



**MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL RURAL DA AMAZÔNIA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS**

ALEXANDRE CAMPELO DE CARVALHO

**REDES NEURAIS ARTIFICIAIS E REGRESSÃO NÃO LINEAR NA ESTIMATIVA
DO VOLUME DE OCO EM TRONCOS DE ÁRVORES NA FLONA DE SARACÁ-
TAQUERA, ESTADO DO PARÁ**

BELÉM

2023

ALEXANDRE CAMPELO DE CARVALHO

**REDES NEURAIAS ARTIFICIAIS E REGRESSÃO NÃO LINEAR NA ESTIMATIVA
DO VOLUME DE OCO EM TRONCOS DE ÁRVORES NA FLONA DE SARACÁ-
TAQUERA, ESTADO DO PARÁ**

Dissertação apresentado ao Programa de Pós-graduação em Ciências Florestais da Universidade Federal Rural da Amazônia, como parte dos requisitos para obtenção do título de Mestre em Ciências Florestais.

Linha de pesquisa: Manejo de ecossistemas florestais.

Orientador: Prof. Dr. José Natalino Macedo Silva.

Coorientador: Profa. Dra. Rosângela de Jesus Sousa.

Coorientador: Prof. Dr. Deivison Venicio Souza.

BELÉM

2023

Dados Internacionais de Catalogação na Publicação (CIP)
Bibliotecas da Universidade Federal Rural da Amazônia
Gerada automaticamente mediante os dados fornecidos pelo(a) autor(a)

- C331r Carvalho, Alexandre campelo de carvalho
REDES NEURAIIS ARTIFICIAIS E REGRESSÃO NÃO LINEAR NA ESTIMATIVA DO
VOLUME DE OCO EM TRONCOS DE ÁRVORES NA FLONA DE SARACÁ-TAQUERA,
ESTADO DO PARÁ /
Alexandre campelo de carvalho Carvalho. - 2023.
54 f. : il. color.
- Dissertação (Mestrado) - Programa de PÓS-GRADUAÇÃO em Ciências Florestais (PPGCF),
Campus Universitário de Belém, Universidade Federal Rural Da Amazônia, Belém, 2023.
Orientador: Prof. Dr. José Natalino Macedo Silva Silva
Coorientador: Prof. Dr. Deivison Venicio Souza & Rosângela de Jesus Sousa.
1. Aprendizado de Máquina 2. Modelos de Regressão 3. Árvores em pé 4. Amazônia 5.
Floresta Natural.. I. Silva, José Natalino Macedo Silva, *orient.* II. Título

CDD

634.9209811

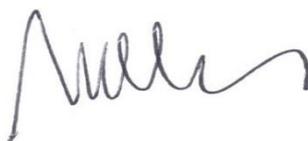
ALEXANDRE CAMPELO DE CARVALHO

**REDES NEURAIS ARTIFICIAIS E REGRESSÃO NÃO LINEAR NA ESTIMATIVA
DO VOLUME DE OCO EM TRONCOS DE ÁRVORES NA FLONA DE SARACÁ-
TAQUERA, ESTADO DO PARÁ**

Dissertação apresentada ao Programa de Pós-graduação em Ciências Florestais da Universidade Federal Rural da Amazônia, como parte dos requisitos para obtenção do título de Mestre em Ciências Florestais. Orientador: Prof. Dr. José Natalino Macedo Silva.

Data da Aprovação: 29/05/2023

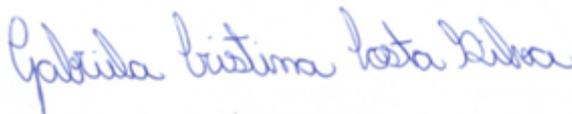
Banca Examinadora:



**Dr. JOSÉ NATALINO MACEDO SILVA - ORIENTADOR UNIVERSIDADE
FEDERAL RURAL DA AMAZÔNIA – UFRA**



**Dr. EDSON MARCOS LEAL SOARES RAMOS – UNIVERSIDADE FEDERAL DO
PARÁ – UFPA**



**Dr. GABRIELA CRISTINA COSTA SILVA - UNIVERSIDADE FEDERAL DE
VIÇOSA – UFV**

Documento assinado digitalmente
 RODRIGO GERONI MENDES NASCIMENTO
Data: 26/06/2023 13:56:14-0300
Verifique em <https://validar.iti.gov.br>

**Dr. RODRIGO GERONI MENDES NASCIMENTO – UNIVERSIDADE FEDERAL
DO PARANÁ – UFPR**

RESUMO

Nas florestas tropicais, entre os diversos desafios para a mensuração florestal está a estimativa do volume de oco nos troncos de árvores. Na Amazônia brasileira, nas transações feitas entre empresários florestais, os volumes deste defeito geralmente são descontados com a aplicação do volume Francon. Como os contratos não preveem o desconto de ocos existentes nas toras, isso representa um prejuízo para as empresas concessionárias em florestas públicas, pois acabam pagando por um volume acima do que realmente exploram. Portanto, sua estimativa em árvores em pé ou toras é importante tanto para o setor privado como para o público caso venha a ser adotado no futuro, em especial nos contratos de concessão onde este volume ainda não é descontado. Volumes de ocos podem ser estimados por meio de técnicas de regressão, tal como se faz para os volumes de troncos. Uma alternativa às técnicas de regressão linear clássica é o uso de técnicas de aprendizado de máquina, um subcampo da inteligência artificial. Este é um método indireto potencial para encontrar modelos preditivos acurados para a estimativa do volume de ocos em troncos de árvores de florestas tropicais. Neste contexto, o objetivo desta pesquisa foi avaliar a eficiência das redes neurais artificiais frente aos modelos de regressão para estimar o volume do oco em troncos de árvores em pé e derrubadas em uma floresta natural da região amazônica, especificamente na Floresta Nacional de Saracá Taquera. Foram mensuradas as seguintes variáveis em 213 troncos-amostra, a saber: comprimento da tora, diâmetros da base e do topo da tora, diâmetros da base e do topo do oco, comprimento do oco, DAP e altura do fuste. Para estimar os volumes dos ocos por meio do aprendizado de máquina, foram treinadas doze redes neurais artificiais (RNA) e ajustados seis modelos de regressão não linear. Cada rede teve de 2 a 16 neurônios na camada de entrada e o número de camadas intermediárias dependeu para cada rede neural. Para fins de modelagem preditiva, o conjunto de dados original ($n = 213$) foi dividido em dados de treinamento (70%) e dados de teste (30%), com uso do método *Leave-One-Out Cross Validation* (LOOCV) para avaliar o desempenho dos modelos durante o processo de aprendizado. Utilizou-se RNAs do tipo *Multilayer Perceptron* (MLP), com algoritmo *Resilient Propagation* para aprendizado dos pesos, e função de ativação linear. Os critérios de parada foram estabelecidos com base no erro médio e número de ciclos (erro de 1% e 30.000 ciclos). Os modelos de regressão foram ajustados utilizando o algoritmo de *Levenberg-Marquardt*. Observou-se que a rede neural R9, que utilizou as variáveis de entrada, diâmetro da base e do topo do oco e comprimento do oco, apresentou o menor erro de estimativa (4,97 %) dentre as redes testadas. Enquanto a equação de regressão do modelo de Schumacher-Hall para M1 que utilizou as variáveis da média do diâmetro do oco ($\overline{D_0}$), e comprimento do oco (C_0) apresentou o menor erro da estimativa (2,60%). Conclui-se que a rede R9 com as variáveis de entrada comprimento do oco, diâmetro da base e do topo do oco foi capaz de descrever e estimar com precisão o volume do oco das toras da Flona de Saracá - Taquera. No entanto, a modelagem por regressão não linear foi ainda mais precisa, utilizando o diâmetro médio do oco e o comprimento do oco como variáveis independentes. Ambos os métodos foram especialmente úteis para estimar o volume do oco em toras derrubadas, que foram reconstituídas para verificar tanto a estimativa do volume do oco em árvores em pé quanto em toras de árvores derrubadas.

Palavras-chave: Aprendizado de Máquina; Modelos de Regressão; Árvores em pé; Amazônia; Inteligência Artificial; Floresta Natural.

ABSTRACT

In tropical forests, among the many challenges for forest measurement is the estimation of hollow volume in tree trunks. In the Brazilian Amazon, in transactions between forestry entrepreneurs, the volumes of this defect are generally discounted using the Francon volume. As the contracts do not provide for the discount of existing holes in the logs, this represents a loss for concessionaire companies in public forests, as they end up paying for a volume above what they actually exploit. Therefore, its estimate in standing trees or logs is important for both the private and public sectors if it is to be adopted in the future, especially in concession contracts where this volume is not discounted yet. Hollow volumes can be estimated using regression techniques, as is done for trunk volumes. An alternative to classical linear regression techniques is the use of machine learning techniques, a subfield of artificial intelligence. This is a potential indirect method to find accurate predictive models for estimating hollow volume in tropical forest tree trunks. In this context, the objective of this research was to evaluate the efficiency of artificial neural networks against regression models to estimate the hollow volume in standing and felled tree trunks in a natural forest in the Amazon region, specifically in the National Forest of Saracá Taquera. The following variables were measured in 213 sample trunks, namely: length of the log, diameters at the base and top of the log, diameters at the base and top of the hollow, length of the hollow, DBHT twelve artificial neural networks (ANN) were trained to estimate the hollow volumes through machine learning were trained and six non-linear regression models were adjusted. Each network had from 2 to 16 neurons in the input layer and the number of intermediate layers depended for each neural network. For predictive modeling purposes, the original dataset ($n = 213$) was divided into training data (70%) and test data (30%), using the *Leave-One-Out Cross Validation* (LOOCV) method to evaluate the performance of the models during the learning process. ANNs of the *Multilayer Perceptron* (MLP) type were used, with a *Resilient Propagation algorithm* for weight learning, and a linear activation function. Stopping criteria were established based on mean error and number of cycles (1% error and 30,000 cycles). Regression models were fitted using the *Levenberg-Marquardt* algorithm. It was observed that the neural network R9, which used the input variables, diameter of the base and top of the hollow and length of the hollow, presented the lowest estimation error (4.97%) among the networks tested. While the regression equation of the Schumacher-Hall model for M1 that used the variables of the average of the hollow diameter ($\overline{D_0}$), and hollow length (C_0) presented the smallest estimation error (2.60%). It is concluded that the R9 network with the input variables hollow length, diameter of the base and top of the hollow was able to accurately describe and estimate the hollow volume of logs from Flona de Saracá - Taquera. However, non-linear regression modeling was even more accurate, using mean hollow diameter and hollow length as independent variables. Both methods were especially useful for estimating hollow volume the felled logs, which were reconstituted to verify both the estimated hollow volume in standing trees and in logs from felled trees.

Keywords: Machine Learning; Regression Models; Standing Trees; Amazon; Artificial intelligence; Natural Forest.

Dedico a Deus pela dádiva da vida, a minha mãe Ana Regina pelo amor imensurável, ao meu pai Afonso e a minha avó Neuza por me apoiarem imensamente todos os dias.

AGRADECIMENTOS

A Deus em primeiro, por ser o meu guia com quem eu creio a criar forças e buscar os meus sonhos e objetivos todos os dias.

À empresa Samise Indústria, Comércio e Exportação Ltda por todos os recursos passados sejam eles financeiros e logísticas e por me oferecerem o local para a coleta dos meus dados e êxito neste trabalho.

Ao meu orientador, Dr. José Natalino Macedo Silva, por todas as lições e ensinamentos e orientações nesta dissertação que foram essenciais durante esses anos.

Aos meus coorientadores, Deivison Venicio Souza e Rosângela de Jesus Sousa por todos os incentivos e auxílios para a realização deste trabalho.

Aos professores, Édson Ramos, Gabriela Cristina Costa Silva e Rodrigo Geroni Mendes Nascimento por aceitarem participar da banca desse estudo.

Aos meus familiares, em especial a minha mãe Ana Regina, por ser meu alicerce, por não pensar duas vezes em se jogar nos meus sonhos, gratidão por todo apoio, confiança, amor, perseverança e afeto que tem por mim, você é luz em minha vida.

Aos meus irmãos Anderson, Andreia, Adriano e Nathan e aos meus tios e primos, Nazaré, Delson, Camilla e Théo, por todo por todo companheirismo, apoio e confiança ao longo desses anos e por sempre acreditarem nos meus objetivos.

Aos meu sobrinhos Ana Beatriz, Ana Clara e André Bernardo por serem minha fonte de alegria diária.

Ao meu namorado Jaime Neto, por ter sido o principal incentivador na conclusão desse mestrado e por sempre ter acreditado no meu potencial e que me inspira todos os dias a ser um profissional melhor.

A minha melhor amiga Elizabeth Lebrege por ser não só amiga e sim uma irmã de outra mãe que não soltou a minha mão durante esses anos, que essa amizade seja eterna.

SUMÁRIO

1. INTRODUÇÃO	10
2. QUESTÕES E HIPÓTESES	12
3. OBJETIVOS	13
3.1 Objetivo geral	13
3.2 Objetivos específicos.....	13
4. REVISÃO DE LITERATURA	14
4.1 Estimativa de volume em árvores	14
4.2 Formação de oco e técnicas utilizadas para sua detecção em árvores em pé	15
4.3 Redes Neurais Artificiais como alternativa para estimar o volume de oco em árvores.....	16
4.4 Modelos de Regressão.....	18
5. MATERIAL E MÉTODOS	20
5.1. Área de estudo.....	20
5.2. A Flona de Saracá-Taquera.....	21
5.3. Coleta de dados	21
a) Cubagem das toras	23
b) Cubagem dos ocos	23
c) Estimativa de volume de oco por meio de redes neurais	25
5.4. Critérios de seleção das RNAs e modelos de regressão não linear.....	29
6. RESULTADOS E DISCUSSÃO	29
6.1 Estimativa de volume de oco por meio de Rede Neurais Artificiais.....	29
6.2 Estimativa de volume de oco por meio de regressão não linear.....	36
7. CONCLUSÃO	42
8. APÊNDICE	5
9. REFERÊNCIAS	11

1. INTRODUÇÃO

A madeira oriunda de florestas tropicais é um produto de alto interesse global, com mais de 400 milhões de hectares designados como área de concessão florestal (ASNER *et al.*, 2009) e contribuição de aproximadamente 15% da produção global de madeira (POUDYAL; MARASENI; COCKFIELD, 2018). Por esse motivo, práticas de Manejo Florestal Sustentável (MFS) vêm sendo continuamente aprimoradas, visando a sustentabilidade da produção com menores impactos, especialmente à biodiversidade e às condições edáficas (CONDÉ *et al.*, 2022; LIMA *et al.*, 2020a; OLIVEIRA *et al.*, 2021). Ademais, estimativas sobre produção e estoque de recursos florestais tornam-se cada vez mais indispensáveis no cenário global, tendo em vista a expansão populacional e, por conseguinte, a crescente demanda por alimentos, bens e serviços ecossistêmicos (BENEDEK; FERTÓ, 2020). Para isso, Inventários Florestais são essenciais, pois se caracterizam como uma atividade de manejo voltada para a obtenção de informações referentes às características quali-quantitativas de um povoamento florestal (KERSHAW *et al.*, 2017).

Nesse contexto, um desafio que se apresenta para a ciência florestal é a estimativa do volume de oco nos troncos, visto que árvores com ocos podem representar uma parcela significativa das árvores selecionadas para o corte e, conseqüentemente, impactar no cálculo do volume final da exploração (NOGUEIRA; NELSON; FEARNESIDE, 2006). Na Floresta Nacional de Saracá-Taquera (PA), em um censo florestal realizado para planejar a exploração, 53% das árvores inventariadas apresentaram ocos (ALMEIDA, 2018).

O conhecimento acerca do volume do oco no Manejo Florestal é importante para que se possa descontá-lo do volume de madeira, pelo fato que a Instrução Normativa Nº 5, limita e fiscaliza o volume de madeira a ser extraído da floresta (BRASIL, 2006).

Pesquisas destinadas à determinação de modelos matemáticos que possam estimar os volumes de árvores em pé são abundantes no Brasil, inclusive em regiões tropicais (FIGUEIREDO FILHO; MACHADO; MIRANDA, 2014). Por outro lado, pesquisas voltadas à estimativa/predição de oco nos troncos são praticamente inexistentes. No Brasil, Dantas (2021) ajustou modelos de regressão tradicionais, comumente usados para a estimativa dos volumes de árvores em pé, para modelar o volume de oco em troncos de árvores da Floresta Nacional de Saracá-Taquera. Neste trabalho foram utilizadas as variáveis diâmetro médio do oco e diâmetro à 1,30 m de altura (DAP) como variáveis independentes.

As equações de volume são ajustadas a partir de variáveis dendrométricas determinadas em campo, em geral com baixo erro de estimativa (COUTO; BASTOS, 1987).

34 Tanto para a modelagem do volume de troncos, como do volume de ocos, os melhores
35 resultados são obtidos com a inclusão das variáveis altura da árvore e da altura do oco.
36 (SOARES *et al.*, 2011). Desse modo, as técnicas estatísticas surgem nesse cenário como
37 importantes fontes de produção de conhecimento para a solução desses problemas (VALENTE
38 *et al.*, 2011).

39 Em vista disso como alternativa a equações de volume, a utilização de redes neurais
40 artificiais (RNAs) vem se mostrando uma ótima escolha para a mensuração florestal
41 (GONÇALVES, 2021), surgindo como opção aos modelos de regressão para determinar o
42 volume de madeira, pois possuem ampla e melhor aplicação, além de não necessitarem de
43 muitas amostras flexíveis, são capazes de relacionar variáveis categóricas e quantitativas e não
44 necessitam atender a pressupostos estatísticos. (HAYKIN, 2001; BINOTI; BINOTI; LEITE,
45 2013).

46 A rede neural artificial (RNA) é um sistema de processamento massivamente paralelo,
47 composto por unidades simples com capacidade natural de armazenar conhecimento e
48 disponibilizá-lo para uso futuro (HAYKIN, 2001). Gonçalves (2021) descreve as RNAs como
49 um agrupamento de unidades de processamento de dados que contêm funções matemáticas,
50 unidas por pesos, tendo a capacidade de aprender, com a mudança dos pesos sinápticos, e
51 generalizar o aprendizado para outra base de dados. Assim, o desenvolvimento de redes neurais
52 passa por três etapas: pré-processamento, processamento e pós-processamento dos dados
53 (GORGENS *et al.*, 2009; SILVA *et al.*, 2009; AKKOÇ, 2012; CARRIJO *et al.*, 2020).

