



**TRABALHO DE CONCLUSÃO DE CURSO**

**Modelos volumétricos e Redes Neurais Artificiais são acurados para a predição do volume individual em povoamentos de *Tectona grandis* Linn. F.**

**Ruan Felipe Lima Caldeira**

**Brasília, setembro de 2022**

**UNIVERSIDADE DE BRASÍLIA**

FACULDADE DE TECNOLOGIA



**UNIVERSIDADE DE BRASÍLIA**  
**FACULDADE DE TECNOLOGIA**  
**DEPARTAMENTO DE ENGENHARIA FLORESTAL**

**Modelos volumétricos e Redes Neurais Artificiais são acurados para a predição do volume individual em povoamentos de *Tectona grandis* Linn.F**

**Ruan Felipe Lima Caldeira**

Trabalho de Conclusão de Curso de graduação apresentado ao Departamento de Engenharia Florestal da Universidade de Brasília como parte das exigências para obtenção do título de Bacharel em Engenharia Florestal.

Orientador: Prof. Dr. Eder Pereira Miguel

Brasília-DF, setembro de 2022



**Universidade de Brasília - UnB**

**Faculdade de Tecnologia - FT**

**Departamento de Engenharia Florestal – EFL**

## FICHA CATALOGRÁFICA



### REFERÊNCIA BIBLIOGRÁFICA

Ruan Felipe Lima Caldeira (CALDEIRA, R. F. L.) **Modelos volumétricos e Redes Neurais Artificiais são acurados para a predição do volume individual em povoamentos de *Tectona grandis* Linn. F.** Monografia (Bacharelado em Engenharia Florestal) – Universidade de Brasília, Brasília, DF.

### CESSÃO DE DIREITOS

AUTOR: Ruan Felipe Lima Caldeira

TÍTULO: Modelos volumétricos e Redes Neurais Artificiais são acurados para a predição do volume individual em povoamentos de *Tectona grandis* Linn.F.

GRAU: Engenheiro(a) Florestal

ANO: 2022

É concedida à Universidade de Brasília permissão para reproduzir cópias deste Projeto Final de Graduação e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte deste Projeto Final de Graduação pode ser reproduzida sem autorização por escrito do autor.

---

Ruan Felipe Lima Caldeira

ruanflc1@gmail.com

## **AGRADECIMENTOS**

Agradeço, primeiramente, a Deus, pois graças a Ele tenho capacidade, saúde e condições de alcançar meus objetivos e sonhos sem desistir diante de todas as adversidades.

Aos meus pais, pelo apoio e amor que me permitiram avançar. Agradeço também aos meus avós, minhas irmãs, meus tios e primos, e todos os demais familiares e amigos que fazem parte da minha vida, por me incentivarem e inspirarem.

Aos meus colegas e professores e aos funcionários do departamento de Engenharia Florestal e da UnB, por todos os anos de convivência e aprendizado.

Ao meu professor e orientador, Eder, por toda a paciência, ensinamentos e cooperação ao longo da construção desse trabalho.

Aos doutorandos Hallefy de Souza e Mario dos Santos, por todas as contribuições a esse trabalho e pelo aceite em participar da banca.

## RESUMO

Ruan Felipe Lima Caldeira (CALDEIRA, R. F. L.) **Modelos volumétricos e Redes Neurais Artificiais são acurados para a predição do volume individual em povoamentos de *Tectona grandis* Linn. F.** Monografia (Bacharelado em Engenharia Florestal) – Universidade de Brasília, Brasília, DF.

A *Tectona grandis* Linn. F. (teca) é uma das espécies tropicais com madeira mais valiosa do mundo, que possui alta demanda, o que causou um intenso crescimento de plantios no território brasileiro. Tendo em vista seu alto valor comercial, é imprescindível estimativas acuradas de seu volume nos inventários florestais. Portanto, esse estudo buscou comparar o desempenho das estimativas de volume individual de teca por intermédio de modelos volumétricos e Redes Neurais Artificiais (RNA) em um povoamento clonal na Amazônia Oriental. Foram cubadas 149 árvores utilizando o método relativo de Hohenadl, com idades variando de 4 a 12 anos. Desses dados, 70 % foram usados no ajuste dos modelos volumétricos e no treino das RNAs, e os demais 30 % na validação utilizando o teste de *bootstrap*. As redes treinadas foram do tipo Multilayer Perceptron, supervisionadas. A precisão do ajuste dos modelos volumétricos e das RNAs treinadas foi avaliada utilizando o erro padrão residual absoluto e percentual da estimativa ( $S_{yx}$  e  $S_{yx}$  %), do coeficiente de correlação ( $r$ ) e da análise gráfica de resíduos. A acurácia da RNA e do modelo volumétrico mais precisos, frente o volume verdadeiro, foram comparados pelo teste de Kruskal-Wallis e como estatística complementar a diferença agregada. Os modelos e as redes apresentaram medidas acuradas, dos quais o modelo de Takata e a RNA nº 4 alcançaram uma correlação de 0,991 e erro menor que 7,5 %. Embora a rede tenha tido uma ligeira superioridade, o teste de Kruskal-Wallis não indicou diferença significativa entre o volume estimado pelas diferentes categorias (regressão e inteligência artificial) frente ao volume real, sendo ambos capazes de gerar estimativas acuradas.

**Palavras-chave:** Teca, Inteligência Artificial, Modelagem, Regressão

## ABSTRACT

Ruan Felipe Lima Caldeira (CALDEIRA, R. F. L.) **Volumetric models and Artificial Neural Network are accurate in individual volume's prediction in a *Tectona grandis* Linn. F. stand.** Monograph (Forestry Degree) – University of Brasília, Brasília, DF.

*Tectona grandis* Linn. F. (teak) is a specie with one of the most highly valued timber in the world, which has a high demand in the international market, leading to an intense increasing in its plantations in Brazilian territory. Regarding its commercial value, accurate estimates of volume are essential to forest inventories. Hence, this study aimed to compare the performance of estimates of teak's volume made by volumetric models and artificial neural networks (ANN) for a clonal stand in the East Amazon. 149 trees were measured by Hohenadl's method, with ages ranging from 4 to 12 years, from which 70 % of the data were used to adjust the volumetric models and train the networks and the remaining 30 % were applied to validate the prediction methods by the *bootstrap* test. The ANN with *Multilayer Perceptron* architecture were trained using supervised learning. The precision of the adjustment of the volumetric models and the trained ANN was evaluated through the absolute residual standard error and percentage of the estimate ( $S_{yx}$  and  $S_{yx\%}$ ), the correlation coefficient ( $r$ ) and the graphic analysis of residues. The accuracy of the most precise ANN and volumetric model, with regard to the real volume, were contrasted by means of the Kruskal-Wallis test and the aggregated difference. Both the models and the networks presented accurate measures, from which the Takata model and ANN n° 4 presented correlation coefficient equal to 0,991 and standard error lower than 7,5 %. Although the ANN showed slightly better measures, the Kruskal-Wallis test did not find any significant difference between them (regression and ANN) when they have been faced with the real volume, being both able to predict accurately teak's volume.

**Keywords:** Teak, Artificial Intelligence, Modeling, Regression.

## LISTA DE FIGURAS

|   |    |
|---|----|
| Figura 1 - Localização da fazenda São Luiz, no município de Capitão Poço, PA.....   | 20 |
| Figura 2 - Relação entre observados x estimados ( $A_i$ ), dispersão de resíduos ( $B_i$ ) e distribuição de classes de resíduos ( $C_i$ ) para equações volumétricas de um plantio clonal de teca. ....              | 28 |
| Figura 3 - Relação entre observados x estimados ( $A_i$ ), dispersão de resíduos ( $B_i$ ) e distribuição de classes de resíduos ( $C_i$ ) para volume predito por redes neurais para um plantio clonal de teca. .... | 31 |
| .....   | 31 |
| Figura 4 – Arquitetura da rede selecionada.....   | 32 |
| Figura 5 – Gráficos de distribuição de volumes observados e estimados usados no (a) ajuste e (b) validação.....   | 33 |



## LISTA DE TABELAS

|  |    |
|--|----|
| Tabela 1 – Modelos volumétricos usados nos ajustes aos dados de povoamentos clonais de teca, em Capitão Poço, PA. .... | 22 |
| Tabela 2 – Distribuição diamétrica das árvores cubadas. ....   | 24 |
| Tabela 3 - Estatísticas descritivas das árvores cubadas.....   | 24 |
| Tabela 4 – Parâmetros e medidas de precisão dos modelos volumétricos ajustados para <i>T. grandis</i> .....            | 27 |
| Tabela 5 – Resultados do teste de equivalência para a validação do modelo volumétrico.....                             | 29 |
| Tabela 6 – Medidas de precisão das redes neurais treinadas e selecionadas. ....  | 30 |
| Tabela 7 – Teste da diferença agregada entre o volume real e os estimados. ....  | 34 |

## SUMÁRIO

|       |  |    |
|-------|--|----|
| 1     | INTRODUÇÃO .....                                     | 8  |
| 2     | OBJETIVOS .....                                      | 11 |
| 2.1   | Objetivo geral .....                                 | 11 |
| 2.2   | Objetivos específicos .....                          | 11 |
| 3     | REVISÃO BIBLIOGRÁFICA .....                          | 12 |
| 3.1   | Teca .....   | 12 |
| 3.2   | Volume .....   | 14 |
| 3.2.1 | Xilômetro .....                                      | 14 |
| 3.2.2 | Cubagem rigorosa .....                               | 14 |
| 3.2.3 | Fator de forma e quociente de forma .....            | 15 |
| 3.2.4 | Modelos volumétricos.....                            | 15 |
| 3.2.5 | Modelo de afilamento .....                           | 16 |
| 3.3   | Redes Neurais Artificiais.....                       | 17 |
| 4     | MATERIAIS E MÉTODOS .....                            | 20 |
| 4.1   | Área de estudo e caracterização dos povoamentos..... | 20 |
| 4.2   | Amostragem.....                                      | 21 |
| 4.3   | Cubagem.....   | 21 |
| 4.4   | Regressão.....                                       | 22 |
| 4.5   | RNA.....   | 22 |
| 4.6   | Ajuste e validação.....                              | 23 |
| 4.7   | Avaliação .....                                      | 25 |
| 4.7.1 | Avaliação dos modelos e critério de escolha .....    | 25 |
| 4.7.2 | Avaliação das redes neurais .....                    | 26 |

|       |  |    |
|-------|--|----|
| 4.7.3 | Comparação entre modelos e redes .....                     | 26 |
| 5     | RESULTADOS E DISCUSSÃO .....                               | 27 |
| 5.1   | Modelagem por regressão.....                               | 27 |
| 5.2   | Modelagem volumétrica por Redes Neurais Artificiais .....  | 30 |
| 5.3   | Comparação entre redes neurais e modelos de regressão..... | 32 |
| 6     | CONCLUSÕES .....   | 36 |
|       | REFERÊNCIAS .....  | 37 |

# 1 INTRODUÇÃO

Historicamente, a humanidade foi dependente de recursos madeireiros para o suprimento de demandas diversas, como energéticas e estruturais. Contudo, nos últimos séculos foi observado um aumento do nível do desmatamento, o que incentivou um uso mais parcimonioso e técnico do volume de madeira consumido. Movido por essas razões, desde o século XX, após grandes mudanças, como a criação do Código Florestal e de órgãos governamentais, e devido aos incentivos fiscais concedidos, além da criação de cursos específicos, na década de 60, o setor florestal ganhou crescente e relevante importância no cenário econômico brasileiro (KENGGEN, 2001). Atualmente, estima-se que estejam plantadas 9,55 milhões de hectares de florestas para propósitos industriais, com destaque para os plantios de eucalipto, pinus, acácia e teca (IBÁ, 2021). Essa última vem tendo um aumento recente nos seus plantios ao longo do território nacional.

A *Tectona grandis* Linn. F., vulgarmente conhecida como teca, é uma espécie asiática que vem conquistando espaço no mercado brasileiro. Ela foi introduzida no Brasil em 1968, na cidade de Cáceres, MT, tendo se adaptado bem as condições naturais oferecidas pelo país, como o clima tropical e os solos profundos e férteis, alcançando hoje uma produtividade que permite uma idade de corte de 25 anos (CÁCERES FLORESTAL S.A, 2002; DANTAS, 2011). Estima-se que haja cerca de 94 mil hectares de terras destinadas ao seu cultivo no país, com maior concentração na região amazônica e no estado do Mato Grosso (IBÁ, 2019; ALMEIDA, 2020).

A madeira de teca é conhecida por sua elevada durabilidade natural, resistência ao ataque de xilófagos e beleza, possuindo grande demanda no mercado internacional, especialmente China e Índia, sendo considerada uma das madeiras tropicais mais valiosas do mundo (MACEDO et al., 2007; ROSHETKO et al., 2013; KOLLERT; WALOTEK, 2015). Devido ao banimento das exportações de Myanmar, detentora de cerca de metade das florestas naturais das espécies, ocorreu um aumento de seu preço, sendo o momento atual oportuno para outros grandes produtores expandirem sua participação no comércio da teca (ROSHETKO et al., 2013; KOLLERT; WALOTEK, 2015). Nesse ponto, destaca-se que o Brasil já é o segundo maior exportador de madeira serrada, em volume, para a Índia e está entre os maiores exportadores para a China.

