

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

FERNANDA DE SOUZA CARDOSO

**METODOLOGIA INOVADORA PARA DETERMINAÇÃO DA DENSIDADE
BÁSICA DA MADEIRA UTILIZANDO IMAGENS MULTIESPECTRAIS E
CÂMERA MAPIR RGNIR.**

**MONTE CARMELO
2025**

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

FERNANDA DE SOUZA CARDOSO

**METODOLOGIA INOVADORA PARA DETERMINAÇÃO DA DENSIDADE
BÁSICA DA MADEIRA UTILIZANDO IMAGENS MULTIESPECTRAIS E
CÂMERA MAPIR RGNIR.**

Dissertação apresentada ao Programa de Pós
Graduação em Agricultura e Informações
Geoespaciais da Universidade Federal de
Uberlândia, *Campus* Monte Carmelo, como
requisito para obtenção do título de Mestre.

Área de Concentração: Sistemas integrados
de produção vegetal – Recursos Florestais

Orientador: Antônio José Vinha Zanuncio
Coorientadores: Prof. Dr. George Deroco
Martins
Prof^ª Dr^a. Amélia Guimarães Carvalho

**MONTE CARMELO
2025**

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

C268
2025 Cardoso, Fernanda de Souza, 2000-
Metodologia inovadora para determinação da densidade básica da madeira utilizando imagens multiespectrais e câmera mapir RGNIR. [recurso eletrônico] / Fernanda de Souza Cardoso. - 2025.

Orientador: Antônio José Vinha Zanuncio.

Coorientador: George Deroco Martins .

Coorientadora: Amélia Guimarães Carvalho.

Dissertação (Mestrado) - Universidade Federal de Uberlândia,
Pós-graduação em Agricultura e Informações Geoespaciais.

Modo de acesso: Internet.

DOI <http://doi.org/10.14393/ufu.di.2025.476>

Inclui bibliografia.

Inclui ilustrações.

1. Agronomia. I. Zanuncio, Antônio José Vinha, 1987-, (Orient.).
II. , George Deroco Martins, 1987-, (Coorient.). III. Carvalho, Amélia
Guimarães, 1987-, (Coorient.). IV. Universidade Federal de
Uberlândia. Pós-graduação em Agricultura e Informações
Geoespaciais. V. Título.

CDU: 631

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:

Gizele Cristine Nunes do Couto - CRB6/2091

Nelson Marcos Ferreira - CRB6/3074



ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Agricultura e Informações Geoespaciais				
Defesa de:	Dissertação de Mestrado Acadêmico				
Data:	28/07/2025	Hora de início:	13h00	Hora de encerramento:	15:00
Matrícula do Discente:	32322AIG003				
Nome do Discente:	Fernanda de Souza Cardoso				
Título do Trabalho:	<i>Metodologia inovadora para determinação da densidade básica da madeira utilizando imagens multiespectrais e câmera Mapir RGNIR</i>				
Área de concentração:	Informações geoespaciais e tecnologias aplicadas à produção agrícola				
Linha de pesquisa:	Sistemas Integrados de Produção Vegetal				
Projeto de Pesquisa:	Conservação e utilização sustentável dos recursos florestais				

Reuniu-se na sala virtual, a banca examinadora, designada pelo Colegiado do Programa de Pós-graduação em Agricultura e Informações Geoespaciais, assim composta: Prof. Dr. Antônio José Vinha Zanuncio (Presidente - Universidade Federal de Uberlândia-UFU), Dra. Olivia Pereira Lopes (Universidade Federal de Uberlândia-UFU) e Prof. Dr. Liniker Fernandes da Silva (Universidade Federal do Recôncavo da Bahia-UFRB). Iniciando os trabalhos o presidente da mesa, Dr. Antônio José Vinha Zanuncio, apresentou a Comissão Examinadora e o candidato, agradeceu a presença do público, e concedeu à discente a palavra para a exposição do seu trabalho. A duração da apresentação da discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor presidente concedeu a palavra, pela ordem sucessivamente, aos examinadores, que passaram a arguir a candidato. Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando a candidata:

Aprovada.

Esta defesa faz parte dos requisitos necessários à obtenção do título de Mestre.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Antônio José Vinha Zanuncio, Professor(a) do Magistério Superior**, em 29/07/2025, às 18:02, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Olivia Pereira Lopes, Técnico(a) de Laboratório**, em 29/07/2025, às 22:05, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Liniker Fernandes da Silva, Usuário Externo**, em 19/08/2025, às 15:52, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **6543753** e o código CRC **62D95F90**.

Referência: Processo nº 23117.051418/2025-30

SEI nº 6543753

FERNANDA DE SOUZA CARDOSO

**METODOLOGIA INOVADORA PARA DETERMINAÇÃO DA DENSIDADE
BÁSICA DA MADEIRA UTILIZANDO IMAGENS MULTIESPECTRAIS E
CÂMERA MAPIR RGNIR.**

Dissertação apresentada ao Programa de Pós
Graduação em Agricultura e Informações
Geoespaciais da Universidade Federal de
Uberlândia, Campus Monte Carmelo, como
requisito para obtenção do título de Mestre.

Área de Concentração: Sistemas integrados
de produção vegetal – Recursos Florestais

Monte Carmelo, 28 de julho de 2025

Banca Examinadora:

Prof. Dr. Antônio José Vinha Zanuncio
Orientador

Prof^a. Dr^a. Olivia Pereira Lopes
Membro da Banca

Prof. Dr. Liniker Fernandes da Silva
Universidade Federal do Reconcavo da Bahia
Membro da Banca

**MONTE CARMELO
2025**

AGRADECIMENTOS

Em primeiro lugar, agradeço a Deus, por guiar meus passos, iluminar meu caminho e colocar pessoas importantes ao longo desta desafiadora jornada.

Sou profundamente grata aos meus pais, Vanice e Nilton, minhas maiores fontes de força, amor e inspiração. Obrigada por acreditaram em mim e me apoiarem incondicionalmente. O incentivo e exemplo de dedicação de vocês foram fundamentais para que eu pudesse alcançar este momento.

Quero expressar meu carinho e agradecimento ao Lucas Mateus, que esteve presente com paciência, compreensão e apoio durante todo esse período. Sua companhia, foi decisiva para que eu mantivesse o foco e a motivação, especialmente nos momentos de maior dificuldade.

Estendo meus agradecimentos a toda a minha família, que sempre esteve ao meu lado com palavras de incentivo e apoio sincero. Cada demonstração de cuidado e conselho recebido me motivaram a seguir em frente.

Manifesto meu reconhecimento ao meu orientador, Professor Antonio José Vinha Zanuncio, pela oportunidade concedida e pela confiança em meu trabalho. Sua orientação, sua disponibilidade e sua generosidade em compartilhar conhecimentos, aliadas à paciência e dedicação, foram essenciais para o desenvolvimento desta pesquisa.

Meus sinceros agradecimentos aos meus coorientadores, Amélia Guimarães e George Deroco, cuja colaborações foram imprescindíveis para o aprimoramento deste trabalho. Ao Professor Jorge, reconheço seu apoio técnico e suas valiosas sugestões, que contribuíram para a consolidação dos resultados. A contribuição de ambos foi fundamental para minha formação acadêmica e para o sucesso deste estudo.

