



TRABALHO DE CONCLUSÃO DE CURSO


**Ferramenta de inteligência artificial associado a dados do satélite
Sentinel 2 na estimativa do volume de madeira em plantios de *Tectona
grandis* Linn F. no Pará**

Gabriel Chagas Suzuki

Brasília, Abril de 2022

UNIVERSIDADE DE BRASÍLIA

FACULDADE DE TECNOLOGIA



UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA FLORESTAL

**Ferramenta de inteligência artificial associado a dados do satélite Sentinel
2 na estimativa do volume de madeira em plantios de *Tectona grandis* Linn
*F. no Pará***

Gabriel Chagas Suzuki

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, Abril de 2022

ANEXO GABRIEL CHAGAS SUZUKI

Universidade de Brasília - UnB
Faculdade de Tecnologia - FT
Departamento de Engenharia Florestal – EFL

FERRAMENTA DE INTELIGÊNCIA ARTIFICIAL ASSOCIADO A DADOS DO SATÉLITE SENTINEL 2 NA ESTIMATIVA DO VOLUME DE MADEIRA EM PLANTIOS DE *TECTONA GRANDIS* L.F. NO PARÁEstudante: **Gabriel Chagas Suzuki**Matrícula: **16/0028426**Orientador: **Prof. Dr. Eder Pereira Miguel**Menção: **SS**

Aprovada por:

Prof. Dr. Eder Pereira Miguel
Universidade de Brasília – UnB
Departamento de Engenharia Florestal
Orientador (EFL)

Prof. Dr. Eraldo Aparecido Trondoli Matricardi
Universidade de Brasília – UnB
Departamento de Engenharia Florestal
Membro da Banca

MsC. Mário Lima dos Santos
Universidade de Brasília – UnB
Departamento de Engenharia Florestal
Membro da Banca

Brasília, 29 de abril de 2022.



Documento assinado eletronicamente por **Eder Pereira Miguel, Professor(a) de Magistério Superior da Faculdade de Tecnologia**, em 29/04/2022, às 09:37, conforme horário oficial de Brasília, com fundamento na Instrução da Reitoria 0003/2016 da Universidade de Brasília.



Documento assinado eletronicamente por **Eraldo Aparecido Trondoli Matricardi, Professor(a) de Magistério Superior da Faculdade de Tecnologia**, em 29/04/2022, às 09:42, conforme horário oficial de Brasília, com fundamento na Instrução da Reitoria 0003/2016 da Universidade de Brasília.



Documento assinado eletronicamente por **Mario Lima dos Santos, Usuário Externo**, em 29/04/2022, às 11:34, conforme horário oficial de Brasília, com fundamento na Instrução da Reitoria 0003/2016 da Universidade de Brasília.



A autenticidade deste documento pode ser conferida no site http://sei.unb.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **7780758** e o código CRC **6773E747**.

FICHA CATALOGRÁFICA

Suzuki, Gabriel Chagas

Ferramenta de inteligência artificial associado a dados do satélite Sentinel 2 na estimativa do volume de madeira em plantios de *Tectona grandis* Linn.F. no Pará 38 p., 210 x 297mm (EFL/FT/UnB, Engenheiro, Engenharia Florestal, 2022).
Trabalho de conclusão de curso - Universidade de Brasília, Faculdade de Tecnologia.
Departamento de Engenharia Florestal

- | | |
|-----------|-------------------------|
| 1. Teca | 2. Redes Neurais |
| 3. Volume | 4. Imagens de Satélites |

I. EFL/FT/UnB

II. Título

REFERÊNCIA BIBLIOGRÁFICA

SUZUKI, G.C. (2022). **Ferramenta de inteligência artificial associado a dados do satélite Sentinel 2 na estimativa do volume de madeira em plantios de *Tectona grandis* L.f. no Pará** Trabalho de conclusão de curso, Departamento de Engenharia Florestal, Universidade de Brasília, Brasília, DF, 38 p.

CESSÃO DE DIREITOS

AUTOR: Gabriel Chagas Suzuki

TÍTULO: Ferramenta de inteligência artificial associado a dados do satélite Sentinel 2 na estimativa do volume de madeira em plantios de *Tectona grandis* L.f. no Pará

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.

Gabriel Chagas Suzuki

gabrielcszwp@gmail.com

Dedico este trabalho ao meu pai, Donato Sadao Suzuki,
principal incentivador da minha graduação.

AGRADECIMENTOS

Agradeço, acima de tudo, ao meu amável Deus, Nosso Senhor Jesus Cristo. Devo a Ele as diversas graças e dons que me capacitaram ao longo destes anos de formação acadêmica, pois sem Sua presença, nenhuma das etapas que enfrentei teria sentido.

Agradeço aos meus pais, pelo amor, paciência e dedicação empenhados em minha educação.

Aos meus irmãos por serem as melhores companhias que eu poderia desejar, estando comigo tanto na felicidade como na dificuldade.

Aos meus amigos, tanto de tempos passados quanto os que formei ao longo do curso.

Ao professor e orientador Professor Dr. Eder Pereira Miguel pelos momentos em que me conduziu, com grande diligência e paciência, na realização deste trabalho.

“Ou dizeis que a árvore é boa e seu fruto bom, ou dizeis que é má e seu fruto mau; porque é pelo fruto que se conhece a árvore”. (Matheus 12, 33)

RESUMO

Suzuki, Gabriel Chagas (SUZUKI, G. C.) **Ferramenta de inteligência artificial associado a dados do satélite Sentinel 2 na estimativa do volume de madeira em plantios de *Tectona grandis* Linn F. no Pará.** Monografia (Bacharelado em Engenharia Florestal) – Universidade de Brasília, Brasília, DF.

Plantações de *Tectona grandis* (teca) ocupam significativamente partes do mercado florestal, e para tal, técnicas de manejo dos povoamentos tornam-se atividades primordiais na otimização da produção. Para que isso seja possível, foi proposto o desenvolvimento de um modelo de predição do volume por meio de redes neurais artificiais associado a imagens de satélites, através do satélite Sentinel – 2, em indivíduos de teca. No trabalho, procurou-se conciliar informações geradas pelos índices de vegetação, calculados com bandas do satélite Sentinel-2, e parâmetros dendrométricos, como idade, índice de sítio, número e tipo de desbaste, a fim de estimar a produção volumétrica. Quanto às redes neurais, 70% dos dados destinou-se ao ajuste da rede e o restante para validação. Após isso, as cinco melhores redes em algumas configurações foram selecionadas pela avaliação dos valores de correlação (r) dos dados observados, erro padrão residual da estimativa (S_{yx} absoluto e relativo) e análise gráfica de resíduos. Os resultados apresentaram valores de alta correlação ($r \geq 0.90$) entre os dados de observados e estimados, para as cinco melhores redes, valores moderados a baixos no erro padrão da estimativa, S_{yx} e $S_{yx}\%$ menores que 20%, e baixa dispersão dos resíduos. Os resultados apontam que unir atributos do povoamento como a idade e a classe de sítio, com técnicas silviculturais como o desbaste associado a índices de vegetação, derivados das imagens do satélite Sentinel-2, são eficazes na predição do volume total por unidade de área em plantios de teca.

Palavras-chave: Teca, Redes Neurais Artificiais, Imagens de Satélites, Modelagem do Volume.

ABSTRACT

Suzuki, Gabriel Chagas (SUZUKI, G. C.) Artificial intelligence tool associated with data from Sentinel 2 satellite to estimate the volume of wood in plantations of *Tectona grandis* Linn F. in Pará. Monograph (Forest Engineering Degree) – University of Brasília, Brasília, DF.

Tectona grandis (teak) plantations occupy significant parts of the forestry market, and for that, stand management techniques become key activities in optimizing production. For this to be possible, it was proposed the development of a volume prediction model through artificial neural networks associated with satellite images, through the Sentinel - 2 satellite, in teak individuals. In the work, we tried to reconcile information generated by vegetation indices, calculated with bands from the Sentinel - 2 satellite, and dendrometric parameters, such as age, site index, number and type of thinning, in order to estimate volumetric production. As for the neural networks, 70% of the data was destined to the adjustment of the network and the rest for validation. After that, the five best networks in some configurations were selected by evaluating the correlation values (r) of the observed data, residual standard error of the estimate (absolute and relative S_{yx}) and graphical analysis of residuals. The results showed high correlation values ($r \geq 0.90$) between observed and estimated data, for the 5 best networks, moderate to low values in the standard error of the estimate, S_{yx} and $S_{yx}\%$ less than 20%, and low dispersion of residuals. The results show that joining stand attributes such as age and site class, with silvicultural techniques such as thinning associated with vegetation indices, derived from Sentinel-2 satellite images, are effective in predicting the total volume per unit area in teak plantations.

Keywords: Teak, Artificial Neural Networks, Satellite Images, Volume Modeling.

