



27 a 29 de agosto | Maceió, AL



APLICAÇÃO DE REDES NEURAIS NA MODELAGEM DO AFILAMENTO DO FUSTE EM FLORESTAS DE VÁRZEA ESTUARINA*

Verena Holanda da Costa^{1*}, Tainara Samilly Barros de Oliveira², Anderson Ribeiro Torres³, Josué Henrique Borges Ramos⁴, Jadson Coelho de Abreu⁵, Robson Borges de Lima⁶

Universidade do Estado do Amapá^{1, 2, 3, 4, 5 e 6}

* holandaverena43@gmail.com

RESUMO

O objetivo do presente trabalho foi treinar e validar diferentes configurações de redes neurais artificiais para estimativa do afilamento do fuste em uma floresta de várzea estuarina. A arquitetura das redes neurais teve como input (entrada) altura a qualquer parte do tronco hi, altura do fuste hfi, diâmetro a 1, 30 m do solo Di (variável categórica), e diâmetro a qualquer parte do tronco di como output (saída), com variação de número de neurônios na camada intermediária variando de 1 a 12 e, diferentes algoritmos de aprendizado. Na estimativa do afilamento, foi empregado os critérios estatísticos: bias, correlação entre volume observado e estimado (r^2) e raiz quadrada do erro quadrático médio (RQEM). Foram elencadas às 3 RNA's com melhores resultados de cada algoritmo, e as configurações com 10 neurônios na camada intermediária para o *Resiliente Propagation* e 11 para o *Simulated Annealing* conseguiram fazer uma boa estimativa para o afilamento do fuste.

Palavras-chave: Aprendizado de máquina; Modelagem florestal; Dendrometria.

INTRODUÇÃO

As florestas de várzea estão localizadas principalmente às margens de rios de águas barrentas e são influenciadas pelos regimes de marés. No estado do Amapá, as maiores florestas de várzea estuarina estão presentes ao longo da costa amazônica, penetrando nos estuários e nas partes inferiores dos diversos rios que deságuam na região (zee, 2008).

Esses ambientes tem uma grande diversidade de espécies que podem ser usadas para fins madeireiros. Sendo que os volumes dessas árvores podem ser quantificados por meio de equações de volume e afilamento. A utilização de funções de afilamento no setor florestal tem contribuído para a otimização dos recursos florestais. Essas funções, devido à sua flexibilidade, permitem uma estratificação, ou seja, uma quantificação dos múltiplos produtos disponíveis para as diversas dimensões pré-estabelecidas (Bernardi *et al.*, 2021). As funções de afilamento desempenham um papel fundamental na determinação do volume de árvores e toras, pois permitem estimar três características básicas das árvores: o diâmetro em qualquer ponto do fuste, a altura no fuste em que se encontra um determinado diâmetro e o volume entre dois pontos quaisquer no fuste (Costa *et al.*, 2024.)

Uma alternativa que pode apresentar resultados iguais ou superiores aos modelos tradicionais de afilamento, são as redes neurais artificiais (RNA's). Essas, são um algoritmo de aprendizado de máquina, caracterizado pela inspiração nos modelos biológicos (Leal *et al.*, 2020), sendo executado por arquiteturas paralelas complexas (hyari *et al.*, 2015; Barros, 2019). (costa *et al.*, 2016). Portanto, o objetivo deste estudo foi treinar e validar diferentes configurações de redes neurais artificiais para estimar o afilamento do fuste em uma floresta de várzea estuarina.

MATERIAL E MÉTODOS

O estudo foi realizado em uma floresta de várzea estuarina no distrito de Itatupã, Gurupá-PA. Foram coletados dados de Di, hfi, di e hi por meio de inventário florestal. Redes neurais artificiais do tipo *Multilayer Perceptron* foram treinadas com mil unidades, utilizando Di, hfi e hi como entradas e di como saída, com variação de 1 a 12 neurônios na camada intermediária.




Figura 1. Exemplificação da estrutura das RNA's

As redes neurais foram treinadas usando os algoritmos *Resilient Propagation* e *Simulated Annealing*, com critérios de parada definidos por erro quadrático médio $\leq 0,001$ ou mil ciclos. Utilizaram-se funções lineares e sigmóides. A seleção da melhor topologia baseou-se em bias, correlação ($r_{\hat{y}\hat{y}}$) e RQEM. O treinamento foi realizado no *software* Neuro 4.0.6, com 70% dos dados para treino e 30% para validação. A fim de garantir resultados objetivos e imparciais, a avaliação da melhor topologia das redes neurais artificiais na estimativa do afilamento do fuste se baseou em critérios estatísticos, a saber: bias, correlação entre o volume observado e estimado ($r_{y\hat{y}}$) e a raiz quadrada do erro quadrático médio (RQEM). Todas as etapas do treinamento das RNA foram conduzidas com o auxílio do *software* Neuro 4.0.6, buscando assim obter resultados precisos e robustos para o objetivo proposto neste estudo.