54 Em se tratando da aplicação de redes neurais para estimar volumes de ocos de árvores
55 na Amazônia, não foram encontrados registros ou resultados de pesquisas para esse fim. Nesse
56 sentido, este trabalho partiu da seguinte questão científica: a técnica de redes neurais artificiais
57 é eficiente na estimativa do volume de oco em troncos de árvores individuais em florestas
58 naturais da Amazônia quando comparadas com modelos de regressão não linear? Assim, o
59 objetivo desta pesquisa foi avaliar a eficiência das redes neurais artificiais e modelos de
60 regressão para estimar o volume do oco em troncos de árvores em uma floresta natural.

61

62

63 2. QUESTÕES E HIPÓTESES

64 **Questão:** A técnica de redes neurais artificiais é eficiente na estimativa do volume de
65 oco em troncos de árvores individuais em florestas naturais da Amazônia quando comparadas
66 com modelos de regressão não linear?

67 **Hipótese:** As redes neurais artificiais são eficientes e precisas para estimar os volumes
68 de ocos de árvores individuais em florestas naturais da Amazônia brasileira, sendo mais precisas
69 que modelos de regressão não linear.

70

71 **3. OBJETIVOS**

72 **3.1 Objetivo geral**

73 Avaliar a eficiência das redes neurais artificiais e modelos de regressão para estimar o
74 volume do oco em troncos de árvores em uma floresta natural da região Amazônica.

75 **3.2 Objetivos específicos**

- 76 • Quantificar os volumes de ocos de espécies arbóreas comerciais na Floresta Nacional (Flona)
77 de Saracá-Taquera;
- 78 • Comparar a acurácia da aplicação de redes neurais artificiais e modelos de regressão não
79 linear para estimar volumes de ocos em troncos de árvores de espécies comerciais na Floresta
80 Nacional (Flona) de Saracá-Taquera.

81

82 4. REVISÃO DE LITERATURA

83 4.1 Estimativa de volume em árvores

84 Tendo em vista a importância que as árvores desempenham na provisão de serviços
85 ecossistêmicos em escala mundial devido ao potencial de assimilação de carbono, o volume de
86 madeira é uma das variáveis consideradas mais importantes em inventário florestais (ABEGG
87 *et al.*, 2023). No manejo florestal, o conhecimento acerca do volume de galhos permite um
88 maior aproveitamento da madeira, bem como a diversificação da produção (ZULETA *et al.*,
89 2022). Por outro lado, em ecossistemas tropicais, a elevada diversidade de espécies torna a
90 estimativa de volume uma atividade complexa e, em muitos casos, pouco precisa, já que
91 geralmente utiliza-se modelos matemáticos que têm como preditores o diâmetro à 1,30 m de
92 altura (DAP) e a altura da árvore (NOGUEIRA *et al.*, 2008; ROMERO *et al.*, 2020). Esta última
93 é sempre de difícil medição, dadas as características das florestas tropicais, em geral com sub-
94 bosque bastante denso, dificultando a sua obtenção com hipsômetros convencionais (VAGLIO
95 LAURIN *et al.*, 2019). Para minimizar este impasse, Heinsdijk e Bastos (1963), pioneiros na
96 pesquisa sobre a volumetria das espécies na Amazônia brasileira, determinaram um fator de
97 forma geral (0,7) para árvores da região, o qual continua sendo utilizado até os dias atuais. Por
98 outro lado, o avanço tecnológico utilizando técnicas de regressão vem favorecendo o
99 desenvolvimento de equações volumétricas específicas para cada floresta e até para espécies
100 individuais da floresta, (BARROS; SILVA JÚNIOR, 2009).

101 A modelagem dos volumes dos troncos pode ser feita, por exemplo, pela aplicação de
102 modelos matemáticos lineares (LEITE; REZENDE, 2010), estes podendo ser divididos em
103 modelos de regressão simples e múltiplos ou modelos de regressão de simples e de múltiplas
104 entradas.

105 O ajuste de equações volumétricas desenvolvidas para as áreas de manejo florestal
106 sustentável se constitui em um procedimento mais eficiente, econômico e com aceitável
107 precisão para a quantificação da produção volumétrica (BARROS; SILVA JÚNIOR, 2009;
108 ROMERO *et al.*, 2022). Os modelos volumétricos ajustados por regressão proporcionam os
109 melhores indicadores de qualidade de ajuste para estimativa de volume em inventários florestais
110 em comparação à estimativa do volume de madeira da floresta utilizando o fator de forma
111 (CAMPOS; LEITE, 2009; CARVALHO, 2018).

112 Por outro lado, a ocorrência de oco no fuste diminui a acurácia dos modelos
113 matemáticos, resultando em superestimativas de até 30% em árvores com DAP > 50 cm na
114 Amazônia (NOGUEIRA; NELSON; FEARNSSIDE, 2006). Assim, como alternativa às
115 equações de volume, as Redes Neurais Artificiais (RNAs) têm sido cada vez mais utilizadas,

116 como uma nova ferramenta que resulta em maior acurácia e precisão nas estimativas de
117 produção volumétrica, dando suporte às tomadas de decisão no manejo das florestas naturais e
118 plantadas (CASTELLANOS; BLANCO; PALENCIA, 2007).

119 **4.2 Formação de oco e técnicas utilizadas para sua detecção em árvores em pé**

120 De uma maneira geral, a formação de oco em espécies florestais está associada à
121 ataques por cupins subterrâneos e, posteriormente, infecções fúngicas, especialmente fungos
122 saproxílicos os quais se alimentam de madeira morta (WAINHOUSE; BODDY, 2022). Esta
123 necromassa auxilia de maneira significativa a ciclagem de nutrientes na Amazônia
124 (MONTEIRO; SARMENTO; SOTÃO, 2019).

125 Em florestas plantadas na Europa, técnicas de manejo como o *pollarding*, ou seja, a
126 poda periódica de galhos, é responsável por intensificar a ocorrência de oco em árvores jovens,
127 uma vez que facilita a colonização de xilófagos (SEBEK *et al.*, 2013).

128 Na Amazônia, o tamanho da árvore e as características da madeira são fatores que
129 influenciam diretamente a formação de ocos (LIMA *et al.*, 2020b), uma vez que estão
130 relacionadas à maior suscetibilidade de cupins (*Coptotermes* sp.), especialmente *Coptotermes*
131 *testaceus* L. (ELEUTERIO; JESUS; PUTZ, 2020).

132 Na maioria dos casos, não é possível detectar visualmente a presença de ocos, embora
133 a dedução seja possível por meio da observação de sintomas tais como casas de cupins e
134 presença de secreções escuras ao longo do tronco e galhos quebrados, que sugerem a presença
135 do oco nas árvores (ELEUTERIO; JESUS; PUTZ, 2020).

136 A audição também pode ser utilizada, encostando-se o ouvido na árvore e com o auxílio
137 de um martelo, batendo-se no tronco no intuito de determinar a presença ou ausência de oco
138 por meio do som emitido (SECCO, 2011). Todavia, essa é uma avaliação subjetiva e com altos
139 índices de erros. Há, portanto, a necessidade de alternativa como, por exemplo, a introdução do
140 sabre do motosserra no tronco no sentido vertical, onde a partir da resistência da madeira à
141 penetração do sabre é possível avaliar a presença (ou não) de oco.

142 O procedimento de introdução do sabre, conhecido como teste do oco, além de ser um
143 procedimento invasivo e capaz de ocasionar danos irreversíveis à árvore (SECCO, 2011), é
144 considerado pouco confiável pois depende da experiência do operador (TROCKENBRODT;
145 IMIYABIR; JOSUE, 2002).

146 O teste do oco é um procedimento que não indica com segurança e eficiência a qualidade
147 do tronco da árvore em pé (LIRA, 2016) nem revela a sua extensão ao longo do fuste para
148 justificar o descarte de um tronco inteiro (LOUCHARD, 2022). Devido à essas dificuldades,

149 estudos para detectar ocos vêm sendo desenvolvidos com equipamentos de ultrassom (SECCO,
 150 2011) e com uma alternativa mais moderna denominada *Ground-Penetrating Radar* (GPR, em
 151 português Radar de Penetração no Solo), a qual consiste em se fazer uma tomografia do tronco
 152 com uso de micro-ondas, que é capaz de avaliar a estrutura interna de árvores, a partir de
 153 respostas visuais por meio de imagens (Figura 1) (TOSTI *et al.*, 2022). Contudo, é válido
 154 ressaltar que por ser uma tecnologia ainda em teste, apresenta limitações em suas configurações
 155 internas (TOSTI *et al.*, 2022), podendo se tornar um impasse para as empresas que venham a
 156 utilizar essa ferramenta tendo em vista eventuais erros.

157 **Figura 1** - (a) Configuração de medição das medições de laboratório do modelo. Amostra de
 158 toco de árvore fica em cima de uma mesa rotativa (vista lateral), (b) A lacuna artificial dentro
 159 do toco e o par de antenas Vivaldi (vista superior). (c) Imagem do aparelho.



160

161 Fonte: (APAYDIN *et al.*, 2022); (CHEN *et al.*, 2023).

162 Santos (2020), realizando uma pesquisa para avaliar e modelar a ocorrência de ocos em
 163 árvores comerciais manejadas na Floresta Nacional do Tapajós (FNT), no estado do Pará,
 164 constatou que a ocorrência de ocos é influenciada tanto pela espécie, quanto pela dimensão do
 165 DAP e da Altura comercial da árvore, e concluiu que é possível realizar a previsão de ocorrência
 166 de ocos por equações logísticas para as principais espécies comerciais encontradas na floresta
 167 estudada.

168

169 **4.3 Redes Neurais Artificiais como alternativa para estimar o volume de oco em árvores**

170 Uma alternativa que pode ser viável para a predição do volume de ocos nas florestas
 171 tropicais são as Redes Neurais Artificiais (RNAs). Estas técnicas têm como principal vantagem
 172 a modelagem de problemas complexos, pela qual, uma vez concluído o treinamento

173 (aprendizado), a rede armazena em sua estrutura o modelo do problema abordado, a princípio,
174 não importando quão complexo ele é (HAYKIN, 2008). Esta ferramenta é um modelo
175 computacional inspirado na relação dos neurônios biológicos com elementos de processamento
176 simples, capazes de gerar, desde que seja treinado, respostas a um conjunto de dados (BINOTI,
177 2012).

178 As redes neurais naturais são organizadas em forma tridimensional por componentes
179 microscópicos, contendo bilhões de neurônios, enquanto na RNA existe restrição do número de
180 neurônios e camadas devido ao esforço computacional necessário (HAYKIN, 2001).

181 Diversas têm sido as aplicações de RNAs no setor florestal. O uso de RNA na pesquisa
182 florestal é uma alternativa para estimativa da variável altura por meio de modelos não lineares
183 (SKUDNIK; JEVŠENAK, 2022). Se constitui, também, em um mecanismo de inteligência
184 capaz de prever incêndios florestais (WU *et al.*, 2022), além de auxiliar na estimativa de
185 mortalidade e sobrevivência de árvores na Amazônia (REIS *et al.*, 2018).

186 Quando se trata de mensuração e manejo florestal, as RNAs têm demonstrado
187 desempenho eficiente, sendo utilizadas por várias empresas brasileiras para estimar variáveis
188 como volume da madeira, altura da árvore, densidade e modelagem do crescimento (LOPES,
189 2018).

190 A aplicação da RNA em muitos setores e para diversas finalidades pode ser justificada
191 pelo fato de o método possuir propriedades úteis, como a tolerância a falhas e ruídos, e pela
192 possibilidade de aprendizagem e generalização a partir de dados de treinamento
193 (BULLINARIA, 2009).

194 Na Floresta Nacional do Tapajós, estudos conduzidos por Santos *et al.* (2018) para
195 modelar o volume de *Couratari stellata* A.C.Smith., revelaram que as RNAs foram
196 ligeiramente superiores em relação ao modelo de Schumacher-Hall utilizado para estimativas
197 volumétricas, já que a RNA utilizada apresentou maior homogeneidade na dispersão de
198 resíduos, além de um menor número de pontos de superestimação e subestimação do volume.

199 Binoti *et al.* (2014) utilizaram RNA para reduzir o número de árvores a serem cubadas
200 para o desenvolvimento de equações volumétricas, e concluíram a técnica resultou em maior
201 eficiência para a estimativa do volume e proporcionou melhor viabilidade financeira devido à
202 redução de custos.

203 Bentes (2018), comparando as metodologias utilizadas para estimar o volume com casca
204 de árvores em pé em uma floresta ombrófila densa no município de Breu Branco-PA, por meio
205 da análise de regressão, fator de forma médio, fator de forma 0,7 proposto por Heinsdijk &
206 Bastos (1963) e treinamento de Redes Neurais Artificiais, concluiu não haver diferenças

207 significativas entre elas, a uma probabilidade de 95%, tendo como base o volume real cubado
208 pela metodologia de Smalian.

209 Leal *et al.* (2015) testaram e compararam o desempenho de RNAs versus o método de
210 regressão linear na estimativa dos volumes em plantio de *Eucalyptus urophylla* S.T.Blake,
211 utilizando como variáveis apenas o número de árvores por parcela e a abertura de dossel, e
212 concluíram que as redes neurais foram mais eficientes no desempenho.

213 Guan e Gerter (1991) utilizaram RNA para modelar a mortalidade de árvores, e
214 concluíram que as redes foram mais eficientes do que o emprego da regressão logística. Soares
215 *et al.* (2012) utilizando uma RNA Perceptron de Múltiplas Camadas a partir de três medidas
216 diâmetro na base da árvore, utilizando as variáveis de entrada o diâmetro do fuste, o diâmetro
217 à altura do peito e a altura total da árvore, compararam as estimativas dos diâmetros das árvores
218 aos valores dos diâmetros reais, e concluíram que os valores dos diâmetros preditos pela RNA
219 foram bem satisfatórios.

220 Diamantopoulou (2005) comprovou que a utilização das RNA foi melhor em relação
221 aos algoritmos de regressão não lineares para estimar o volume de casca em *Pinus* sp,
222 concluindo que as RNAs têm grande potencial para diversas aplicações em modelagem
223 florestal, sendo uma alternativa às aplicações tradicionais.

224 Gorgens *et al.* (2009), testaram formas de pré-processamento dos dados e arquiteturas
225 de RNA para estimar volume de árvores de eucalipto (*Eucalyptus* sp.) e teca (*Tectona grandis*
226 L.f.) utilizando dados de cubagem de diferentes empresas florestais, concluindo que as RNA
227 testadas foram capazes de substituir as equações de volume, sendo possível realizar a
228 modelagem por meio das RNA.

229 Silva (2008) obteve resultados satisfatórios com a utilização de RNA, em seu estudo
230 sobre a estimativa precisa dos diâmetros sem casca e do cerne ao longo do fuste para árvores
231 de teca, em três estados brasileiros, Bahia, Minas Gerais e São Paulo.

232 Gorgens *et al.* (2009), confirmaram que a modelização por RNA foi perfeitamente
233 viável para estimar com eficiência o volume de árvores de eucalipto (*Eucalyptus* spp.) e teca
234 (*Tectona grandis* L.f.) em reflorestamentos nos estados da Bahia, Minas Gerais e São Paulo.

235

236 **4.4 Modelos de regressão**

237 A modelagem dos volumes dos troncos pode ser feita, por exemplo, pela aplicação de
238 modelos matemáticos lineares (LEITE; REZENDE, 2010). Estes modelos podem ser divididos
239 em modelos de regressão simples e múltiplos ou modelos de regressão de simples entrada, com
240 apenas a variável independente DAP, e os de múltiplas entradas, que incluem a altura da árvore

241 junto ao DAP (RUMSEY, 2014). e comumente estimado por meio de modelos tradicionais
242 como os de Schumacher-Hall, Spurr, Hohenadl & Krenn, e Husch, dentre outros (CAMPOS;
243 LEITE, 2009).

244 Nesse contexto, existem ainda os modelos não lineares, que são aqueles em que os
245 parâmetros agregados estão apresentados na forma não aditiva, ou seja, os modelos não lineares
246 são deduzidos a partir de suposições teóricas, resultando em parâmetros interpretáveis
247 (DRAPER; SMITH, 1981).

248 Algumas regras são usadas para selecionar modelos estatísticos que melhor representem
249 os dados populacionais de uma floresta. Para critérios de precisão geralmente os mais utilizados
250 são o maior coeficiente de determinação e coeficiente de determinação ajustado (R^2_{aj}), menor
251 coeficiente de variação (CV%), menor erro padrão da estimativa (S_{yx}), e a distribuição
252 normalizada dos resíduos (SOARES *et al.*, 2012).

253 A relação entre a variável dependente e as variáveis independentes aponta o modelo a
254 ser utilizado (ZEVIANI; RIBEIRO JÚNIOR; BONAT, 2013). As medidas precisas de volume
255 de madeira são ferramentas de suma importância para o planejamento do uso do recurso
256 florestal, nas florestas naturais tropicais. Rolim *et al.* (2006), abordaram em seu estudo
257 “Modelos volumétricos para a Floresta Nacional do Tapirapé-Aquirí, na Serra dos Carajás
258 (PA)”, concluíram que o modelo logarítmico de dupla entrada de Schumacher-Hall foi o que
259 melhor estimou o volume para a floresta em questão. O modelo apresentou elevado coeficiente
260 de determinação, não tendencioso e apresentou um baixo erro padrão da estimativa.

261 Carvalho (2018) ajustou modelos lineares simples, lineares múltiplos e não lineares para
262 estimar o volume de madeira de árvores em uma floresta no sul do estado do Amazonas. A
263 autora comparou os volumes estimados pela equação de romaneio, equação de regressão e a
264 equação do cilindro corrigida pelo fator de forma, e concluiu que a equação linear múltipla
265 ajustada apresentou os melhores resultados para estimativa de volume em relação à equação
266 não linear para a floresta estudada.

267 Araújo (2015) verificando a modelagem por regressão e redes neurais para estimativa
268 da altura de *Calycophyllum spruceanum* nos municípios do Pará e Amapá, notou que os
269 modelos de regressão tradicionais para estimativas de altura são tão precisos quanto as redes
270 neurais artificiais. Dentre os modelos ajustados no referido trabalho o modelo não-linear de
271 Schumacher e Hall gerou estimativas de volume sem tendenciosidade, e o de Garay foi
272 correspondeu a melhor precisão para estimar afilamento do fuste da espécie.