Tradicionalmente, em plantios florestais, devido a sua importância comercial, a variável de interesse de seus gestores é o volume de madeira. Porém, devido a irregularidades na forma do fuste, o uso de fórmulas geométricas simples não é acurado e sua obtenção por metodologias de medição direta, como a cubagem rigorosa, é laboriosa, lançando-se mão de métodos indiretos, como cálculos com fator de forma ou modelos de regressão (DA SILVA; NETO, 1979; DA CUNHA, 2004; CAMPOS; LEITE, 2013). Devido a sua maior confiabilidade, modelos são mais adotados na mensuração de florestas comerciais, em detrimento do uso de fatores, sendo de uso amplo em tais condições.

Os modelos de regressão são ferramentas estatísticas que permitem equacionar uma relação entre uma variável dependente e uma ou mais variáveis independentes. Em sua aplicação mais comum no meio florestal, utilizam variáveis de mais fácil obtenção, como o diâmetro e altura, para gerarem estimativas do volume de madeira. Comumente são ajustados tanto modelos lineares, quanto não lineares, especialmente o de Schumacher e Hall e o de Spurr. O modelo de Schumacher-Hall é aquele que tem apresentado os resultados mais precisos na estimativa do volume de teca (SILVA, 2012; VENDRUSCOLO et al., 2014; ALMEIDA et al., 2016; CERQUEIRA et al., 2017).

As Redes Neurais Artificiais são uma alternativa ao uso de modelos de regressão usuais, fornecendo estimativas precisas do volume de madeira (GORGENS et al., 2009; SILVA et al., 2009; MIGUEL et al., 2016) e de outras variáveis dendrométricas (CASTRO et al., 2013; BINOTI et al., 2015). Seu funcionamento se assemelha às redes neurais biológicas, processando os dados de forma similar. As Redes consistem de um sistema massivo constituído de várias unidades de processamento simples, os neurônios artificiais, que atuam de forma paralela e simultânea no cálculo de determinada função (GORGENS et al., 2009; BINOTI et al., 2015).

Existem muitos estudos que exploraram o uso de RNAs nas estimativas de variáveis dendrométricas para os gêneros *Pinus* e *Eucalyptus*, no entanto, poucos estudos foram desenvolvidos para teca. Dentre estes, destacam-se trabalhos que avaliaram a estimativa de altura (VENDRUSCOLO et al., 2016), espessura de casca (VENDRUSCOLO et al., 2018), incremento médio anual do volume (MEDEIROS et al., 2019), preço da madeira (SIVARAM, 2014), mas há ainda poucos sobre o volume de teca (TAVARES JÚNIOR, 2022). Tais estudos

vêm apontando para um desempenho estatístico bem acurado das RNAs, demonstrando seu potencial de aplicação na área.

Dentro desta perspectiva, levantou-se a seguinte questão: O uso de Redes Neurais Artificiais permite gerar estimativas volumétricas de teca mais precisas que os métodos tradicionalmente utilizados? Com isso, esse trabalho buscou avaliar seu desempenho quando comparadas aos modelos volumétricos, testando-se a hipótese de que as Redes apresentam indicadores de precisão mais acurados que os modelos e de que há uma diferença significativa entre volume estimado pelas duas ferramentas e o volume real que indique maior exatidão das Redes.

## **2 OBJETIVOS**

### **2.1 Objetivo geral**

Avaliar o desempenho de modelos e de redes neurais artificiais na predição do volume individual de árvores de *T. grandis* Linn. F. em um povoamento no município de Capitão Poço, no Estado do Pará.

### **2.2 Objetivos específicos**

- Ajustar e validar modelos lineares e não lineares preditores do volume individual de teca.
- Treinar e validar redes neurais artificiais e selecionar a melhor para estimar o volume individual de teca.
- Comparar o desempenho dos modelos e das redes neurais frente aos valores reais de volume.

### 3 REVISÃO BIBLIOGRÁFICA

#### 3.1 Teca

Desde o início da Idade Moderna a preocupação com reservas de madeira, para fins industriais e civis, vem se tornando crescente, causando um aumento no plantio de espécies madeireiras e o desenvolvimento de novas técnicas para acompanhar essas novas culturas. Foi observado uma ampliação na área de florestas plantadas de 170 milhões de hectare a 278 Mha em 2015 e 292 Mha em 2020. São utilizadas majoritariamente nos cultivos espécies nativas no Hemisfério Norte, como *Pinus*, e exóticas no Hemisfério Sul, como *Eucalyptus* e *Acacia* (PAYN et al., 2015; FAO, 2020).

É notável o papel do Brasil como potência florestal, sendo no mundo a maior reserva de biodiversidade, florestas tropicais e estoque crescente (*growing stock*), com mais de 120 bilhões de m<sup>3</sup> de madeira em florestas, cerca de 22% do estoque mundial (FAO, 2020). Mesmo com suas vastas áreas de vegetação nativa, maior parte de sua demanda madeireira é suprida por plantios de espécies majoritariamente exóticas, que ocupam mais de 9,5 milhões de hectare, reforçando o impacto do setor florestal no mercado nacional e internacional (IBÁ, 2021).

A teca, ou *T. grandis* Linn. F., é uma árvore pertencente à família Lamiacea, originada do Sudeste e Sul Asiático. É encontrada nativamente na Índia, Laos, Myanmar e Tailândia, sendo também naturalizada na Indonésia, na ilha de Java (KAOSA-ARD, 1998). É terceira espécie tropical mais plantada do mundo, atrás apenas de eucaliptos e acácias (KRISHNAPILLAY, B., 2000). Estima-se que, em 2009, houve uma produção mundial de 4 milhões de m<sup>3</sup> de madeira de teca, com expectativa de 20 milhões de m<sup>3</sup> em 2020 (BEZERRA et al., 2011).

A teca é uma árvore de grande porte, heliófila, decídua, cuja altura costuma chegar de 25 a 35 m e seu diâmetro os 100 cm. Suas folhas são simples, opostas, coriáceas e elípticas, com largura variando de 20 a 35 cm de largura e 30 a 40 cm de comprimento, em adultos (FIGUEIREDO et al., 2005; MACEDO et al., 2007; SOUZA, 2021). A espécie se desenvolve melhor em solos profundos, bem drenados e férteis, e em áreas de clima com amplitude térmica de 13 a 40 °C e índice pluviométrico variando de 1.250 a 3.750 mm/ano (KRISHNAPILLAY, B., 2000).



Sua introdução no Brasil ocorreu em Cáceres, no Mato Grosso, localizada no Pantanal, próxima à Cuiabá e à fronteira com a Bolívia (CÁCERES FLORESTAL S.A, 2002; DANTAS, 2011). Na região, com clima semelhante à sua área de origem, melhor fertilidade do solo e uso de tratamentos silviculturais, foi possível reduzir o ciclo de produção de 80 anos para 25 anos (TSUKAMOTO FILHO et al., 2003). A área plantada no país é estimada em mais de 90 mil hectares, distribuídos principalmente na região amazônica, com destaque para o estado do Mato Grosso (IBÁ, 2019; ALMEIDA, 2020).

O principal produto obtido de suas plantações é a madeira, que apresenta uma densidade aparente média, de 0,66 g/cm<sup>3</sup>, possui diversas qualidades, como elevada durabilidade natural, resistindo a fungos, insetos e intempéries, boa estabilidade dimensional, sofrendo poucos defeitos ao secar, e resistência mecânica (MACEDO et al., 2007; IPT, 2022). Ela possui fácil trabalhabilidade, não sendo difíceis seu aplainamento, torneamento, furação, lixamento e colagem (IPT, 2022). Essas qualidades, somadas a sua beleza, tornam-na uma das madeiras tropicais nobres mais valiosas do mundo, superando inclusive o mogno, sendo usada na produção de móveis, artesanato, construção civil e naval (MACEDO et al., 2007; ROSHETKO et al., 2013; KOLLERT; WALOTEK, 2015; YASODHA et al. 2018).

Outro fator que afeta o valor de teca no mercado internacional é o desequilíbrio entre a oferta do produto e sua demanda, crescente, sendo os maiores importadores a Índia, Tailândia e China (KOLLERT; WALOTEK, 2015; KOLLERT; KLEINE, 2017). Cerca de um quarto das toras comercializadas provem de Myanmar, que detém metade das florestas naturais de teca. Em 2014, devido ao desmatamento das florestas, o governo do país proibiu a exportação da madeira, provocando um aumento de seu preço (ROSHETKO et al., 2013; KOLLERT; WALOTEK, 2015).

Devido a essa alta demanda, houve um aumento nos últimos anos do plantio em outros países tropicais, principalmente na África e América Latina. A área plantada mundialmente foi estimada, em 2010, entre 4,35 e 6,89 milhões de hectares, dos quais 83% estão na Ásia, 11% na África e 6% nas Américas (KOLLERT; CHERUBINI, 2012; KOLLERT; KLEINE, 2017). No Brasil, em especial, o maior produtor das Américas, é destacável a expansão de plantios clonais de alta qualidade, que permitem o fornecimento de madeira serrada no mercado internacional (KOLLERT; WALOTEK, 2015; KOLLERT; KLEINE, 2017).

## **3.2 Volume**

Todos os pontos levantados reforçam o papel da madeira como produto de maior importância comercial em florestas de teca. Para haver um comércio justo entre produtores e consumidores, essa madeira deve ser rigidamente quantificada em unidades volumétricas, pois o menor erro acarretaria em enormes prejuízos financeiros para os interessados. Por essa razão, o volume é a variável de maior importância para gestores florestais, que trabalhem com teca ou outras espécies madeireiras, servindo tanto na estimação do estoque de madeira em pé, como na prognose do crescimento das florestas (DA CUNHA, 2004; CAMPOS; LEITE, 2013).

Teoricamente, se as dimensões do fuste de uma árvore fossem regulares em todo seu comprimento, seria possível calcular seu volume através de fórmulas geométricas simples que considerassem sua altura e diâmetro. Porém, sabe-se que podem ocorrer diferentes formas geométricas ao longo do tronco e isso é devido, principalmente, ao afinamento natural que o mesmo sofre com o aumento de altura (DA SILVA; NETO, 1979; DA CUNHA, 2004; CAMPOS; LEITE, 2013). Essa é uma das maiores dificuldades no cálculo do volume de uma árvore e para contorná-la são usados diferentes métodos. Há métodos destrutivos, que requerem o abate da árvore para sua mensuração, sendo os principais a cubagem rigorosa e a medição com o xilômetro. Eles são considerados medições diretas da árvore, retornando o valor real de seu volume (SOARES et al., 2012).

### **3.2.1 Xilômetro**

O uso do xilômetro, um recipiente com água, adota o princípio de Arquimedes na qual o volume de um objeto inserido no recipiente é igual ao volume ou o peso da água deslocada, sendo a forma de mensuração mais precisa (MACHADO et al., 2006). Sua aplicação, porém, é bem restrita, devido ao gasto excessivo de tempo em sua operação, restringindo-se a pequenas toras em baixa quantidade (DA SILVA; NETO, 1979; SOARES et al., 2012).

### **3.2.2 Cubagem rigorosa**

A cubagem rigorosa é a mais comum forma de mensuração direta do tronco, consistindo em medições do diâmetro ao longo das seções do fuste, determinando-se o volume de cada

seção através de fórmulas e somando cada volume ao final (LEITE; ANDRADE, 2002). Há dois tipos de fórmulas aplicada: as absolutas, sendo as principais as de Smalian, Huber e Newton, e as relativas, que dividem as árvores em toras de iguais comprimentos, a exemplo de Hohenald e FAO (DA SILVA; NETO, 1979).

Além desses, há métodos não destrutivos, como cálculos com fator de forma, quociente de forma e equações de regressão, que são considerados estimativas do volume e não seu valor real, devendo serem usados com cuidado em relação a sua precisão (SOARES et al., 2012). Os principais métodos são os seguintes:

### **3.2.3 Fator de forma e quociente de forma**

O uso de fator de forma é extremamente simples, sendo inserido em uma fórmula do volume de um cilindro, que use a altura e o diâmetro à altura do peito (DAP). Tal fator é um valor médio obtido pela razão entre o volume real e o cilíndrico da árvore, sendo sempre inferior a 1 (DA SILVA; NETO, 1979; SOARES et al., 2012).

Semelhantemente, o quociente de forma relaciona diferentes diâmetros, a exemplo do quociente de Shiffel que é dado pela razão entre o diâmetro a meia altura da árvore e o DAP. Ao se multiplicar o quociente pelo volume do cilindro é estimado o volume real (SOARES et al., 2012).

### **3.2.4 Modelos volumétricos**

Como os cálculos com fator de forma levam a estimativas sem uma precisão desejada e a cubagem total não é viável, e por vezes se quer desejável quando o inventário é feito antes do ano de corte, a quantificação de madeira de uma floresta é feita comumente através de outro método: os modelos volumétricos. Eles são expressões matemáticas que utilizam variáveis dendrométricas de fácil obtenção e estimam a variável de interesse.

Tais modelos são gerados a partir de análise de regressão, que consiste no ajuste gráfico de uma curva que melhor se adequa aos dados, de tal forma que a soma do quadrado das diferenças entre os valores reais e os estimados seja minimizada (DA SILVA; NETO, 1979).