LISTA DE FIGURAS

Figura 1. Esquema de um neurônio artificial: com suas variáveis e respectivos pesos (camada de entrada), função aditiva, função de ativação e saída.....	21
Figura 2. Localização da área de estudo: município de Capitão Poço, estado do Pará, Brasil.....	23
Figura 3. Análises gráficas dos resíduos da RNA 3 para os dados dos povoamentos de teca no Pará, Brasil.....	30
Figura 4. Arquitetura da RNA selecionada na configuração (13-12-1) para predição do volume dos povoamentos de teca no Pará, Brasil.....	31

LISTA DE TABELAS

Tabela 1. Informações das resoluções espaciais e bandas espectrais do satélite Sentinel – 2.....	19
Tabela 2. Equações utilizadas para cálculo dos índices de vegetação dos povoamentos de <i>Tectona grandis</i> no Pará, Brasil.....	24
Tabela 3. Informações dos Índices de Vegetação e Volume total dos povoamentos de <i>Tectona grandis</i> no Pará, Brasil.....	27
Tabela 4. Matriz de Correlação dos Índices de Vegetação dos povoamentos de <i>Tectona grandis</i> no Pará, Brasil.....	28
Tabela 5. Valores de precisão das redes neurais artificiais treinadas para os dados dos povoamentos de teca no Pará, Brasil.....	29

LISTA DE ABREVIATURAS E SIGLAS

ESA	EuropeanSpaceAgency
MLP	Multi-layer Perceptron
RNA	Rede Neural Artificial

SUMÁRIO

1	INTRODUÇÃO	13
2	OBJETIVOS	15
2.1	Objetivo geral	15
2.2	Objetivos específicos	15
3	REVISÃO BIBLIOGRÁFICA	16
3.1	Tectona grandis	16
3.2	Modelagem do Volume de Povoamentos Florestais	17
3.3	Sensoriamento Remoto	28
3.4	Redes Neurais Artificiais	20
4	MATERIAL E MÉTODOS	23
4.1	Área de estudo e suas características	23
4.2	Inventário Florestal	24
4.3	Índice de vegetação	24
4.4	Variáveis Independentes	25
4.5	Treinamento das Redes Neurais Artificiais	25
4.6	Seleção e validação das redes	25
5	RESULTADOS E DISCUSSÃO	27
5.1	Índice de Vegetação	27
5.2	Treinamento das redes neurais	28
6	CONCLUSÕES	32
7	REFERÊNCIAS BIBLIOGRÁFICAS	33

1 INTRODUÇÃO

A demanda por produtos de origem florestal sempre teve seu espaço reservado no mercado nacional e internacional. Para atendê-la, as florestas plantadas se tornaram o melhor modelo para suprir as exigências do consumidor, contribuindo para aliviar a pressão de desmatamento sobre florestas nativas. Dentre as espécies de grandes relevâncias utilizadas nas plantações temos a *Tectona grandis* Linn. F., conhecida pelo nome popular de teca (NEWBY et al., 2012; PELISSARI et al., 2014). Sua boa aceitação no mercado florestal deve-se pelas características intrínsecas da madeira e seus usos, como: boa resistência à flexão, tração e peso, além de sua boa estabilidade, durabilidade e beleza estética, que lhe confere maior utilidade na produção de móveis, na construção civil e naval (PELISSARI et al., 2014; MIDGLEY et al., 2015).

O sudeste asiático, além de ser o local de origem dessa espécie, concentra a maior parte da sua produção (PANDEY, BROWN, 2000; PALANISAMY et al., 2009; YASODHA et al., 2018). Entretanto, plantações comerciais na América Latina e na África ganham destaque pelas facilidades na implantação dos povoamentos, devido ao avanço das técnicas de manejo e à compatibilidade com clima suportado pela espécie (TEWARI et al., 2013; KOLLERT, WALOTEK, 2015; MIDGLEY et al. 2015; YASODHA et al., 2018).

Para o manejo dessas áreas, faz-se necessário o monitoramento de informações sobre o a produção volumétrica nos povoamentos. Esse monitoramento acontece muitas vezes pela estimativa do volume, utilizando-se de variáveis como altura e diâmetro, o que possibilita o acompanhamento do povoamento e a estimativa precisa dos estoques de madeira, sendo estes, processos importantes para a tomada de decisões de manejo e para a otimização da produção (DAVIS, JOHNSON, 1987). Na predição do volume, frequentemente são utilizadas informações extraídas por meio do método tradicional, no qual o levantamento de campo entrega aos interessados um certo grau de confiabilidade e precisão na estimativa, embasado em um grande acervo científico (MACEDO et al., 2017). Em contrapartida, a medição constante dos indivíduos pode ser economicamente inviável, ainda mais considerando métodos diretos e destrutivos como a cubagem rigorosa, em razão dos custos envolvidos na aplicação da atividade de manejo do povoamento, considerando que em locais extensos e de difícil acesso requerem tempo de levantamento (FREITAS, MAGALHÃES, 2012; ALVES et al., 2013; BARROS et al., 2015).

Em virtude disso, alternativas estão sendo desenvolvidas para alcançar essa economia de custos, sem perder a confiabilidade das técnicas tradicionais (ALVES et al., 2013; SANTOS et al, 2017). Dentre elas, o uso de sensoriamento remoto por satélites, técnica de geoprocessamento, mostrou-se bastante viável (ALVES et al., 2013). A fim de aproveitar melhor as informações obtidas por satélites, foram elaborados os índices de vegetação (IVs) (ROSENDO, 2005). Os IVs descrevem matematicamente o comportamento da cobertura vegetal, combinando as bandas que constituem intervalos específicos do espectro eletromagnético, as quais reagem à dinâmica da vegetação. A aplicação desses índices nas imagens de satélites resolve o problema de monitorar locais de difícil acesso, apesar de não produzir dados com precisão semelhante àqueles que são obtidos em campo (GONÇALVES, 2021).

Todavia, o problema de imprecisão presente no sensoriamento remoto pode ser remediado pelo poder computacional presente em algoritmos de aprendizado de máquina. Um deles é a rede neural artificial (RNA), inspirada no funcionamento do sistema nervoso humano, formada por um conjunto de unidades computacionais conectadas entre si, programadas para realizar uma tarefa específica, como uma regressão (MITCHELL, 1997; HAYKIN, 2001, CHOW, 2007; CASTRO, FERRARI, 2016). De fato, o uso de RNA se mostra eficaz para tarefas como a predição de volume e de biomassa do Cerrado brasileiro, com o uso dos índices de vegetação (MIGUEL et al., 2015).

Ao relacionar índices de vegetação derivados de imagens de sensoriamento remoto com redes neurais artificiais, é possível minimizar as deficiências de precisão presentes nos métodos de sensoriamento remoto e fornecer-se mais informações para a rede neural, aumentando a capacidade de estimativa de ambas as partes. Essa combinação compõe uma técnica de manejo precisa e automatizada com a RNA, de baixo custo e aplicabilidade em locais de difícil acesso por parte do sensoriamento remoto, capaz de conhecer a produção da floresta e, a partir disso, facilitar a tomada de decisão do manejo, como a compra de florestas ou de ações envolvendo equipes de campo. No presente trabalho, buscou-se estudar e desenvolver um modelo neural-artificial capaz de estimar o volume de madeira de um povoamento de Teca no estado do Pará, usando dados de sensoriamento remoto com atributos do povoamento de fácil obtenção, como idade, índice de sítio e número e tipo de desbaste.

2 OBJETIVOS

2.1 Objetivo geral

Desenvolver um modelo de predição de volume comercial de um povoamento de Teca (*Tectona grandis*) usando variáveis dendrométricas, índices de vegetação derivados de imagens Sentinel-2 e do povoamento florestal.

2.2 Objetivos específicos

- Estimar a correlação de índices de vegetação com a produção em volume;
- Refinar a predição do volume em modelos matemáticos de manejo de povoamentos florestais usando dados georreferenciadas (índices de vegetação, variáveis categóricas como idade, índice de sítio, número de desbaste e tipo de desbaste);
- Elaborar, treinar e validar redes neurais artificiais para predizer o volume de madeira de Teca no povoamento florestal.

3 REVISÃO BIBLIOGRÁFICA

3.1 *Tectona grandis*

A teca, oriunda das florestas tropicais de monção do sudeste asiático (PANDEY, BROWN, 2000; PALANISAMY et al., 2009; NEWBY et al., 2012; YASODHA et al., 2018; KUSBACH et al., 2021), é uma espécie da família das Lamiaceae. Descreve-se como uma espécie pioneira caducifólia de grande porte, podendo alcançar 2,50 metros de diâmetro e mais de 50 metros de altura (FLORESTAL, 2017). Pelas características de pioneira também observa-se que é uma planta heliófita, ou seja, não tolera sombreamento, de rápido crescimento inicial em sua altura e grande produção de flores e frutos justamente para ocupação das clareiras abertas nas florestas (FIGUEIREDO et al., 2005; PALANISAMY et al., 2009; PELISSARI et al., 2014; FLORESTAL, 2017).

As folhas são grandes, coriáceas, arredondadas e opostas, medindo cerca de 30 a 40 cm de comprimento por 25 cm de largura em indivíduos adultos. Quanto às flores, são ordenadas em panícula com 700 a 3.500 flores brancas e pequenas. Desse total, 1% a 2% se tornam frutos, os quais são do tipo drupa, de cor castanho-claro, envoltos em um cálice membranoso (PALANISAMY et al., 2009; PELISSARI et al., 2014).

Seu tronco, de alto valor comercial, é retilíneo, de cor cinza ou marrom e possui casca gretada e fina com 1,2 cm de espessura (FIGUEIREDO et al., 2005; PELISSARI et al., 2014). A madeira apresenta elevada resistência natural às intempéries e ataque de xilófagos, devido a alguns extrativos químicos encontrados dentro da madeira que lhe conferem essa propriedade contra insetos e fungos (MACEDO et al., 2005; FLORESTAL, 2017). Além disso, valoriza-se a madeira pela sua durabilidade, longevidade, resistência mecânica, estabilidade e de fácil trabalho (MACEDO et al., 2005; FLORESTAL, 2017). Mediante tantas vantagens, essa madeira possui diversos usos, sendo empregada na fabricação de decks, dormentes, móveis, artesanato e na construção civil e naval (PELISSARI et al., 2014; MIDGLEY et al., 2015).

