



Máquinas de aprendizado extremo para a predição do volume de clones de eucaliptos

N. Soares

R. Santis

L. Goliatt

E. Aguiar

nielsonsoares@ymail.com

leonardo.goliatt@ufjf.edu.br

eduardo.aguiar@ufjf.edu.br

Universidade Federal de Juiz de Fora

Faculdade de Engenharia. Campus Universitário, 36036-330, Juiz de Fora, MG, Brasil

Abstract. *O eucalipto no Brasil apresenta suma importância para o desenvolvimento econômico do país. Neste cenário, a realização de um manejo florestal se faz necessário, a fim de se obter um planejamento ótimo para então explorar os plantios de forma efetiva. Uma das ações que compõem um manejo florestal é a estimação do volume das árvores exploradas, que é essencial para o planejamento. Este estudo propõe uma comparação abrangente de técnicas de máquinas de aprendizado extremo para a previsão de volume de eucaliptos. Os resultados mostraram que o método de máquinas de aprendizado extremo produziram respostas competitivas com as redes neurais, porém com um custo computacional menor.*

Palavras chaves: *Máquinas de aprendizado extremo, Eucaliptos, Engenharia Florestal, Inteligência Computacional*

INTRODUÇÃO

A cultura do eucalipto (*Eucalyptus*) no Brasil apresenta suma importância para o desenvolvimento econômico do país. Dados da indústria revelam 5,56 milhões de hectares de área plantada no país, localizados principalmente nos estados de Minas Gerais, São Paulo e Mato Grosso do Sul. Essa relevância se dá pela vasta utilização dessa espécie nas indústrias de base florestal, como os setores de celulose e papel, energia provinda de lenha industrial e carvão vegetal e também na produção de madeiras que são utilizadas na construção civil e na fabricação de móveis. Neste cenário, a realização de um manejo florestal se faz necessário, a fim de se obter um planejamento ótimo para então explorar os plantios de forma efetiva, extraíndo o máximo de recursos com menor custo. Uma das ações que compõem um manejo florestal é a estimação do volume de árvores exploradas. A determinação do volume produzido pela floresta plantada é necessária para se planejar o corte e a comercialização do produto final.

A fim de evitar o processo de derrubada de árvores para o processo de cubagem, estudos utilizando técnicas de predição têm sido realizados para estimação do volume. Os mais recentes estudos indicam uma tendência na aplicação de redes neurais artificiais para o dado problema. No entanto, existem na literatura outras técnicas de previsão com potencial de apresentar resultados mais precisos.

A cubagem, que é o processo de obtenção de volume de toras de madeira, pode ser feita em árvores derrubadas ou em pé [Leite and Rezende, 2010]. Com o objetivo de evitar a derrubada prematura de árvores, por ser um procedimento destrutivo e moroso, fórmulas volumétricas como a de Schumacher e Hall vêm sendo amplamente utilizados na predição do volume de árvores. Alternativamente, várias formas de se estimar o volume de árvores foram estudadas por diversos pesquisadores da área e diversos métodos de inteligência computacional foram aplicados para esse fim. Alguns desses estudos serviram de guia para o estudo aqui apresentado, como o de [da Silva et al., 2009], onde é aplicado o uso de redes neurais artificiais para estimar o volume de árvores de eucalipto e teca, onde eles encontram bons resultados e recomendam altamente o uso dessa aplicação. O estudo feito por [Binoti et al., 2014], em que ele avalia diferentes configurações para o treinamento de ANN para estimar o volume de árvores de eucalipto, chegando a conclusão que diversas configurações podem ser feitas afim de se atingir o objetivo. Outro estudo analisa a influência dessas configurações na hora de estimar o volume para uma árvore de eucalipto, chegando a conclusão de que a ANN deve ser construída com mais de 10 (dez) neurônios na primeira camada e também recomenda o uso de mais de uma camada intermediária [Gorgens et al., 2014]. Outro foi o trabalho de [Binoti et al., 2016], que objetivou-se testar a aplicação da técnica de Máquinas vetores de suporte (*Support Vector Machine* - SVM) para a estimação do volume de árvores de eucalipto.

