

INSTITUTO FEDERAL DE EDUCAÇÃO CIÊNCIA E TECNOLOGIA  
DE MINAS GERAIS - *CAMPUS* SÃO JOÃO EVANGELISTA  
BACHARELADO EM AGRONOMIA

Ilana de Castro Almeida

**USO DE ÍNDICES ESPECTRAIS NA ESTIMATIVA DA PRODUTIVIDADE DO  
CAFEIRO POR MEIO DE TÉCNICAS DE APRENDIZADO DE MÁQUINA**

São João Evangelista

2026

ILANA DE CASTRO ALMEIDA

**USO DE ÍNDICES ESPECTRAIS NA ESTIMATIVA DA PRODUTIVIDADE DO  
CAFEIRO POR MEIO DE TÉCNICAS DE APRENDIZADO DE MÁQUINA**

Trabalho de conclusão de curso apresentado  
como requisito obrigatório de Curso de  
Bacharelado em Agronomia do Instituto Federal  
de Educação, Ciência e Tecnologia de Minas  
Gerais – *Campus* São João Evangelista.

Orientador: Dr. Jonathan da Rocha Miranda

São João Evangelista

2026

---

A447u Almeida, Ilana de Castro.  
Uso de índices espectrais na estimativa da produtividade do  
cafeeiro por meio de técnicas de aprendizado de máquina / Ilana de  
Castro Almeida – 2026.  
37f.: il.

Orientador: Dr. Jonathan da Rocha Miranda.  
Trabalho de Conclusão de Curso (bacharelado em Agronomi) –  
Instituto Federal Minas Gerais. *Campus* São João Evangelista, 2026.

1. Coffea arabica. 2. Sensoriamento remoto. 3. Agricultura de  
precisão. 4. Índices de vegetação. 5. Previsão de safra. I. Almeida,  
Ilana de Castro. II. Instituto Federal de Minas Gerais *Campus* SJE. III.  
Título.

CDD 633.73

---

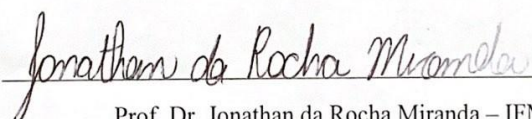
Catálogo: Esther Soares Cunha - CRB-6/4333

ILANA DE CASTRO ALMEIDA

**USO DE ÍNDICES ESPECTRAIS NA ESTIMATIVA DA PRODUTIVIDADE DO  
CAFEIEIRO POR MEIO DE TÉCNICAS DE APRENDIZADO DE MÁQUINA**

Trabalho de Conclusão de Curso apresentado  
como requisito parcial para obtenção do grau  
de bacharel em Agronomia, no Instituto  
Federal de Minas Gerais campus São João  
Evangelista (IFMG/SJE).

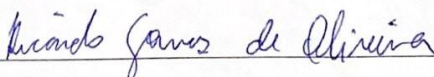
Aprovado em: 10/02/2026 pela banca examinadora:



Prof. Dr. Jonathan da Rocha Miranda – IFMG



Dr. Alisson José Eufrásio de Carvalho



Ms. Ricardo Gomes Oliveira

## AGRADECIMENTOS

Agradeço à minha primeira professora, Risa de Araújo Castro (*in memorian*), que além de exercer essa linda profissão, foi e sempre será minha professora de vida. Às minhas irmãs Iane de Castro Almeida (*in memorian*) e Iale de Castro Almeida. Vocês são inspiração e motivação! Sinônimo de força, resiliência, feminilidade, amor, carinho, afeto, acolhimento e compreensão. Agradeço também ao meu pai, Wilson Ernani de Almeida, por todo apoio, todo conselho, toda ligação, toda palavra.

Reconheço também cada pessoa que esteve comigo ao longo deste ciclo. Seja apenas no início, seja apenas no meio, seja apenas no fim, seja em todo ele. Foram muitos sorrisos, muitas lágrimas, muitos momentos compartilhados nesta jornada. Carrego comigo uma parte de muitos.