Agradeço à Universidade Federal de Uberlândia, *campus* Monte Carmelo, e a todos os professores que, direta ou indiretamente, colaboraram para a construção do meu conhecimento ao longo do curso. A excelência do corpo docente e a infraestrutura da instituição foram pilares importantes nessa trajetória.

Registro também meu agradecimento ao Programa de Pós-Graduação da UFU em Agricultura e Informações Geoespaciais e ao Instituto de Ciências Agrárias (ICIAG/UFU), cujos apoios institucionais foram fundamentais para o desenvolvimento deste trabalho.

Aos Professores Doutores Olívia e Liniker, agradeço profundamente por aceitarem o convite para compor a banca examinadora e pelas valiosas contribuições que certamente enriqueceram este trabalho, proporcionando uma avaliação crítica e construtiva.

Finalmente, a todos que, de alguma forma, direta ou indiretamente, torceram, apoiaram e oraram por essa conquista. Cada gesto de incentivo, palavra de encorajamento e demonstração de confiança foram importantes para que eu pudesse seguir firme até aqui.

*"O sucesso nasce do querer, da
determinação e da persistência em se chegar
a um objetivo."*

(José de Alencar)

BIOGRAFIA

Fernanda de Souza Cardoso nasceu em Monte Carmelo – MG, em 28 de abril de 2000, filha de Vanice Helena de Souza Cardoso e Nilton José Cardoso. Estudou em escolas públicas do município dos 5 aos 17 anos, demonstrando desde a infância interesse pelas ciências da natureza e pelo ambiente rural.

Motivada pelo desejo de atuar em prol da preservação ambiental e da sustentabilidade no campo, ingressou em 2018 no curso de Engenharia Florestal da Universidade Federal de Uberlândia – *Campus* Monte Carmelo, por meio do Sistema de Seleção Unificada (SiSU), utilizando a nota do Exame Nacional do Ensino Médio (ENEM).

Durante a formação, participou de atividades acadêmicas e extracurriculares voltadas à nutrição do solo integrando o Programa Institucional de Bolsas de Iniciação Científica (PIBIC), com os projetos “Capacidade máxima de adsorção e dessorção de fosfato em Latossolos com mineralogia contrastante da região do Cerrado Mineiro” e “Efeito da matéria orgânica na capacidade máxima de adsorção e dessorção de fosfato em Latossolos do Cerrado Mineiro”. Também realizou estágio não obrigatório no Instituto Estadual de Florestas (IEF) em Monte Carmelo – MG.

No último período da graduação, ingressou no estágio obrigatório no escritório de consultoria ambiental Gestão de Recursos Hídricos – GH2O, atuando na área de regularização ambiental junto a órgãos públicos. Essa experiência marcou seu primeiro trabalho na área, assumindo o cargo de Analista em 2023, logo após formatura.

Naquele mesmo ano se desligou da consultoria e passou a atuar na Cooperativa Regional de Cafeicultores em Guaxupé Ltda. – Cooxupé, contribuindo com projetos e treinamentos voltados à segurança do trabalho e boas práticas agrícolas junto aos cafeicultores da região. Atualmente, exerce a função de consultora social na cooperativa, com foco em melhorias constantes das propriedades e fortalecimento das relações entre produtores e trabalhadores, a fim de adequar as fazendas à programas de sustentabilidade.

Em 2023, ingressou no Programa de Pós-Graduação em Agricultura e Informações Geoespaciais da Universidade Federal de Uberlândia – *Campus* Monte Carmelo, sob orientação do Prof. Dr. Antonio José Vinha Zanuncio. Sua pesquisa de mestrado teve como objetivo avaliar estimativas de densidade de madeira com base em espectros registrados nos planos transversais e tangenciais de amostras, utilizando uma câmera Mapir com filtro RGN — ferramenta de baixo custo, fácil manuseio e alta agilidade. Ao término de dois anos de dedicação à pesquisa, recebeu, em agosto de 2025, o título de “Mestre”.

SUMÁRIO

1 INTRODUÇÃO	9
2 MATERIAIS E MÉTODOS	10
2.1 <i>Determinação da densidade básica</i>	10
2.2 <i>Captura de imagens multiespectrais.....</i>	10
2.3 <i>Extração de dados de reflectância e análise de correlação</i>	11
2.4 <i>Modelos testados para estimar a densidade básica</i>	11
3 RESULTADOS E DISCUSSÃO	13
3.1 <i>Densidade básica</i>	13
3.2 <i>Análise de correlação</i>	14
3.3 <i>Modelagem para estimar a densidade básica</i>	16
4 CONCLUSÃO.....	22
REFERÊNCIAS	23

RESUMO

CARDOSO, Fernanda de Souza. Metodologia inovadora para determinação da densidade básica da madeira utilizando imagens multiespectrais e câmera Mapir RGNIR. Orientador: Antônio José Vinha Zanuncio. 2025. 25 f. Dissertação (Mestrado em Agricultura e Informações Geoespaciais) – Universidade Federal de Uberlândia, Monte Carmelo, 2025.

A densidade básica da madeira influencia diretamente o rendimento, os custos operacionais e a qualidade do produto final, sendo um parâmetro essencial no setor florestal. Contudo, os métodos tradicionais para sua determinação são demorados, destrutivos e onerosos, o que demanda alternativas mais ágeis e econômicas. Este estudo utilizou imagens multiespectrais obtidas com uma câmera *Mapir Survey 3* (RGNIR) para estimar a densidade básica da madeira de *Eucalyptus grandis* e *Pinus oocarpa*. Foram analisadas 142 amostras, com imagens capturadas em quatro estágios de secagem: saturada, em secagem natural, em umidade de equilíbrio e anidra. As imagens foram processadas no software ENVI Classic para extração da reflectância; o Minitab 16 foi utilizado para análise de correlação, e o software Weka 3.8.6 para o ajuste dos modelos de aprendizado de máquina: Regressão Linear, *Multilayer Perceptron* (MLP), *Random Forest* (RF) e *Support Vector Machine* para Regressão (SMOreg). A reflectância no plano transversal, especialmente na faixa espectral do vermelho, apresentou maior correlação com a densidade básica. O modelo Random Forest obteve os melhores resultados, com coeficiente de correlação superior a 83% e 81%, e RMSE inferior a 11% e 12% para os dados de treinamento e validação cruzada, respectivamente. Os modelos MLP, SMOreg e Regressão Linear também apresentaram desempenho satisfatório, especialmente com madeira saturada. Esta pesquisa evidencia a viabilidade de se estimar a densidade básica da madeira por meio de imagens multiespectrais, oferecendo uma metodologia rápida, não destrutiva, de baixo custo e de simples aplicação para o setor florestal.

Palavras-chave: *Eucalyptus grandis* e *Pinus oocarpa*; imagens multiespectrais, inteligência artificial; modelos de predição.

ABSTRACT

CARDOSO, Fernanda de Souza. Innovative methodology for determining basic wood density using multispectral images and a Mapir RGNIR camera. Advisor: Antônio José Vinha Zanuncio. 2025. 25 p. Dissertation (Master's in Agriculture and Geospatial Information) – Federal University of Uberlândia, Monte Carmelo, 2025.

