

UNIVERSIDADE FEDERAL DE VIÇOSA

Avaliação do sequestro de carbono em plantios de macaúba (*Acrocomia aculeata*) através de dados LIDAR e imagens multiespectrais

Débora Nascimento Rosario
Magister Scientiae

**VIÇOSA - MINAS GERAIS
2025**

DÉBORA NASCIMENTO ROSARIO

Avaliação do sequestro de carbono em plantios de macaúba (*Acrocomia aculeata*) através de dados LIDAR e imagens multiespectrais

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Meteorologia Aplicada, para obtenção do título de *Magister Scientiae*.

Orientadora: Hewlley M. A. Imbuzeiro

**VIÇOSA - MINAS GERAIS
2025**

**Ficha catalográfica elaborada pela Biblioteca Central da Universidade
Federal de Viçosa - Campus Viçosa**

T

R789a
2025

Rosário, Débora Nascimento, 1995-

Avaliação do sequestro de carbono em plantios de macaúba (*Acrocomia aculeata*) através de dados LiDAR e imagens multiespectrais / Débora Nascimento Rosário. – Viçosa, MG, 2025.

1 dissertação eletrônica (77 f.): il. (algumas color.).

Orientador: Hewlley Maria Acioli Imbuzeiro.

Dissertação (mestrado) - Universidade Federal de Viçosa, Departamento de Engenharia Agrícola, 2025.

Referências bibliográficas: f. 75-77.

DOI: <https://doi.org/10.47328/ufvbbt.2025.670>

Modo de acesso: World Wide Web.

1. Macaúba - Cultivo - Sensoriamento remoto. 2. Sequestro de carbono. 3. Imagens multiespectrais. I. Imbuzeiro, Hewlley Maria Acioli, 1980-. II. Universidade Federal de Viçosa. Departamento de Engenharia Agrícola. Programa de Pós-Graduação em Meteorologia Aplicada. III. Título.

CDD 22. ed. 6333.851

DÉBORA NASCIMENTO ROSARIO

Avaliação do sequestro de carbono em plantios de macaúba (*Acrocomia aculeata*) através de dados LIDAR e imagens multiespectrais

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Meteorologia Aplicada, para obtenção do título de *Magister Scientiae*.

APROVADA: 18 de julho de 2025.

Assentimento:

Débora Nascimento Rosario
Autora

Hewlley Maria Acioli Imbuzeiro
Orientadora

Essa dissertação foi assinada digitalmente pela autora em 16/10/2025 às 16:50:03 e pela orientadora em 17/10/2025 às 14:42:05. As assinaturas têm validade legal, conforme o disposto na Medida Provisória 2.200-2/2001 e na Resolução nº 37/2012 do CONARQ. Para conferir a autenticidade, acesse <https://siadoc.ufv.br/validar-documento>. No campo 'Código de registro', informe o código **FXKK.BGWZ.SH3R** e clique no botão 'Validar documento'.

Aos meus pais, irmãos, amigos e Deus

AGRADECIMENTOS

Aos meus pais, Cida e Laercio, por todo o amor, apoio e confiança incondicional em cada decisão que tomei. Nada seria possível sem o exemplo de força, dedicação e carinho que sempre me deram.

Aos meus irmãos, Luciana, Victor e Júnior, por serem as pessoas mais especiais da minha vida, meu alicerce, minhas risadas e minha inspiração diária.

Às minhas amigas e amigos, em especial Luna, Clarissa e Carine, pela presença constante, pelas palavras de incentivo e por compartilharem comigo não só os momentos difíceis, mas também as alegrias e conquistas ao longo desse caminho. Ao colega Heitor Filpi, por toda a parceria, apoio e incentivo durante o desenvolvimento deste trabalho. A caminhada foi mais leve e produtiva com a sua colaboração.

À professora Hewlley, pela orientação, confiança e oportunidade de fazer parte deste projeto, que tanto contribuiu para o meu aprendizado pessoal e profissional.

À Universidade Federal de Viçosa, pela oportunidade de realizar a pós-graduação e por todo o conhecimento e experiências proporcionadas ao longo dessa trajetória.

Este trabalho foi realizado com o apoio das seguintes agências de pesquisa brasileiras: Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001, Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) e Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

“Aprender é a única coisa que a mente nunca se cansa, nunca tem medo e nunca se
arrepende”.
(Leonardo da Vinci)

RESUMO

ROSARIO, Débora Nascimento, M.Sc., Universidade Federal de Viçosa, julho de 2025. **Avaliação do sequestro de carbono em plantios de macaúba (*Acrocomia aculeata*) através de dados LIDAR e imagens multiespectrais.** Orientadora: Hewlley Maria Acioli Imbuzeiro.

A Macaúba (*Acrocomia aculeata*) destaca-se como um recurso valioso no combate às mudanças climáticas devido ao seu elevado potencial de sequestro de carbono (absorção de dióxido de carbono atmosférico). Essa característica permite que a espécie desempenhe um papel crucial na mitigação das mudanças climáticas e na geração de créditos de carbono em âmbito internacional. No entanto, a ausência de métodos práticos e modernos para monitorar o incremento de biomassa e o armazenamento de carbono na Macaúba dificulta a gestão sustentável desses recursos naturais. A melhoria na obtenção desses dados é essencial para impulsionar o desenvolvimento econômico nas regiões onde a Macaúba ocorre. Neste contexto, o presente trabalho teve como objetivo implementar um método em larga escala para integrar dados LiDAR aerotransportado com imagens de satélite multiespectrais e, assim, estimar o estoque de carbono em sistemas integrados de produção com Macaúba, localizados na Fazenda Espelho, no município de João Pinheiro, e na estação experimental de Araponga, ambos em Minas Gerais, Brasil. O modelo de melhor desempenho foi extrapolado para diferentes anos e áreas, com o objetivo de avaliar o crescimento da cultura e o aumento da biomassa e do carbono estocado pela Macaúba ao longo do tempo. Os modelos de aprendizado de máquina (machine learning) baseados em satélite Landsat apresentaram os melhores desempenhos preditivos na fase de treinamento, com coeficientes de determinação e (R^2) superiores a 0,93 e erros absolutos baixos tanto para a biomassa (RMSE = 5,07 t/ha e MAE = 3,35 t/ha) quanto para o carbono (RMSE = 2,89 t/ha e MAE = 1,93 t/ha). Embora tenha ocorrido uma leve redução de desempenho na validação, esses modelos ainda superaram os demais, obtendo métricas de validação superiores (biomassa: R^2 = 0,73, RMSE = 11,09 t/ha e MAE = 7,19 t/ha; carbono: R^2 = 0,71, RMSE = 6,37 t/ha e MAE = 4,13 t/ha). Em contraste, os modelos baseados em redes neurais artificiais apresentaram desempenho inferior, com R^2 entre 0,70 e 0,81, apesar de exibirem maior estabilidade entre as fases de treinamento e validação. Esses resultados reforçam a viabilidade de aplicação prática do método desenvolvido para monitoramento de carbono.

Palavras-chave: Macaúba; Sensoriamento remoto; Estoque de carbono

ABSTRACT

ROSARIO, Débora Nascimento, M.Sc., Universidade Federal de Viçosa, July, 2025.
Evaluating carbon sequestration in macaúba (*Acrocomia aculeata*) plantations using LIDAR and multispectral imagery. Adviser: Hewlley Maria Acioli Imbuzeiro.

The Macaúba stands as a significant asset in the fight against climate change, owing to its remarkable capacity to absorb atmospheric carbon dioxide and its consequential carbon sequestration potential. This attribute holds immense promise in mitigating climate change impacts and fostering the generation of carbon credits within the international market. However, the absence of practical and contemporary methodologies for monitoring Macaúba's biomass increase and carbon storage has impeded the sustainable management of these natural resources. Enhancing the acquisition of such data is imperative to catalyze the economic development of regions where the Macaúba thrives. In this context, this study aimed to implement a large-scale method that integrates airborne LiDAR data with multispectral satellite imagery to estimate carbon stocks in integrated Macaúba production systems, located at Fazenda Espelho in João Pinheiro and the Araponga experimental station, both in Minas Gerais, Brazil. The trained model was extrapolated to different years and regions to evaluate the growth, biomass accumulation, and carbon storage of Macaúba. Among the tested models, those based on machine learning using Landsat satellite imagery demonstrated the highest predictive performance during training, with R^2 values exceeding 0,93 and lower error rates for both biomass (RMSE = 5,07 t/ha; MAE = 3,35 t/ha) and carbon (RMSE = 2,89 t/ha; MAE = 1,93 t/ha). Although performance declined slightly during validation, these models still outperformed the others (biomass: R^2 = 0,73, RMSE = 11,09 t/ha, MAE = 7,19 t/ha; carbon: R^2 = 0,71, RMSE = 6,37 t/ha, MAE = 4,13 t/ha). Neural network-based models showed comparatively lower accuracy, with R^2 values ranging from 0,70 to 0,81, though their performance was more consistent across training and validation phases.

Keywords: Macaúba; Remote sensing; Carbon stock; Dissertation

LISTA DE ILUSTRAÇÕES

Figura 1 – Localização da Fazenda Espelho, no município de João Pinheiro.	16
Figura 2 – Climatologia de João Pinheiro do período de 1994 a 2024.....	17
Figura 3 – Localização dos talhões de cultivo de Macaúba na Estação Experimental do município de Araponga.....	18
Figura 4 – Normal Climatológica de Araponga, do período de 1991 a 2021.....	19
Figura 5 – Talhões de cultivo de <i>Acrocomia aculeata</i> selecionados para coleta de dados LiDAR.	20
Figura 6 – Talhões de cultivo de <i>Acrocomia aculeata</i> selecionados em Araponga...	22
Figura 7 – Acúmulo de biomassa em função da altura total em palmeiras de Macaúba.	24
Figura 8 – Acúmulo de carbono em função da altura total em palmeiras de Macaúba.	24
Figura 9 – Fluxograma com o processamento da nuvem de pontos.....	25
Figura 10 – Exemplo de reamostragem dos pixels com resolução 5x5m para 10x10m, utilizando a metodologia de agregação por soma.	28
Figura 11 – Exemplo de reamostragem dos pixels com resolução 5x5m para 30x30m, utilizando a metodologia de agregação por soma.	28
Figura 12 – Fluxograma geral do processo de modelagem preditiva.....	32
Figura 13 – Modelo de altura do dossel para os talhões selecionados de Macaúba – Talhões 16, 17, 27 e 32.....	34
Figura 14 – Modelo de altura do dossel para os talhões selecionados de Macaúba – Talhões 1, 2 e 3.....	35
Figura 15 – Biomassa obtida a partir do CHM com resolução 5x5m e reamostragem para 10x10m (Sentinel) e 30x30m (Landsat) dos talhões 16, 17, 27 e 32.	37
Figura 16 – Biomassa obtida a partir do CHM com resolução 5x5m e reamostragem para 10x10m (Sentinel) e 30x30m (Landsat) dos talhões 1, 2 e 3.	38
Figura 17 – Carbono obtida a partir do CHM com resolução 5x5m e reamostragem para 10x10m (Sentinel) e 30x30m (Landsat) dos talhões 16, 17, 27 e 32.	39

