



UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO

INSTITUTO DE TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA

AGRÍCOLA E AMBIENTAL

BILTON GILBERTO NHANTUMBO

**FENOTIPAGEM DIGITAL E REDES NEURAIAS ARTIFICIAIS PARA ESTIMATIVA DE
VARIÁVEIS BIOMÉTRICAS DE MUDAS DE *MORINGA OLEIFERA* LAM**

**SEROPÉDICA
2026**



**UNIVERSIDADE FEDERAL RURAL DO RIO DE
JANEIRO
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA AGRÍCOLA E AMBIENTAL**



BILTON GILBERTO NHANTUMBO

**FENOTIPAGEM DIGITAL E REDES NEURAIAS ARTIFICIAIS PARA ESTIMATIVA DE
VARIÁVEIS BIOMÉTRICAS DE MUDAS DE *MORINGA OLEIFERA* LAM**

Dissertação apresentada ao programa Pós-Graduação em Engenharia Agrícola e Ambiental da Universidade Federal Rural do Rio de Janeiro, como requisito parcial para a obtenção do grau de Mestre em Engenharia Agrícola, Área de concentração em Sistemas Agrícolas.

Orientador(a): Doutor Gustavo Bastos Lyra

Coorientador(a): Doutor Anderson Gomide Costa

**SEROPÉDICA
2026**

Universidade Federal Rural do Rio de Janeiro
Biblioteca Central / Seção de Processamento Técnico

Ficha catalográfica elaborada
com os dados fornecidos pelo(a) autor(a)

N193f Nhantumbo, Bilton Gilberto, 2000-
 FENOTIPAGEM DIGITAL E REDES NEURAIS ARTIFICIAIS
 PARA ESTIMATIVA DE VARIÁVEIS BIOMÉTRICAS DE MUDAS DE
 MORINGA OLEIFERA LAM / Bilton Gilberto Nhantumbo. -
 rio de janeiro, 2026.
 81 f.: il.

 Orientador: Gustavo Bastos Lyra.
 Coorientador: Anderson Gomide Costa.
 Dissertação (Mestrado). -- Universidade Federal
 Rural do Rio de Janeiro, PROGRAMA DE PÓS-GRADUAÇÃO EM
 ENGENHARIA AGRÍCOLA E AMBIENTAL, 2026.

 1. Análise de imagens. 2. Aprendizado
 computacional. 3. Atributos morfométricos. 4.
 Monitoramento vegetativo. 5. ; Reflectância espectral.
 I. Lyra, Gustavo Bastos, 1975-, orient. II. Costa,
 Anderson Gomide, 1985-, coorient. III Universidade
 Federal Rural do Rio de Janeiro. PROGRAMA DE PÓS
 GRADUAÇÃO EM ENGENHARIA AGRÍCOLA E AMBIENTAL. IV.
 Título.

É permitida a cópia parcial ou total desta TFC/Dissertação/Tese, desde que seja citada a
fonte

**O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal
de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.”**

UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO

PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA E
AMBIENTAL

BILTON GILBERTO NHANTUMBO

FENOTIPAGEM DIGITAL E REDES NEURAS ARTIFICIAIS PARA ESTIMATIVA DE
VARIÁVEIS BIOMÉTRICAS DE MUDAS DE *MORINGA OLEIFERA* LAM

Dissertação apresentada ao programa Pós-Graduação em Engenharia Agrícola e Ambiental da Universidade Federal Rural do Rio de Janeiro, como requisito parcial para a obtenção do grau de Mestre em Engenharia Agrícola, Área de concentração em Sistemas Agrícolas.

DISSERTAÇÃO APROVADA EM 09 / 02 /2026.



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
SISTEMA INTEGRADO DE PATRIMÔNIO, ADMINISTRAÇÃO E
CONTRATOS

FOLHA DE ASSINATURAS

ATA Nº 94ª ATA DE DEFESA DE DISSERTAÇÃO DE BILTON /2026 - PPGEAAMB (12.28.01.00.00.00.40)
(Nº do Documento: 319)

(Nº do Protocolo: NÃO PROTOCOLADO)

(Assinado digitalmente em 13/02/2026 08:08)

GUSTAVO BASTOS LYRA
PROFESSOR DO MAGISTERIO SUPERIOR
DeptCAmb (12.28.01.00.00.00.29)
Matricula: ###740#5

(Assinado digitalmente em 10/02/2026 11:31)

RICARDO VILAR NEVES
PROFESSOR DO MAGISTERIO SUPERIOR
CoordCGEAC (12.28.01.00.00.00.37)
Matricula: ###987#3

(Assinado digitalmente em 12/02/2026 09:09)

BILTON GILBERTO NHANTUMBO
DISCENTE
Matricula: 2024#####7

(Assinado digitalmente em 10/02/2026 13:08)

MARCEL CARVALHO ABREU
ASSINANTE EXTERNO
CPF: ###,###,546-##

DEDICATÓRIA

Este trabalho é dedicado aos:

Meus progenitores Gilberto José Nhantumbo e Felizarda Alfredo Nhapulo

Aos meus irmãos Adriano, Leonel, Alfredo, Edmilson e Nairo.

AGRADECIMENTOS

Agradeço, primeiramente, a Deus, pela saúde, força e discernimento concedidos ao longo de toda a realização deste trabalho.

Registro meus agradecimentos aos meus pais, Gilberto José Nhantumbo e Felizarda Alfredo Nhapulo, pelo constante apoio, incentivo e dedicação durante toda a minha trajetória acadêmica.

Estendo meus agradecimentos aos meus irmãos Adriano, Leonel, Alfredo, Edmilson e Nairo Nhantumbo pelo companheirismo, pela amizade e pela presença contínua ao longo de minha formação.

Às minhas cunhadas Fernanda, Muaziza, Elsa e Micaela agradeço pela consideração, apoio e cordialidade sempre demonstrados.

Aos colegas de laboratório :Breno Gabriel, Samuel Vilela, Ângelo Mantovani, Álvaro Linhares, Raphaela Cabral, Pedro Ferrari, Larissa Couto, Livia Amorim e Ana Lúcia agradeço pela cooperação e auxílio prestados nas atividades de campo e no ambiente acadêmico.

À Universidade Federal Rural do Rio de Janeiro (UFRRJ), ao Programa de Pós-Graduação em Ambiente e Agricultura (PPGAAMB) e à CAPES, agradeço pela oportunidade e pelo suporte institucional e financeiro que viabilizaram a execução deste mestrado. Manifesto também minha gratidão aos docentes do programa pelas contribuições ao meu desenvolvimento acadêmico.

Aos meus orientadores, Prof. Dr. Gustavo Bastos Lyra e Prof. Dr. Anderson Gomide Costa, expresso sincera e profunda gratidão pela orientação qualificada, pela confiança em meu potencial e pela condução e dedicada durante todas as etapas deste trabalho.

À minha companheira, Nélia Dalúvia Rafael, manifesto agradecimento pelo apoio contínuo, compreensão, incentivo e colaboração durante este período.

Agradeço igualmente ao Grupo de Modelagem Ambiental e Atmosférica (GMAAT), ao Grupo de Estudos em Visão Computacional Aplicada à Agricultura (AGRIVIS), ao Prof. Ricardo Vilar e ao Prof. Dr. Mauro Antunes do Laboratório e Espectroradiômetro e Sensoriamento Remoto (LABspec/UFRRJ) e ao Prof. José Carlos Arthur Júnior, coordenador do viveiro florestal “Fernando Luiz Oliveira Capellão” do Instituto de Florestas/UFRRJ pelo suporte técnico e científico indispensável à mensuração e à análise dos dados utilizados nesta pesquisa.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.”

RESUMO

NHANTUMBO, Bilton Gilberto. **Fenotipagem digital aplicada e redes neurais artificiais para estimativa de variáveis biométricas de mudas de *Moringa oleifera* Lam.** 2026. 81p. Dissertação (Mestrado em Engenharia Agrícola e Ambiental). Instituto de Tecnologia, Universidade Federal Rural do Rio de Janeiro, Seropédica, 2026.

A crescente demanda por mudas de alta qualidade tem impulsionado o uso de técnicas de fenotipagem digital no setor florestal, especialmente em espécies de rápido crescimento, como *Moringa oleifera* Lam. Com os avanços tecnológicos e a crescente necessidade de aprimorar a eficiência no processo de produção de mudas, a fenotipagem digital é uma alternativa promissora para o monitoramento não destrutivo e, permite avaliações rápidas, precisas e de baixo custo. Nesse contexto, técnicas de imagens multiespectrais têm sido amplamente aplicadas para caracterizar atributos biométricos, subsidiar a tomada de decisão em viveiros e otimizar o manejo de espécies florestais. O objetivo desta pesquisa foi avaliar o potencial de imagens multiespectrais na estimativa do Índice de Área Foliar (IAF) e do diâmetro do coleto de mudas de *Moringa oleifera* Lam., integrando modelos de regressão linear múltipla e redes neurais artificiais. O experimento foi conduzido durante o desenvolvimento inicial das mudas, com avaliações semanais, envolvendo a coleta de variáveis biométricas tradicionais (IAF e diâmetro) e a aquisição de imagens com a câmera MAPIR Survey3 (bandas vermelhas - R, verde - G e infravermelho próximo - NIR). Para cada avaliação, foram calculados os índices de vegetação NDVI, GNDVI, RVI e CVI, após correção radiométrica e segmentação das imagens. A correlação de Pearson indicou forte associação entre o IAF e os índices NDVI ($r = 0,89$), GNDVI ($r = 0,98$) e SAVI ($r = 0,90$), enquanto o diâmetro apresentou correlações elevadas com NDVI ($r = 0,88$) e GNDVI ($r = 0,79$). Os modelos de regressão linear múltipla apresentaram alto desempenho para estimar IAF ($R^2 = 0,935$) e diâmetro ($R^2 = 0,90$), com destaque para o GNDVI como variável mais significativa. A análise com redes neurais artificiais mostrou resultados superiores, com valores de $R^2 = 0,994$ para o IAF e $R^2 = 0,992$ para o diâmetro, o que indicou excelente capacidade de generalização. Os resultados demonstram que a combinação entre fenotipagem digital e modelos estatísticos ou de inteligência artificial constitui uma ferramenta robusta para a estimativa de atributos biométricos em mudas e, permite avanços significativos no monitoramento em viveiros e oferece subsídios para práticas de manejo mais eficientes e sustentáveis.

Palavras-chave: Análise de imagens; Aprendizado computacional; Atributos morfométricos; Monitoramento vegetativo; Reflectância espectral

ABSTRACT

NHANTUMBO, Bilton Gilberto. **Digital phenotyping and artificial neural networks applied to estimate biometric variables of *Moringa oleifera* Lam seedlings**. 2026. 81p. Dissertation (Master's in Agricultural and Environmental Engineering). Institute of Technology, Federal Rural University of Rio de Janeiro, Seropédica, 2026.

The growing demand for high-quality seedlings has driven the use of digital phenotyping techniques in the forestry sector, especially for fast-growing species such as *Moringa oleifera* Lam. With technological advances and the increasing need to improve efficiency in seedling production, digital phenotyping has emerged as a promising alternative for non-destructive monitoring, enabling fast, accurate, and low-cost evaluations. In this context, multispectral imaging techniques have been widely applied to characterize biometric attributes, support decision-making in forest nurseries, and optimize the management of forest species. The aim of this research was to assess the potential of multispectral images for estimating Leaf Area Index (LAI) and stem diameter of *Moringa oleifera* seedlings using multiple linear regression models and artificial neural networks (ANN). The experiment was carried out during the early growth of the seedlings, with weekly assessments involving the collection of traditional biometric variables (LAI and diameter) and the acquisition of images using a MAPIR Survey3 camera (red - R, green - G, and near infrared - NIR bands). For each assessment, vegetation indices NDVI, GNDVI, RVI, and CVI were calculated after radiometric correction and image segmentation. Pearson correlation showed strong associations between LAI and NDVI ($r = 0.89$), GNDVI ($r = 0.98$), and SAVI ($r = 0.90$), while stem diameter displayed high correlations with NDVI ($r = 0.88$) and GNDVI ($r = 0.79$). Multiple linear regression models demonstrated high performance in estimating LAI ($R^2 = 0.935$) and stem diameter ($R^2 = 0.90$), with GNDVI standing out as the most influential variable. The artificial neural network analysis produced superior results, achieving $R^2 = 0.994$ for LAI and $R^2 = 0.992$ for stem diameter, indicating excellent generalization capacity. The results demonstrate that the combination of digital phenotyping and statistical modeling or artificial intelligence algorithms constitutes a robust tool for estimating biometric attributes in seedlings, enabling significant advances in forest nurseries monitoring and supporting more efficient and sustainable management practices.

Keywords: Spectral reflectance; Computational learning; Vegetative monitoring; Morphometric attributes; Image analysis.

LISTA DE FIGURAS

Figura 1. Formação de imagens digitais	9
Figura 2. Cobertura Espectral de Sensores RGB e Multiespectral	10
Figura 3. Arquitetura de uma Rede Neural Artificial Multicamadas (Perceptron Multicamadas - MLP)	19
Figura 4. Semeadura da moringa olifeira lam.	23
Figura 5. Medições tradicionais do IAF (A), Diâmetro do caule (B)	25
Figura 6. Tripé fixo utilizado para acoplar a câmera mapir survey 3.	25
Figura 7. Camera Mapir Survey 3 RGNIR	26
Figura 8. Espectro radiômetro (FieldSpec 4 Standard-Res) (A), Medição da refletância da placa teflon (B)	27
Figura 9. Curvas de transmissão espectral dos filtros ópticos da câmera MAPIR Survey3, correspondentes às bandas verde (G), vermelha (R) e infravermelho próximo (NIR), conforme especificações do fabricante.	28
Figura 10. Curvas de reflectância da placa de Teflon e do padrão de referência obtidas com espectrorradiômetro.	29
Figura 11. Carregamento da imagem do padrão de referência, visualização da placa lambertiana e extração dos valores médios de número digital (DN) por banda.	30
Figura 12. Inserção dos valores de reflectância obtidos em laboratório (espectrorradiômetro) e apresentação dos fatores de correção radiométrica por banda (R, G e NIR).	32
Figura 13. Relação entre os valores observados e estimados de diâmetro obtidos pelo modelo de RNA(A), Curva de Loss (B).	33
Figura 14. Remoção do fundo da imagem da amostra utilizando segmentação automática.	34
Figura 15. Resultados da correção radiométrica com apresentação da reflectância média corrigida por banda (R, G e NIR).	35
Figura 16. Fluxograma esquemático detalhando a interação das funcionalidades do software RAIC.	36
Figura 17. Arquitetura da RNA adotada.	39

LISTA DE TABELAS

Tabela 1: Descrição dos principais métodos de determinação do Índice de Área Foliar (IAF)	6
Tabela 2. Condições meteorológicas médias entre 11h e 13h nos dias de coleta	22
Tabela 3. Reflectância média da placa de Teflon nas bandas espectrais utilizadas para a calibração radiométrica.	29
Tabela 4. Análise descritiva dos dados dos índices de vegetação calculados	40
Tabela 5. Coeficientes de correlação de Pearson (r) entre os índices de vegetação (IVs) e os atributos biométricos	43
Tabela 6. Coeficientes estimados, erros-padrão, estatísticas t e valores de p do modelo de regressão múltipla utilizado para estimativa do Índice de Área Foliar (IAF)	46

Tabela 7. Coeficientes estimados, erros-padrão, estatísticas t e valores de p do modelo de regressão múltipla utilizado para estimativa do diâmetro..... 49

LISTA DE ABREVIATURAS E SIGLAS

ANN – Artificial Neural Network

BIO – Biossólido

BS – Batch size (tamanho de lote)

CEDAE – Companhia Estadual de Águas e Esgotos do Rio de Janeiro

COMLURB – Companhia Municipal de Limpeza Urbana do Rio de Janeiro

CSV – *Comma-Separated Values*

CVI – *Chlorophyll Vegetation Index (Índice de Vegetação de Clorofila)*

DC – Diâmetro do Caule

DIC – Delineamento Inteiramente Casualizado

DN – *Digital Number*

DR – Dropout

FERT – Fertilurb (composto orgânico)

fIPAR – Fração da Radiação Fotossinteticamente Ativa Interceptada

GNDVI – *Green Normalized Difference Vegetation Index*

IAF – Índice de Área Foliar

LAI – Leaf Area Index

LR – Learning rate (taxa de aprendizagem)

MAE – *Mean Absolute Error*

MAPIR – *Multispectral Aerial Photography InfraRed*

MLM – Modelo Linear Múltiplo

MLP – Multilayer Perceptron

MSE – *Mean Squared Error*

NDVI – Normalized Difference Vegetation Index

NIR – Near-Infrared (Infravermelho Próximo)