Este trabalho tem por objetivo propor uma solução utilizando o método de Máquina de Aprendizado Extremo (*Extreme Learning Machine* - ELM). Para a seleção de modelos é empregada a técnica de validação cruzada com busca exaustiva nos parâmetros de cada modelo testado. Algumas métricas de desempenho são usadas para comparar as previsões a partir dos experimentos computacionais conduzidos. Os dados utilizados neste estudo foram provenientes de cubagens de 2.307 árvores de povoamentos clonais híbridos (*Eucalyptus grandis* x *Eucalyptus urophylla*) localizados no sul da Bahia. Na definição de estratificação de cubagens tradicionalmente usada foram definidos 53 estratos (definidos pela estratificação projeto e clone). As previsões de volume são comparadas com resultados obtidos com os métodos

de Regressão Linear, Ridge, Lasso e ANN. As máquinas de aprendizado extremo produziram resultados competitivos com as redes neurais, porém com um custo computacional menor.

Este trabalho está dividido em quatro seções. A segunda seção descreve o conjunto de dados, apresenta a abordagem proposta para a realização do estudo, descreve sobre técnicas utilizadas para melhorar a generalização dos modelos e as métricas empregadas para comparação. A terceira seção apresenta os resultados encontrados e uma discussão sobre os mesmos. Por fim, a última seção traz as conclusões acerca do estudo conduzido.

ABORDAGEM PROPOSTA

Conjunto de Dados

Os dados [da Silva et al., 2009] foram obtidos através do povoamento de clones de eucalipto e tiveram uma cubagem rigorosa. As variáveis de entrada dos modelos foram o DAP (diâmetro de altura de peito) e a altura total da árvore (Ht). O volume (V) foi utilizado como variável de saída. Segundo [da Silva et al., 2009], os volumes individuais da cubagem foram calculados pelo Método de Smalian. Foram considerados indivíduos com diâmetro mínimo comercial de 4 cm e seções com intervalo de 1 m ao longo do fuste. A expressão para o método de Smalian é mostrada na Eq.(1),

$$V = \frac{(A_t - A_b)}{2} c \quad (1)$$

onde V é o volume em m^3 ; A_t é a área da extremidade da seção em m^2 ; A_b é a área da base da seção em m^2 ; e c é o comprimento da seção em m.

O modelo volumétrico utilizado é dado pela equação linearizada de Shumacher e Hall, descrito pela Eq.(2)

$$\log(V) = \beta_0 + \beta_1 \log(DAP) + \beta_2 \log(Ht) + \epsilon \quad (2)$$

onde V é o volume em m^3 ; DAP é o diâmetro a 1,3 m de altura do solo em cm; Ht é a altura total da árvore em m; β_i , $i = \{0, 1, 2\}$ são parâmetros do modelo; e ϵ é o erro com distribuição normal. Para fins de comparação entre os valores preditos e os calculados para o volume, utiliza-se V ao invés de $\log(V)$.

Regressão Linear

A análise de regressão é um dos métodos mais utilizados para estimar coeficientes em um modelo linear. O comportamento dos dados é descrito pelo modelo mostrado na Eq. (3) [Hastie et al., 2009].

$$\hat{y} = \beta_0 + \sum_{i=1}^n x_i \beta_i \quad (3)$$

onde $\hat{y}$ é valor predito; x_i são as variáveis de entrada, $i = \{1, 2, \dots, n\}$, $n \in \mathbb{N}$; e β são parâmetros de ajuste da regressão.

Regressão Ridge - regularização L_2

A regressão Ridge escolhe o conjunto de coeficientes impondo uma penalidade de norma L_2 ao seu tamanho. Os coeficientes Ridge são obtidos através da minimização dos quadrados dos resíduos

$$\beta^{ridge} = \underset{\beta_0, \beta_1, \dots, \beta_k}{\operatorname{argmin}} \left\{ \sum_{i=1}^n \left(y_i - \beta_0 - \sum_{j=1}^k \beta_j x_{ij} \right)^2 + \lambda \sum_{j=1}^k \beta_j^2 \right\} \quad (4)$$

onde o parâmetro $\lambda \geq 0$ é o fator de regularização e controla o quão rigorosa é a penalização. Quanto maior for λ , maior será a penalização [Hastie et al., 2009].

