et al. (2009). Em virtude da ampla diversidade de arranjos espaciais, a qualidade do ajuste do modelo linearizado foi considerada satisfatória, fornecendo estimativas volumétricas precisas nas fases de parametrização e de validação (Tabela 2). A qualidade preditiva do volume foi confirmada visualmente na Figura 1, não sendo identificados vieses.

Encontrou-se maior dispersão residual nos fustes de menor DAP nos gráficos de resíduos em todas as técnicas de modelagem (Figura 1). Estes fustes contidos nas menores classes de diâmetro apresentaram maiores variabilidades volumétricas; coeficiente de variação de 37,35%, 23,11%, 19,74%, 14,95%, 12,03% e 6,10% para os centros de classe de 5,5, ... e 11,5cm (amplitude de 3cm), respectivamente. É provável que tal fato seja

consequencia da intensa competição que árvores menores são sujeitas, mais limitadas à disponibilidade de radiação luminosa, nutrientes e água (RESENDE et al., 2016). Assumindo como outliers aqueles resíduos padronizados além do intervalo de -3 a 3 , identificou-se que somente as MVS de base radial com três variáveis explicativas forneceram estimativas sem discrepâncias.

O desempenho preditivo das duas técnicas de inteligência artificial foi examinado em relação à estimativa volumétrica de árvores de eucalipto. O uso de duas variáveis explicativas para a modelagem via random forest não forneceu estimativas enviesadas para os diferentes arranjos espaciais, também, comprovado pelo teste F de Graybill. Todavia, seu desempenho preditivo foi prejudicado pela inclusão de uma terceira variável explicativa (espaçamento entre plantas), com superestimativas de volume em fustes de menor DAP e subestimativas naqueles de maiores dimensões. É importante salientar que estimativas enviesadas não são desejáveis para a quantificação de recursos florestais (CAMPOS; LEITE, 2017), principalmente, para fustes de maiores dimensões que possuem ampla representatividade no volume total.

Apesar da inclusão do espaçamento entre plantas como variável explicativa não ter contribuído estatisticamente para o ajuste do modelo de Schumacher e Hall (durante a fase exploratória dos dados) e da modelagem via random forest, o emprego de uma tripla entrada foi essencial para a precisão das máquinas de vetor. O emprego da função Kernel de base radial aumentou o desempenho dessas máquinas, tendo melhorias consideráveis em precisão quando comparada, especialmente, com as funções sigmoideal e polinomial (Tabelas 3 e 4). Essa melhoria preditiva com uso da função Kernel de base radial tem sido relatado em diversos trabalhos que envolvem a modelagem biométrica vegetal via máquinas de vetor (TRINDADE et al., 2019; LAFETÁ et al., 2020).

A implementação das MVS de base radial com três variáveis explicativas mostrou o melhor desempenho preditivo volumétrico de árvores de eucalipto em diferentes arranjos espaciais de plantio. Esse fato possui grande relevância prática e operacional, uma vez que informações mais precisas favorecem o planejamento da colheita, regulação, logística e assertividade da tomada de decisão por gestores florestais. Além disso, a implementação das máquinas de vetor em ambiente R é relativamente simples e de fácil execução, assim como, a técnica de regressão. Uma das principais diferenças entre as máquinas de vetor e random forest se referiu às gerações de soluções a partir de uma

mesma base de dados; as MVS de base radial convergiram para uma única solução ótima, sendo obtidas múltiplas soluções para a random forest.

Enquanto a implementação da técnica de random forest consistiu na geração e análise prévia de 100 parametrizações, foram obtidas apenas quatro máquinas de vetor, uma para cada função Kernel. A eficiência computacional e flexibilidade para a representação de diversos fenômenos naturais são aspectos que favorecem a aplicação de máquinas vetor (SILVA et al., 2017). Outro aspecto relevante é que o uso desta técnica de modelagem tem por objetivo principal a alta capacidade de generalização, buscando a minimização do erro de parametrização e de sua complexidade (CORDEIRO et al., 2015).