OLS – Ordinary Least Squares

PAR – Photosynthetically Active Radiation

PNG – Portable Network Graphics

R – Banda Vermelha (Red)

RAIC – Radiometric Image Correction (software desenvolvido)

RFA – Radiação Fotossinteticamente Ativa

RGB – Red, Green and Blue

RMSE – Root Mean Square Error

RNA – Rede Neural Artificial

RVI – *Ratio Vegetation Index*

SAVI – *Soil Adjusted Vegetation Index*

SC – Substrato Comercial

SIG – Sistema de Informações Geográficas

T1, T2, T3, T4, T5, T6 – Tratamentos experimentais

TIFF – Tagged Image File Format

UFRRJ – Universidade Federal Rural do Rio de Janeiro

Sumário

1. INTRODUÇÃO.....	1
2. REVISÃO DE LITERATURA.....	3
2.1. <i>Moringa oleifera</i> Lam.....	3
2.2. Variáveis Biométricas Em Mudas.....	5
2.2.1. Índice de Área Foliar (IAF).....	5
2.2.2. Métodos de determinação do IAF.....	5
2.2.3. Diâmetro do coleto (DC) e índice de área foliar (IAF).....	7
2.3. Fenotipagem digital e imagens multiespectrais em plantas.....	8
2.4. Índices de vegetação.....	11
2.4.1. <i>NDVI (Normalized Difference Vegetation Index)</i>	11
2.4.2. <i>GNDVI (Green Normalized Difference Vegetation Index)</i>	12
2.4.3. <i>RVI (Ratio Vegetation Index)</i>	12
2.4.4. <i>CVI (Chlorophyll Vegetation Index</i> (ou índices similares sensíveis à clorofila))...	12
2.5. Correção Radiométrica.....	14
2.6. Modelos Lineares Múltiplos.....	16
2.7. Redes Neurais Artificiais.....	17
2.7.1. Estrutura de uma Rede Neural Artificial.....	18
2.7.2. Redes Multicamadas (Multilayer Perceptrons).....	18
3. MATERIAIS E MÉTODOS.....	21
3.1. Caracterização das etapas metodológicas.....	21
3.2. Localização da área experimental.....	21
3.3. Delineamento Experimental e Condução da pesquisa.....	22
3.4. Fenotipagem digital e coleta de variáveis biométricas.....	23
3.5. Calibração radiométrica.....	26

3.6.	Análise de correlação	36
3.7.	Criação, ajuste e avaliação dos modelos de estimativa.....	36
3.7.1.	Regressão Linear Múltipla.....	36
3.7.2.	Redes Neurais Artificiais	38
3.7.2.1.	Arquitetura da Rede Neural.....	38
3.7.2.2.	Treinamento e Busca de Hiperparâmetros	39
4.	RESULTADOS E DISCUSSÃO	40
4.1.	Análise estatística descritiva dos índices de vegetação.....	40
4.2.	Correlação entre atributos da cultura e índices de vegetação.....	42
4.3.	Ajuste do modelo linear múltiplo para estimativa do índice de área foliar (IAF)	44
4.4.	Ajuste do modelo linear múltiplo para estimativa do diâmetro	47
4.5.	Redes neurais artificiais (desempenho comparativo).....	50
5.	CONCLUSÃO.....	55

1. INTRODUÇÃO

A procura por mudas de espécies florestais de qualidade tem crescido no Brasil, em razão da necessidade de se produzir plantas vigorosas e livres de patógenos para uso em áreas de reflorestamento e na silvicultura comercial. Essa demanda exige uma produção em grande escala e em curto espaço de tempo (Silva et al.,2020).

A *Moringa oleífera* lam (Jean-Baptiste Lamarck) é uma planta nativa das partes ocidentais e sub-Himalaias do noroeste da Índia, Paquistão e Afeganistão, pertence à família botânica Moringaceae. Esta planta também demonstrou adaptação e aptidão na região semiárida do nordeste do Brasil. Suas características gerais incluem folhas compostas bi pinadas, copa rala com altura que pode atingir até 10 metros, flores esbranquiçadas e frutos do tipo cápsula alada e deiscente, apresentando aspecto de vagem com marcações por semente que podem medir até 35 cm (Pereira et al., 2019).

De acordo De Jesus Lobo et al. (2023) o que faz com que a *Moringa oleífera* seja uma planta adequada para o cultivo nas regiões semiáridas e áridas do Brasil é a sua rusticidade, rápido crescimento, resistência às secas e tolerância ao estresse hídrico. Para que a moringa oleífera se desenvolva com melhores condições é necessário que se obtenha mudas de boa qualidade, pois este é um fator que ajuda no sucesso da sua produção.

A *Moringa oleífera* é uma excelente fonte de nutrientes para os animais pois, nas suas folhas e talos finos possui proteína e fibra de qualidade que se transformam em energia tornando-a ideal para a alimentação de ruminantes (Oliveira et al., 2020). Suas sementes contêm elevados teores de lipídios e proteínas, e suas flores são ricas em cálcio e fósforo.

O substrato é fator importante na produção de mudas, pois além do suporte estrutural às plantas, disponibiliza água e nutrientes necessários ao pleno crescimento das mudas (Frare, 2023). Inúmeros substratos, em sua composição original ou combinada, têm sido empregados para propagação de mudas de espécies arbóreas. O lodo de esgoto (biossólidos) tem apresentado grande potencial na formulação de substrato para a produção de mudas, se caracterizando como fonte alternativa de nutrientes para as plantas (Silva et al.,2021).

Plataformas de fenotipagem, por meio de imagens digitais, destacam-se como importante tecnologia para examinar ao longo do tempo o crescimento das plantas. Neste contexto, o

processamento de imagem e a determinação de características podem ser ferramentas eficientes para quantificar o crescimento e qualidade das mudas. A fenotipagem digital engloba o gerenciamento de dados, análise de imagem e visualização de resultados de conjuntos de dados fenotípicos em grande escala (Ribeiro et al., 2024).

Para o gerenciamento de informações ambientais e a análise de padrões em imagens obtidas por sensores multiespectrais, o uso de modelos lineares tem sido amplamente aplicado diversas áreas. (Gonçalves et al., 2016). Esses modelos destacam-se por sua simplicidade, interpretabilidade e eficiência na descrição de relações lineares entre variáveis, sendo ferramentas valiosas na modelagem de fenômenos complexos de forma objetiva e estatisticamente consistente (Gonçalves et al., 2016).

Santos et al. (2022) investigaram a aplicação de imagens multiespectrais de alta resolução na estimativa do Índice de Área Foliar (IAF) e do Índice de Área da Planta (IAP) em florestas secas do bioma Caatinga. O estudo comparou estimativas derivadas de sensores RGB, RGN e Landsat-8, utilizando o Índice de Vegetação por Diferença Normalizada (NDVI) como parâmetro de entrada. Os modelos demonstraram elevada relação com os valores de referência ($R^2 > 0,99$), destacando-se o período chuvoso, em que as imagens RGB registraram os maiores valores médios de LAI ($2,18 \text{ m}^2 \text{ m}^{-2}$) e PAI ($3,42 \text{ m}^2 \text{ m}^{-2}$). Por outro lado, as imagens RGN exibiram maior homogeneidade espacial e melhor capacidade de discriminação de alvos em campo, particularmente durante o período seco. Os autores concluíram que modelos simplificados aplicados a imagens são eficientes para o monitoramento ambiental em regiões semiáridas, permitindo a captação precisa da dinâmica sazonal da cobertura vegetal.

Cechi et al. (2021) empregaram imagens multiespectrais para estimar variáveis biométricas em cultivos de milho e soja, considerando sistemas irrigados e de sequeiro. A modelagem baseou-se no Índice de Vegetação por Diferença Normalizada (NDVI), processado na plataforma *Google Earth Engine*, e foi calibrada com dados coletados *in situ*. A estimativa da *fc* foi realizada por meio de equações empíricas adaptadas, enquanto o IAF foi obtido mediante regressão linear com o NDVI. Os resultados demonstraram elevada acurácia, com coeficientes de determinação R^2 superiores a 0,99 para a *fc* e entre 0,97 e 0,98 para o IAF, além de erros quadráticos médios RMSE de até 0,05 (para *fc*) e 0,61 para IAF.

Uma alternativa aos modelos lineares, são o uso de modelos não lineares e multivariados que apresentam vantagens como nos últimos anos, as Redes Neurais Artificiais (RNA) têm despertado um crescente interesse, sendo utilizadas com êxito em diversas áreas, como no gerenciamento de informações ambientais e no reconhecimento de padrões em imagens de câmeras multiespectrais (Gonçalves et al., 2016). As Redes Neurais Artificiais (RNA) destacam-se por sua estrutura paralela e distribuída, que proporciona uma habilidade única de aprendizado e generalização, possibilitando a resolução de problemas complexos (Binoti, 2013).

Um exemplo de aplicação das RNAs pode ser observado em Pereira et al. (2024) que investigaram a aplicação de imagens e algoritmos de aprendizado de máquina na estimativa da altura e do diâmetro de copa de cafeeiros (*Coffea arabica* L. cv. Yellow Bourbon). O estudo comparou o desempenho de diferentes algoritmos preditivos incluindo Random Forest, Random Tree e Redes Neurais Multilayer Perceptron (MLP) na modelagem desses parâmetros biométricos a partir de dados radiométricos das bandas RGB e infravermelho próximo (NIR). Os resultados indicaram que o algoritmo Random Tree, utilizando imagens RGB, apresentou a melhor precisão na estimativa da altura das plantas (RMSE = 0,11 m; RMSE% = 3,45%). Já para o diâmetro de copa, o modelo Random Forest, baseado em imagens RGN (Red-Green-NIR), obteve o menor erro (RMSE = 0,15 m; RMSE% = 8,16%).

O estudo tem como objetivo avaliar o uso de imagens multiespectrais em associação com modelos lineares múltiplos e Redes Neurais Artificiais (RNAs), na estimativa de atributos de crescimento das mudas de *Moringa Oleifera* Lam (Jean-Baptiste Lamarck) cultivada em diferentes tipos de substratos. Busca-se, por meio dessa abordagem, desenvolver uma metodologia precisa e não destrutiva para o monitoramento das mudas, visando subsidiar práticas de manejo mais eficientes e sustentáveis, com foco na melhoria da produtividade e da qualidade das mudas.

2. REVISÃO DE LITERATURA

2.1. *Moringa oleifera* Lam

A *Moringa oleifera* é uma planta angiosperma pertencente à família Moringaceae e à ordem Capparidales. Das 14 espécies conhecidas, nove são originárias da África, duas de Madagascar,

uma da Arábia e duas da Índia. Entre elas, a *Moringa oleifera* Lam é a mais conhecida (DE JESUS LOBO et al., 2023).

A espécie apresenta folhas pequenas, arredondadas, de cor verde pálida, decíduas, alternadas, pecioladas e compostas. Cada pina contém sete folíolos pequenos, ricos em proteínas e vitaminas, especialmente A e C. Esses folíolos possuem formato elíptico e podem estar dispostos lateralmente ou na posição terminal (CHITIYO et al., 2021).

A *Moringa* pode ser utilizada para diversas finalidades, incluindo a medicina tradicional. Em vários países, de acordo com o conhecimento popular de cada região, ela é empregada no combate e tratamento de inúmeras doenças, tais como: feridas e infecções na pele, congestão no peito, cólera, conjuntivite, tosse, diarreia, infecções nos olhos e ouvidos, febre, edema glandular, dores de cabeça, hipertensão, histeria, dores articulares, erupções cutâneas, psoríase, problemas respiratórios, escorbuto, deficiência em esperma, dor de garganta, tuberculose e no tratamento de vermes intestinais, entre outros (Oliveira, 2022).

No contexto da alimentação animal, a *Moringa* foi introduzida com o objetivo de melhorar a qualidade nutricional na região semiárida, especialmente durante o período de seca, quando a escassez de alimentos para o rebanho se torna uma das principais preocupações dos produtores e criadores. Grande parte das gramíneas não resiste à falta de água e às altas temperaturas típicas do Nordeste nessa época. Por isso, a *Moringa* foi adotada como uma nova matriz vegetal, graças ao seu alto teor de proteínas, presença de aminoácidos essenciais, rápida taxa de crescimento, elevada produção de fitomassa, facilidade de manejo e notável capacidade de rebrota (SILVA; PADILHA; PADILHA, 2021).

Na nutrição de ruminantes (ovinos, bovinos e caprinos), estudos destacam o grande potencial da *Moringa*, uma vez que ela apresenta uma alta taxa de decomposição no rúmen dos animais, convertendo-se em um alimento de elevado valor nutricional, especialmente para bovinos. Isso ocorre porque a planta possui, em suas folhas e galhos finos, uma concentração significativa de proteínas e fibras, que são absorvidas pelos animais e transformadas em energia (CARVALHO et al., 2023).

2.2. Variáveis Biométricas Em Mudas

2.2.1. Índice de Área Foliar (IAF)

O Índice de Área Foliar (IAF) é uma medida biofísica essencial, definida como a razão entre a área total das folhas de uma população vegetal e a área de solo que ela ocupa, expressa em metros quadrados de folha por metro quadrado de solo (Watson, 1947). Essa variável é importante na compreensão da dinâmica de ecossistemas e sistemas agrícolas, uma vez que está diretamente associada a processos fundamentais, como a interceptação da radiação solar, a eficiência fotossintética e a transpiração do dossel vegetal (Machado et al., 2002; Lima et al., 2012).

O IAF constitui um parâmetro determinante da capacidade assimilatória do dossel vegetal. Valores elevados indicam maior superfície foliar disponível para interceptação de radiação fotossinteticamente ativa (RFA), potencializando a produção de fotoassimilados desde que não haja limitações por outros fatores edafoclimáticos como por exemplo a disponibilidade hídrica, nutrientes ou temperatura (Faria et al., 2008).

Por outro lado, valores reduzidos de IAF frequentemente refletem condições de estresse, incluindo deficiência hídrica, ocorrência de desfolha ou incidência de patógenos, resultando em comprometimento do vigor vegetativo e da produtividade (Breda, 2003). Em ecossistemas naturais, como formações florestais e fitofisionomias campestres, o IAF exerce influência direta na regulação microclimática, afetando variáveis como temperatura do ar, umidade relativa e evapotranspiração, além de apresentar dinâmica sazonal intimamente relacionada ao estado fisiológico da vegetação (Duarte et al., 2016).

2.2.2. Métodos de determinação do IAF

Os métodos diretos envolvem a coleta de folhas e a medição de sua área foliar utilizando equipamentos como planímetros ou integradores ópticos como, LI-3100, LI-COR, ou ainda por meio da relação entre área foliar e massa seca obtida em amostras representativas (Jonckheere et al., 2004). Embora forneçam dados precisos, esses métodos demandam esforço amostral significativo e são inviáveis para monitoramento contínuo, além de implicarem a destruição do material vegetal (Lima et al., 2012).

Alternativamente, os métodos indiretos estimam o IAF com base na interação entre a radiação e o dossel vegetal, fundamentados em princípios de transferência radiativa (Norman & Campbell, 1989). Entre os principais instrumentos e técnicas destacam-se:

Tabela 1: Descrição dos principais métodos de determinação do Índice de Área Foliar (IAF)

Método	Princípio de funcionamento	Vantagens	Limitações	Referências
Direto (Planimetria / Integrador óptico)	Medição direta da área foliar (m^2) após coleta de folhas	Alta precisão; referência para calibração	Destrutivo; trabalhoso; inviável para séries temporais	Lima et al. (2012)
Relação área/massa foliar	Área determinada em amostra e extrapolada pela massa seca total de folhas	Simples; baixo custo	Depende de amostragem representativa; destrutivo	Jonckheere et al. (2004)
LAI-2000/LAI-2200	Medição da RFA transmitida em múltiplos ângulos	Rápido; não destrutivo	Requer luz difusa; calibração necessária	Faria et al. (2008)
Ceptômetro	Medição da RFA acima/abaixo do dossel e cálculo por Beer–Lambert	Integra espacialmente; rápido; não destrutivo	Influência de luz direta; depende de k preciso	Duarte et al. (2016); Machado et al. (2002)
Fotografia hemisférica	Análise da abertura do dossel via imagem “olho-de-peixe”	Documenta visualmente; útil em florestas	Processamento complexo; sensível à iluminação	Lima et al. (2012)
Sensoriamento remoto (MODIS)	Estimativa por algoritmos a partir de reflectância	Abrange grandes áreas; séries temporais	Resolução limitada; validação necessária	Myneni et al. (2002); Duarte et al. (2016)

O ceptômetro é um instrumento amplamente utilizado para estimar o IAF e a interceptação luminosa de dosséis vegetais de forma rápida e não destrutiva. O princípio de funcionamento baseia-se na medição da radiação fotossinteticamente ativa (RFA) incidente acima do dossel e transmitida até o nível da superfície. A partir da razão entre esses valores e de parâmetros estruturais do dossel (como ângulo foliar médio e coeficiente de extinção de luz, k), é possível estimar o IAF utilizando modelos de atenuação da radiação, como a Lei de Beer–Lambert (Norman & Campbell, 1989; Faria et al., 2008).