273

274

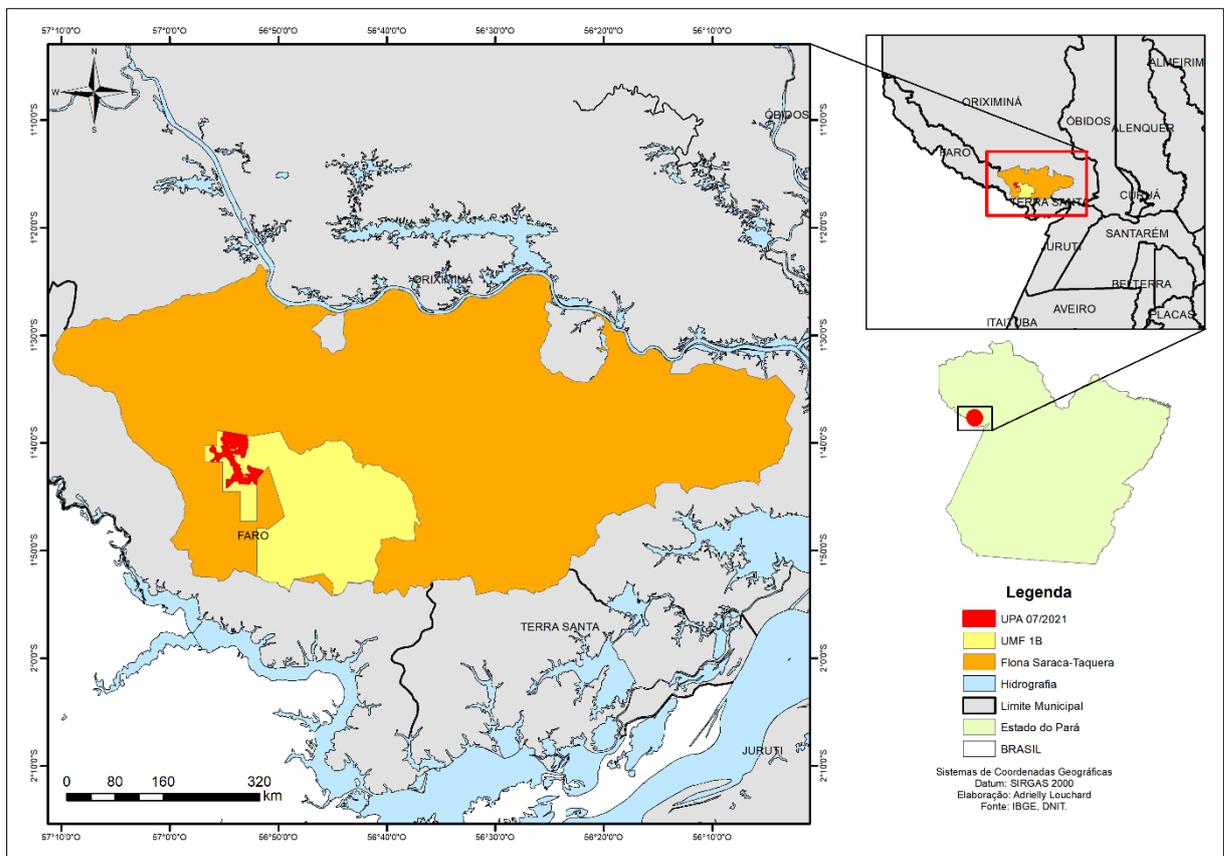
275 5. MATERIAL E MÉTODOS

276 5.1. Área de estudo

277 O estudo foi desenvolvido em uma área de concessão na Floresta Nacional (Flona) de
 278 Saracá-Taquera no estado do Pará, localizada nos limites da área Unidade de Produção Anual
 279 7, referente à Unidade de Manejo Florestal (UMF) 1B, adjudicada à empresa SAMISE
 280 Indústria, Comércio e Exportação Ltda (Figura 2). O clima na Floresta Nacional de Saracá-
 281 Taquera, de acordo com a classificação de Köppen, é o Tropical Equatorial Af, subtipo Af2 –
 282 muito a moderadamente chuvoso (ALVARES *et al.*, 2013). Na região da Flona, a média
 283 pluviométrica anual varia entre 2.500 e 3.000 mm, com umidade relativa do ar média de 80%
 284 (LUZ *et al.*, 2013). O solo predominante é do tipo Latossolo Amarelo Distrófico, apresentando
 285 textura argilosa ou muito argilosa, o qual inclui solos minerais em avançado estágio de
 286 intemperização (IBGE, 2008), além de Gleissolos, Neossolos e Argissolos (SETA, 2014).

287

288 **Figura 2** - Área de concessão localizada na Flona de Saracá-Taquera, estado do Pará,
 289 pertencente à Unidade de Manejo Florestal (UMF) 1B da empresa SAMISE Indústria,
 290 Comércio e Exportação Ltda, UPA 7.



291

292 Fonte: Louchard (2022).

293 A vegetação predominante na Flona de Saracá-Taquera é a Floresta Ombrófila Densa.
294 Segundo consta no Plano de Manejo Florestal Sustentável – PMFS (SETA, 2014) e no Edital
295 de Concessão Florestal da Flona de Saracá-Taquera (SFB, 2012a), as tipologias presentes na
296 UMF 1B são: *i*) a Floresta Ombrófila Densa de Terras Baixas, ocupando 28.692,30 hectares,
297 48,30% da UMF; *ii*) a Floresta Ombrófila Densa Submontana, com 20.995,00 hectares, 35,27%
298 da UMF; *iii*) a Floresta Ombrófila Densa Submontana de Platôs, ocupando 8.520,02 hectares,
299 14,34% da UMF; *iv*) a Floresta Pioneira com Influência Fluvial, com 1.236,80 hectares, 2,08%
300 da área da UMF; e *v*) uma área antropizada de 3,7 hectares, 0,01% da área total da UMF 1B.

301 **5.2 A Flona de Saracá-Taquera**

302 De acordo com o Art. 14º, inciso III, da Lei Nº 9.985, de 18 de julho de 2000, a Flona
303 de Saracá-Taquera é uma unidade de conservação da categoria de Uso Sustentável (BRASIL,
304 2000), a qual foi criada em 27 de dezembro de 1989, pelo Decreto Federal nº 98.704, e possui
305 área total de 429.600 ha. Esta unidade de conservação situa-se nos municípios de Faro,
306 Oriximiná e Terra Santa; limita-se ao norte com a Reserva Biológica do Rio Trombetas e tem
307 como limite geográfico, em sua maior parte, o Rio Trombetas. A Flona faz parte do sistema
308 hidrográfico do rio Amazonas, presente na região Hidrográfica da Calha Norte, no estado do
309 Pará. Os principais rios que banham a unidade de conservação são: Nhamundá, Trombetas,
310 Urubu, Uatumã, Jatapu e Preto da Eva. Além disso, a principal sub-bacia hidrográfica na UMF
311 1B é a do rio Taquera, possuindo uma pequena parte do rio Jamari dentro da unidade (SFB,
312 2012a).

313 **5.3. Coleta de dados**

314 A coleta de dados foi realizada na Unidade de Produção Anual - UPA 7/2021 de
315 2.680,0367 hectares no decorrer dos meses de agosto e setembro de 2021, durante o período de
316 atividade de romaneio, o romaneio consiste em levantamento de informações por meio de
317 medições das toras localizados no pátio de estocagem das madeiras (Figura 2A). Foram medidas
318 as dimensões dos ocos em 213 árvores amostra, distribuídas em diferentes classes de diâmetro
319 de oco (Tabela 1).

320 Para o somatório do volume de cada tora foi utilizada as informações da cadeia de
321 custódia que estava fixada em cada tora, a cadeia de custódia visam o controle e a identificação
322 de origem e as rotas da madeira até o seu destino final, e está fixada : , a identificação da UMF;
323 identificação da UPA; número da UT a que a árvore pertence; pátio no qual a tora foi romaneada
324 e identificada; e o número da árvore atribuído no censo florestal (inventário a 100%) (Figura
325 2B), auxiliaram na identificação das árvores e suas respectivas seções (toras).

341 **a) Cubagem das toras**

342 Aplicou-se a metodologia recomendada pelo Serviço Florestal Brasileiro (SFB, 2012b)
 343 para cubagem de toras de árvores. Nas extremidades de cada tora (base e topo) foram medidos
 344 dois diâmetros perpendiculares, primeiramente o diâmetro maior e, posteriormente, o diâmetro
 345 perpendicular a este, para obtenção dos diâmetros médios aritméticos de cada extremidade da
 346 tora (Figura 4). Foi também medido o comprimento total da tora para a determinação do volume
 347 geométrico e em seguida, calculado o volume das toras (Eq. 1) e do tronco (Eq. 2).

348 **Figura 4** - Método de medição dos diâmetros das toras, conforme requerido pelo Serviço
 349 Florestal Brasileiro.



350 Fonte: SFB (2012b).
 351

$$352 \quad V_t = \frac{\left[(D_b^2 * \frac{\pi}{4}) + (D_t^2 * \frac{\pi}{4}) \right]}{2} * C_t \quad (1)$$

353

354 Onde: V_t = volume da tora ou volume geométrico (m^3); D_b = média aritmética dos diâmetros na
 355 base da tora (m); D_t = média aritmética dos diâmetros obtidos no topo da tora (m); C_t =
 356 comprimento da tora (m).

$$357 \quad V_t = \sum_{i=1}^n V_i \quad (2)$$

358 Onde: V_t = volume total do tronco (m^3); V_i = volume de cada tora que compõe um tronco (m^3);
 359 n = número (quantidade) de toras.

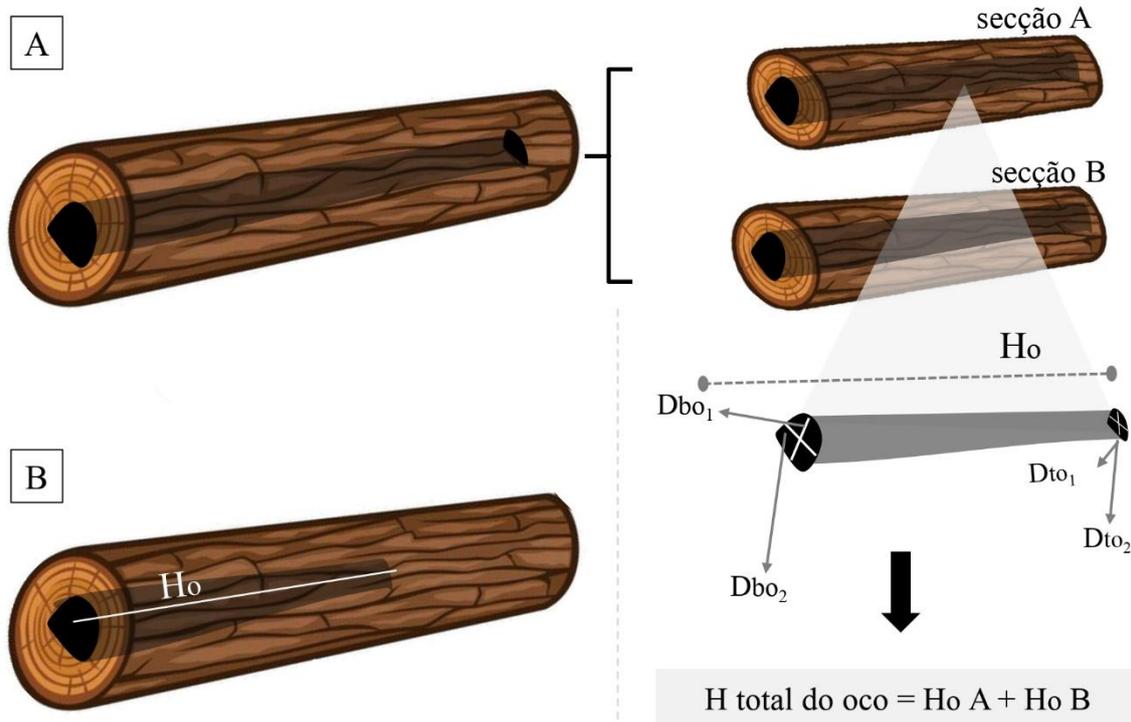
360

361 **b) Cubagem dos ocos**

362 As dimensões dos ocos presentes nas toras foram obtidas de acordo com procedimento
 363 descrito em Dantas (2021). Após a constatação visual da presença do oco mediu-se dois

364 diâmetros perpendiculares nos ocos situados na base (D_{b1} e D_{b2}) e dois situados no topo de
 365 cada tora (D_{t1} e D_{t2}). Primeiramente foi medido o maior diâmetro e, posteriormente, o diâmetro
 366 perpendicular a este. As médias aritméticas das medições da base (D_{b1} e D_{b2}) e do topo (D_{t1} e
 367 D_{t2}) representaram o diâmetro médio do oco em cada tora (Figura 5A). O comprimento do oco,
 368 que neste caso é o próprio comprimento da tora, pois o defeito atinge a outra extremidade da
 369 tora, foi medido com uma fita métrica graduada em centímetros. Nos casos em que o oco não
 370 alcançou as duas extremidades da tora, o comprimento do oco foi medido com o auxílio de uma
 371 vara graduada em centímetros introduzida na cavidade (Figura 5B).

372 **Figura 5** - Medição dos diâmetros e comprimento dos ocos na base e topo das toras das árvores
 373 amostra: **A)** comprimento do oco atingindo a outra extremidade da tora e suas seções (toras);
 374 **B)** comprimento do oco quando não atinge a outra extremidade da tora.



375

376 Fonte: Adaptado de Dantas (2021).

377 Quando o fuste de uma árvore amostra apresentou mais de uma tora, adicionou-se o
 378 comprimento do oco de cada tora para se obter o comprimento total do oco no fuste. O mesmo
 379 foi aplicado ao volume total do oco da árvore (Figura 5A).

380 Admitindo-se que o oco das árvores apresenta a forma de um tronco de cone, o volume
 381 geométrico do oco das toras foi calculado segundo Machado & Figueiredo Filho (2014) (Eq.
 382 3).

$$383 \quad V_o = \frac{\pi H_o}{12} (Db^2 + Db * Dt + Dt^2) \quad (3)$$

384 Onde: V_o = volume do oco (m^3); D_b = média aritmética dos dois diâmetros da base do oco
 385 (m); D_t = média aritmética dos dois diâmetros do topo do oco (m); H_o = comprimento do oco
 386 (m).

387 Quando o comprimento do oco não atingiu as duas extremidades da tora, foi utilizada
 388 uma vara graduada em metros e centímetros, para medir o comprimento. Neste caso foi utilizada
 389 a Equação 4 para calcular o volume do oco (MACHADO; FIGUEIREDO FILHO, 2014).

$$390 \quad V_o = \frac{\pi D^2 H_o}{12} \quad (4)$$

391 Onde: V_o = Volume do oco (m^3); D = Diâmetro do oco na extremidade visível (m); H_o =
 392 comprimento do oco (m).
 393

394 O volume total do oco do tronco foi calculado pela somatória dos volumes dos ocos
 395 presentes em cada tora (Eq. 5).

$$396 \quad V_{t_o} = \sum_{i=1}^n V_{i_o} \quad (5)$$

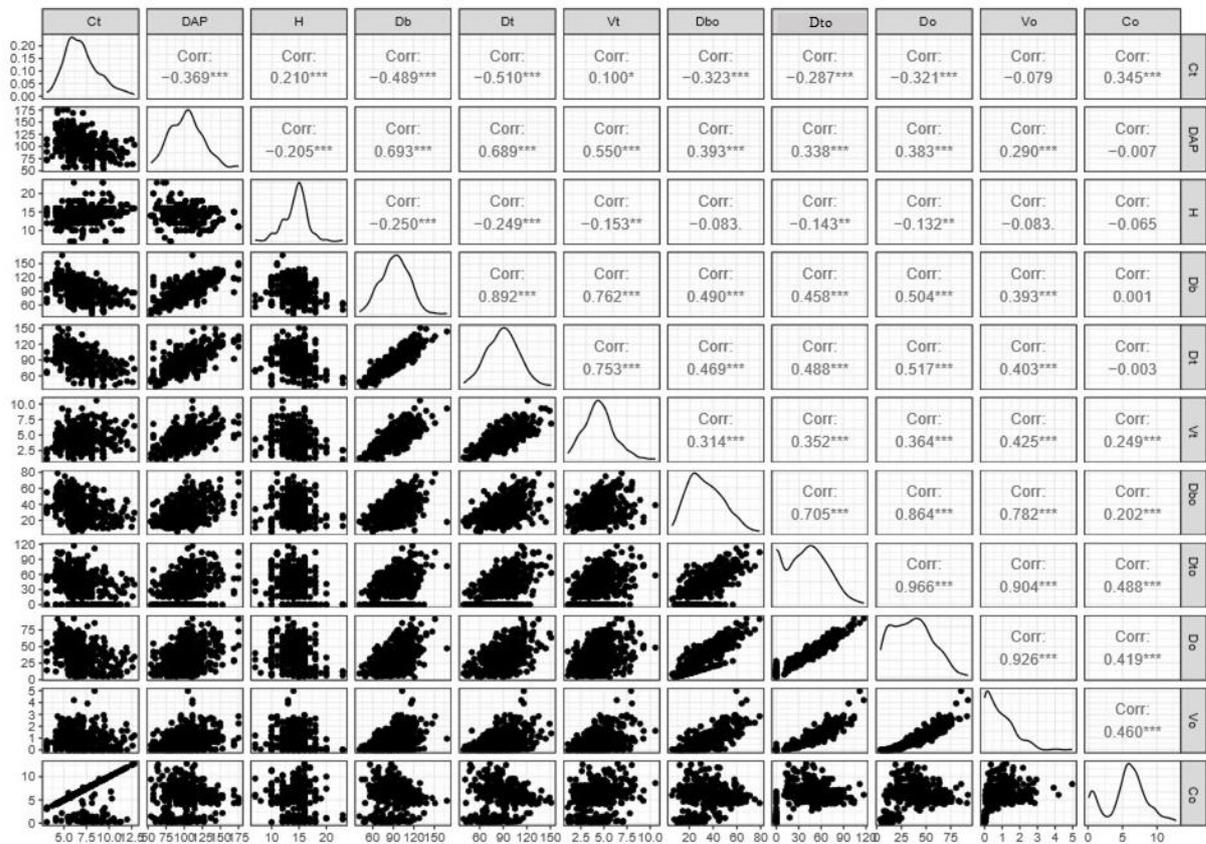
397 Onde: $V_{t_{oco}}$ = volume total do oco na árvore (m^3); V_{i_o} = volume do oco em cada tora que
 398 compõe uma árvore (m^3); n = número (quantidade) de toras.

399 c) Estimativa de volume de oco por meio de redes neurais

400

401 Previamente ao treino das RNAs, foi realizada análise de correlação com o intuito de
 402 pré-selecionar as variáveis que participariam da modelagem para a estimativa do volume do
 403 oco (Figura 6). As correlações variaram de (-0,5 a 0,9), destacando-se a forte correlação entre
 404 Diâmetro do topo do oco (D_{to}) e Volume do oco (V_o) e não houve transformação dos dados.