Figura 18 – Carbono obtida a partir do CHM com resolução 5x5m e reamostragem para 10x10m (Sentinel) e 30x30m (Landsat) dos talhões 1, 2 e 3.	40
Figura 19 – Aplicação do modelo Landsat MLRF para a obtenção de biomassa estocada entre 2016 e 2024 nos talhões de Macaúba da Fazenda Espelho, João Pinheiro – MG.....	57
Figura 20 – Aplicação do modelo Landsat DLRN para a obtenção de biomassa estocada entre 2016 e 2024 nos talhões de Macaúba da Fazenda Espelho, João Pinheiro – MG.....	58
Figura 21 – Aplicação do modelo Landsat MLRF para a obtenção de carbono acumulado entre 2016 e 2024 nos talhões de Macaúba da Fazenda Espelho, João Pinheiro – MG.....	59
Figura 22 – Aplicação do modelo Landsat DLRN para a obtenção de carbono acumulado entre 2016 e 2024 nos talhões de Macaúba da Fazenda Espelho, João Pinheiro – MG.....	60
Figura 23 – Aplicação do modelo Landsat MLRF para a obtenção de biomassa estocada entre 2011 e 2024 nos talhões de Macaúba da área experimental de Araponga – MG.	61
Figura 24 – Aplicação do modelo Landsat DLRN para a obtenção de biomassa estocada entre 2011 e 2024 nos talhões de Macaúba da área experimental de Araponga – MG.	62
Figura 25 – Aplicação do modelo Landsat MLRF para a obtenção de carbono acumulado entre 2011 e 2024 nos talhões de Macaúba da área experimental de Araponga – MG.....	63
Figura 26 – Aplicação do modelo Landsat DLRN para a obtenção de carbono acumulado entre 2011 e 2024 nos talhões de Macaúba da área experimental de Araponga – MG.....	64
Figura 27 – Incremento anual de biomassa em plantio de Macaúba da Fazenda Espelho, João Pinheiro.....	66
Figura 28 – Incremento anual de biomassa em plantio de Macaúba ao sul da Fazenda Espelho, João Pinheiro.....	67
Figura 29 – Incremento anual de carbono em plantio de Macaúba da Fazenda Espelho, João Pinheiro.....	68

Figura 30 – Incremento anual de carbono em plantio de Macaúba ao sul da Fazenda Espelho, João Pinheiro.....	69
Figura 31 – Curva de acúmulo de carbono em plantas de Macaúba para um ciclo comercial de 360 meses (30 anos).....	70
Figura 32 – Taxa anual de acumulação de carbono em palmeiras de Macaúba (A. aculeata) (linha contínua) e produtividade média de carbono por planta (linha pontilhada).	70
Figura 33 – Incremento anual de biomassa nos talhões de Macaúba da área experimental de Araponga.	72
Figura 34 – Incremento anual de carbono nos talhões de Macaúba da área experimental de Araponga.	73
Gráfico 1 – Relação entre a Biomassa observada e predita pelo algoritmo gerado pela técnica Random Forest, sensores Landsat, nas fases de treinamento e de validação.	42
Gráfico 2 – Relação entre a Biomassa observada e predita pelo algoritmo gerado pela técnica Random Forest, sensores Sentinel, nas fases de treinamento e de validação.	42
Gráfico 3 – Relação entre a Biomassa observada e predita pelo algoritmo gerado pela técnica Rede Neural Artificial simples, sensores Landsat, nas fases de treinamento e de validação.	43
Gráfico 4 – Relação entre a Biomassa observada e predita pelo algoritmo gerado pela técnica Rede Neural Artificial simples, sensores Sentinel, nas fases de treinamento e de validação.	43
Gráfico 5 – Relação entre a Carbono observada e predita pelo algoritmo gerado pela técnica Random Forest, sensores Landsat, nas fases de treinamento e de validação.	45
Gráfico 6 – Relação entre a Carbono observada e predita pelo algoritmo gerado pela técnica Random Forest, sensores Sentinel, nas fases de treinamento e de validação.	45
Gráfico 7 – Relação entre a Carbono observada e predita pelo algoritmo gerado pela técnica Rede Neural Artificial simples, sensores Landsat, nas fases de treinamento e de validação.	46

Gráfico 8 – Relação entre a Carbono observada e predita pelo algoritmo gerado pela técnica Rede Neural Artificial simples, sensores Sentinel, nas fases de treinamento e de validação.	46
Gráfico 9 – Classificação das cinco variáveis quanto a sua importância no cálculo de Biomassa pelo método Random Forest utilizando os sensores Landsat.	48
Gráfico 10 – Classificação das cinco variáveis quanto a sua importância no cálculo de Biomassa pelo método Random Forest utilizando os sensores Sentinel.	48
Gráfico 11 – Classificação das cinco variáveis quanto a sua importância no cálculo de Biomassa pelo método Rede Neural Artificial simples utilizando os sensores Landsat.....	49
Gráfico 12 – Classificação das cinco variáveis quanto a sua importância no cálculo de Biomassa pelo método Rede Neural Artificial simples utilizando os sensores Sentinel.	49
Gráfico 13 – Classificação das cinco variáveis quanto a sua importância no cálculo de Carbono pelo método Random Forest utilizando os sensores Landsat. ...	50
Gráfico 14 – Classificação das cinco variáveis quanto a sua importância no cálculo de Carbono pelo método Random Forest utilizando os sensores Sentinel. ...	50
Gráfico 15 – Classificação das cinco variáveis quanto a sua importância no cálculo de Carbono pelo método Rede Neural Artificial simples utilizando os sensores Landsat.....	51
Gráfico 16 – Classificação das cinco variáveis quanto a sua importância no cálculo de Carbono pelo método Rede Neural Artificial simples utilizando os sensores Sentinel.	51

LISTA DE TABELAS

Tabela 1 – Características dos talhões de Macaúba selecionados para coleta de dados LiDAR.	20
Tabela 2 – Características dos talhões de Macaúba na Área Experimental de Araponga – MG.	21
Tabela 3 – Resumo comparativo entre os índices calculados.....	27
Tabela 4 – Importância das variáveis nos modelos de Biomassa.	52
Tabela 5 – Importância das variáveis nos modelos de Carbono.	53
Tabela 6 – Métricas do modelo de Biomassa.....	54
Tabela 7 – Métricas do modelo de Carbono.....	55

SUMÁRIO

1 INTRODUÇÃO	14
2 MATERIAIS E MÉTODOS	16
2.1 Áreas de estudo.....	16
2.2 Base de dados.....	19
2.2.1 Seleção dos talhões de cultivo de macaúba	19
2.2.2 Processamento da nuvem de pontos e cálculo de biomassa e carbono por indivíduo.....	22
2.2.3 Processamento das Imagens de Satélite e cálculo dos índices utilizados	25
2.3 Modelagem.....	27
2.3.1 Integração dos Dados	27
2.3.2 Desenvolvimento dos modelos preditivos	28
2.3.3 Avaliação dos Modelos	30
2.4 Aplicação do modelo: crescimento e incremento de biomassa e carbono estocado da Macaúba em diferentes regiões de Minas Gerais	31
3 RESULTADOS E DISCUSSÃO	33
3.1 PROCESSAMENTO DA NUVEM DE PONTOS	33
3.1.1 Modelo de Altura do Dossel – CHM	33
3.1.2 Biomassa e carbono por indivíduo	36
3.2 TREINAMENTO E VALIDAÇÃO DOS MODELOS	40
3.2.1 Desempenho dos modelos.....	40
3.2.2 Importância das variáveis.....	47
3.2.3 Comparação entre sensores	53
3.3 Avaliação do crescimento e incremento de biomassa e carbono estocado da Macaúba em diferentes regiões de Minas Gerais	56
3.3.1 Incremento de biomassa e carbono	64
4 CONCLUSÕES.....	74
REFERÊNCIAS.....	75

1 INTRODUÇÃO

O Cerrado, o segundo maior bioma brasileiro, desempenha um papel crucial na conservação da biodiversidade e é reconhecido como um “*hotspot*” prioritário de conservação. A adoção de estratégias voltadas à conservação e ao cultivo de espécies nativas, assim como o desenvolvimento de métodos para avaliar as condições de cobertura do solo, são fundamentais para manter os serviços ecossistêmicos deste bioma (Colman *et al.*, 2024; Strassburg *et al.*, 2017).

Dentre as espécies nativas, destaca-se a *Acrocomia aculeata* (Jacq.) Lodd. ex Mart., popularmente conhecida como Macaúba, uma palmeira amplamente distribuída no território brasileiro. Essa espécie apresenta elevada resiliência a condições adversas, como secas e queimadas, sendo adaptada a regiões com precipitação anual entre 400 e 2500 mm e tolerância a déficit hídricos acumulados de até -1400 mm (Benezoli; Imbuzeiro; Abrahão, 2017).

A Macaúba representa uma importante fonte de renda, alimento e insumos medicinais para as comunidades locais, por meio do extrativismo (Favaro; Guiducci, 2023). Seus frutos, folhas, caule e outras estruturas podem originar diversos produtos com potencial econômico e ambiental relevante (Motoike *et al.*, 2013). O óleo extraído dos frutos, por exemplo, pode ser utilizado tanto na produção de biocombustíveis sustentáveis quanto na formulação de cosméticos de alto valor agregado.

Além dos benefícios sociais e econômicos, a Macaúba se destaca por seu potencial de sequestro de CO₂ atmosférico, devido à sua elevada capacidade de alocar carbono, o que pode contribuir para a mitigação das mudanças climáticas e para a geração de créditos de carbono no mercado internacional, conforme previsto no Art. 6º do Acordo de Paris (Favaro; Guiducci, 2023; Moreira *et al.*, 2020). No entanto, a mensuração do crescimento da Macaúba, bem como a quantificação precisa do seu estoque de carbono e biomassa, é realizada atualmente a partir de métodos tradicionais de inventário florestal, que possui uma logística complexa e demanda levantamentos de campo recorrentes. Isso dificulta o monitoramento periódico do crescimento e acúmulo de biomassa nos plantios, que são informações fundamentais para entender o comportamento da Macaúba em diferentes escalas temporais e espaciais.

Tradicionalmente, a quantificação da biomassa baseia-se em métodos destrutivos ou em inventários florestais, com base na relação entre volume do

indivíduo e sua massa seca. Existem muitos métodos que descrevem essa relação volume da planta e quantidade de biomassa. O estudo do Painel Intergovernamental sobre Mudanças Climáticas (IPCC) estima inclusive o fator 0,47 para a relação carbono estocado e biomassa total (IPCC, 2006).

Para superar esses desafios, é fundamental desenvolver métodos mais eficientes e práticos de quantificação de incremento de biomassa, que possam ser aplicados em larga escala e em períodos mais frequentes, pois esta informação possibilita entender melhor o comportamento das espécies em diferentes condições de clima e solo. Tecnologias baseadas em sensores LiDAR (*Light Detection and Ranging*) embarcados em Veículos Aéreos Não Tripulados (VANTs) têm se destacado na estimativa da altura de espécies florestais - variável-chave para a estimativas de biomassa (Almeida *et al.*, 2022; Moreira *et al.*, 2025). A partir da utilização de sensores LiDAR, é possível gerar dados tridimensionais de todo o ambiente florestal e obter o *Canopy High Model* (CHM), que representa a variação da altura da vegetação (Corte *et al.*, 2022).

Diante disso, os objetivos específicos deste estudo foram: propor um método que permita estimar o estoque de carbono e quantificar o incremento de biomassa em plantios de Macaúba utilizando multi ferramentas, tais como algoritmos de aprendizado de máquina, variáveis estruturais como altura obtidos a partir de sensores LiDAR a bordo de drones e imagens multiespectrais de satélite, uma vez que essas imagens também possibilitam a estimativa da idade dos plantios, contribuindo para uma análise mais precisa. Os objetivos específicos deste estudo foram: estimar a biomassa e carbono a partir do CHM das áreas de plantio de Macaúba, desenvolver um modelo utilizando técnicas de *machine learning* e *deep learning* relacionando imagens de satélite multiespectrais e a quantidade de biomassa e carbono estocado em grandes áreas de cultivo e calcular o incremento de biomassa e carbono ao longo dos anos de produção.


2 MATERIAIS E MÉTODOS

2.1 Áreas de estudo

O estudo foi conduzido em duas localidades distintas no estado de Minas Gerais, selecionadas por apresentarem características complementares em termos de ambiente físico, sistema de cultivo e estágio de desenvolvimento da *Acrocomia aculeata*.

A primeira área, onde foram realizados os sobrevoos de drone equipado com sensor LiDAR, compreende a Fazenda Espelho (Figura 1), situada no município de João Pinheiro, na região Noroeste do estado, nas coordenadas 18°1'25,29"S e 45°58'1,80"W. A fazenda é de propriedade da empresa SOLEUM e abrange uma área total de 2.254 hectares, dos quais aproximadamente 680 hectares são destinados ao cultivo de Macaúba, conduzido sob diferentes sistemas de produção.