O equipamento consiste em uma barra com múltiplos sensores lineares de PAR (geralmente 80–100 cm de comprimento), que integram as leituras ao longo de seu eixo. Essa configuração permite capturar a variabilidade espacial da luz transmitida sob o dossel, reduzindo erros associados a medições pontuais (Lazzarini et al., 2017)

Para a determinação do IAF com ceptômetro, realizam-se medições simultâneas ou quase simultâneas da RFA acima e abaixo da copa (equação 2). Leituras acima do dossel podem ser obtidas diretamente, quando há acesso, ou por um sensor de referência instalado em área aberta próxima ao experimento. A fração de radiação interceptada (fIPAR) (equação 1) é calculada como:

$$fIPAR = 1 - \frac{RFA_{abaixo}}{RFA_{acima}} \quad (1)$$

Com a fIPAR, o IAF é estimado pela equação:

$$IAF = - \frac{\ln \left(\frac{RFA_{acima}}{RFA_{abaixo}} \right)}{K} \quad (2)$$

O ceptômetro mostra-se adequado para mudanças em viveiros devido à sua natureza não destrutiva, permite produtividade repetida sem comprometer o material vegetal, o que é essencial para monitoramento contínuo do crescimento em estágios iniciais. Em mudas florestais, ele quantifica o índice de área foliar com precisão, correlacionando-se a parâmetros morfológicos como altura e diâmetro do coletor, facilitando a seleção de plantas de alta qualidade sem usar métodos invasivos. Essa metodologia é particularmente vantajosa em viveiros, onde o espaço é limitado e a avaliação rápida de sombreamento e desenvolvimento foliar otimiza a produção em larga escala (Kunstman et al., 2022)

2.2.3. Diâmetro do coleto (DC) e índice de área foliar (IAF)

O diâmetro do coleto (DC) e destacam-se como dois dos parâmetros mais consistentes e robustos para a avaliação da qualidade de mudas produzidas em viveiros. Segundo Silva (2020), o diâmetro do coleto é um indicador direto do vigor estrutural da muda, refletindo a espessura do caule e a capacidade da planta de suportar o estresse mecânico e hídrico após o transplântio. De

acordo com Pacheco et al. (2021), mudas com maior diâmetro acumulam mais reservas e tendem a desenvolver sistemas radiculares mais eficientes, o que aumenta a sobrevivência e acelera o crescimento inicial em campo.

O Índice de Área Foliar (IAF) tem sido amplamente empregado como variável fisiológica essencial para mensurar a capacidade fotossintética das mudas. Em seu estudo, Rodrigues et al. (2023) reforçam que o IAF expressa a proporção de superfície foliar ativa por unidade de solo, estando diretamente associado ao acúmulo de biomassa e à eficiência de uso da luz. (Macedo et al., 2025) argumentam que o IAF, quando avaliado juntamente com o DC, permite uma compreensão mais precisa do desempenho inicial das mudas, visto que combina informações estruturais e fisiológicas.

Para espécies de rápido crescimento, como *Moringa oleifera* Lam., existe uma forte integração entre essas duas métricas. Segundo Almeida et al. (2027), o DC apresenta correlação positiva com o IAF, indicando que mudas mais robustas tendem a suportar maior área foliar sem comprometer a estabilidade mecânica. Estudos conduzidos por Souza et al. (2017) demonstram que a combinação de alto DC e alto IAF favorece maior eficiência fotossintética, maior massa seca acumulada e melhor desenvolvimento radicular. Matias et al. (2023) apontam que a avaliação conjunta desses parâmetros é fundamental para selecionar mudas de *M. oleifera* capazes de manter crescimento vigoroso sob condições adversas, incluindo restrição hídrica e alta irradiância.

2.3.Fenotipagem digital e imagens multiespectrais em plantas

A fenotipagem digital refere-se ao conjunto de técnicas que utilizam sensores de imagem e métodos computacionais para quantificar características morfológicas, fisiológicas e biofísicas das plantas de forma automatizada e não destrutiva. Técnicas baseadas em imagens têm avançado significativamente com o uso de sensores que capturam dados no visível e fora dele, aumentando a capacidade de monitorar com precisão grandes populações de plantas em tempo real (Gill et al., 2022).

Quando a radiação eletromagnética incide sobre um objeto vegetal, ocorre uma interação complexa entre fótons e a estrutura das folhas, parte da energia é absorvida por pigmentos como clorofila e carotenoides, parte é transmitida e parte é refletida de volta ao sensor (figura 1). A

reflectância espectral medida em diferentes faixas do espectro, é a base fundamental da extração de informações fenotípicas a partir de imagens digitais. Em imagens obtidas por sensores, cada pixel representa um ponto espacial, com valores digitais associados à intensidade refletida em cada banda do sensor, os quais são transformados em matrizes digitais para posterior análise quantitativa (Prado, 2023).




Figura 1. Formação de imagens digitais

Sensores tradicionais RGB (Red, Green, Blue) coletam intensidades de reflectância nas três bandas do espectro visível (aproximadamente 400–700 nm). A decomposição de uma imagem RGB em suas bandas individuais possibilita análises separadas da resposta espectral em cada faixa, que pode ser correlacionada com características fenotípicas como cor, vigor e atributos morfológicos de plantas em estágios iniciais de desenvolvimento (Tharuka; Kularathna; Ray, 2025). No entanto, apesar de eficazes para traços morfológicos, sensores RGB sozinhos têm limitações para capturar variações fisiológicas mais sutis ligadas à saúde e ao estresse da planta, eventos que se refletem em regiões fora do visível (Tharuka; Kularathna; Ray, 2025).

Sensores multiespectrais ampliam a capacidade de análise ao incluir bandas fora da faixa visível, especialmente no infravermelho próximo (NIR) (figura 2), onde plantas geralmente apresentam alta reflectância devido à estrutura das células foliares. Essa inclusão permite derivar índices espectrais, como o NDVI (Normalized Difference Vegetation Index), que quantifica a diferença entre as reflectâncias NIR e vermelha para estimar vigor e biomassa vegetal (Gill et al., 2022). Câmeras multiespectrais modernas, inclusive modelos comerciais específicos para

agricultura, podem substituir a banda azul pela banda NIR ou combiná-la com bandas adicionais, melhorando a sensibilidade à variabilidade fisiológica do dossel vegetal uma abordagem útil para monitoramento de estresse hídrico, deficiência nutricional e produtividade potencial (Prado, 2023)




Figura 2. Cobertura Espectral de Sensores RGB e Multiespectral

Em imagens multiespectrais, sensores capazes de capturar bandas no visível e no infravermelho próximo têm se mostrado ferramentas essenciais para estimar índices como NDVI, GNDVI, SAVI e outros correlacionados ao vigor e ao estado fisiológico das plantas. A multiespectralidade amplia a capacidade de detectar variações sutis associadas ao estresse hídrico, deficiência nutricional ou redução da atividade fotossintética, fenômenos que muitas vezes não são perceptíveis a olho nu (Badagliacca et al., 2023).

Em viveiros e sistemas de produção de mudas, a fenotipagem digital tem ganhado relevância devido à necessidade de monitoramento rápido e preciso de variáveis estruturais como diâmetro do coleto, área foliar e uniformidade. Segundo Silva et al. (2024), o uso de câmeras multiespectrais e ferramentas digitais permite acompanhar o crescimento das mudas de forma padronizada, com suporte a decisões de manejo, seleção e classificação automática. Estudos recentes, como o de Medeiros e Carvalho (2025), indicam que métodos digitais reduzem o tempo de avaliação, aumentam a repetibilidade e auxiliam na identificação de mudas com maior potencial de desempenho em campo.

Borges et al. (2020) utilizaram fenotipagem digital baseada em imagens RGB e multiespectrais para estimar atributos morfológicos e fisiológicos em mudas de eucalipto, integrando análises de área foliar, índice de vegetação e crescimento inicial. O processamento das imagens foi realizado em pipeline semiautomatizado com técnicas de segmentação e extração de índices espectrais, destacando-se o NDVI e o VARI, que apresentaram forte correlação com medidas obtidas *in situ*. De acordo com os autores, a abordagem permitiu estimativas precisas de biomassa aérea e vigor, com coeficientes de determinação superiores a 0,90 para todas as variáveis analisadas.

Yang et al. (2020) também demonstraram o potencial da fenotipagem digital ao empregar plataformas automatizadas para quantificar área foliar, arquitetura e acúmulo de biomassa em culturas agrícolas, evidenciando ganhos expressivos de velocidade e reprodutibilidade.

2.4. Índices de vegetação

Os índices de vegetação (VIs) são transformações espectrais, derivadas de bandas refletidas (como vermelho, verde, azul e infravermelho próximo), criadas para realçar características estruturais e fisiológicas da vegetação, como densidade de dossel, vigor, área foliar equivalente (IAF), biomassa e saúde geral da planta. Estes índices permitem comparações espaciais e temporais consistentes, com dados de sensoriamento remoto ou proximal, e são amplamente utilizados em agricultura, ecologia e monitoramento florestal (Yan et al., 2025)

2.4.1. NDVI (*Normalized Difference Vegetation Index*)

O *Normalized Difference Vegetation Index* (NDVI) é o índice mais utilizado em sensoriamento remoto e fenotipagem. Ele é calculado a partir da diferença entre a reflectância no infravermelho próximo (NIR) e no vermelho (RED) (equação 3), normalizada pela soma dessas reflectâncias (Nițu et al., 2025). Valores próximos a +1 indicam vegetação densa e saudável, enquanto valores mais baixos (próximos de zero ou negativos) podem indicar solo exposto, vegetação pouco vigorosa, água ou áreas sem vegetação (Stamford et al., 2023). Devido à sua sensibilidade à biomassa verde e à saúde da vegetação, o NDVI tem sido amplamente empregado para estimativas indiretas de IAF, biomassa aérea e vigor foliar em culturas agrícolas e florestais (Ayanlade, 2017).

$$NDVI = \frac{(NIR-RED)}{(NIR+RED)} \quad (3)$$

2.4.2. GNDVI (*Green Normalized Difference Vegetation Index*)

O *Green Normalized Difference Vegetation Index* (GNDVI) é uma variação do NDVI que utiliza notadamente a banda verde em substituição à banda vermelha, combinando-a com a banda NIR (equação 4). A proposta desse índice é aumentar a sensibilidade à clorofila e ao conteúdo foliar, tornando-o apto para detectar variações na saúde da vegetação, especialmente em termos de pigmentação e atividade fotossintética (Silva et al., 2024). Estudos atuais indicam que o GNDVI apresenta bom desempenho em culturas agrícolas e florestais, sendo capaz de indicar bem o vigor, o conteúdo de pigmentos e possíveis deficiências nutricionais especialmente nitrogênio antes que estas se manifestem visualmente (Vidican et al., 2023).

$$GNDVI = \frac{(NIR-GREEN)}{(NIR+GREEN)} \quad (4)$$

2.4.3. RVI (*Ratio Vegetation Index*)

O *Ratio Vegetation Index* (RVI), ou Índice de Razão de Vegetação, é um dos índices mais simples: consiste na razão entre a reflectância no infravermelho próximo (NIR) e a reflectância no vermelho (RED)(equação 5). Porém, como se baseia em razão simples, o RVI tende a ser mais sensível a variações de solo exposto, sombras e ruído atmosférico, o que pode limitar sua precisão em regiões com cobertura vegetal baixa ou heterogênea. Apesar dessas limitações, continua sendo útil em cenários onde a vegetação apresenta cobertura razoável, e quando se busca uma métrica direta e de fácil cálculo para estimativas de biomassa ou densidade de dossel (Xue; Su, 2017).

$$RVI = \frac{NIR}{RED} \quad (5)$$

2.4.4. CVI (*Chlorophyll Vegetation Index* (ou índices similares sensíveis à clorofila))

O *Chlorophyll Vegetation Index* (CVI) destaca-se por sua elevada sensibilidade ao conteúdo relativo de clorofila. Ele combina informações das bandas visíveis (como GREEN ou

RED) com NIR, permite detectar variações fisiológicas de forma mais refinada do que índices convencionais baseados apenas em NIR-RED, especialmente quando se busca estimar teor de pigmentos, vigor ou estresse nutricional (Coswosk et al., 2024) (equação 6). O uso de CVI e índices semelhantes tem se mostrado eficiente para identificar estresses leves que ainda não se manifestam visualmente por exemplo, alterações iniciais na capacidade fotossintética ou redução no teor de pigmentos o que torna esses índices bastante promissores em estudos de fenotipagem multiespectral e de alta produtividade (Li et al., 2024).

$$RVI = \frac{NIR}{GREEN^2} \quad (6)$$

Embora índices como Soil-Adjusted Vegetation Index (SAVI) ou índices baseados em red-edge como Red-Edge Chlorophyll Index (RECI) sejam ainda comuns nas aplicações práticas, a literatura recente destaca um número crescente de índices desenvolvidos para estimar conteúdos de clorofila, vigor fisiológico e detectar estresse nutricional ou hídrico precocemente (Tang et., al 2022). Esses índices que podemos agrupar genericamente como “índices de clorofila/vegetação” (CVI, em sentido amplo) combinam bandas visíveis (geralmente verde ou vermelha) com NIR ou red-edge, conforme a disponibilidade espectral, com o objetivo de captar alterações no teor de pigmentos, densidade foliar ou estresse antes da manifestação visual (Qiao et al., 2022).

O uso desses índices é importante quando o objetivo é avaliar a saúde, o vigor, o estresse nutricional, pois oferecem uma visão mais sensível e precoce sobre o estado fisiológico complementando índices estruturais ou de biomassa como *Normalized Difference Vegetation Index* (NDVI) ou razão NIR/RED (RVI) os quais muitas vezes saturam em dosséis densos ou não capturam alterações sutis na clorofila (Li et al., 2024).

2.5. Correção Radiométrica

A correção radiométrica é o processo que ajusta as imagens capturadas por sensores ópticos para remover desvios sistemáticos causados tanto pelas características do próprio sensor quanto pelas condições ambientais (Xie; Shen; Cen, 2024). Todos os sensores remotos registram valores em unidades arbitrárias, números digitais sem significado físico até serem calibrados, ou seja, sem essa correção os NDs são sem sentido do ponto de vista científico (Ma et al., 2019). Na prática, a correção radiométrica visa converter esses D em reflectância (ou radiância) comparável, compensando fatores como ganho do sensor, tempo de exposição, nível de fundo e calibração espectral (Daniels et al., 2023).

Em experimentos de campo, a aplicação da correção radiométrica é especialmente importante devido às variações de iluminação e atmosfera que ocorrem ao longo da aquisição de dados (Xue et al., 2023; Dimiyati et al., 2023). Alterações na irradiância solar causadas por diferentes posições do Sol, cobertura de nuvens e razão entre luz solar direta e difusa bem como mudanças no ângulo Sol-objeto-sensor e efeitos de dispersão e absorção atmosférica, geram flutuações nos sinais medidos (Aasen et al., 2018). Se não corrigidos, esses fatores podem introduzir erros significativos na estimativa da reflectância real dos alvos vegetais (Xue et al., 2023). Além disso, ruídos intrínsecos do sensor, como ruído térmico e vinhetamento óptico, também afetam os valores brutos capturados. Por isso, a literatura recomenda que imagens de drones ou câmeras multiespectrais sejam calibradas radiometricamente para permitir comparabilidade espectral entre as imagens realizados em condições distintas (Dimiyati et al., 2023).

Os métodos de correção radiométrica mais utilizados envolvem o uso de alvos de referência (painéis-padrão) ou sensores de irradiância (AASEN Et al., 2018). Em laboratório ou em condições controladas, podem-se usar lâmpadas de calibração e painéis referenciais com reflectância conhecida, como painéis Spectralon branco e cinza, para determinar fatores de conversão que transformam os DN's em reflectância (Ma et al., 2019). Em campo, destaca-se o método da linha empírica (Empirical Line Method – ELM), adquirindo-se imagens de alvos de referência com reflectâncias medidas em laboratório, estabelece-se uma relação linear entre os DN's observados e

essas reflectâncias conhecidas, permitindo converter todas as outras medidas da imagem em reflectância (Ma et al., 2019).

Em princípio, dois alvos, um de reflectância alta e outro baixa, são necessários para definir a inclinação e o intercepto da relação linear, mas implementações simplificadas, que utilizam apenas um painel claro e assumem intercepto fixo, também são reportadas na literatura (Aasen et al., 2018). Complementarmente, pode-se empregar sensores de luz ambiente (irradiância descendente) montados no solo para registrar continuamente a irradiância solar real durante as imagens, permitindo ajustar variações na iluminação incidente sem depender exclusivamente de alvos estáticos (Wang et al., 2024). De modo geral, tanto o uso de painéis calibrados quanto o de sensores auxiliares visa compensar oscilações externas e produzir imagens espectralmente consistentes (Johansen et al., 2019).