A regressão é uma ferramenta muito comum no meio florestal, usada tanto na geração de equações para as grandes culturas comerciais, como eucalipto (SILVA et al., 2009; SCHRÖDER et al., 2013) e pinus (MACHADO et al., 2002; STEFANELLO et al., 2011), quanto a vegetação nativa (IMANÑA-ENCINAS, 2009; BARBOSA et al., 2019). Sua aplicação não se restringe à estimativa de volume, sendo também usada para estimar altura (CRECENTE-CAMPO et al., 2010; KOIRALA et al., 2017), biomassa (HIGUCHI et al., 1998; LIMA et al., 2012) e outras variáveis biométricas.

Os principais modelos volumétricos utilizados no Brasil nas últimas décadas são o de Schumacher e Hall, Stoate, Spurr, Meyer, Naslund, Ogaya, Takata e Honer. Dentre os citados, Schumacher e Hall, um modelo não linear, Spurr e Meyer, modelos lineares, foram capazes de gerar estimativas mais precisas nos povoamentos brasileiros, sendo mais comumente aplicados (ANDRADE et al., 2017).

O ajuste dos modelos requer uma base de dados reais proveniente de cubagem rigorosa das árvores do povoamento. São selecionados os indivíduos em uma quantidade proporcional à distribuição diamétrica da floresta em estudo, que são normalmente abatidos e cubados para cálculo do volume e geração dos modelos. As equações geradas serão válidas para a espécie e condições ambientais e de manejo que foram avaliadas. Por essa razão são requeridos ajustes de vários modelos, para que haja estimativas confiáveis (THOMAS et al., 2006).

### **3.2.5 Modelo de afilamento**

Outra forma de estimar o volume de uma árvore é através de modelos de afilamento. O modelo de afilamento, ou de *taper*, é capaz de aferir a redução do diâmetro sofrida pelo fuste de uma árvore (CAMPOS & LEITE, 2013). Ele é, portanto, capaz de prever o diâmetro do fuste a uma dada altura. Os principais modelos usados nesse cálculo são polinomiais, destacando-se o de Kozak (2ª ordem), Prodan (5ª ordem) e de Hadetzky.

Os modelos em si não retornam o volume, mas é possível estima-lo através de sua integral. Esses modelos são especialmente úteis na quantificação dos multiprodutos de uma floresta, apresentando a quantidade e volume individualizado por produto.

### 3.3 Redes Neurais Artificiais

Desde os anos 70 a aplicação de IA na solução de problemas diversos vem sendo difundida mundialmente, com o uso de diferentes ferramentas. Muitas dessas ferramentas baseiam-se no Aprendizado de Máquina, ou *Machine Learning*, que, através de algoritmos, são capazes de manipular dados (FACELI et al., 2001; MUELLER; MASSARON, 2019).

O Aprendizado de Máquina (AM) permite que a IA se adapte às mudanças ocorrentes no ambiente ao detectar padrões e ajustar seu comportamento da maneira mais adequada possível (MUELLER; MASSARON, 2019). Os algoritmos de AM são capazes de realizar tarefas de natureza preditiva e descritiva, sendo classificados em algoritmos supervisionados e não supervisionados. No aprendizado supervisionado há um conhecimento prévio dos valores desejados, sendo a IA treinada para prevê-los, com base em entradas, com o mínimo de erros. Já no aprendizado não supervisionado esses valores não são conhecidos, devendo a IA encontrar padrões no ambiente, sendo ao final julgada pelo seu desempenho (FACELI et al., 2001; HAYKIN, 2001).

Dentre os modelos de IA que utilizam mecanismos de aprendizado de máquina, vem se destacando recentemente as Redes Neurais Artificiais. Redes Neurais Artificiais (RNA), chamadas internacionalmente de *Artificial Neural Network* (ANN), são modelos computacionais que consistem de um conjunto de nós interconectados, emulando o funcionamento de um cérebro humano. Elas surgiram da tentativa de inúmeros pesquisadores de modelar matematicamente a estrutura de um sistema nervoso (KOVÁCS, 1996; HAYKIN, 2001).

Pode-se entender o cérebro, analogamente, como um computador bastante complexo, não linear e paralelo. Neurônios seriam, portanto, componentes estruturais do cérebro capazes de realizar certos processamentos computacionais (HAYKIN, 2001). Eles são constituídos de soma, o corpo da célula responsável pelos processos metabólicos, do qual projetam-se filamentos: os dendritos e o axônio (KOVÁCS, 2001).

A transmissão de dados entre neurônios ocorre por impulsos nervosos através das conexões sinápticas, que ligam os dendritos de uma célula ao axônio de outras, envolvendo um processo eletroquímico. As entradas ocorrem na árvore dendrital, sendo suas informações

processadas no soma gerando uma saída transmitida no axônio (KOVÁCS, 1996; HAYKIN, 2001). Adotando essas ideias como princípios, McCulloch e Pitts publicaram em 1943 um artigo intitulado “*A Logical Calculus of the Ideas Immanent in Nervous Activity*”, que, embora seja considerada uma representação simplória de um neurônio biológico, foi o trabalho pioneiro em Redes Neurais Artificiais.

Essencialmente, as RNAs são modelos computacionais análogos ao sistema nervoso animal, sendo compostas de uma massiva rede de nós conectados, baseados nos neurônios reais, emulando o complexo processo biológico para a realização de certo procedimento. Esses neurônios artificiais possuem plasticidade, isso é, são desenvolvidos através do acúmulo de experiências que absorvem do ambiente, e armazenam esse aprendizado em pesos sinápticos. As trocas de dados ocorrem através de entradas (*inputs*), análogas aos dendritos, que são ponderadas por pesos sinápticos, gerando uma saída (*output*), semelhante ao axônio (BRAGA et al., 1998; CERQUEIRA et al., 2001; HAYKIN, 2001; DE MELO et al., 2006).

Os neurônios podem ser organizados em diferentes quantidades de camadas, sendo aquelas que recebem inicialmente as informações chamadas de *camadas de entradas*, as que transmitem ao final uma saída de dados são as *camadas de saída*, e podem haver entre elas as *camadas ocultas* ou *intermediárias*. De acordo com o número de nós e camadas, sua estruturação e distribuição e o sentido das sinapses, é determinado a arquitetura da RNA, podendo ser classificada em: Rede alimentada em uma ou múltiplas camadas ou Rede Recorrente (HAYKIN, 2001; GORGENS et al., 2014).

Desde as primeiras pesquisas até o momento atual, com a expansão de estudos sobre as RNAs e a evolução tecnológica que ocorreu ao de décadas, principalmente referente ao aumento da capacidade de processamento de computadores, as Redes passaram a ser eficazmente aplicadas em inúmeros contextos. São atribuídas principalmente a tarefas de aproximação de funções matemáticas, na extração de padrões de associação e no agrupamento de dados (FACELI et al., 2001; HAYKIN, 2001; GORGENS et al., 2009).

Na área florestal seu potencial de uso é bem diverso, havendo trabalhos que evidenciam sua eficácia na classificação de imagens de satélite (KAVZOGLU; MATHER, 2003), na simulação do fluxo de carbono em plantios (WEN et al., 2014), na otimização de algoritmos de controle de guas florestais (WYDRA et al., 2020), na identificação anatômica de madeiras

(ESTEBAN et al., 2017), na classificação de sítios (COSENZA et al., 2017). As RNAs também podem contribuir na redução de custos de inventários, conforme apontado por estudo conduzido por Binoti et al. (2012).

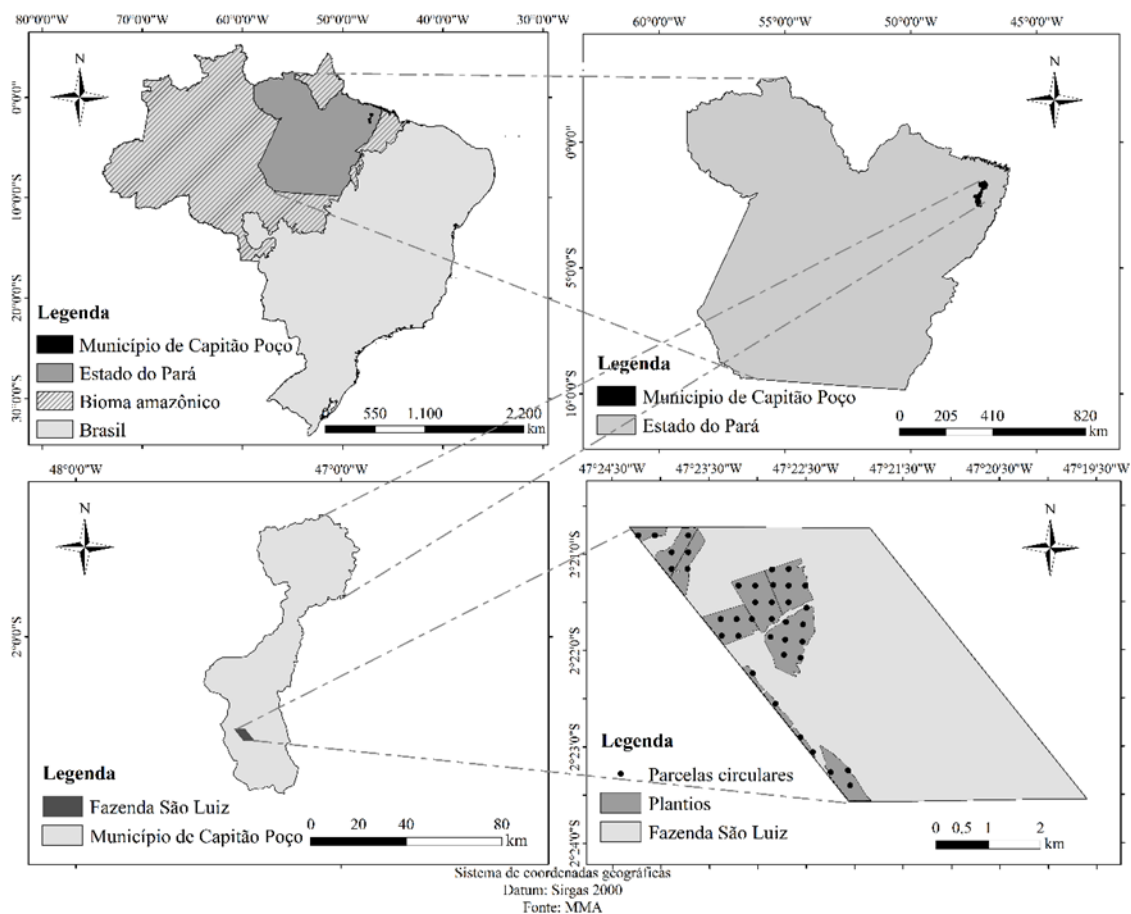
Um dos maiores interesses no campo de estudo é na previsão e modelagem de variáveis biométricas. Por essa razão, são implementadas redes neurais com os dados conhecidos das variáveis, ajustadas pelo aprendizado supervisionado, i.e., pelo treinamento com exemplos. Nesse modelo de treinamento são fornecidos os dados de entrada e saída e a rede deve retornar valores com o mínimo de erros. Para tanto, são ajustados pesos sinápticos e o valor do liminar, de forma a minimizá-los. Esse aprendizado é feito, principalmente, através de algoritmos de correção por erro ou de retropropagação de erro, usado em redes multicamadas como o *Multilayer Perceptron*, que permitem solucionar a função de ativação dos neurônios (KOVÁCS, 1996; HAYKIN, 2001).

A utilização dessas RNAs aplicadas a pesquisas florestais pode trazer resultados positivos, devido a qualidades, como boa adaptabilidade, o processamento não linear dos neurônios e sua capacidade de generalizar, que as permitem capturar padrões mais implícitos nos dados biológicos, se comparadas aos tradicionais modelos estatísticos (LEK et al., 1996; HAYKIN, 2001). Os trabalhos de Gorgens et al. (2009), Silva et al. (2009) e Leite et al. (2011) demonstraram sua eficácia nas estimativas, apontando inclusive superioridade em relação aos métodos tradicionais.

## 4 MATERIAIS E MÉTODOS

### 4.1 Área de estudo e caracterização dos povoamentos

O presente estudo foi realizado em plantios clonais de teca, localizado no município de Capitão Poço, Estado do Pará, distando cerca de 200 km da capital Belém, em área pertencente à Fazenda São Luiz, do grupo Tietê Agrícola LTDA. A fazenda possui uma área total de 2.399,62 ha, localizando-se entre as coordenadas geográficas 2°30'S, 47°20'W e 2°20'S, 47°30'W, tendo 833,03 ha dedicados ao plantio florestal de teca (Figura 1).



**Figura 1** - Localização do povoamento de teca e das parcelas amostradas, no município de Capitão Poço, PA. FONTE: o autor (2022).

A área de estudo situa-se na região de Floresta Densa ou Floresta Ombrófila Tropical, na sub-região dos altos platôs do Pará-Maranhão (IBGE, 2012). De acordo com Santos et al. (2018), na região predominam os seguintes solos: Latossolo Amarelo Distrófico Petroplúntico



(LAd), Latossolo Amarelo Distrófico Típico (Lad) e Plintossolo Pétrico Concrecionário (FFc). As declividades são classificadas como suave e suavemente ondulada, chegando próximo de 5% (IBGE, 2012), com altitudes em torno de 79 metros (INMET, 2020). De acordo com a classificação climática de Köppen, a região da bacia do Guajará está enquadrada no clima do tipo Am, o que o caracteriza como um clima tropical quente e úmido, com chuvas intensas ao longo do ano e com estação seca de curta duração (ALVARES et al., 2013).