O sucesso da gestão florestal depende do detalhamento e da qualidade das informações disponíveis. Os métodos de modelagem demonstraram capacidade em representar informações biológicas, sendo promissoras para reduzir o esforço amostral em levantamentos volumétricos em inventários florestais e aumentar a precisão de estimativas. Os resultados obtidos fornecem subsídios importantes para o desenvolvimento de futuras pesquisas relacionadas à aplicação da inteligência artificial na modelagem biométrica. É conveniente ressaltar que técnicas de inteligência artificial, normalmente, não são sensíveis à colinearidade, normalidade ou linearidade (GÖRGENS et al., 2015). Portanto, não possuem as pressuposições clássicas da estatística paramétrica.

O interesse do setor florestal no uso de inteligência computacional, como as técnicas de random forest e MVS, aliada a aplicabilidade da modelagem volumétrica contribuem para a quantificação do estoque de crescimento em talhões comerciais (MONTAÑO et al., 2017). Esse potencial pode ser mais explorado em circunstâncias em que há restrições no uso de técnicas convencionais, como regressão. Enfatiza-se, ainda, que limitações no uso da inteligência artificial têm sido solucionadas devido a avanços tecnológicos da informática, facilitando parametrizações e a escolha da melhor alternativa de modelagem.

5 CONCLUSÕES

O uso das técnicas de máquinas vetor de suporte com função Kernel de base radial, random forest e o ajuste do modelo de Schumacher e Hall linearizado permite a obtenção de estimativas precisas do volume comercial com casca de árvores eucalipto em

diferentes arranjos espaciais de plantio. Alcançou-se maior precisão da estimativa volumétrica com a implementação das máquinas de vetor.

REFERÊNCIAS

- ALVES, J. de A. **Modelagem volumétrica em povoamentos de Eucalipto**. 2018. 132 p. Tese (Doutorado em Engenharia Florestal) - Universidade Federal de Lavras, Lavras, 2017.
- ANDRADE, V.C.L. et al. **Revisão sobre modelos volumétricos empregados em povoamentos florestais brasileiros**. *Advances in Forest Science*, v.6, n.1, p.561-566, 2019.
- ARAÚJO, T. A.; MOTA, F. C. M.; PEREIRA, R. S.; MIGUEL, É. P.; JÚNIOR, I. M. L. **Técnicas de modelagem florestal empregadas na estimativa volumétrica de eucalipto**. *ENCICLOPÉDIA BIOSFERA*, Centro Científico Conhecer, Goiânia, ano 2016, v. 13, n. 14, p. 1011, 5 dez. 2016.
- AZEVEDO, T. L.; MELLO, A. A.; FERREIRA, R. A.; SANQUETTA, C. R.; AKAJIMA, N. Y. **Equações hipsométricas e volumétricas para um povoamento de *Eucalyptus* sp. localizado na FLONA do Ibura, Sergipe**. *Revista Brasileira de Ciências Agrárias*, v. 6, nº 1, p. 105-112. 2011.
- BINOTI, M. L. M. da S. **Redes neurais artificiais em mensuração e manejo florestal. 2012**. Tese (Doutorado em Ciência Florestal) - Universidade Federal de Viçosa, Viçosa, MG.
- BREIMAN, L. **Bagging predictors**. *Machine Learning*, 24:123–140, 1996.
- BREIMAN, L. **Consistency For a Simple Model of Random Forests**. Technical Report 670, UC Berkeley, 2004.
- BREIMAN, L. **Random forests**. *Machine Learning*, 45:5–32, 2001.
- BREIMAN, L. **Some Infinity Theory for Predictor Ensembles**. Technical Report 577, UC Berkeley, 2000.
- CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal: perguntas e respostas**. 3.ed. rev. E ampl. Viçosa, MG: Universidade Federal de Viçosa, 2009. Pag. 94.
- CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal: perguntas e respostas**. 2.ed. Viçosa, MG: Universidade Federal de Viçosa, 2006. 470p.

CAMPOS, J. C. C.; TREVIZOL JÚNIOR, T. L.; PAULA NETO, F. Ainda, sobre a seleção de equações de volume. **Revista Árvore**, v. 9, n. 2, p. 115-126, 1985.