Basic wood density directly influences yield, operational costs, and final product quality, making it an essential parameter in the forestry sector. However, traditional methods for its determination are time-consuming, destructive, and costly, which highlights the need for faster and more economical alternatives. This study used multispectral images obtained with a Mapir Survey 3 (RGNIR) camera to estimate the basic wood density of *Eucalyptus grandis* and *Pinus oocarpa*. A total of 142 samples were analyzed, with images captured at four drying stages: saturated, naturally drying, equilibrium moisture content, and oven-dry. The images were processed using ENVI Classic software to extract reflectance; Minitab 16 was used for correlation analysis, and Weka 3.8.6 software was used to fit machine learning models: Linear Regression, Multilayer Perceptron (MLP), Random Forest (RF), and Support Vector Machine for Regression (SMOreg). Reflectance in the cross-sectional plane, especially in the red spectral band, showed the strongest correlation with basic density. The Random Forest model achieved the best results, with correlation coefficients above 83% and 81%, and RMSE below 11% and 12% for the training and cross-validation datasets, respectively. The MLP, SMOreg, and Linear Regression models also performed satisfactorily, particularly with saturated wood. This research demonstrates the feasibility of estimating basic wood density through multispectral imagery, offering a rapid, non-destructive, low-cost, and easy-to-apply methodology for the forestry sector.

Index terms: *Eucalyptus grandis* and *Pinus oocarpa*; multispectral images, artificial intelligence; prediction models

1 INTRODUÇÃO

O setor florestal brasileiro atingiu valor bruto de produção de R\$ 202,6 bilhões em 2023, representando 0,9% do PIB nacional e gerou 2,69 milhões de empregos diretos e indiretos, consolidando-se como um dos pilares econômicos e sociais do Brasil (IBÁ, 2024). A extensão de áreas de árvores plantadas no país atingiu 10 milhões de hectares em 2023, registrando um aumento de 3% em comparação ao ano anterior. O eucalipto é a espécie mais cultivada, engloba 7,8% milhões de hectares e 76% da área plantada no Brasil. Em seguida, o pinus ocupa 19% da área plantada com 1,9 milhão de hectares plantados (IBÁ, 2024).

O cultivo de árvores de pinus e eucalipto são utilizados na produção de polpa celulósica, papel, painéis de madeira, pisos laminados, madeira serrada e carvão vegetal. Todos esses produtos dependem da densidade da madeira, que afeta rendimento, custo e qualidade do produto (Cunha; et al., 2021; Yin e Liu, 2021; Silva et al., 2024).

A densidade básica é determinada pela relação entre massa seca e volume saturado, sendo o parâmetro mais avaliado da madeira, devido a sua fácil determinação e relação com o desempenho industrial da madeira em diferentes setores (Almeida et al., 2023; Pimenta et al., 2024; Romero et al., 2024). Por isso, determinar a densidade é uma etapa essencial e rotineira em empresas florestais (Silva; Vale; Miguel, 2021). Embora a densidade seja importante, sua determinação pelos meios tradicionais utiliza métodos destrutivos, demorados e onerosos, dificultando sua implementação em larga escala. Para analisar a qualidade da madeira, é essencial que as empresas florestais adotem técnicas rápidas, não destrutivas e econômicas (Xin; et al., 2022; Amaral; et al., 2021).

Sensores multiespectrais permitem a captura de imagens em diferentes bandas espectrais, proporcionando uma melhor compreensão de características físicas (Amaral; et al., 2021), químicas (Mancini; et al., 2021), mecânicas (Ma; et al., 2021) e anatômicas (Sánchez; et al., 2013) das plantas, como a saúde, a densidade e tipo de vegetação (Novo; Ponzoni, 2021). Sua metodologia envolve a exposição de amostras à radiação eletromagnética dentro da faixa espectral de interesse, resultando na obtenção dos espectros. A partir dos resultados pode-se correlacionar a reflectância das amostras com dados encontrados diretamente no campo ou laboratório, permitindo que sejam realizadas estimativas precisas (Arriel, 2019).

Considerando as grandes quantidades de matéria-prima que chegam as fábricas todos os dias, a determinação da densidade da madeira por métodos rápidos, como os

sensores multiespectrais são extremamente úteis. Assim, o objetivo deste estudo é determinar a densidade básica da madeira a partir de modelos de inteligência artificial com base em espectros registrados nos planos transversais e tangenciais de amostras de *Eucalyptus grandis* e *Pinus oocarpa*, obtidos por uma câmera multiespectral de baixo custo.

2 MATERIAIS E MÉTODOS

2.1 Determinação da densidade básica

O estudo utilizou cinco árvores de *Eucalyptus grandis* com 15 anos e cinco árvores de *Pinus oocarpa* com 18 anos. As amostras foram retiradas em diferentes posições da árvore de forma aleatória, sendo 55 amostras de *Eucalyptus grandis* e 87 de *Pinus oocarpa*, totalizando 142 amostras com 150 mm × 50 mm × 50 mm em comprimento, largura e espessura, respectivamente. Os mesmos foram submersos em recipiente com água até a saturação.

Após a saturação, o volume das amostras foi mensurado com um paquímetro, em seguida, condicionadas em ambiente climatizado (50% de umidade relativa e 25°C) para secagem até atingirem a umidade de equilíbrio. Após estabilização das massas, as amostras foram colocadas em estufa a 105°C por 48 horas para obtenção de sua massa anidra. A densidade básica foi calculada pela razão entre a massa anidra e o volume saturado conforme NBR 11941 (ABNT, 2003).

2.2 Captura de imagens multiespectrais

Para obtenção dos valores de reflectância, foram capturadas imagens multiespectrais nas superfícies tangenciais e transversais com duas repetições, à céu aberto em Monte Carmelo - MG, Brasil (18° 43' 30" S, 47° 29' 56" O). As imagens foram capturas durante o período de climatização e perda de umidade, sendo realizadas em quatro momentos: madeira saturada (zero dias de secagem); em processo de secagem natural (após cinco dias); após atingir a umidade de equilíbrio (15 dias de secagem); e em condição anidra (após secagem em estufa). Esta medida foi tomada para considerar a capacidade de determinação da densidade através de imagens multiespectrais independente da umidade da madeira.

A aquisição dos dados foi realizada por meio de uma câmera multiespectral de baixo custo, modelo *MAPIR Survey 3*, equipada com o filtro RGNIR (Red-Green-NIR). A escolha dessa câmera se justifica por sua acessibilidade e praticidade operacional, permitindo a obtenção de imagens multiespectrais sem a necessidade de equipamentos laboratoriais complexos. Além disso, sua configuração espectral possibilita a captura de bandas no infravermelho próximo, que demonstram forte correlação com as propriedades estruturais e químicas da madeira. Essa abordagem reduz significativamente os custos operacionais e viabiliza a implementação da metodologia em larga escala.