A área de plantio de 883,03 ha está dividida em 19 talhões. As mudas clonais foram plantadas manualmente em diferentes espaçamentos iniciais: de 4 x 4 m, que foi realizado no ano de 2010; de 3,75 x 3,75 m, implantados nos anos de 2012 e 2013; e de 3,5 x 3,5 m, nos anos de 2014 e 2015, sempre nos meses de janeiro ou fevereiro. Foram realizadas as seguintes práticas silviculturais na condução do povoamento: combate às formigas com iscas; limpeza de área com trator de esteira; coroamento com enxada; roçagem mecanizada e semi-mecanizada; e desbaste e desrama artificial.

Foi realizada a correção do solo por calagem com calcário dolomítico (3 t ha<sup>-1</sup>), adubação de plantio (200g/planta de NPK 8-28-16 e 100 g/planta de KCl) e de manutenção (7 g/planta de Boro e 100 g/planta de KCl) no 1º, 3º, 5º e 7º ano. Foram realizados desbastes com intensidade de remoção de 50 % da área basal, no 5º ano o primeiro desbaste e no 9º ano o segundo.

## **4.2 Amostragem**

Os dados utilizados neste estudo são oriundos de um inventário florestal contínuo, realizado entre os anos de 2012 a 2022, nos meses de julho, com 72 parcelas permanentes de área fixa circular com raio de 12,61 m e área de 500 m<sup>2</sup>, com um processo de amostragem sistemática com grades de 320 x 320 m. Foram coletados os dados de altura total (HT), com auxílio de um hipsômetro Vertex, o diâmetro à altura do peito (DAP), com fita diamétrica, e a idade dos indivíduos.

## **4.3 Cubagem**

Com os dados coletados ao longo dos anos foram selecionadas 149 árvores, com distribuição diamétrica proporcional à do povoamento, para a cubagem (SOARES et al., 2012).

Foi adotado o método de cubagem relativa de Hohenadl, que consistiu na divisão do tronco em 10 seções proporcionais à altura total da árvore, medindo-se os diâmetros ( $d_{0,i}$ ) nas posições de 5, 15, 25, 35, 45, 55, 65, 75, 85 e 95% (MACHADO; FIGUEIREDO FILHO, 2014). O volume foi calculado conforme a equação 1:

$$v = \frac{HT}{10} (g_{0,05} + g_{0,15} + g_{0,25} + g_{0,35} + g_{0,45} + g_{0,55} + g_{0,65} + g_{0,75} + g_{0,85} + g_{0,95}) \quad (1)$$

Onde:  $v$  = Volume de árvore considerada ( $m^3$ );  $HT$  = Altura (m);  $g$  = área seccional ( $m^2$ ) com diâmetros tomados a 5, 15, 25, 35, 45, 55, 65, 75, 85, 95% da altura da árvore (h). Fonte: Machado e Figueiredo Filho (2014).

#### 4.4 Regressão

Os quatro modelos volumétricos selecionados para o ajuste estão listados na Tabela 1. Foram escolhidos um modelo linear de dupla entrada, um modelo não linear de simples entrada e dois modelos lineares de dupla entrada.

**Tabela 1** – Modelos volumétricos usados nos ajustes aos dados de povoamentos clonais de teca, em Capitão Poço, PA.

| Número | Modelo   | Autor             |
|--------|--|-------------------|
| 1      | $v = \beta_0 + \beta_1 Dap^2 Ht + \varepsilon$             | Spurr             |
| 2      | $v = \beta_0 Dap^{\beta_1} Ht^{\beta_2} + \varepsilon$     | Schumacher & Hall |
| 3      | $v = \frac{Dap^2 Ht}{\beta_0 + \beta_1 Dap} + \varepsilon$ | Takata            |
| 4      | $v = \beta_0 Dap^{\beta_1} + \varepsilon$                  | Berkhout          |

Onde:  $\beta_i$  = parâmetros dos modelos;  $v$  = volume ( $m^3$ );  $DAP$  = diâmetro à altura do peito (cm);  $HT$  = altura total (m);  $\varepsilon$  = erro aleatório.

#### 4.5 RNA

Foi aplicado um treinamento supervisionado de 20 redes neurais utilizando a ferramenta *Intelligent Problem Solver* (IPS) disponível no software Statística 14.0.1 (STATSOFT, 2014), isto é, as variáveis de entrada e de saída foram informadas para o treinamento das redes. Os dados foram normalizados entre 0-1 e testados diversas arquiteturas, o que permite a otimização da arquitetura da RNA definindo o melhor número de neurônios na camada oculta e as melhores funções de ativação das camadas ocultas e de saída (BINOTI et al., 2015; VALE et al., 2017),

visando atingir a menor taxa de erro nas previsões (MIGUEL et al., 2018). O algoritmo utilizado pelo IPS para o processamento das redes neurais foi o algoritmo quase-Newton de Broyden-Fletcher-Goldfarb-Shanno (BFGS) (BROYDEN, 1970; FLETCHER, 1970; GOLDFARB, 1970; SHANNO, 1970), além de ser o método quasi-Newton mais popular, este possui grande poder de resolução para problemas de otimização e previsões (GUERROUT et al., 2018).

As redes treinadas possuem arquitetura do tipo Perceptron de Múltiplas Camadas (*Multilayer Perceptron* – MLP) em que a camada de entrada foi constituída pelas variáveis DAP e HT, uma camada oculta constituída por  $n$  neurônios e uma camada de saída constituída por um neurônio, o volume individual da árvore (Vol) (CARRIJO et al., 2020; GONÇALVES et al., 2021). A arquitetura MLP se distingue pela presença de uma ou mais camadas ocultas, onde a função dos neurônios ocultos é extrair as relações lineares e não lineares entre a entrada e a saída da rede (HAYKIN, 2001).

O neurônio é o elemento fundamental da estrutura da RNA visto que é responsável pelo processamento de dados e informações ao receber os valores de entrada (DAP e HT) até que o resultado de interesse ( $v$ ) seja alcançado. A funcionalidade dos neurônios das RNAs é estimada pela combinação e reprodução de informações baseadas em conexões entre os  $n$  possíveis *inputs* (variáveis de entrada)  $x_1, x_2, \dots, x_n$  e o *output* (variável de saída)  $y$ . Para cada entrada é definido um peso  $w$  que representa as sinapses onde as redes MLP armazenam o conhecimento fazendo com que o processo de aprendizado alcance estimativas dos valores acuradas dos parâmetro (GORUNESCU; BELCIUG, 2016; CARRIJO et al., 2020; GONÇALVES et al., 2021).

#### **4.6 Ajuste e validação**

Foram selecionadas aleatoriamente 70 % das 149 árvores cubadas (104 indivíduos) para o treinamento das redes neurais e dos modelos volumétricos, respeitando-se a distribuição diamétrica. As 30 % (45 árvores) restantes foram utilizadas para a validação dos resultados (ZUCCHINI, 2000). Para a distribuição diamétrica, os dados de DAP foram agrupados em classes com amplitudes de 2 cm, conforme a Tabela 2. As estatísticas descritivas das árvores usadas no ajuste e na validação foram sumarizadas, conforme a Tabela 3.

**Tabela 2** – Distribuição diamétrica das árvores cubadas.

| Classe de DAP (cm) | Centro de classe (cm) | Quantidade | Frequência (%) |
|--------------------|-----------------------|------------|----------------|
| <11                | -                     | 3          | 2.01           |
| 11-15              | 13                    | 18         | 12.08          |
| 15-19              | 17                    | 29         | 19.46          |
| 19-23              | 21                    | 40         | 26.85          |
| 23-27              | 25                    | 34         | 22.82          |
| 27-31              | 29                    | 18         | 12.08          |
| 31-35              | 33                    | 5          | 3.36           |
| >35                | -                     | 2          | 1.34           |
| Total              |                       | 149        | 100            |

FONTE: o autor (2022).

**Tabela 3** - Estatísticas descritivas das árvores cubadas.

| Estatísticas das árvores usadas no ajuste.    |        |       |        |           |               |        |
|---|--------|-------|--------|-----------|---------------|--------|
|   | Mínimo | Média | Máximo | Variância | Desvio Padrão | CV (%) |
| DAP (cm)                                      | 10,50  | 22,46 | 40,23  | 34,18     | 5,85          | 26,03  |
| HT (m)  | 8,70   | 15,69 | 19,85  | 5,42      | 2,33          | 14,84  |
| v (m <sup>3</sup> )                           | 0,05   | 0,32  | 0,89   | 0,03      | 0,17          | 54,78  |
| Estatísticas das árvores usadas na validação. |        |       |        |           |               |        |
|   | Mínimo | Média | Máximo | Variância | Desvio Padrão | CV (%) |
| DAP (cm)                                      | 10,50  | 22,46 | 40,23  | 34,18     | 5,85          | 26,03  |
| HT (m)  | 8,70   | 15,69 | 19,85  | 5,42      | 2,33          | 14,84  |
| v (m <sup>3</sup> )                           | 0,05   | 0,32  | 0,89   | 0,03      | 0,17          | 54,78  |

Onde: DAP = diâmetro a altura do peito; HT = altura total; v = volume; FONTE: o autor (2022).

Os cálculos de ajuste de regressão linear e não linear foram processados utilizando o software *R Studios* (ELZHOV et al., 2016) com o algoritmo de Levenberg–Marquardt da função “nlsLM”, do pacote ‘minpack.lm’. As árvores destinadas à validação do melhor modelo foram submetidas a uma técnica de *bootstrap*. Ela foi feita pelo teste “Regression-based TOST using bootstrap”, através do pacote “equivalence” (ROBINSON et al., 2005). Tal teste inverte a hipótese de similaridade das variáveis e é usado para lidar com a não-normalidade dos dados, consistindo em repetidas reamostragem com recombinações para gerar a distribuição amostral dos parâmetros (MOONEY et al., 1993; GUJARATI; PORTER, 2009).

## 4.7 Avaliação

### 4.7.1 Avaliação dos modelos e critério de escolha

Para a avaliação e seleção das equações, adotou-se os seguintes critérios: 1) menor erro padrão absoluto ( $S_{yx}$ ) e relativo ( $S_{yx}\%$ ) (2 e 3); 2) maior coeficiente de correlação ( $r$ ) (5); 3) análise gráfica dos resíduos; 4) menor critério de informação de Akaike (6). A análise de resíduos foi feita plotando-se em um gráfico de dispersão os resíduos percentuais versus os valores observados da variável de interesse. Foram também construídos gráficos de valores observados versus estimados e histogramas de frequência dos resíduos.

O erro padrão indica o grau de erro da equação e é dado por:

$$S_{yx} = \sqrt{\text{QMR}} \quad (2)$$

Onde o QMR (4), Quadrado Médio do Resíduo, é dado por:

$$\text{QMR} = \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n - p} \quad (3)$$

Onde:  $Y_i$  = valor observado;  $\hat{Y}_i$  = valor estimado;  $n$  = número de observações;  $p$  = número de coeficientes.

Para um melhor entendimento da dimensão do erro padrão, é feito a sua relativização para um valor porcentual, mais fácil de fazer comparações. É usada a seguinte fórmula:

$$S_{yx}\% = \frac{S_{yx}}{\bar{Y}} * 100 \quad (4)$$

Onde  $\bar{y}$  = média dos valores observados.

O coeficiente de correlação indica o quão bem os valores estimados responderam aos valores observados. Quanto mais próximo de 0, pior a equação, enquanto que quanto mais perto de 1 ou - 1 estiver, melhor ela será. É dado por:

$$r = \frac{\sum_{i=1}^n [(X_i - \bar{X}_i)(Y_i - \bar{Y}_i)]}{\sqrt{\sum_{i=1}^n (X_i - \bar{X}_i)^2} * \sqrt{\sum_{i=1}^n (Y_i - \bar{Y}_i)^2}} \quad (5)$$

Onde:  $r$  = Coeficiente de correlação de Pearson;  $X_i$  e  $Y_i$  = valores observados e estimados;  $\bar{X}_i$  e  $\bar{Y}_i$  = média dos valores observados.

O critério de informação de Akaike é dado por:

$$\text{AICc} = -2\left(\frac{-n}{2} \ln\left(\frac{1}{n} \sum_{i=1}^n e_i^2\right)\right) + 2K \frac{n}{n - K - 1} \quad (6)$$

Onde: AICc = Critério de informação de Akaike; e = resíduos; n = número de observações; K= p+1; p= número de parâmetros do modelo.

Por meio da regressão, também é possível avaliar a significância dos parâmetros ou coeficientes de regressão ( $\beta$ ) da equação, se eles acrescentam uma informação importante nas estimativas. Essa avaliação é feita por teste t, que retorna valores  $p$  para cada coeficiente. Valores de  $p$  maiores que o alfa de significância ( $\alpha = 0,05$ ) indicam que o  $\beta$  deve ser removido.