A etapa de correção radiométrica é crucial para obter índices espectrais confiáveis. Índices como NDVI ou NDRE são calculados a partir de razões entre reflectâncias em diferentes bandas, de modo que erros nos valores absolutos de reflectância se refletem diretamente nesses índices (WANG Et al., 2024). Imagens multiespectrais precisam ser convertidas em dados de reflectância antes de serem interpretadas ou utilizadas no cálculo de índices de vegetação, pois imagens não calibradas podem apresentar vieses ou elevada variabilidade espectral quando comparadas entre diferentes dias ou horários (Xue et al., 2023). Estudos indicam que a calibragem radiométrica produz mapas de reflectância mais acurados e, conseqüentemente, índices vegetativos mais consistentes e comparáveis (Johansen et al., 2019). Em suma, sem a correção radiométrica adequada, análises temporais e quantitativas, como estimativas biométricas ou avaliação fenológica, podem ser seriamente comprometidas, uma vez que parte das variações observadas pode ser atribuída às condições de aquisição e não a diferenças reais na vegetação (Ang et al., 2024).

Se tratando de sensores multiespectrais baseados em câmeras, como a câmera MAPIR Survey3, que opera em bandas visíveis e no infravermelho próximo, aplicam-se as mesmas preocupações discutidas anteriormente (Dimyati et al., 2023). Essas câmeras exigem alvos de referência padronizados ou sensores de irradiância ambiente para permitir a conversão dos DN's capturados em valores de reflectância percentuais após o processamento (Dimyati et al., 2023). Assim,

utilizando painéis calibrados em branco ou cinza e considerando as condições de luz natural, as imagens multiespectrais do Survey3 podem ser calibradas para gerar reflectâncias confiáveis em suas bandas (R, G e NIR), garantindo que os índices espectrais derivados reflitam efetivamente as propriedades das mudas de *Moringa oleifera* e não artefatos das variações de aquisição, assegurando a validade científica das análises realizadas (Johansen et al., 2019).

2.6. Modelos Lineares Múltiplos

Um modelo linear múltiplo (MLM) é uma generalização da regressão linear simples em que uma variável dependente contínua Y é explicada por várias variáveis independentes (Haghverdi, 2023). Formalmente, pode-se escrever para cada observação i :

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + \epsilon_i \quad (7)$$

Onde:

- ✚ Y_i : valor da variável dependente (ou resposta) observado para a i -ésima observação;
- ✚ β_0 : intercepto do modelo; representa o valor esperado de Y quando todas as variáveis explicativas X são iguais a zero;
- ✚ $\beta_1, \beta_2, \dots, \beta_k$: coeficientes de regressão associados às variáveis explicativas; indicam a variação média esperada em Y para um aumento unitário em X_j , mantendo as demais variáveis constantes;
- ✚ $X_{1i}, X_{2i}, \dots, X_{ki}$: valores das variáveis independentes (ou explicativas) para a i -ésima observação;
- ✚ k : número total de variáveis explicativas no modelo;
- ✚ ϵ_i : termo de erro aleatório, que representa a parcela da variabilidade de Y_i não explicada pelas variáveis XXX ; geralmente assume-se que possui média zero e variância constante.

Os modelos lineares constituem uma das abordagens estatísticas mais consolidadas na agricultura e no sensoriamento remoto, tendo sido amplamente empregados para explicar associações entre variáveis espectrais e atributos biofísicos das plantas. Segundo Gonçalves et al. (2016), esses modelos se destacam por sua simplicidade matemática e pela facilidade de interpretação dos coeficientes, o que permite compreender a magnitude e o sentido da contribuição de cada variável espectral na predição de parâmetros biométricos. De acordo com (Lafetá et al.,

2024), essa característica torna os modelos lineares ferramentas importantes para análises iniciais ou para situações em que a estrutura espectral da vegetação apresenta baixa complexidade.

Santos et al. (2022) observaram que, embora modelos lineares apresentem alta correlação com o IAF em determinadas condições, seu desempenho tende a diminuir quando há aumento da densidade do dossel ou quando ocorre saturação espectral situação comum em índices como NDVI e SAVI. De acordo com Debastiani et al. (2019), a multicolinearidade inerente às bandas espectrais é outro fator que compromete a precisão do modelo linear, uma vez que a forte correlação entre preditores aumenta a variabilidade dos coeficientes estimados, dificultando sua interpretação.

Mesmo diante dessas limitações, os modelos lineares seguem relevantes em estudos envolvendo mudas ou plantas jovens, em que o dossel ainda é pouco denso e a resposta espectral tende a apresentar comportamento mais próximo da linearidade. Segundo Chechi et al. (2021), essa característica explica a elevada eficiência de modelos lineares na estimativa de IAF em estágios iniciais de crescimento, quando a interferência do solo é menor e o desenvolvimento foliar é relativamente homogêneo.

2.7.Redes Neurais Artificiais

As Redes Neurais Artificiais (RNAs) são modelos computacionais inspirados na estrutura do sistema nervoso biológico, concebidos para aprender a resolver problemas complexos por meio de exemplos dados (Chan et al., 2023).

As Redes Neurais Artificiais (RNAs) constituem um dos pilares da Aprendizagem de Máquina (Machine Learning) e das metodologias de Inteligência Artificial (IA) contemporâneas. Inspiradas na estrutura das redes neurais biológicas, tais como aquelas observadas no cérebro humano, as RNAs são modelos computacionais capazes de aprender relações complexas entre variáveis por meio da exemplificação de dados (Ahmed, 2023). A utilização de RNAs tem-se expandido rapidamente devido à sua versatilidade em tarefas de classificação, regressão e reconhecimento de padrões, especialmente em problemas não lineares para os quais métodos tradicionais apresentam desempenho inferior (Ahmed, 2023).

2.7.1. Estrutura de uma Rede Neural Artificial

As RNAs são geralmente estruturadas em três tipos básicos de camadas: (i) camada de entrada, que recebe os dados brutos a serem processados; (ii) uma ou mais camadas ocultas, que realizam transformações intermediárias nos dados por meio de funções de ativação; e (iii) a camada de saída, que produz a predição ou classificação final (Unni et al., 2024). Em arquiteturas tradicionais de redes feedforward, os neurônios de cada camada recebem sinais apenas da camada anterior e transmitem suas saídas à próxima camada, caracterizando um fluxo de informação unidirecional (Unni et al., 2024).

A função de ativação é um componente essencial para introduzir não linearidade ao sistema, permitindo que RNAs aprendam e representem relações que não podem ser capturadas por modelos estritamente lineares. As funções de ativação mais utilizadas incluem sigmoide, tangente hiperbólica (tanh) e ReLU (Rectified Linear Unit), cada uma com características que influenciam a estabilidade e a rapidez da aprendizagem.

2.7.2. Redes Multicamadas (Multilayer Perceptrons)

Uma das arquiteturas mais tradicionais e amplamente utilizadas de RNA é o Perceptron Multicamadas (Multilayer Perceptron – MLP), composto por múltiplas camadas de neurônios totalmente conectadas (feedforward), tipicamente incluindo a camada de entrada, uma ou mais camadas ocultas e uma camada de saída (Lima et al., 2016) (figura 3). A capacidade do MLP de resolver problemas que não são linearmente separáveis baseia-se justamente na combinação de várias camadas e funções de ativação não lineares, superando as limitações do perceptron simples (Lima et al., 2016). A figura ilustra a estrutura de uma Rede Neural Artificial do tipo *Perceptron Multicamadas* (MLP), composta por uma camada de entrada, múltiplas camadas ocultas totalmente conectadas e uma camada de saída, típica de problemas de regressão ou classificação supervisionada.




Figura 3.Arquitetura de uma Rede Neural Artificial Multicamadas (Perceptron Multicamadas - MLP)

Fonte: (Chan et al., 2023)

Onde:

- ✚ $x_1, x_2, \dots, x_n$: representam as variáveis de entrada do modelo, correspondentes aos atributos ou características observadas do sistema analisado;
- ✚ Input layer (Camada de entrada): é responsável por receber os dados brutos e repassá-los para a rede, sem realizar processamento computacional;
- ✚ Hidden layers (Camadas ocultas): são responsáveis pelo processamento intermediário das informações, realizando combinações lineares das entradas ponderadas por pesos sinápticos e aplicando funções de ativação não lineares;
- ✚ $w_{11} \dots w_{21}$: representam os pesos sinápticos associados às conexões entre os neurônios das diferentes camadas, os quais determinam a influência relativa de cada entrada no neurônio subsequente;
- ✚ As bias :(termos de polarização): representados pelos neurônios adicionais conectados às camadas ocultas, atuam como parâmetros de ajuste do limiar de ativação dos neurônios;
- ✚ Output layer (Camada de saída) :é responsável por fornecer o resultado final da rede;

✚ $y_1, y_2, \dots, y_m$: representam as saídas do modelo, correspondentes às variáveis estimadas ou classes previstas pela rede neural;

O treinamento de redes multicamadas é realizado por meio de algoritmos de otimização, como o gradiente descendente com retropropagação do erro (backpropagation), que ajusta os pesos das conexões de forma a minimizar uma função custo baseada no erro entre a saída prevista e a saída real. Essa abordagem iterativa de aprendizado supervisionado tem se mostrado eficaz em tarefas como previsão de séries temporais, classificação de imagens e regressão de variáveis contínuas. (Dos Santos; Chaucoski, 2021).

As Redes Neurais Artificiais (RNAs) têm sido amplamente adotadas no monitoramento vegetal devido à sua capacidade de modelar relações não lineares e detectar padrões complexos em dados espectrais. Segundo Gonçalves et al. (2016), a estrutura paralela e distribuída das RNAs permite que elas aprendam e generalizem informações mesmo em cenários com grande variabilidade e multicolinearidade entre preditores.

Oliveira et al. (2024) demonstraram que algoritmos de aprendizado de máquina, incluindo RNAs, superaram significativamente modelos lineares na estimativa de altura, perfilhamento e diâmetro de colmos em cana-de-açúcar. De acordo com Fernandes et al. (2019), a aplicação de MLP em mudas florestais permitiu estimativas mais precisas do IAF e massa seca, evidenciando a aplicabilidade da técnica em sistemas com estrutura foliar em desenvolvimento. Pereira et al. (2024) ressaltam que RNAs são especialmente eficientes em ambientes de viveiro, onde a variabilidade entre plantas é alta e pequenos incrementos fisiológicos precisam ser detectados. Segundo os autores, a capacidade de capturar padrões sutis, invisíveis aos métodos tradicionais, torna as RNAs uma ferramenta promissora para o monitoramento automatizado em viveiros florestais.

Por outro lado, Fernandes et al. (2019) demonstram que, à medida que a planta cresce e sua estrutura se torna mais complexa, métodos lineares passam a falhar, especialmente devido à saturação espectral e às interações não lineares entre folhas, ramos e o ângulo de incidência da radiação. De acordo com Oliveira et al. (2024), algoritmos não lineares, como as RNAs, conseguem superar essas limitações, capturando nuances espectrais e morfológicas que não são detectadas por modelos lineares.

3. MATERIAIS E MÉTODOS

3.1.Caracterização das etapas metodológicas

O presente estudo foi conduzido a partir de duas etapas metodológicas distintas. A primeira corresponde à parte experimental de campo, realizada no viveiro florestal da Universidade Federal Rural do Rio de Janeiro, envolvendo a produção e condução das mudas de *Moringa oleifera* Lam., a aplicação dos tratamentos experimentais, a coleta das variáveis biométricas (índice de área foliar e diâmetro do coleto) e a aquisição das imagens multiespectrais ao longo do desenvolvimento das mudas.

A segunda etapa refere-se à fase de desenvolvimento computacional e processamento digital das imagens, que compreendeu a correção radiométrica, a segmentação, o cálculo da reflectância, a extração dos índices de vegetação e a implementação das rotinas computacionais, incluindo o software RAIC. Essa etapa foi realizada com suporte técnico do respectivo grupo de pesquisa, não sendo caracterizada como atividade experimental de campo.

3.2.Localização da área experimental

O experimento foi conduzido no viveiro Florestal “Fernando Luiz de Oliveira Capellão”, localizado no Instituto de Florestas no campus da Universidade Federal Rural do Rio de Janeiro (UFRRJ), município de Seropédica (22°46’29.55” S e 43°41’12.16” O), Estado do Rio de Janeiro, Brasil. O clima regional é do tipo Aw (Clima de savana) segundo a classificação climática de Köppen-Geiger, com médias anuais de precipitação entre 1.300 a 1.600 mm e temperatura do ar entre 22 a 24° C, respectivamente (Alvares et al., 2013).

A semeadura ocorreu em 10 de abril de 2025, sendo realizado o desbaste das mudas em 30 de abril de 2025. A aleatorização dos tratamentos foi efetuada em 05 de maio de 2025. A coleta de imagens multiespectrais e a mensuração dos atributos de crescimento tiveram início em 08 de maio de 2025, sendo realizadas em intervalos de 7 dias, totalizando seis campanhas de coleta, conforme apresentado na tabela 2. As avaliações se estenderam até 19 de junho de 2025, acompanhando o desenvolvimento das mudas ao longo do período experimental.

Os dados meteorológicos foram obtidos a partir da estação meteorológica da Embrapa Agrobiologia, localizada em Seropédica–RJ, considerando exclusivamente o intervalo entre 11h e 13h, período correspondente à realização das coletas de imagens e das mensurações dos atributos de crescimento. Para cada dia de coleta, foram determinadas as médias de temperatura do ar e umidade relativa, bem como a precipitação pluviométrica acumulada e a radiação solar média nesse intervalo horário, de forma a representar as condições ambientais no momento das avaliações (tabela 2).

Tabela 2. Condições meteorológicas médias entre 11h e 13h nos dias de coleta

Data de coletas	Temperatura do ar (°C)	Umidade relativa (%)	Precipitação (mm)	Radiação solar (kJ m⁻²)
08/05/2025	26,3	64,6	0	1310,00
15/05/2025	22,4	73,3	0	1185,80
22/05/2025	23,3	77,3	0	1152,83
29/05/2025	24,6	71	0	223,50
05/06/2025	26,6	62,3	0	1096,03
19/06/2025	24,5	61,6	0	1033,83

3.3. Delineamento Experimental e Condução da pesquisa

O experimento foi conduzido em delineamento inteiramente casualizado (DIC), com seis tratamentos e seis repetições. Cada bandeja não constituiu uma parcela única, sendo compartilhada por dois tratamentos distintos. Em cada bandeja foram alocadas duas parcelas experimentais, correspondentes a dois tratamentos, sendo que cada tratamento foi composta por 12 mudas, cultivadas individualmente em recipientes (saquinhos). Dessa forma, cada bandeja continha 24 mudas, totalizando 360 mudas no experimento (6 tratamentos × 6 repetições × 12 mudas).

Os tratamentos consistiram em diferentes substratos formulados à base de biossólido (BIO), oriundo de estações de tratamento de esgoto da Companhia Estadual de Águas e

Esgotos do Rio de Janeiro (CEDAE), do composto orgânico comercial Fertilurb (FERT), produzido pela Companhia de Limpeza Urbana do Rio de Janeiro (COMLURB), e de um substrato comercial (SC), utilizado como tratamento controle de referência.

As proporções dos constituintes que definem os seis tratamentos são as seguintes: T1: 100% BIO; T2: 100% FERT; T3: 100% Substrato Comercial; T4: 75% BIO e 25% FERT; T5: 50% BIO e 50% FERT; T6: 25% BIO e 75% FERT. As misturas foram homogeneizadas usando betoneira profissional e colocadas em saquinhos para mudas de polietileno de alta densidade, com dimensões de 15 x 25 cm. A semeadura foi realizada, alocando duas sementes pré-selecionadas de *Moringa oleífera lam* por recipiente na bandeja (figura 4).



Figura 4. Semeadura da moringa olifeira lam.

As sementes de *Moringa oleífera* foram adquiridas em uma loja de comércio virtual por uma empresa registrada no Registro Nacional de Sementes e Mudas (RENASSEM), garantindo a qualidade e procedência das sementes utilizadas no experimento.

3.4. Fenotipagem digital e coleta de variáveis biométricas

As variáveis biométricas mensuradas foram o diâmetro do caule e o índice de área foliar (IAF). O diâmetro do caule foi determinado utilizando um paquímetro digital (figura 5A). Para cada tratamento, as doze mudas que compunham a parcela experimental foram mensuradas, sendo realizada uma leitura do diâmetro do caule por planta. O valor representativo do diâmetro do caule

para cada tratamento foi obtido a partir da média aritmética das medições realizadas nas 12 plantas, sendo este valor utilizado nas análises subsequentes.