A Ásia responde por 88% da produção mundial, mas encontram-se povoamentos na região tropical da África e América Latina, 8% e 4% respectivamente (TEWARI et al., 2013; KOLLERT, WALOTEK, 2015; MIDGLEY et al. 2015; KOLLERT; KLEINE, 2017). O Brasil, destaca-se na produção de teca na América Latina, pela sua extensão de áreas já plantadas (94 mil ha) (IBÁ 2020), potencial de reflorestamento de novas áreas, pela

semelhança climática com a região nativa da espécie e pelo conhecimento e tecnologia aplicados no manejo de outras espécies (BEZERRA, 2009). Os primeiros povoamentos da espécie surgiram na região do Centro-Oeste, entre a década de 60 e 70, ganhando força no setor florestal brasileiro nos estados de Mato Grosso, Rondônia e Pará. (FIGUEIREDO et al., 2005; FLORESTAL, 2017).

3.2 Modelagem do volume de povoamentos florestais

No manejo das florestas, as informações relativas ao povoamento são necessárias para o conhecimento do estado atual dos recursos florestais, ponto de partida para o planejamento de ações futuras que otimizem o resultado da produção (DAVIS, JOHNSON, 1987; LEAL, 2013; VENDRUSCOLO, 2014; SOUZA, 2021). O volume do povoamento é uma dessas informações, o qual descreve qualitativa e quantitativamente a produção material dos povoamentos florestais, bem como o desenvolvimento dos indivíduos plantados (LEAL, 2015; RIBEIRO, 2019). Com essa finalidade, inventários florestais são realizados para estimá-lo com certo grau de precisão.

Os inventários podem usar métodos diretos, como a cubagem rigorosa e a pesagem da árvore, ou indiretos, como os modelos volumétricos (BERRA, 2012; LEAL, 2013; MACEDO et al., 2017). A metodologia indireta é a mais utilizada, pois é a que menos demanda tempo e recurso, ainda mantendo um grau de precisão aceitável de descrição da realidade. Nessa metodologia, as estimativas dos modelos indiretos utilizam-se de parâmetros amostrais como altura, diâmetro a altura do peito (dap), idade e área basal para generalizar padrões aos demais indivíduos e compreender como as intervenções silviculturais e/ou ambientais impactam no desenvolvimento do povoamento (LEAL, 2013; SOUZA, 2021).

No entanto, o levantamento de informações no campo pode ser facilitado e os custos em seu processo podem ser reduzidos (LEAL, 2015). Para isso, novas alternativas de modelagem estão sendo desenvolvidas, tais como modelos que se utilizam de sensoriamento remoto ou redes neurais artificiais, incorporando novas tecnologias e ganhando notoriedade

pelos benefícios que trazem consigo, uma vez que dispensam o retorno periódico do inventário florestal (LEAL, 2015; GONÇALVES, 2021).

3.3 Sensoriamento Remoto

As tecnologias de geoprocessamento incorporaram ao manejo a possibilidade de aquisição, processamento e análise de dados espacialmente referenciadas em povoamentos florestais, de forma econômica, acessível e eficiente (FREITAS, MAGALHÃES, 2012; ALVES, 2013; BARROS et al., 2015; KERSKI, 2015; SANTOS et al., 2017; GONÇALVES, 2021). Uma das tecnologias empregadas é o uso de sensores remotos, a partir dos quais é possível captar a radiação refletida pela superfície terrestre em diversas faixas do espectro magnético e em várias resoluções, dependendo da finalidade almejada (MORAES, 2002; QUARTAROLI, 2014). Os sensores podem ser ativos, quando operam com sua própria fonte de emissão ou luz, ou passivos, quando dependem da energia refletida, e encontram-se instalados em plataformas terrestres; aéreas, como aviões e drones; ou orbitais, como satélites artificiais (MORAES, 2002; QUARTAROLI, 2014).

Os satélites artificiais imageadores são umas das opções mais usuais dentre os tipos de sensores remotos. Eles conseguem captar a reflectância em bandas do visível e do infravermelho, que são boas em caracterizar as dinâmicas da vegetação e do solo. Alguns satélites têm serventia para estudo florestais, como o Landsat, que já foi utilizado em estimativas de volume em espécies de eucalipto (BERRA, 2012), bem como satélites RapidEye (LEAL, 2015, CARRIJO 2020), IKONOS II (NASCIMENTO, 2006) e Sentinel – 2, os quais foram utilizados para descrição e classificação da cobertura terrestre.

O Sentinel - 2, foi projetado para monitorar vegetações, solos e áreas costeiras, munido de sensores ópticos de alta resolução espacial (ESA, 2012; EMBRAPA TERRITORIAL, 2018). Foi fruto da missão Sentinel, planejada pela Agência Espacial Europeia (ESA) para dar continuidade a missões antigas da União Europeia de monitoramento do tempo, do clima, do uso e ocupação das terras e dos recursos naturais terrestres e marítimos (ESA, 2012; EMBRAPA TERRITORIAL, 2018). A razão para o sucesso do Sentinel - 2 nessa missão é o uso do MSI (Multi Spectral Instrument), cuja eficácia decorre da captação de raios eletromagnéticos em 13 bandas espectrais distintas, da sua alta resolução radiométrica, ao comportar uma faixa de valores de intensidade de luz variantes de 0 a 4095,

com 12 bits de precisão, contribuindo para extração de informações com maior exatidão (ESA, 2015; GONÇALVES, 2021) e do design óptico de seu telescópio, com campo de visão de 290 km (ESA, 2015; EMBRAPA TERRITORIAL, 2018) e resolução espacial que varia de 10 a 60 metros, a depender da banda espectral (ESA, 2015). As especificidades técnicas do satélite encontram-se na Tabela 1.

Tabela 1. Informações das resoluções espaciais e bandas espectrais do satélite Sentinel - 2.

Banda	Nome da Banda	Comprimento de onda central (nm)	Largura da Banda (nm)	Resolução Espacial (m)
1	Aerossol	443	20	60
2	Blue	490	65	10
3	Green	560	35	10
4	Red	665	30	10
5	Red Edge 1	705	15	20
6	Red Edge 2	740	15	20
7	Red Edge 3	783	20	20
8	NIR	842	115	10
8a	Red Edge 4	865	20	20
9	Water Vapor	945	20	60
10	Cirrus	1380	30	60
11	SWIR 1	1610	90	20
12	SWIR 2	2190	180	20

Onde: NIR = Near Infrared; SWIR = Short-Wave Infrared
 Fonte: ESA (2012).

3.3.1 Índices de Vegetação

Mediante as informações de satélites, os índices de vegetação (IVs) surgiram na tentativa de caracterizar a vegetação por manipulações matemáticas de bandas espectrais que possuem interação com a mesma (BORATTO, GOMIDE 2013; LEAL, 2013). As faixas úteis na extração de informações específicas a respeito do estado da vegetação normalmente utilizadas são do vermelho e infravermelho próximo, pois 90% da resposta da variação espectral da vegetação está situada nessa região. (EPIPHANIO et al., 1996). Os IVs não baseiam-se somente na respostas vinda das bandas do vermelho e do infravermelho próximo, devido a reflectância da atividade fotossintética da vegetação, mas também na utilização de

duas ou mais bandas espectrais que podem minimizar os “ruídos” das fontes que afetam a resposta da vegetação (SILVA, 2004; ROSENDO, 2005; BORATTO, GOMIDE, 2013). Exemplos de IVs são o NDVI, SAVI e MSAVI, e EVI e EVI2.

O primeiro IV é o Índice de Vegetação da Diferença Normalizada (NDVI), sendo o Índice mais usado, que têm a capacidade de minimizar efeitos topográficos ao produzir uma escala linear de medida e normalizada, variando entre -1 a $+1$ (DEERING, 1978; ROSENDO, 2005). Outros índices são o SAVI (*Soil Adjusted Vegetation Index*), que possui a propriedade de minimizar os efeitos do solo de fundo com um fator L na equação NDVI (HUETE, 1988; ROSENDO, 2005), de forma que o valor de L depende da reflectância do solo e da densidade da vegetação; e a sua modificação MSAVI (*Modified SAVI*), com fator L alterado, minimizando o efeito do solo desnudo do SAVI e induzindo a remoção do ruído do solo não considerado no NDVI (QI et.al., 1994). Os últimos IVs foram o EVI, *Enhanced Vegetation Index*, e EVI 2 que foram desenvolvidos para otimizar o sinal da vegetação em regiões de alta biomassa, além de apresentar melhor capacidade de monitoramento através de uma quebra do sinal do substrato do dossel vegetal e de redução das influências atmosféricas (LIU & HUETE, 1995; HUETE et. al. 1997; JIANG et al., 2008).

3.4 Redes Neurais Artificiais

Redes Neurais Artificiais possuem um grande domínio de aplicação, de modo que já são concretos estudos em reconhecimento facial, filtragem de conteúdos e diagnósticos médicos (HAYKIN, 2001; JUNIOR, 2011; LOBO, 2017). As RNAs são estudadas e empregadas nessas áreas pela sua capacidade computacional de trabalho com grande quantidade de dados, extraindo informações como reconhecimento de padrões que indiquem algum evento ou atividade, classificação em classes por combinações de parâmetros, previsão de comportamentos futuros e otimização de recursos limitados (ELMASRI, NAVATHE, 2018). Para a realidade florestal, o emprego dessa novidade justifica-se pelos resultados positivos que estão sendo aplicados. Finalidades como estimativa de potencial energético (CARRIJO, 2020), estimativa da resistência da madeira (MIGUEL et. al., 2018), predição de volume e biomassa (MIGUEL et.al., 2015), classificação de estratos florestais (GONÇALVES, 2016) e identificação de áreas prioritárias para recuperação florestal (ARCOVERDE, 2011) demonstram sua funcionalidade na área.