Figura 1 – Localização da Fazenda Espelho, no município de João Pinheiro.



A Fazenda Espelho está inserida no bioma Cerrado, caracterizando-se pela presença de diferentes fitofisionomias, incluindo veredas, formações savânicas e formações florestais densas. Os solos predominantes são planos e apresentam duas principais classes: o Cambissolo Háplico, pouco desenvolvido e com presença de minerais primários e fragmentos de rochas, e o Latossolo Vermelho-Amarelo, que ocorre em menor proporção e se destaca por sua profundidade, estrutura e uniformidade em cor e textura, ambos típicos de regiões tropicais e subtropicais (UFV *et al.*, 2010; Zaroni; Santos, 2021).

A altitude local varia entre 600 e 1.000 metros, e o clima é classificado como tropical de savana com estação seca no inverno (Aw), segundo Köppen-Geiger, apresentando precipitação média anual de aproximadamente 1.300 mm e temperatura média anual de 23,1 °C (INMET, 2025; Peel; Finlayson; McMahon, 2007). A região, no entanto, também apresenta déficit hídrico sazonal, que varia de 60 a 120 mm (Figueiredo *et al.*, 2010). A Climatologia do município de João Pinheiro do período de 1994 a 2024, considerando a precipitação total mensal e temperatura média compensada encontra-se na Figura 2 a seguir.

Figura 2 – Climatologia de João Pinheiro do período de 1994 a 2024.




Fonte: INMET (<https://bdmep.inmet.gov.br/>).

A segunda área utilizada neste estudo compreende a Estação Experimental de Araponga (Figura 3), pertencente à Universidade Federal de Viçosa (UFV), localizada

no município de Araponga, na Zona da Mata mineira, nas coordenadas 20°39'6,00"S e 42°32'14,00"O. Nesta unidade experimental, os talhões de cultivo de Macaúba ocupam aproximadamente 17 hectares.


Figura 3 – Localização dos talhões de cultivo de Macaúba na Estação Experimental do município de Araponga.



Inserida nos domínios do bioma Mata Atlântica, essa área apresenta relevo predominantemente forte ondulado a montanhoso e altitude média de 839 metros. Os solos são majoritariamente classificados como Latossolo Vermelho-Amarelo com horizonte A húmico e textura muito argilosa, embora ocorram também sinais de Cambissolo Háplico e Húmico em certos pontos (UFV *et al.*, 2010; Zaroni; Santos, 2021). O clima local é do tipo subtropical úmido (Cfa), com verões quentes e úmidos e invernos frios, sem estação seca definida, conforme a classificação de Köppen-Geiger. A região apresenta temperatura média anual de 18,9 °C e precipitação média anual de 1.484 mm (Climate Data, 2025; Peel; Finlayson; McMahon, 2007). A Normal

Climatológica do município de Araponga do período de 1991 a 2021, considerando a precipitação total mensal e temperatura média encontra-se na Figura 4 a seguir.

Figura 4 – Normal Climatológica de Araponga, do período de 1991 a 2021.



Fonte: Climate Data (<https://pt.climate-data.org/>).

2.2 Base de dados

2.2.1 Seleção dos talhões de cultivo de Macaúba


Com base no mapeamento prévio da plantação comercial de *Acrocomia aculeata* na Fazenda Espelho, foram selecionados sete talhões com diferentes características estruturais para a realização da coleta de dados. A escolha buscou contemplar a variabilidade existente no plantio, considerando critérios como idade das plantas, cobertura vegetal, porte e estágio de desenvolvimento.

Entre os talhões selecionados, os talhões 16, 17, 27 e 32 se destacaram por apresentarem vegetação mais estruturada, com indivíduos de Macaúba em estágios mais avançados de desenvolvimento e cobertura densa. Já os talhões restantes (1, 2 e 3) apresentaram menor cobertura populacional e plantas em fases mais jovens de crescimento. A Figura 5 e a Tabela 1 apresentam a localização e as principais características dos talhões selecionados, respectivamente.

Tabela 1 – Características dos talhões de Macaúba selecionados para coleta de dados LiDAR.

Talhão	Coordenadas (centroide)	Data de plantio	Idade em out/2022 (meses)	Espaçamento (m x m)	Estágio de desenvolvimento	Área (ha)
16	18° 2'49,44"S 45°59'54,93"O	05/02/2016	80	5 x 5	Adulto	11,92
17	18° 2'41,52"S 45°59'50,84"O	12/02/2016	80	5 x 5	Adulto	11,63
27	18° 1'29,90"S 45°59'40,83"O	21/11/2016	71	5 x 5	Adulto	8,77
32	18° 1'21,48"S 45°59'13,33"O	08/11/2016	71	5 x 5	Adulto	12,84
1	18° 0'48,33"S 45°58'50,42"O	11/04/2018	54	5 x 5	Adulto	32,93
2	18° 1'01,94"S 45°59'03,49"O	11/04/2018	54	5 x 5	Adulto	32,42
3	18° 0'57,74"S 45°58'16,12"O	11/04/2018	54	5 x 5	Adulto	28,42

Fonte: SOLEUM.


Figura 5 – Talhões de cultivo de *Acrocomia aculeata* selecionados para coleta de dados LiDAR.

A Tabela 2 e a Figura 6 apresentam as principais características dos talhões da Área Experimental de Araponga, os quais foram posteriormente utilizados na aplicação do modelo. Os talhões exibem variações quanto à idade e ao espaçamento, com a maioria dos plantios estabelecida nos anos de 2009 e 2014. O espaçamento entre plantas varia entre 5 × 5 m, 7 × 3,5 m e o arranjo em fileiras duplas de 4 × 4 m, com 8 m entre as fileiras duplas.

Tabela 2 – Características dos talhões de Macaúba na Área Experimental de Araponga – MG.

Talhão	Coordenadas (centroide)	Ano de plantio	Espaçamento (m x m)	Área (ha)
1	20°39'11,64"S 42°32' 1,24"O	2009	5 x 5	3,89
2	20°39'16,56"S 42°31'57,53"O	2009	5 x 5	0,97
3	20°39'15,35"S 42°31'55,68"O	2014	7 x 3,5	0,60
4	20°39'19,32"S 42°31'58,52"O	2014	7 x 3,5	2,23
5	20°39'24,46"S 42°31'58,73"O	2014	Fileira dupla 4 x 4 e 8 m entre fileiras	1,92
6	20°39'11,12"S 42°31'52,12"O	2014	7 x 3,5	1,02
7	20°39'10,49"S 42°31'56,51"O	2014	Fileira dupla 4 x 4 e 8 m entre fileiras	1,03
8	20°39' 8,52"S 42°31'47,99"O	2009	5 x 5	0,97
9	20°39'12,95"S 42°31'46,15"O	2009	5 x 5	0,27
10	20°39' 9,05"S 42°32'11,03"O	2012	5 x 5	0,75
11	20°39' 5,10"S 42°32'13,70"O	2012	5 x 5	0,54
12	20°39' 6,11"S 42°32' 7,68"O	2014	Fileira dupla 4 x 4 e 8 m entre fileiras	0,49
13	20°39' 3,14"S 42°32'11,78"O	2014	7 x 3,5	0,17
14	20°39' 0,10"S 42°32'14,82"O	2014	7 x 3,5	0,21
15	20°38'57,01"S 42°32'19,89"O	2013	5 x 5	1,28

Figura 6 – Talhões de cultivo de *Acrocomia aculeata* selecionados em Araponga.



2.2.2 Processamento da nuvem de pontos e cálculo de biomassa e carbono por indivíduo

A partir dos sete talhões selecionados, conforme descrito na seção anterior, foram realizados sobrevoos com VANT equipado com sensor LiDAR, possibilitando a aquisição de nuvens de pontos tridimensionais para cada área. O levantamento foi realizado em outubro de 2022 pelas empresas SOLEUM e BIOFLORE, que disponibilizaram os dados para a execução do trabalho. Nos talhões 16, 17, 27 e 32 o sobrevoos foi realizado a uma altura mais baixa (60m) a fim de garantir maior detalhamento da estrutura vegetal, enquanto nos talhões 1, 2 e 3, com plantas de até 4 anos, os voos foram realizados a uma altitude mais alta (80m), para conseguir gerar nuvens de pontos de diferentes densidades de pontos.

Esses dados foram processados com o uso do pacote lidR na linguagem R (Roussel *et al.*, 2020), o qual oferece uma gama de ferramentas especializadas para


manipulação, filtragem e modelagem de dados LiDAR em ambientes florestais. O primeiro passo do processamento consistiu na filtragem de pontos espúrios (ruído) e na geração do Modelo Digital do Terreno (MDT), fundamental para a normalização da nuvem de pontos. Essa normalização permitiu referenciar todas as medidas de altura ao nível do solo, nivelando a base das árvores e possibilitando a análise precisa da altura relativa dos indivíduos de Macaúba.

Em seguida, foi gerado o modelo de altura do dossel (CHM), com resolução espacial de 5 metros. Essa resolução foi escolhida por ser compatível com o espaçamento regular entre as plantas (5 x 5 metros), permitindo representar adequadamente a distribuição espacial e o porte individual das palmeiras. Os dados provenientes de cada um dos sete talhões foram processados individualmente e depois integrados em um único arquivo raster. O resultado deste processamento foi a criação de um raster, no qual cada pixel corresponde aproximadamente à altura estimada de um indivíduo de Macaúba, servindo como base para as etapas seguintes de modelagem e análise estrutural da plantação.

Para estimar os valores de biomassa e estoque de carbono a partir do *raster* gerado com a altura das palmeiras de Macaúba, foram aplicadas equações alométricas desenvolvidas por Moreira, 2019, e Moreira *et al.*, 2025. Esse autor realizou coletas por meio do método destrutivo de indivíduos de Macaúba de diferentes idades, obtendo dados dendrométricos da espécie. A partir desses dados, foi possível calcular a massa seca, a biomassa e o carbono por planta, permitindo, posteriormente, estabelecer relações matemáticas com a altura das árvores.


As equações alométricas utilizadas (Figura 7 e Figura 8) expressam a correlação entre a altura total das plantas, parâmetro extraído diretamente do CHM, considerando desde as raízes da planta até a curvatura da folha mais alta, e as respectivas quantidades de biomassa seca e carbono acumulado por indivíduo. O uso dessas equações alométricas representa uma alternativa eficiente e de baixo custo em relação a métodos destrutivos de quantificação, possibilitando estimativas mais precisas e replicáveis em grandes áreas.

Figura 7 – Acúmulo de biomassa em função da altura total em palmeiras de Macaúba.



Onde r = coeficiente de correlação entre os valores de massa seca observados (y) e estimados ($\hat{y}$); $Sy.x$ = Erro padrão residual. Fonte: Moreira, 2019.


Figura 8 – Acúmulo de carbono em função da altura total em palmeiras de Macaúba.



Onde r = coeficiente de correlação entre os valores de carbono observados (y) e estimados ($\hat{y}$); $Sy.x$ = Erro padrão residual. Fonte: Moreira, 2025.

A Figura 9 a seguir apresenta um fluxograma que sintetiza as etapas metodológicas adotadas para o processamento dos dados LiDAR obtidos por drone nos talhões selecionados. O diagrama ilustra, de forma sequencial, desde a aquisição da nuvem de pontos até a geração do CHM e sua posterior utilização na estimativa da altura das palmeiras, biomassa e estoque de carbono por indivíduo.

Figura 9 – Fluxograma com o processamento da nuvem de pontos.



Fonte: Elaborado pela autora.