CAMPOS, J.C.C.; LEITE, H.G. **Mensuração florestal: perguntas e respostas**. 5. ed. Viçosa, MG: UFV, 2017. 636p.

CORDEIRO, M. A.; PEREIRA, N. N. J.; BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G. Estimativa do volume de *Acacia mangium* utilizando técnicas de redes neurais artificiais e máquinas vetor de suporte. **Pesquisa Florestal Brasileira**, v. 35, n. 83, p. 255-261, 2015.

CORDEIRO, M. A.; Pereira, N. N. J; BINOTI, D. H. B.; BINOTI, M. L. M. S.; LEITE, H. G. 2015. **Estimativa do volume de *Acacia mangium* utilizando técnicas de redes neurais artificiais e Máquinas Vetor de Suporte**. *Pesq. flor. bras.*, Colombo, v. 35, n. 83, p. 255-261, jul./set. 2015.

ELZHOV, T. V.; MULLEN, K. M., SPIESS, A.; BOLKER, B. **minpack.lm**: R interface to the Levenberg-Marquardt nonlinear least squares algorithm found in MINPACK, Plus Support for Bounds. R package version 1.2-1, 2016.

FREUND, Y. SHAPIRE, R. **Experiments with a new boosting algorithm**. In L. Saitta, editor, *Machine Learning: Proceedings of the 13th International Conference*, p. 148–156, San Francisco, 1996. Morgan Kaufmann

GENUER, R. POGGI, J. M. TULEAU, C. **Random Forests: Some Methodological Insights**. arXiv:0811.3619, 2008.

GÖRGENS, E. B.; MONTAGHI, A.; RODRIGUEZ, L. C. E. A performance comparison of machine learning methods to estimate the fast-growing forest plantation yield based on laser scanning metrics. **Computers and Electronics in Agriculture**, v. 116, p. 221-227, 2015.

GRAYBILL, F. A. **Theory and application of the linear model**. Belmont: Duxbury Press, 1976, 704p.

INSTITUTO NACIONAL DE METEOROLOGIA – INMET. **Banco de Dados Meteorológicos para Ensino e Pesquisa**. Brasília. Disponível em: <<http://www.inmet.gov.br/>>. Acesso em 20 jan. 2021.

KÖPPEN, W. **Das geographische system der klimate**. Berlin: Gerbrüder Bornträger, 1936. 44p.

LAFETÁ, B. O.; SILVA, F. F.; SANTOS, M. A.; PIMENTA, I. A.; FONTAN, I. C. I.; FONSECA, N. R.; SARTORI, C. J. Modelagem morfométrica de *Licania tomentosa* (Benth.) por regressão logística e máquina vetor de suporte. **Scientia Plena**, v. 16, n. 6, 060206, 2020.

LEITE, F. S.; RESENDE, A. V. **Estimativa do volume de madeira partindo do diâmetro da cepa em uma área explorada de floresta amazônica de terra firme.** Revista Ciência Florestal, Santa Maria, v. 20, n. 1, p. 69- 79, 2010.

LEITE, H. G.; ANDRADE, V. C. L. **Um método para condução de inventários florestais sem o uso de equações volumétricas.** Revista Árvore, v.26, n.3, p.321-328, 2002.

LIAW, A.; WIENER, M. Classification and Regression by randomForest. **R News**, v. 2, n. 3, p. 18-22, 2002.

MACHADO, S. do A.; URBANO, E.; CONCEIÇÃO, M. B. da. **Comparação de métodos de estimativa de bolome para *Pinus oocarpa* em diferentes idades e regimes de desbastes.** Boletim de Pesquisa Florestal, Colombo, n. 50, p. 81-98, 2005.

MEYER, D.; DIMITRIADOU, E.; HORNIK, K.; WEINGESSEL, A.; LEISCH, F.; CHANG, C.; LIN. C. **e1071:** Misc Functions of the Department of Statistics, Probability Theory Group (Formerly: E1071), TU Wien. R package version 1.6-8, 2017.