RESULTADOS E DISCUSSÃO

Algoritmo	RNA	R	RQME	BIAS
<i>Resilient propagation</i>	RNA 5	0,9494	0,0228	-0,3491
	RNA 11	0,9516	0,0685	-0,2802
	RNA 12	0,9502	0,0574	-0,0334
<i>Simulated Annealing</i>	RNA 9	0,9472	0,0358	-0,1845
	RNA 10	0,9487	0,0318	-0,2994
	RNA 5	0,9467	0,0330	-0,0425

Tabela 1. Estatísticas das RNA's por algoritmo

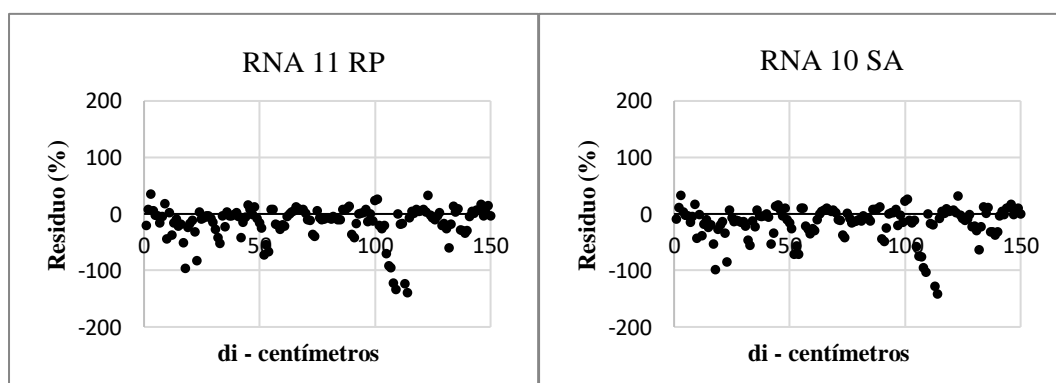


Figura 2. Gráficos de dispersão de resíduos para os algoritmos *Resilient Propagation* (RP) e *Simulated Annealing* (SA).

No contexto do algoritmo *Resilient Propagation*, as três Redes Neurais Artificiais (RNAs) de destaque foram identificadas como sendo a RNA 11, a RNA 12 e a RNA 5, em ordem sequencial. Notavelmente, a RNA 11 se destacou ao apresentar o valor de correlação mais próximo de 1 entre as RNAs avaliadas, bem como os valores de Erro Quadrático Médio (RQME) e Biais mais próximos de zero. Essas características indicam que a

RNA 11 demonstrou uma notável precisão na tarefa de estimar o afilamento, em consonância com as descobertas previamente reportadas por Cunha Neto *et al.* (2019). O estudo de Schikowski *et al.* (2015) obteve bons resultados na estimativa do fuste de eucalipto com Redes Neurais Artificiais (RNAs) contendo 7 e 8 neurônios na camada oculta. Embora o presente estudo tenha utilizado RNAs com 12 e 5 neurônios, os resultados também foram satisfatórios. Os coeficientes de correlação foram semelhantes entre os estudos, alinhando-se com Campos *et al.* (2017), que observaram bons desempenhos com 6 ou 8 neurônios. Isso indica que, na área florestal, modelos de RNAs simples já são eficazes na estimativa do afilamento do fuste.

Os resultados de Erro Quadrático Médio (RQME) e média (bias) mostraram-se próximos de zero, indicando boa precisão, com destaque para a RNA 5, que obteve o RQME mais baixo. Esses dados reforçam as conclusões de Martins *et al.* (2016), que alertam que redes com muitos neurônios podem sofrer *overfitting*, prejudicando a capacidade de generalização do modelo. A homogeneidade dos dados, evidenciada pelos gráficos, mostra que a dispersão dos resíduos foi semelhante entre as diferentes configurações de RNAs. Isso indica estabilidade do algoritmo aliado à função sigmoide, demonstrando que as redes são robustas e fornecem estimativas confiáveis do afilamento do fuste, mesmo com variações em suas configurações.

