







PREDIÇÃO DO VOLUME DE MADEIRA SERRADA UTILIZANDO MÁQUINA DE VETOR DE SUPORTE NA AMAZÔNIA

Jadson Coelho de Abreu¹, Robson Borges de Lima¹, Fernando Galvão Rabelo¹,
Perseu da Silva Aparício¹, Verena Holanda da Costa¹, Rodrigo Galvão Teixeira de
Souza¹

1 Universidade do Estado do Amapá, Macapá, AP, Brasil. E-mail: jadson.abreu@ueap.edu.br;
robson.lima@ueap.edu.br; fernando.rabelo@ueap.edu.br; perseu.aparicio@ueap.edu.br;
verena.holanda13@gmail.com; rodrigossouza55@hotmail.com
Autor correspondente: Jadson Coelho de Abreu. E-mail: jadson.abreu@ueap.edu.br.

RESUMO

O objetivo do presente trabalho é treinar o algoritmo de máquina de vetor de suporte para predição do volume de madeira serrada no Amapá. Foram utilizadas seis configurações de máquina de vetor de suporte, formadas a partir de duas funções de erro e três funções de *kernel*. Para o treinamento, considerou-se como variáveis de entrada: os diâmetros na base inferior e superior da tora, comprimento da tora, o volume da tora, além da variável categórica espécie, e como variável de saída, o volume de madeira serrada. Os algoritmos de máquina de vetor de suporte conseguiram aprender e generalizar o volume de madeira serrada.

Palavras-chave: Algoritmo; inteligência artificial; volumetria;

SAWN WOOD VOLUME PREDICTION USING SUPPORT VECTOR MACHINE IN THE AMAZON, BRAZIL

ABSTRACT

The objective of this work is to train the support vector machine algorithm for the prediction of lumber volume in Amapá, Brazil. Six support vector machine configurations were used, formed from two error functions and three kernel functions. For the training, it was considered as input variables: diameters at the lower and upper base of the log, length of the log, volume of the log, in addition to the categorical variable species, and as output variable, the volume of sawn wood. Support vector machine algorithms were able to learn and generalize lumber volume.

Key words: *Algorithm; artificial intelligence; volumetrics*



INTRODUÇÃO

No comércio de madeira, além do volume real de uma tora sem casca, é importante conhecer o volume de madeira serrada para definidos propósitos, com maior valor agregado estimar o valor monetário das florestas. Nos trópicos, cerca de 40% do comércio de madeira serrada resulta anualmente de florestas naturais (Payn *et al.*, 2015).

Técnicas modernas que otimizem a estimativa de volume de madeira serrada podem ser empregadas e obter resultados mais precisos. Nesse sentido, as técnicas de aprendizado de máquina podem ser fundamentais, não só para o fim de obter resultados mais precisos, mas também por poder utilizar uma menor quantidade de dados que leva a uma redução de custos no processo de cubagem.

Entre as técnicas de aprendizado de máquina, podemos citar a máquina de vetor de suporte (MVS) usada para classificação, no entanto também pode ser usada para regressão. Na regressão, o objetivo é encontrar uma função (h) que mais se aproxime da função real $f(x)$, para que esta função consiga prever o valor da variável dependente (y) através das variáveis independentes (x). A ligação dos pontos de x real e y predito gera uma linha e, esta linha deve ser semelhante da linha que é gerada pela ligação dos pontos x e y (Faceli *et al.*, 2011). Partindo da hipótese que os algoritmos de aprendizado de máquina conseguem solucionar problemas complexos, o objetivo do presente trabalho é treinar e validar o algoritmo de máquina de vetor de suporte para predição do volume de madeira serrada no Amapá.

MATERIAL E MÉTODOS

O trabalho foi desenvolvido com dados obtidos em uma serraria de médio porte, localizada na zona rural do Município de Porto Grande, Amapá (00° 41' 53,91" N e 51° 26',4,27" O). Foi avaliada a produção volumétrica de madeira em tora e serrada de nove espécies comerciais que são provenientes das explorações autorizadas nos planos de operação anual e que apresentam bom retorno econômico para a empresa, a saber: *Dinizia excelsa* Ducke, *Dipteryx odorata* L, *Manilkara huberi* L, *Carapa guianensis* Aubl, *Hymenolobium petraeum* Ducke, *Goupia glabra* Aubl, *Hymenaea courbaril* L, *Ocotea rubra* Mez e *Vochysia guianensis* Aubl.