O índice de área foliar (IAF) foi obtido com o auxílio de um ceptômetro AccuPAR LP-80 (Figura 5 B), equipamento destinado à medição indireta da área foliar a partir da interceptação da radiação fotossinteticamente ativa (PAR) (figura 5A). O aparelho possui uma barra de 80 cm composta por 80 sensores PAR linearmente espaçados, além de um sensor PAR externo, utilizados para a estimativa da interceptação luminosa pelo dossel.

O equipamento foi previamente configurado com data, horário e localização em cada dia de avaliação. As medições foram realizadas posicionando-se a barra do ceptômetro próxima ao nível do substrato, entre as mudas, de forma a representar a interceptação luminosa do dossel. Em função da disposição das mudas em recipientes individuais, foram utilizados cinco elementos sensores da barra, adequados à largura da parcela avaliada.

Para cada parcela experimental, foram realizadas quatro medições, posicionadas no centro do conjunto de 12 mudas, sendo duas medições em cada lado da parcela, alternando-se a posição do equipamento. O valor de IAF representativo de cada parcela foi obtido a partir da média aritmética das quatro medições, tomando-se o cuidado de evitar sombreamento do dossel durante as leituras.



A



B

Figura 5. Medições tradicionais do IAF (A), Diâmetro do caule (B)

As imagens multiespectrais foram obtidas em 6 estágios de crescimento, utilizando uma câmera MAPIR Survey3, acoplada a um tripé fixado a 1,50 m de altura em relação ao topo das mudas (figura 6). A câmera foi configurada para capturar faixas espectrais correspondentes ao vermelho (660 nm), verde (550 nm) e infravermelho próximo (850 nm).



Figura 6. Tripé fixo utilizado para acoplar a câmera mapir survey 3.

As aquisições das imagens foram realizadas nos mesmos dias em que ocorreram as mensurações das variáveis biométricas, de forma a garantir a correspondência temporal entre os dados espectrais e os atributos de crescimento avaliados. As imagens foram coletadas no período entre 11h30 e 12h30, intervalo de maior intensidade de radiação solar, evitando-se condições de sombreamento causadas por nuvens ou estruturas próximas à área de captura.

A câmera foi configurada com resolução de 12 megapixels, sensibilidade ISO 1600, balanço de branco no modo customizado, compensação de exposição ajustada para +0.0, e velocidade do obturador em modo automático, mantendo-se constantes os parâmetros durante todas as campanhas de aquisição (Figura 7).




Figura 7. Camera Mapir Survey 3 RGNIR

3.5. Calibração radiométrica

A calibração radiométrica foi realizada com o objetivo de corrigir os valores de reflectância obtidos nas imagens multiespectrais e eliminar as interferências provocadas por variações de iluminação. Para esse procedimento, utilizou-se uma placa de Teflon.

A reflectância da placa foi medida em ambiente controlado de laboratório, utilizando um espectro radiômetro (FieldSpec 4 Standard-Res). A medição em ambiente fechado foi adotada por recomendação técnica, considerando que o Teflon, por ser um material Lambertiano, mantém propriedades de reflectância estáveis independentemente da fonte de iluminação (vide na Figura 8 A e B).



A



B

Figura 8. Espectro radiômetro (FieldSpec 4 Standard-Res) (A), Medição da refletância da placa teflon (B).

Os dados obtidos foram utilizados para a correção radiométrica das imagens multiespectrais, minimizando os efeitos de variações de iluminação durante as diferentes aquisições. A partir dessas medições, foi gerado um gráfico de refletância da placa de Teflon, representando o comportamento espectral em distintos comprimentos de onda, o qual serviu como base de referência para os ajustes radiométricos. Realizou-se a caracterização espectral dos filtros ópticos da câmera MAPIR Survey3, a partir do gráfico de transmissão espectral (Filter Transmission) disponibilizado pelo fabricante no site oficial da MAPIR (vide na Figura 9). Esse gráfico apresenta as curvas de transmissão correspondentes às bandas espectrais sensíveis do sensor, permitindo a identificação das faixas espectrais específicas utilizadas nas análises abrangendo as regiões do vermelho (R), verde (G) e infravermelho próximo (NIR).

Survey3 RGN (Red, Green, Near Infrared) - Filter Transmission




Figura 9. Curvas de transmissão espectral dos filtros ópticos da câmera MAPIR Survey3, correspondentes às bandas verde (G), vermelha (R) e infravermelho próximo (NIR), conforme especificações do fabricante.

A reflectância da placa de Teflon utilizada como padrão lambertiano foi determinada em laboratório por meio do espectrorradiômetro FieldSpec 4 Standard-Res. A figura 10 apresenta as curvas espectrais obtidas para a placa (Teflon) e para o padrão de referência do equipamento, evidenciando a estabilidade da reflectância ao longo do espectro e sua adequação como material de calibração.




Figura 10. Curvas de reflectância da placa de Teflon e do padrão de referência obtidas com espectrorradiômetro.

A partir das curvas espectrais, foram extraídos os valores médios de reflectância nas bandas correspondentes aos filtros ópticos da câmera MAPIR Survey3 (Red, Green e NIR) (tabela 3). Esses valores serviram como referência absoluta para o cálculo dos fatores de correção radiométrica aplicados às imagens multiespectrais, permitindo converter os valores digitais (DN) em reflectância corrigida.

Tabela 3. Reflectância média da placa de Teflon nas bandas espectrais utilizadas para a calibração radiométrica.

Banda	Reflectância
Red (660 nm)	0.79776
Green (550 nm)	0.80835
NIR (850 nm)	0.78257

Para realização da correção radiométrica, processamento das imagens e extração das intensidades medias das bandas foi desenvolvido o software RAIC – *Radiometric Image Correct* (BR512025004362-7). O RAIC integra rotinas de leitura de imagens, extração de valores digitais (DN) e cálculo de fatores de correção radiométrica a partir de uma referência de laboratório e aplicação desses fatores às imagens amostrais. As rotinas foram implementadas em Python, utilizando-se as bibliotecas OpenCV e NumPy para processamento de imagens e cálculos numéricos, e módulos auxiliares para entrada/saída de arquivos e interface gráfica. O software aceita imagens nos formatos raster comumente utilizados (por exemplo, TIFF, PNG, JPEG) e produz um arquivo consolidado de resultados em formato CSV contendo métricas por imagem.

Foram necessários dois tipos de arquivos de entrada, uma imagem de referência da placa Lambertiana (Teflon) e as imagens amostrais das mudas (figura 13). A imagem de referência foi utilizada para extrair os valores digitais médios (DN) por banda (figura 11); a reflectância espectral absoluta da placa foi determinada em laboratório e introduzida no software como valores de reflectância de referência por banda (valores experimentais medidos com espectrorradiômetro).




Figura 11. Carregamento da imagem do padrão de referência, visualização da placa lambertiana e extração dos valores médios de número digital (DN) por banda.

Cada imagem é carregada e decomposta nas suas bandas espectrais correspondentes (Red, Green e Nir). Para a imagem de referência calcula-se o DN médio por banda (valor médio de todos os pixels da respectiva banda). Para as imagens amostrais, o DN médio é calculado apenas sobre os pixels correspondentes às plantas, isto é, após remoção do fundo (figura 14).

Os fatores de correção (CF) foram calculados para cada banda segundo a equação (8);

$$CBb = \frac{Rb^{lab}}{DNb^{ref}} \quad (8)$$

Em que:

✚ Rb^{lab} - Reflectância medida em laboratório para a placa de referência. Banda R = 0,79776; Banda G = 0,80835; Banda NIR = 0,78257; (figura 12)

✚ DNb^{ref} -é o valor médio de DN extraído da imagem da placa para a banda b.

2. Enter Reference Standard Reflectance Values

3. Correct Image

4. Results

Enter Reference Standard Reflectance Values

Red Reflectance:

0.79776

Green Reflectance:

0.80835

Blue Reflectance:

0.78257

Calculate Correction Factors

Correction Factors

Calculated Correction Factors:

Red: 0.00312993

Green: 0.00339485

Blue: 0.00306948

Figura 12. Inserção dos valores de reflectância obtidos em laboratório (espectrorradiômetro) e apresentação dos fatores de correção radiométrica por banda (R, G e NIR).

Antes do cálculo de DN médio nas imagens amostrais, realiza-se a segmentação para isolar a área ocupada pelas mudas. A segmentação foi implementada por um método baseado em limiarização automática (método de Otsu) aplicado ao canal em escala de cinza, seguido da aplicação da máscara resultante para extrair somente os pixels da planta (figura 14). Esse procedimento assegura que as estatísticas (DN médio e reflectância média) representem exclusivamente material vegetal.




Figura 13. Relação entre os valores observados e estimados de diâmetro obtidos pelo modelo de RNA(A), Curva de Loss (B).




Figura 14. Remoção do fundo da imagem da amostra utilizando segmentação automática.

A correção radiométrica foi aplicada multiplicando cada banda da imagem amostral pelo respectivo fator de correção, de acordo com a equação 9.

$$\rho_b(x, y) = CF_b * DN_b(x, y) \quad (9)$$

Em que:

- ✚ $\rho_b(x, y)$ -é a reflectância estimada no pixel (x, y) para a banda b;
- ✚ $DN_b(x, y)$ -é o valor digital original do pixel nessa banda.
- ✚ CF_b -Fator de conversão radiométrica da banda b (*Conversion Factor*).

Após a correção, o software calcula a reflectância média por banda sobre os pixels vegetais (máscara aplicada). Os resultados que incluem nome do ficheiro, fatores de correção por banda,

DN médios antes da correção e reflectância média após a correção são gravados num ficheiro CSV consolidado na pasta da imagem amostral (figura 14). O ficheiro contém cabeçalho padronizado, que facilita a posterior análise estatística e integração com bancos de dados.

```
Results After Applying Correction Factors

--- CORRECTION RESULTS ---

File: 10.25B75F.JPG

Mean Sample Image DN (before correction):
- Blue: 218.22
- Green: 187.10
- Red: 169.95

Mean Corrected Reflectance:
- Red: 0.531945
- Green: 0.635178
- Blue: 0.669811
```

Figura 15. Resultados da correção radiométrica com apresentação da reflectância média corrigida por banda (R, G e NIR).

A figura 16 apresenta um fluxograma esquemático detalhando a interação das funcionalidades do software RAIC.




Figura 16. Fluxograma esquemático detalhando a interação das funcionalidades do software RAIC.

3.6. Análise de correlação

A relação entre os índices de vegetação e os atributos biométricos (índice de área foliar e diâmetro do caule) foi avaliada por meio do coeficiente de correlação de Pearson (r), calculado a partir dos dados experimentais. A significância estatística das correlações foi determinada por meio do teste t , considerando os respectivos valores de p .

3.7. Criação, ajuste e avaliação dos modelos de estimativa

3.7.1. Regressão Linear Múltipla

Para a modelagem das variáveis biométricas, índice de área foliar e diâmetro do coleto (variáveis observadas) foi adotada uma abordagem de regressão linear múltipla no software

rstudio, empregando como preditores índices vegetativos (NDVI, GNDV, RVI e CVI) derivados das imagens multiespectrais. Os conjuntos de dados utilizados foi dividido em 70% para treinamento e 30% para validação.

O ajuste do modelo foi realizado por mínimos quadrados ordinários (OLS) usando a função `lm()` em R. A tabela de coeficientes e os níveis de significância foram extraídos e formatados com o auxílio do pacote *broom* para apresentação (estimativas, erro-padrão, estatística t e p-valor), que permitem a avaliação da contribuição individual de cada preditor.

Após o ajuste no conjunto de treinamento, foram geradas previsões tanto para o conjunto de treinamento quanto para o conjunto de validação por meio da função `predict()`. As previsões sobre o conjunto de validação foram utilizadas para calcular métricas de desempenho que quantificam a capacidade preditiva do modelo em dados independentes. Foram calculadas as seguintes métricas de desempenho do modelo como coeficiente de determinação (R^2) (equação 10), RMSE (Root Mean Square Error) (equação 11) e MAE (Mean Absolute Error) (equação 12).

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (10)$$

$$RMSE = \sqrt{\frac{1}{n} * \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (11)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (12)$$

- ✚ R^2 -Coeficiente de determinação que mede o grau de ajuste do modelo aos dados observados, indicando a proporção da variabilidade da variável dependente que é explicada pelo modelo;
- ✚ Y_i - Valor observado da variável dependente para a i-ésima observação;
- ✚ $\hat{Y}_i$ - Valor estimado (ou predito) pelo modelo para a i-ésima observação;
- ✚ $\bar{y}_i$ - Média aritmética dos valores observados da variável dependente;
- ✚ $\sum (y_i - \hat{y}_i)^2$ - Soma dos quadrados dos resíduos (SQRes);

- ✚ $\sum (y_i - \bar{y})^2$ - Soma total dos quadrados (SQTot);
- ✚ RMSE-*Root Mean Square Error* (Raiz do Erro Quadrático Médio).
- ✚ n-Número total de observações da amostra;
- ✚ $1/n$ - Média dos erros quadráticos;
- ✚ $\sum_{i=1}^n (y_i - \hat{y}_i)^2$ - Soma dos quadrados dos erros ao longo de todas as observações.
- ✚ MAE-Mean Absolute Error (Erro Médio Absoluto);
- ✚ $\sum_{i=1}^n |y_i - \hat{y}_i|$ -Soma dos erros absolutos ao longo de todas as observações.

3.7.2. Redes Neurais Artificiais

A modelagem das variáveis biométricas das mudas de *Moringa oleifera* foi complementada por uma abordagem baseada em Redes Neurais Artificiais (RNA) do tipo perceptron multicamada (MLP). A mesma arquitetura de rede e o mesmo procedimento de treinamento foram empregados tanto para a estimativa do Índice de Área Foliar (IAF) quanto para a estimativa do diâmetro do caule, alterando-se apenas a variável resposta.

Os dados foram divididos em 70% para treinamento e 30% para validação. Foram considerados como variáveis preditoras os índices espectrais derivados das imagens multiespectrais (NDVI, GNDVI, RVI e CVI).

3.7.2.1.Arquitetura da Rede Neural

A arquitetura da RNA (figura 17) adotada apresentou natureza simples e de fácil generalização, composta pelos seguintes elementos:

- ✚ Uma camada densa inicial com quatro neurónios, ativação não linear (hiperparâmetro testado entre relu, sigmoid e tanh) e regularização L2;
- ✚ Uma camada Dropout (taxa variando entre 0,2 e 0,3) para mitigação de sobreajuste;
- ✚ Uma segunda camada densa com dois neurónios e mesma função de ativação;
- ✚ Uma camada de saída linear com um neurónio, adequada para problemas de regressão.




Figura 17.Arquitetura da RNA adotada.

O otimizador utilizado foi Adam, com diferentes taxas de aprendizagem testadas. A função de perda adotada foi o Erro Quadrático Médio (MSE) e a métrica de avaliação secundária foi o Erro Absoluto Médio (MAE).

3.7.2.2.Treinamento e Busca de Hiperparâmetros

Foi implementada uma busca aleatória por hiperparâmetros dentro de um espaço pré-definido, incluindo:

- ✚ Três funções de ativação (relu, sigmoid e tanh),
- ✚ Três taxas de aprendizagem (0,01; 0,001; 0,0005),
- ✚ Três tamanhos de *batch* (8, 16 e 32),
- ✚ Duas taxas de *dropout* (0,2 e 0,3),
- ✚ Dois valores de regularização L2 (0,001 e 0,0001).

Foram selecionadas 20 combinações aleatórias, além de rodadas adicionais complementares, totalizando até 20 tentativas extras caso houvesse melhoria do desempenho. Cada modelo foi treinado por até 500 épocas, aplicando-se *early stopping* baseado na perda de validação, com o objetivo de reter sempre os melhores pesos e evitar sobreajuste.

A avaliação quantitativa do desempenho foi realizada por meio das seguintes métricas :Coeficiente de determinação (R^2) (equação 10), RMSE (Root Mean Square Error) (equação 11) e MAE (Mean Absolute Error) (equação 12).

Para assegurar a reprodutibilidade computacional dos modelos, foram fixadas sementes para todas as fontes de aleatoriedade (NumPy, TensorFlow, Python e SO), ativado o modo determinístico do TensorFlow e registrados todos os parâmetros de treinamento.

4. RESULTADOS E DISCUSSÃO

4.1.Análise estatística descritiva dos índices de vegetação

A Tabela 4 apresenta as estatísticas descritivas dos índices vegetativos NDVI, GNDVI, RVI, SAVI e CVI obtidos a partir das imagens multiespectrais das mudas de *Moringa oleífera* Lam. São exibidas medidas de tendência central, dispersão, assimetria, curtose e o teste de normalidade, a fim de caracterizar o comportamento estatístico das variáveis utilizadas nos modelos de predição.