A Eq. (4) pode ser representada vetorialmente por [Hastie et al., 2009]

$$\beta^{ridge} = (\mathbf{X}^T \mathbf{X} + \lambda \mathbf{I})^{-1} \mathbf{X}^T \mathbf{y} \quad (5)$$

onde

$$\mathbf{Y} = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix}, \quad \mathbf{X} = \begin{pmatrix} 1 & DAP_1 & Ht_1 \\ 1 & DAP_2 & Ht_2 \\ \vdots & \vdots & \vdots \\ 1 & DAP_n & Ht_n \end{pmatrix}$$

e o volume é estimado por

$$\mathbf{y} = \mathbf{X}\beta \quad (6)$$

onde β é o conjunto de coeficientes encontrados na regressão Ridge.

Regressão Lasso - regularização L_1

Os coeficientes Lasso são obtidos da mesma maneira que os da regressão Ridge, porém a penalização imposta sobre a soma dos quadrados é de norma L_1 ao invés de norma L_2 :

$$\beta^{lasso} = \underset{\beta_0, \beta_1, \dots, \beta_k}{\operatorname{argmin}} \left\{ \sum_{i=1}^n \left(y_i - \beta_0 - \sum_{j=1}^k \beta_j x_{ij} \right)^2 + \lambda \sum_{j=1}^k |\beta_j| \right\} \quad (7)$$

onde o fator de regularização $\lambda \geq 0$ controla a penalização aplicada. Quanto maior for λ , maior a penalização aos coeficientes. O volume predito é dado pela Eq. (5), onde β é o conjunto de coeficientes encontrados pela regressão Lasso.

Rede neuronal artificial

Uma rede neuronal pode ser definida como uma técnica de processamento paralelo e massivamente distribuído, composta por unidades de processamento simples, os neurônios, que tem uma tendência natural para guardar conhecimento experencial e torná-lo disponível para uso [Haykin, 2008]. O conhecimento é adquirido através de um processo de aprendizagem e pesos sinápticos são utilizados para o armazenar esse conhecimento.

De acordo com [Binoti et al., 2010], um neurônio artificial possui sete elementos básicos: sinais de entrada $\{x_1, x_2, \dots, x_n\}$; pesos sinápticos $\{w_1, w_2, \dots, w_n\}$; combinador linear $\{\sum\}$; limiar de ativação $\{\theta\}$; potencial de ativação $\{u\}$; função de ativação $\{g\}$ e sinal de saída $\{y\}$.

A Eq. 8 e a Eq. 9 representam o resultado produzido na saída de um neurônio artificial. Um modelo básico de um neurônio artificial pode ser visto na Figura 1.

$$u = \sum_{i=1}^n (w_i x_i) - \theta \quad (8)$$

$$y = g(u) \quad (9)$$




Figura 1: modelo de neurônio artificial simples

Uma ANN é composta de vários neurônios artificiais organizados em camadas, que são usualmente classificadas em três grupos: camada de entrada, camada de saída e camada intermediária ou oculta. A Fig. 2 mostra um exemplo de uma arquitetura simples para uma rede neuronal artificial.




Figura 2: Exemplo de uma RNA de 3 camadas, com 3 entradas e 1 saída

Máquina de aprendizado extremo

As máquinas de aprendizado extremo são redes neurais com arquitetura *feedforward* e com apenas uma única camada intermediária [Huang et al., 2006]. Os pesos da camada de entrada e da camada intermediária são escolhidos aleatoriamente, sem a necessidade de treinamento para ajustá-los, e os pesos da camada de saída são determinados de forma analítica, tornando o treinamento do modelo em um problema linear. Com isso, o tempo de treinamento

de uma ELM pode é relativamente menor quando comparado ao de uma ANN. Contudo, o número de neurônios na camada intermediária é relativamente maior em uma ELM. Com o uso das máquinas de aprendizado extremo busca-se reduzir o custo computacional na fase de treinamento e também um desempenho competitivo em generalização quando comparado à outros modelos [Huang et al., 2015].

O uso de técnicas de regularização podem melhorar a generalização do das máquinas de aprendizado extremo [Deng et al., 2009], proporcionando o equilíbrio entre o risco estrutural e o risco empírico, que compõem o risco de predição real, através de um fator de regularização de norma L_2 . Neste trabalho é proposto o uso de uma ELM regularizada (*Regularized Extreme Learning Machine* - ELM-R) como uma alternativa para melhorar o desempenho das estimativas de volume.