#### **4.7.2 Avaliação das redes neurais**

Para a seleção das redes neurais foram adotados os seguintes critérios: 1) o menor erro padrão; 2) a menor correlação do ajuste e a menor correlação da validação; 3) a análise gráfica de resíduos plotados com a variável observada.

#### **4.7.3 Comparação entre modelos e redes**

Para se comparar a precisão das estimativas foi feita uma Análise de Variância (Anova) de fator único ao nível de 95% de probabilidade, comparando o volume real com o estimado pela rede e modelo de regressão mais acurados. Os pressupostos da Anova foram testados a partir do teste de Shapiro-Wilk, para a normalidade dos resíduos, e pelo teste de Bartlett, para a homogeneidade das variâncias, sendo que, caso estes pressupostos não sejam atendidos (resíduos normais e variâncias homogêneas), será aplicado teste não paramétrico de Kruskal-Wallis ao nível de 95% de probabilidade. Caso um desses indique diferença significativas entre a RNA e o modelo volumétrico o teste de médias de Tuckey será aplicado.

Por fim, visando analisar a acurácia dos volumes predito pela melhor RNA e o melhor modelo volumétrico selecionado, foi feito o cálculo da Diferença Agregada em porcentagem (%). A Diferença Agregada é dada pela diferença entre a soma dos valores observados e estimados de volume e indica o quanto as estimativas distaram ao todo dos valores observados.

## 5 RESULTADOS E DISCUSSÃO

### 5.1 Modelagem por regressão

Na Tabela 4 são apresentados os parâmetros dos modelos e suas respectivas estatísticas de precisão. Os valores de  $r$  variaram de 0,980 a 0,991, enquanto o erro padrão variou de 7,4 a 10,9 %, com valores próximos a  $0,03 \text{ m}^3$ , havendo pouca discrepância entre as equações ajustadas. O modelo de Schumacher e Hall e de Takata tiveram as maiores correlações e menores erros padrões e menor valor para o critério de Akaike entre os modelos.

**Tabela 4** – Parâmetros e medidas de precisão dos modelos volumétricos ajustados para *T. grandis*.

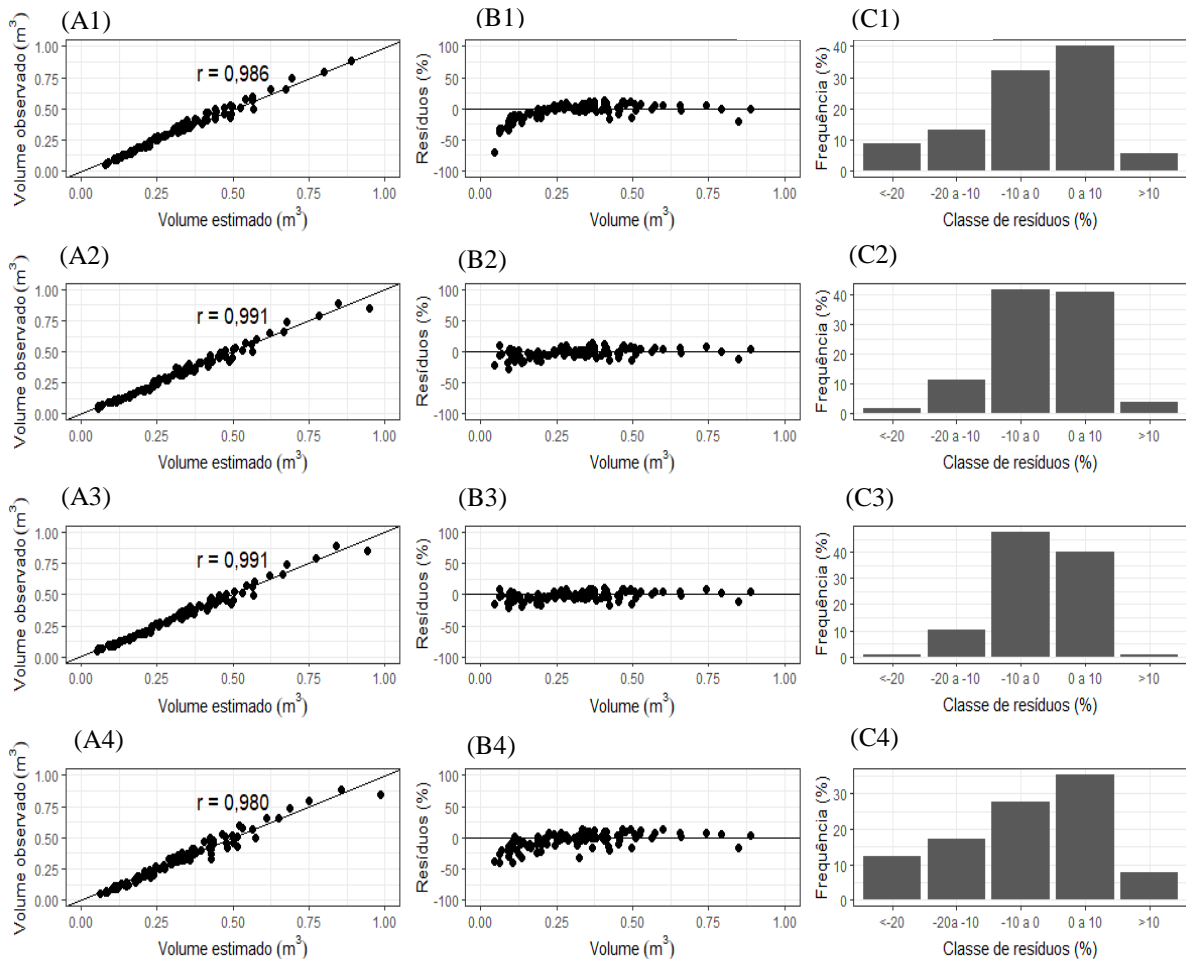
| Modelo | Parâmetros                         | Erro padrão            | $r$   | $S_{yx}$ | $S_{yx} \%$ | AIC     |
|--------|------------------------------------|------------------------|-------|----------|-------------|---------|
| 1      | $\beta_0 = 4,218 \times 10^{-2} *$ | $5,519 \times 10^{-3}$ | 0,986 | 0,029    | 9,324       | -435,80 |
|        | $\beta_1 = 3,092 \times 10^{-5} *$ | $5,236 \times 10^{-7}$ |       |          |             |         |
| 2      | $\beta_0 = 8,239 \times 10^{-5} *$ | $1,766 \times 10^{-5}$ | 0,991 | 0,024    | 7,599       | -477,61 |
|        | $\beta_1 = 1,560 *$                | $5,574 \times 10^{-2}$ |       |          |             |         |
|        | $\beta_2 = 1,206 *$                | $1,196 \times 10^{-1}$ |       |          |             |         |
| 3      | $\beta_0 = 18.155,59 *$            | 896,41                 | 0,991 | 0,024    | 7,404       | -484,21 |
|        | $\beta_1 = 385,25 *$               | 32,29                  |       |          |             |         |
| 4      | $\beta_0 = 5,202 \times 10^{-4} *$ | $7,557 \times 10^{-5}$ | 0,980 | 0,035    | 10,965      | -401,75 |
|        | $\beta_1 = 2,043 *$                | $4,375 \times 10^{-2}$ |       |          |             |         |

Onde:  $\beta_i$  = parâmetros dos modelos;  $r$  = coeficiente de correlação;  $S_{yx}$  = erro padrão absoluto;  $S_{yx}\%$  = erro padrão relativo; AIC = critério de Akaike; \* = significativo a 1 %. FONTE: o autor (2022).

Em um povoamento de teca de 8 anos em Alta Floresta, De Moraes et al. (2020) obtiveram, para os modelos de Spurr e Schumacher, um erro padrão de 9,5 e 9,4 %, respectivamente, superiores aos encontrados no presente trabalho, e um coeficiente de determinação superior a 90 %, indicando uma boa precisão desses tradicionais modelos na estimativa do volume de *T. grandis* no país. Bermejo et al. (2003), trabalhando com plantios na Costa Rica, encontraram valores de  $S_{yx}$  maiores que 18 %. Já em Tonini et al. (2009), usando modelos lineares em Roraima, os valores de erro variaram de 5 a 11 %.

De modo geral, as estimativas dos modelos demonstraram uma tendência a superestimar valores de volume inferiores a  $0,25 \text{ m}^3$ , sendo essa tendência mais pronunciada dentre os dados ajustados por Spurr e Berkhout, comparado aos demais, havendo uma notável curvilinearidade

(Figura 2B). Essa tendência curvilínea indica sua inadequação ao ajuste, devendo, se mantido for o seu uso, adicionar outra variável que permita melhor uniformização dos resíduos (CAMPOS et al., 1985). Já as estimativas superiores a 0,25 apresentaram resíduos bem distribuídos, sem tendências ou vies aparente.



**Figura 2** - Relação entre observados x estimados (Ai), dispersão de resíduos (Bi) e distribuição de classes de resíduos (Ci) para equações volumétricas de um plantio clonal de teca. Em que i: 1 – modelo de Spurr; 2 – modelo de Schumacher & Hall; 3 – modelo de Takata; 4 – modelo de Berkhout. FONTE: o autor (2022).

Ao se observar os histogramas e o gráfico de dispersão de resíduos, nota-se que o modelo de Spurr apresentou a maior amplitude de erros, com valores alcançando até - 75 %, seguido pelo modelo de Berkhout, com resíduos no intervalo de - 45 a 15 % (Figura 2C). O mesmo modelo de Berkhout teve a maior concentração de resíduos em classes inferiores a - 20 %, indicando uma maior tendência a superestimativas. Takata e Schumacher tiveram uma



menor amplitude, com distribuição mais homogênea de resíduos num intervalo de  $0 \pm 10 \%$ , sendo um indicio da possível não ocorrência de problemas de heterocedastidade, tornando-os os mais adequados (SOARES et al., 2012). O gráfico de valores reais vs. observados evidencia a tendência a superestimativas do ajuste feito por Spurr.

Nota-se que o modelo de Berkhout teve estatísticas inferiores às dos demais modelos, corroborando com a noção de que os modelos de dupla entrada, ao incluírem a variável altura junto ao DAP, conseguem capturar com maior precisão a variabilidade de volume de uma árvore de teca (VENDRUSCOLO et al., 2014). Semelhantemente, em Ferreira e Batista (2021), Miguel e Leal (2012) e Silva et al. (1984), trabalhando com *Eucalyptus grandis* em São Paulo, *E. urophylla* em Goiás e espécies nativas da Amazônia no Pará, respectivamente, foi significativo o aumento de precisão ganho com esses modelos.

Ao avaliar as estatísticas de precisão e os gráficos de dispersão e histogramas, concluiu-se que o modelo com melhor ajuste e maior precisão foi o de Takata, com uma ligeira superioridade em relação ao de Schumacher & Hall. Isso reforça o poder preditivo dos modelos não-lineares, que refletem melhor a natureza biológica do crescimento em diâmetro e altura de uma árvore e, por consequência, seu volume.

O modelo de Takata foi validado pelo teste de equivalência ( $\epsilon=0,25$  e  $\alpha = 0,05$ ), sendo apontada a não diferença estatística entre os valores observados e estimados, rejeitando-se a hipótese de dissimilaridade para os parâmetros (Tabela 5). Em Souza (2021), trabalhando com teca neste mesmo povoamento, o modelo de Takata teve o melhor desempenho, com um erro padrão de 5,77 % e correlação de 0,994. Em Cañadas et al. (2018), houveram resultados semelhantes, com desempenho superior do modelo não linear de Newnhan. Diversos outros trabalhos, porém, apontaram o modelo de Schumacher & Hall, em sua forma linear e não linear, como superior na estimativa de volume de teca no Brasil (ALMEIDA et al., 2016; CERQUEIRA et al., 2017; DE MORAIS et al., 2020).

**Tabela 5** – Resultados do teste de equivalência para a validação do modelo volumétrico.

| Modelo | Parâmetro | Intervalo de confiança | Região de similaridade | Dissimilaridade |
|--------|-----------|------------------------|------------------------|-----------------|
| Takata | $\beta_0$ | $0,309 \pm 0,325$      | $0,069 \pm 0,569$      | Rejeitada       |
|        | $\beta_1$ | $0,951 \pm 1,053$      | $0,75 \pm 1,25$        | Rejeitada       |

Onde:  $\beta_i$  = parâmetros da regressão do teste de equivalência. Fonte: o autor (2022).

## 5.2 Modelagem volumétrica por Redes Neurais Artificiais

Na Tabela 6 estão registradas as medidas de precisão das quatro melhores redes treinadas. A correlação para os dados usados no treinamento e erro padrão tiveram pouca variação dentre as redes selecionadas, variando de 0,990 a 0,991, e de 7,277 a 7,892 %, respectivamente, indicando seu poder preditivo. O número de neurônios na camada oculta variou de 3 a 7. A rede 4 teve o menor erro padrão entre as selecionadas.