Na aquisição de imagens, as amostras foram posicionadas à altura de 1,00 m do solo em fundo preto e no intervalo de 12 às 13h para captação das imagens. Nessa faixa de horário, o sol geralmente está em um ângulo alto no céu, proporcionando luz uniforme e reduzindo as sombras, o que pode minimizar distorções nas imagens e facilitar a análise espectral (Souza, 2021). Os sensores RGNIR utilizados possuem uma lente óptica com três filtros para separar a radiação eletromagnética em três comprimentos de onda: vermelho, verde e infravermelho próximo. É uma modificação do sensor RGB tradicional, onde o filtro azul é substituído pelo filtro de infravermelho próximo.

2.3 Extração de dados de reflectância e análise de correlação

Para a extração dos valores de reflectância utilizou-se o *software ENVI Classic*. No *software Minitab 16* foram excluídos os *outliers* e realizada análise de correlação entre as bandas e índices de vegetação em relação à densidade básica determinada em laboratório.

2.4 Modelos testados para estimar a densidade básica

Para estimar a densidade básica da madeira, foram testados quatro modelos de aprendizado de máquina utilizando o *software Weka 3.8.6*: Regressão Linear, *Random Forest*, *Multilayer Perceptron* (MLP) e *Support Vector Machine* para Regressão (SMOreg) (Tabela 1). Esses modelos foram escolhidos com base em sua capacidade de capturar relações entre as variáveis espectrais e a densidade da madeira, buscando um método preciso, eficiente e de fácil implementação para o setor florestal.

Tabela 1. Modelos utilizados para estimar a densidade básica da madeira

Nome do modelo	Tipo
Regressão linear	Regressão simples
<i>Multilayer Perceptron</i> (MLP)	Rede neural
<i>Random Forest</i> (RF)	Conjunto de árvores de decisão
<i>Support Vector Machine</i> para Regressão (SMOreg)	Vetores de suporte

Os valores de reflectância extraídos das imagens foram utilizados como variáveis preditoras nos modelos de aprendizado de máquina, juntamente com os índices espectrais NDVI (*Normalized Difference Vegetation Index*) e GNDVI (*Green Normalized Difference Vegetation Index*) (Tabela 2). A inclusão desses índices foi baseada na literatura, que demonstra que a reflectância na banda NIR pode fornecer informações indiretas sobre a estrutura celular e a densidade da madeira. Além disso, os índices espectrais permitem minimizar a influência de fatores externos, como iluminação e variabilidade das amostras, aumentando a robustez das estimativas. A relação desses índices com a umidade da madeira também foi considerada, uma vez que a secagem influencia diretamente na reflectância e, conseqüentemente, na resposta espectral utilizada pelos modelos preditivos.

Tabela 2. Índices de vegetação calculados

Índice de vegetação	Equação
NDVI	$NDVI = \frac{(NIR-R)}{NIR+R}$ (ROUSE et al., 1973)
GNDVI	$GNDVI = \frac{(NIR-G)}{NIR+G}$ (GITELSON et al., 1996)

Entre os algoritmos testados, a Regressão Linear foi incluída como um modelo tradicional de fácil interpretação, permitindo avaliar a influência individual de cada variável espectral na densidade da madeira. O *Random Forest* (RF), composto por um conjunto de árvores de decisão, foi testado por sua capacidade de lidar com variáveis correlacionadas e proporcionar alta precisão preditiva. O *Multilayer Perceptron* (MLP), baseado em redes neurais, foi utilizado para capturar padrões não lineares, explorando a complexidade das interações espectrais com a densidade. Por fim, o *Support Vector Machine* para Regressão (SMOreg) foi incluído devido à sua eficiência na modelagem de variáveis contínuas em dados complexos.

A avaliação da qualidade do ajuste foi conduzida com base no coeficiente de determinação (R^2) (Equação 1), representando a qualidade do ajuste da linha de regressão;

raiz do erro médio quadrático (RMSE%) (Equação 2), uma métrica de avaliação utilizada para medir o desempenho de modelos de regressão; e uma análise gráfica da distribuição dos resultados do melhor modelo.

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

$$RMSE (\%) = \frac{\left(\sqrt{\frac{\sum(y_i - \hat{y}_i)^2}{n}} \right)}{\bar{y}} * 100 \quad (2)$$

Sendo, y_i os valores observados da variável dependente; \hat{y}_i os valores preditos pelo modelo; \bar{y} a média dos valores observados; e n o número de observações.

3 RESULTADOS E DISCUSSÃO

3.1 Densidade básica

A densidade básica das amostras de *E. grandis* e *P. oocarpa* variaram de 0,4861 g. cm⁻³ a 0,7354 g. cm⁻³ e 0,2648 g. cm⁻³ e 0,5440 g. cm⁻³, respectivamente. Resultando em médias de 0,618 g. cm⁻³ e 0,389g. cm⁻³, respectivamente (Tabela 3).

Tabela 3. Resultados de massa seca média, volume saturado médio e densidade básica média calculados para eucalipto e pinus.

Espécie	Massa seca (g)	Volume saturado (cm ³)	Densidade básica (g. cm ⁻³)
<i>Eucalyptus grandis</i>	253,43	410,1392	0,618
<i>Pinus oocarpa</i>	154,78	397,2206	0,389

A madeira de eucalipto apresenta, em geral, uma densidade básica mais elevada do que a de pinus, atribuída às suas características anatômicas, como maior porcentagem de parede celular das fibras, principal componente da madeira de eucalipto. A densidade do eucalipto varia entre 0,420 g. cm⁻³ a 0,600 g. cm⁻³ (Bonfatti Jr., et al, 2023). Em contrapartida, madeiras de pinus tendem a ter densidades mais baixas, entre 0,370 g. cm⁻³ e 0,440 g. cm⁻³ devido ao maior volume de espaços vazios das traqueídes longitudinais, que corresponde a mais de 90% da composição da madeira deste grupo (Ramos, et al,

2024). A densidade da madeira é um fator crucial que influencia diretamente suas propriedades mecânicas, como resistência e durabilidade, sendo essencial para determinar seu uso adequado em diversas aplicações, como construção civil, movelaria, energia ou produção de polpa celulósica (Gao et al., 2017; Luan et al., 2021).

3.2 Análise de correlação

Nas capturas no plano transversal (tabela 4), a faixa do vermelho apresentou correlação de Pearson moderada negativa com a densidade básica com a madeira saturada (-0,692), a medida que a madeira iniciou o processo de secagem a correlação piorou, porém se manteve alta (-0,530). No plano longitudinal, o valor não foi significativo para todas as bandas e índices de vegetação com a madeira saturada, nas outras medições, do plano longitudinal, os valores de correlação foram piores quando comparados as medições no plano transversal.