Seleção de modelos por validação cruzada e busca exaustiva

Um dos problemas relacionados aos modelos de predição é o chamado *overfitting*, que se dá quando não se tem acesso completo aos dados ou a quantidade de amostras é relativamente pequena, fazendo com que o modelo fique condicionado aos dados de treino, falhando, assim, na validação quando dados diferentes são utilizados. Uma das alternativas para esse tipo de problema é a aplicação da técnica de validação cruzada *k-fold*. Essa técnica consiste na separação de k subconjuntos de igual tamanho, onde destes, $k - 1$ subconjuntos são utilizados no treinamento do modelo e um serve como base para a validação do mesmo.

Este processo é repetido k vezes, utilizando um conjunto de teste distinto em cada iteração. A Fig. 3 mostra um exemplo da divisão do conjunto de dados em $k = 5$ subconjuntos a cada iteração do processo da validação cruzada.




Figura 3: Divisão do conjunto de dados em $k = 5$ subconjuntos (folds)

Grid search

Na aplicação de qualquer um dos métodos anteriormente descritos, é necessário que haja um ajuste de parâmetros a fim de se alcançar a melhor configuração para a execução dos processos. Para buscar a melhor configuração de parâmetros para os modelos, emprega-se a técnica denominada *grid search* (busca em grade), que consiste em uma busca exaustiva no espaço de parâmetros definidos pelo usuário. O modelo então é treinado para cada configuração de

parâmetros e depois avaliado por meio de validação cruzada. A partir dessa validação, a configuração contendo os parâmetros que produziram os melhores resultados com o método empregado é a escolhida [Bergstra and Bengio, 2012].

Métricas de avaliação

De modo a avaliar o desempenho de previsão dos modelos, foram utilizadas neste trabalho três métricas de avaliação: o coeficiente de determinação R^2 , o erro percentual absoluto médio (*Mean Absolute Percentage Error* - MAPE) e o erro quadrático médio (*Mean Squared Error* - MSE). Representando os valores preditos pelos modelos por $\hat{y}$, os valores reais calculados por y , a média dos valores reais calculados por $\bar{y}$ e o número de amostras por N , podemos definir as métricas conforme mostrado abaixo.

O coeficiente de determinação R^2 é escrito como:

$$R^2(y, \hat{y}) = \frac{\sum_{i=1}^N (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (10)$$

Sendo que o valor do R^2 varia entre 0 e 1, e quanto mais próximo de 1, mais representativo é o modelo.

O erro percentual absoluto médio (MAPE) é definido como:

$$\text{MAPE}(y, \hat{y}) = \frac{1}{N} \sum_{i=1}^N \frac{|y_i - \hat{y}_i|}{|y_i|} \times 100 \quad (11)$$

E o erro quadrático médio (MSE) é dado por:

$$\text{MSE}(y, \hat{y}) = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (12)$$

RESULTADOS E DISCUSSÃO

Os métodos foram desenvolvidos utilizando a linguagem de programação *python* juntamente com a biblioteca *scikit-learn* [Pedregosa et al., 2011], que possui ferramentas para o desenvolvimento de métodos de aprendizado de máquina. A predição do volume baseou-se na Eq. (2), que é a equação linearizada de Schumacher e Hall.

Para se obter uma melhor generalização, e assim melhores resultados, cada modelo teve o processo de treinamento repetido 30 vezes, onde para cada iteração foi utilizado a técnica de validação cruzada, apresentada na Seção 2.7. Com o objetivo de avaliar o impacto da regularização no modelo de Schumacher, foram testados os modelos SCH-L1 e SCH-L2 que correspondem ao modelo dado Eq. (2) acrescido de regularização L_1 e L_2 . Em cada uma das

Tabela 1: Conjunto de parâmetros de cada método para o uso da técnica de *grid search*