Tabela 4.Análise descritiva dos dados dos índices de vegetação calculados

Estatística descritiva	NDVI	GNDVI	RVI	SAVI	CVI
Media	0,0755	-0,0333	1,1776	0,0811	0,749
Mediana	0,0996	-0,0324	1,2213	0,1057	0,7652
Mínimo	-0,0677	-0,1527	0,8822	-0,0689	0,5586

Máximo	0,1231	0,029	1,2808	0,1332	0,8919
Amplitude	0,1908	0,1817	0,3986	0,2021	0,3333
Desvio Padrão	0,043	0,0414	0,0805	0,046	0,078
Normalidade	0	0,0004	0	0	0,0457
Curtose	0,5124	-0,2529	0,3288	0,4101	-0,6347
Assimetria	-1,1613	-0,6783	-0,9623	-1,1418	-0,3857
Soma	7,4703	-3,2991	116,58	8,0274	74,1472
CV (%)	56,9941	-124,16	6,8368	56,7633	10,4111

Os valores médios observados do RVI (1,1776) e o CVI (0,7490) apresentaram as maiores magnitudes entre os índices estudados, enquanto NDVI (0,0755) e SAVI (0,0811) exibiram valores substancialmente menores. Este comportamento demonstra maior sensibilidade de índices baseados em razão simples (como o RVI) e índices baseados na banda verde (como o CVI) quando aplicados a plantas em estágios iniciais de crescimento ou com baixa densidade foliar (Nitu, 2025).

O índice GNDVI apresentou média negativa (-0,0333), indicando que a refletância na banda verde superou momentaneamente a refletância no NIR. Zhang et al. (2024) demonstraram que o GNDVI mantém elevada sensibilidade ao conteúdo de clorofila mesmo em folhas jovens, porém apresenta maior variabilidade em condições de pigmentação reduzida.

Os valores de dispersão mostram desvios-padrão moderados, variando de 0,0414 a 0,0805. A análise do coeficiente de variação (CV) destacou diferenças importantes na estabilidade métrica dos índices. O NDVI (56,99 %) e o SAVI (56,76 %) apresentaram elevada variabilidade relativa, refletindo a sensibilidade desses índices às variações estruturais entre mudas jovens. Segundo Martins et al. (2023), estudos com mudas de repolho demonstram que índices normalizados apresentam maior ruído espectral e perda de sensibilidade em fases iniciais de desenvolvimento e em condições de baixa cobertura, essas limitações tornam o NDVI e o SAVI mais sujeitos a variação amostral em viveiros. O RVI (6,83 %) e o CVI (10,41 %) apresentaram menor variabilidade, indicando maior estabilidade espectral conforme observado.

A avaliação das distribuições estatísticas revelou que nenhum dos índices apresentou normalidade ($p < 0,05$), comportamento amplamente relatado em literatura recente de sensoriamento remoto, tanto devido aos limites matemáticos dos índices quanto à heterogeneidade

intrínseca das superfícies vegetadas (Congalton et al., 2019). A forte rejeição da normalidade, com p-valores próximos de zero para NDVI, GNDVI, RVI e SAVI, sugere que procedimentos de modelagem podem exigir métodos robustos ou transformações de dados, como discutido nas abordagens estatísticas contemporâneas aplicadas à análise de variáveis ambientais (Frontiers In Earth Science, 2023).

A assimetria negativa observada em todos os índices ($-0,3857$ a $-1,1613$) indica maior concentração de valores acima da média, com caudas estendidas para valores baixos. Essa característica é compatível com conjuntos de dados espectrais onde o dossel está em formação e variações pequenas são mais frequentes do que valores extremos. Da mesma forma, os coeficientes de curtose situaram-se entre $-0,6347$ e $0,5124$, caracterizando distribuições predominantemente platicúrticas a mesocúrticas. Estudos recentes em índices de vegetação confirmam que dados espectrais coletados em ambientes controlados e estágios iniciais de desenvolvimento tendem a apresentar distribuições achatadas, devido à reduzida amplitude fisiológica entre indivíduos (Sonia et al., 2023).

Os resultados obtidos demonstram que RVI e CVI apresentam maior magnitude e estabilidade, enquanto NDVI e SAVI são mais sensíveis às condições estruturais da vegetação jovem. O comportamento não normal, a assimetria negativa e os baixos valores médios refletem o estágio inicial das mudas e reforçam a necessidade de abordagens estatísticas apropriadas para dados espectrais de alta heterogeneidade. Esses resultados, destacam a importância de compreender a distribuição e a variabilidade dos índices de vegetação antes de sua aplicação em modelos de inferência e predição (Sonia et al., 2023).

4.2. Correlação entre atributos da cultura e índices de vegetação

A matriz de correlação mostrou fortes relações entre o IAF e os índices espectrais NDVI ($r = 0,89$) e GNDVI ($r = 0,98$), enquanto índices como RVI ($r = -0,14$) e CVI ($r = -0,18$) apresentaram correlações negativas ou muito baixas. O índice SAVI mostra correlação positiva elevada ($r = 0,90$) com o IAF, sugerindo que tanto NDVI como GNDVI e SAVI são bons preditores da área foliar no contexto amostrado (tabela 5). Em particular, a correlação quase perfeita entre

IAF e GNDVI ($r = 0,98$) indicou que este índice capta a variação da folhosidade com maior sensibilidade do que os demais neste conjunto de dados.

Segundo (Du et al., 2022) redes neurais baseadas em NDVI foram capazes de prever com precisão o desenvolvimento de mudas em ambientes de viveiro, evidenciando que esse índice mantém bom desempenho enquanto a vegetação apresenta baixa a moderada densidade foliar.

A correlação entre NDVI e SAVI indicou alta multicolinearidade entre os dois índices, evidenciando que ambos capturam sinais espectrais semelhantes. Em contraste, a correlação negativa entre IAF e CVI sugere que este último índice pode não ser adequado ou apresenta inversão de sinal para estimativa do IAF na vegetação analisada. Em seu estudo (Du et al., 2022), indicadores que dependem fortemente das bandas vermelha ou azul tendem a sofrer interferência do substrato, iluminação artificial e alta variabilidade angular, o que explica as correlações negativas observadas neste estudo.

Tabela 5. Coeficientes de correlação de Pearson (r) entre os índices de vegetação (IVs) e os atributos biométricos.

Atributo	NDVI	GNDVI	RVI	SAVI	CVI
IAF	0,89	0,98	-0,14	0,90	-0,18
Diâmetro do caule (DC)	0,88	0,00	-0,05	0,90	0,02

A tabela 5 demonstra associações substanciais entre o diâmetro observado e alguns índices espectrais. Observou-se correlação de $r = 0,88$ entre o diâmetro e o NDVI. O índice SAVI também apresentou correlação elevada com o diâmetro ($r = 0,90$). Em contrapartida, índices como RVI ($r = -0,05$) e CVI ($r = 0,02$) apresentaram correlação praticamente nula ou muito baixa. Tais resultados indicam que, para este conjunto de mudas, os índices NDVI, e SAVI capturam bem a variação diamétrica, ao passo que RVI e CVI não refletem adequadamente esse atributo estrutural.

De acordo com (Alvino et al., 2020), mudas de cultivares agrícolas jovens, os índices NDVI, GNDVI e SAVI apresentaram aderência elevada com variáveis de crescimento estrutural, como altura e diâmetro basal, reforçando a observação de correlação de para NDVI no presente estudo. Em seu estudo (Alvino et al., 2020) destacaram que a GNDVI frequentemente supera o NDVI em sensibilidade a mudanças iniciais de biomassa foliar.

4.3.Ajuste do modelo linear múltiplo para estimativa do índice de área foliar (IAF)

O modelo linear múltiplo foi ajustado utilizando o conjunto de treinamento, apresentando coeficiente de determinação $R^2 = 0,957$, erro quadrático médio $RMSE = 0,111$ e erro absoluto médio $MAE = 0,097$, indicando bom ajuste aos dados utilizados na calibração do modelo. O desempenho do modelo foi posteriormente avaliado por meio de sua aplicação ao conjunto de validação, conforme apresentado na (Figura 18).




Figura 18. Relação entre valores observados e estimados do Índice de Área Foliar (IAF) obtidos pelo modelo de regressão múltipla, e métricas de desempenho (R^2 , RMSE e MAE).

A Tabela 6 apresenta os coeficientes estimados para cada variável do modelo. O intercepto foi significativo ($\beta = 18,306$; $p < 0,001$), refletindo a contribuição base do modelo. Entre os índices avaliados, apenas o GNDVI apresentou efeito estatisticamente significativo sobre o IAF ($\beta = 180,782$; $p < 0,001$), indicando forte associação positiva com a variável resposta. Esse comportamento está de acordo com a literatura, que aponta o GNDVI como um dos índices mais sensíveis à estrutura foliar e ao conteúdo de clorofila em dosséis vegetados.

Tabela 6. Coeficientes estimados, erros-padrão, estatísticas t e valores de p do modelo de regressão múltipla utilizado para estimativa do Índice de Área Foliar (IAF).

	Coeficiente	Estimativa	Erro-padrão	t-valor	p-valor
1	(Intercept)	18.306	0.4181	43.779	0.0000
2	NDVI	0.3703	17.320	0.2138	0.8314
3	GNDVI	180.782	11.954	151.229	0.0000
4	RVI	-0.4289	0.3661	-11.716	0.2458
5	CVI	0.2062	0.2411	0.8551	0.3957

Os índices NDVI, RVI e CVI não apresentaram significância estatística ($p > 0,05$), sugerindo que sua contribuição individual para o modelo é limitada quando analisados conjuntamente com o GNDVI. Ainda assim, a manutenção dessas variáveis não comprometeu o ajuste global, indicando possível colinearidade moderada entre os índices, característica comum em dados derivados de reflectância.

Segundo Lv et al. (2024), o GNDVI tende a apresentar maior sensibilidade à estrutura foliar e ao conteúdo de clorofila, sobretudo em dosséis mais densos, onde índices tradicionais, como o NDVI, frequentemente sofrem com efeitos de saturação. Em seus estudos comparativos, os autores mostraram que a resposta espectral na região do verde correlaciona-se melhor com aumentos progressivos do IAF, o que explica sua predominância no modelo ajustado.

De acordo com Nițu et al. (2025), muitos índices derivados do infravermelho próximo apresentam limitações quando aplicados a culturas com elevada biomassa, situação em que o NDVI pode perder capacidade discriminante. Esse padrão também é visível nos resultados deste estudo, já que o NDVI não apresentou significância estatística, apesar de ser um dos índices mais amplamente empregados em sensoriamento remoto. Os autores destacam que, em condições de alta densidade foliar, índices alternativos como GNDVI, CI green ou índices de borda-vermelha são mais adequados para captar variações sutis na estrutura do dossel o que corrobora a dominância observada do GNDVI.

Fan et al. (2024) ressaltam que a combinação de múltiplos índices pode melhorar a performance global dos modelos, mesmo quando apenas parte dos coeficientes se mostra estatisticamente significativa. Esse comportamento também foi observado nos resultados aqui apresentados: embora somente o GNDVI tenha contribuído de forma significativa, o modelo como um todo apresentou elevada capacidade explicativa ($R^2 = 0,935$). Assim, mesmo que NDVI, RVI e CVI não tenham apresentado significância individual, sua presença no modelo pode ter auxiliado na redução da variabilidade residual, favorecendo o desempenho global.

Segundo Yan et al. (2025), muitos índices são altamente correlacionados entre si, o que pode gerar colinearidade e reduzir a capacidade de detectar efeitos independentes no ajuste do modelo linear. Além disso, os autores destacam que o comportamento espectral é fortemente influenciado por fatores como arquitetura foliar, estágio fenológico, ângulo solar e características específicas da cultura o que reforça a necessidade de validar os modelos em diferentes contextos.

Outro ponto relevante refere-se à escalabilidade dos resultados. De acordo com Li et al. (2023), modelos baseados em índices espectrais apresentam bom desempenho em condições controladas, mas sua generalização depende da avaliação em diferentes ambientes, sensores e períodos fenológicos. Nesse sentido, embora o alto R^2 do presente estudo demonstre boa aderência local, a extrapolação para outras condições deve ser realizada com cautela.

Em síntese, os resultados indicam que o GNDVI é um índice altamente adequado para estimativas de IAF em condições semelhantes às avaliadas. Ao mesmo tempo, reafirmam conclusões recentes na literatura de que a performance de índices tradicionais pode ser limitada em vegetação densa. Recomenda-se, portanto, que estudos futuros explorem modelos não lineares, integração de bandas de borda-vermelha ou técnicas de aprendizado de máquina, conforme sugerido por Gao et al. (2024), para potencializar ainda mais a precisão das estimativas de IAF.

4.4. Ajuste do modelo linear múltiplo para estimativa do diâmetro

O modelo linear múltiplo foi ajustado utilizando o conjunto de treinamento para a estimativa do diâmetro do caule, apresentando coeficiente de determinação $R^2 = 0,9447$, erro

quadrático médio RMSE = 0,2312 e erro absoluto médio MAE = 0,1863, indicando bom ajuste aos dados utilizados na calibração do modelo. O desempenho do modelo foi posteriormente avaliado por meio de sua aplicação ao conjunto de validação, conforme apresentado (figura 19). Segundo Li et al. (2025), modelos multivariados tendem a capturar variações estruturais do dossel de maneira mais eficiente do que análises univariadas, em razão da complementaridade espectral entre os índices.




Figura 19. Relação entre valores observados e estimados do Diâmetro obtidos pelo modelo de regressão múltipla e métricas de desempenho (R^2 , RMSE e MAE).

Tabela 7. Coeficientes estimados, erros-padrão, estatísticas t e valores de p do modelo de regressão múltipla utilizado para estimativa do diâmetro.

	Coeficiente	Estimativa	Erro-padrão	t-valor	p-valor
1	(Intercept)	39.170	23.881	16.402	0.1059
2	NDVI	-186.300	27.499	-67.749	0.0000
3	GNDVI	407.916	28.654	142.358	0.0000
4	RVI	41.387	30.718	13.473	0.1826
5	CVI	-26.440	18.301	-14.447	0.1534

A significância estatística observada para NDVI e GNDVI indica que ambos exercem influência consistente sobre o diâmetro, embora de forma distinta. O coeficiente negativo do NDVI, por exemplo, pode ser explicado pela saturação desse índice em condições de maior biomassa, fenômeno amplamente discutido por Nițu et al. (2025), que destacam que o NDVI perde sensibilidade em dosséis densos, podendo até inverter tendências quando pequenas variações estruturais não são captadas adequadamente pelo sensor.

Por outro lado, o forte efeito positivo do GNDVI confirma sua reconhecida sensibilidade ao vigor vegetativo e à clorofila, sobretudo em espécies e sistemas onde o desenvolvimento foliar desempenha papel determinante no crescimento radial. De acordo com Lv et al. (2024), o GNDVI apresenta melhor desempenho do que o NDVI em estimativas associadas à produtividade e ao acúmulo de biomassa, justamente por explorar informações espectrais mais lineares em relação ao crescimento vegetativo. Em seus estudos, os autores verificaram que pequenas variações na reflectância da banda verde estão fortemente relacionadas à expansão foliar, o que explica sua expressiva significância no presente modelo.

Yan et al. (2025) relatam que índices simples baseados em razões espectrais, como RVI, tendem a apresentar colinearidade elevada com outros índices, perdendo capacidade discriminante em modelos multivariados. De modo semelhante, Li et al. (2025) destacam que índices derivados da relação vermelho-verde, como o CVI, são sensíveis a mudanças fenológicas iniciais, mas podem não capturar adequadamente variações estruturais mais avançadas, como é o caso do crescimento do diâmetro.

O desempenho do modelo é reforçado pela proximidade entre os valores estimados e observados, indicando que, apesar de apenas parte das variáveis ter sido estatisticamente significativa, o conjunto contribuiu para a estabilidade do ajuste. Esse comportamento é consistente com o que descrevem Martínez et al. (2024), que observaram que modelos multivariados podem apresentar alta acurácia mesmo quando alguns coeficientes individuais não são significativos, desde que exista complementaridade espectral.

O GNDVI desempenha papel central na estimativa de variáveis biométricas, especialmente em sistemas vegetativos mais densos. Ao mesmo tempo, reforçam a necessidade de considerar limitações inerentes a índices como o NDVI, que podem apresentar respostas não lineares sob determinadas condições estruturais.

4.5. Redes neurais artificiais (desempenho comparativo)

Os modelos de redes neurais artificiais (RNA) avaliados apresentaram desempenho bastante variável conforme a combinação de funções de ativação, taxa de aprendizagem (learning rate), tamanho do batch, dropout e profundidade da rede. De modo geral, observou-se que arquiteturas mais profundas, associadas a taxas de aprendizagem moderadas e uso de funções de ativação contínuas (tanh e sigmoid), resultaram em maior acurácia na estimativa do IAF.