Tabela 4. Correlação de Person entre faixas espectrais e índices de vegetação e a densidade básica das amostras de madeira de eucalipto e pinus nos quatro estágios de secagem: madeira saturada (MS); em processo de secagem (PS); madeira em equilíbrio (ME); e madeira anidra (MA) no plano transversal e longitudinal

Faixas espectrais e índices de vegetação	Plano transversal			
	Estágio de secagem			
	MS	PS	ME	MA
Vermelho	-0,692	-0,530	NÃO SIG.	0,542
Verde	-0,49	-0,460	-0,674	-0,547
Infravermelho próximo	-0,476	-0,456	-0,606	NÃO SIG.
NDVI	NÃO SIG.*	-0,289	-0,510	-0,199
GNDVI	NÃO SIG.	0,231	NÃO SIG.	NÃO SIG.
Faixas espectrais e índices de vegetação	Plano longitudinal			
	Estágio de secagem			
	MS	PS	ME	MA
Vermelho	NÃO SIG.*	-0,438	0,269	0,535
Verde	NÃO SIG.	-0,288	-0,734	-0,725
Infravermelho próximo	NÃO SIG.	-0,439	-0,587	-0,837
NDVI	NÃO SIG.	-0,225	-0,597	-0,843
GNDVI	NÃO SIG.	NÃO SIG.	0,569	0,485

*valor não significativo considerando p-valor igual a 0,05

No plano transversal, as amostras saturadas apresentaram correlação negativa moderada a forte entre as faixas Vermelho (-0,692) e Verde (-0,49) e a densidade da

madeira. Portanto, nesse estágio, quanto maior a reflectância nessas faixas, menor a densidade da madeira. A faixa Infravermelho Próximo apresentou uma correlação negativa fraca com a densidade (-0,476). Os índices de vegetação NDVI e GNDVI não apresentaram correlação significativa com a densidade neste estágio.

Durante o processo de secagem (PS), as faixas Vermelho, Verde e Infravermelho Próximo apresentaram correlação negativa moderada com a densidade, com valores de -0,530; -0,460 e -0,456, respectivamente. Os índices NDVI e GNDVI apresentaram correlações fracas com a densidade.

Na madeira em umidade de equilíbrio higroscópico (UEH), a faixa Verde, Infravermelho Próximo e NDVI apresentaram correlação negativa moderada com a densidade, com valores de -0,674; -0,606 e -0,510, respectivamente. Não houve correlação significativa entre a faixa Vermelho e o índice GNDVI com a densidade neste estágio.

Na madeira anidra (MA), a faixa Vermelho passou a apresentar uma correlação positiva moderada com a densidade (0,542), indicando que, nesse estágio, quanto maior a reflectância nessa faixa, maior a densidade da madeira. A faixa Verde, por outro lado, apresentou correlação negativa moderada com a densidade (-0,547). O índice NDVI apresentou correlação negativa fraca, enquanto a faixa Infravermelho Próximo e o índice GNDVI não apresentaram correlação significativa.

Os resultados indicam que a correlação entre as faixas espectrais e a densidade da madeira varia ao longo do processo de secagem, o que pode ser atribuído a alterações nas propriedades da madeira, como a perda de água, a contração celular e as mudanças na composição química (Ma et al., 2022; Tsuchikawa, Inagaki e Ma, 2023). Na madeira saturada e em processo de secagem, as faixas Vermelho e Verde apresentaram correlação negativa com a densidade, possivelmente devido à maior absorção da luz por componentes como a lignina e a água presentes na madeira. Na madeira anidra, a correlação da faixa Vermelho se tornou positiva, sugerindo que a reflectância nessa faixa pode estar relacionada à estrutura celular da madeira após a remoção da água.

A correlação negativa da faixa Verde com a densidade na madeira em equilíbrio higroscópico e anidra pode estar relacionada à interação da luz com a estrutura da madeira, como o tamanho e arranjo das células. A ausência de correlação significativa para algumas faixas e índices pode ser atribuída à complexidade da interação da luz com a madeira e à influência de outros fatores, como a composição química e a presença de extrativos (Ma et al., 2022).

No plano longitudinal, não houve correlação significativa entre as faixas espectrais e índices de vegetação com a densidade quando a madeira se encontrava saturada. Para as madeiras em processo de secagem, as faixas Vermelho, Verde e Infravermelho Próximo, assim como o índice NDVI, apresentaram correlação negativa fraca com a densidade. O índice GNDVI não apresentou correlação significativa. Para a madeira na umidade de equilíbrio, a faixa Vermelho apresentou correlação positiva fraca com a densidade, enquanto a faixa Verde e o índice NDVI apresentaram correlação negativa forte e moderada, respectivamente. A faixa Infravermelho Próximo apresentou correlação negativa moderada. O índice GNDVI apresentou correlação positiva moderada com a densidade. Por fim, para a madeira anidra, a faixa Vermelho apresentou correlação positiva moderada com a densidade, enquanto as faixas Verde e Infravermelho Próximo, assim como o índice NDVI, apresentaram correlação negativa forte. O índice GNDVI apresentou correlação positiva fraca com a densidade.

As correlações foram mais evidentes quando as fotos foram tiradas no plano transversal. Neste plano, os elementos anatômicos estão mais expostos, além de permitir uma variação radial maior, o que possibilitou uma melhor análise das variações da densidade da madeira.

3.3 Modelagem para estimar a densidade básica

As métricas de acurácia associadas aos modelos de regressão foram capazes de estimar a densidade da madeira a partir de espectros coletados nos planos transversais e longitudinais (Tabela 5), sendo os melhores desenvolvidos usando espectros registrados na superfície transversal da madeira.

Tabela 5. Coeficiente de determinação para treinamento e validação (R^2); coeficiente de determinação validação cruzada (R^2_{cv}); raiz do erro médio quadrático para treinamento e validação (RMSE%); raiz do erro médio quadrático para validação cruzada (RMSE% $_{cv}$) dos modelos *Multilayer Perceptron* (MP), *Support Vector Machine* para regressão (SMOreg), *Randon Forest* (RF) e Regressão Linear (RL) testados para estimar a densidade básica de amostras de madeira de eucalipto e pinus nos quatro estágios de secagem: madeira saturada (MS); em processo de secagem (PS); madeira em equilíbrio (ME); e madeira anidra (MA) no plano transversal e longitudinal

Plano Transversal							
Modelo	Técnica validação	Medidas de validação	MS	PS	ME	MA	Média
MP	Treino e validação	RMSE%	10,92	13,80	9,82	10,59	11,28
		R^2	90,75	84,27	87,15	71,98	83,54

SMOreg		RMSE%	8,35	12,78	9,71	15,81	11,66
		R ²	93,50	78,08	86,77	36,54	73,72
RF		RMSE%	10,67	9,65	10,86	10,27	10,36
		R ²	88,64	87,98	84,94	83,42	86,25
RL		RMSE%	9,02	12,20	10,01	13,05	11,07
		R ²	93,64	78,79	87,01	60,46	79,98
MP		RMSE%cv	10,30	13,12	12,22	12,88	12,13
		R ² cv	87,10	79,75	83,59	77,26	81,93
SMOreg		RMSE%cv	9,40	11,28	11,53	12,10	11,08
		R ² cv	89,96	83,06	59,37	78,71	77,78
RF		RMSE%cv	9,79	10,97	10,59	11,27	10,65
		R ² cv	88,52	83,78	85,50	81,72	84,88
RL		RMSE%cv	9,75	11,66	12,54	12,39	11,59
		R ² cv	88,56	83,14	51,39	75,96	74,76
Plano Longitudinal							
Modelo	Técnica validação	Medidas de validação	MS	PS	ME	MA	Média
MP		RMSE%	8,81	13,26	10,28	12,26	11,15
		R ²	90,62	85,62	89,61	94,77	90,16
SMOreg		RMSE%	8,87	12,23	10,40	8,40	9,98
		R ²	89,59	86,19	89,26	91,55	89,15
RF		RMSE%	9,38	12,15	9,74	7,15	9,60
		R ²	90,76	87,24	92,09	93,45	90,89
RL		RMSE%	8,91	12,62	9,68	8,24	9,86
		R ²	89,57	86,56	90,87	91,48	89,62
MP		RMSE%cv	11,20	12,44	12,02	10,28	11,49
		R ² cv	85,73	80,31	86,23	89,31	85,40
SMOreg		RMSE%cv	9,59	12,33	9,66	8,66	10,06
		R ² cv	90,50	83,06	90,69	91,86	89,03
RF		RMSE%cv	9,21	13,15	8,81	8,37	9,88
		R ² cv	91,16	80,61	90,96	92,42	88,79
RL		RMSE%cv	10,05	12,25	9,26	8,54	10,02
		R ² cv	89,58	83,47	91,27	92,19	89,13