MIGUEL, E.P; CANZI, L.F; RUFINO, R.F; SANTOS, G.A. **Ajuste de modelo volumétrico e desenvolvimento de fator de forma para plantios de *Eucalyptus grandis* localizados no município de Rio Verde – GO.** Enciclopédia Biosfera Centro Científico Conhecer – Goiânia, v. 6, n.11, 2010. Disponível em: <http://www.conhecer.org.br/enciclop/2010c.htm>.

MONTAÑO, R. A. N. R.; SANQUETTA, C. R.; WOJCIECHOWSKI, J.; MATTAR, E.; CORTE, A. P. D.; TODT, E. Artificial intelligence models to estimate biomass of tropical forest trees. **POLIBITS**, v. 56, p. 29-37, 2017.

R CORE TEAM. **R: A language and environment for statistical computing.** Vienna: R Foundation for Statistical Computing. 2018.

RESENDE, R. T.; MARCATTI, G. E.; PINTO, D. S.; TAKAHASHI, E. K.; CRUZ, C. D.; RESENDE, M. D. V. Intra-genotypic competition of *Eucalyptus* clones generated by environmental heterogeneity can optimize productivity in forest stands. **Forest Ecology and Management**, v. 380, p. 50-58, 2016.

SCHNEIDER, P. R.; SCHNEIDER, P. S. P.; SOUZA, C. A. M. **Análise de Regressão aplicada à Engenharia Florestal**. 2. Ed- Santa Maria: FACOS, 2009. 294p.

SCHUMACHER, F. X.; HALL, F. S. Logarithmic expression of timber-tree volume. **Journal of Agricultural Research**, Washington, v.47, n.9, p.719-734, 1933.

SILVA, M. B. P.; ESCOBEDO, J. F.; SANTOS, C. M.; ROSSI, T. J.; SILVA, S. H. M. G. Performance of the Angstrom-Prescott Model (A-P) and SVM and ANN techniques to estimate the daily global solar irradiation in Botucatu/SP/Brazil. **Journal of Atmospheric and solar-terrestrial physics**, v. 160, p. 11-23, 2017.

SILVA, M. L. M. et al. Ajuste do modelo de Schumacher e Hall e aplicação de redes neurais artificiais para estimar volume de árvores de eucalipto. **Rev. Árvore**, Viçosa, v. 33, n. 6, p. 1133-1139, Dec. 2009. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-67622009000600015&lng=en&nrm=iso>. Acesso em 18 Jan. 2021.

SILVA, M. L. M.; BINOTI, D. H. B.; GLERIANI, J. M.; LEITE, H. G. Ajuste do modelo de Schumacher e Hall e aplicação de redes neurais artificiais para estimar o volume de árvores de eucalipto. **Revista Árvore**, v. 33, n. 6, p. 1133-1139, 2009.

SMOLA, A. J.; SCHOLKOPF, B. **A tutorial on support vector regression**. **Statistics and Computing**, n.14, p.199-222, 2004.

SOARES, C. P. B.; PAULA NETO, F.; SOUZA, A. P. **Dendrometria e Inventário florestal**. 2. Ed. – Viçosa: Editora UFV. 2011. 227p.

TAYLOR, J. S; CRISTIANINI, N. **Kernel Methods for Pattern Analysis**. Cambridge University Press, Cambridge, 2004.

THOMAS, C.; ANDRADE, C. M.; SCHNEIDER, P.R.; FINGER, C. A. G. Comparação de equações volumétricas ajustadas com dados de cubagem e análise de tronco. **Ciência Florestal**, Santa Maria, RS, v. 16, n.3, p. 319-327, 2006.

TRINDADE, R. N. R.; LAFETÁ, B. O.; AGUIA, V. F.; SILVA, A. G.; FERRARO, A. C.; PENIDO, T. M. A.; VIEIRA, D. S. Morfometria da copa de povoamentos de *Eucalyptus grandis* Hill ex Maiden x *E. urophylla* S. T. Blake em diferentes espaçamentos de plantio. **Scientia Forestalis**, v. 47, n. 121, p. 83-91, 2019.

VAPNIK, V. N. **The nature of statistical learning theory**. New York: Springer-Verlag, 1995. 188p.