2.2.3 Processamento das Imagens de Satélite e cálculo dos índices utilizados

Para realizar o treinamento e validação dos modelos, foram utilizadas imagens dos satélites Sentinel-2 (Missão Copernicus) e Landsat (Landsat 7 e 8), acessadas por meio da plataforma *Google Earth Engine* (GEE). Para garantir a consistência temporal na modelagem, foram selecionadas imagens referentes ao mês de outubro de 2022, coincidindo com a data de aquisição dos dados LiDAR e refletindo com maior precisão o estado da vegetação no momento da coleta da nuvem de pontos.

Durante a etapa de pré-processamento, foram selecionadas bandas espectrais essenciais para a análise da vegetação: vermelho (*Red*), verde (*Green*), azul (*Blue*), infravermelho próximo (NIR) e infravermelho de ondas curtas (SWIR). A partir dessas bandas, foram calculados os seguintes índices espectrais utilizados para avaliação da vegetação e da umidade da cobertura vegetal, os quais serviram como variáveis de entrada (*input*) nos modelos preditivos:

- I. NDVI – Índice de Vegetação da Diferença Normalizada (Rouse *et al.*, 1974): estima a atividade fotossintética e a densidade de vegetação verde; é amplamente utilizado como indicador de vigor vegetal

$$NDVI = \frac{NIR - Red}{NIR + Red}$$

- II. EVI – Índice de Vegetação Aprimorado (*Enhanced Vegetation Index*) (Huete *et al.*, 2002): reduz os efeitos atmosféricos e a influência do solo, oferecendo melhor desempenho em áreas de vegetação densa

$$EVI = G \times \frac{(NIR - Red)}{(NIR + C_1 \times Red - C_2 \times Blue + L)}$$

Onde as constantes típicas assumem os seguintes valores: $G = 2,5$; $C_1 = 6,0$; $C_2 = 7,5$, e $L = 1,0$ (fator de correção atmosférica).

- III. NDMI – Índice de Umidade da Diferença Normalizada (*Normalized Difference Moisture Index*): estima a umidade da vegetação; é sensível à presença de água nas folhas

$$NDMI = \frac{NIR - SWIR}{NIR + SWIR}$$

- IV. SAVI – Índice de Vegetação Ajustado ao Solo (*Soil Adjusted Vegetation Index*) (Huete, 1988): compensa a interferência do solo exposto em áreas com pouca vegetação; reduz o impacto do brilho do solo

$$SAVI = \frac{(NIR - Red)}{(NIR + Red + L)} \times (1 + L)$$

Onde L é o fator de correção do solo (varia entre 0 e 1; comumente adotado como $L = 0,5$).

- V. MSAVI – Índice de Vegetação Ajustado ao Solo Modificado (*Modified SAVI*) (Qi *et al.*, 1994): uma versão avançada do SAVI, ajusta o fator de correção do solo dinamicamente com base na reflectância da vegetação; é ideal para áreas com cobertura vegetal muito baixa e para avaliação de crescimento inicial de plantações

$$MSAVI = \frac{2 \times NIR + 1 - \sqrt{(2 \times NIR + 1)^2 - 8 \times (NIR - Red)}}{2}$$

Para facilitar a compreensão das diferenças entre os principais índices de vegetação utilizados no sensoriamento remoto, a Tabela 3 a seguir apresenta um resumo comparativo entre NDVI, EVI, NDMI, SAVI e MSAVI. Nela são destacados os tipos de bandas necessárias, as aplicações mais adequadas, a sensibilidade à vegetação, e se cada índice considera ou corrige os efeitos do solo e da atmosfera.

Tabela 3 – Resumo comparativo entre os índices calculados.

Índice	Sensores necessários	Melhor uso	Sensibilidade à vegetação	Correção do solo	Correção da atmosfera
NDVI	RED, NIR	Vegetação geral	Alta	Não	Não
EVI	RED, NIR, BLUE	Vegetação densa	Muito alta	Sim	Sim
NDMI	NIR, SWIR	Umidade vegetal	Moderada	Não	Não
SAVI	RED, NIR	Vegetação rala	Alta	Sim (manual)	Não
MSAVI	RED, NIR	Vegetação rala e seca	Alta	Sim (automático)	Não

Após o cálculo dos índices, todas as imagens foram reprojetaadas para o sistema de referência SIRGAS 2000 UTM Zona 23S, garantindo compatibilidade espacial com os dados LiDAR.

Na etapa de aplicação do modelo, foram adquiridas imagens dos satélites Landsat 7 e 8 para ambas as áreas de estudo. Para João Pinheiro, as imagens cobriram o período de 2015 a 2024, enquanto para Araponga, o intervalo foi de 2011 a 2024. As coletas foram realizadas entre os meses de junho e setembro, conforme a disponibilidade das cenas, coincidindo com o período seco em ambas as regiões.

2.3 Modelagem

2.3.1 Integração dos Dados

Com as estimativas de biomassa e estoque de carbono obtidas por meio das equações alométricas de Moreira (2019) e Moreira *et al.* (2025), foi realizada a etapa de integração dos diferentes conjuntos de dados para treinamento e validação no modelo preditivo a partir da reamostragem espacial dos *rasters* gerados.

A reamostragem dos *rasters* de biomassa e carbono foi realizada utilizando uma metodologia de agregação por soma, por meio da função *aggregate* do pacote *raster* na linguagem R, de modo que os valores de biomassa e carbono dos pixels

originais (com resolução de 5 m) foram acumulados em novos pixels (com resolução de 10 m e 30 m), compatíveis com a resolução dos dados espectrais. Assim, cada pixel reamostrado passou a representar o valor total de biomassa e carbono contido na sua área correspondente, assegurando uma representação fiel do acúmulo desses atributos em escala espacial compatível com a modelagem. Um exemplo da metodologia utilizada pode ser observado nas Figura 10 e Figura 11 a seguir.

Figura 10 – Exemplo de reamostragem dos pixels com resolução 5x5m para 10x10m, utilizando a metodologia de agregação por soma.





Figura 11 – Exemplo de reamostragem dos pixels com resolução 5x5m para 30x30m, utilizando a metodologia de agregação por soma.



Nesta etapa, os arquivos raster contendo os índices de vegetação foram coletados utilizando um *shapefile* com o contorno dos talhões selecionados, permitindo isolar as áreas com presença efetiva da espécie cultivada. Essa filtragem espacial garantiu que apenas os pixels correspondentes aos talhões de cultivo fossem considerados na modelagem.

2.3.2 Desenvolvimento dos modelos preditivos

Com o objetivo de estimar os estoques de biomassa e carbono da palmeira Macaúba (*Acrocomia aculeata*) a partir de dados orbitais, foram implementados dois modelos supervisionados de predição: Random Forest (MLRF) e Rede Neural Artificial (DLRN). Ambos os modelos utilizaram como variáveis preditoras cinco índices espectrais derivados de imagens multiespectrais (NDVI, EVI, NDMI, SAVI e MSAVI),

conforme descrito no Tópico 2.2.3. As variáveis-resposta consistiram nos valores de biomassa e carbono acumulado, previamente reamostrados conforme o Tópico 2.3.1.

O modelo Random Forest (Breiman, 2001), foi o primeiro a ser implementado, com o objetivo de capturar relações não lineares entre os índices espectrais e os estoques de biomassa e carbono. A modelagem foi realizada com 2000 árvores de decisão ($n_{tree} = 2000$) e seleção de 3 variáveis a cada divisão ($m_{try} = 3$), em um processo de otimização empírica para maximizar o desempenho preditivo. A avaliação do modelo foi conduzida por meio de validação cruzada do tipo *k-fold* ($k = 5$), na qual os dados foram divididos em cinco subconjuntos. Para cada rodada de validação, 70% dos dados foram usados no treinamento e 30% na validação, garantindo robustez na avaliação do modelo e evitando sobreajuste.

Em paralelo, foi desenvolvido um segundo modelo baseado em Rede Neural Artificial de arquitetura simples, implementada com o pacote *nnet* da linguagem R, que utiliza de uma rede neural do tipo *Feed Forward* com uma única camada oculta (Ripley; Venables, 2025). A rede foi configurada com uma única camada escondida contendo 5 neurônios ($size = 5$), taxa de regularização (*decay*) igual a 0,01, e número máximo de iterações fixado em 500 ($maxit = 500$). As mesmas variáveis-resposta e índices de vegetação utilizadas no modelo MLRF foram utilizadas como entradas da rede neural, permitindo uma comparação direta entre os métodos.

Ambos os modelos foram avaliados com o mesmo procedimento de validação cruzada (*k-fold*) e pelas mesmas métricas estatísticas, viabilizando uma comparação direta entre as abordagens. A escolha por modelos de naturezas distintas, Random Forest como método de ensemble baseado em árvores de decisão, e a Rede Neural como um modelo não linear de aprendizado supervisionado, teve como objetivo investigar suas respectivas capacidades de estimar os atributos biofísicos da vegetação, neste caso a biomassa e carbono estocados, com base em dados de sensoriamento remoto.

A implementação dos modelos foi realizada com o auxílio do pacote *caret* (*Classification and Regression Training*) (Kuhn, 2008), amplamente utilizado em modelagem estatística e aprendizado de máquina no ambiente R. O *caret* foi essencial por oferecer uma interface padronizada para o ajuste, a validação cruzada e a avaliação de diferentes algoritmos, além de permitir a automatização de processos como normalização dos dados, seleção de variáveis e ajuste de hiperparâmetros. Sua

aplicação neste estudo permitiu a condução eficiente e comparável de ambos os modelos, utilizando dados espectrais provenientes dos sensores Landsat e Sentinel.

2.3.3 Avaliação dos Modelos

A avaliação dos modelos foi realizada com base em métricas de erro e ajuste: Raiz do Erro Médio Quadrático, Coeficiente de Determinação e Erro Médio Absoluto.

- I. Raiz do Erro Quadrático Médio (RMSE, *Root Mean Square Error*): Mede o quão distantes estão os valores previstos dos valores reais; quanto menor o RMSE, melhor o modelo; é sensível a erros grandes (*outliers*).

$$RMSE = \sqrt{\frac{1}{n} \times \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

Onde y_i é o valor real e $\hat{y}_i$ é o valor previsto.

- II. Coeficiente de Determinação (R^2): Mede a proporção da variância dos dados que é explicada pelo modelo. Varia de 0 a 1, onde valores próximos a 1 representam uma previsão perfeita, enquanto valores próximos a zero indicam que o modelo não explica nada da variância dos dados.