Volume de madeira em tora e serrada

Para cada espécie foram selecionadas aleatoriamente 50 toras com diâmetro médio maior que 50 cm. Em cada tora, foram mensurados os diâmetros da base e do topo com casca, além do comprimento total e estimado o volume por meio de cubagem rigorosa pelo método de Smalian.

A madeira em tora foi transformada, por meio de desdobro tangencial em serra-fita vertical, gerando produtos de diversos formatos e dimensões de acordo com a demanda comercial da serraria. As medidas de espessura (E), em cada extremidade, foram obtidas com auxílio de um paquímetro. As medidas de largura (L), uma em cada extremidade do produto e o comprimento (C), foram mensuradas com auxílio de trena. O volume de cada produto foi determinado por meio

VI Encontro Brasileiro de Mensuração Florestal

da Equação: $Vp = E.L.C$. Após a determinação dos volumes dos produtos, eles foram somados, obtendo-se o volume em madeira serrada para cada tora processada.

Treinamento da máquina de vetor de suporte

Para o treinamento das máquinas de vetor de suporte (MVS) os dados foram separados de forma aleatória em que 70% foram utilizados para treinamento e 30% para validação. Foram utilizadas seis configurações de MVS, formadas a partir de duas funções de erro (Tipo I e Tipo II) e três funções de *kernel* (linear, polinomial, função de base radial [RBF]). Para o treinamento considerou-se como variáveis de entrada: os diâmetros na base inferior e superior da tora, comprimento da tora (L), o volume da tora (vt), além da variável categórica espécie, e como variável de saída, o volume de madeira serrada (vs). Para validação foram utilizadas as seguintes estatísticas: coeficiente de correlação entre os volumes observados e estimados ($r_{y\hat{y}}$), e raiz quadrada do erro quadrático médio (RQEM); bem como realizada a análise gráfica dos resíduos e da distribuição das frequências por classe de erros em percentagem. Todas as análises de dados foram realizadas pelo software R versão 4.1 utilizando o pacote *e1071*.

RESULTADOS E DISCUSSÃO

As seis configurações de máquinas de vetor de suporte (MVS) treinadas apresentaram boas estatísticas. A melhor MVS para o conjunto de treinamento foi o modelo RBF-II (Tabela 1). Trabalhos em que se usa um algoritmo de aprendizado de máquina para estimativa do volume de madeira serrada não são comuns, é mais comum trabalho para estimativa do volume do fuste em florestas plantadas (Cordeiro *et al.*, 2015; Binoti *et al.*, 2016) e florestas nativas (Abreu *et al.*, 2017).

Tabela 1. Estatísticas de treino e validação para os seis modelos de máquina de vetor de suporte

Modelo	Treino		Validação	
	RQEM	$r_{y\hat{y}}$	RQEM	$r_{y\hat{y}}$
Linear I	0,2521	0,8914	0,2570	0,8788
Linear II	0,2478	0,8924	0,2543	0,8781
Polinomial I	0,1493	0,9621	0,3288	0,8002
Polinomial II	0,1494	0,9620	0,3253	0,8044
RBF I	0,1207	0,9753	0,2992	0,8344
RBF II	0,1202	0,9755	0,2985	0,8353

Em que: RQEM = raiz quadrada do erro quadrático médio; $r_{y\hat{y}}$ = coeficiente de correlação entre os volumes observados e estimados

Na validação, a RBF perdeu um pouco do poder de generalização. A MVS Linear tipo I apresentou as melhores estatísticas de $r_{y\hat{y}}$ e RQEM, resultado esse comprovado pelos gráficos de distribuição dos resíduos e histograma de frequência do erro (Figura 1).

Os modelos Linear e RBF tipo I e II apresentaram boas distribuições de resíduos, no entanto alguns pontos foram notados fora de um intervalo admissível, porém mesmo com dois ou três

VI Encontro Brasileiro de Mensuração Florestal

pontos fora de um intervalo admissível, isso não influencia negativamente na estimativa do modelo (Costa *et al.*, 2012).

Na Figura 2 são apresentados os gráficos de valores observados versus estimados, gerados para o melhor modelo. Percebe-se que é apresentado pontos próximos à reta de 45°, sem a indicação de tendências nas estimativas.