405 **Figura 6** - Correlação linear entre as variáveis contínuas para estimativa do volume do oco das
 406 árvores amostra na Flona de Saracá-Taquera, estado do Pará.



407

408 Fonte: Autor (2023).

409

410

411 Para o treinamento das RNAs, o conjunto de dados foi dividido em dois grupos distintos,
 412 denominados de “treino” e “teste” (Tabela 2). Para o treinamento utilizou-se 70% dos dados e
 413 o teste 30%. Utilizou-se o método *Leave-One-Out CrossValidation* (LOOCV) para verificar o
 414 desempenho das redes durante o processo de aprendizado. Foram utilizadas RNAs do tipo
 415 *Multilayer Perceptron* (MLP), com algoritmo *Resilient Propagation* para aprendizado dos
 416 pesos, e função de ativação linear, devido a que melhor se ajustou em relação as outras que não
 417 deram certo. Os critérios de parada foram estabelecidos com base no erro médio e no número
 418 de ciclos (erro de 1% e 30.000 ciclos) (LACERDA, 2019). Para o treinamento e teste utilizou-
 419 se a linguagem de programação R e o pacote Caret.

419

420

421

422

R7	$V_o =$	Espécie	+	DAP	+	\overline{D}_o	+	C_o
R8	$V_o =$	\overline{D}_o	+	C_o				
R9	$V_o =$	Db_o	+	Dt_o	+	C_o		
R10	$V_o =$	DAP	+	H				
R11	$V_o =$	DAP	+	C_t				
R12	$V_o =$	Espécie	+	DAP	+	H	+	\overline{D}_o

443 Onde : Volume do oco (V_o), diâmetro a 1,30 m de altura do solo (DAP,), diâmetro da base da tora (Db ,),
 444 diâmetro do topo da tora (Dt), Altura estimada do Inventário Florestal a 100% (H) , média do diâmetro do oco
 445 (\overline{D}_o), volume total da tora (V_t, m^3), diâmetro da base do oco (Db_o ,), diâmetro do topo do oco (Dt_o), comprimento
 446 do oco (C_o) e comprimento da tora (C_t , número de toras (n).

447 Fonte: Autor (2023).

448 **d) Estimativa de volume de oco por meio de regressão não linear**

449 Para a estimativa do volume do oco por meio de regressão não linear, foi pré-
 450 selecionado o modelo de Schumacher-Hall sob seis diferentes formas. Com isso, foram
 451 utilizadas as seguintes combinações de variáveis independentes para estimativa do volume
 452 do oco (Quadro 2):

453 **Quadro 2** - Modelos de regressão selecionados para estimativa do volume do oco das árvores
 454 na Flona de Saracá-Taquera, estado do Pará.

N	Modelo
M1	$V_o = \beta_0 * \overline{D}_o^{\beta_1} * C_o^{\beta_2}$
M2	$V_o = \beta_0 * DAP^{\beta_1} * H^{\beta_2}$
M3	$V_o = \beta_0 * DAP^{\beta_1} * C_t^{\beta_2}$
M4	$V_o = \beta_0 * \overline{D}_o^{\beta_1}$
M5	$V_o = \beta_0 * Dt_o^{\beta_1} * Db_o^{\beta_2} * C_o^{\beta_3}$
M6	$V_o = \beta_0 * DAP^{\beta_1} * H^{\beta_2} * C_o^{\beta_3}$

455 Onde: Volume do oco (V_o), diâmetro a 1,30 m de altura do solo (DAP,), diâmetro da base da tora (Db ,), diâmetro
 456 do topo da tora (Dt), Altura estimada do Inventário Florestal a 100% (H) , média do diâmetro do oco (\overline{D}_o),
 457 diâmetro da base do oco (Db_o ,), parâmetros do modelo a ser estimado, (β_i), diâmetro do topo do oco (Dt_o),
 458 comprimento do oco (C_o), e comprimento da tora (C_t).

459
 460 Fonte: Autor (2023)

461 Os modelos foram ajustados sem considerar o efeito das espécies, isto é, foram gerados
 462 modelos globais, porque não tem como colocar a variável espécie em um modelo tradicional
 463 de regressão. Os modelos foram ajustados considerando 70% dos dados, assim como nas redes
 464 neurais. A validação foi realizada apenas para o modelo selecionado, na qual foi utilizado o
 465 teste *t* de *student* pareado a 95% de probabilidade para os restantes dos dados (30%). Para o
 466 ajuste dos modelos, foi utilizado o algoritmo de Levenberg–Marquardt da função “nlsLM”, do
 467 pacote ‘minpack.lm’ do software R® (ELZHOV et al., 2016).

468 5.4. Critérios de seleção das RNAs e modelos de regressão não linear

469 Os critérios estatísticos para avaliar a RNA e modelo de regressão foram: coeficiente de
470 correlação ($r_{\hat{y}y}$), (6) bias (7) e Erro Médio Percentual Quadrático (RMSE) (8), para a verificação
471 de qual deles é mais eficiente e preciso para estimar os volumes de ocos de árvores individuais
472 testando assim a hipótese do presente estudo.

$$473 \quad r_{\hat{y}y} = \frac{n^{-1}(\sum_{i=1}^n (\hat{Y}_i - \bar{Y}_m)(Y_i - \bar{Y}))}{\sqrt{n^{-1} \sum_{i=1}^n (\hat{Y}_i - \bar{Y}_m)^2 (n^{-1} \sum_{i=1}^n (Y_i - \bar{Y}_m)^2)}} \quad (6)$$

474 Onde: Y_i = Valores observados; \hat{Y}_i = Valores estimados; \bar{Y} = Média dos valores da variável sob análise; n = número
475 de observações.

$$476 \quad \text{Bias} = n^{-1} \sum_{i=1}^n (Y_i - \hat{Y}_i) \quad (7)$$

477 Onde: Y_i = Valores Observados; \bar{Y} = Média dos valores da variável sob análise; n = Número de observações.

$$478 \quad RMSE = \frac{100}{\bar{Y}} \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (8)$$

479 Onde: Y_i = Valores Observados; \hat{Y}_i = Valores Estimados; \bar{Y} = Média dos valores da variável sobre análise; n =
480 Número de observações.

481 6. RESULTADOS E DISCUSSÃO

482 6.1 Estimativa de volume de oco por meio de Rede Neurais Artificiais

483 Foi observada uma alta variação nas estatísticas de precisão das RNAs (Tabela 3). A
484 rede 9 (R9), que utilizou as variáveis, diâmetro da base e do topo do oco e comprimento do oco,
485 apresentou o menor erro de estimativa (0,0428 m³; 4,9721%). As demais redes apresentaram
486 erros superiores, variando de 0,0430 a 0,8019 m³ (4,9988 a 93,1596 %) (Tabela 3). Com base
487 no coeficiente de correlação, é possível destacar ligeira superioridade das redes R8 e R9 ($r_{\hat{y}y} >$
488 0,99), ou seja, estas redes apresentaram maior grau de associação entre os valores observados
489 e estimados. Do total de doze redes treinadas e testadas, oito redes apresentaram erros acima de
490 10% (RMSE% > 10%), mostrando que existe diferença estatística entre os valores observados
491 e estimados.

492 **Tabela 3**– Estatísticas resultantes dos modelos para a estimativa de volume de oco das árvores
493 da Flona de Saracá - Taquera, estado do Pará a partir das redes neurais artificiais.

Rede	$r_{\hat{y}y}$	RMSE	RMSE%	Bias	Bias%
<i>Conjunto de treino</i>					
R1	0,9923	0,0993	11,8316	-0,0048	-0,5706
R2	0,9950	0,0787	9,3818	3,50.10 ⁻⁰⁵	0,0042

R3	0,9936	0,0895	10,6678	$3,20 \cdot 10^{-05}$	0,0038
R4	0,9908	0,1071	12,7658	$7,00 \cdot 10^{-06}$	0,0009
R5	0,9908	0,1072	12,7717	$7,00 \cdot 10^{-06}$	0,0008
R6	0,9415	0,2656	31,6542	0,0001	0,0067
R7	0,9947	0,0860	9,9867	-0,0008	-0,0887
R8	0,9987	0,0430	4,9988	-0,0041	-0,4743
R9	0,9974	0,0428	4,9721	0,0002	0,0192
R10	0,2460	0,8019	93,1596	-0,0009	-0,1005
R11	0,2793	0,7926	92,0779	-0,0017	-0,1978
R12	0,9460	0,2554	30,4485	-0,0013	-0,1553
Conjunto de teste					
R1	0,9967	0,0045	7,7932	-0,0029	-0,3419
R2	0,9963	0,0051	8,3363	0,0067	0,7809
R3	0,9943	0,0077	10,2275	0,0055	0,6373
R4	0,9932	0,0093	11,2331	0,0092	1,0745
R5	0,9930	0,0096	11,3895	0,0072	0,8345
R6	0,9577	0,0564	27,5991	0,0078	0,9115
R7	0,9911	0,1050	12,5141	$-3 \cdot 10^{-6}$	-0,0004
R8	0,9963	0,0679	8,0944	0,000346	0,0412
R9	0,9975	0,0553	6,5998	-0,00044	-0,0519
R10	0,3448	0,7399	88,1859	0,00087	0,103664
R11	0,3121	0,7487	89,2325	-0,00054	-0,06414
R12	0,959	0,2327	26,9638	-0,0034	-0,3920

494 **Onde:** $r_{\hat{y}y}$ = coeficiente de correlação entre valores observados e preditos; RMSE= erro médio percentual
 495 quadrático.; RMSE% = erro médio percentual quadrático.

496 Dantas (2019) avaliou a precisão de modelos tradicionais de regressão para estimar o
 497 volume do oco de árvores abatidas na Flona de Saracá-Taquera, no estado do Pará, obtendo
 498 modelos precisos, com erros de estimativa inferiores a 10%. No entanto, recomendou que outros
 499 métodos fossem pesquisados para estimar volume do oco, e que se leve em consideração a
 500 espécie. Apesar disso, foi observado a partir do uso de Redes Neurais, que a inserção da variável
 501 espécie não contribuiu com a redução do erro das estimativas, cujas redes R8 e R9, que não
 502 usaram esta variável apresentaram os menores erros, pois a amostragem deve ser maior para
 503 abordar o número de toras dentro das espécies, devido algumas espécies apresentarem uma
 504 quantidade menor de toras.

505 Além disso, destaca-se que o uso de variáveis do inventário na estimativa do volume do
 506 oco, proporcionaram erros superiores a 90%, não sendo indicadas para esta finalidade. A
 507 informação coletada no censo florestal, como o DAP, apresentou correlação fraca com a
 508 variável volume do oco, cujas redes R1, R7 e R12, que utilizou DAP como variável preditora,
 509 apresentou erro superior a 10% para estimativa do volume do oco. Campos & Leite (2017)
 510 recomendaram que os erros das estimativas de variáveis florestais não ultrapassem 10%.

511 Caso as variáveis de campo do inventário pré-corte apresentassem correlações fortes e
512 significativas com volume do oco, estas poderiam vir a prever a produção não aproveitável de
513 uma árvore em pé. Nesse sentido, fica evidente a dificuldade em se quantificar o volume do oco
514 em florestas tropicais, pois as variáveis que mais se correlacionaram àquele volume são aquelas
515 de medidas diretas, isto é, o diâmetro da base e do topo do oco, como foi observado por Dantas
516 (2019).

517 Almeida *et al.* (2022), quantificaram a presença e o volume do oco na mesma Flona e
518 registraram a ocorrência de defeitos em 53% das árvores colhidas. Dentro desta perspectiva, a
519 presença do oco em árvores manejadas pode trazer importantes consequências para o manejo
520 florestal, tendo em vista que o estoque comercial da floresta diminui devido a substituição de
521 árvores. Além disso, comprometem a taxa de crescimento de árvores comerciais, devido a
522 manutenção de árvores ocas que competem por recursos e fatores de produção com as árvores
523 sadias.

524 A maior precisão da R9 também pode ser observada na avaliação dos gráficos de
525 resíduos das RNAs, tanto no treino (Figuras 7-A9 e 8- B9) quanto no teste (Figuras 9-A9 e 10-
526 B9). A rede R9 apresentou uma concentração maior resíduos nas proximidades da linha central,
527 isto é, concentrou-se nas classes próximas a zero. Os gráficos de volumes observados por
528 estimados (Figuras 8 e 10, B9-B9), apresentaram alta significância e forte correlação ($> 0,9$).
529 Além do mais, não foram observadas tendências nas estimativas do volume do oco, sendo
530 verificado apenas um valor mais discrepante em relação aos demais (valor entre 3,5 e 4,5 m³)
531 no treino, com tendência de superestimativa (Figuras 7 e 9, A9-A9).