**Tabela 6** – Medidas de precisão das redes neurais treinadas e selecionadas.

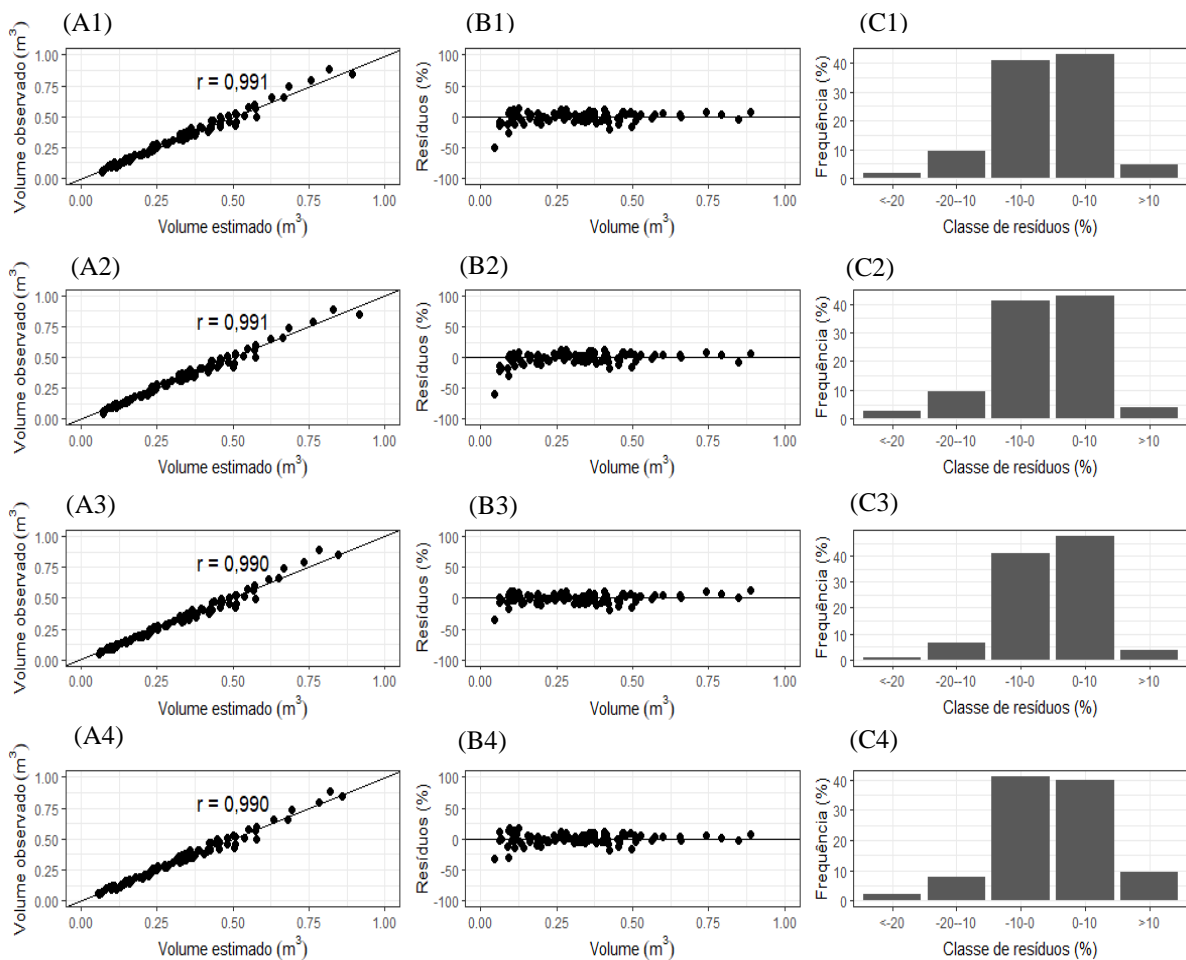
| Número | Arquitetura | $r$ Tr | $r$ Val | $S_{yx}$ Tr | $S_{yx}$ Val | Algoritmo | f(x) da oculta | f(x) da saída |
|--------|-------------|--------|---------|-------------|--------------|-----------|----------------|---------------|
| 1      | MLP 2-7-1   | 0,991  | 0,991   | 7,488       | 7,236        | BFGS 18   | Logística      | Exponencial   |
| 2      | MLP 2-8-1   | 0,991  | 0,990   | 7,467       | 7,269        | BFGS 15   | Tangencial     | Exponencial   |
| 3      | MLP 2-7-1   | 0,990  | 0,991   | 7,892       | 7,275        | BFGS 7    | Exponencial    | Exponencial   |
| 4      | MLP 2-3-1   | 0,991  | 0,991   | 7,277       | 6,972        | BFGS 34   | Exponencial    | Logística     |

Onde:  $r$  Tr e  $S_{yx}$  Tr= correlação e erro padrão (%) para os valores usados no treino;  $r$  Val e  $S_{yx}$  Val= correlação e erro padrão (%) dos valores usados na validação e teste; f(x) = função de ativação. FONTE: o autor (2022).

Destaca-se a importância do algoritmo de Broyden-Fletcher-Goldfarb-Shanno (BFGS), de rápida convergência, usado em problemas não-lineares. O mesmo é capaz de chegar à solução das redes com maior eficácia e menor número de iterações, embora exija um bom poder computacional (GEEM, 2006; GUERROUT et al., 2018). Dentre as funções de ativação, tanto nas camadas oculta quanto nas de saída, predominaram a escolha por funções exponenciais, havendo também as funções logísticas e as tangencias hiperbólicas. Em Gorgens et al. (2009), as redes de melhor desempenho utilizavam funções exponenciais de ativação e 5 nodos nas camadas ocultas. Ao classificar sítios para povoamento de eucalipto, Consenza et al. (2017), usando a função de erro Entropia Cruzada, encontrou as melhores redes com a função “Softmax” na camada de saída, com uma correlação de treino de 0,915.

Semelhante aos modelos ajustados, as redes apresentaram uma leve tendência a superestimativas de volumes, quando o observado era inferior a 0,25 m<sup>3</sup>, embora as demais estimativas tenham sido bem uniformes ao longo do eixo (Figura 3B). As redes 3 e 4 tiveram uma adequada distribuição, mesmo em volumes menores, sem ocorrência aparente de heterocedastidade. Ao analisar os histogramas de resíduos, nota-se que todos os modelos tiveram seus resíduos distribuídos uniformemente, concentrados no intervalo de  $\pm 10$  % (Figura 3C). As redes 1 e 2 apresentaram maior densidade de resíduos inferiores a 0 - 10 %, alcançando

valores menores que - 50 %, sendo algo indesejável. Em Gorgens et al. (2014), usando redes com funções logísticas, foi encontrado esse padrão de superestimativas em árvores menores.




**Figura 3** - Relação entre observados x estimados (Ai), dispersão de resíduos (Bi) e distribuição de classes de resíduos (Ci) para volume predito por redes neurais para um plantio clonal de teca. Em que i: 1 – RNA 1; 2 – RNA 2; 3 – RNA 3; 4 – RNA 4. FONTE: o autor (2022).

Todas as quatro redes selecionadas tiveram um ajuste preciso, com erro padrão inferior a 10 % e correlação maior que 0,99, estando plenamente aptas a estimar o volume do fuste de teca nesse povoamento. Em Miguel et al. (2016), em povoamento de *E. urophylla* de 7 anos, usando redes com uma (DAP) e duas entradas (DAP e HT), foram obtidos valores de correlação entre 0,989 e 0,994, semelhantes aos encontrados no presente trabalho, e raiz de erro quadrático menores que 2,5 %, indicando o poder preditivo de redes mesmo com poucas entradas

relacionadas a saída. De modo geral, a quatro Redes tiveram menor erro e maior correlação que os modelos ajustados.

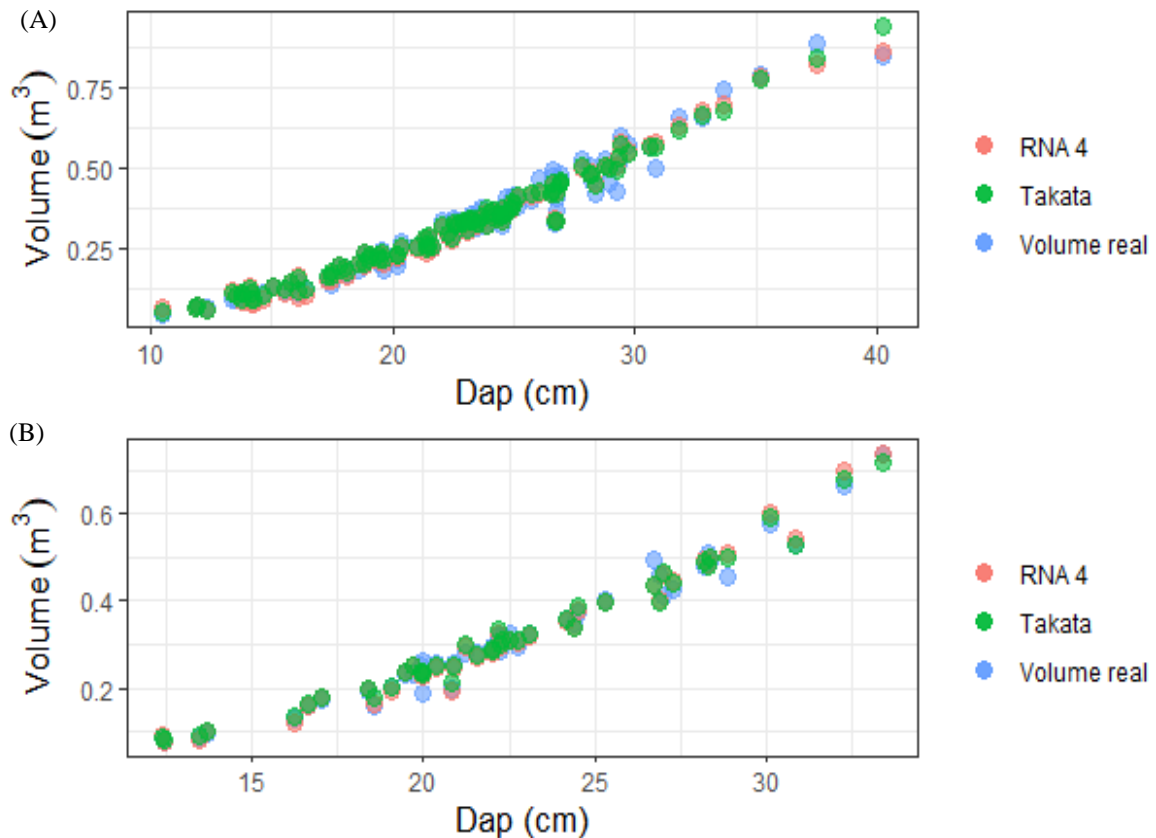
Apesar de pequenas diferenças apontadas pelas medidas de precisão e pelos gráficos de resíduos, pode-se notar uma tênue superioridade da Rede nº 4, com o menor erro padrão de treinamento e de validação e a distribuição mais uniforme e menos ampla de resíduos. A mesma apresentou uma arquitetura com 3 neurônios na camada intermediária (Figura 4), a função de ativação exponencial na camada intermediária e função logística na saída.



**Figura 4** – Arquitetura da rede selecionada. FONTE: o autor (2022).

### 5.3 Comparação entre redes neurais e modelos de regressão

Ao se comparar a Rede 4 e a equação ajustada de Takata, que tiveram respectivamente o melhor desempenho entre as redes e entre os modelos, nota-se que não houve uma diferença tão discrepante, tendo ambos uma correlação de 0,991 e havendo uma ligeira superioridade da Rede quando comparados os erros padrões. Na Figura 5 podem ser visualizados os valores observados e estimados plotados em gráficos de dispersões com os dados usados no ajuste (a) e na validação (b).



**Figura 5** – Gráficos de distribuição de volumes observados e estimados usados no (A) ajuste e (B) validação. FONTE: o autor (2022).

Comparando-se os gráficos de resíduos e histogramas, nota-se uma maior uniformização dos resíduos produzidos pelas estimativas da Rede nº 4, havendo uma distribuição praticamente igualitária entre valores positivos e negativos, enquanto o modelo de Takata teve mais resíduos negativos, gerando superestimativas. Porém, destaca-se o fato de o modelo ter mantido mais resíduos concentrados no intervalo de  $\pm 10\%$ , próximos de 0.

Outro resultado que apontou uma ligeira vantagem para a Rede selecionada foi o teste da diferença agregada, que foi de  $0,427\%$ , contra  $-0,438\%$  do modelo (Tabela 7). Esse mesmo padrão de estimativas foi encontrado por Miguel et al. (2015), trabalhando com árvores do Cerradão. Ao comparar a diferença agregada absoluta com a média das árvores cubadas, de  $0,319\text{ m}^3$ , nota-se os dois métodos estimadores cometeram um erro inferior a esse valor, indicando que tanto a rede quanto o modelo cometeram um erro de estimativa menor que uma árvore na totalidade de árvores cubadas.

**Tabela 7** – Teste da diferença agregada entre o volume real e os estimados.

|          | $\Sigma y$ | DA      | DA%    |
|----------|------------|---------|--------|
| Real     | 47,492     | 0,000   | 0,000  |
| RNA nº 4 | 47,289     | 0,203   | 0,427  |
| Takata   | 47,699     | - 0,208 | -0,438 |

Em que:  $\Sigma y$  = soma dos volumes das árvores cubadas; DA = diferença agregada em m<sup>3</sup>; DA % = diferença agregada relativa (%). FONTE: o autor (2022).