No plano transversal, *Random Forest* apresentou os melhores resultados, com o menor RMSE% médio (10,36%) e o maior R² (86,25%), se destacando por seu desempenho estável e alta precisão. O modelo de *Multilayer Perceptron* testado por meio de treinamento e validação resultou em um RMSE% médio de 11,28% e R² médio de 83,54%. Um bom desempenho, mas com variabilidade entre os dados, especialmente com a madeira anidra, onde o R² cai para 71,98%. Para o modelo SMOreg o RMSE% médio foi igual a 11,66% e o R² médio foi 73,72%. O R² foi especialmente baixo para a medição na madeira anidra (36,54%), proporcionando baixa precisão na previsão para esses dados. Para Regressão Linear o RMSE% médio foi de 11,07%, com R² médio de 79,98%, sendo

alto para a madeira saturada e na umidade de equilíbrio, mas com queda significativa para a madeira anidra (60,46%).

Para os modelos transversais testados por meio de validação cruzada de dados, *Random Forest* permaneceu com bom desempenho na validação cruzada, com RMSE%cv médio de 10,65% e R^2 cv médio de 84,88%. O modelo é consistente e com alta precisão, mostrando que lida bem com a variabilidade nos dados. Para SMOreg o RMSE%cv médio foi de 11,08% com R^2 cv de 77,78%, com um baixo valor de R^2 cv para madeira em equilíbrio (59,37%), o que pode indicar uma variabilidade no desempenho. O modelo de Regressão Linear apresentou RMSE%cv médio de 11,59% e R^2 cv médio de 74,76%. Assim como no treinamento com 80%, o R^2 cv cai para 51,39% para ME. O modelo *Multilayer Perceptron* apresentou RMSE%cv médio mais alto (12,13%) do que no treinamento com 80% dos dados e um R^2 cv médio de 81,93%.

No plano longitudinal, RF apresentou RMSE% médio de 9,60% e R^2 médio igual a 90,89%, sendo o modelo mais consistente, com o menor erro médio e o coeficiente de determinação mais alto, mostrando-se eficiente na captura de padrões nos dados. O modelo MP testado via treinamento e validação, apresentou RMSE% médio igual a 11,15% e R^2 médio de 90,16%, com valores acima de 85 em todos os dias, atingindo 94,77% para madeira anidra. SMOreg apresentou RMSE% médio de 9,98% e R^2 médio de 89,15%, se mostrando um modelo estável e elevado, com erro médio próximo ao do MP. Seu R^2 é um pouco menor em alguns dias, mas o modelo se comporta bem em geral. O modelo de Regressão Linear apresentou RMSE% médio igual a 9,86% e R^2 médio de 89,62%. O desempenho da Regressão Linear é semelhante ao do SMOreg, com bom R^2 e RMSE% médio baixo. Este modelo teve boa performance, especialmente para a madeira anidra, onde o R^2 alcançou 91,48%.

Os modelos testados via validação cruzada no observado o plano longitudinal também apresentou bom desempenho. RF continua mostrando alto desempenho com o segundo menor erro médio (9,88%) e um R^2 cv consistente (88,79%). Ele lida bem com a validação, mostrando estabilidade. MP apresentou RMSE%cv médio de 11,49% e R^2 cv médio de 85,40%, erro médio um pouco maior e o coeficiente de determinação médio menor comparado ao treinamento com 80%, indicando um desempenho aceitável. SMOreg apresentou RMSE%cv médio de 10,06% e R^2 cv médio de 89,03%. O SMOreg apresenta uma boa média de R^2 cv e RMSE%cv médio mais baixo em comparação com o MP, mantendo-se estável com boa precisão. Regressão Linear tem um desempenho e

composição semelhante ao SMOreg e RF, mantendo um R^2_{cv} (89,13%) elevado e um RMSE% $_{cv}$ médio competitivo (10,02%).

Random Forest e SMOreg são os modelos que apresentaram o melhor equilíbrio entre erro e coeficiente de determinação tanto no treinamento com 80% dos dados quanto na validação cruzada nos dois planos amostrados. A regressão Linear tem um desempenho razoável, com um bom ajuste nos dados e um erro médio baixo. E o *Multilayer Perceptron* mostra bom desempenho, mas tem um erro médio um pouco mais elevado na validação cruzada.

Silva et al. (2018) em experimento comparando a eficácia de se utilizar *Multilayer Perceptron* para estimar a densidade básica de espécies nativas do cerrado mineiro com uso do aparelho de penetração *Pilodyn* e variáveis dendrométricas, autores observaram resultados superiores da MLP na validação dos dados quando comparada aos modelos de regressão para quatro situações analisadas. Sendo, a MLP que considerou como variáveis de entrada a espécie, diâmetro a 1,3 m do solo (DAP), altura total a que obteve melhores resultados, com R^2 igual a 74%, relação entre a densidade básica determinada e estimada com inclinação próxima aos 45°, demonstrando existir uma forte correlação positiva.

Pereira et al. (2021) observaram que o RF apresentou melhor coeficiente de determinação, correlação linear entre valores observados e previstos, erro absoluto médio e erro quadrático médio, comparado aos resultados de *Support Vector Regression* (SVR) e Regressão Linear Múltipla (MLR), testados para decidir qual algoritmo seria capaz de relacionar as propriedades da madeira e do carvão vegetal.

Os modelos de *Random Forest* apresentam característica de captar o comportamento de dados complexos, melhorando a capacidade de modelagem e aumentando a precisão das estimativas (Cosenza et al., 2021). Portanto, para uma estimativa mais confiável e robusta, *Random Forest* é a melhor opção, seguida por SMOreg e Regressão Linear. Esses modelos mantêm boa precisão e generalização com diferentes abordagens de validação.

A relação entre os valores de densidade básica da madeira obtidos pelo método convencional e valores estimados pelo modelo *Random Forest* via treinamento e validação e validação cruzada são apresentados nas Figuras 1 e 2, respectivamente.