Modelos	Descrição dos parâmetros	Variação dos Parâmetros
ANN	Camada escondida	[5], [10], [20], [10,10], [5,5], [5,5,5]
	Taxa de aprendizado	0.001, 0.01, 0.1
	Função de ativação	logistic, tanh, relu
ELM	Camada oculta	[10], [30], [50], [80], [100], [120], [150], [200]
	Função de ativação	Sigmóide, Tangente Hiperbólica, Gaussiana, Multiquádrica e Multiquádrica Inversa
	Camada oculta	[10], [30], [50], [80], [100], [120], [150], [200]
ELM-R	Função de ativação	Sigmóide, Tangente Hiperbólica, Gaussiana, Multiquádrica e Multiquádrica Inversa
	α	10^{-1} , 10^{-2} , 10^{-3} , 10^{-4} , 10^{-5} , 10^{-6}
SCH	-	Sem parâmetros de ajuste
SCH-L1	α	10^{-1} , 10^{-2} , 10^{-3} , 10^{-4} , 10^{-5} , 10^{-6}
SCH-L2	α	10^{-1} , 10^{-2} , 10^{-3} , 10^{-4} , 10^{-5} , 10^{-6}

30 execuções independentes, o conjunto original foi dividido em dez subconjuntos ($k = 10$), e em seguida foi aplicada a técnica de *grid search* nos parâmetros mostrado na Tabela 1.

A Tabela 2 mostra as médias e os desvios padrões em 30 iterações independentes das métricas usadas para comparação. Os valores das médias e desvios padrões foram usados de forma a garantir uma maior confiabilidade na avaliação do desempenho dos modelos. A partir dos resultados apresentados nessa tabela, analisando-se o coeficiente R^2 , que todos os modelos tiveram bons resultados, indicando uma boa representatividade dos mesmos. A rede neuronal e a máquina de aprendizado extremo apresentaram resultados levemente melhores. Analisando o erro quadrático médio (MSE) e o erro percentual absoluto médio (MAPE), observa-se que ANN, ELM e ELM-R possuem menor média, mas a regressão linear e com regularização L_1 e L_2 possuem uma menor variância desse erro, como pode ser visto pelo desvio padrão.

Tabela 2: Resultados das métricas de avaliação para cada modelo

Modelos	R^2	R	MSE	$MAPE$
ANN	0.992 (0.0002138)	0.996 (9.544e-05)	0.0002293 (6.059e-06)	6.021 (0.052)
ELM	0.992 (0.000164)	0.996 (8.13e-05)	0.0002286 (4.65e-06)	6.037 (0.067)
ELM-R	0.992 (0.0004102)	0.996 (0.0001744)	0.0002282 (1.163e-05)	6.017 (0.087)
SCH	0.989 (5.561e-05)	0.995 (2.153e-05)	0.0003244 (1.576e-06)	7.274 (0.010)
SCH-L1	0.989 (5.559e-05)	0.995 (2.153e-05)	0.0003245 (1.576e-06)	7.275 (0.010)
SCH-L2	0.989 (5.314e-05)	0.996 (2.107e-05)	0.0003121 (1.506e-06)	7.248 (0.010)




Figura 4: Boxplot das métricas para os modelos de predição

A Fig. 4 apresenta os resultados em *boxplots* onde essas relações podem ser vistas mais claramente. Os modelos ANN, ELM e ELM-R apresentaram os melhores resultados, com destaque para o último. Nota-se a existência de *outliers* para os mesmos, o que explica um maior desvio padrão na Tabela 2.

A Fig. 5 mostra a relação entre os valores dos volumes preditos pelos modelos e os valores dos volumes reais calculados. A reta de regressão serve de referência para analisar essa




Figura 5: Gráfico com a melhor regressão (menor $MAPE$) de cada modelo aplicado

relação. Todos os modelos apresentaram resultados satisfatórios para um volume baixo, porém para volume maiores, os pontos no gráfico se tornam mais dispersos indicando maior erro de previsão. As máquinas de aprendizado extremo, juntamente com a rede neuronal, apresentam uma dispersão menor e consequentemente menores erros.

Os experimentos computacionais e o conjunto de métricas empregadas neste trabalho permitem realizar uma avaliação consistente e análises conclusivas do desempenho comparativo das máquinas de aprendizado extremo. O trabalho de [da Silva et al., 2009] também resolve o problema abordado por este, porém todos os resultados foram apresentados de forma qua-

litativa, por meio de gráficos de dispersão, dificultando uma comparação entre os resultados obtidos aqui.

CONCLUSÃO

Este trabalho propôs a utilização de máquina de aprendizado extremo para a predição de volume de árvores. Esses modelos são uma variação de redes neurais artificiais, e podem apresentar melhores resultados com custo computacional menor. O uso de validação cruzada e *grid search* garantiu a melhor configuração para os métodos aqui aplicados.