A Rede Neural Artificial vem do desenvolvimento de modelos computacionais inspirados no sistema neural de seres humanos (STUART, PETER, 2016), visto que é uma série de unidades computacionais conectadas entre si, simulando uma rede de neurônios, programadas para realizar uma tarefa específica (MITCHELL, 1997; CHOW, 2007).

O neurônio humano é a menor unidade operacional do sistema nervoso biológico formado de três partições: os dendritos, responsável pela captura de dados externos ao neurônio; os axônios, responsáveis pela condução dos impulsos nervosos através da sinapse; e o corpo celular, dedicado ao processamento das informações obtidas (MITCHELL, 1997; HAYKIN, 2001; CHOW, 2007). O neurônio artificial se assemelha ao neurônio biológico pela sua composição descrita na Figura 1, na qual possui a camada de entrada, por onde as variáveis e seus respectivos pesos entram, a região operacional, correspondentes à adição neural e função de ativação, e a saída (MITCHELL, 1997; CHOW, 2007).




Figura 1. Esquema de um neurônio artificial: com suas variáveis e respectivos pesos (camada de entrada), função aditiva, função de ativação e saída.

Fonte: Mitchell (1997).

Os pesos representam a força sináptica de cada conexão neural, sendo cada um deles ajustado no processo de treinamento da rede. A função aditiva é aquela responsável pela soma de todos os sinais de entrada que foram ponderados pelos respectivos pesos sinápticos a fim de produzir um valor passível de ativação (CHOW, 2007). Uma vez somados, o valor obtido será submetido a uma função de ativação que determinará se a informação do neurônio é importante para o restante da rede, ou seja, se o valor do neurônio vai ter ou não impacto, como na figura x (MITCHELL, 1997; CHOW, 2007).

As redes podem ser organizadas e classificadas pela sua forma de aprendizagem: redes supervisionadas ou não supervisionadas (CHOW, 2007). Define-se por aprendizagem o processo de adaptação do comportamento que visa o melhor resultado usando experiências passadas, ou seja, no contexto de rede neural seria análogo ao treinamento com que a rede é

submetida para encontrar o valor dos pesos e viés, seguindo parâmetros estatísticos (MITCHELL, 1997; CASTRO, FERRARI, 2016).

A forma de aprendizagem não-supervisionada é aquela da qual dispõe-se apenas da base de dados, sem variáveis discretas ou contínuas para ter como “professor”. Simplificando, o algoritmo foca na capacidade de agrupar e categorizar os objetos (CHOW, 2007; CASTRO, FERRARI, 2016). Enquanto a forma de aprendizagem supervisionada é baseada em um conjunto de dados para os quais os *output* desejados são conhecidos, ou seja, ações de regressão e classificação são possíveis de serem realizadas (MITCHELL, 1997; CHOW, 2007; CASTRO, FERRARI, 2016).

A principal arquitetura de RNA utilizada para fins de estimativa são as redes MLP (Multi-layer Perceptron) (HAYKIN, 2001). Define-se um Multi-layer Perceptron como uma rede Perceptron, sendo esta uma rede de camada única, composta de uma ou mais camadas ocultas, além da camada de entrada e de saída (MITCHELL, 1997; CASTRO, FERRARI, 2016). O Perceptron é a forma mais simples de rede neural capaz de classificar padrões lineares (CASTRO, FERRARI, 2016). As MLPs surgiram como uma forma de solucionar um problema inerente dos Perceptron que era a estimativa de padrões não-lineares (CASTRO, FERRARI, 2016). Para isso, as MLPs possuem os sinais de entrada propagados para frente através da rede, camada por camada, conceituadas como feedforward, uma função de ativação não linear do tipo sigmoidal e alto grau de conectividade entre neurônios com o objetivo de sanar esse déficit (ALCÂNTARA, 2015; CASTRO, FERRARI, 2016).

4 MATERIAL E MÉTODOS

4.1 Área de estudo e suas características

O estudo foi conduzido em um povoamento de teca no município de Capitão Poço, Pará, Brasil. A plantação se localiza na Fazenda São Luiz, pertencente a empresa Tietê Agrícola Ltda (Figura 2). A região possui Floresta Ombrófila Densa, com relevo plano com leves ondulações (IBGE 2012). Nessa área, foram observados os tipos de solo Latossolo Amarelo distrófico petroplântico (LAd), Latossolo Amarelo distrófico típico (LAdt) e Plintossolo Pétrico concrecionário (FFc) (SANTOS, 2018). Além disso, o clima local, segundo a classificação de Köppen, é tropical quente e úmido (Am), a precipitação pluviométrica no município foi, em média, de 2.370 mm e a temperatura média foi de 26 °C (PACHECO, BASTOS, 2001; ALVARES et al. 2013).

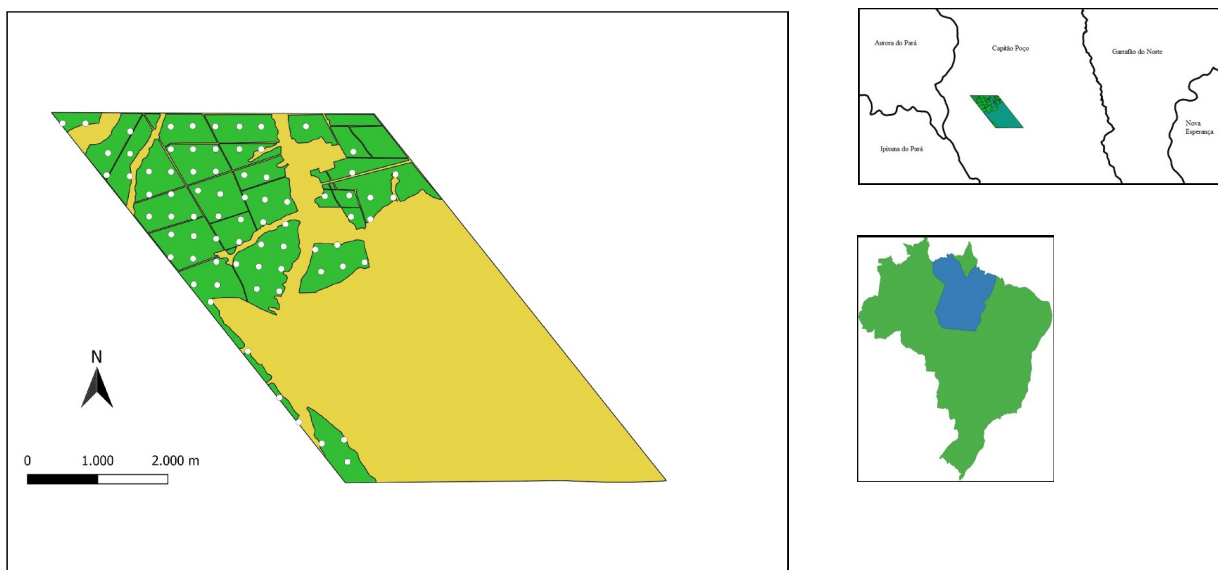


Figura 2. Localização da área de estudo: município de Capitão Poço, estado do Pará, Brasil.

Fonte: Autor (2022).

A área plantada (745,4 ha) está dividida em 19 talhões com idades de 6, 7, 8, 9 e 11 anos com espaçamentos de 3,5 m 3,5 m; 3,75 m 3,75 m e 4 m 4 m. Nas ações silviculturais houve o combate às formigas cortadeiras com iscas formicidas, a limpeza da área com trator de esteira, a calagem com calcário dolomítico (3 t ha⁻¹), o plantio manual, a adubação inicial (200 g/planta de NPK 8-28-16 e 100 g/planta de KCl), o controle de plantas daninhas por coroamento com enxada, a roçagem mecanizada e semimecanizada com trator hidráulico, a adubação de manutenção com aplicação de Boro (7 g/planta) e KCl (100 g/planta) e a desrama artificial com

serra manual e motopoda. Por fim, sucedeu-se o desbaste sistemático, com intensidade de 50% da remoção da área basal, aos cinco e nove anos do plantio (SOUZA et al., 2022).

4.2 Inventário Florestal

Na construção do inventário florestal, nove avaliações foram feitas em 76 parcelas fixas de 500 m², dispostas sistematicamente sobre o plantio em uma grade de 320 m x 320 m. Além disso, nas parcelas, utilizou-se uma fita diamétrica para o diâmetro a 1,3 m do solo (diâmetro a altura do peito) e o hipsômetro Vertex IV à altura total (ht) (Haglöf, 2007). Já a altura dominante (hdom) foi determinada de acordo com o critério estabelecido por Assmann (1970), com a medição da altura de cinco indivíduos dominantes. Por último, foram cubadas 138 árvores usando o método de hohenadl, ou seja, dividiu-se a madeira em 10 seções proporcionais à altura total do indivíduo, em intervalos de 10% começando na posição de 5% até 95% do fuste (MACHADO, FIGUEIREDO FILHO, 2014).