No uso do algoritmo *Simulated Annealing*, as RNAs 10, 9 e 5 se destacaram na estimativa do afilamento do fuste, com a RNA 10 apresentando o valor de correlação mais próximo de 1. Embora a RNA 5 tenha tido o menor desempenho entre as três, ainda mostrou bons resultados. As métricas obtidas com *Simulated Annealing* foram mais próximas das do algoritmo *Resilient Propagation* do que do *Backpropagation*. Os resultados obtidos neste estudo contrastam com os de Martins *et al.* (2016), que observaram desempenho insatisfatório com o *Simulated Annealing*, evidenciando a eficácia do método neste caso específico. Essas discrepâncias sugerem a importância de considerar a especificidade dos dados e do problema em questão ao avaliar a eficácia de diferentes algoritmos de treinamento de redes neurais. Portanto, os resultados deste estudo indicam que, para a tarefa de estimar o afilamento do fuste em árvores, o *Simulated Annealing* pode ser uma alternativa viável e eficaz, ao contrário das conclusões anteriores baseadas em diferentes contextos ou conjuntos de dados.

É interessante notar que os resultados de Binoti *et al.* (2014) em seu estudo de estimativa de volume em um povoamento florestal de eucalipto usando configurações de redes neurais com o *Simulated Annealing* não foram satisfatórios. Essa discrepância em relação aos resultados do presente estudo sublinha a influência significativa que a natureza dos dados e as características específicas do problema podem exercer sobre o desempenho dos algoritmos de treinamento de redes neurais.

A eficácia do *Simulated Annealing* pode variar conforme o contexto e as condições do estudo. Por isso, a escolha do algoritmo de treinamento deve considerar as características do problema e a qualidade dos dados. As diferenças entre estudos reforçam a importância de validar e adaptar os modelos às especificidades de cada pesquisa.

CONCLUSÕES

- Todas as configurações de Redes Neurais Artificiais (RNAs) apresentaram bom desempenho na estimativa do afilamento do fuste para espécies em floresta de várzea.
- O algoritmo *Resilient Propagation*, com 11 neurônios na camada oculta, obteve os melhores resultados estatísticos e maior precisão nas estimativas.
- O algoritmo *Simulated Annealing*, com 10 neurônios na camada oculta, apresentou desempenho satisfatório, ficando em segundo lugar em eficiência.
- As diferenças observadas em relação a estudos anteriores destacam que o desempenho dos algoritmos depende diretamente das características dos dados e do problema em estudo.
- A escolha do algoritmo e da configuração da rede deve considerar as especificidades do problema, sendo indispensável uma validação criteriosa para assegurar a precisão e a confiabilidade dos modelos.

AGRADECIMENTOS

Agradeço a Universidade do Estado do Amapá (UEAP), pela formação acadêmica de excelência e pelo suporte oferecido durante a realização deste trabalho. Ao laboratório de manejo pelo incentivo a pesquisa, juntamente ao conselho nacional de desenvolvimento científico e tecnológico (CNPQ) que através do programa institucional de bolsas (PIBIC) oferta apoio juntamente as bolsas de iniciação científica, tornando possível a realização deste estudo.