Aos meus amigos do Prata: essa realização também é de vocês.

Não obstante, sou grata a todos os docentes que exercem essa profissão incrível, que forma profissionais e, não obstante, pessoas. Agradeço em especial ao orientador Dr. Jonathan da Rocha Miranda, que não poupou esforços, atenção e esteve disponível para o desenvolvimento do presente trabalho.

Ao IFMG, lugar que foi por muitas vezes a minha segunda casa, por vezes, meu lar.

## RESUMO

A cultura do café (*Coffea arabica* L.) apresenta alta variabilidade espacial e temporal, o que torna a estimativa de safra um desafio complexo frente ao fenômeno da bienalidade e das variações edafoclimáticas. O uso de sensoriamento remoto associado ao aprendizado de máquina surge como uma alternativa promissora para contornar a ineficiência das amostragens manuais. O objetivo deste trabalho foi estimar a variabilidade espacial da produtividade de uma lavoura cafeeira utilizando índices espectrais derivados de imagens orbitais de alta resolução integrados ao algoritmo *Random Forest* (RF). O estudo foi conduzido no município de São João Evangelista - MG, em uma lavoura da cultivar Arara (três anos de idade). A coleta de dados de produtividade ocorreu em 100 plantas georreferenciadas por meio de derraça manual. Imagens multiespectrais do satélite CBERS-4A (sensor WPM) foram adquiridas em setembro de 2024 (período de pré-florada) e submetidas à fusão de imagens (*pansharpening*) para obtenção de resolução espacial de 2 metros, contornando ruídos e a mistura espectral das entrelinhas. Foram calculados os índices NDVI, SAVI, NDWI e VARI. Para a modelagem preditiva, empregou-se o algoritmo RF validado pelo método *Leave-One-Out Cross-Validation* (LOOCV). Os resultados demonstraram alta variabilidade produtiva na área (CV de 51,77%), associada à altitude e à dinâmica de estabelecimento inicial do estande. Índices baseados no infravermelho próximo (NDVI e SAVI) mostraram forte coerência espacial com a produtividade, enquanto o VARI (restrito ao visível) não apresentou capacidade de discriminação entre as zonas de manejo. O modelo RF alcançou um coeficiente de determinação ( $R^2$ ) de 0,61 e um Erro Médio Absoluto (MAE) de 0,51 L planta<sup>-1</sup> (~6,3 sc ha<sup>-1</sup>). O NDWI destacou-se como a variável preditora de maior importância. Conclui-se que o uso de imagens de alta resolução no período de pré-florada, aliado ao algoritmo *Random Forest*, é uma ferramenta robusta e eficaz para a previsão antecipada da safra cafeeira, fornecendo mapas detalhados que viabilizam a transição para a agricultura de precisão por meio de adubações em taxa variável e podas sítio-específicas.

**Palavras-chave:** *Coffea arábica*. Sensoriamento remoto. Agricultura de precisão. Índices de vegetação. Previsão de safra.

## ABSTRACT

Coffee cultivation (*Coffea arabica* L.) exhibits high spatial and temporal variability, making yield estimation a complex challenge due to the biennial bearing phenomenon and edaphoclimatic variations. The use of remote sensing associated with machine learning emerges as a promising alternative to overcome the inefficiency of manual sampling. The objective of this study was to estimate the spatial variability of coffee yield using spectral indices derived from high-resolution orbital imagery integrated with the Random Forest (RF) algorithm. The study was conducted in São João Evangelista - MG, in a three-year-old plantation of the Arara cultivar. Yield data were collected from 100 georeferenced plants through manual stripping. Multispectral images from the CBERS-4A satellite (WPM sensor) were acquired in September 2024 (pre-flowering period) and subjected to pansharpener to obtain a spatial resolution of 2 meters, mitigating noise and spectral mixing from the inter-rows. NDVI, SAVI, NDWI, and VARI indices were calculated. For predictive modeling, the RF algorithm was employed and validated using the Leave-One-Out Cross-Validation (LOOCV) method.