O resultado do teste de Bartlett ( $p$ -valor = 0,973) não indicou variâncias heterogêneas entre os grupos, porém não ocorreu a normalidade dos dados, segundo o teste de Shapiro-Wilk ( $p$ -valor = 0,00035). Por essa razão, os valores observados e estimados foram levados para o teste de Kruskal-Wallis. Miguel et al. (2016), ajustando redes neurais para um estande de eucalipto, deparou-se com uma situação semelhante de não-normalidade dos dados. Apesar do melhor desempenho das redes frente aos modelos alométricos, não foi encontrado pelo teste diferença significativa entre valor predito por eles e os volumes reais, apontado pelo valor-P, de 0,986, superior ao nível de 0,05.

Conclui-se, portanto, que a hipótese de nulidade deve ser aceita, não havendo diferença a um nível de significância de 5 % entre os valores de volume real e os estimados pela Rede nº 4 e pelo modelo de Takata, sendo por essa razão válidos para estimativas do volume de madeira de teca sob as condições descritas no presente trabalho. Em Tavares Júnior et al. (2021), trabalhando com teca no Mato Grosso, os autores concluíram que para predizer o volume com e sem casca as RNAs foram superiores, ao passo que na predição do volume do cerne modelos de regressão foram melhores.

Diversos trabalhos apontaram para uma superioridade das Redes frente aos modelos, porém sem diferenças significativas, como em Miguel et al. (2015), com árvores do cerradão, Lacerda et al. (2017), em um cerrado savânico, e de Azevedo et al. (2020), modelando multivolumes em povoamento de eucalipto. Tavares Júnior et al. (2019), trabalhando com volume comercial de eucalipto no nordeste do Pará, deparou-se com uma situação em que era mais favorável utilizar modelos em certas condições e redes em outras.

Apesar disso, diversos autores apontaram as vantagens das redes, como sua não exigência de normalidade e linearidade, tolerância a ruídos, poder de generalização

(EGRIOGLU et al., 2014; MIGUEL et al., 2015) e sua maior habilidade ao lidar com dados de diferentes espécies em simultâneo (LACERDA et al., 2017; SOARES et al., 2021). Além disso, foi apontado que as redes podem reduzir os custos de inventário e realizar um processamento mais rápido e menos laborioso, se comparado ao ajuste por regressão (BHERING et al., 2015; BINOTI et al., 2013).

Sob as condições listadas no presente estudo, indica-se o uso de Redes Neurais como ferramentas preferíveis na predição de volume de madeira de teca, devido a sua maior acurácia, além de sua tendência a subestimar o volume, em detrimento de modelos, que tendem a gerar superestimativas, projetando uma quantidade de madeira que não existe. Porém, as Redes requerem em sua aplicação o emprego do software que as gerou, além de seu próprio arquivo. No caso da ausência de um desses, o uso de modelos volumétricos, que exigem apenas seus parâmetros e equação, é recomendado, não havendo prejuízo significativo em estimativas, conforme indicado pelo teste de Kruskal-Wallis.

## 6 CONCLUSÕES

Dentre os modelos volumétricos de madeira de *T. grandis* avaliados, o modelo de Takata apresentou estatísticas de ajuste e precisão mais acuradas. Dentre as RNAs, usando diâmetro e altura como entradas, a Rede nº 4, de arquitetura MLP 2-3-1, foi a mais indicada na quantificação de madeira. Embora a Rede nº 4 tenha tido menor erro padrão que o modelo de Takata, o teste de Kruskal-Wallis não encontrou diferença significativa entre o volume estimado por eles e o volume observado.

Por fim, reafirma-se que ambas as metodologias foram acuradas, sendo formas adequadas de estimar o volume de teca nas condições descritas. Cita-se também a escassez de bibliografia acerca do tópico e a necessidade mais avaliações que comparem redes e modelos sob diferentes condições, espécies e locais, de modo que possa trazer um avanço do uso dessas ferramentas no âmbito da atuação profissional em florestas.



## REFERÊNCIAS

ALMEIDA, D. L. C. DA S. DE et al. DETERMINAÇÃO DE EQUAÇÃO VOLUMÉTRICA E HIPSOMÉTRICA PARA UM PLANTIO DE *Tectona grandis* L. F. EM ALTA FLORESTA - MT. **Revista de Ciências Agroambientais**, v. 14, n. 2, 18 dez. 2016.

ALMEIDA, M. P. DE. Predição da altura de *Tectona grandis* Linn F. por meio de modelos genéricos e redes neurais artificiais. [s.l.] Universidade de Brasília, 2020.

ALVARES, C. A. et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, dez. 2013.

ANDRADE, V. C. L. DE. Modelos Volumétricos de Dupla Entrada para Aplicar em Povoamentos Florestais Brasileiros. **Floresta e Ambiente**, v. 24, n. 0, 2017.

BARBOSA, R. I. et al. Allometric models to estimate tree height in northern Amazonian ecotone forests. **Acta Amazonica**, v. 49, n. 2, p. 81–90, abr. 2019.

BERMEJO, I.; CAÑELLAS, I.; MIGUEL, A. S. Growth and yield models for teak plantations in Costa Rica. **Forest Ecology and Management**, v. 189, n. 1–3, p. 97–110, fev. 2004.

BEZERRA, A. F. et al. ANÁLISE DA VIABILIDADE ECONÔMICA DE POVOAMENTOS DE *Tectona grandis* SUBMETIDOS A DESBASTES NO MATO GROSSO. **CERNE**, v. 17, n. 4, p. 10, 2011.

BHERING, L. L. et al. Application of neural networks to predict volume in eucalyptus. **Crop Breeding and Applied Biotechnology**, v. 15, n. 3, p. 125–131, set. 2015.

BINOTI, D. H. B. et al. Redução dos custos em inventário de povoamentos equiâneos. **Revista Brasileira de Ciências Agrárias - Brazilian Journal of Agricultural Sciences**, v. 8, n. 1, p. 125–129, 28 mar. 2013.

BINOTI, M. L. M. DA S. et al. PROGNOSE EM NÍVEL DE POVOAMENTO DE CLONES DE EUCALIPTO EMPREGANDO REDES NEURAIS ARTIFICIAIS. **CERNE**, v. 21, n. 1, p. 97–105, mar. 2015.

BINOTI, M. L. M. DA S. et al. Prognose Em Nível De Povoamento De Clones De Eucalipto Empregando Redes Neurais Artificiais. **Cerne**, v. 21, n. 1, p. 97–105, 2015.

BRAGA, A. D. P. et al. Redes Neurais Artificiais: Teoria e Aplicações. 2. ed. Rio de Janeiro: **LTC**, p. 226, 2014.

BROYDEN, C. G. The convergence of a class of double-rank minimization algorithms 1. General Considerations. **IMA Journal of Applied Mathematics**, v. 3, n. 1, p. 76–90, 1970

CÁCERES FLORESTAL S.A. **Manual do Cultivo da Teca**. 3a edição, (1000 exemplares), 2002.

CAMPOS, J. C. C.; LEITE, H. G. **Mensuração florestal: perguntas e respostas**. 4. ed. Viçosa, MG: Ed. UFV, 2013.

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

CAÑADAS-L, Á. et al. Growth and Yield Models for Teak Planted as Living Fences in Coastal Ecuador. **Forests**, v. 9, n. 2, p. 55, 24 jan. 2018.

CARRIJO, J. V. N. et al. Artificial intelligence associated with satellite data in predicting energy potential in the Brazilian savanna woodland area. **iForest - Biogeosciences and Forestry**, v. 13, n. 1, p. 48, 2020.

CASTRO, R. V. O. et al. Individual Growth Model for Eucalyptus Stands in Brazil Using Artificial Neural Network. **ISRN Forestry**, p. 1–12, 15 abr. 2013.

CERQUEIRA, C. L. et al. Modelagem da altura e volume de *Tectona grandis* L.F. na mesorregião Nordeste do Pará. **Nativa**, v. 5, 2017.

CERQUEIRA, E. O. DE et al. Redes neurais e suas aplicações em calibração multivariada. **Química Nova**, v. 24, n. 6, p. 864–873, dez. 2001. DA CUNHA, U. S. **Dendrometria e Inventário Florestal**. Manaus: Universidade Federal do Amazonas, 2004.

COSENZA, D. N. et al. SITE CLASSIFICATION FOR EUCALYPT STANDS USING ARTIFICIAL NEURAL NETWORK BASED ON ENVIRONMENTAL AND MANAGEMENT FEATURES. **CERNE**, v. 23, n. 3, p. 310–320, set. 2017.

CRECENTE-CAMPO, F. et al. A generalized nonlinear mixed-effects height–diameter model for *Eucalyptus globulus* L. in northwestern Spain. **Forest Ecology and Management**, v. 259, n. 5, p. 943–952, 20 fev. 2010.

DA SILVA, J. A. A.; NETO, F. P. **Princípios básicos de dendrometria**. Recife: Universidade Federal Rural de Pernambuco, Departamento de Ciência Florestal, p. 198, 1979.

DANTAS, M. L. **DESAFIOS PARA A PLANTAÇÃO COMERCIAL DE TECA EM GOIÁS: A IMPORTÂNCIA DAS POLÍTICAS PÚBLICAS**. Goiânia - GO: PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS – PUC GO, 2011.

DE AZEVEDO, G. B. et al. Multi-volume modeling of *Eucalyptus* trees using regression and artificial neural networks. **PLOS ONE**, v. 15, n. 9, p. e0238703, 11 set. 2020.

DE MELO, F. R. et al. Generalizador Neural de Espaços de Aprendizagem em Sistemas Tutores Inteligentes. **XVII Simpósio Brasileiro de Informática na Educação – SIBIE – UNB/UCB**, p. 10, 2006.

DE MORAIS, A. C.; SOARES, T. S.; CRUZ, E. S. Height, volume and form factor equations for *Tectona grandis* L.f. in Alta Floresta (MT). **Scientia Agraria Paranaensis**, v. 1, n. 1, p. 27, 23 maio 2020.

EGRIOGLU, E. et al. Recurrent Multiplicative Neuron Model Artificial Neural Network for Non-linear Time Series Forecasting. **Procedia - Social and Behavioral Sciences**, v. 109, p. 1094–1100, jan. 2014.

ELZHOV, T. et al. Package “minpack.lm”, 2016. Disponível em: <<https://cran.r-project.org/web/packages/minpack.lm/minpack>>.

ESTEBAN, L. G. et al. Application of artificial neural networks as a predictive method to differentiate the wood of *Pinus sylvestris* L. and *Pinus nigra* Arn subsp. *salzmannii* (Dunal) Franco. **Wood Science and Technology**, v. 51, n. 5, p. 1249–1258, set. 2017.

FACELI, K. et al. **Inteligência artificial: uma abordagem de aprendizado de máquina**. [s.l.] LTC, 2011.

FERREIRA, V. P.; BATISTA, J. L. F. Utilização de variáveis qualitativas de localização em equações volumétricas e a seleção de modelos. **Ciência Florestal**, v. 31, n. 4, p. 1968–1990, 17 nov. 2021.

FIGUEIREDO, E. O.; DE OLIVEIRA, L. C.; BARBOSA, L. K. F. Teca (*Tectona grandis* L.f.): Principais Perguntas do Futuro Empreendedor Florestal. **Embrapa Acre**, p. 87, 2005.

FLETCHER, R. A new approach to variable metric algorithms. **The computer Journal**, v. 13, n. 3, p. 317–322, 1970.

GEEM, Z. W. Parameter Estimation for the Nonlinear Muskingum Model Using the BFGS Technique. **Journal of Irrigation and Drainage Engineering**, v. 132, n. 5, p. 474–478, out. 2006.

**Global Forest Resources Assessment 2020**. Rome, Italy: FAO, 2020.

GOLDFARB, D. A family of variable-metric methods derived by variational means. **Mathematics of Computation**, v. 24, n. 109, p. 23, 1970.

GONÇALVES, F. C. et al. Artificial intelligence associated with Sentinel-2 data in predicting commercial volume in Brazilian Amazon Forest. <https://doi.org/10.1117/1.JRS.15.044511>, v. 15, n. 4, p. 044511, 10 nov. 2021.

GORGENS, E. B. et al. Estimação do volume de árvores utilizando redes neurais artificiais. **Revista Árvore**, v. 33, n. 6, p. 1141–1147, dez. 2009.

GORGENS, E. B. et al. Influência da arquitetura na estimativa de volume de árvores individuais por meio de redes neurais artificiais. **Revista Árvore**, v. 38, n. 2, p. 289–295, abr. 2014.

GORUNESCU, F.; BELCIUG, S. Boosting backpropagation algorithm by stimulus-sampling: Application in computer-aided medical diagnosis. **Journal of Biomedical Informatics**, v. 63, p. 74–81, 1 out. 2016.

GUERROUT, E.-H. et al. Hidden Markov random field model and Broyden-Fletcher-Goldfarb-Shanno algorithm for brain image segmentation. **Journal of Experimental & Theoretical Artificial Intelligence**, v. 30, n. 3, p. 415–427, jun. 2018.

GUJARATI, D. N.; PORTER, D. C. **Basic econometrics**. 5th ed ed. Boston: McGraw-Hill Irwin, 2009.