O melhor desempenho entre todos os modelos foi obtido por uma configuração que corresponde ao uso do conjunto de variáveis de entrada extra, função de ativação tangente hiperbólica (tanh), taxa de aprendizagem (lr) de 0,01, tamanho de lote (batch size) igual a 8, dropout de 0,3 e regularização L2, que apresentou MAE = 0.026, RMSE = 0.032 e $R^2 = 0.995$, (figura 20 A) indica ajuste próximo da realidade entre valores estimados e observados. Este resultado evidencia que a combinação entre taxa de aprendizagem elevada (0.01), função de ativação tanh e dropout moderado (0.3) favoreceu o processo de convergência e evitou sobreajuste, mesmo em uma arquitetura compacta (l2) (figura 20 A).

De acordo com Oliveira et al. (2024), técnicas de redes neurais aplicadas a variáveis estruturais de vegetação podem alcançar elevada precisão quando parametrizadas com cuidado, o que corrobora as elevadas métricas observadas neste estudo. Em seu trabalho, Oliveira et al. (2024)


demonstraram que a combinação de algoritmos de aprendizagem profunda com dados espectrais e amostras experimentais resultou em desempenho superior ao de métodos tradicionais.

As curvas de perda (loss) (Figura 20 B) de treino e de validação diminuem rapidamente nas primeiras épocas, estabilizando-se de forma paralela ao longo do restante do treinamento. A perda de validação mantém-se sempre inferior à perda de treino, sugerindo que o modelo alcançou boa generalização, sem evidências de sob reajuste significativo. A ausência de oscilação abrupta no erro ao longo das épocas indicou um processo de otimização estável, favorecido pela combinação entre taxa de aprendizagem moderada e dropout intermediário.

Este comportamento está alinhado com o que foi descrito por Silva et al. (2024), que observou em estudos com redes neurais aplicadas à reflectância hiperespectral de arroz que a estabilização precoce da loss e a manutenção de desempenho entre treino e validação indicam robustez e boa capacidade de generalização. Segundo Jin (2024), a adoção de taxas de aprendizagem moderadas e regularização adequada evita o sob reajuste em experimentos com alta complexidade espectral.




A




B

Figura 20. Relação entre valores observados e estimados do Diâmetro obtidos pelo modelo de regressão múltipla, linha ajustada e métricas de desempenho (R^2 , RMSE e MAE).

O modelo RNA para estimativa do diâmetro configurado com ativação *extra_tanh*, taxa de aprendizagem de 0,01, batch size de 8 e dropout de 0,3 apresentou desempenho superior para estimativa de diâmetro. Os valores obtidos foram MAE = 0,061, RMSE = 0,085 e $R^2 = 0,992$ indicam que aproximadamente 99,2% da variância observada do diâmetro das plantas foi explicada pelo modelo. Este resultado evidencia elevada precisão e acurácia no ajuste entre estimativas e medições observadas (figura 21 A).



A



B

Figura 21. Relação entre os valores observados e estimados de diâmetro obtidos pelo modelo de RNA(A), Curva de Loss (B)

Pohan et al. (2020), que utilizaram RNA com back-propagation em mudas e obtiveram cerca de 92,8% de acurácia para crescimento de plântulas em casa de vegetação. A superioridade do ajuste no presente estudo pode ser atribuída à escolha otimizada dos hiperparâmetros (ativação, batch ,size,dropout) e a adequação do dataset ao modelo.

De acordo com (Dirks; Poole, 2022), modelos RNA aplicados a atributos morfológicos de plantas mostraram ganhos de desempenho ao otimizar arquitetura e parâmetros da rede. Contudo, é fundamental reconhecer limitações. Apesar do excelente ajuste local obtido ($R^2=0,992$), a aplicação em outros contextos por exemplo, diferentes espécies, escalas de plantio ou sensores pode exigir re-treinamento ou adaptação. Em seu trabalho, (Dirks; Poole, 2022) destacaram que modelos aplicados a sistemas diferentes ou sob estresse podem apresentar queda de desempenho se não forem ajustados ao novo cenário. Dessa forma, recomenda-se que futuras investigações validem o modelo em condições variadas e incluam validação externa para assegurar generalização.

Recomenda-se que estudos futuros ampliem a base de dados, explorem sensores com mais bandas espectrais (especialmente red-edge e hiperespectrais) e realizem validações externas em diferentes condições ambientais, de modo a fortalecer a robustez e aplicabilidade dos modelos desenvolvidos. Assim, os achados deste trabalho contribuem para o avanço do uso da fenotipagem digital na engenharia agrícola, especialmente no contexto da produção sustentável de mudas.

5. CONCLUSÃO

O estudo demonstra que a fenotipagem digital, aliada ao uso de modelos estatísticos e computacionais, constitui uma estratégia eficiente, precisa e não destrutiva para estimar variáveis biométricas em mudas de *Moringa oleifera* Lam.

A utilização de imagens multiespectrais corrigidas radiometricamente permite a determinação confiável de índices de vegetação, evidenciando que o GNDVI e NDVI apresentam maior sensibilidade tanto ao IAF quanto ao diâmetro do coleto, sobretudo em estágios iniciais de crescimento.

Os modelos lineares múltiplos apresentaram elevado poder explicativo, embora nem todos os índices tenham sido estatisticamente significativos. Para a estimativa do IAF, destacou-se como significativo o índice GNDVI enquanto RVI e CVI não contribuíram de forma relevante. Para o diâmetro do caule, os índices NDVI e GNDVI apresentaram significância, ao passo que RVI e CVI não foram significativos.

Os modelos lineares múltiplos mostram um elevado poder explicativo, ainda que alguns índices variáveis não apresentam significância individual. Os modelos de Redes Neurais Artificiais superaram os modelos tradicionais, alcançando acurácia superior e maior capacidade de generalização.

Os resultados indicam que a integração de sensores multiespectrais com técnicas de aprendizado de máquina pode ser incorporada de forma efetiva ao monitoramento de mudas em viveiros, reduzindo custos, acelerando o processo de avaliação e aumentando a precisão das estimativas. Este conjunto de técnicas representa uma ferramenta promissora para apoiar práticas de manejo, seleção de mudas vigorosas e otimização da produção florestal.

Os resultados indicam que a integração de sensores multiespectrais com técnicas de aprendizado de máquina pode ser incorporada de forma efetiva ao monitoramento de mudas em viveiros, reduzindo custos, acelerando o processo de avaliação e aumentando a precisão das estimativas. Este conjunto de técnicas representa uma ferramenta promissora para apoiar práticas de manejo, seleção de mudas vigorosas e otimização da produção florestal.

REFERENCIAS BIBLIOGRÁFICAS

AASEN, Helge; BURKART, Andreas; BARETH, Georg; BENDIG, Juliane. Generating 3D hyperspectral information with lightweight UAV snapshot cameras for vegetation monitoring: From camera calibration to quality assurance. *ISPRS Journal of Photogrammetry and Remote Sensing*, Amsterdam, v. 108, p. 245–259, 2018.

AHMED, Dr. Roheen Qamar, *Mesopotamian Journal of Computer science* Vol.(2023), 2023, pp. 130-139. 2023.

ALMEIDA, André Quintão De et al. Índice de Área Foliar de Eucalyptus Estimado por Índices de Vegetação Utilizando Imagens TM - Landsat 5. *Floresta e Ambiente*, v. 22, n. 3, p. 368–376, set. 2015.

ALVINO, Francisco C. G. *et al.* Vegetation Indices For Irrigated Corn Monitoring. *Engenharia Agrícola*, v. 40, n. 3, p. 322–333, jun. 2020.

ANG, Muliady *et al.* Rice Leaf Nitrogen Content Estimation Through A Methodological Framework Using Single-Sensor Multispectral Images. *Journal of Engineering Technology and Applied Physics*, v. 6, n. 2, p. 38–46, 15 set. 2024.

AZEEM, Muhammad et al. Salinity stress improves antioxidant potential by modulating physio-biochemical responses in *Moringa oleifera* Lam. *Scientific Reports*, v. 13, n. 1, p. 2895, 18 fev. 2023.

BADAGLIACCA, Giuseppe et al. Multispectral Vegetation Indices and Machine Learning Approaches for Durum Wheat (*Triticum durum* Desf.) Yield Prediction across Different Varieties. *AgriEngineering*, v. 5, n. 4, p. 2032–2048, 2 nov. 2023.

Benchmarking of chlorophyll vegetation index (CVI)-2020. Disponível em: <https://www.researchgate.net/figure/Benchmarking-of-chlorophyll-vegetation-index-CVI-2020_fig23_358044519>. Acesso em: 24 maio. 2025.

BINOTI, Mayra Luiza Marques Da Silva; BINOTI, Daniel Henrique Breda; LEITE, Helio Garcia. Aplicação de redes neurais artificiais para estimação da altura de povoamentos equiâneos de eucalipto. *Revista Árvore*, v. 37, n. 4, p. 639–645, ago. 2013.

BRÉDA, N. Ground-based measurements of leaf area index: a review of methods, instruments and current controversies. *Journal of Experimental Botany*, Oxford, v. 54, n. 392, p. 2403–2417, 2003.

CAMPBELL, G. S.; NORMAN, J. M. *An introduction to environmental biophysics*. 2. ed. New York: Springer, 1998.

CARVALHO, Layne Araujo et al. Plantas alimentícias não convencionais e seus principais compostos bioativos. *Brazilian Journal of Development*, v. 9, n. 3, p. 11579–11591, 20 mar. 2023.

CHAN, Kit Yan *et al.* Deep neural networks in the cloud: Review, applications, challenges and research directions. *Neurocomputing*, v. 545, p. 126327, ago. 2023.

CHECHI, L. et al. Estimation of canopy cover and leaf area index by multispectral imaging in early growth stages. *Remote Sensing Applications: Society and Environment*, v. 23, 2021. DOI: <https://doi.org/10.1016/j.rsase.2021.100532>

CHITIYO, Sharon T. et al. Biochemical responses of *Moringa oleifera* Lam. plants to graded moisture deficit. *South African Journal of Botany*, v. 138, p. 41–49, maio 2021.

Coelho de Pesquisa. Disponível em: <<https://researchrabbitapp.com/home>>. Acesso em: 4 fev. 2025.

CORREIA, Pedro M. P. et al. High-throughput phenotyping of physiological traits for wheat resilience to high temperature and drought stress. *Journal of Experimental Botany*, v. 73, n. 15, p. 5235–5251, 3 set. 2022.

DANIELS, Louis *et al.* Identifying the Optimal Radiometric Calibration Method for UAV-Based Multispectral Imaging. *Remote Sensing*, v. 15, n. 11, p. 2909, jan. 2023.

DE JESUS LOBO, Laurenice et al. Desenvolvimento inicial de mudas de moringa oleífera em diferentes substratos. *Recital - Revista de Educação, Ciência e Tecnologia de Almenara/MG*, v. 5, n. 1, p. 106–116, 28 abr. 2023a.

DE OLIVEIRA, Romário Porto et al. Predicting Sugarcane Biometric Parameters by UAV Multispectral Images and Machine Learning. *Agronomy*, v. 12, n. 9, p. 1992, 23 ago. 2022.

DE SOUSA, Jonathan R. *et al.* Python e predição de dados usando redes neurais multicamadas. 2021.

DEBASTIANI, A. B.; MOURA, M. M.; REX, F. E.; SANQUETTA, C. R.; CORTE, A. P. D.; PINTO, N. Regressões robusta e linear para estimativa de biomassa via imagem Sentinel em uma floresta tropical. *Biofix Scientific Journal*, Curitiba, v. 4, n. 2, p. 81–87, 2019. DOI: <https://doi.org/10.5380/biofix.v4i2.62922>

DEPARTMENT OF GEOGRAPHY, OBAFEMI AWOLOWO UNIVERSITY, ILE-IFE, NIGERIA; AYANLADE, Ayansina. Remote sensing vegetation dynamics analytical methods: a review of vegetation indices techniques. *Geoinformatica Polonica*, v. 16, p. 7–17, 2017.

DIMYATI, M. *et al.* A Comparison Of Several UAV-Based Multispectral Imageries In Monitoring Rice Paddy (A Case Study In Paddy Fields In Tottori Prefecture, Japan). *ISPRS International Journal of Geo-Information*, v. 12, n. 2, art. 36, 2023

DIRKS, Matthew; POOLE, David. Automatic neural network hyperparameter optimization for extrapolation: Lessons learned from visible and near-infrared spectroscopy of mango fruit. *Chemometrics and Intelligent Laboratory Systems*, Amsterdam, v. 231, p. 104685, 2022. DOI: 10.1016/j.chemolab.2022.104685.

DU, Xinwu *et al.* Classification of plug seedling quality by improved convolutional neural network with an attention mechanism. *Frontiers in Plant Science*, v. 13, p. 967706, 4 ago. 2022.

DUARTE, H. F. *et al.* Seasonal variation of leaf area index and its relationship with meteorological variables in a Brazilian cerrado. *Acta Scientiarum. Agronomy*, Maringá, v. 38, n. 1, p. 33–42, 2016.

ELIAS, Adão Robson; PIROLI, Edson Luís; FELIPETTO, Henrique Dos Santos. Análise de imagens multiespectrais de RPA para mapeamento de vegetação em áreas ciliares. *Periódico Eletrônico Fórum Ambiental da Alta Paulista*, v. 20, n. 2, 29 jun. 2024.

FAN, X.; GAO, P.; ZHANG, M.; CANG, H.; ZHANG, L.; ZHANG, Z.; WANG, J.; LV, X.; ZHANG, Q.; MA, L. The fusion of vegetation indices increases the accuracy of cotton leaf area prediction. *Frontiers in Plant Science*, v. 15, 2024. DOI: 10.3389/fpls.2024.1357193.

FARIA, R. T. et al. Leaf area index, crop coefficient and water relations of coffee crop. *Agricultural Water Management*, Amsterdam, v. 95, n. 11, p. 1261–1270, 2008.

FERNANDES, M. M. et al. Redes neurais artificiais na estimação de variáveis biométricas de mudas de espécies florestais produzidas em diferentes substratos. *Revista de Ciências Agroveterinárias*, v. 18, n. 1, p. 47–58, 2019. DOI: <https://doi.org/10.5965/223811711812019047>

FERRAZ, Marcelo Araújo Junqueira et al. Sorghum grain yield estimation based on multispectral images and neural network in tropical environments. *Smart Agricultural Technology*, v. 9, p. 100661, dez. 2024.

FILHO, Henrique Bergamin et al. Centro De Energia Nuclear Na Agricultura Universidade De São Paulo. 2010.

FRANCISCO MARTO DE SOUZA et al. Initial growth of *Moringa oleifera* Lam. as a function of poultry litter doses and granulometry. *Scientia Agrícola*, v. 76, n. 4, 2018. DOI: 10.1590/1983-40632018v4852447.

FRARE, Julio Cesar Vieira. Qualidade Do Solo E Dinâmica De Crescimento De Espécies Florestais E Frutíferas Em Sistemas Agroflorestais Sem Queima Na Amazônia. 2023.

GAO, Si et al. Assessment of remote-sensed vegetation indices for estimating forest chlorophyll concentration. *Ecological Indicators*, v. 162, p. 112001, maio 2024.

GARBOUGE, Hadhami; RASTI, Pejman; ROUSSEAU, David. Enhancing the Tracking of Seedling Growth Using RGB-Depth Fusion and Deep Learning. *Sensors*, v. 21, n. 24, p. 8425, 17 dez. 2021.

GILL, Taqdeer *et al.* A Comprehensive Review of High Throughput Phenotyping and Machine Learning for Plant Stress Phenotyping. *Phenomics*, v. 2, n. 3, p. 156–183, jun. 2022.

GLEICIANA NASCIMENTO DE ALMEIDA et al. Desenvolvimento de mudas de *Moringa oleifera* submetidas a diferentes substratos. *Revista Ciência Agrícola*, v. 17, n. 2, 6511, 2019. DOI: 10.28998/rca.v17i2.6511.

GONÇALVES, D.; SILVA, F.; ALMEIDA, R. Modelagem linear e redes neurais aplicadas ao processamento de dados ambientais. *Revista Brasileira de Ecologia*, v. 20, p. 45–59, 2016.

GONTIJO DA CUNHA, Vitor A. et al. Early detection of tomato bacterial spot disease in transplant tomato seedlings utilising remote sensing and artificial intelligence. *Biosystems Engineering*, v. 234, p. 172–186, out. 2023.

JOHANSEN, Kasper et al. Unmanned Aerial Vehicle-Based Phenotyping Using Morphometric and Spectral Analysis Can Quantify Responses of Wild Tomato Plants to Salinity Stress. *Frontiers in Plant Science*, v. 10, 29 mar. 2019.