The results demonstrated high yield variability in the area (CV of 51.77%), associated with altitude and initial stand establishment dynamics. Indices based on the near-infrared (NDVI and SAVI) showed strong spatial coherence with yield, while VARI (restricted to the visible spectrum) lacked the ability to discriminate between management zones. The RF model achieved a coefficient of determination ( $R^2$ ) of 0.61 and a Mean Absolute Error (MAE) of 0.51 L plant<sup>-1</sup> (~6.3 bags ha<sup>-1</sup>). NDWI stood out as the most important predictor variable. It is concluded that the use of high-resolution imagery during the pre-flowering period, combined with the Random Forest algorithm, is a robust and effective tool for early coffee yield forecasting, providing detailed maps that enable the transition to precision agriculture through variable rate fertilization and site-specific pruning.

**Keywords:** *Coffea arabica*. Remote sensing. Precision agriculture. Vegetation indices. Crop forecasting.

## LISTA DE FIGURAS

Figura 1. Representação do espectro eletromagnético.....	15
Figura 2. Localização da área de estudo .....	17
Figura 3. Implementação de cultura em 12 abr. 2022.....	17
Figura 4. Distribuição espacial dos pontos amostrais .....	18
Figura 5. Coleta de ponto em receptor GNSS RTK .....	18
Figura 6. <i>Boxplot</i> dos quartis em função da produtividade.....	23
Figura 7. Distribuição espacial dos quartis em função da produtividade .....	24
Figura 8. Boxplot dos quantis em função dos índices espectrais .....	26
Figura 9. Distribuição espacial dos índices espectrais.....	28
Figura 10. Mapa comparativo entre produtividade de referência e estimada .....	29
Figura 11. Modelo de regressão <i>Random Forest</i> e importância das variáveis na predição da produtividade do cafeeiro.....	30

## **LISTA DE TABELAS**

Tabela 1. Especificações técnicas do sensor WPM (CBERS 4-A) .....	19
Tabela 2. Estatística descritiva da produtividade em 2025 .....	23

## LISTA DE EQUAÇÕES

Equação 1. NDVI.....	20
Equação 2. SAVI .....	21
Equação 3. NDWI.....	21
Equação 4. SAVI .....	21

## SUMÁRIO

1.	INTRODUÇÃO.....	12
2.	REFERENCIAL .....	14
2.1	Cafeicultura no Brasil e a importância da estimativa de produtividade.....	14
2.2	Geoprocessamento aplicado à agricultura .....	14
2.3	Espectros .....	14
2.4	Aprendizado de máquina ( <i>Random Forest</i> ) .....	15
3.	MATERIAL E MÉTODOS .....	17
3.1	Área de estudo .....	17
3.2	Composição amostral .....	18
3.3	Componente espectral .....	20
3.3.1	Fusão de imagens .....	21
3.3.2	<i>Índices espectrais</i> .....	21
3.4	Estatística descritiva .....	22
3.5	Modelagem preditiva .....	22
4.	RESULTADOS E DISCUSSÕES.....	24
5.	CONCLUSÃO.....	34
	REFERÊNCIAS.....	35

## 1. INTRODUÇÃO

A cultura do café (*Coffea arabica* L.) possui expressiva importância econômica e social no cenário global, sendo o Brasil o maior produtor e exportador mundial do grão, com destaque para o estado de Minas Gerais e Espírito Santo, responsáveis por aproximadamente 75% da produção nacional (CONAB, 2025). Diante da competitividade do mercado, das variações climáticas e dos altos custos operacionais, a adoção de tecnologias ligadas à agricultura de precisão tem se tornado essencial. Conforme destacam Nascimento (2019) e Bolaños *et al.* (2023), a capacidade de estimar a produtividade via sensoriamento remoto é essencial para o planejamento da colheita, a previsão de rendimento e a definição de estratégias sobre o uso de insumos e logística de mão de obra.