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

- III. Erro Médio Absoluto (MAE, *Mean Absolute Error*): É a média das diferenças absolutas entre os valores reais e os previstos; quanto menor o MAE, melhor o modelo. Ao contrário do RMSE, o MAE não penaliza tanto os grandes erros.

$$MAE = \frac{1}{n} \times \sum_{i=1}^n |y_i - \hat{y}_i|$$

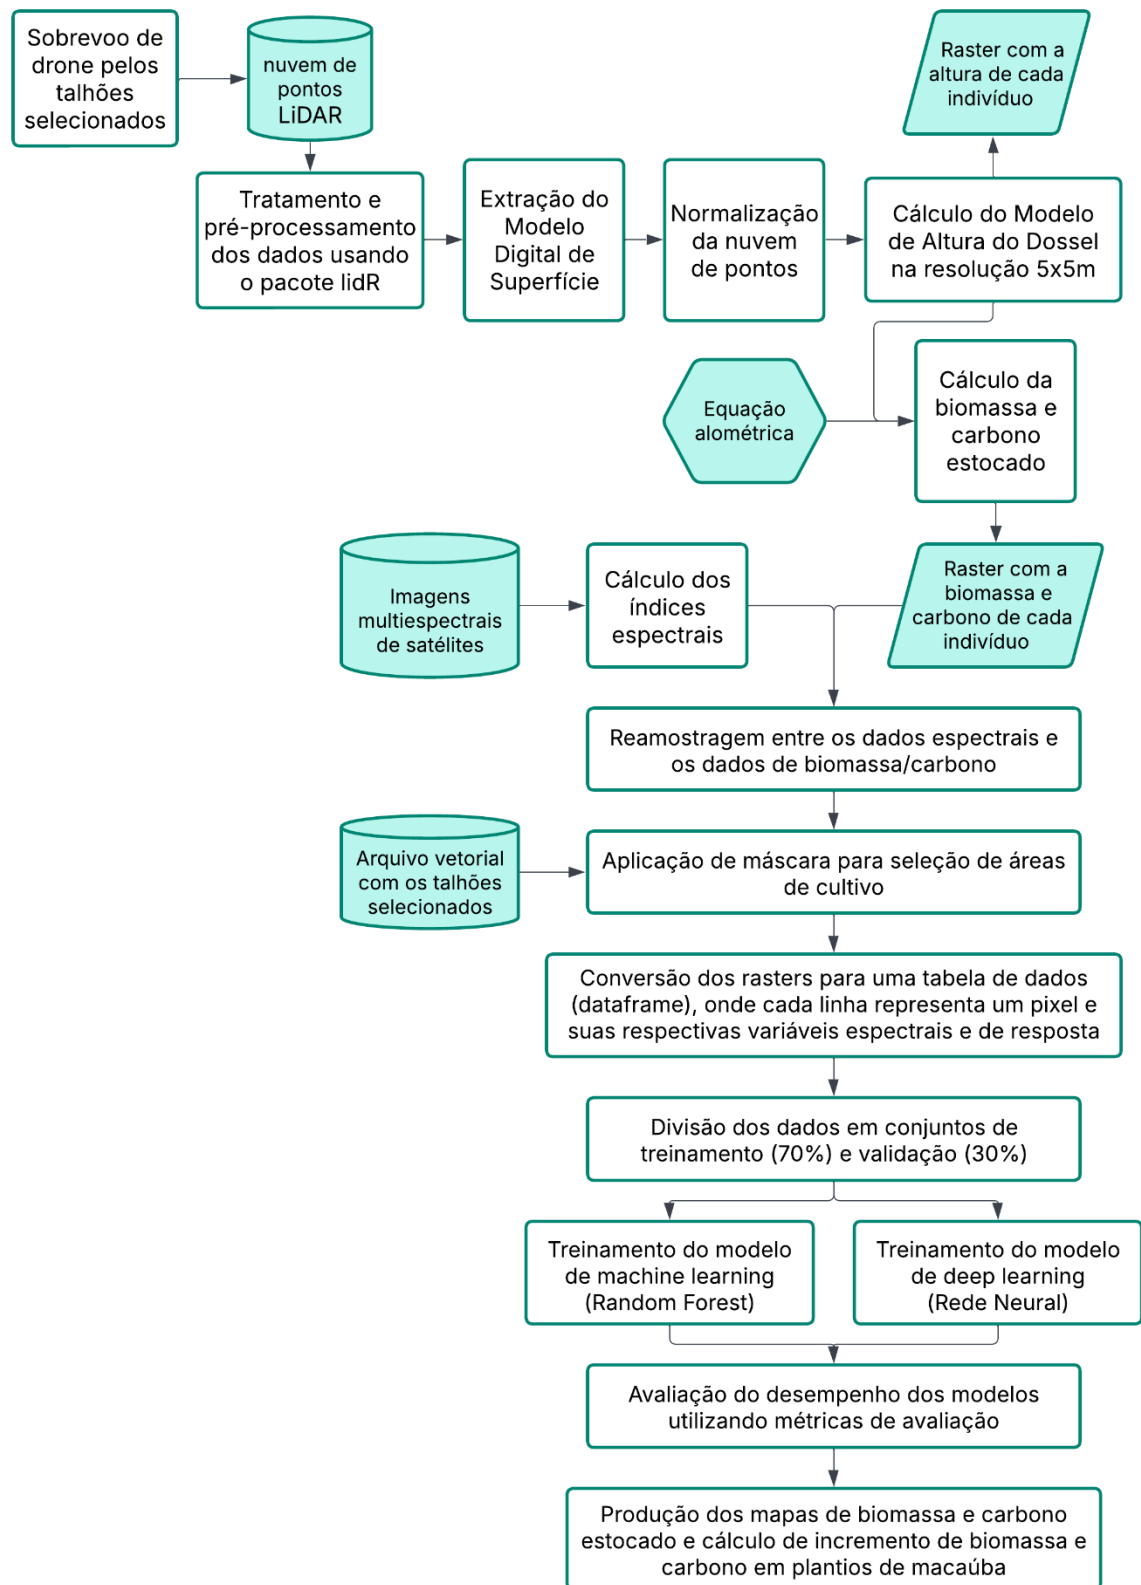
2.4 Aplicação do modelo: crescimento e incremento de biomassa e carbono estocado da Macaúba em diferentes regiões de Minas Gerais

Para a avaliação da dinâmica de biomassa e carbono, foi realizada a etapa de comparação dos resultados dos modelos para posteriormente escolher os modelos que seriam utilizados para calcular o incremento de biomassa e carbono. A análise foi realizada no ambiente R, utilizando o modelo previamente treinado e validado com dados de campo. As imagens multiespectrais utilizadas foram adquiridas para as regiões de João Pinheiro (a partir de 2015) e Araponga (a partir de 2011), priorizando o período seco, compreendido entre os meses de junho e setembro. Essa janela temporal foi escolhida por apresentar menor cobertura de nuvens, garantindo melhor qualidade das imagens. A seleção dos anos também considerou a disponibilidade dos dados para cada período.

A partir das composições anuais, foi possível gerar mapas de biomassa e carbono para cada ano analisado nas duas áreas de estudo. Para o cálculo dos incrementos anuais dessas variáveis, realizou-se a subtração entre os mapas raster de anos consecutivos, obtendo-se assim mapas que representam o acréscimo anual de biomassa e carbono nos plantios de Macaúba.

A Figura 12 apresenta o fluxograma geral do processo de modelagem preditiva, desde a aquisição dos dados até a geração dos mapas de estimativas de biomassa e carbono. Inicialmente, os dados LiDAR foram processados para gerar os modelos de altura do dossel e, a partir destes, foram estimados os estoques de biomassa e carbono com base em equações alométricas. Em paralelo, imagens dos satélites Sentinel-2 e Landsat-8 foram adquiridas e processadas para cálculo dos índices espectrais. Os arquivos raster com estimativa de biomassa e carbono foram então reamostrados para coincidir com a resolução espacial das imagens de satélite, permitindo a integração dos conjuntos. Após a unificação e limpeza dos dados, os modelos de Random Forest e Rede Neural foram treinados com 70% dos dados e validados com os 30% restantes. Por fim, os modelos calibrados foram aplicados sobre as áreas de interesse para geração dos mapas de carbono e biomassa ao longo dos anos de cultivo e incremento de biomassa e carbono.

Figura 12 – Fluxograma geral do processo de modelagem preditiva.



Fonte: elaborado pela autora.

3 RESULTADOS E DISCUSSÃO

3.1 PROCESSAMENTO DA NUVEM DE PONTOS

O processamento da nuvem de pontos seguiu a metodologia proposta por Roussel *et al.* (2020), utilizando o pacote lidR, da linguagem R. O principal objetivo foi gerar um mapa com as alturas dos indivíduos a partir da nuvem de pontos, que serviu como base para o treinamento do modelo. Para isso, foi considerado o posicionamento aproximado de cada planta nos talhões, assumindo um espaçamento regular de 5 × 5 metros entre os indivíduos.


3.1.1 Modelo de altura do dossel – CHM

As Figuras 13 e 14 apresentam os resultados do pré-processamento da nuvem de pontos e do cálculo do CHM em nível de indivíduos. Observa-se que os talhões 16, 17, 27 e 32 apresentaram alturas variando entre 5 e 12 metros, valores compatíveis com os reportados na literatura. Na fase de coleta dos pontos, em outubro de 2022, os talhões 16 e 17 estavam com 6,7 anos e os talhões 27 e 32 com 6 anos de idade. De acordo com Lorenzi (1992), a Macaúba pode atingir de 10 a 15 metros na fase adulta. Moreira *et al.* (2025), por sua vez, reporta altura média de $7,10 \pm 0,86$ m para indivíduos com 4,8 anos de idade, e de $10,25 \pm 0,99$ m plantas com 9 anos.

Em contrapartida, os talhões 1, 2 e 3, com idade 4,5 anos na data de coleta da nuvem de pontos, apresentaram, em sua maioria, alturas inferiores a 5 metros, abaixo do esperado de acordo com a literatura. No entanto, foram observadas algumas exceções: na área 1, indivíduos mais altos concentraram-se no canto superior esquerdo, enquanto na área 2 foram identificados fragmentos isolados com alturas superiores. Isso indica que as palmeiras não obtiveram um crescimento e desenvolvimento homogêneo nesses talhões. Apesar disso, a variação nas alturas entre os diferentes talhões é benéfica para o treinamento do modelo, pois amplia sua capacidade de generalização ao lidar com áreas compostas por plantas em diferentes estágios de desenvolvimento.


Vale destacar que o talhão 3 apresentou alguns indivíduos isolados de outra espécie, o que pode introduzir ruídos na interpretação dos resultados e impactar, ainda que de forma limitada, o desempenho do modelo preditivo.

Figura 13 – Modelo de altura do dossel para os talhões selecionados de Macaúba – Talhões 16, 17, 27 e 32.



Fonte: elaborado pela autora.

Figura 14 – Modelo de altura do dossel para os talhões selecionados de Macaúba – Talhões 1, 2 e 3.



Fonte: elaborado pela autora.


3.1.2 Biomassa e carbono por indivíduo

A análise espacial dos estoques de carbono e biomassa foi realizada em três resoluções distintas (5×5 m, 10×10 m e 30×30 m), com o objetivo de avaliar o comportamento dos dados frente à reamostragem e sua aplicabilidade em diferentes escalas. Os mapas gerados (Figuras 15 a 18) evidenciam padrões consistentes entre biomassa e carbono, refletindo a estreita relação entre essas variáveis.

Os talhões 16, 17, 27 e 32 destacaram-se por apresentarem os maiores estoques de carbono e biomassa em todas as resoluções, com ênfase para o talhão 32, que manteve concentrações elevadas mesmo após a reamostragem para 30 m. Para a reamostragem de 30x30m, os talhões 16 e 17 (6,7 anos) apresentaram uma faixa de 9,1 a 36,4 t de carbono acumulado por hectare, enquanto os talhões 27 e 32 (6 anos) acumularam não só nessa faixa, mas como também apresentaram valores de 36,4 a 70 t/ha por toda faixa direita do talhão 32. Esses resultados indicam áreas de plantio mais desenvolvidas ou com maior cobertura vegetal dos indivíduos. Por outro lado, os talhões 1, 2 e 3 (4,5 anos), cujos indivíduos apresentaram majoritariamente alturas inferiores a 5 metros, resultaram em menores estoques de carbono e biomassa, com carbono acumulado abaixo de 9 t/ha na resolução 30x30m nas áreas com o menos desenvolvimento dos indivíduos de Macaúba. Ainda assim, nesses talhões foram identificadas manchas isoladas de maior acúmulo, especialmente no canto superior da área 1 e em fragmentos esparsos da área 2, sugerindo a presença de indivíduos mais vigorosos, apresentando um acúmulo de carbono entre 9,1 e 18,2 t/ha na resolução de 30x30m. Ressalta-se que, no talhão 3, há indivíduos isolados que possivelmente pertencem a outra espécie, o que pode introduzir ruídos nos dados e comprometer a acurácia dos modelos.


Observa-se, ainda, que os valores máximos das legendas variam conforme a resolução espacial adotada, com amplitudes maiores nos mapas de 5 m (até 235 t Carbono/ha) e menores nos de 30 m (até 70 t Carbono/ha). Esse comportamento está de acordo com o esperado, uma vez que a reamostragem tende a suavizar gradientes e reduzir os valores extremos. Embora tal atenuação possa afetar a precisão em análises de alta resolução, no contexto deste estudo, isso não compromete os resultados, já que o foco está na identificação de padrões espaciais em escala mais ampla, e não na análise individual das plantas.

Figura 15 – Biomassa obtida a partir do CHM com resolução 5x5m e reamostragem para 10x10m (Sentinel) e 30x30m (Landsat) dos talhões 16, 17, 27 e 32.