532

533

534

535

536

537

538

539

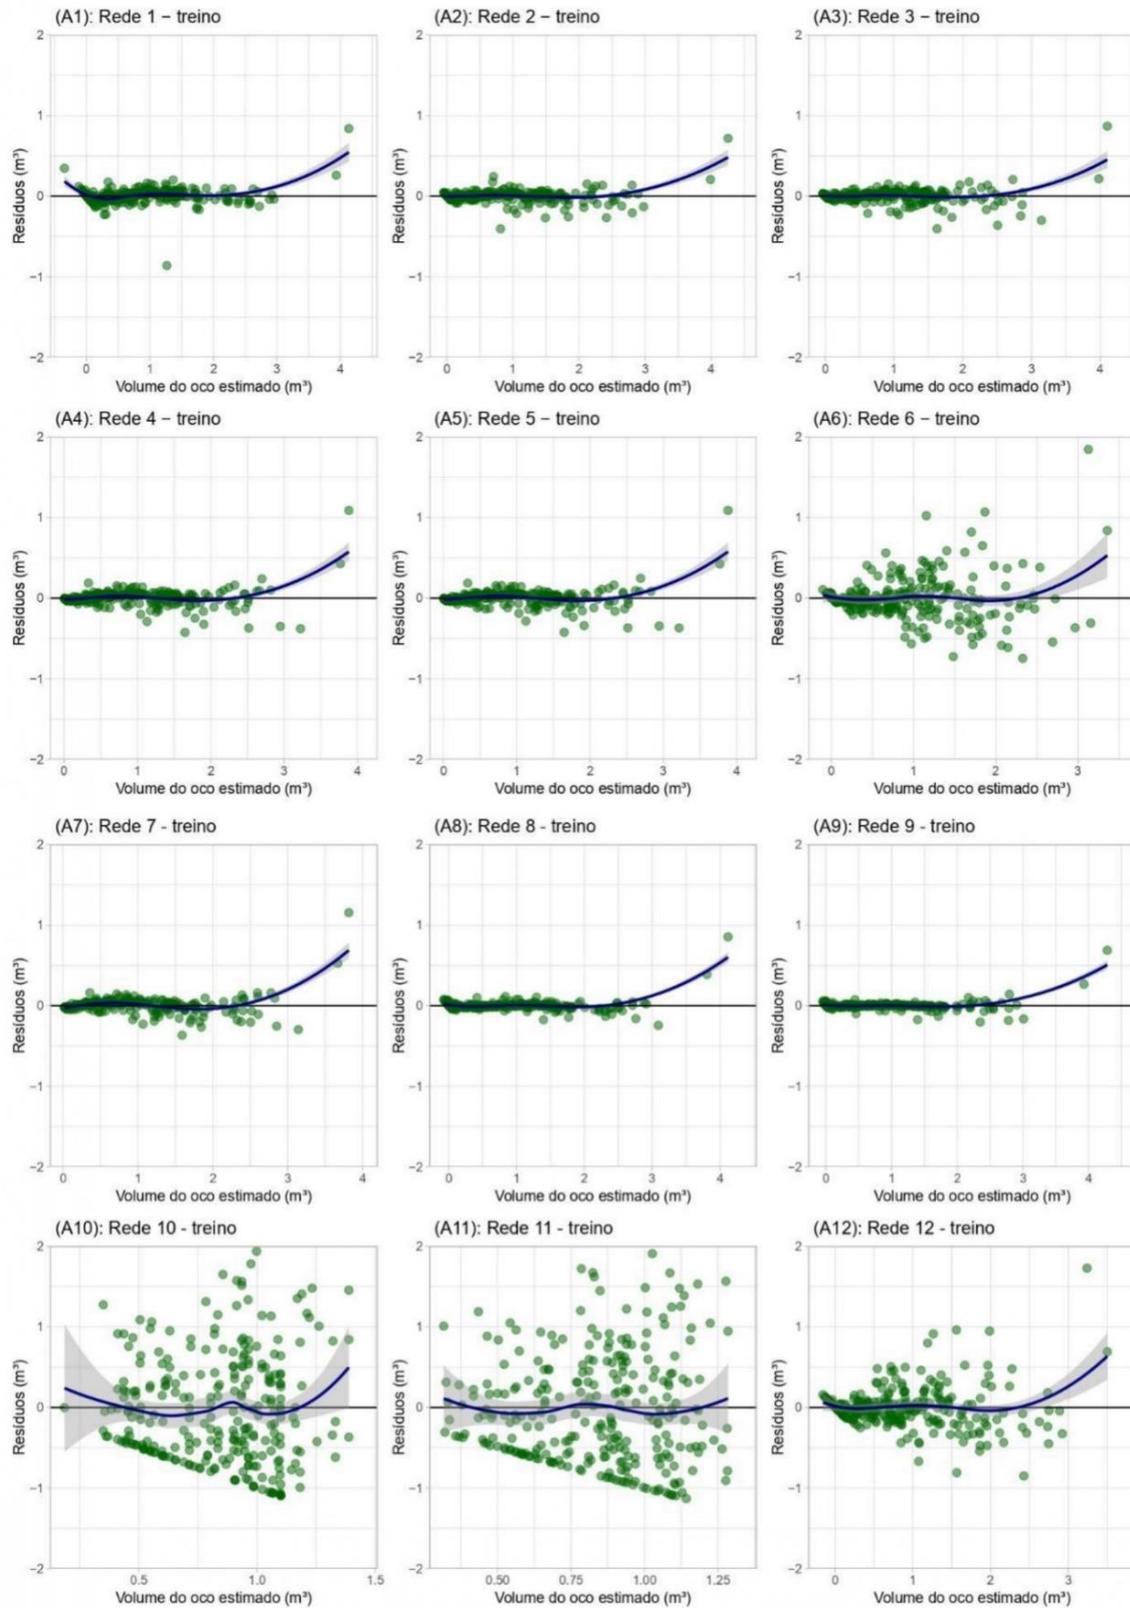
540

541

542

543

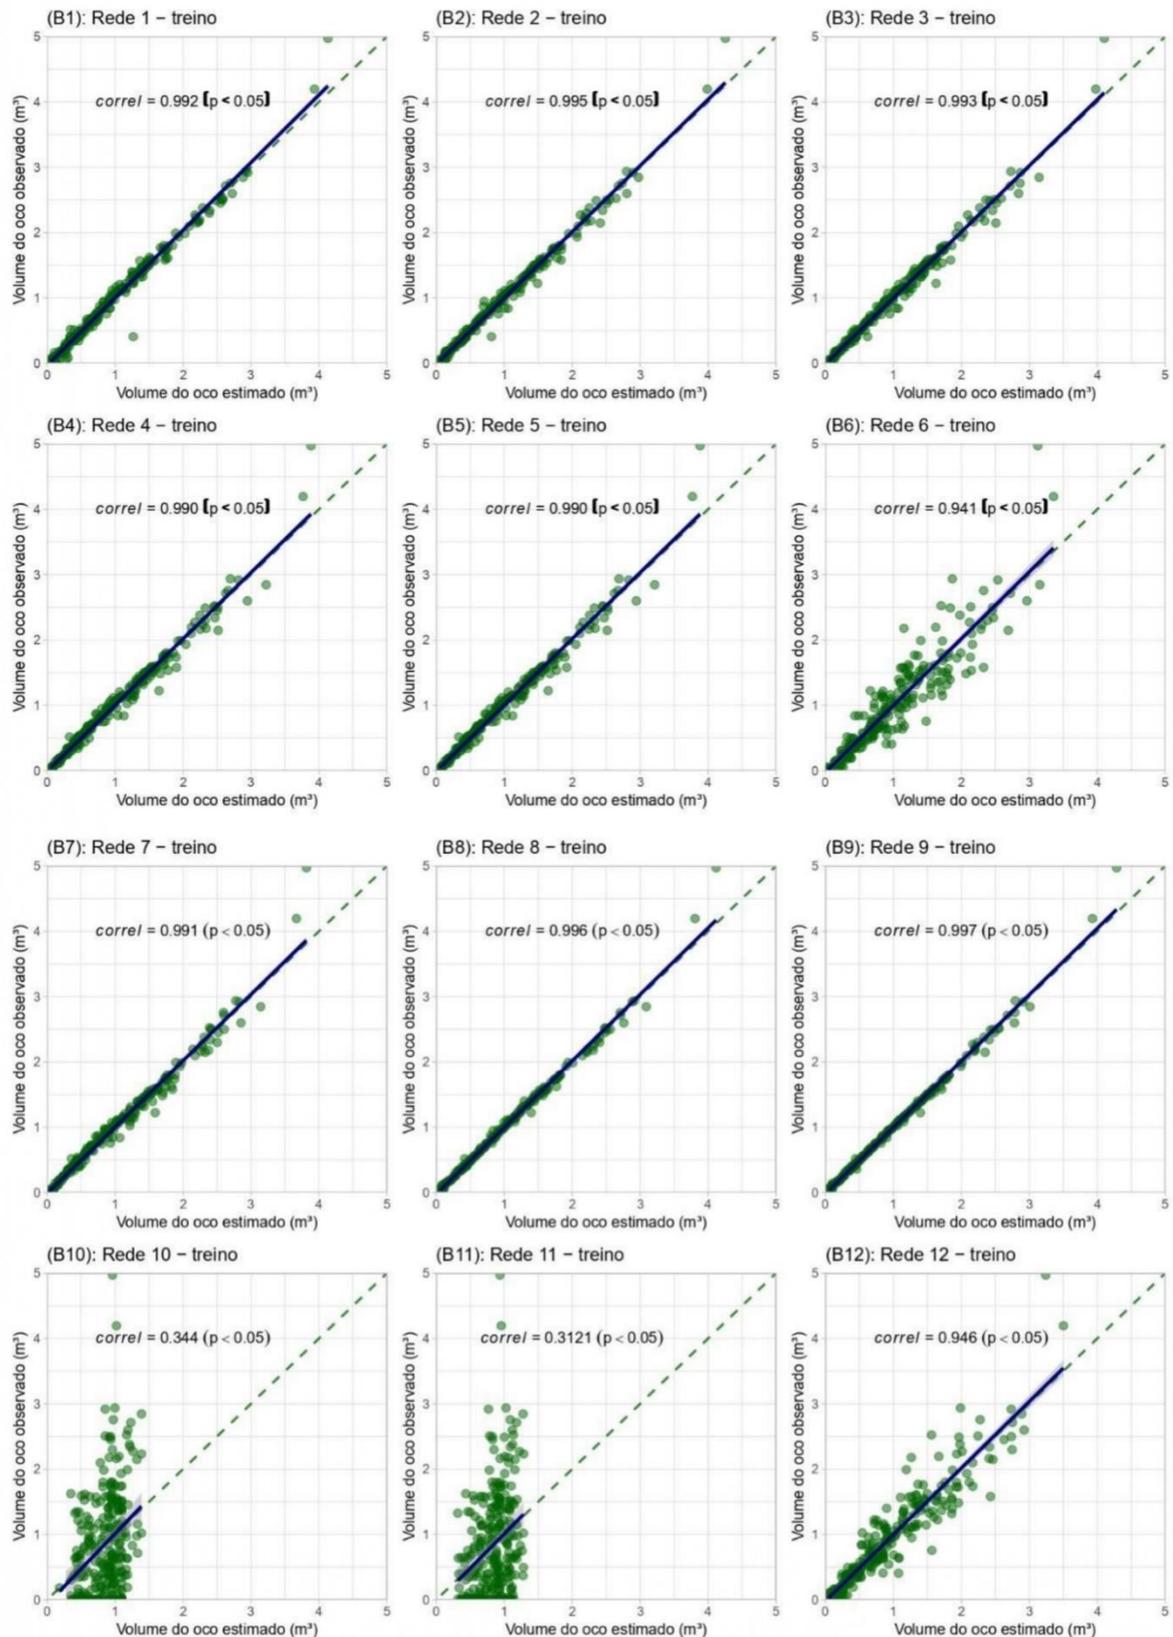
544 **Figura 7** – Gráfico dos resíduos versus volume do oco estimado para doze modelos, para
545 estimativa do volume do oco das árvores da Flona de Saracá - Taquera, estado do Pará em 2021.



546

547 Fonte: Autor (2023).

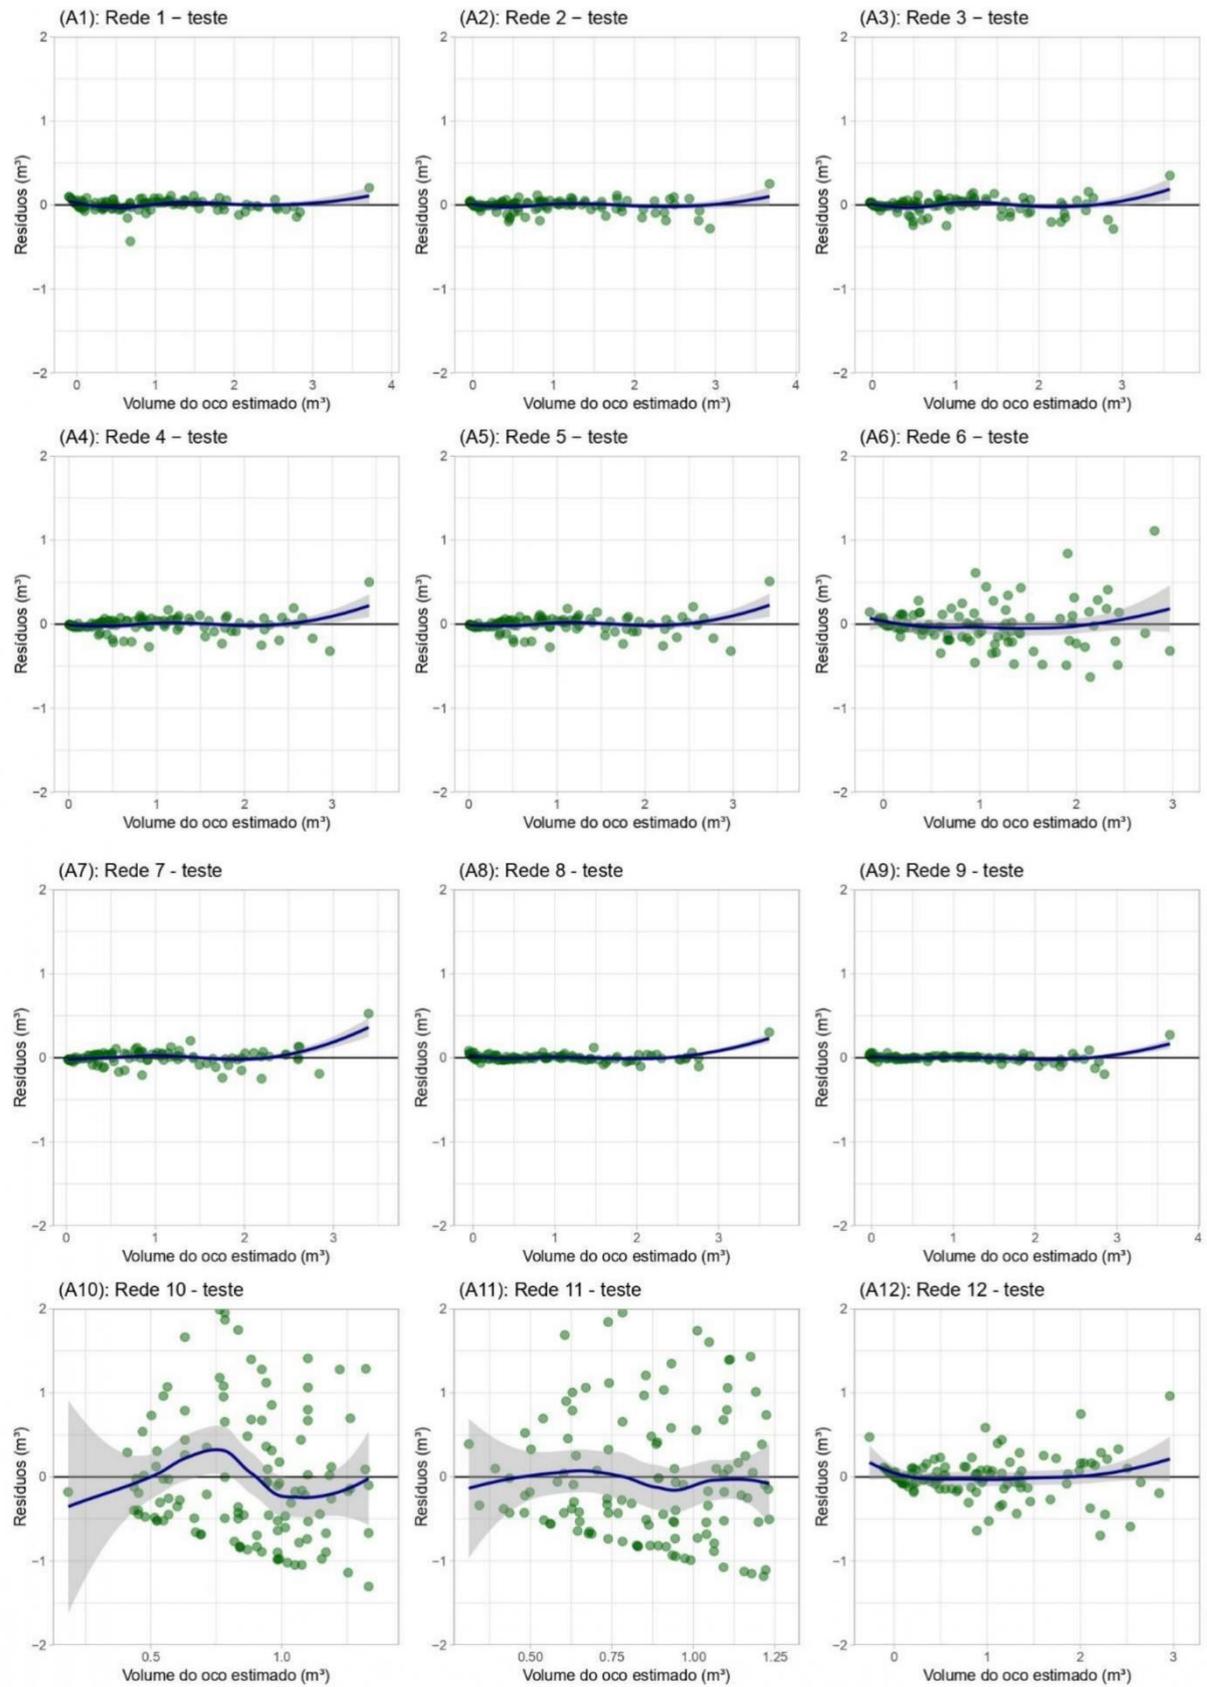
548 **Figura 8** - Gráfico dos volumes observados versus volumes estimados para estimar o volume
 549 de oco a partir dos modelos de redes neurais artificiais das árvores da Flona de Saracá – Taquera,
 550 estado do Pará em 2021.



551

552 Fonte: Autor (2023).

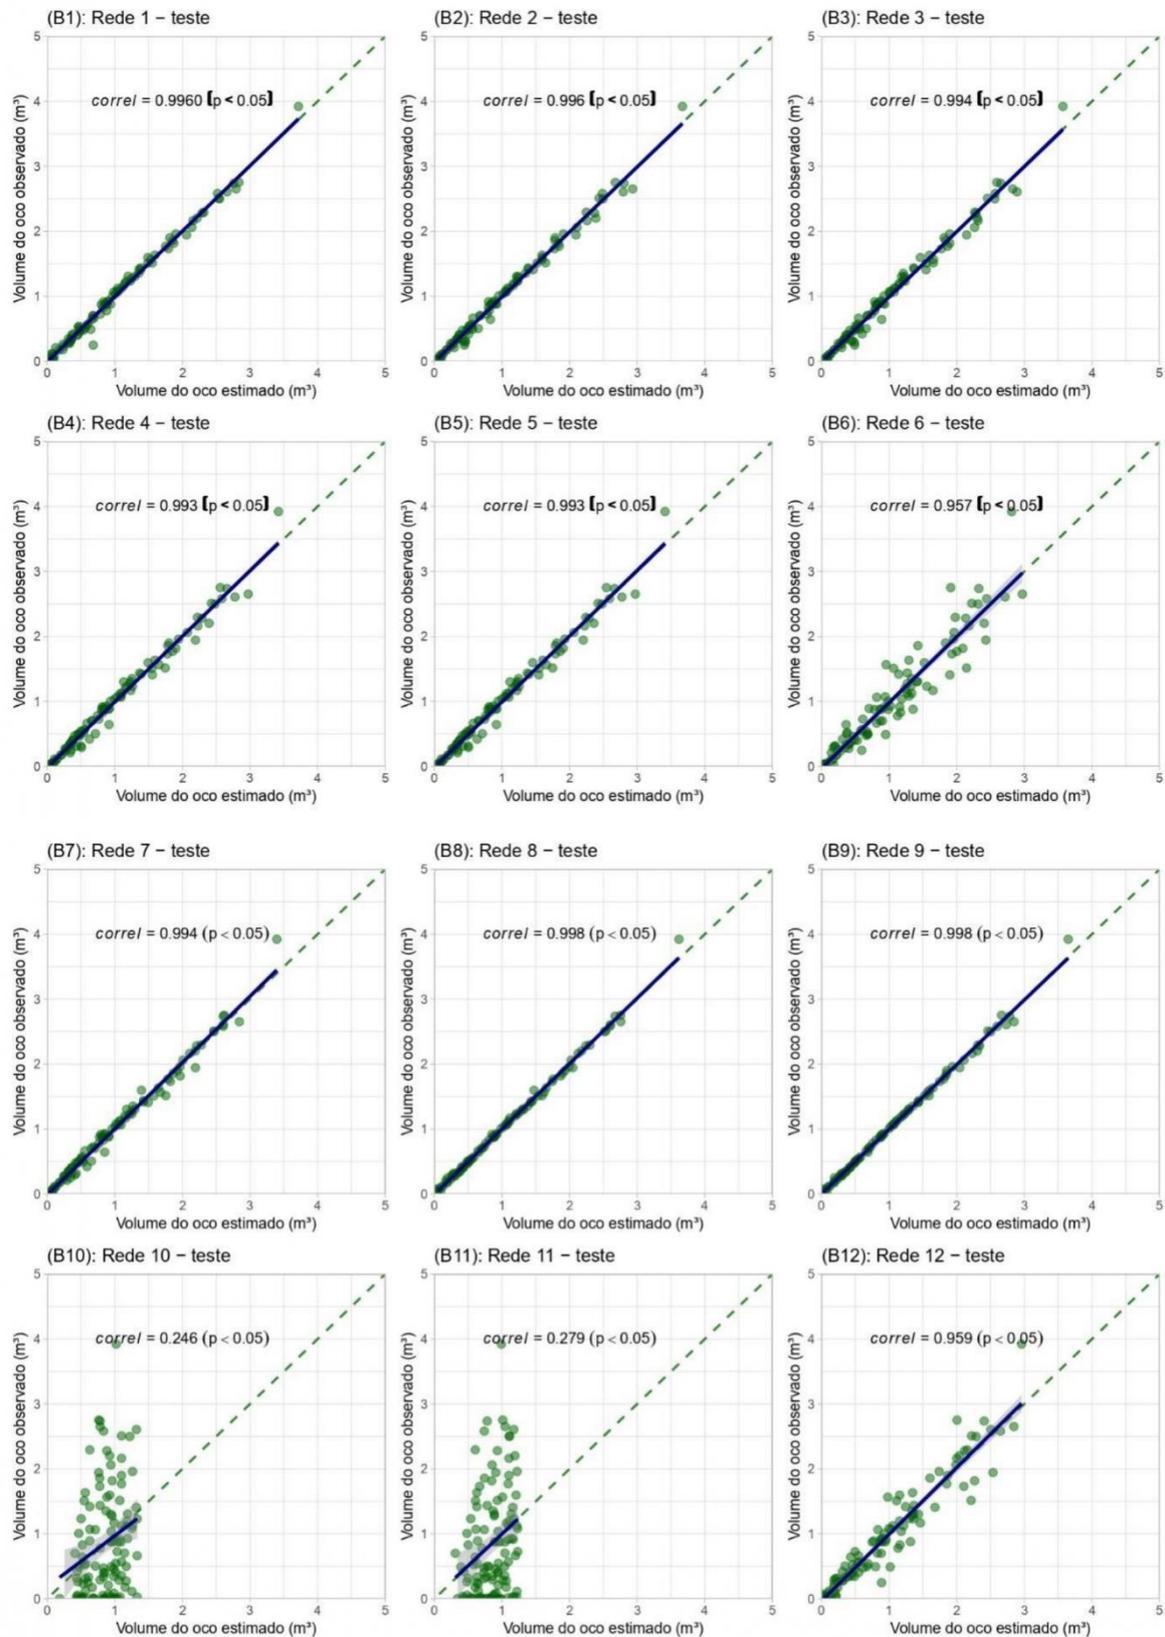
553 **Figura 9** - Gráfico dos resíduos versus volume do oco estimado para doze modelos, para
 554 estimativa do volume do oco das árvores da Flona de Saracá - Taquera, estado do Pará em 2021.