REFERÊNCIAS

- BERNARDI, L. K. *et al.*,. Diferentes modelos para o afilamento do tronco de Eucalyptus sp. para o cenário florestal brasileiro. *Ciência Florestal*, v. 31, n. 3, p. 1364–1382, 6 set. 2021.
- COSTA, E. A. *et al.*,. FUNÇÃO DE AFILAMENTO E SORTIMENTOS DE MADEIRA PARA Araucaria angustifolia. *Ciência Florestal*, v. 26, n. 2, p. 523–533, 20 jun. 2016. **CONCERTAÇÃO AMAZÔNIA**. Povos Indígenas, Quilombolas e Comunidades Tradicionais: diversidade cultural e social na Amazônia. **Cadernos da Concertação**, v. 5, 2024.
- BINOTI, M. L. M. D. S.; BINOTI, D. H. B.; LEITE, H. G.; GARCIA, S. L. R.; FERREIRA, M. Z.; RODE, R.; SILVA, A. A. L. D. Redes neurais artificiais para estimação do volume de árvores. *Revista Árvore*, v.38, n.2, 283-288, 2014.
- HYARI, K. H.; AL-DARASEH, A.; EL-MASHALEH, M. Conceptual cost estimation model for engineering services in public construction projects. *Journal of Management in Engineering*, v. 32, n. 1, p. 1–9, 2015.
- BARROS, L. B. Aplicação de redes neurais artificiais no contexto de estimativa de custos de construção de rodovias. Dissertação (Mestrado) – Universidade de Brasília, 2019.
- BINOTI, M. L. M. D. S.; BINOTI, D. H. B.; LEITE, H. G.; GARCIA, S. L. R.; FERREIRA, M. Z.; RODE, R.; SILVA, A. A. L. D. Redes neurais artificiais para estimação do volume de árvores. *Revista Árvore*, v.38, n.2, 283-288, 2014.
- CUNHA NETO, E. M.; BEZERRA, J. C. F.; ANDRADE, J. S.; MAR, A. L.; VAZ, M. M.; ROCHA, J. E.C.; MELO, M. R. S.; ALVES, G. A. R. Redes neurais artificiais e regressão na estimativa da altura em povoamento experimental misto e equiâneo. *Caderno de Ciências Agrárias*, Minas Gerais, v. 10, n. 3, p.60-68, dez. 2018.
- HYARI, K. H.; AL-DARASEH, A.; EL-MASHALEH, M. Conceptual cost estimation model for engineering services in public construction projects. *Journal of Management in Engineering*, v. 32, n. 1, p. 1–9, 2015.
- MACEDO, Ernandes. Modelo de Kozak e Redes Neurais Artificiais na Estimativa do Afilamento do Fuste de Eucalipto. *Revista de Engenharia e Tecnologia*, v. 11, p. 150-158, set. 2019.
- MIGUEL, E. P.; MOTA, F. I. C. M.; TÉO, S. J.; NASCIMENTO, R. G. M.; LEAL, F. I. A.; PEREIRA, R. S. E.; REZENDE, A. V. E. Artificial intelligence tools in predicting the volume of trees within a forest stand. *African Journal of Agricultural Research*, v.11, n.21, p.1914-1923, 2016.
- RIBEIRO, R. B. D. S.; GAMA, J. R. V.; SOUZA, A. L. D.; LEITE, H. G.; SOARES, C. P. B.; SILVA, G. F. D. Métodos para estimar o volume de fustes e galhos na floresta nacional do tapajós1. *Revista Árvore*, v.40, n.1, p.81-88, 2016.
- RODRIGUES, V. Como máquinas aprendem... Volume III. Cannes, França. 2 ed. 2021.
- SILVA, L. B. D.; MORAIS, V. A.; CAETANO, M. G.; BERNARDES, L. F. G. D. M. Equações para estimativa volumétrica de espécies arbóreas da Amazônia. *Revista de ciências agroambientais*, v.18, n.1, p.16-26, 2020.
- VEGA, A.E.D. Modelagem de povoamentos de eucalipto no nordeste da Bahia utilizando regressão e redes neurais artificiais. Dissertação (Mestrado). Universidade Federal de Viçosa. Viçosa, 2018.
- Zoneamento Ecológico-Econômico (2008) Macrodiagnóstico do estado do Amapá primeira aproximação do ZEE. Macapá: IEPA, 2008. 3ª edição. 142p. URL <http://www.iepa.ap.gov.br/arquivopdf/macrodiagnostico.pdf>.
- BIOFIX Scientific Journal v. 4 n. 2 p. 166-171 2019 Cunha Neto, E. M. da *et al.*,.
- SCHIKOWSKI, A.B. *et al.*,. Estudo da forma do fuste utilizando redes neurais artificiais e funções de afilamento. *Pesquisa Florestal Brasileira*, v.35, n.82, p.119-127, 2015
- CAMPOS, Bráulio Pizziôlo Furtado *et al.*,. Descrição do perfil do tronco de árvores em plantios de diferentes espécies por meio de redes neurais artificiais. *Pesquisa Florestal Brasileira*, [S.L.], v. 37, n. 90, p. 99, 30 jun. 2017. Embrapa Florestas. <http://dx.doi.org/10.4336/2017.pfb.37.90.1181>.
- MARTINS, E.R.; BINOTI, M.L.M.s.; LEITE, H.G.; BINOTI, D.H.B.; DUTRA, G.C.. Configuração de redes neurais artificiais para estimação do afilamento do fuste de árvores de eucalipto. **Revista Brasileira de Ciências Agrárias - Brazilian Journal Of Agricultural Sciences**, [S.L.], v. 11, n. 1, p. 33-38, 31 mar. 2016. *Revista Brasileira de Ciencias Agrarias*. <http://dx.doi.org/10.5039/agraria.v11i1a5354>.