Fonte: elaborado pela autora.

Figura 16 – Biomassa obtida a partir do CHM com resolução 5x5m e reamostragem para 10x10m (Sentinel) e 30x30m (Landsat) dos talhões 1, 2 e 3.




Fonte: elaborado pela autora.

Figura 17 – Carbono obtida a partir do CHM com resolução 5x5m e reamostragem para 10x10m (Sentinel) e 30x30m (Landsat) dos talhões 16, 17, 27 e 32.



Fonte: elaborado pela autora.

Figura 18 – Carbono obtida a partir do CHM com resolução 5x5m e reamostragem para 10x10m (Sentinel) e 30x30m (Landsat) dos talhões 1, 2 e 3.



Fonte: elaborado pela autora.

3.2 TREINAMENTO E VALIDAÇÃO DOS MODELOS

3.2.1 Desempenho dos modelos

Os gráficos de dispersão ilustram o desempenho dos modelos na predição da biomassa e carbono estocado da Macaúba, a partir de dados espectrais obtidos pelos sensores Landsat e Sentinel. Foram avaliadas duas abordagens de modelagem: a Rede Neural Simples (DLRN) e o algoritmo de Random Forest (MLRF), resultando em quatro cenários distintos para cada variável resposta. Cada gráfico exibe os valores preditos em função dos valores observados ($t \cdot ha^{-1}$), para os conjuntos de treinamento


e validação, permitindo uma análise visual e quantitativa da acurácia e capacidade preditiva dos modelos.

Conforme descrito na metodologia, a base de dados foi dividida aleatoriamente, com 70% dos pontos destinados ao treinamento e 30% à validação dos modelos. De forma geral, os modelos baseados em Random Forest apresentaram melhor desempenho em termos de erro quadrático médio (RMSE) e coeficiente de determinação (R^2), especialmente quando aplicados a dados Landsat. Por outro lado, as redes neurais demonstraram maior sensibilidade à escolha das variáveis e ao ajuste dos parâmetros, mas apresentaram melhor estabilidade entre as fases de treinamento e validação. Nas estimativas de biomassa utilizando as imagens do Landsat, o modelo MLRF (Gráfico 1) obteve excelente ajuste durante o treinamento ($R^2 = 0,95$; RMSE = 5,07 t.ha⁻¹; MAE = 3,35 t.ha⁻¹), mas apresentou queda acentuada de desempenho ($R^2 = 0,73$), sugerindo a ocorrência de superajuste (*overfitting*). Em contraste, o modelo DLRN (Gráfico 3) alcançou resultados mais equilibrados entre as duas fases ($R^2 = 0,81$ no treinamento e $R^2 = 0,79$ na validação), embora com erros absolutos mais elevados, indicando menor precisão, porém maior capacidade de generalização.

Em relação às estimativas baseadas no sensor Sentinel, observou-se padrão semelhante. O modelo MLRF (Gráfico 2) apresentou novamente desempenho elevado no treinamento ($R^2 = 0,93$), porém com maior discrepância na validação ($R^2 = 0,66$ e RMSE = 13,68 t.ha⁻¹), o que reforça a tendência ao sobreajuste. Por sua vez, o modelo DLRN (Gráfico 4), embora com coeficientes de determinação mais modestos ($R^2 \approx 0,71$ em ambas as fases), demonstrou consistência nos resultados, o que pode ser interpretado como uma maior robustez diante de novos dados.


De maneira geral, os modelos Random Forest se mostraram mais precisos durante o treinamento, refletindo sua capacidade de capturar padrões complexos nos dados. No entanto, essa alta performance inicial nem sempre se manteve na fase de validação, o que sugere um risco maior de superajuste, especialmente em cenários com menor representatividade amostral ou maior heterogeneidade estrutural da vegetação. Por outro lado, as redes neurais simples apresentaram desempenho mais conservador, mas com menor discrepância entre as fases, indicando maior estabilidade preditiva.

Gráfico 1 – Relação entre a Biomassa observada e predita pelo algoritmo gerado pela técnica Random Forest, sensores Landsat, nas fases de treinamento e de validação.




Fonte: elaborado pela autora.

Gráfico 2 – Relação entre a Biomassa observada e predita pelo algoritmo gerado pela técnica Random Forest, sensores Sentinel, nas fases de treinamento e de validação.




Fonte: elaborado pela autora.

Gráfico 3 – Relação entre a Biomassa observada e predita pelo algoritmo gerado pela técnica Rede Neural Artificial simples, sensores Landsat, nas fases de treinamento e de validação.



Fonte: elaborado pela autora.

Gráfico 4 – Relação entre a Biomassa observada e predita pelo algoritmo gerado pela técnica Rede Neural Artificial simples, sensores Sentinel, nas fases de treinamento e de validação.



Fonte: elaborado pela autora.


Para a variável carbono, a análise seguiu os mesmos critérios adotados para a biomassa, com ênfase nas diferenças observadas entre sensores e algoritmos de modelagem. Utilizando o sensor Landsat, o modelo MLRF (Gráfico 5) apresentou novamente ótimo desempenho na fase de treinamento ($R^2 = 0,94$; RMSE = 2,90 t.ha⁻¹; MAE = 1,79 t.ha⁻¹). No entanto, observou-se uma queda significativa na fase de validação ($R^2 = 0,61$; RMSE = 7,49 t.ha⁻¹; MAE = 4,43 t.ha⁻¹), indicando possível superajuste (*overfitting*) do modelo.

Por outro lado, o modelo DLRN (Gráfico 7) demonstrou desempenho mais equilibrado, com $R^2 = 0,76$ no treinamento e $R^2 = 0,70$ na validação, além de erros mais moderados e estáveis.

No caso do sensor Sentinel, observou-se um padrão semelhante. O modelo MLRF (Gráfico 6) obteve ótimo ajuste durante o treinamento ($R^2 = 0,92$; RMSE = 3,99 t.ha⁻¹), mas apresentou queda no desempenho na validação ($R^2 = 0,57$), o que reforça a tendência de sobreajuste observada anteriormente. Já o modelo DLRN (Gráfico 8) manteve desempenho mais consistente entre as fases, com R^2 de 0,65 no treinamento e 0,66 na validação, apresentando variações menores nos índices de erro.


De modo geral, os modelos Random Forest demonstraram maior capacidade de ajuste ao conjunto de dados de treinamento, enquanto os modelos baseados em rede neural simples mostraram-se mais estáveis e com melhor capacidade de generalização para novos dados, o que é desejável em aplicações práticas de monitoramento de carbono em larga escala.

Gráfico 5 – Relação entre a Carbono observada e predita pelo algoritmo gerado pela técnica Random Forest, sensores Landsat, nas fases de treinamento e de validação.



Fonte: elaborado pela autora.


Gráfico 6 – Relação entre a Carbono observada e predita pelo algoritmo gerado pela técnica Random Forest, sensores Sentinel, nas fases de treinamento e de validação.



Fonte: elaborado pela autora.

Gráfico 7 – Relação entre a Carbono observada e predita pelo algoritmo gerado pela técnica Rede Neural Artificial simples, sensores Landsat, nas fases de treinamento e de validação.


Carbono - Landsat DLRN



Fonte: elaborado pela autora.

Gráfico 8 – Relação entre a Carbono observada e predita pelo algoritmo gerado pela técnica Rede Neural Artificial simples, sensores Sentinel, nas fases de treinamento e de validação.

Carbono - Sentinel DLRN



Fonte: elaborado pela autora.

3.2.2 Importância das variáveis

Com base na modelagem realizada, foi possível calcular a importância relativa de cada variável espectral utilizada como preditora dos estoques de biomassa e carbono. Foram consideradas cinco variáveis presentes no modelo, com os respectivos pesos expressos em porcentagem. Essa abordagem permitiu avaliar de forma mais precisa a contribuição individual de cada banda ou índice espectral, destacando, por exemplo, a alta relevância do índice NDVI e das bandas SWIR e NIR na estimativa da biomassa total. A avaliação da importância relativa das variáveis preditoras foi realizada para todos os modelos desenvolvidos.

Nos modelos Random Forest, observou-se um padrão marcante de concentração da importância em uma única variável dominante, especialmente o índice NDMI. Esse padrão foi consistente tanto para os modelos de biomassa quanto o de carbono: para a biomassa o NDMI representou 82,8% da importância com Landsat (Gráfico 9) e 82,0% com Sentinel (Gráfico 10); para o carbono o NDMI foi responsável por 82,2% (Landsat, Gráfico 13) e 86,9% (Sentinel, Gráfico 14). As demais variáveis apresentaram contribuições quase residuais, o que sugere que esses modelos dependem fortemente de um único índice para realizar as predições.


Em contraste, os modelos com redes neurais apresentaram uma distribuição mais equilibrada da importância das variáveis, evidenciando uma maior diversidade de atributos relevantes. Para biomassa, o modelo com Landsat (Gráfico 11) destacou o NDVI (37,5%) e o SAVI (34,2%) como mais influentes, seguidos por MSAVI e NDMI. Já o Sentinel (Gráfico 12) mostrou maior peso para SAVI (37,5%), MSAVI (35,7%) e NDVI (24,6%). Esses resultados sugerem que aspectos relacionados à estrutura da vegetação e à cobertura do solo (capturados por SAVI e MSAVI) são relevantes para a modelagem da biomassa nesses casos.

Para carbono, também se observou uma distribuição diversificada da importância, onde para Landsat (Gráfico 15), os destaques foram NDVI (42,5%), seguido de SAVI (28,0%) e EVI (21,5%), enquanto com Sentinel (Gráfico 16) os índices se dividiram entre NDVI (40,3%), SAVI (39,6%) e MSAVI (16,1%). Esse padrão indica que o modelo considera múltiplas dimensões da vegetação, como cobertura vegetal, vigor e umidade superficial, na estimativa dos estoques de carbono.

Além disso, o índice EVI apresentou importância baixa nos modelos MLRF, e o índice NDMI teve importância praticamente nula nos modelos DLRN, o que pode estar


relacionado à sua sensibilidade à saturação em áreas com vegetação densa ou à interferência de solo exposto, reduzindo sua eficácia como preditor nesses ambientes.

Gráfico 9 – Classificação das cinco variáveis quanto a sua importância no cálculo de Biomassa pelo método Random Forest utilizando os sensores Landsat.




Fonte: elaborado pela autora.

Gráfico 10 – Classificação das cinco variáveis quanto a sua importância no cálculo de Biomassa pelo método Random Forest utilizando os sensores Sentinel.




Fonte: elaborado pela autora.

Gráfico 11 – Classificação das cinco variáveis quanto a sua importância no cálculo de Biomassa pelo método Rede Neural Artificial simples utilizando os sensores Landsat.




Fonte: elaborado pela autora.

Gráfico 12 – Classificação das cinco variáveis quanto a sua importância no cálculo de Biomassa pelo método Rede Neural Artificial simples utilizando os sensores Sentinel.




Fonte: elaborado pela autora.

Gráfico 13 – Classificação das cinco variáveis quanto a sua importância no cálculo de Carbono pelo método Random Forest utilizando os sensores Landsat.




Fonte: elaborado pela autora.

Gráfico 14 – Classificação das cinco variáveis quanto a sua importância no cálculo de Carbono pelo método Random Forest utilizando os sensores Sentinel.




Fonte: elaborado pela autora.

Gráfico 15 – Classificação das cinco variáveis quanto a sua importância no cálculo de Carbono pelo método Rede Neural Artificial simples utilizando os sensores Landsat.



Fonte: elaborado pela autora.

Gráfico 16 – Classificação das cinco variáveis quanto a sua importância no cálculo de Carbono pelo método Rede Neural Artificial simples utilizando os sensores Sentinel.



Fonte: elaborado pela autora.