Cálculo do volume

$$\frac{d_i}{DAP} = \beta_0 + \beta_1 \left(\frac{h_i}{H_t} \right) + \beta_2 \left(\frac{h_i}{H_t} \right)^2 + \beta_3 \left(\frac{h_i}{H_t} \right)^3 + \beta_4 \left(\frac{h_i}{H_t} \right)^4 + \beta_5 \left(\frac{h_i}{H_t} \right)^5 + \varepsilon_i \quad (1)$$

$$V = K \int_{h_1}^{h_2} d_i^2 \delta h \quad (2)$$

Onde: d_i : diâmetro comercial com casca e do cerne (cm) ou diâmetro correspondente a qualquer altura; h_i : especificada ou comercial; DAP: diâmetro à altura do peito (cm); H_t : Altura total (m); β_i - Coeficientes da regressão; ε_i : Erro aleatório.

<i>Modelo</i>	<i>Coefficientes</i>	<i>R²_{aj}</i>	<i>S_{yx}</i>	<i>S_{yx}%</i>	<i>AIC</i>
<i>Diâmetro com casca</i>	$b_0 = 1,37570773209341^*$	0,98	1,19	7,95	432,24
	$b_1 = -6,30483800773411^*$				
	$b_2 = 27,6048762767335^*$				
	$b_3 = -58,9312432175408^*$				
	$b_4 = 56,0474413702162^*$				
	$b_5 = -19,802074091257^*$				

Onde: b_i : coeficientes ajustados; R^2_{aj} : Coeficiente de determinação ajustado; S_{yx} and $S_{yx}\%$: erro padrão da estimativa absoluto e em porcentagem recalculado, respectivamente; AIC: critério de informação de Akaike; * significativo ao nível de 5% de probabilidade ($p \leq 0,05$).

4.3 Índice de vegetação

As imagens foram obtidas do satélite Sentinel-2, bandas 2, 4 e 8, com resolução espacial de 10 m no formato GeoTIFF, tomadas no dia 02 de maio de 2021. Foram aplicadas correções

nas imagens utilizadas, considerando a reflectância do topo da atmosfera, a fim de reduzir erros nos cálculos dos índices de vegetação. A partir das imagens de satélites foram calculados cinco índices de vegetação conforme (Tabela 2).

Tabela 2. Equações utilizadas para cálculo dos índices de vegetação dos povoamentos de *Tectona grandis* no Pará, Brasil.

#	Índice	Equação
Eq. 3	Índice de vegetação da diferença normalizada - NDVI	$\frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}}$
Eq. 4	Índice de vegetação ajustado ao solo - SAVI	$\frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED} + L} \cdot (1 + L)$
Eq. 5	Índice de vegetação ajustado ao solo modificado - MSAVI	$\frac{2 \cdot \rho_{NIR} + 1 - \sqrt{(2 \cdot \rho_{NIR} + 1)^2 - 8 \cdot (\rho_{NIR} - \rho_{RED})}}{2}$
Eq. 6	Índice de vegetação melhorado - EVI	$\frac{2,5 \cdot (\rho_{NIR} - \rho_{RED})}{\rho_{NIR} + 6 \cdot \rho_{RED} - 7,5 \cdot \rho_{BLUE} + 1}$
Eq. 7	Índice de vegetação melhorado 2 - EVI II	$\frac{2,5 \cdot (\rho_{NIR} - \rho_{RED})}{\rho_{NIR} + 2,4 \cdot \rho_{RED} + 1}$

Onde: ρ_{NIR} = reflectância do infravermelho próximo; ρ_{RED} = reflectância do vermelho; ρ_{BLUE} = reflectância do azul; e L = fator de correção do solo, tal que L = 0,50 foi usado para esse trabalho.

4.4 Variáveis Independentes

Após a estimativa dos índices de vegetação, foram separados atributos do povoamento para compor o modelo artificial. Logo, informações como idade do plantio (6, 7, 8, 9 e 11 anos), número de desbastes (1º e 2º), tipo de desbaste (sistemático e seletivo) e índice de sítio (14, 17 e 20 m) serviram de parâmetros categóricos pro modelo por RNAs.

4.5 Treinamento das Redes Neurais Artificiais

No treinamento das RNAs, foram desenvolvidas redes do tipo MLP de camada oculta única. O número de neurônios nas camadas de entrada foi determinado por uma análise de regressão e um teste de correlação entre os índices e o resultado real do volume para as variáveis contínuas, sendo acrescida de variáveis categóricas como quantidade e tipo de desbaste, idade e índice de sítio.

Na camada oculta, o número de neurônios, o algoritmo utilizado e as funções de ativação das camadas ocultas e de saída foram otimizadas por meio da ferramenta Intelligent Problem Solver (IPS) do software Statistica versão 12 (STATSOFT INC, 2011), buscando assim encontrar a menor taxa de erro nas previsões (MIGUEL et.al., 2018).

O número de neurônios da camada oculta variaram entre três a 20 neurônios. Para as

camadas intermediárias e de saída, alternou-se configurações usando funções de ativação sigmoideal como a logística, a exponencial, a hiperbólica tangente (tahn), a de identidade e seno. Os algoritmos de otimização usados foram os: gradiente conjugado, gradiente descendente e o BFGS.

4.6 Seleção e validação das redes

70% das parcelas foram escolhidos aleatoriamente para o ajuste das RNAs, já as demais parcelas foram destinadas à validação utilizando o teste “t” a nível de significância de 0,05. No total foram treinadas 500 Rnas e retida as cinco redes neurais com os melhores resultados estatísticos.

Para avaliar a qualidade estatística das redes neurais treinadas seguiu-se os seguintes parâmetros: correlação entre os valores previstos e observados (r); análise gráfica dos resíduos; e erro padrão absoluta e relativa da estimativa (S_{yx} e $S_{yx}\%$), calculado como nas equações 8 e 9:

$$S_{yx} = \sqrt{\frac{\sum_{i=1}^n (\bar{Y}_i - Y_i)^2}{n}} \quad (8)$$

$$S_{yx} (\%) = \frac{S_{yx}}{\bar{Y}_{média}} \cdot 100 \quad (9)$$

$$DA\% = \frac{\sum_{i=1}^n Y_i - \sum_{i=1}^n \bar{Y}_i}{\sum_{i=1}^n \bar{Y}_i} \cdot 100 \quad (10)$$

Onde: S_{yx} e $S_{yx} \%$ = Erro padrão absoluta e relativa da estimativa; \bar{Y}_i = volume observado; Y_i = Volume estimado; $\bar{Y}_{média}$ = média do volume observado; n = tamanho de casos amostrais.

Por fim, a RNA que apresentou o melhor desempenho foi submetida ao processo de validação utilizando o teste - t a uma probabilidade α de 0,05 e, posteriormente, foi calculada a diferença agregada em porcentagem (DA%), métrica estatística definida pela diferença entre o somatório dos valores reais e o somatório dos valores preditos como na equação 10, utilizada como indicador de sub ou superestimação (MIGUEL et al., 2015; CARRIJO, 2020).

Os dados foram analisados pelo software Microsoft Excel 2016®, os índices foram calculados pelo software de Geoprocessamento QGIS® versão 3.24.1 (Datum SIRGAS 2000, zona UTM 21 sul), e o treinamento das RNAs foi realizado pelo programa Statistica 12.0. A partir de 76 parcelas alocadas de forma aleatória na área, foram coletados dados dos 5 índices de

vegetação, idade, índice de sítio, número e tipo de desbastes.

5 RESULTADOS E DISCUSSÃO

5.1 Índices de Vegetação

Para obtenção de dados sobre as variáveis que iriam compor o modelo de RNA, foram analisadas os dados do volume, variável dependente, e calculadas os índices de vegetação, variável independente, das parcelas amostrais. Ao avaliar o coeficiente de variação, responsável por indicar o grau de heterogeneidade dos dados, o volume das parcelas apresentou-se um coeficiente de variação (CV%) de 39,64%, ou seja, o volume tinham alta heterogeneidade. Já os índices de vegetação tiveram valores de CV% abaixo de 10%, baixa heterogeneidade. Conforme apresentado na Tabela 1, mostram-se os dados dos índices de vegetação e do volume total.

Tabela 3. Estatística descritiva dos Índices de Vegetação e Volume total dos povoamentos de *Tectona grandis* no Pará, Brasil.

	Vt	NDVI	SAVI	MSAVI	EVI	EVI2
Médias	91,32	0,7949	0,4400	0,4221	0,4688	0,4359
Máximo	229,89	0,8603	0,5083	0,5113	0,5577	0,5164
Mínimo	34,36	0,6669	0,3629	0,3324	0,3722	0,3512
Variância	1310,03	0,0013	0,0010	0,0015	0,0016	0,0013
Desvio	36,19	0,0361	0,0310	0,0390	0,0395	0,0356
CV %	39,63	4,5410	7,0528	9,2366	8,4236	8,1780

Onde: Vt = Volume total ($\text{m}^3 \text{ha}^{-1}$); NDVI = índice de vegetação da diferença normalizada; MSAVI = índice de vegetação ajustada ao solo; MSAVI = índice de vegetação ajustada ao solo modificado; EVI = índice de vegetação melhorado; EVI2 = índice de vegetação melhorado 2.

Fonte: Autor (2022).

Para escolher quais índices iriam compor a camada de entrada da rede, adotou-se os maiores coeficientes de correlação de Pearson (r) como o critério. O coeficiente de correlação é um indicador que demonstra o grau de interdependência entre duas variáveis contínuas. O intervalo da correlação varia entre +1 e -1, na qual o valor +1 indica dependência total positiva, -1 para dependência total invertida e 0 (zero) independência. Hinkle et al. (2003) estabelece um critério para definir o grau de interdependência entre variáveis. Se o valor da correlação estiver entre $0,30 < r < 0,49$ a interdependência é considerada baixa; se o valor for entre $0,50 < r < 0,69$

é moderada e (r) acima de 0,70, a probabilidade é considerada alta.