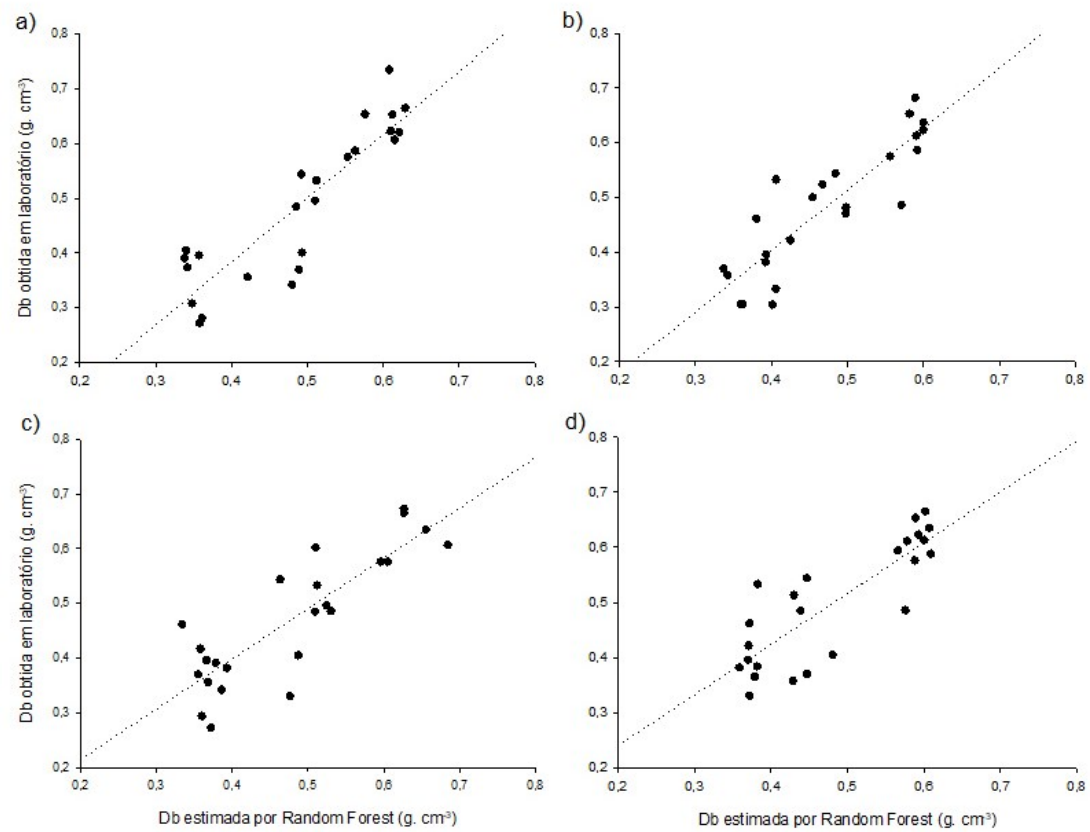


Figura 1. Valores de densidade básica da madeira determinados em laboratório (g. cm⁻³) e estimados pelo modelo de *Random Forest* (g. cm⁻³) por meio de treinamento e validação a partir de capturas no plano transversal da madeira quando a madeira estava saturada (a), em processo de secagem (b), em equilíbrio (c) e anidra (d).

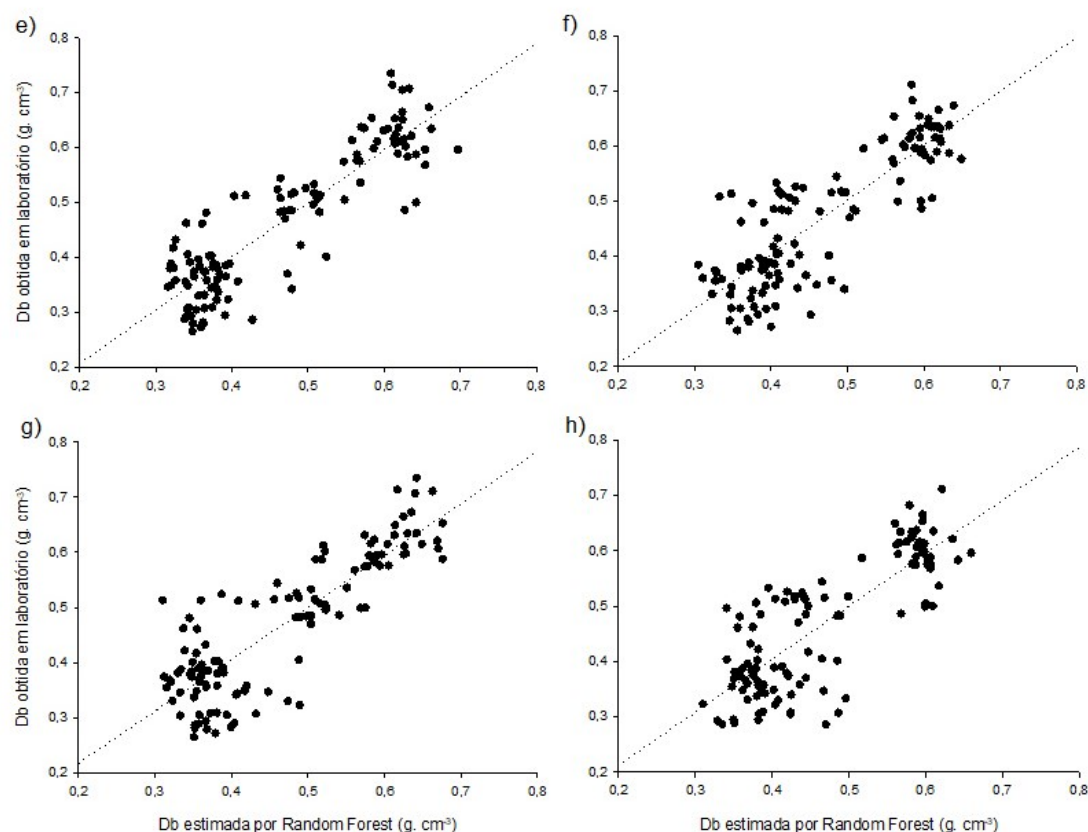


Figure 2. Valores de densidade básica da madeira determinados em laboratório (g. cm⁻³) e estimados pelo modelo de *Random Forest* (g. cm⁻³) por meio de cruzamento e validação a partir de capturas no plano transversal da madeira quando a madeira estava saturada (e), em processo de secagem (f), em equilíbrio (g) e anidra (h).

As análises das Figuras 1 e 2 revela que os pontos (círculos) se distribuem próximos à linha de igualdade em todas as condições de umidade. Isso indica que o modelo de *Random Forest* é capaz de estimar a densidade básica da madeira com boa precisão, mesmo quando a madeira se encontra em diferentes estados de umidade. Os resultados apresentados nas Figuras 1 e 2 evidenciam o potencial do modelo de RF para estimar a densidade básica da madeira com base em imagens do plano transversal, independentemente da condição de umidade. Essa técnica pode representar um avanço significativo na área, agilizando e facilitando a determinação dessa importante propriedade da madeira.

4 CONCLUSÃO

Os resultados mostraram correlação entre as faixas espectrais captados na câmera *Mapir* com filtro RGNIR e a densidade da madeira, especialmente no plano transversal e em amostras saturadas ou em processo de secagem.

O modelo de *Random Forest* se destacou como o mais eficiente na estimativa da densidade básica, apresentando o menor erro médio e o maior coeficiente de determinação, tanto no treinamento com 80% dos dados quanto na validação cruzada. Sua capacidade de lidar com a variabilidade dos dados e fornecer resultados precisos o torna uma ferramenta promissora para aplicações em larga escala na indústria madeireira.