A análise comparativa das importâncias (Tabela 4 e

Tabela 5) confirma que o índice NDMI se destaca de forma consistente nos modelos de Random Forest, sendo o principal preditor tanto da biomassa quanto do carbono em ambos os sensores. O destaque é ainda mais evidente nos dados do sensor Sentinel, onde o NDMI chegou a representar quase 98% da importância preditiva. Esse resultado evidencia a alta sensibilidade do modelo à umidade da vegetação, refletida na forte correlação entre NDMI, acúmulo de biomassa e o estoque de carbono neste cenário.

Os modelos de rede neural artificial simples apresentaram uma maior diversidade e equilíbrio na distribuição da importância entre os índices espectrais, com destaque para NDVI, SAVI e MSAVI. Isso sugere que essas variáveis atuam de forma complementar na predição dos estoques, capturando diferentes dimensões da vegetação. Do ponto de vista interpretativo, tais modelos podem ser considerados mais robustos, pois incorporam atributos relacionados à cobertura do dossel, cobertura do solo e vigor vegetativo, proporcionando uma representação mais abrangente das condições biofísicas da vegetação.

Essas interpretações são coerentes com estudos anteriores. Por exemplo, Watzlawick; Kirchner; Sanquetta (2009), utilizando imagens de alta resolução do sensor Ikonos II, também identificaram correlações significativas entre os índices SAVI e NDVI com dados de biomassa e carbono orgânico acumulado, ao estimar estoques em florestas de araucárias.

Tabela 4 – Importância das variáveis nos modelos de Biomassa.

Satélite	Modelo	Índice mais importante	Importância	Demais índices relevantes
Landsat	MLRF	NDMI	82,8	EVI (14,3%)
	DLRN	NDVI	37,5	SAVI (34,2%), MSAVI (15,3%), NDMI (13%)
Sentinel	MLRF	NDMI	82,0	MSAVI (6,7%), NDVI (6,7%)
	DLRN	SAVI	37,5	MSAVI (35,7%), NDVI (24,6%)

MLRF: Machine learning – random forest; DLRN: Deep learning – rede neural artificial simples.

Tabela 5 – Importância das variáveis nos modelos de Carbono.

Satélite	Modelo	Índice mais importante	Importância (%)	Demais índices relevantes
Landsat	MLRF	NDMI	82,2	EVI (17,1%)
	DLRN	NDVI	42,5	SAVI (28%), EVI (21,5%), MSAVI (10,5%)
Sentinel	MLRF	NDMI	86,9	SAVI (5,1%), MSAVI (4,7%), NDVI (3,2%)
	DLRN	NDVI	40,3	SAVI (39,6%), MSAVI (16,1%), EVI (4%)

MLRF: Machine learning – random forest; DLRN: Deep learning – rede neural artificial simples.

3.2.3 Comparação entre sensores

As Tabelas 6 e 7 apresentam a análise comparativa geral dos modelos para a predição de biomassa e carbono, respectivamente. Conforme indicado na Tabela 6, o modelo com melhor desempenho para a biomassa foi o MLRF com dados do sensor Landsat, enquanto o pior desempenho foi observado no modelo Sentinel DLRN com dados do Sentinel. Para a variável carbono, os resultados foram semelhantes, com o sensor Landsat novamente associado ao melhor desempenho, conforme mostrado na

Tabela 7.

Tabela 6 – Métricas do modelo de Biomassa.

Satélite	Método	RMSE (ton/ha)		R ²		MAE (ton/ha)	
		treino	validação	treino	validação	treino	validação
Landsat	MLRF	5,07	11,09	0,95	0,73	3,35	7,19
	DLRN	9,04	9,83	0,81	0,79	6,12	6,53
Sentinel	MLRF	6,28	13,68	0,93	0,66	3,82	8,67
	DLRN	12,40	12,64	0,71	0,71	8,04	8,27

MLRF: Machine learning – random forest; DLRN: Deep learning – rede neural artificial simples; RMSE: Raiz do Erro Quadrático Médio; R²: Coeficiente de Determinação; MAE: Erro Absoluto Médio.

Tabela 7 – Métricas do modelo de Carbono.

Satélite	Método	RMSE (ton/ha)		R ²		MAE (ton/ha)	
		treino	validação	treino	validação	treino	validação
Landsat	MLRF	2,89	6,37	0,94	0,71	1,93	4,13
	DLRN	5,54	6,64	0,76	0,70	3,61	4,11
Sentinel	MLRF	3,37	8,05	0,94	0,64	2,08	4,94
	DLRN	7,81	8,01	0,65	0,66	4,23	4,31

MLRF: Machine learning – random forest; DLRN: Deep learning – rede neural artificial simples; RMSE: Raiz do Erro Quadrático Médio; R²: Coeficiente de Determinação; MAE: Erro Absoluto Médio.

De maneira geral, os resultados evidenciam que os modelos baseados em Random Forest apresentaram os melhores desempenhos preditivos na fase de treinamento, com valores de R² superiores a 0,93 e menores erros (RMSE e MAE), tanto para a biomassa quanto para o carbono. No entanto, essa elevada performance nos dados de treinamento foi acompanhada por uma redução na etapa de validação, indicando possível *overfitting*. Isso sugere que esses modelos aprenderam bem os dados de treinamento, mas tiveram menor capacidade de generalização para dados não vistos.

Por outro lado, os modelos baseados em Redes Neurais apresentaram desempenho absoluto inferior, com R² variando entre 0,65 e 0,76, mas com resultados mais consistentes entre as fases de treinamento e validação. Esse comportamento indica maior robustez e menor sensibilidade às variações dos dados de entrada, o que pode ser vantajoso em aplicações operacionais.

Além disso, os modelos DLRN apresentaram ligeira vantagem ao utilizar dados do sensor Landsat enquanto nos modelos MLRF o desempenho foi mais variável entre sensores, sem um padrão claro de superioridade. Em síntese, os modelos Random Forest ofereceram maior precisão preditiva sob condições ideais, especialmente no treinamento, enquanto os modelos com rede neural demonstram maior confiabilidade e estabilidade em contextos práticos, reforçando seu potencial para aplicações em ambientes com maior variabilidade ou incerteza nos dados.

3.3 Avaliação do crescimento e incremento de biomassa e carbono estocado da Macaúba em diferentes regiões de Minas Gerais

Com base nos resultados apresentados no Tópico 3.2, os modelos com melhor desempenho foram aqueles que utilizaram as imagens Landsat. O modelo MLRF apresentou o melhor desempenho no conjunto de treino, enquanto o DLRN demonstrou maior estabilidade. Assim, ambos foram empregados para estimar a dinâmica temporal dos estoques e incrementos de biomassa e carbono em duas áreas de estudo, no período de 2011 a 2024.

Na área correspondente a Fazenda Espelho, as áreas foram plantadas entre os anos de 2016 e 2018. Com isso, os valores estimados de biomassa

Na Fazenda Espelho, os plantios foram estabelecidos entre 2016 e 2018. Consequentemente, os valores estimados de biomassa (Figura 19 e 20) e carbono (Figura 21 e 22) permaneceram baixos durante a maior parte da série temporal, com incrementos quase nulos até 2021, quando os talhões apresentavam entre 3 e 5 anos de idade. A partir de 2022, observa-se um aumento nos estoques e nos incrementos, especialmente nos setores ao sul da área, possivelmente associado à implantação recente de novos plantios florestais ou ao crescimento natural de indivíduos de macaúba previamente estabelecidos, principalmente nos talhões localizados do centro ao sul da propriedade, com aproximadamente 6 anos de idade. Esses resultados indicam diferentes estágios de desenvolvimento florestal dentro da área e ressaltam o potencial do sensoriamento remoto multitemporal para monitorar a dinâmica do sequestro de carbono em paisagens tropicais e sistemas agroflorestais.

Na área experimental de Araponga, cujos plantios foram realizados inicialmente em 2009 nos talhões centrais e, posteriormente, em 2012, 2013 e 2014 nos talhões adjacentes, observou-se uma trajetória contínua de acúmulo de biomassa (Figura 23 e 24) e carbono (Figura 25 e 26) ao longo dos anos, com os valores mais elevados concentrados entre 2018 e 2024. Os mapas temporais indicam crescimento mais acentuado em 2020, quando os indivíduos mais antigos atingiram cerca de 11 anos de idade, seguido por uma redução no ritmo de incremento nos anos subsequentes. Esse comportamento pode refletir uma fase de estabilização do crescimento ou até mesmo a saturação da capacidade produtiva da vegetação, à medida que o povoamento atinge maior maturidade.

Quanto às diferenças entre os modelos, o DLRN apresentou uma faixa de valores mais ampla para biomassa, variando de 0 a 150 t/ha, enquanto o MLRF apresentou valores entre 0 e 90 t/ha. Para o carbono, ambos os modelos mostraram uma amplitude semelhante, variando de 0 a 80 t/ha.

Figura 19 – Aplicação do modelo Landsat MLRF para a obtenção de biomassa estocada entre 2016 e 2024 nos talhões de Macaúba da Fazenda Espelho, João Pinheiro – MG.

Aplicação do modelo Landsat MLRF - Biomassa




Figura 20 – Aplicação do modelo Landsat DLRN para a obtenção de biomassa estocada entre 2016 e 2024 nos talhões de Macaúba da Fazenda Espelho, João Pinheiro – MG.

Aplicação do modelo Landsat DLRN - Biomassa




Figura 21 – Aplicação do modelo Landsat MLRF para a obtenção de carbono acumulado entre 2016 e 2024 nos talhões de Macaúba da Fazenda Espelho, João Pinheiro – MG.




Figura 22 – Aplicação do modelo Landsat DLRN para a obtenção de carbono acumulado entre 2016 e 2024 nos talhões de Macaúba da Fazenda Espelho, João Pinheiro – MG.

Aplicação do modelo Landsat DLRN - Carbono




Figura 23 – Aplicação do modelo Landsat MLRF para a obtenção de biomassa estocada entre 2011 e 2024 nos talhões de Macaúba da área experimental de Araponga – MG.




Figura 24 – Aplicação do modelo Landsat DLRN para a obtenção de biomassa estocada entre 2011 e 2024 nos talhões de Macaúba da área experimental de Araponga – MG.




Figura 25 – Aplicação do modelo Landsat MLRF para a obtenção de carbono acumulado entre 2011 e 2024 nos talhões de Macaúba da área experimental de Araponga – MG.





Figura 26 – Aplicação do modelo Landsat DLRN para a obtenção de carbono acumulado entre 2011 e 2024 nos talhões de Macaúba da área experimental de Araponga – MG.



3.3.1 Incremento de biomassa e carbono

Tradicionalmente, a estimativa dos incrementos de biomassa e carbono ao longo do tempo baseia-se em dados de campo obtidos por meio de medições repetidas em parcelas permanentes. No entanto, tais dados não estavam disponíveis neste estudo. Diante dessa limitação, foi adotada uma abordagem baseada em

sensoriamento remoto, que se mostrou uma alternativa viável e eficaz para estimar a dinâmica dos incrementos em escala espacial contínua. Por meio da modelagem aplicada sobre imagens multiespectrais, foi possível gerar mapas anuais de incremento de biomassa e carbono para as áreas de estudo, permitindo uma análise detalhada do crescimento das plantações ao longo do período avaliado.

A dinâmica temporal do incremento de biomassa em João Pinheiro (Figura 27 e Figura 28) revela um padrão consistente de crescimento da cultura de Macaúba ao longo dos anos. Segundo informações fornecidas pela empresa SOLEUM, o estabelecimento dos plantios nos diferentes talhões ocorreu entre 2016 e 2019. Esse período é caracterizado por incrementos discretos e localizados, compatíveis com a fase inicial de implementação das plantações. A partir de 2020, observa-se um aumento expressivo na magnitude dos incrementos, com extensas áreas alcançando valores entre 45 e 70 t.ha⁻¹.ano⁻¹. Esse padrão se intensifica nos anos de 2023 e 2024, quando a maior parte da área cultivada apresenta incrementos generalizados, refletindo o vigor e a maturidade dos sistemas produtivos, com valores máximos próximos a 90 t.ha⁻¹.ano⁻¹.