555
 556

Fonte: Autor (2023).

557 **Figura 10** - Gráfico dos volumes observados versus volumes estimados para estimativa do
 558 volume de oco a partir dos modelos de redes neurais artificiais das árvores da Flona de Saracá
 559 – Taquera, estado do Pará em 2021.



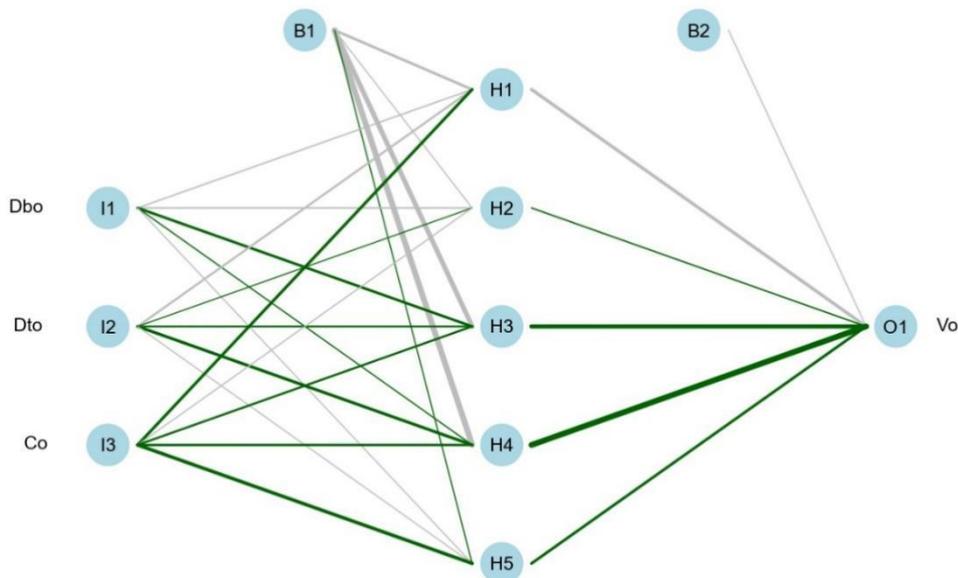
560

561 Fonte: Autor (2023).

562 Dantas (2019) ao estimar o volume de oco por intermédio de modelos de regressão,
 563 encontrou tendenciosidades nas estimativas, ratificando a tendência dos dados e a importância
 564 de avaliar a distribuição dos resíduos em conjunto com as medidas de precisão. A análise da
 565 distribuição dos resíduos é fundamental para que o processo de estimativa siga a mesma
 566 tendência de distribuição dos valores observados, limitando possíveis disfunções no
 567 comportamento da variável observada em campo (GORGENS *et al.*, 2009).

568 A arquitetura R9 indicou os melhores resultados por utilizar variáveis que são e podem
 569 ser obtidas durante o romaneio das toras, acrescentando os diâmetros do oco nas extremidades
 570 das mesmas e o comprimento do oco onde as linhas verdes das redes são os valores positivos
 571 exemplo (i3->h1) e as cores cinzas são valores negativos (i1->h1) (Apêndice 1) e as espessuras
 572 das linhas são os pesos, então quanto maior foi espessura maior foi o seu impacto (Figura 11).

573 **Figura 11** - Arquitetura de rede 9 selecionada e treinada para estimativa do volume do oco das
 574 árvores da Flona de Saracá - Taquera, estado do Pará.



575

576 **Onde:** I1, I2, I3 (Camada de entrada), B1, B2 (pesos da rede), H1, H2, H3, H4, H5 (Camadas ocultas ou
 577 intermediárias), O1 (camada de saída).

578 Fonte: Autor (2023).

579 6.2 Estimativa de volume de oco por meio de regressão não linear

580 Os modelos de volume de oco ajustados por regressão não linear, indicaram que o modelo
 581 de M1 foi mais preciso, com RMSE% inferior a 3% (Tabela 4), utilizando as variáveis de
 582 diâmetro médio do oco e comprimento do oco. O coeficiente de correlação foi superior a 0,99,
 583 indicando uma forte associação entre os valores estimados e observados. Resultados similares

584 foram observados para o modelo M5, porém com RMSE% ligeiramente superior a 5%. Por
 585 outro lado, as equações M2, M3 e M6 apresentaram resultados inferiores, com valores de
 586 RMSE% superior a 50% e coeficientes de correlação variando entre 0,26 e 0,55. Além disso,
 587 M2, M3 e M6 apresentaram coeficientes não significativos ao nível de 95% de probabilidade.
 588

589 **Tabela 4** - Estatísticas resultantes dos modelos para a estimativa de volume de oco das árvores
 590 da Flona de Saracá - Taquera, estado do Pará a partir dos modelos não lineares.

Modelo	Coefficientes	Erro padrão	$r_{\hat{y}y}$	RMSE	RMSE%	Bias	Bias%
<i>Dados de treino</i>							
M1	$b_0 = 0,00007885^{**}$	0,0000017	0,9996	0,0218	2,6004	-0,00083	-0,1
	$b_1 = 1,998^{**}$	0,004292					
	$b_2 = 1,011^{**}$	0,004747					
M2	$b_0 = 0,004137$	0,006737	0,2942	0,7532	89,7678	0,002517	0,3
	$b_1 = 1,179466^{**}$	0,251467					
	$b_2 = -0,057367$	0,334931					
M3	$b_0 = 0,001425$	0,002112	0,2998	0,7519	89,6056	0,003356	0,4
	$b_1 = 1,287242^{**}$	0,269656					
	$b_2 = 0,217303$	0,212661					
M4	$b_0 = 0,0013801^{**}$	0,0002934	0,9343	0,2815	33,5534	0,012586	1,5
	$b_1 = 1,7453092^{**}$	0,0519778					
	$b_0 = 0,00009409^{**}$	0,0000055					
M5	$b_1 = 1,228^{**}$	0,01237	0,9975	0,0567	6,7605	-0,00671	-0,8
	$b_2 = 0,7195^{**}$	0,01314					
	$b_3 = 1,002^{**}$	0,01264					
M6	$b_0 = 0,001518$	0,002087	0,5750	0,6462	77,0162	0,019299	2,3
	$b_1 = 1,070454^{**}$	0,210319					
	$b_2 = 0,075769$	0,262983					
	$b_3 = 0,710326^{**}$	0,12599					
<i>Dados de teste</i>							
M1	-	-	0,9997	0,0025	2,3897	-0,00084	-0,1
	-	-					
	-	-					
M2	-	-	0,2749	0,7936	92,1976	0,004195	0,5
	-	-					
	-	-					
M3	-	-	0,2647	0,7960	92,4728	0,001678	0,2
	-	-					
	-	-					
M4	-	-	0,9588	0,2371	27,5509	0,023494	2,8
	-	-					
	-	-					
M5	-	-	0,9986	0,0442	5,1378	-0,00587	-0,7
	-	-					
	-	-					

	-	-	_____					
M6	-	-	_____	0,5507	0,6923	80,4294	0,004195	0,5
	-	-	_____					
	-	-	_____					

591 **Onde:** $r_{\hat{y}y}$ = coeficiente de correlação entre valores observados e preditos; RMSE= raiz quadrada do erro médio;
592 RMSE%= erro médio percentual quadrático.
593 Fonte: Autor (2023).

594 A partir das análises de qualidade de ajuste, estatísticas de precisão e demais análises
595 gráficas, optou-se por selecionar a equação M1 para a estimativa do volume do oco para
596 validação. Conforme os resultados do teste *t* pareado (*p-valor* = 0,5468) não há diferença entre
597 os valores observados e estimados pela equação M1, que foi confirmado pelos resultados para
598 o banco de dados selecionados para teste com suas respectivas métricas na Tabela 4.

599 A dispersão de resíduos dos modelos ajustados, mostrou poucas tendências, tanto de
600 superestimativas quanto de subestimativas para a equação M1 (Figura 12 - A1 e B1). Por outro
601 lado, os modelos M2, M3 e M6 apresentaram maiores tendências de erros ao longo de
602 praticamente toda amplitude do volume do oco (Figura 12). Os mesmos padrões foram
603 observados para o banco de dados de teste, evidenciando a superioridade da equação M1
604 (Figura 13).

605

606

607

608

609

610

611

612

613

614

615

616

617

618

619

620

621

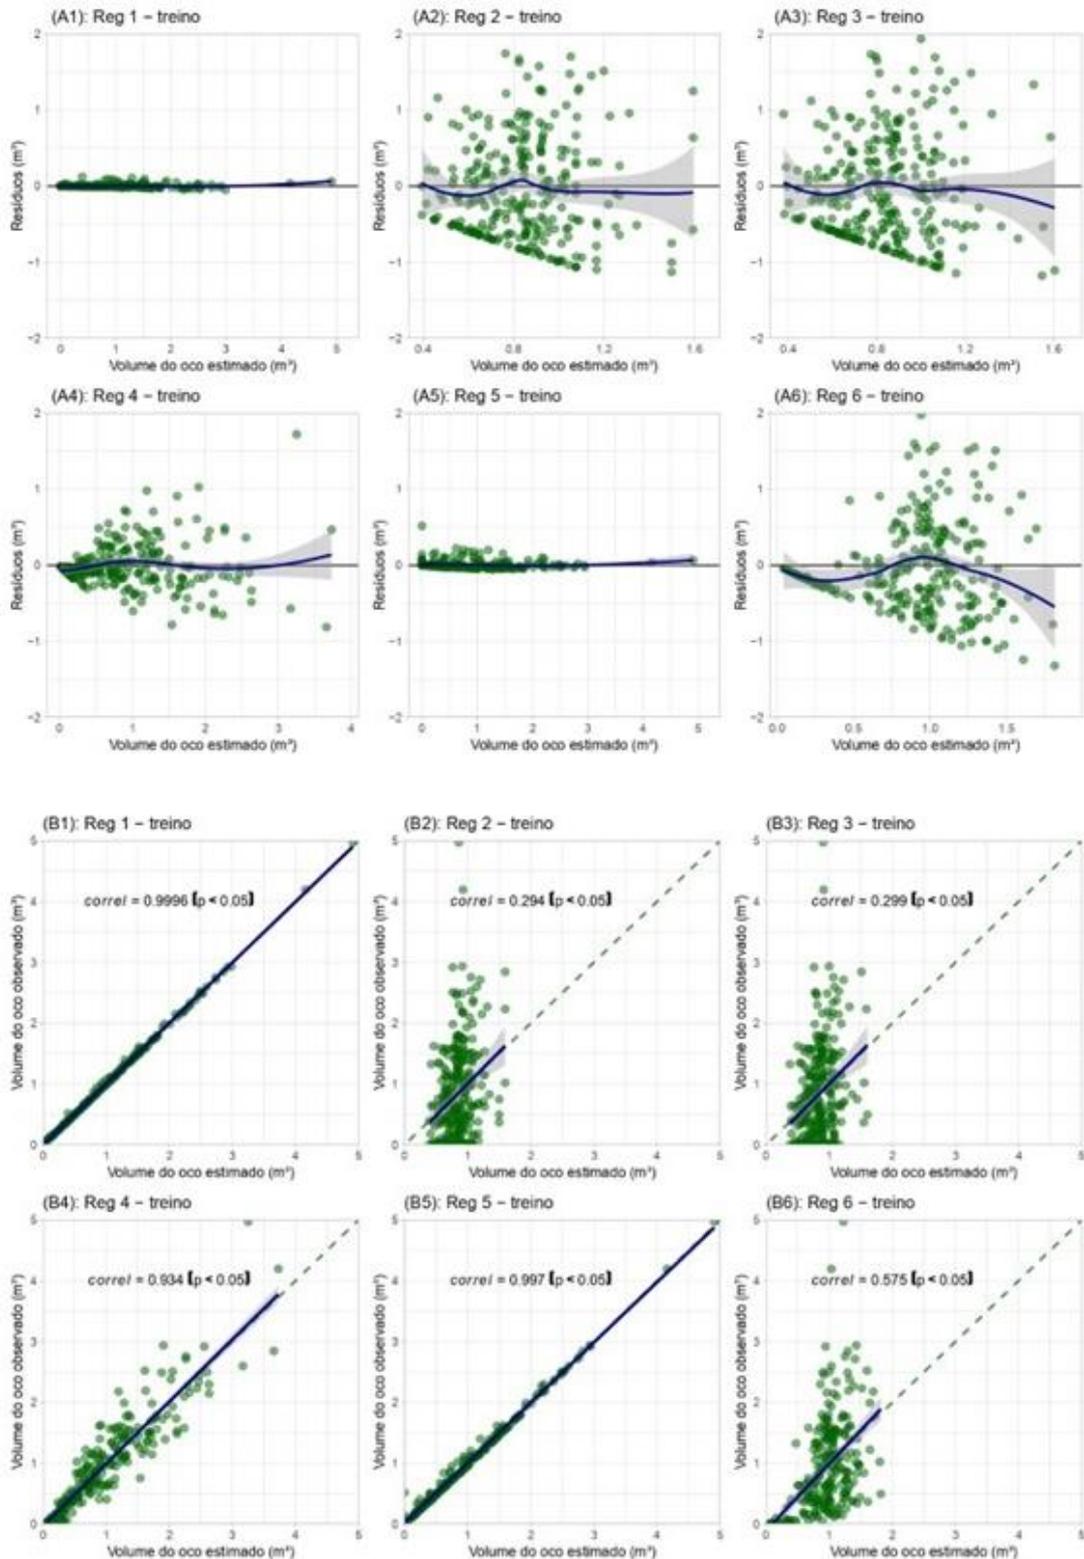
622

623

624

625
 626
 627
 628
 629
 630

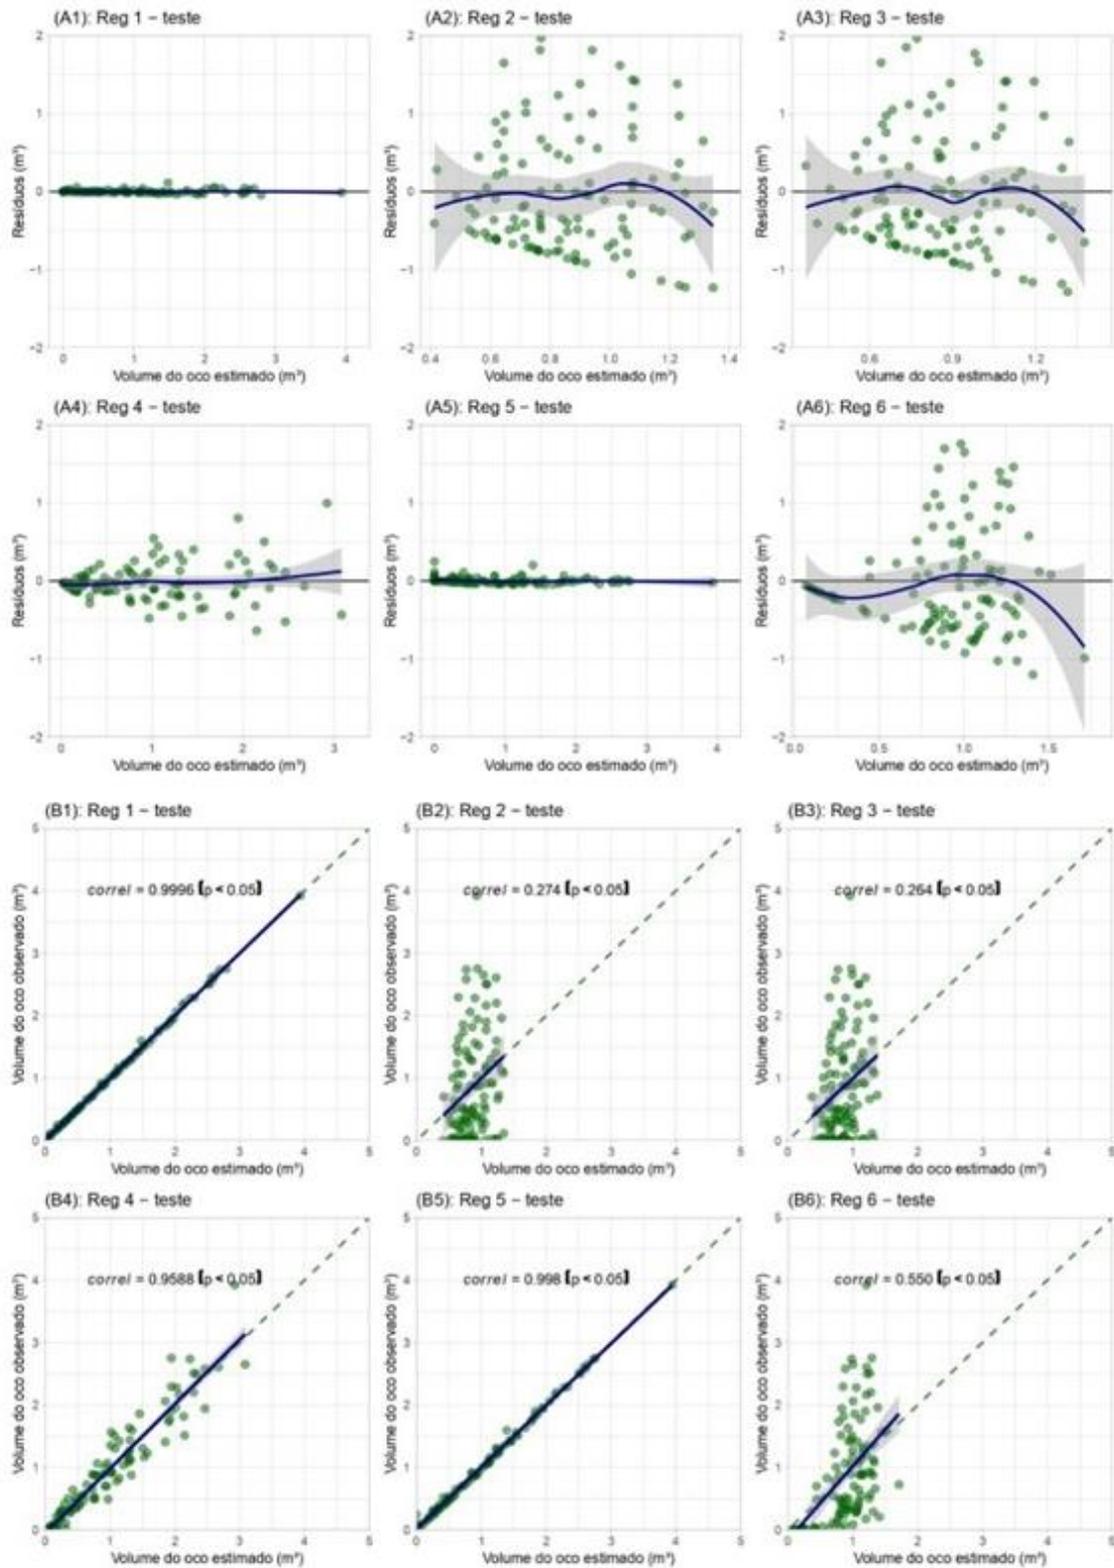
Figura 12. Gráfico dos resíduos versus volume do oco estimado (A) e relação entre os volumes observados e estimados para seis modelos de regressão não linear, para estimativa do volume do oco das árvores da Flona de Saracá - Taquera, estado do Pará em 2021.