A matriz de correlação da Tabela 2 apresentou valores baixos para todos os índices de vegetação $r < 0,49$, no entanto apenas o NDVI destacou-se entre os demais por ser o que tinha a melhor correlação com o volume e por ser o único significativo a 95% de probabilidade. O NDVI foi selecionado e utilizado dentre os índices como variável contínua independente da rede neural por conseguir explicar o comportamento do volume da teca.

Tabela 4. Matriz de Correlação dos Índices de Vegetação dos povoamentos de *Tectona grandis* no Pará, Brasil.

	Vt	NDVI	SAVI	MSAVI	EVI	EVI2
Vt	1					
NDVI	0,43	1				
SAVI	0,3	0,65	1			
MSAVI	0,29	0,62	0,99	1		
EVI	0,27	0,57	0,98	0,99	1	
EVI2	0,29	0,62	0,99	0,99	0,99	1

Onde: Vt = Volume total; NDVI = índice de vegetação da diferença normalizada; SAVI = índice de vegetação ajustada ao solo; MSAVI = índice de vegetação ajustada ao solo modificado; EVI = índice de vegetação melhorado; EVI2 = índice de vegetação melhorado 2.

Fonte: Autor (2022).

Segundo Ponzoni (2001) e ratificado por Miguel et al. (2015), os baixos valores de correlação entre os índices e as variáveis dendrométricas, volume nesse caso, é explicado por conta da limitação e dos erros intrínsecos ao sensor remoto em captar fidedignamente os aspectos da cobertura vegetal, como interferências externas como efeitos atmosféricos, fontes de radiação externas, dinâmicas do dossel. Além do mais, a informação gerada pelos sensores capta apenas um aspecto da vegetação, o que muitas vezes não incluem a interferência de outras variáveis e fatores ambientais.

5.2 Treinamento das redes neurais

Na formação da rede, as variáveis utilizadas para estimativa foram cinco: (NDVI, Índice de Sítio, Idade, Quantidade e Tipo de desbaste) e uma de saída, que seria o volume. O NDVI entrou como variável contínua, ou seja, tem domínio infinito de valores, enquanto que o índice

de sítio, idade, quantidade e tipo de desbaste entraram no modelo como variáveis categóricas, que se resume em um valor capaz de agrupar dados com base em alguma propriedade qualitativa.

Nessas condições, foram treinadas 1000 RNAs e as cinco melhores selecionadas apresentaram estatísticas de ajuste e precisão, com valores de coeficiente de correlação (r) superiores a 0,90 e erros de estimativa inferiores a 20%. A rede neural 3 foi a RNA que demonstrou melhor capacidade preditiva, segundo valores de Syx e Syx% e coeficiente de correlação (r) (**Tabela 3**).

Tabela 5. Valores de precisão das redes neurais artificiais treinadas para os dados dos povoamentos de teca no Pará, Brasil.

Arquitetura	Função de Ativação		r	Syx	Syx (%)
	Camada Intermediária	Camada de Saída			
MLP 13-13-1	Tanh	Exponencial	0,932685	15,453	16,921
MLP 13-19-1	Tanh	Exponencial	0,945754	14,877	16,291
MLP 13-12-1	Tanh	Logistic	0,960190	13,346	14,614
MLP 13-9-1	Tanh	Logistic	0,932003	15,548	17,025
MLP 13-13-1	Tanh	Exponencial	0,931976	15,458	16,927

Onde: r = coeficiente de correlação; Syx = erro padrão absoluto da estimativa; Syx (%) = erro padrão relativo da estimativa.

Fonte: Autor (2022).

A eficiência das RNAs pode ser constatada em diversos estudos segundo trabalhos como de Vendruscolo et al.(2017) e Almeida (2020) para estimativa de altura de *Tectona grandis*, de Carrijo et al. (2020) para predição de potencial energético no Cerradão brasileiro e de Miguel et al. (2018) para estimativa da resistência da madeira. Nesses trabalhos apresentaram valores de correlação e erro padrão semelhantes ao do presente estudo.

Todavia, os critérios estatísticos podem não considerar erros tendenciosos em uma região da variável de interesse. Com isso, acompanha-se os indicativos estatísticos com a análise gráfica dos resíduos para a escolha do modelo.

Após as métricas estatísticas, foi realizada a avaliação gráfica do resíduo da rede para as redes neurais (Figura 3). A RNA 3 foi a escolhida por apresentar boa acurácia nos valores preditos (a), distribuição aceitável dos resíduos (b) e o histograma referente a classes de erros (c) mostrou uma concentração de resíduos no intervalo $0 \pm 10\%$, comprovando a baixa presença de sub ou superestimativa.

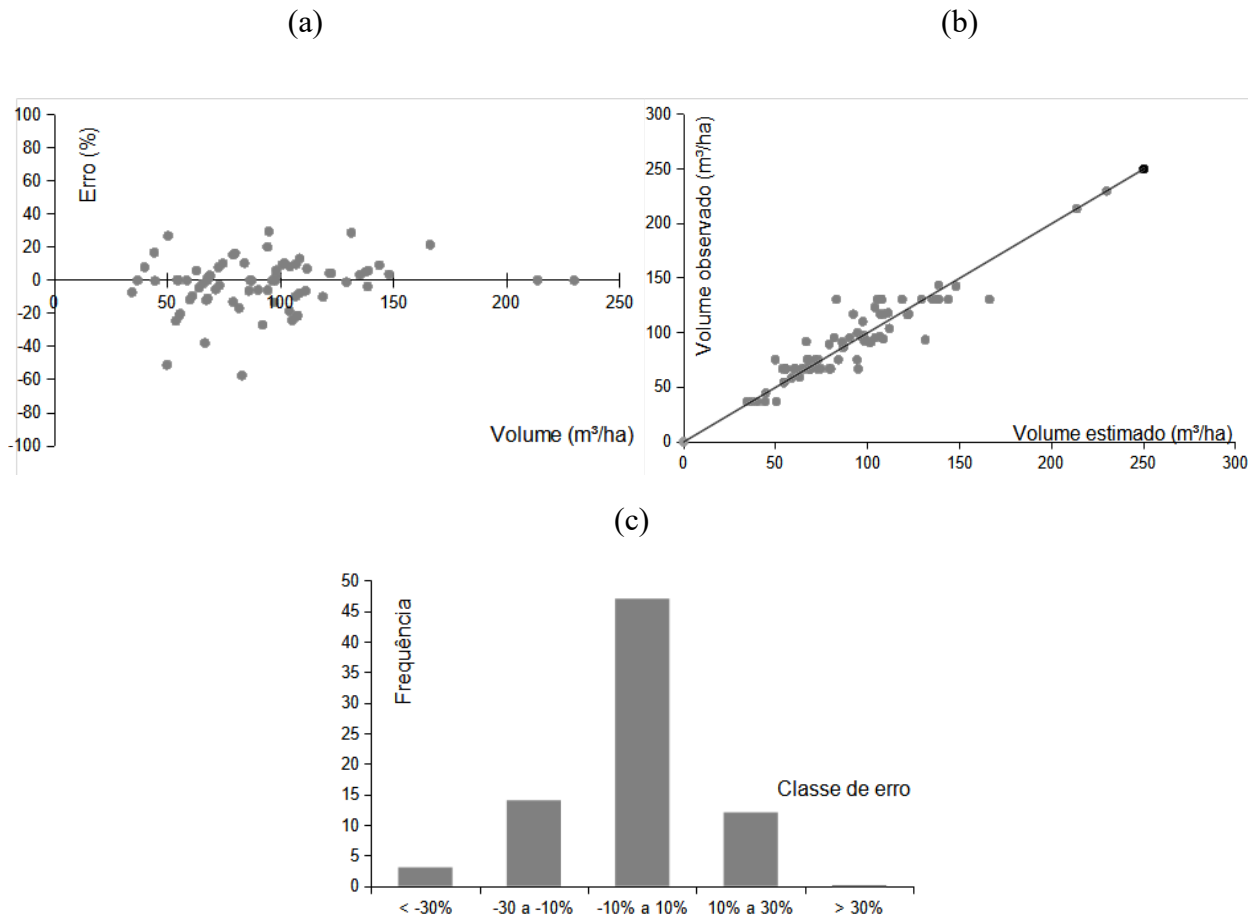


Figura 3. Análises gráficas dos resíduos da RNA 3 através da distribuição dos erros da estimativa (a), da correlação de volume estimado e observado (b) e do histograma da frequência dos erros (c) para os dados dos povoamentos de *Tectona grandis* no Pará, Brasil.

Fonte: Autor (2022).

O algoritmo quase-Newton desenvolvido por Broyden - Fletcher - Goldfarb - Shanno (BFGS) apresentou melhores resultados pela ferramenta IPS, em conformidade com outros trabalhos feitos, por sua capacidade de resolver problemas de otimização e previsão (GUERROUT et al., 2018). A arquitetura final da RNA selecionada foi 13-12-1, sendo treze neurônios preditores na camada de entrada, doze neurônios na camada oculta, ativada por uma função tanh, enquanto a camada de saída com um único neurônio (volume) foi ativada por uma função logística conforme esquema da Figura 4.