JONCKHEERE, I. et al. Review of methods for in situ leaf area index determination: part I. Theories, sensors and hemispherical photography. *Agricultural and Forest Meteorology*, Amsterdam, v. 121, n. 1–2, p. 19–35, 2004.

KUNSTMAN, Grzegorz et al. Nondestructive Detection Method for the Calcium and Nitrogen Content of Living Plants Based on Convolutional Neural Networks (CNN) Using Multispectral Images. *Agriculture*, v. 12, n. 6, p. 747, 25 maio 2022.

LAFETÁ, Bruno Oliveira et al. Crescimento diamétrico e tempo de passagem em um fragmento de Mata Atlântica sob recuperação florestal. *Revista de Ciências Agroveterinárias*, v. 23, n. 3, p. 483–491, 4 out. 2024.

LAZZARINI, Luiz Eduardo Santos et al. Uso De Diodos Emissores De Luz (Led) Na Fisiologia De Plantas Cultivadas – REVISÃO. v. 16, n. 2, 2017.

LI, Yi et al. Individual tree segmentation of airborne and UAV LiDAR point clouds based on the watershed and optimized connection center evolution clustering. *Ecology and Evolution*, v. 13, n. 7, p. e10297, jul. 2023.

LIMA, Mauro Almeida et al. Uso de Redes Neurais Artificiais (RNA) do tipo Multilayer Perceptrons (MLP) modificado com processamento estatístico em paralelo para estudo do

problema de classificação da origem de vinho tinto. *Revista Brasileira de Agropecuária Sustentável*, v. 6, n. 2, 30 jun. 2016.

LIU, Shuaibing et al. Estimating leaf area index using unmanned aerial vehicle data: shallow vs. deep machine learning algorithms. *Plant Physiology*, v. 187, n. 3, p. 1551–1576, 3 nov. 2021.

LIU, Tao et al. Maize height estimation using combined unmanned aerial vehicle oblique photography and LIDAR canopy dynamic characteristics. *Computers and Electronics in Agriculture*, v. 218, p. 108685, mar. 2024.

LV, Fangyi et al. Estimation of Leaf Area Index across Biomes and Growth Stages Combining Multiple Vegetation Indices. *Sensors*, v. 24, n. 18, p. 6106, 21 set. 2024.

MACHADO, Igor Eloi Silva et al. Modelos para estimativa de variáveis florestais com a utilização de imagens multiespectrais. *Pesquisa Florestal Brasileira*, v. 37, n. 90, p. 171, 30 jun. 2017.

MAKKY, Muhammad. Multi-modal Bio-metrics Evaluation for Non-destructive Age States Determination of Tomato Plants (*Solanum lycopersicum*). *International Journal on Advanced Science, Engineering and Information Technology*, v. 6, n. 3, p. 349, 10 maio 2016.

MARTINS, George D. et al. Estimation of biometric, physiological, and nutritional variables in lettuce seedlings using multispectral images. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v. 25, n. 10, p. 689–695, ago. 2021.

MASHAMAITE, Chuene Victor et al. Local Knowledge, Perceptions, and Uses of the Potentially Conflict-Generating Plant Species, *Moringa oleifera* Lam.: A case Study in Limpopo Province, South Africa. *Human Ecology*, v. 51, n. 5, p. 979–994, out. 2023.

MELNYK, Oleksandr; BRUNN, Ansgar. Analysis of Spectral Index Interrelationships for Vegetation Condition Assessment on the Example of Wetlands in Volyn Polissya, Ukraine. *Earth*, v. 6, n. 2, p. 28, 11 abr. 2025.

MERAJ, Talha et al. Computer vision-based plants phenotyping: A comprehensive survey. *iScience*, v. 27, n. 1, p. 108709, jan. 2024.

MONTEITH, J. L. Solar radiation and productivity in tropical ecosystems. *Journal of Applied Ecology*, London, v. 9, n. 3, p. 747–766, 1972.

MURALI, M.; ANTONY JOSEPH RAJ; AFAQ MAJID WANI. Survival, growth, and leaf area index of annual *Moringa oleifera* cuttings in different diameter classes. *International Journal of Advanced Biochemistry Research*, v. 7, n. 2S, p. 259–264, 2023. DOI: 10.33545/26174693.2023.v7.i2Sd.220.

NIȚU, Andreea et al. NDVI and Beyond: Vegetation Indices as Features for Crop Recognition and Segmentation in Hyperspectral Data. *Sensors*, v. 25, n. 12, p. 3817, 18 jun. 2025.

NORMAN, J. M.; CAMPBELL, G. S. Canopy structure. In: PEARCY, R. W. et al. (ed.). *Plant physiological ecology: field methods and instrumentation*. London: Chapman and Hall, 1989. p. 301–325.

OLIVEIRA JUNIOR, Valdir Moura De et al. CRESCIMENTO VEGETATIVO DA MORINGA EM DISTINTOS REGIMES DE IRRIGAÇÃO ASSOCIADOS A COMPOSIÇÕES DE DIFERENTES SUBSTRATOS. *IRRIGA*, v. 1, n. 4, p. 646–652, 23 dez. 2021.

OLIVEIRA, Andressa Pereira et al. Utilização de arquiteturas de redes neurais artificiais para a análise do fluxo de potência com geração distribuída. *Caderno Pedagógico*, v. 21, n. 1, p. 663–681, 8 jan. 2024.

OLIVEIRA, P. L. G.; et al. Artificial Neural Network and Remote Sensing combined to predict the Aboveground Biomass in the Cerrado biome. *Anais da Academia Brasileira de Ciências*, Rio de Janeiro, v. 96, n. 3, 2024. DOI: <https://doi.org/10.1590/0001-3765202420221041>

OLIVEIRA, Palloma Vitória Carlos de et al. Utilização de moringa oleífera na alimentação animal / Utilization of oil moringa oleiferous in animal feed. *Brazilian Journal of Development*, v. 6, n. 7, p. 53881–53893, 3 ago. 2020.

OLIVEIRA, Rubmara Ketzer. Avaliação de cultivos por meio de índices de vegetação obtidos por câmera multiespectral. Doutorado em Engenharia de Sistemas Agrícolas—Piracicaba: Universidade de São Paulo, 8 fev. 2024.

PATIL, Satish V. et al. Moringa Tree, Gift of Nature: a Review on Nutritional and Industrial Potential. *Current Pharmacology Reports*, v. 8, n. 4, p. 262–280, ago. 2022.

PEDRO, Tiago Otilio Baptista; ROMUA, Cássimo Lacerda; SERROTE, Caetano Miguel Lemos. Alternative Substrates For The Production Of Moringa Seedlings In Mozambique. v. 19, n. 2, 2021.

PEREIRA, Etiandro et al. Produção E Crescimento Inicial Da Moringa Em Diferentes Doses De Esterco Ovino. *Agrarian Academy*, v. 6, n. 11, p. 281–291, 22 jul. 2019.

PEREIRA, Fernando Vasconcelos et al. Estimating coffee crop parameters through multispectral imaging and machine learning algorithms. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, v. X-3–2024, p. 317–323, 4 nov. 2024.

PEREIRA, R. et al. Artificial neural networks for phenotyping seedlings under controlled conditions. *Computers and Electronics in Agriculture*, v. 209, 2024. DOI: <https://doi.org/10.1016/j.compag.2023.108225>

PINA, J. C.; MORBECK DE OLIVEIRA, A. K.; MATIAS, R. Crescimento inicial de *Moringa oleifera* em substrato arenoso com adição de vermicomposto em duas luminosidades. *Revista Unimontes Científica*, v. 25, n. 2, p. 1–16, 2023. DOI: 10.46551/ruc.v25n2a8.

PINA, José Carlos; MORBECK DE OLIVEIRA, Ademir Kleber; MATIAS, Rosemary. Crescimento inicial de *Moringa oleifera* em substrato arenoso com adição de vermicomposto em duas luminosidades: Initial growth of *Moringa oleifera* in the sandy substrate with the addition of vermicompost in two luminosities. *Revista Unimontes Científica*, v. 25, n. 2, p. 1–16, 16 ago. 2023.

POHAN, S.; WARSITO, B.; SURYONO, S. Backpropagation artificial neural network for prediction plant seedling growth. *Journal of Physics: Conference Series*, v. 1524, n. 1, p. 012147, 2020. DOI: 10.1088/1742-6596/1524/1/012147.

PRADO, Everton V. do et al. Fenotipagem digital de plantas por meio de ferramentas digitais e sensores multiespectrais. *Revista Científica Agrícola*, Ituverava, v. 20, n. 1, p. 101–110, 2023.

QI, Haixia et al. Estimation of Peanut Leaf Area Index from Unmanned Aerial Vehicle Multispectral Images. *Sensors*, v. 20, n. 23, p. 6732, 25 nov. 2020.

RIBEIRO, Ana Maria Pereira et al. Fenotipagem de plântulas de tabaco pela análise de imagens. *CONTRIBUCIONES A LAS CIENCIAS SOCIALES*, v. 17, n. 2, p. e5437, 26 fev. 2024.

ROBSON LUIS SILVA DE MEDEIROS; ADAILZA GUILHERME CAVALCANTE; ALIAN CÁSSIO PEREIRA CAVALCANTE; VÊNIA CAMELO DE SOUZA. Crescimento e qualidade de mudas de *Moringa oleifera* Lam em diferentes proporções de composto orgânico. *Revista Ifes Ciência*, v. 3, n. 1, p. 204–216, 2017. DOI: 10.36524/ric.v3i1.315.

RODRIGUES, José Cunegundes Weckner *et al.* A Importância Da Produção De Mudanças De Essências Florestais Na Região Amazônica: Uma Revisão Sistemática. *Revista Científica da Faculdade de Educação e Meio Ambiente*, v. 14, n. 1, p. 10–24, 22 fev. 2023.

SANTOS, M. N. et al. Machine learning and spectral vegetation indices for estimating leaf area index in crops. *Remote Sensing*, v. 14, n. 5, 2022. DOI: <https://doi.org/10.3390/rs14051234>

SANTOS, Otávio Lube Dos; PANDOLFI, André Serafim; RAMALDES, Gabriel Pecinalli. Análise De Índice De Vegetação Através De Imagens Obtidas Por Vant. *Revista Científica Faesa*, v. 14, n. 1, p. 142–162, 1 dez. 2018.

SANTOS, R. S. et al. Growth and biomass production of *Moringa oleifera* cultivated in semiarid region as responses to row spacing and cuts. *Tropical Animal Science Journal*, v. 44, n. 2, p. 18307, 2021. DOI: 10.5398/tasj.2021.44.2.183.

Sapkota, A., Haghverdi, A., & Montazar, A. Estimativa da produtividade da alfafa (*Medicago sativa* L.) colhida no outono usando imagens multiespectrais e térmicas obtidas por veículos aéreos não tripulados no sul da Califórnia. *Agrosystems, Geosciences & Environment* , 6 (2). <https://doi.org/10.1002/agg2.20392>. 2023.

SILVA, Carlos Augusto Alves Cardoso; OLIVEIRA, et al. Generalization of VIS–NIR–SWIR spectral models for nitrogen prediction in sugarcane leaves. *Remote Sensing, Basel*, v. 16, n. 22, art. 4250, 2024. DOI: 10.3390/rs16224250.

SILVA, Leonardo França Da et al. Sensoriamento Remoto E Índices De Vegetação: Conceitos E Aplicações - REVISÃO DE LITERATURA. In: SILVA, Leonardo França Da; OLIVEIRA, Josiane

Rosa Silva De; JESUS, Fernanda Lamede Ferreira De (Eds.). Cultivando o futuro: tendências e desafios nas ciências agrárias 5. 1. : Atena Editora, 2024. p. 19–32.

SILVA, Maria Vitoria Serafim Da; PADILHA, Rodrigo Tenório; PADILHA, Déborah De Melo Magalhães. Benefícios da Moringa oleifera para saúde humana e animal: Revisão de Literatura. Research, Society and Development, v. 10, n. 8, p. e50010817495, 16 jul. 2021.

SILVA, Marina. Estratégias de seleção de milho doce por fenotipagem convencional e de alto desempenho. [S.l.]: Universidade Federal de Uberlândia, 27 fev. 2020.

SILVA, Wallyson Francisco Lopes Da et al. Desenvolvimento inicial de mudas de moringa oleífera Lam submetidas a diferentes de substrates. Conjecturas, v. 21, n. 3, p. 434–450, 27 set. 2021.

SIMÕES, Cláudia Rossini et al. Imagens multiespectrais para avaliação de índice de área foliar e massa seca do capim “Tifton 85”, sob adubação nitrogenada. Ciência Rural, v. 45, n. 4, p. 697–703, abr. 2015.

SOARES, Júlia Martins et al. Low-cost system for multispectral image acquisition and its applicability to analysis of the physiological potential of soybean seeds. Acta Scientiarum. Agronomy, v. 45, p. e57060, 22 nov. 2022.

SONIA et al. Appraisal of long-term responsiveness of normalized difference vegetation index to climatic factors using multiscale time–frequency decomposition in an arid environment. Frontiers in Earth Science, v. 11, p. 1265292, 19 out. 2023.

SOUZA, Francisco Marto De. Universidade Federal da Paraíba Centro de Ciências Agrárias Departamento de Solos e Engenharia Rural Programa de Pós-Graduação em Ciência do Solo. 2018.

SOUZA, Jhiorranni F. et al. Relationship between spectral indices and quality parameters of tifton 85 forage. Revista Caatinga, v. 37, p. e12139, 2024.

STAMFORD, John D. et al. Development of an accurate low cost NDVI imaging system for assessing plant health. Plant Methods, v. 19, n. 1, p. 9, 30 jan. 2023.

STRONG, Conor J.; BURNSIDE, Niall G.; LLEWELLYN, Dan. The potential of small-Unmanned Aircraft Systems for the rapid detection of threatened unimproved grassland communities using an Enhanced Normalized Difference Vegetation Index. PLOS ONE, v. 12, n. 10, p. e0186193, 12 out. 2017.

THARUKA, M. V. T.; KULARATHNA, K. M.; RAY, Ram L. Application of RGB-Imaging techniques for high-throughput plant phenotyping- A Review. Turkish Journal of Agriculture - Food Science and Technology, v. 13, n. s2, p. 3678–3686, 23 nov. 2025.

TRINDADE, Polyanna Ribeiro; RODRIGUES, Carlos Ribeiro. Sensores Portáteis Para Avaliação Do Nitrogênio Na Soja E Avaliação Do Crescimento De Raiz De Milho Com Bioestimulante. 2020.

UNNI, Rohit *et al.* Advancing materials science through next-generation machine learning. Current Opinion in Solid State and Materials Science, v. 30, p. 101157, jun. 2024.

VIDICAN, Roxana *et al.* Using Remote Sensing Vegetation Indices for the Discrimination and Monitoring of Agricultural Crops: A Critical Review. Agronomy, v. 13, n. 12, p. 3040, dez. 2023.

VINCINI, M.; FRAZZI, E.; D’ALESSIO, P. A broad-band leaf chlorophyll vegetation index at the canopy scale. Precision Agriculture, v. 9, n. 5, p. 303–319, out. 2008.

WANG, Weixuan *et al.* Integration of high-throughput phenotyping, GWAS, and predictive models reveals the genetic architecture of plant height in maize. Molecular Plant, v. 16, n. 2, p. 354–373, fev. 2023.

WANG, Y. *et al.* UAV multispectral remote sensing for agriculture: A comparative study of radiometric correction methods under varying illumination conditions. Biosystems Engineering, v. 248, p. 240–254, 2024

Watson, D. J. Comparative physiological studies on the growth of field crops: I. Variation in net assimilation rate and leaf area between species and varieties and within and between years. Annals of Botany, v. 11, p. 41–76, 1947

WATSON, D. J. Comparative physiological studies on the growth of field crops: I. Variation in net assimilation rate and leaf area between species and varieties and within and between years. *Annals of Botany*, Oxford, v. 11, n. 41, p. 41–76, 1947.

XIE, Jiayang; SHEN, Yutao; CEN, Haiyan. Real-time Reflectance Generation for UAV Multispectral Imagery using an Onboard Downwelling Spectrometer in Varied Weather Conditions. arXiv, , 27 dez. 2024. Disponível em: <<http://arxiv.org/abs/2412.19527>>. Acesso em: 9 jan. 2026

XUE, Jinru; SU, Baofeng. Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications. *Journal of Sensors*, v. 2017, p. 1–17, 2017.

YAN, Kai et al. A global systematic review of the remote sensing vegetation indices. *International Journal of Applied Earth Observation and Geoinformation*, v. 139, p. 104560, maio 2025.

ZHANG, Yamei et al. Hyperspectral Prediction Models of Chlorophyll Content in Paulownia Leaves under Drought Stress. *Sensors*, v. 24, n. 19, p. 6309, 29 set. 2024.