631
 632

Fonte: autor 2023.

633 **Figura 13.** Gráfico dos resíduos versus volume do oco estimado (A) e relação entre os volumes
 634 observados e estimados para seis modelos de regressão não linear, para estimativa do volume
 635 do oco das árvores da Flona de Saracá - Taquera, estado do Pará em 2021.



636

637 Fonte: autor 2023.

638 A partir dos resultados deste estudo, verificou-se a superioridade da equação M1 frente
639 as redes neurais. Com isso, rejeita-se a hipótese elaborada, de que, as RNAs são mais precisas
640 que os modelos de regressão para estimar o volume do oco de árvores individuais em florestas
641 naturais da Amazônia brasileira. Além disso, os modelos de regressão são aplicáveis e
642 parcimoniosos, tendo em vista que, a equação selecionada possui apenas três coeficientes,
643 enquanto a melhor rede possui 27 pesos para sua aplicação.

644 De acordo com o estudo realizado por Almeida *et al.* (2022), a maioria das árvores ocas
645 permanece em pé na floresta devido à retirada de árvores substitutas após a realização do teste
646 de oco. Entretanto, mesmo com essa prática, ainda é necessário quantificar a presença de ocos
647 em árvores remanescentes. Além disso, a distribuição de árvores ocas por diâmetro indica que,
648 durante o processo de colheita, é necessário considerar não apenas as espécies com maior
649 incidência de ocos, mas também os diâmetros em que esse defeito é mais frequente (ALMEIDA
650 *et al.*, 2022).

651 Os resultados deste estudo evidenciam a dificuldade em estimar o volume do oco de
652 árvores tropicais a partir de medidas indiretas, como o DAP e altura das árvores. Pois, os ocos
653 em árvores vivas (em pé) podem ser formados por microrganismos que entram em feridas no
654 tronco ou galhos, que então decompõem a medula e o cerne destas árvores. Além de
655 microrganismos, agentes xilófagos e outros agentes como fogo, raios e ventos, iniciam ou
656 aceleram este processo de formação de ocos. Portanto, as árvores ocas continuam a crescer à
657 medida que a madeira está sendo decomposta (REMM; LÖHMUS, 2011; COCKLE; MARTIN;
658 ROBLEDO, 2012; EDWORTHY; MARTIN, 2014).

659 A taxa de decomposição da madeira destas árvores determina a velocidade de formação
660 e expansão do oco. A decomposição da madeira é afetada não apenas pelas propriedades físicas
661 e químicas, mas também por fatores ambientais, como umidade e temperatura (EDWORTHY;
662 MARTIN, 2014). Por exemplo, a ação de microrganismos, particularmente de fungos, é
663 fortemente potencializada em ambientes úmidos como a Amazônia.

664 Dentro deste contexto, as taxas de decomposição da madeira do oco, podem diferir entre
665 os microsítios florestais. Assim, os ocos de árvores geralmente começam a se formar em árvores
666 maduras, o que implica que estes são mais jovens do que as árvores hospedeiras com presença
667 de oco. No entanto, a presença de grandes cavidades, que podem se estender ao longo de todo
668 o fuste, sugere que as taxas da madeira em decomposição dentro das cavidades das árvores
669 vivas podem ser altas em comparação com as taxas de crescimento das árvores (EDWORTHY;
670 MARTIN, 2014). Portanto, o uso de variáveis como DAP e altura, dificilmente conseguirão

671 explicar e estimar o oco em árvores tropicais, tendo em vista que sua formação advém de uma
672 série de processos ecológicos complexos.

673 **7. CONCLUSÃO**

674 A RNA com as variáveis de entrada comprimento do oco, diâmetro médio da base e do
675 topo do oco, podem descrever e estimar o volume do oco das toras da Flona de Saracá - Taquera
676 de forma precisa. No entanto, foi menos precisa que a modelagem por regressão, que utilizou
677 como variáveis independentes diâmetro médio do oco e comprimento do oco. Ambas se
678 mostraram especialmente úteis para estimar o volume do oco em toras derrubadas, pois é difícil
679 determinar com precisão o volume do oco em árvores em pé.

8. APÊNDICE

Pesos das seis redes treinadas

Rede 1		Rede 2		Rede 3		Rede 4		Rede 5		Rede 6	
param	value										
b->h1	-2.63265	b->h1	-2.67925	b->h1	-1.46474	b->h1	-2.13895	b->h1	-2.14914	b->h1	-1.30103
i1->h1	0.029545	i1->h1	0.010023	i1->h1	-0.05634	i1->h1	-0.04265	i1->h1	-0.04415	i1->h1	0.022786
i2->h1	-0.04456	i2->h1	0.116146	i2->h1	-0.17978	i2->h1	-0.00165	i2->h1	0.003023	i2->h1	-0.33138
i3->h1	-0.06011	i3->h1	-0.08734	i3->h1	0.031213	i3->h1	0.010092	i3->h1	0.012001	i3->h1	-0.00811
i4->h1	-0.01831	i4->h1	0.006416	i4->h1	-0.04894	i4->h1	0.003204	i4->h1	0.002179	i4->h1	0.101092
i5->h1	0.193984	i5->h1	-0.00219	i5->h1	0.003905	i5->h1	0.005112	i5->h1	0.006267	i5->h1	-0.0022
i6->h1	0.074377	i6->h1	0.041752	i6->h1	0.020419	i6->h1	0.026216	i6->h1	0.026013	i6->h1	0.024657
i7->h1	0.003564	i7->h1	0.023377	i7->h1	-0.02199	i7->h1	-0.00922	i7->h1	-0.00952	i7->h1	0.026086
i8->h1	0.078998	i8->h1	0.024535	i8->h1	-0.03189	i8->h1	-0.01057	i8->h1	-0.01051	i8->h1	0.016217
i9->h1	0.014924	i9->h1	-0.03317	i9->h1	0.047515	i9->h1	-0.02004	i9->h1	-0.02283	i9->h1	-0.04897
i10->h1	-0.11234	i10->h1	-0.44149	i10->h1	0.11271	i10->h1	0.015651	i10->h1	0.426976	i10->h1	-0.20699
i11->h1	-0.43488	i11->h1	-0.29082	i11->h1	-0.1303	i11->h1	0.42229	i11->h1	0.840417	i11->h1	0.943173
i12->h1	-0.47421	i12->h1	0.658439	i12->h1	0.564395	i12->h1	0.83565	i12->h1	0.606827	b->h2	-0.18111
i13->h1	0.871188	i13->h1	0.34205	i13->h1	0.611232	i13->h1	0.596389	b->o	-0.01949	i1->h2	-0.01626
i14->h1	0.70705	i14->h1	1.078519	i14->h1	0.517442	b->o	-0.02108	h1->o	4.884326	i2->h2	0.099783
i15->h1	0.967568	i15->h1	0.111117	b->h2	-2.74561	h1->o	4.878216			i3->h2	0.034247
i16->h1	-0.0285	b->h2	-1.36035	i1->h2	-0.00649					i4->h2	-0.108
b->h2	0.126175	i1->h2	-0.04695	i2->h2	0.070121					i5->h2	-0.03584
i1->h2	-0.01664	i2->h2	-0.33083	i3->h2	-0.04278					i6->h2	-0.01704
i2->h2	0.006822	i3->h2	0.09272	i4->h2	0.052922					i7->h2	-0.02955
i3->h2	0.011552	i4->h2	0.004056	i5->h2	-0.00274					i8->h2	-0.0183
i4->h2	-0.00034	i5->h2	-0.01105	i6->h2	0.070015					i9->h2	-0.07584
i5->h2	-0.42614	i6->h2	0.016456	i7->h2	-0.00829					i10->h2	0.035893
i6->h2	0.00287	i7->h2	-0.03042	i8->h2	0.01031					i11->h2	0.381657

i7->h2	-0.00625	i8->h2	-0.02694	i9->h2	-0.11718	b->h3	-1.74173
i8->h2	-0.05423	i9->h2	0.030511	i10->h2	-0.43769	i1->h3	0.043286
i9->h2	-0.02942	i10->h2	0.040682	i11->h2	0.430437	i2->h3	0.080958
i10->h2	0.065121	i11->h2	-0.01016	i12->h2	0.242877	i3->h3	-0.25437
i11->h2	-0.1042	i12->h2	-0.05053	i13->h2	1.112948	i4->h3	0.037492
i12->h2	-0.01989	i13->h2	0.503053	i14->h2	0.358028	i5->h3	0.154897
i13->h2	0.056979	i14->h2	0.645733	b->o	-0.07171	i6->h3	0.0711
i14->h2	0.095271	i15->h2	0.446288	h1->o	2.114376	i7->h3	0.045128
i15->h2	0.59726	b->o	-0.09631	h2->o	3.197958	i8->h3	0.02492
i16->h2	0.014781	h1->o	3.227217			i9->h3	0.154471
b->o	-0.678	h2->o	2.107426			i10->h3	0.862785
h1->o	3.574313					i11->h3	0.58069
h2->o	2.005479					b->h4	0.277409
						i1->h4	0.014399
						i2->h4	-0.01091
						i3->h4	-0.04793
						i4->h4	0.099599
						i5->h4	0.037469
						i6->h4	0.013154
						i7->h4	0.027452
						i8->h4	0.017539
						i9->h4	0.060965
						i10->h4	-0.10652
						i11->h4	-0.39552
						b->h5	-0.18335
						i1->h5	-0.01498
						i2->h5	0.022295
						i3->h5	0.057544
						i4->h5	-0.10458

i5->h5	-0.03473
i6->h5	-0.01461
i7->h5	-0.02729
i8->h5	-0.01734
i9->h5	-0.0655
i10->h5	0.082248
i11->h5	0.355883
b->o	-0.08622
h1->o	1.590403
h2->o	0.571741
h3->o	1.987106
h4->o	-0.6976
h5->o	0.55213

Rede 7		Rede 8		Rede 9		Rede 10		Rede 11		Rede 12	
param	value	param	value	param	value	param	value	param	value	param	value
b->h1	-2.3551	b->h1	-1.02742	b->h1	-0.96759	b->h1	1.148003	b->h1	0.27172	b->h1	-2.55154
i1->h1	-0.03582	i1->h1	-0.64476	i1->h1	-0.21218	i1->h1	-0.63627	i1->h1	1.069668	i1->h1	0.195355
i2->h1	0.006524	i2->h1	1.100573	i2->h1	-0.62196	i2->h1	-1.05176	i2->h1	0.182608	i2->h1	-0.1027
i3->h1	0.007397	b->h2	-1.5728	i3->h1	1.109222	b->h2	0.323704	b->o	0.215267	i3->h1	-0.35706
i4->h1	0.000459	i1->h2	0.963446	b->h2	-0.03711	i1->h2	1.669749	h1->o	1.119174	i4->h1	-0.04172
i5->h1	0.004113	i2->h2	0.472562	i1->h2	-0.32717	i2->h2	1.024265			i5->h1	0.139888
i6->h1	0.035403	b->h3	-3.19379	i2->h2	0.025711	b->o	-0.81167			i6->h1	0.174689
i7->h1	-0.00878	i1->h3	1.635673	i3->h2	-0.08834	h1->o	1.260891			i7->h1	0.42071
i8->h1	-0.00539	i2->h3	0.865031	b->h3	-2.24447	h2->o	1.326347			i8->h1	0.123791
i9->h1	-0.02551	b->h4	-0.04346	i1->h3	0.953689					i9->h1	0.130342
i10->h1	-0.02797	i1->h4	-0.03361	i2->h3	0.471417					i10->h1	-0.2439
i11->h1	1.353812	i2->h4	1.443113	i3->h3	0.648786					i11->h1	1.642034
i12->h1	0.605608	b->h5	-0.04733	b->h4	-2.84744					i12->h1	-0.29475
b->o	0.009144	i1->h5	-0.27201	i1->h4	0.121795					b->h2	0.348874
h1->o	5.029787	i2->h5	-0.10382	i2->h4	1.167943					i1->h2	-0.18454
		b->o	-0.12197	i3->h4	0.817893					i2->h2	-0.01959
		h1->o	-1.23265	b->h5	0.060099					i3->h2	0.209784
		h2->o	1.368937	i1->h5	-0.06049					i4->h2	0.085834
		h3->o	3.550798	i2->h5	-0.06156					i5->h2	0.08001
		h4->o	0.926104	i3->h5	1.426302					i6->h2	0.041569
		h5->o	0.270531	b->o	-0.06251					i7->h2	-0.19507
				h1->o	-1.30404					i8->h2	-0.25394
				h2->o	0.224528					i9->h2	-0.37181
				h3->o	1.914661					i10->h2	-0.96756
				h4->o	2.837583					i11->h2	0.363084
				h5->o	1.000187					i12->h2	-0.25516
										b->h3	-1.69911

i1->h3	-0.15154
i2->h3	0.045186
i3->h3	0.046668
i4->h3	0.102046
i5->h3	-0.0282
i6->h3	0.036534
i7->h3	-0.19856
i8->h3	0.111837
i9->h3	0.064336
i10->h3	-0.01987
i11->h3	1.224124
i12->h3	0.279391
b->h4	0.484679
i1->h4	-0.01478
i2->h4	0.148285
i3->h4	0.002938
i4->h4	-0.06316
i5->h4	-0.0298
i6->h4	-0.05415
i7->h4	-0.21898
i8->h4	-0.32752
i9->h4	0.358677
i10->h4	0.973726
i11->h4	0.420529
i12->h4	0.308184
b->o	-1.0819
h1->o	1.85631
h2->o	1.046299
h3->o	1.999846

681 **9. REFERÊNCIAS**

- 682 ABEGG, M. *et al.* Tree volume estimation with terrestrial laser scanning — Testing for bias in
683 a 3D virtual environment. **Agricultural and Forest Meteorology**, v. 331, p. 109348, mar.
684 2023.
- 685 AKKOÇ, S. An empirical Comparison of conventional techniques, neural networks and the
686 three-stage hybrid Adaptive Neuro Fuzzy Inference System (ANFIS) model for credit scoring
687 analysis: The case of Turkish credit card data. **European Journal of Operational Research**,
688 v. 222, p. 168–178, 2012.
- 689 ALMEIDA, V. B. **Impacto da ocorrência de oco no rendimento volumétrico e financeiro**
690 **da colheita de madeira na Floresta Nacional de Saracá-Taquera, Pará.** 2018. 53f.
691 Dissertação (Mestrado em Ciências Florestais). Programa de Pós-Graduação em Ciências
692 Florestais. Universidade Federal Rural da Amazônia, Belém Pará, 2018.
- 693 ALMEIDA, *et al.* Impacto da ocorrência de árvores ocas no rendimento da colheita de madeira
694 na Floresta Nacional de Saracá-Taquera, Pará. **Pesquisa Florestal Brasileira**, [S. l.], v. 42,
695 2022.
- 696 ALVARES, C. A. *et al.* Köppen's climate classification map for Brazil. **Meteorologische**
697 **Zeitschrift**, v. 22, n. 6, p. 711–728, 2013.
- 698 APAYDIN *et al.*, Extracting tomographic images of interior structures of cylindrical objects
699 and trees using Ground Penetrating Radar method. **Results in Engineering**. Volume 14, 2022.
- 700 ARAÚJO, B. H. P. de. **Modelagem da altura, volume e afilamento do fuste de**
701 **Calycophyllum Spruceanum Benth. empregando regressão e redes neurais artificiais.**
702 2015. 53f. Dissertação (Mestrado) - Instituto Nacional de Pesquisas da Amazônia, Manaus,
703 2015.
- 704 ASNER, G. P. *et al.* A Contemporary Assessment of Change in Humid Tropical Forests.
705 **Conservation Biology**, v. 23, n. 6, p. 1386–1395, dez. 2009.
- 706 BARROS, P. L. C.; SILVA JÚNIOR, A. T. Equação de volume para árvores de uma floresta
707 tropical densa no município de Anapu, oeste do estado do Pará, Amazônia oriental. **Revista**
708 **Ciências Agrárias**, Belém, n.5, p. 15-126, 2009.
- 709 BENEDEK, Z.; FERTŐ, I. Does economic growth influence forestry trends? An environmental
710 Kuznets curve approach based on a composite Forest Recovery Index. **Ecological Indicators**,
711 v. 112, p. 9, maio 2020.
- 712 BENTES, B. A. H. F. **Aplicação de redes neurais artificiais para estimativa de volume de**
713 **árvores em pé em uma floresta ombrófila densa na Amazônia Oriental.** 2018. 59f.
714 Dissertação (Mestrado em Ciências Florestais). Programa de Pós-Graduação em Ciências
715 Florestais. Universidade Federal Rural da Amazônia, Belém, Pará, 2018.
- 716 BINOTI, M. L. M. S. **Emprego de redes neurais artificiais em mensuração e manejo**
717 **florestal.** Tese (Doutorado em Ciência Florestal). Programa de Pós-Graduação em Ciência
718 Florestal. Universidade Federal de Viçosa, Viçosa, Minas Gerais, 2012.