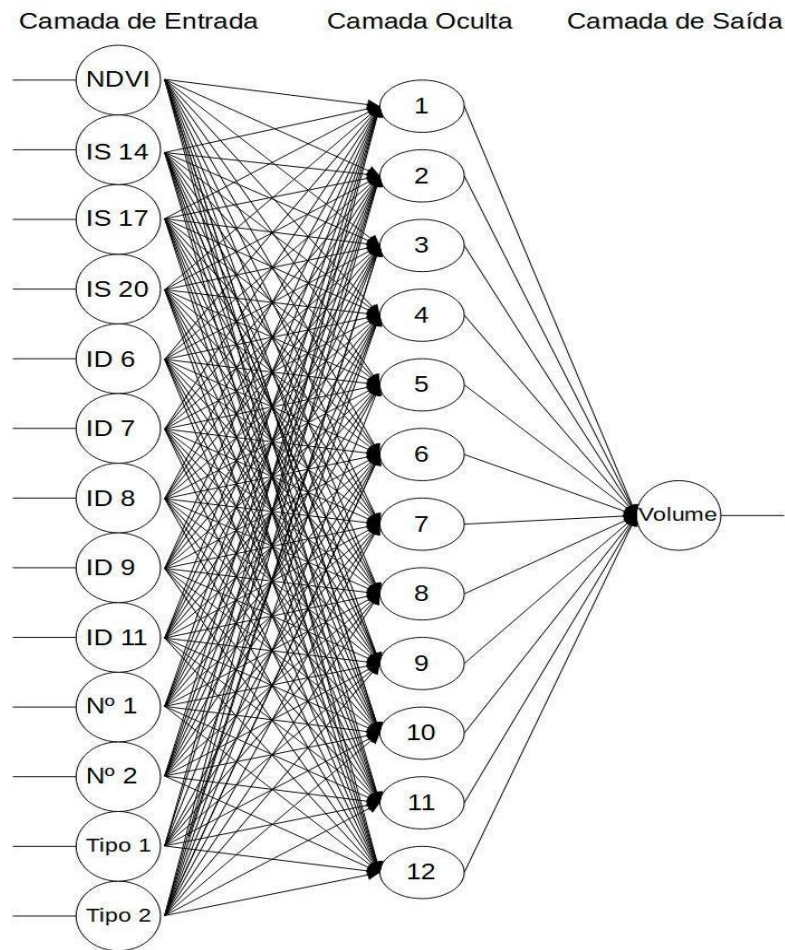


Figura 4. Arquitetura da RNA selecionada na configuração (13-12-1) para predição do volume dos povoamentos de teca no Pará, Brasil.

Onde: NDVI = índice de vegetação; IS = índice de sítio; ID = idade; Nº = quantidade de desbaste; Tipo = desbaste sistemático e seletivo.

Fonte: Autor (2022)

A partir dos resultados referentes as métricas estatísticas (Tabela 3) e na análise gráfica dos resíduos (Figura 3), observa-se que o uso de imagens de satélites, por meio dos índices de vegetação, concomitante de variáveis qualitativas na rede neural artificial apresentaram melhorias nas estimativas do volume de teca, o que se confirma em estudos de metodologia semelhante como em Leal et al. (2016) ou em Gonçalves (2021) em plantios de eucaliptos e florestas nativas respectivamente.

Por fim, o resultado do *test - t* demonstrou que a RNA selecionada tinha valores de p maior que $\alpha = 0,05$ ($p = 0,5962$), portanto não se verificou diferenças estatísticas significativas entre os valores preditos pelas redes neurais com os valores observados nas faixas de validação. No cálculo de AD%, superestimou-se em 4,59% em relação aos valores reais.

Contudo, destaca-se que os resultados deste estudo foram específicos para povoamentos

de *Tectona grandis*, em local e condições ambientais específicas. Com isso, novos estudos precisam ser desenvolvidos para esta espécie em condições e regimes de manejos distintos. Recomenda-se que novas formas de obtenção de dados, seja por outros índices de vegetação, seja por outros sensores remotos de melhor resolução espectral, espacial e temporal, possam ser testadas. Por fim, recomenda-se que sejam avaliados experimentos com outras configurações e outras arquiteturas, por exemplo, adicionado mais uma dimensão na variável independente.

6 CONCLUSÕES

Os modelos derivados de redes neurais artificiais combinados a dados de sensoriamento remoto foram eficazes e precisos para estimativas de volume de madeiras em plantações de *Tectona grandis* na área de estudo no estado do Pará.

Os índices de vegetação derivados de imagens do satélite Sentinel-2, sensor MSI, em conjunto com variáveis qualitativas do povoamento florestal contribuíram para estimativas eficazes e consistentes do volume do plantio de *Tectona grandis*.

As redes neurais artificiais do tipo Multi-layer Perceptron, utilizando funções de ativação sigmoidal e o algoritmo BFGS para treinamento, demonstraram precisão na estimativa do volume comercial de Teca.

Os resultados obtidos nesta pesquisa contribuem positivamente na criação de uma alternativa de gestão e manejo, uma vez que propiciam informações precisas e de fácil obtenção em áreas de grande dimensão territorial ou até mesmo em áreas de difícil acesso.

7 REFERÊNCIAS BIBLIOGRÁFICAS

- ALCÂNTARA, A.E.M. de. Redes neurais artificiais para prognose do crescimento e da produção de povoamentos de eucalipto em Minas Gerais. 2015.
- ALMEIDA, M.P. de. Predição da altura de *Tectona grandis* Linn F. por meio de modelos genéricos e redes neurais artificiais. 2020. 55 f., il. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Florestal) — Universidade de Brasília, Brasília, 2020.
- ALVARES, C. A. et al. Köppen's climate classification map for Brazil. *Meteorologische Zeitschrift*, v. 22, n. 6, p. 711–728, 2013.
- ALVES, M.V.G. et al. Aplicação de k-nearest neighbor em imagens multispectrais para a estimativa de parâmetros florestais. *Floresta*, v. 43, n. 3, p. 351-362, 2013.
- ARCOVERDE, G.F.B. et al. Identificação de áreas prioritárias para recuperação florestal com o uso de rede neural de mapas auto-organizáveis. *Boletim de Ciências Geodésicas*, v. 17, p. 379-400, 2011.
- BARROS, B.S.X. de, GUERRA, S.P.S., BARROS, Z.X. de, CATITA, C.M.S. e FERNANDES, J.C.C.C. 2015. Uso de imagens de satélite para cálculo de volume em floresta de eucalipto no Município de Botucatu/SP. *Energia na Agricultura*, v. 30, n. 1, p. 60-67, 2015.
- BERRA, E. F. et al. Estimativa do volume total de madeira em espécies de eucalipto a partir de imagens de satélite Landsat. *Ciência Florestal*, v. 22, n. 4, p. 853-864, 2012.
- BEZERRA, A. F. Modelagem do crescimento e da produção de povoamentos de *Tectona grandis* submetidos a desbaste. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa – MG, p. 73, 2009.
- BORATTO, I. M. P.; GOMIDE, R. L. Aplicação dos índices de vegetação NDVI, SAVI e IAF na caracterização da cobertura vegetativa da região Norte de Minas Gerais. In: Embrapa Milho e Sorgo-Artigo em anais de congresso (ALICE). In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16., 2013, Foz do Iguaçu. Anais... São José dos Campos: INPE, 2013. p. 7345-7352., 2013.
- CAMPOS, J. C. C.; LEITE, H. G. Mensuração florestal: perguntas e respostas. 4. ed. **Viçosa: Editora UFV**, 2013. 407 p
- 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.

- CARRIJO, J.V.N. et al. The growth and production modeling of individual trees of *Eucalyptus urophylla* plantations. **Journal of Forestry Research**, v. 31, n. 5, p. 1663–1672, 2020.
- CASTRO, L.N. de; FERRARI, D.G. Introdução à mineração de dados: conceitos básicos, algoritmos e aplicações. **São Paulo: Saraiva**, v. 5, 2016.
- CHOW, T.W.; CHO, D.S. Neural networks and computing: Learning algorithms and applications. **World Scientific**, 2007.
- DAVIS, L.S.; JOHNSON, K. N. Forest Management. 3. ed. New York: McGraw-Hill Book, 1987. 790 p.
- DEERING, D. W. Rangeland reflectance characteristics measured by aircraft and spacecraft sensors. 338 f. Dissertation (Ph. D) – Texas A&M University, College Station, TX, 1978.
- ELMASRI, R.; NAVATHE, S.B. Sistemas de banco de dados / Ramez Elmasri, Shamkant B. Navathe; tradução Daniel Vieira; revisão técnica Enzo Seraphim, Thatyana de Faria Piola Seraphim. - 7. ed - São Paulo: Pearson Education do Brasil, 2018.
- EMBRAPA TERRITORIAL. Satélites de Monitoramento. Campinas, 2018.
- EPIPHANIO, J. C. N.; GLERIANI, J. M.; FORMAGGIO, A. R.; RUDORFF, B. F. T. Índices de vegetação no sensoriamento remoto da cultura do feijão. **Pesquisa agropecuária brasileira**, Brasília, v. 31, n. 6, p. 445-454, 1996.
- EUROPEAN SPACE AGENCY (Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services (ESA SP-1322/2 March 2012)), 2012.
- EUROPEAN SPACE AGENCY Sentinel-2 User Handbook Document. Technical Report issue 1 revision 2.: European Space Agency, 2015.
- FIGUEIREDO, E. O.; OLIVEIRA, A. D. de; BARBOSA, L. K. F. Teca (*Tectona grandis* L.f.): principais perguntas do futuro empreendedor florestal. **Rio Branco: Embrapa Acre**, 2005. 87 p. (Embrapa Acre. Documentos, 97).
- FLORESTAL, C. Manual do cultivo da teca, 2017.
- FREITAS, W. K. D., MAGALHÃES, L. M. S. Métodos e parâmetros para estudo da vegetação com ênfase no estrato arbóreo. **Floresta e Ambiente**, 19(4), 520-539, 2012.
- GONÇALVES, F.C. 2021. Predição volumétrica utilizando redes neurais artificiais e dados de sensoriamento remoto em floresta nativa na Amazônia brasileira. Dissertação de Mestrado em Ciências Florestais, Publicação Programa de Pós-graduação em Ciências Florestais Departamento de Engenharia Florestal, Universidade de Brasília, Brasília, DF. 64 p.
- GONÇALVES, W.G. et al. Classificação de estratos florestais utilizando redes neurais artificiais e dados de sensoriamento remoto. **Revista Ambiente & Água**, v. 11, p. 612-624, 2016.