O ajuste dos modelos de aprendizado de máquina otimiza e reduz a quantidade de dados observados, pois com apenas 70% dos dados seis dos oito modelos testados apresentaram boas estatísticas e conseguiram generalizar bem em uma nova base de dados. Para esse mesmo conjunto de dados, bons resultados foram encontrados por Lima *et al.* (2018) ajustando modelos de regressão por espécie. A vantagem dos métodos de aprendizado de máquina é que eles podem usar os dados simultâneos de todas as espécies em menor quantidade e mesmo assim gerar estatísticas próximas ou superiores aos modelos testados por espécie, gerando economia na coleta de dados para se estimar com precisão a variável de interesse.

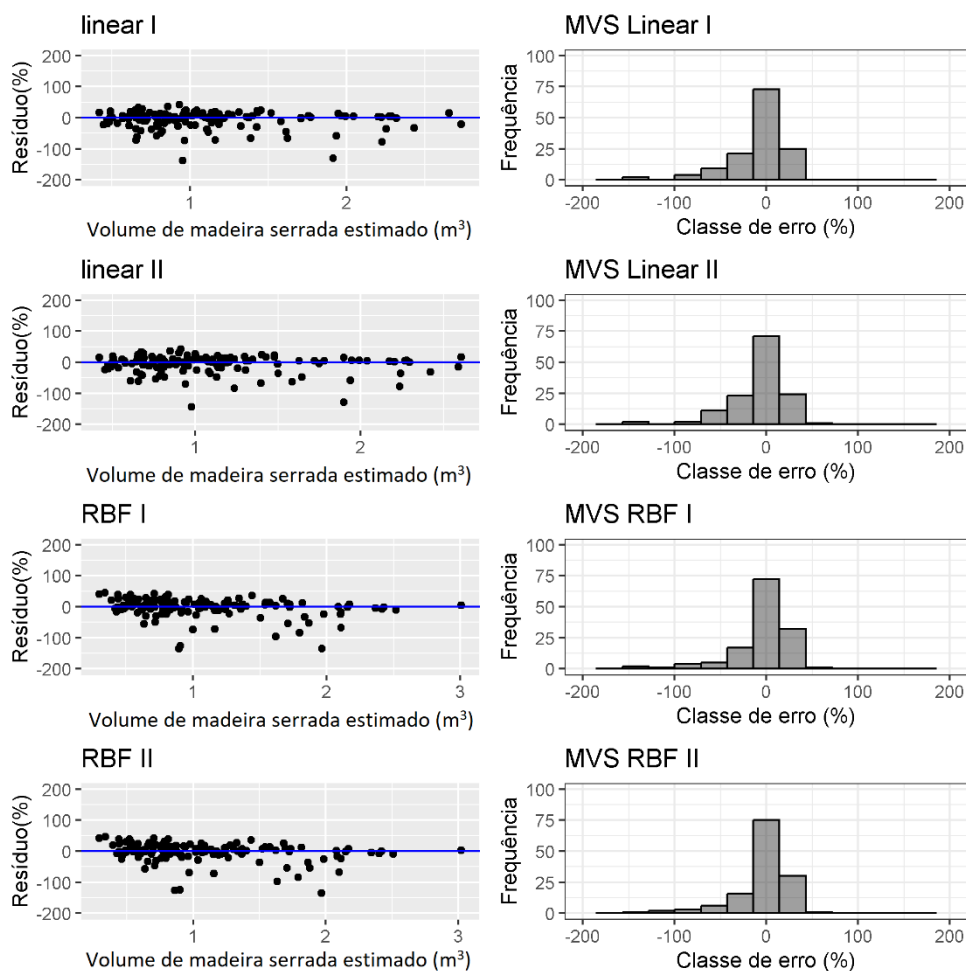


Figura 1. Distribuição gráfica e histograma dos resíduos em classe dos modelos de máquina de vetor de suporte. Em que: MVS = máquina de vetor de suporte; RBF = função de base radial