- 719 BINOTI, M. L. M. S.; BINOTI, D. H. B.; LEITE, H. G. Aplicação de redes neurais artificiais
720 para estimação da altura de povoamentos equiâneos de eucalipto. **Revista Árvore**, Viçosa-MG,
721 v.37, n.4, p.639-645, 2013
- 722 BINOTI, M. L. M. S. *et al.* Redes neurais artificiais para estimação do volume de árvores.
723 **Revista Árvore**, v. 38, n. 2, p. 283-288, 2014.
- 724 BRASIL. **Lei Nº 9.985, de 18 de julho de 2000**. Regulamenta o art. 225, § 1o, incisos I, II, III
725 e VII da Constituição Federal, institui o Sistema Nacional de Unidades de Conservação da
726 Natureza e dá outras providências.
- 727 BRASIL. **Instrução Normativa MMA nº 5 de 11/12/2006**. Disponível em:
728 <https://www.legisweb.com.br/legislacao/?id=76720>. Acesso em: 2 fev. 2018. Publicada
729 originalmente no Diário Oficial da República Federativa do Brasil, Brasília, DF, em 13 dez.
730 2006.
- 731 BULLINARIA, J. A. **Introduction to neural Computation**, 2009.
- 732 CAMPOS, J. C. C; LEITE, H. G. **Mensuração florestal: perguntas e respostas**. 3.ed. Viçosa,
733 MG: Universidade Federal de Viçosa, 2009. 543p.
- 734 CAMPOS, J.C.C, LEITE, H.G. **Forest Measurement**, 5th ed. UFV, Viçosa, Minas
735 Gerais,2017. 636 pp.
- 736 CARRIJO, J. V. N. *et al.* Artificial intelligence associated with satellite data in predicting
737 energy potential in the Brazilian savanna woodland area. **iForestBiogeosciences and Forestry**,
738 v.13, n. 1, 48, 2020.
- 739 CARVALHO, L. V. **Modelagem do volume comercial de madeira em pé e extraída de uma**
740 **floresta ombrófila aberta com bambu no Sul do estado do Amazonas**. 2018. Dissertação
741 (Mestrado em Ciências Florestais). Programa de Pós-Graduação em Ciências Florestais.
742 Universidade Federal Rural da Amazônia, Belém, Pará, 2018.
- 743 CASTELLANOS, A.; BLANCO, A. M.; PALENCIA, V. Applications of radial basis neural
744 networks for arca forest. **International Journal Information Theories and Applications**,
745 v.14, p.218-222, 2007.
- 746 CHEN *et al.*, Internal decay inspection of tree trunks using 3D point cloud and reverse time
747 migration of ground penetrating radar data. **NDT & E International**.Volume
748 137,2023.COCKLE, K.L., MARTIN, K. ROBLEDO, G. **Linking fungi, trees, and hole-using**
749 **birds in a Neotropical tree-cavity network**: pathways of cavity production and implications
750 for conservation. *Forest Ecology and Management*, 264, 210–219. 2012.
751
- 752 CONDÉ, T. M. *et al.* Effects of sustainable forest management on tree diversity, timber
753 volumes, and carbon stocks in an ecotone forest in the northern Brazilian Amazon. **Land Use**
754 **Policy**, v. 119, p. 106145, ago. 2022.
- 755 COUTO, H. T. Z; BASTOS, N.L.M. Modelos de equações de volume e relações hipsométricas
756 para plantações de Eucalyptus no Estado de São Paulo. ESALQ-USP, Depto. de Ciências
757 Florestais, Piracicaba, p. 33-44. 1987.
- 758 DANTAS, A. G. S. O. **Estimativa do volume de oco em árvores de uma floresta ombrófila**
759 **densa na Amazônia oriental brasileira**. 2021. 42f. Tese (Doutorado). Programa de Pós-

- 760 Graduação em Ciências Florestais. Universidade Federal Rural da Amazônia. Belém, Pará,
761 2021.
- 762 DIAMANTOPOULOU, M. J. Artificial neural network as an alternative tool in pine bark
763 volume estimation. **Computers and Electronics in Agriculture**, v. 48, n.3, p. 235-244, 2005.
- 764 DRAPER, N. R.; SMITH, H. Applied regression analysis. John Wiley, New York, 1981.
- 765 EDWORTHY, A. MARTIN, K. **Long-term dynamics of the characteristics of tree cavities**
766 **used for nesting by vertebrates**. Forest Ecology and Management, 334, 122–128.2014.
- 767 ELEUTERIO, A. A.; JESUS, M. A. DE; PUTZ, F. E. Stem Decay in Live Trees: Heartwood
768 Hollows and Termites in Five Timber Species in Eastern Amazonia. **Forests**, v. 11, n. 10, p.
769 1087, 13 out. 2020.
- 770 ELZHOV, T.V. *et al.* **minpack.lm**: R interface to the levenberg-marquardt nonlinear least-
771 squares algorithm found in MINPACK, plus support for bounds. 2016.
- 772 FIGUEIREDO FILHO, A; MACHADO, S. A; MIRANDA, R. O. V. **Compêndio de equações**
773 **de volume e de afilamento de espécies florestais plantadas e nativas para as regiões**
774 **geográficas do Brasil**. Curitiba: os autores, 2014. 306p.
- 775 GONÇALVES, F. C. **Predição volumétrica utilizando redes neurais artificiais e dados de**
776 **sensoriamento remoto em floresta nativa na Amazônia brasileira**. 2021. 65f. Dissertação
777 (Mestrado - Mestrado em Ciências Florestais). Programa de Pós-Graduação em Ciências
778 Florestais. Universidade de Brasília, Distrito Federal, Brasília, 2021.
- 779 GORGENS, E. B. *et al.* Estimação do volume de árvores utilizando redes neurais artificiais.
780 **Revista Arvore**, v.33, n.6, p.1 141-1147, 2009.
- 781 GUAN, B. T; GERTNER, G. Z. Using a paralled distributed processing system to model
782 individual tree mortality. **Forest Science**. Lawrence, v. 37, n. 3, p. 871-885, 1991.
- 783 HAYKIN, S. **Neural Networks and Learning Machines**, Prentice Hall, Third Edition, 2008.
- 784 HAYKIN, S. **Redes neurais: princípios e prática**. Porto Alegre: 2001. 900p.
- 785 HEINSDIJK, D.; BASTOS, A.M. **Inventários florestais na Amazônia**. Rio de Janeiro, 1963,
786 100p. (Serviço Florestal. Boletim, 6).
- 787 IBGE – Instituto Brasileiro de Geografia e Estatística. **Pedologia**: Mapa esquemático de Solos.
788 Brasília, 2008. Disponível em:
789 [ftp://geoftp.ibge.gov.br/informacoes_ambientais/pedologia/mapas/unidades_da_federacao/pa_](ftp://geoftp.ibge.gov.br/informacoes_ambientais/pedologia/mapas/unidades_da_federacao/pa_pedologia.pdf)
790 [pedologia.pdf](ftp://geoftp.ibge.gov.br/informacoes_ambientais/pedologia/mapas/unidades_da_federacao/pa_pedologia.pdf). Acesso em: 26 fev. 2022.
- 791 KERSHAW JR, J. A. *et al.* **Forest mensuration**. 5° ed. John Wiley & Sons. Chichester, 2017
- 792 LACERDA, W. S. **Guia de aulas práticas de redes neurais artificiais**: versão 1.3.
793 Universidade Federal de Lavras. Lavras, 2019. 70 p.VAGLIO LAURIN, G. *et al.* Tree height
794 in tropical forest as measured by different ground, proximal, and remote sensing instruments,
795 and impacts on above ground biomass estimates. Int. J. Appl. Earth Obs. Geoinf. 2019, 82,
796 101899.

- 797 LEAL, F. A. *et al.* Redes neurais artificiais na estimativa de volume em um plantio de eucalipto
798 em função de fotografias hemisféricas e número de árvores. **Revista Brasileira de Biometria**,
799 v. 33, n. 2, p. 233-249, 2015.
- 800 LEITE F. S; REZENDE, A. V. Estimativa do volume de madeira partindo do diâmetro da cepa
801 em uma área explorada de floresta Amazônica de terra firme. **Revista Ciência Florestal**, Santa
802 Maria, v. 20, n. 1, p. 71-82. 2010.
- 803 LIMA, K. S. *et al.* Wood-Logging Process Management in Eastern Amazonia (Brazil).
804 **Sustainability**, v. 12, n. 18, p. 7571, 14 set. 2020a.
- 805 LIMA, R. B. *et al.* Effect of species and log diameter on the volumetric yield of lumber in
806 northern Brazilian Amazonia: preliminary results. **Journal of Sustainable Forestry**, v. 39, n.
807 3, p. 283–299, 2 abr. 2020b.
- 808 LIRA, J. N. **Qualidade do lenho de duas espécies amazônicas com base na densidade**
809 **básica, anatomia e por método não destrutivo de ondas de tensão em área de manejo**
810 **florestal**. 2016. 86f. Dissertação (Mestrado em Ciências Florestais e Ambientais). Programa de
811 Pós-Graduação em Ciências Florestais e Ambientais. Faculdade de Ciências Agrárias,
812 Universidade Federal do Amazona, Manaus, Amazonas, Brasil, 2016.
- 813 LOPES, M. S. **Redes Neurais Artificiais e o Manejo Florestal**. 2018. Disponível em:
814 [https://www.matanativa.com.br/redes-neurais-artificiais-e-o-manejo-](https://www.matanativa.com.br/redes-neurais-artificiais-e-o-manejo-florestal/#:~:text=As%20RNA%20t%C3%AAm%20mostrado%20um,crescimento%2C%20dentre%20muitas%20outras%20aplica%C3%A7%C3%B5es)
815 [florestal/#:~:text=As%20RNA%20t%C3%AAm%20mostrado%20um,crescimento%2C%20dentre%20muitas%20outras%20aplica%C3%A7%C3%B5es](https://www.matanativa.com.br/redes-neurais-artificiais-e-o-manejo-florestal/#:~:text=As%20RNA%20t%C3%AAm%20mostrado%20um,crescimento%2C%20dentre%20muitas%20outras%20aplica%C3%A7%C3%B5es). Acesso em: 27 abr. 2022.
- 817 LOUCHARD, A. R. B. **Produção volumétrica e custos da exploração florestal madeireira**
818 **com a inclusão de árvores ocas, em uma floresta ombrófila densa no Oeste do Pará**. 2022.
819 72f. Dissertação (Mestrado em Ciências Florestais). Programa de Pós-Graduação em Ciências
820 Florestais. Universidade Federal Rural da Amazônia, Belém, Pará, Brasil, 2022.
- 821 LUZ, L. M. *et al.* **Atlas geográfico escolar do estado do Pará**. 1ªed. GAPTA/UFPA. Belém,
822 2013.
- 823 MACHADO, S. A.; FIGUEIREDO FILHO, A. **Dendrometria**. 2. ed., 2. reimp. Guarapuava:
824 UNICENTRO, 2014. 316 p.
- 825 MONTEIRO, J. S.; SARMENTO, P. S. M.; SOTÃO, H. M. P. Saprobic conidial fungi
826 associated with palm leaf litter in Eastern Amazon, Brazil. **Anais da Academia Brasileira de**
827 **Ciencias**, v. 91, n. 3, 2019.
- 828 NOGUEIRA, E. M. *et al.* Estimates of forest biomass in the Brazilian Amazon: New allometric
829 equations and adjustments to biomass from wood-volume inventories. **Forest Ecology and**
830 **Management**, v. 256, n. 11, p. 1853–1867, nov. 2008.
- 831 NOGUEIRA, E. M.; NELSON, B. W.; FEARNESIDE, P. M. Volume and biomass of trees in
832 central Amazonia: influence of irregularly shaped and hollow trunks. **Forest Ecology and**
833 **Management**, v. 227, n. 1–2, p. 14–21, maio 2006.
- 834 OLIVEIRA, M. S. *et al.* Biomass of timber species in Central American secondary forests:
835 Towards climate change mitigation through sustainable timber harvesting. **Forest Ecology and**

- 836 **Management**, v. 496, p. 119439, set. 2021.
- 837 POUDYAL, B. H.; MARASENI, T.; COCKFIELD, G. Evolutionary dynamics of selective
838 logging in the tropics: A systematic review of impact studies and their effectiveness in
839 sustainable forest management. **Forest Ecology and Management**, v. 430, p. 166–175, dez.
840 2018.
- 841 REIS, L. P. *et al.* Estimation of mortality and survival of individual trees after harvesting wood
842 using artificial neural networks in the amazon rain forest. **Ecological Engineering**, v. 112, p.
843 140–147, mar. 2018.
- 844 REMM, J. LÔMUS, A. **Tree cavities in forests—The broad distribution pattern of a**
845 **keystone structure for biodiversity**. *For. Ecol. Manag.* 262, 579–585. 2011.
- 846
- 847 ROLIM, S. G. *et al.* Modelos volumétricos para a Floresta Nacional do Tapirapé-Aquirí, Serra
848 dos Carajás (PA). **Acta Amazônica**, v. 36, n. 1, p. 107-114, 2006.
- 849 ROMERO, F. M. B. *et al.* Allometric Equations for Volume, Biomass, and Carbon in
850 Commercial Stems Harvested in a Managed Forest in the Southwestern Amazon: A Case Study.
851 **Forests**, v. 11, n. 8, p. 874, 11 ago. 2020.
- 852 ROMERO, F. M. B. *et al.* Aboveground biomass allometric models for large trees in
853 southwestern Amazonia. **Trees, Forests and People**, v. 9, p. 100317, set. 2022.
- 854 RUMSEY, D. Estatística II para leigos. Rio de janeiro: **Alta Books**, 2014. 434 p.
- 855 SANTOS, K. N. F. *et al.* Ajuste de equações volumétricas e redes neurais artificiais na
856 estimativa do volume de Tauari na floresta nacional do Tapajós. **Revista Agroecossistemas**, v.
857 10, n. 1, p. 1-17, 2018.
- 858 SANTOS, M. F. **Modelagem de ocorrência de ocos e de equações de volume genéricas e**
859 **específicas para espécies manejadas na Amazônia**. 2020. Dissertação (Mestrado em Ciências
860 Florestais). Universidade Estadual do Centro-Oeste, Irati, Paraná, 2020.
- 861 SEBEK, P. *et al.* Is Active Management the Key to the Conservation of Saprophytic
862 Biodiversity? Pollarding Promotes the Formation of Tree Hollows. **PLOS ONE**, v. 8, n. 3, p.
863 e60456, 27 mar. 2013.
- 864 SECCO, C. B. **Deteção de oco em toras utilizando métodos de propagação de ondas**
865 **ultrassônicas**. 2011. Dissertação (Mestrado em Engenharia Agrícola). Faculdade de
866 Engenharia Agrícola, Universidade Estadual de Campinas, Campinas, 2011.
- 867 SETA – Serviços Técnicos Ambientais. Plano de Manejo Florestal Sustentável de Uso Múltiplo
868 da Floresta Nacional de Saracá-Taquera UMF 1B. Belém, 2014.
- 869 SFB – Serviço Florestal Brasileiro. Edital de Licitação para Concessão Florestal – Floresta
870 Nacional Saracá-Taquera/PA-Lote Sul. Brasília, 2012a. Disponível em:
871 [https://www.gov.br/agricultura/pt-br/assuntos/servico-florestal-brasileiro/concessao-](https://www.gov.br/agricultura/pt-br/assuntos/servico-florestal-brasileiro/concessao-florestal/concessoes-florestais-em-andamento-1/edital_saraca_taquera_lote_sul_rev.pdf)
872 [florestal/concessoes-florestais-em-andamento-1/edital_saraca_taquera_lote_sul_rev.pdf](https://www.gov.br/agricultura/pt-br/assuntos/servico-florestal-brasileiro/concessao-florestal/concessoes-florestais-em-andamento-1/edital_saraca_taquera_lote_sul_rev.pdf).
873 Acesso em: 17 de maio de 2022.

- 874 SFB - Serviço Florestal Brasileiro. **Guia para medição de produtos e subprodutos florestais**
875 **madeireiros das concessões florestais**. SFB. Brasília, 2012b.
- 876 SILVA, M. L. M. **Estimação do diâmetro sem casca e diâmetro do cerne para árvores de**
877 **Tectona Grandis Linn. utilizando redes neurais artificiais**. 2008.47f. Monografia
878 (Exigência para conclusão do curso de Engenharia Florestal) - Universidade Federal de Viçosa,
879 Viçosa, MG, 2008.
- 880 SILVA, M. L. M. *et al.* Ajuste do modelo de Schumacher e Hall e aplicação de redes neurais
881 artificiais para estimar volume de árvores de eucalipto. **Revista Árvore**, v. 33, n. 6, p. 1133-
882 1139, 2009.
- 883 SKUDNIK, M.; JEVŠENAK, J. Artificial neural networks as an alternative method to nonlinear
884 mixed-effects models for tree height predictions. **Forest Ecology and Management**, v. 507, p.
885 120017, mar. 2022.
- 886 SOARES, C. P. B; *et al.* Dendrometria e Inventário Florestal. 2. ed. Viçosa, Minas Gerais:
887 Editora UFV, p. 272, 2011.
- 888 SOARES, F. A. A. M. N. *et al.* Recursive diameter prediction for calculating merchantable
889 volume of Eucalyptus clones without previous knowledge of total tree height using artificial
890 neural networks. **Applied Soft Computing**. v. 12, p. 2030-2039, 2012.
- 891 TOSTI, F. *et al.* The Use of GPR and Microwave Tomography for the Assessment of the
892 Internal Structure of Hollow Trees. **IEEE Transactions on Geoscience and Remote Sensing**,
893 v. 60, p. 1–14, 2022.
- 894 TROCKENBRODT, M.; IMIYABIR, Z.; JOSUE, J. Hollow logs and logging residues from
895 Deramakot Forest Reserve, Sabah, Malaysia. **Forest Ecology and Management**, v. 165, n. 1–
896 3, p. 141–150, jul. 2002.
- 897 WAINHOUSE, M.; BODDY, L. Making hollow trees: Inoculating living trees with wood-
898 decay fungi for the conservation of threatened taxa - A guide for conservationists. **Global**
899 **Ecology and Conservation**, v. 33, p. e01967, jan. 2022.
- 900 WU, Z. *et al.* Simulation of forest fire spread based on artificial intelligence. **Ecological**
901 **Indicators**, v. 136, p. 108653, mar. 2022.
- 902 VALENTE, M. D. R. *et al.* Modelo de predição para o volume total de quaruba (*Vochysia*
903 *inundata* ducke) via análise de fatores e regressão. **Revista Árvore**, Viçosa, v.35, n.2, p.307-
904 317, 2011.
- 905 ZEVIANI, W. M.; RIBEIRO JÚNIOR, P. J.; BONAT, W. H. **Modelos de regressão não-**
906 **linear**. Curitiba, UFPR: Departamento de Estatística, 2013.
- 907 ZULETA, D. *et al.* Vertical distribution of trunk and crown volume in tropical trees. **Forest**
908 **Ecology and Management**, v. 508, p. 120056, mar. 2022.
- 909