Os resultados mostram que o método de máquinas de aprendizado extremo apresentou resultados competitivos com a rede neuronal, porém com um custo computacional menor, visto que para o ELM é necessário ajustar somente os pesos da camada de saída. Além disso, as máquinas de aprendizado extremo produziram resultados melhores que os obtidos pela regressão linear sem regularização, com regularização L_1 e regularização L_2 . Isso indica que os modelos de ELMs são eficazes para resolver problemas de predição de volume de árvores e surgem como uma alternativa interessantes aos métodos propostos atualmente.

Como o eucalipto possui grande importância econômica para as indústrias de base florestal e o seu plantio ocupa 71,9% do total de hectares da área de árvores plantadas no Brasil [Iba, 2015], qualquer melhora no desempenho da estimativa de volume sobre a plantação pode garantir um melhor planejamento do manejo florestal e com isso aumentar o ganho de produção. Mesmo que o ELM tenha apresentado uma melhora relativamente pequena em relação à regressão linear, essa pequena melhora pode se tornar mais significativa devido a elavada quantidade de árvores que serão analisadas.

REFERÊNCIAS

- [Bergstra and Bengio, 2012] Bergstra, J. and Bengio, Y. (2012). Random search for hyperparameter optimization. *Journal of Machine Learning Research*, 13(Feb):281–305.
- [Binoti et al., 2016] Binoti, D. H. B., Binoti, M. L. M. d. S., Leite, H. G., Andrade, A. V., Nogueira, G. S., Romarco, M. L., and Pitangui, C. G. A. (2016). SUPPORT VECTOR MACHINE TO ESTIMATE VOLUME OF EUCALYPT TREES. *Revista Árvore*, 40:689 – 693.
- [Binoti et al., 2014] Binoti, D. H. B., da Silva Binoti, M. L. M., and Leite, H. G. (2014). Configuração de redes neurais artificiais para estimação do volume de árvores. *Revista Ciência da Madeira (Brazilian Journal of Wood Science)*, 5(1):10–12953.
- [Binoti et al., 2010] Binoti, M. L. M. d. S. et al. (2010). Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto.
- [da Silva et al., 2009] da Silva, M. L. M., Binoti, D. H. B., Gleriani, J. M., and Leite, H. G. (2009). Ajuste do modelo de schumacher e hall e aplicação de redes neurais artificiais para estimar volume de árvores de eucalipto. *Revista Árvore*, 33(6).
- [Deng et al., 2009] Deng, W., Zheng, Q., and Chen, L. (2009). Regularized extreme learning machine. In *Computational Intelligence and Data Mining, 2009. CIDM'09. IEEE Symposium on*, pages 389–395. IEEE.
- [Gorgens et al., 2014] Gorgens, E. B., Leite, H. G., Gleriani, J. M., Soares, C. P. B., and Ceolin, A. (2014). Influência da arquitetura na estimativa de volume de árvores individuais por meio de redes neurais artificiais. *Revista Árvore*, 38(2).
- [Hastie et al., 2009] Hastie, T., Tibshirani, R., and Friedman, J. (2009). *The Elements of Statistical Learning - Data Mining, Inference, and Prediction*. Springer, New York, Verlag, New York, 2 edition.
- [Haykin, 2008] Haykin, S. O. (2008). *Neural Networks and Learning Machines*. Prentice Hall, New Jersey - USA, 3 edition.
- [Huang et al., 2015] Huang, G., Huang, G.-B., Song, S., and You, K. (2015). Trends in extreme learning machines: A review. *Neural Networks*, 61:32 – 48.
- [Huang et al., 2006] Huang, G.-B., Zhu, Q.-Y., and Siew, C.-K. (2006). Extreme learning machine: theory and applications. *Neurocomputing*, 70(1):489–501.
- [Iba, 2015] Iba (2015). Relatório Ibá 2015. Technical report, Indústria Brasileira de Árvores.
- [Leite and Rezende, 2010] Leite, F. S. and Rezende, A. V. (2010). ESTIMATIVA DO VOLUME DE MADEIRA PARTINDO DO DIAMETRO DA CEPA EM UMA AREA EX-

PLORADA DE FLORESTA AMAZONICA DE TERRA FIRME. *Ciência Florestal*, 20:69 – 79.

[Pedregosa et al., 2011] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., et al. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12:2825–2830.