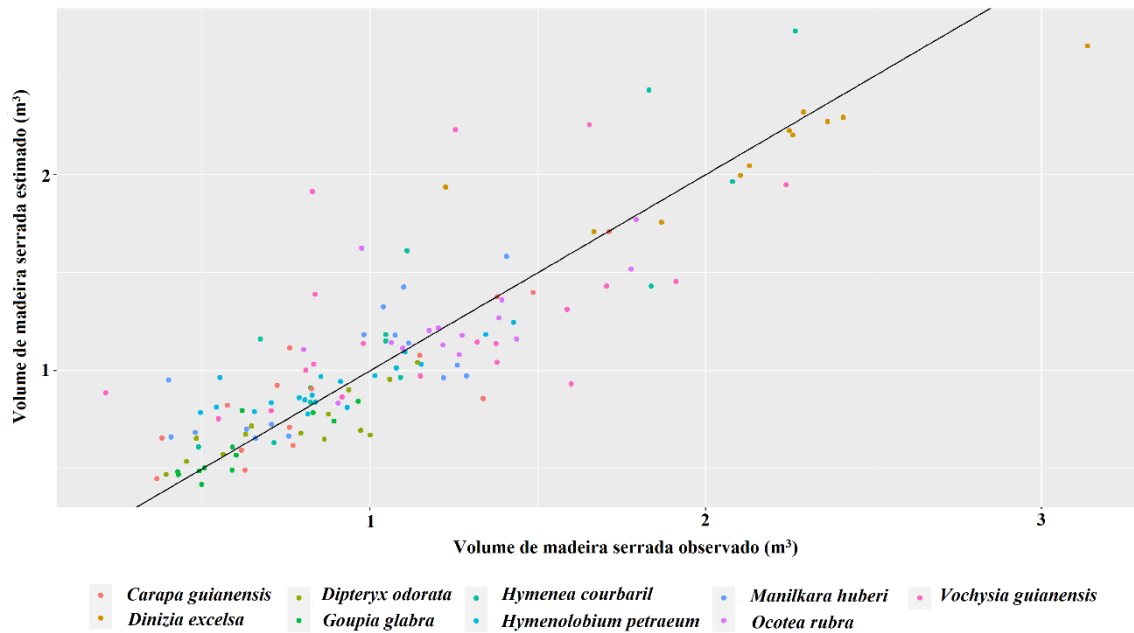


Figura 2. Predição volumétrica do modelo linear tipo I

CONCLUSÃO

Dentre as seis configurações de máquina de vetor de suporte utilizada para treinamento de madeira serrada a que apresentou as melhores estatísticas de validação foi a configuração com função *kernel* linear e erro tipo I.

REFERÊNCIAS BIBLIOGRÁFICAS

- Abreu, J. C.; Soares, C. P. B.; Leite, H. G. Assessing alternatives to estimate the stem volume of a seasonal semi-deciduous forest. **Floresta**, v. 47, n. 4, p. 375-382, 2017. <https://doi.org/10.5380/rf.v47i4.54259>.
- Binoti, D. H. B.; Binoti, M. L. M. S.; Leite, H. G.; Andrade, A. V.; Nogueira, G. S.; Romarco, M. L.; Pitangui, C. G. Support vector machine to estimate volume of eucalypt trees. **Revista Árvore**, v.40, n.4, p.689-693, 2016. <https://doi.org/10.1590/0100-67622016000400012>.
- 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. <https://doi.org/10.4336/2015.pfb.35.83.596>.
- Costa, T. R.; Campos, L.; Cysneiros, F. J. A.; Cunha Filho, M. Modelos lineares mistos: uma aplicação na curva de lactação de vacas da raça Sindi. **Revista Brasileira de Biometria**, v. 30, n. 1, p. 23 - 49, 2012. http://jaguar.fcav.unesp.br/RME/fasciculos/v30/v30_n1/A2_Resumo.pdf. 19 Mar. 2023.
- Faceli, K.; Lorena, A. C.; Gama, J.; Carvalho, A. C. P. L. F. **Inteligência artificial: uma abordagem de aprendizagem de máquina**. Rio de Janeiro: LTC, 2011.
- Lima, R. B.; Ferreira, R. L. C.; Silva, J. A. A.; Guedes, M. C.; Oliveira, C. P.; Silva, D. A. S.; Santos, R. M.; Carvalho, E. P.; Silva, R. M. A. Lumber volume modeling of Amazon Brazilian species. **Journal of Sustainable Forestry**, v.38, n.3, 262-274, 2018. <https://doi.org/10.1080/10549811.2018.1546596>.
- Payn, T.; Carnus, J.-P.; Freer-Smith, P.; Kimberley, M.; Kollert, M.; Liu, S.; Orazio, C.; Rodriguez, L.; Silva, L.N.; Wingfield, M.J. Changes in planted forests and future global implications. **Forest Ecology and Management**, v. 352, p. 57-67, 2015. <https://doi.org/10.1016/j.foreco.2015.06.021>.