A dinâmica espacial e temporal do incremento de carbono (Figura 29 e Figura 30) acompanha o padrão observado para a biomassa. Nos anos iniciais, os valores são baixos, aumentando gradativamente com o desenvolvimento das plantações. Em 2020 e 2021, destacam-se núcleos de acúmulo mais intensos nas porções sul e oeste da área de estudo. Em 2024, observa-se a consolidação dos incrementos em larga escala, com registros próximos a 30 t.ha⁻¹.ano⁻¹, evidenciando o elevado potencial de sequestro de carbono associado à expansão e ao amadurecimento dos cultivos implantados.

Figura 27 – Incremento anual de biomassa em plantio de Macaúba da Fazenda Espelho, João Pinheiro.




Figura 28 – Incremento anual de biomassa em plantio de Macaúba ao sul da Fazenda Espelho, João Pinheiro.




Figura 29 – Incremento anual de carbono em plantio de Macaúba da Fazenda Espelho, João Pinheiro.






Figura 30 – Incremento anual de carbono em plantio de Macaúba ao sul da Fazenda Espelho, João Pinheiro.




A partir da Curva de Acúmulo de Carbono para um ciclo comercial de 360 meses (Figura 31) e das taxas anuais de acumulação e produtividade média de carbono por planta (Figura 32), propostas por Moreira et al. (2025), verifica-se que o padrão de variação observado neste estudo segue o comportamento típico das curvas de crescimento de *Acrocomia aculeata*, caracterizadas por um pico de desenvolvimento aos 7,5 anos de idade.

Figura 31 – Curva de acúmulo de carbono em plantas de Macaúba para um ciclo comercial de 360 meses (30 anos).



Fonte: Moreira, 2025.

Figura 32 – Taxa anual de acumulação de carbono em palmeiras de Macaúba (*A. aculeata*) (linha contínua) e produtividade média de carbono por planta (linha pontilhada).



Fonte: Moreira, 2025.

Em Araponga, os incrementos de biomassa apresentam variações significativas ao longo do tempo (Figura 33). Os maiores valores foram observados entre 2011 e 2014, com destaque para o ano de 2013, quando os incrementos variaram entre 45 e 90 t.ha⁻¹.ano⁻¹, indicando uma fase de crescimento acelerado nos estágios iniciais do ciclo produtivo. Entre 2015 e 2019, verifica-se uma redução

gradual nos valores, possivelmente relacionada à maturação da cultura ou à influência de fatores climáticos e operacionais. Destaca-se o ano de 2018, no qual os incrementos situaram-se predominantemente entre 20 e 45 t.ha⁻¹.ano⁻¹.

Em 2020, ocorre um novo pico de incremento, com grande parte da área cultivada apresentando valores próximos a 22,5 t.ha⁻¹.ano⁻¹, e máximos de até 67,5 t.ha⁻¹.ano⁻¹, especialmente na porção norte da área de estudo. Nos anos subsequentes, observa-se uma redução acentuada dos incrementos, que se tornam praticamente nulos a partir de 2022, sugerindo uma estabilização da biomassa acima do solo.

A variação dos incrementos de carbono em Araponga reflete a mesma tendência observada para a biomassa (Figura 34). Entre 2011 e 2014, concentram-se os maiores valores, com destaque para o ano de 2013, cujas áreas apresentaram incrementos entre 34 e 45 t.ha⁻¹.ano⁻¹. Após esse período, os incrementos diminuem progressivamente, com novo pico observado em 2020, com valores variando entre 20 e 45 t.ha⁻¹.ano⁻¹. A partir de 2022, os incrementos tornam-se muito baixos ou ausentes, sugerindo que os cultivos atingiram a fase de maturidade, caracterizada por um menor acúmulo anual de carbono.

Figura 33 – Incremento anual de biomassa nos talhões de Macaúba da área experimental de Araponga.





Figura 34 – Incremento anual de carbono nos talhões de Macaúba da área experimental de Araponga.



4 CONCLUSÕES

A aplicação integrada de dados LiDAR, imagens multiespectrais (Landsat e Sentinel) e algoritmos de aprendizado de máquina demonstrou elevada eficácia na estimativa dos estoques e incrementos de biomassa e carbono em plantios de Macaúba (*Acrocomia aculeata*). A geração do CHM por meio do pacote lidR resultou em produtos compatíveis com a literatura e sensíveis às variações estruturais entre os talhões, ampliando a capacidade preditiva dos modelos e sua aplicabilidade em diferentes contextos.

Entre os modelos testados, o Random Forest apresentou maior acurácia nos dados de treinamento, embora com tendência ao sobreajuste. Já a Rede Neural Simples demonstrou desempenho mais estável entre as fases de treino e validação, oferecendo maior robustez para aplicações práticas. O modelo MLRF com dados Landsat foi selecionado para a análise temporal dos incrementos, possibilitando a caracterização detalhada da dinâmica de crescimento dos plantios: em João Pinheiro, os incrementos se intensificaram a partir de 2020, com picos em 2023 e 2024; em Araponga, o crescimento foi mais acentuado entre 2011 e 2014, seguido por estabilização a partir de 2022.

A análise da importância das variáveis espectrais evidenciou a dominância do NDMI nos modelos Random Forest, refletindo a sensibilidade à umidade da vegetação. Por sua vez, os modelos DLRN utilizaram um conjunto mais diversificado de índices (NDVI, SAVI e MSAVI), proporcionando maior capacidade de interpretação dos atributos da vegetação.

Os achados reforçam a necessidade de equilibrar precisão e generalização na escolha de modelos preditivos, especialmente em cenários complexos como o dos sistemas agroflorestais. De modo geral, este estudo confirma o potencial do sensoriamento remoto multiespectral combinado a técnicas de machine learning para o monitoramento eficiente da dinâmica de crescimento e do sequestro de carbono em larga escala, fornecendo subsídios técnicos relevantes para o planejamento e a gestão sustentável no bioma Cerrado.

REFERÊNCIAS

- ALMEIDA, Catherine Torres de *et al.* Canopy Height Mapping by Sentinel 1 and 2 Satellite Images, Airborne LiDAR Data, and Machine Learning. **Remote Sensing**, [s. l.], v. 14, n. 16, p. 4112, 2022. Disponível em: <https://www.mdpi.com/2072-4292/14/16/4112/htm>. Acesso em: 2 jun. 2025.
- BENEZOLI, Victor Hugo; IMBUZEIRO, Hewlley; ABRAHÃO, Gabriel. Water limitations for the natural occurrence of macaúba and dendê in Brazil. **XX Congresso Brasileiro de Agrometeorologia**, [s. l.], n. April 2018, p. 5, 2017.
- BREIMAN, Leo. Random Forests. **Kluwer Academic Publishers**, [s. l.], p. 5–32, 2001.
- CLIMATE DATA. **Clima Araponga: Temperatura, Tempo e Dados climatológicos Araponga**. [S. l.], 2025. Disponível em: <https://pt.climate-data.org/america-do-sul/brasil/minas-gerais/araponga-176511/>. Acesso em: 10 maio 2025.
- COLMAN, Carina Barbosa *et al.* Modeling the Brazilian Cerrado land use change highlights the need to account for private property sizes for biodiversity conservation. **Scientific Reports**, [s. l.], v. 14, n. 1, p. 1–11, 2024. Disponível em: <https://doi.org/10.1038/s41598-024-55207-1>.
- CORTE, Ana Paula Dalla *et al.* **Aplicações do LiDAR para o inventário florestal – Enfoque unidade de área**. Ponta Grossa: [s. n.], 2022.
- FAVARO, Simone Palma; GUIDUCCI, Rosana do Carmo Nascimento. Mulheres na cadeia produtiva da macaúba. [s. l.], 2023. Disponível em: www.embrapa.br/fale-conosco/sac. Acesso em: 30 maio 2025.
- FIGUEIREDO, Maria Auxiliadora Pereira *et al.* Alteração estrutural de uma área de cerrado explorada sob regime de manejo no município de João Pinheiro-Minas Gerais-Brasil. **Revista Árvore**, [s. l.], v. 34, n. 3, p. 521–528, 2010. Disponível em: <https://www.scielo.br/j/rarv/a/3FnRQhRXJKCbqtThsPFXq9R/?lang=pt>. Acesso em: 4 jun. 2025.
- HUETE, A. R. A Soil-Adjusted Vegetation Index (SAVI). **Remote Sensing of Environment**, [s. l.], v. 25, n. 3, p. 295–309, 1988.
- HUETE, A. *et al.* Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, [s. l.], v. 83, n. 1–2, p. 195–213, 2002. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0034425702000962>. Acesso em:

27 jun. 2025.

INSTITUTO NACIONAL DE METEOROLOGIA (INMET). **Dados mensais de precipitação e temperatura da estação meteorológica de João Pinheiro – 1994 a 2024**. [S. l.], 2025. Disponível em: <https://bdmep.inmet.gov.br/>. Acesso em: 1 jun. 2025.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC). **Guidelines for national Greenhouse Gas Inventories**. Disponível em: <http://www.ipcc-nggip.iges.or.jp/public/2006gl/index.html>. Acesso em: 1 jun. 2025.

LORENZI, Harri. **Arvores brasileiras**. [S. l.: s. n.], 1992.

MOREIRA, Sandro Lúcio Silva. **Acúmulo de biomassa e carbono em cultivo de macaúba (*Acrocomia aculeata*)**. 2019. 57 f. - Universidade Federal de Viçosa, [s. l.], 2019. Disponível em: <https://www.posmet.ufv.br/eng/wp-content/uploads/2015/07/TESE-SANDRO-LUCIO-SILVA-MOREIRA.pdf>.

MOTOIKE, S. Y. *et al.* **A Cultura da Macaúba - implantação e manejo de cultivos racionais**. [S. l.]: Editora UFV, 2013.

PEEL, M C; FINLAYSON, B L; MCMAHON, T. A. Updated world map of the Köppen-Geiger climate classification. **Hydrology and Earth System Sciences**, [s. l.], v. 11, n. 5, p. 1633–1644, 2007. Disponível em: www.hydrol-earth-syst-sci.net/11/1633/2007/. Acesso em: 4 jun. 2025.

QI, J. *et al.* A modified soil adjusted vegetation index. **Remote Sensing of Environment**, [s. l.], v. 48, n. 2, p. 119–126, 1994.

RIPLEY, Brian; VENABLES, William. **Package “nnet”**. [S. l.: s. n.], 2025.

ROUSE, J. W. Jr. *et al.* **Monitoring vegetation systems in the Great Plains with ERTS.NASA. Goddard Space Flight Center 3D ERTS-1 Symp.** [S. l.: s. n.], 1974.

ROUSSEL, Jean Romain *et al.* lidR: An R package for analysis of Airborne Laser Scanning (ALS) data. **Remote Sensing of Environment**, [s. l.], v. 251, n. August, p. 112061, 2020. Disponível em: <https://doi.org/10.1016/j.rse.2020.112061>.

STRASSBURG, Bernardo B.N. *et al.* Moment of truth for the Cerrado hotspot. **Nature Ecology and Evolution**, [s. l.], v. 1, n. 4, p. 1–3, 2017. Disponível em: <http://dx.doi.org/10.1038/s41559-017-0099>.

UFV *et al.* **Mapa de solos do estado de Minas Gerais**. [S. l.: s. n.], 2010. Disponível em: <https://dps.ufv.br/software/>.

WATZLAWICK, Luciano Farinha; KIRCHNER, Flávio Felipe; SANQUETTA, Carlos

Roberto. Estimativa de biomassa e carbono em floresta com araucaria utilizando imagens do satélite ikonos II. **Ciencia Florestal**, [s. l.], v. 19, n. 2, p. 169–181, 2009.

ZARONI, Maria José; SANTOS, Humberto Gonçalves dos. **SiBCS - Portal Embrapa**. [S. l.], 2021. Disponível em: <https://www.embrapa.br/agencia-de-informacao-tecnologica/tematicas/solos-tropicais/sibcs>. Acesso em: 10 jun. 2025.