HAYKIN, S. **Redes Neurais: Princípios e Prática**. 2. ed. Ontário, Canadá: Bookman Editora, 2001.

HIGUCHI, N. et al. Biomassa da parte aérea da vegetação da Floresta Tropical úmida de terra-firme da Amazônia Brasileira. **Acta Amazonica**, v. 28, n. 2, p. 153–153, jun. 1998.

IBÁ (INDÚSTRIA BRASILEIRA DE ÁRVORES). **Relatório Anual de 2019**. São Paulo – SP: IBÁ, p. 80, 2019. Disponível em: <<https://www.iba.org/datafiles/publicacoes/relatorios/relatorioiba2019-final.pdf>>. Acesso em: 06/05/2022.

IBGE. **Manual técnico da vegetação brasileira**. 2 ed. Rio de Janeiro, RJ, p. 217, 2012.

IMAÑA-ENCINAS, J. et al. Equações de volume de madeira para o Cerrado de Planaltina de Goiás. **Floresta**, v. 39, n. 1, p. 10, 27 mar. 2009.

INMET. **National Institute of Meteorology**. 2020. Disponível em: <<http://www.inmet.gov.br/portal/index.php?r=estacoes/estacoesConvencionais>>.

IPT - Instituto de Pesquisas Tecnológicas. Disponível em: <[https://www.ipt.br/informacoes\\_madeiras/78-teca.htm](https://www.ipt.br/informacoes_madeiras/78-teca.htm)>. Acesso em: 29 maio. 2022.

KAOSA-ARD, Apichart. Teak (*Tectona grandis* Linn. f) its natural distribution and related factors. **Nat. His. Bulletin Siam. Soc**, v. 29, p. 55-74, 1981.

KAVZOGLU, T.; MATHER, P. M. The use of backpropagating artificial neural networks in land cover classification. **International Journal of Remote Sensing**, v. 24, n. 23, p. 4907–4938, jan. 2003.

KENGEN, S. a política florestal Brasileira: uma perspectiva histórica [Brazilian forest policy: a historical perspective]. 1º Simpósio Ibero-americano de gestão e economia Florestal,

Porto Seguro, Brazil. Instituto de Pesquisas e estudos Florestais.(2001). Retrieved May, v. 4, p. 2007, 2001.

KOIRALA, A.; KIZHA, A. R.; BARAL, S. Modeling Height-Diameter Relationship and Volume of Teak (*Tectona grandis* L. F.) in Central Lowlands of Nepal. **Journal of Tropical Forestry and Environment**, v. 7, n. 1, 30 jul. 2017.

KOLLERT, W.; CHERUBINI, L. **Teak resources and market assessment 2010**. Rome, Italy: FAO Planted Forests and Trees, 2012.

KOLLERT, W.; KLEINE, M. **The global teak study: analysis, evaluation and future potential of teak resources**. Vienna: IUFRO, 2017.

KOLLERT, W.; WALOTEK, P. J. **Global teak trade in the aftermath of Myanmar's log export ban**. Rome: FAO, 2015.

KOVACS, Z. L. **Redes neurais artificiais: fundamentos e aplicações, um texto básico**. 1. ed. São Paulo, SP: Acadêmica, 1996.

KRISHNAPILLAY, D. B. Silviculture and management of teak plantations. **UNASYLVA-FAO**, v. 201, p. 14–21, 1 jan. 2000.

LACERDA, T. H. S. et al. ARTIFICIAL NEURAL NETWORKS FOR ESTIMATING TREE VOLUME IN THE BRAZILIAN SAVANNA. **CERNE**, v. 23, n. 4, p. 483–491, dez. 2017.

LEITE, H. G. et al. Estimation of inside-bark diameter and heartwood diameter for *Tectona grandis* Linn. trees using artificial neural networks. **European Journal of Forest Research**, v. 130, n. 2, p. 263–269, mar. 2011.

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

LEK, S. et al. Application of neural networks to modelling nonlinear relationships in ecology. **Ecological Modelling**, v. 90, n. 1, p. 39–52, set. 1996.

LIMA, A. J. N. et al. Allometric models for estimating above- and below-ground biomass in Amazonian forests at São Gabriel da Cachoeira in the upper Rio Negro, Brazil. **Forest Ecology and Management**, v. 277, p. 163–172, ago. 2012.

MACEDO, R. L. G. et al. FENOLOGIA E CRESCIMENTO INICIAL DE *Tectona grandis* L. F (TECA) EM LAVRAS MINAS GERAIS. **CERNE**, v. 13, p. 81–90, 2007.

MACHADO, S. A. et al. Comparação de métodos de cubagem absolutos com o volume obtido pelo xilômetro para bracatinga (*Mimosa scabrella* Bentham). **Cerne**, v. 12, n. 3, p. 239-253, 2006.

MACHADO, S. A.; FIGUEIREDO-FILHO, A. **Dendrometria**. 2 ed. Irati: Unicentro. 2014. 316 p.

MACHADO, S. DO A.; DA CONCEIÇÃO, M. B.; DE FIGUEIREDO, D. J. Modelagem do volume individual para diferentes idades e regimes de desbaste em plantações de *Pinus oocarpa*. **Revista Ciências Exatas e Naturais**, v. 4, n. 2, 2002.

MCCULLOCH, W. S.; PITTS, W. A LOGICAL CALCULUS OF THE IDEAS IMMANENT IN NERVOUS ACTIVITY. **Bulletin of Mathematical Biology**, v. 5, n. 1, p. 115–133, 1943.

MEDEIROS, R. A. et al. Productive potential of *Tectona grandis* in Midwest Brazil. **Advances in Forestry Science**, v. 6, n. 4, p. 803, 30 dez. 2019.

MIGUEL, E. P. et al. 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, 26 maio 2016.

MIGUEL, E. P. et al. Redes neurais artificiais para a modelagem do volume de madeira e biomassa do cerradão com dados de satélite. **Pesquisa Agropecuária Brasileira**, v. 50, n. 9, p. 829–839, set. 2015.

MIGUEL, E. P. et al. Using artificial neural networks in estimating wood resistance. **Maderas. Ciencia y tecnología**, v. 20, n. 4, p. 531–543, 1 out. 2018.

MIGUEL, E. P.; LEAL, F. A. SELEÇÃO DE EQUAÇÕES VOLUMÉTRICAS PARA A PREDIÇÃO DO VOLUME TOTAL DE *Eucalyptus urophylla* S. T. BLAKE NA REGIÃO NORTE DO ESTADO DE GOIÁS. p. 15, 2012.

MOONEY, C. Z.; DUVAL, R. D. **Bootstrapping: A Nonparametric Approach to Statistical Inference**. 1st edition ed. Newbury Park, Calif: SAGE Publications, Inc, 1993.

MUELLER, J. P.; MASSARON, L. **Aprendizado de Máquina Para Leigos**. [s.l.] Alta Books, 2019. ROSHETKO, J. M. et al. Teak systems' contribution to rural development in Indonesia. **World Teak Conference 2013**, p. 18, 2013.

PAYN, T. et al. Changes in planted forests and future global implications. **Forest Ecology and Management**, v. 352, p. 57–67, set. 2015.

ROBINSON, A. P.; DUURSMA, R. A.; MARSHALL, J. D. A regression-based equivalence test for model validation: shifting the burden of proof. **Tree Physiology**, v. 25, n. 7, p. 903–913, 1 jul. 2005.

ROSHETKO, J. M. et al. Teak systems' contribution to rural development in Indonesia. **World Teak Conference 2013**, p. 18, 2013.

SANTOS, H. G., et al. **Sistema Brasileiro de Classificação de Solos**. 3. ed. Brasília: Embrapa, p. 353, 2013.

SCHRÖDER, T.; PEREIRA, L. D.; HOFIÇO, N. DOS S. A. Comparação de Métodos de Estimativa de Volume Total para *Eucalyptus grandis* W. Hill ex Maiden. **Floresta e Ambiente**, 2013.

SHANNO, D. F. Conditioning of quasi-Newton methods for cuntion minimization. **Mathematics of Computation**, v. 24, n. 111, p. 647, 1970.

SILVA, F. R. D. CRESCIMENTO E PRODUÇÃO DE *Tectona grandis* L.f EM UM PLANTIO NO MUNICÍPIO DE ALTA FLORESTA – MT. Cuiabá - MT: UNIVERSIDADE FEDERAL DE MATO GROSSO, 2012.

SILVA, J. N. M. et al. EQUAÇÕES DE VOLUME PARA A FLORESTA NACIONAL DO TAPAJOS. p. 50–63, 1984.

SILVA, M. L. M. DA et al. Ajuste do modelo de Schumacher e Hall e aplicação de redes neurais artificiais para estimar volume de árvores de eucalipto. **Revista Árvore**, v. 33, n. 6, p. 1133–1139, dez. 2009.

SIVARAM, M. **Modeling the price of trends of teak wood using statistical and artificial neural network techniques**. University of Salento, 2014. Disponível em: <<http://siba-ese.unile.it/index.php/ejasa/article/view/11772>>. Acesso em: 6 maio. 2022

SOARES, C. P. B.; DE PAULA NETO, F.; DE SOUZA, A. L. **Livro Dendrometria e Inventário Florestal**. 2ª ed. Viçosa, MG: Editora UFV, 2012.

SOARES, G. M. et al. ARTIFICIAL NEURAL NETWORKS (ANN) FOR HEIGHT ESTIMATION IN A MIXED-SPECIES PLANTATION OF *Eucalyptus globulus* LABILL AND *Acacia mearnsii* DE WILD. **Revista Árvore**, v. 45, p. e4512, 2021.

SOUZA, H. J. DE et al. Thinning-response modifier term in growth models: An application on clonal *Tectona grandis* Linn F. stands at the amazonian region. **Forest Ecology and Management**, v. 511, p. 120109, maio 2022.

SOUZA, H. J. DE. **MODELOS DINÂMICOS NO ESTUDO DO CRESCIMENTO E PRODUÇÃO EM NÍVEL DE POVOAMENTO TOTAL EM PLANTIOS DE *Tectona grandis* Linn. F.** Dissertação de mestrado—Brasília, DF: UnB, 2021.

STEFANELLO, F. R. et al. Preussner functions for volume estimation of *Pinus taeda* L. in Southern Brazil. **New Zealand Journal of Forestry Science**, v. 51, 2 jun. 2021.

TAVARES JÚNIOR, I. DA S. et al. Machine learning and regression models to predict multiple tree stem volumes for teak. **Southern Forests: a Journal of Forest Science**, v. 83, n. 4, p. 294–302, 2 out. 2021.

TAVARES JÚNIOR, I. et al. Artificial Neural Networks and Linear Regression Reduce Sample Intensity to Predict the Commercial Volume of Eucalyptus Clones. **Forests**, v. 10, n. 3, p. 268, 17 mar. 2019.

THOMAS, C. et al. Comparação de equações volumétricas ajustadas com dados de cubagem e análise de tronco. **Ciência Florestal**, v. 16, n. 3, p. 319–327, 30 set. 2006.

TONINI, H.; COSTA, M. C. G.; SCWENGBER, L. A. M. Crescimento da Teca (*Tectona grandis*) em Reflorestamento na Amazônia Setentrional. **Pesquisa Florestal Brasileira**, v. 0, n. 59, p. 11/39, 26 fev. 2010.

TSUKAMOTO FILHO, A. DE A. et al. Análise econômica de um plantio de teca submetido a desbastes. **Revista Árvore**, v. 27, n. 4, p. 487–494, ago. 2003.

VALE, A. T. DO et al. Artificial neural networks in predicting energy density of *Bambusa vulgaris* in Brazil. **African Journal of Agricultural Research**, v. 12, n. 10, p. 856–862, 9 mar. 2017.

VENDRUSCOLO, D. G. S. et al. Estimativa da altura de árvores de *Tectona grandis* L.f. utilizando regressão e redes neurais artificiais. **Nativa**, v. 5, n. 1, 2017.

VENDRUSCOLO, D. G. S. et al. MODELOS VOLUMÉTRICOS PARA TECA EM DIFERENTES ESPAÇAMENTOS EM CÁCERES, MATO GROSSO. **ENCICLOPÉDIA BIOSFERA**, p. 1333–1341, 2014.

VENDRUSCOLO, D. G. S. et al. THICKNESS ACCURACY OF TEAK BARK BY ARTIFICIAL INTELLIGENCE. **FLORESTA**, v. 49, n. 3, p. 449, 16 jul. 2019.

WEN, X. et al. Applying an artificial neural network to simulate and predict Chinese fir (*Cunninghamia lanceolata*) plantation carbon flux in subtropical China. **Ecological Modelling**, v. 294, p. 19–26, dez. 2014.

WYDRA, M. et al. Moderne Steueralgorithmen für Forstkräne mittels künstlichen neuronalen Netzen imitieren und optimieren. **LANDTECHNIK**, p. Bd. 75 Nr. 2 (2020), 17 jun. 2020.

YASODHA, R. et al. Draft genome of a high value tropical timber tree, Teak (*Tectona grandis* L. f): insights into SSR diversity, phylogeny and conservation. **DNA Research**, v. 25, n. 4, p. 409–419, 1 ago. 2018.

ZUCCHINI, W. An Introduction to Model Selection. **Journal of Mathematical Psychology**, v. 44, n. 1, p. 41–61, 1 mar. 2000.