- GUERROUT, E. H.; AIT-AOUDIA, S.; MICHELUCCI, D.; MAHIOU, R. Hidden Markov random field model and Broyden–Fletcher–Goldfarb–Shanno algorithm for brain image segmentation. **Journal of Experimental and Theoretical Artificial Intelligence**, v. 30, n. 3, p. 415–427, 2018.
- HAYKIN, S. *Redes Neurais: Princípios e prática*. 2a ed. Hamilton: Bookman. 900 p, 2001.
- HUETE, A. R. A soil-adjust vegetation index (Savi). *Remote Sensing of Environment*, v. 25, p. 295–309, 1988.
- HINKLE, D. E., et al. *Applied statistics for the behavioral sciences*. Cengage Learning, Boston: [s. n.], v. 5, p. 756, 2003.
- IBGE. *Manual Técnico da Vegetação Brasileira 2a edição*. 2012.
- JIANG, Z. et al. Development of a two-band enhanced vegetation index without a blue band. *Remote Sensing of Environment*, v. 112, p. 3833-3845, 2008.
- JUNIOR, L.F.M.C. *Reconhecimento Facial Utilizando Redes Neurais*. 2011.
- KERSKI, J. J. Geo-awareness, Geo-enablement, Geotechnologies, Citizen Science, and Storytelling: Geography on the World Stage. *Geography Compass*, v. 9, n. 1, p. 14-26, 2015.
- KOLLERT, W.; KLEINE, M. *The Global Teak Study: Analysis, Evaluation and Future Potential of Teak Resources*. 2017.
- KOLLERT, W.; WALOTEK, P.. *Global teak trade in the aftermath of Myanmar’s log export ban*. FAO Planted Forests and Trees Working Paper FP/47/E, Roma, Italia, 2015.
- KUSBACH, A. et al. Site-specific approach to growth assessment and cultivation of teak (*Tectona grandis*) in Nicaraguan dry tropics. **Forest Ecology and Management**, v. 480, 2021.
- LEAL, F.A. et al. Índice de vegetação na estimativa do volume em um povoamento de eucalipto. **Enciclopédia Biosfera**, v. 9, n. 17, 2013.
- LEAL, F.A. *Técnicas de sensoriamento remoto e geoestatística aplicadas em um povoamento de Eucalyptus urophylla S. T. Blake para estimativa de volume*. 2013. 96 f., il. Dissertação (Mestrado em Ciências Florestais)—Universidade de Brasília, Brasília, 2013.
- LEAL, F.A. et. al. Redes neurais artificiais na estimativa de volume em um plantio de eucalipto em função de fotografias hemisféricas e número de árvores. **Revista Brasileira de Biometria**, v. 33, n. 2, p. 233-249, 2015.
- LEAL, F.A.; MIGUEL, E.P.; MATRICARDI, E.A.T. Estimativa do volume em um povoamento de eucalipto utilizando redes neurais artificiais e dados provenientes do satélite RapidEye. **3 MensuFlor**, 2016.

- LOBO, L. C. Inteligência artificial e medicina. **Revista Brasileira de Educação Médica**, v. 41, n. 2, p. 185-193, 2017.
- LIU, H. Q., HUETE, A. A feedback based modification of the NDVI to minimize canopy background and atmospheric noise. **IEEE Transactions on Geoscience and Remote Sensing**, v 33 n. 2, p. 457-465, 1995.
- MACHADO, S. DO A.; FIGUEIREDO FILHO, A. **Dendrometria**. Guarapuava: UNICENTRO, 2014.
- MACEDO, F.L. et al. Estimativa do volume de madeira para Eucalyptus sp. Com imagens de satélite de alta resolução espacial. **Scientia Forestalis/Forest Sciences**, v. 45, n. 114, 2017.
- MACEDO, R.L.G. et al. Desenvolvimento inicial de Tectona grandis Lf (teca) em diferentes espaçamentos no município de Paracatu, MG. **Cerne**, v. 11, n. 1, p. 61-69, 2005.
- MENDONÇA, A. R. D. et al.. Modelos hipsométricos tradicionais e genéricos para Pinus caribaea var. hondurensis. **Pesquisa florestal brasileira**, Colombo, v. 35, n. 81, p. 47-54, jan. 2015.
- MIDGLEY, S. et al.. Global market for plantation teak; implications for growers in Lao PDR. **ACIAR: Australian Centre for International Agricultural Research**: Canberra, p. 75, 2015.
- 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, 2015.
- MIGUEL, E. P.; MELO, R. R. DE; SERENINI JUNIOR, L.; DEL MENEZZI, C. H. S. Using artificial neural networks in estimating wood resistance. **Maderas. Ciencia y tecnología**, v. 20, n. 4, 2018.
- MITCHELL, T. M. 1997. Machine Learning. McGraw Hill, New York, NY. MORAES, E. C. de. Capítulo 1 fundamentos de sensoriamento remoto. 2002.
- NASCIMENTO, M. C. do et al. Mapeamento dos fragmentos de vegetação florestal nativa da bacia hidrográfica do Rio Alegre, Espírito Santo, a partir de imagens do satélite IKONOS II. **Revista Árvore**, v. 30, n. 3, p. 389-398, 2006.
- NEWBY, J. C.; CRAMB, R. A.; SAKANPHET, S.; McNAMARA, S. Small holder teak and agrarian change in Northern Laos. **Small-scale Forestry**, v. 11, p. 27-46, 2012.
- PACHECO, N. A.; BASTOS, T. X. Caracterização climática do município de Capitão Poço-PA. **Embrapa Amazônia Oriental-Documentos (INFOTECA-E)**, 2001.
- PALANISAMY, K.; HEGDE, M.; YI, J. Teak (Tectona grandis Linn. f.): A renowned

- commercial timber species. **Journal of Forest and Environmental Science**, v. 25, n. 1, p. 1-24, 2009.
- PANDEY, D.; BROWN, C.. Teak: a global overview. **Unasyuva-FAO-**, v. 51, n. 201, p. 3-12, 2000
- PELISSARI, A. L. et al.. Cultivo da teca: características da espécie para implantação e condução de povoamentos florestais. **Agrarian Academy**, Goiânia, v. 1, n. 1, p. 127-146, abr./2014.
- PONZONI, F.J. Comportamento espectral da vegetação. In: MENESES, P.R.; MADEIRA NETTO, J. da S. (Ed.). Sensoriamento remoto: reflectância dos alvos naturais. Brasília: Ed. da UnB, Planaltina: Embrapa Cerrados; 2001. p.157-199.
- QI, J. et al. A modified soil adjusted vegetation index. **Remote sensing of environment**, v. 48, n. 2, p. 119-126, 1994.
- QUARTAROLI, C. F.; VICENTE, L. E.; ARAÚJO, L.S. de. Sensoriamento remoto. Embrapa Monitoramento por Satélite-Capítulo em livro técnico-científico (ALICE), 2014.
- RIBEIRO, C.V. et al. Modelos Volumétricos para *Tectona grandis* L. f. no Distrito Federal. **Enciclopédia Biosfera**, v. 16, n. 29, 2019.
- ROSENDO, J. dos S. Índices de vegetação e monitoramento do uso do solo e cobertura vegetal na bacia do rio Araguari-MG-utilizando dados do sensor Modis. Uberlândia: Universidade Federal de Uberlândia, 2005.
- SANTOS, H.G. dos et al. **Sistema brasileiro de classificação de solos**. Brasília, DF: Embrapa, 2018
- SANTOS, M. M., MACHADO, I. E. S., CARVALHO, E. V., VIOLA, M. R., GIONGO, M. Estimativa de parâmetros florestais em área de cerrado a partir de imagens do sensor Landsat-8. *Floresta*, 47(1), 75-84, 2017.
- SILVA, E. T. J. B. Utilização dos índices de Vegetação do Sensor MODIS para Detecção de Desmatamentos no Cerrado: Investigação de Parâmetros e Estratégias. 2004, 146 f. Dissertação (Mestrado em Geologia) – Universidade de Brasília, Brasília, 2004.
- 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, 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. 2021. 112 f., il. Dissertação (Mestrado em Ciências Florestais) — Universidade de Brasília, Brasília, 2021.
- STUART, R.; PETER, N. Artificial intelligence-a modern approach 3rd ed. 2016.

- TEWARI, V. P.; MARISWAMY, K. M.; ARUNKUMAR, A. N. Total and Merchantable Volume Equations for *Tectona grandis* Linn. f. Plantations in Karnataka, India. **Journal of Sustainable Forestry**, v. 32, n. 3, p. 213–229, 2013.
- VENDRUSCOLO, Diogo et al. Modelos volumétricos para teca em diferentes espaçamentos em Cáceres, Mato Grosso. **Enciclopédia Biosfera**, v. 10, n. 19, 2014.
- VENDRUSCOLO, Diogo Guido Streck et al. Estimativa da altura de árvores de *Tectona grandis* Lf utilizando regressão e redes neurais artificiais. **Nativa**, v. 5, n. 1, p. 52-58, 2017.
- 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, 2018.