Os resultados deste estudo indicam que a espectroscopia multiespectral, combinada com modelos de aprendizado de máquina, pode ser uma alternativa promissora aos métodos tradicionais de determinação da densidade básica da madeira. Essa técnica não destrutiva, rápida e econômica pode otimizar o controle de qualidade na produção de madeira e seus derivados, além de contribuir para o manejo florestal sustentável.

REFERÊNCIAS

- ALMEIDA, M. N. F. de.; et al. Wood density variations of *E. urophylla* clone among growth sites are related to climate. **Canadian Journal Of Forest Research**, v. 1, p. 1, 2023. <https://doi.org/10.1139/cjfr-2022-0037>
- AMARAL, E. A.; et al. Evaluating basic density calibrations based on NIR spectra recorded on the three wood faces and subject to different mathematical treatments. **Nz J Forestry Sci**, v. 51, n. 2, p. 1-7, 2021. <https://doi.org/10.33494/nzjfs512021x100x>
- ARRIEL, T. G.; et al. Developing near infrared spectroscopic models for predicting density of *Eucalyptus* wood based on indirect measurement. **Cerne**, v. 25, n. 3, 2019. <https://doi.org/10.1590/01047760201925032646>
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 14660**: Madeira- Determinação de densidade básica. Rio de Janeiro: ABNT. 2003, 7p.
- BONFATTI, E. A. JÚNIOR., et al. Basic wood density, fiber dimensions, and wood chemical composition of four *Eucalyptus* species planted in southern brazil. **Revista Árvore**, v. 47, 2023. <https://doi.org/10.1590/1806-9088202300000004>
- COSENZA, D. N. et al. Comparison of linear regression, k-nearest neighbour and random forest methods in airborne laser-scanning-based prediction of growing stock. **Forestry: An International Journal of Forest Research**, v. 94, n. 2, p. 311– 323, 2021. <https://doi.org/10.1093/forestry/cpaa034>
- CUNHA, T. Q. G. da S.; et al. *Eucalyptus* expansion in Brazil: Energy yield in new forest frontiers. **Biomass and Bioenergy**, 144, 105900, 2021. <https://doi:10.1016/j.biombioe.2020.105900>.
- GAO, S.; et al. A critical analysis of methods for rapid and nondestructive determination of wood density in standing trees. **Annals of Forest Science**, v. 74, n. 27, 2017. <https://doi.org/10.1007/s13595-017-0623-4>
- GITELSON, A. A.; KAUFMAN, Y. J.; MERZLYAK, M. N. Use of a green channel in remote sensing of global vegetation from EOS- MODIS. **Remote Sensing of Environment**, v. 58, n. 3, p. 289–298, 1996. [https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7)
- INDUSTRIA BRASILEIRA DE FLORESTAS. Relatório anual: 2024. [On-line]. Disponível: <https://iba.org/datafiles/publicacoes/relatorios/relatorio2024.pdf>
- LUAN, Y.; et al. Wood mechanical densification: a review on processing. **Materials and Manufacturing Processes**, v. 37, n. 4, p. 359–371, 2021. <https://doi.org/10.1080/10426914.2021.2016816>
- MA, T.; et al. Comparative Performance of NIR-Hyperspectral Imaging Systems. **Foundations**, v. 2, p. 523-540, 2022. <https://doi.org/10.3390/foundations2030035>

MA, T.; et al. Measuring the tensile strain of wood by visible and near-infrared spatially resolved spectroscopy. **Cellulose**, v. 28, n. 17, p. 10787-10801, 2021.

<https://doi.org/10.1007/s10570-021-04239-1>

MANCINI, L. T. et al. Estimation of total extractive content of wood from planted and native forests by near infrared spectroscopy. **iForest**, v. 14, n. 1, p.18-25, 2021.

<https://doi.org/10.3832/ifor3472-013>

NOVO, E. M; PONZONI, F. J. **Introdução ao sensoriamento remoto**. São José dos Campos, 2021.

PEREIRA, K. D.; et al. Study of the influence of wood properties on the charcoal production: applying the random forest algorithm. **Revista Árvore**, v. 45, n. 2, 2021.

<http://dx.doi.org/10.1590/1806-908820210000002>

PIMENTA, E. M.; et al. Planting spacing and genotype affected the tree growth and variation of wood density and lignin content along *Eucalyptus* trunks. **Industrial Crops and Products**. v. 222, Part 2, n. 15, 2024.

<https://doi.org/10.1016/j.indcrop.2024.119595>

RAMOS, R. D.; et al. Influência da densidade básica e da composição química da madeira para a indústria de polpa celulósica: um estudo de caso. *Ciência Florestal*, v. 34, n. 3, 2024.

<https://doi.org/10.1590/1806-908820210000002>

ROMERO, F. M. B.; et al. Basic Wood Density in Large Trees: Impacts on Biomass Estimates in the Southwest Brazilian Amazon. **Forests**, v. 734, n. 15, 2024.

<https://doi.org/10.3390/f15050734>

ROUSE, J. W.; et al. No Title Monitoring vegetation systems in the Great Plains with ERTS. Proceedings of 3rd Earth Resources Technology Satellite-1 Symposium.

Anais,1973.

SÁNCHEZ, I. G.; et al. Aplicación de analisis de imagen y tecnología nirs a la evaluacion de la porosidad de planchas, láminas y tapones decorcho y su relacion con la calidad industrial. **Maderas Maderas-Cienc Tecnol**, v. 15, n. 3, p. 293-309, 2013.

<http://dx.doi.org/10.4067/S0718-221X2013005000023>

SILVA da, C.J., VALE do, A.T., MIGUEL, E.P. Basic density of wood from Cerradão species in the state of Tocantins. **New Zealand Journal of Forestry Science**, v. 51, n. 2, 2021.

<https://doi.org/10.4336/2015.pfb.35.82.822>

SILVA, E.S.G.; et al. Physical and Mechanical Properties of Juvenile Wood of *Anadenanthera peregrina* (L.) Speg. from Thinning. **Forests**, v. 15, n. 1240, 2024.

<https://doi.org/10.3390/f15071240>

SILVA, J. P. M.; et al. Redes neurais artificiais para estimar a densidade básica de madeiras do cerrado. **Pesq. flor. bras.**, Colombo, v. 38, p. 1-10, 2018.

<https://doi.org/10.4336/2018.pfb.38e201801656>

TSUCHIKAWA, S., INAGAKI, T. & MA, T. Application of Near-Infrared Spectroscopy to Forest and Wood Products. **Curr. For. Rep.** v. 9, p. 401–412, 2023. <https://doi.org/10.1007/s40725-023-00203-3>

YIN, Q.; LIU, H.-H. Drying Stress and Strain of Wood: A Review. **Appl. Sci.**, 11, 5023, 2021. <https://doi.org/10.3390/app11115023>

XIN, Z.; et al. Non-destructive evaluating the density and mechanical properties of ancient timber members based on machine learning approach. **Construction and Building Materials**, v. 341, n. 25, 2022. <https://doi.org/10.1016/j.conbuildmat.2022.127855>