Apesar de sua relevância, a estimativa precisa da produtividade cafeeira é um desafio complexo. O cafeeiro é uma cultura perene que apresenta uma alta variabilidade espacial e temporal, fortemente influenciada por interações edafoclimáticas contínuas e pelo fenômeno da bienalidade, no qual a planta alterna anos de alta e baixa carga pendente de frutos (BERNARDES *et al.*, 2012). Tradicionalmente, as estimativas de safra dependem de amostragens manuais em campo que, além de trabalhosas e destrutivas, frequentemente falham em capturar a verdadeira heterogeneidade espacial das lavouras (SILVA *et al.*, 2021).

Nesse contexto, o sensoriamento remoto surge como uma alternativa não destrutiva e altamente promissora para o monitoramento agrícola. O uso de imagens multiespectrais permite a extração de índices de vegetação — como o Índice de Vegetação por Diferença Normalizada (NDVI), o Índice de Vegetação Ajustado ao Solo (SAVI) e o Índice de Diferença Normalizada da Água (NDWI) —, que avaliam e refletem as condições do vigor vegetativo, da densidade de biomassa e o *status* hídrico da planta (NOGUEIRA; MOREIRA; VOLPATO, 2018). A literatura indica que o intervalo entre os meses de julho e setembro, que compreende fenologicamente o repouso vegetativo e a quebra de dormência do cafeeiro arábica, é considerado um período estratégico para o monitoramento agrícola via sensoriamento remoto (CAMARGO e CAMARGO, 2001). Do ponto de vista radiométrico, este período de pré-florada é apontado como ideal para a predição da produtividade, segundo Fagundes (2025).

Entretanto, a arquitetura de plantio do café e a presença de solo exposto nas entrelinhas frequentemente resultam em mistura espectral, limitando a acurácia em sensores orbitais de média resolução (CHEMURA *et al.*, 2018). Para superar essa limitação e extrair fidedignamente o sinal do dossel, a utilização de imagens de alta resolução espacial associada

a algoritmos de aprendizado de máquina (*Machine Learning*) tem demonstrado resultados superiores na modelagem de parâmetros agronômicos (ABREU JÚNIOR *et al.*, 2022). Dentre as diversas técnicas, o algoritmo *Random Forest* (RF) destaca-se amplamente na literatura por sua grande capacidade de lidar com a alta dimensionalidade dos dados e modelar relações complexas e não-lineares, Miftahuddin e Rais (2024) destacam que o RF apresenta estabilidade e acurácias superiores quando comparado a outros métodos baseados em árvores de decisão.

Diante do exposto, o presente trabalho tem como objetivo estimar a variabilidade espacial da produtividade de uma lavoura de café utilizando índices espectrais derivados de imagens orbitais de alta resolução integrados ao algoritmo de aprendizado de máquina *Random Forest*. A obtenção de estimativas precoces (em setembro) visa validar essa tecnologia como uma ferramenta estratégica, fornecendo mapas detalhados de potencial produtivo que viabilizem a transição para a agricultura de precisão na aplicação de insumos em taxa variável e no manejo sítio-específico de podas.

## **2. REFERENCIAL**

### **2.1 Cafeicultura no Brasil e a importância da estimativa de produtividade**

A cafeicultura possui papel central no desenvolvimento econômico, social e territorial do Brasil, destacando-se tanto pela expressiva participação nas exportações agrícolas quanto pela geração de emprego e renda. O país é o maior produtor e exportador mundial de café, com destaque para os estados de Minas Gerais e Espírito Santo, que concentram grande parte da produção nacional (CONAB, 2025).

A estimativa da produtividade do café é uma etapa fundamental para o planejamento agrícola, permitindo a tomada de decisões relacionadas ao manejo da lavoura, comercialização, logística e políticas públicas. Métodos tradicionais de estimativa, baseados exclusivamente em levantamentos de campo, apresentam limitações quanto ao custo, tempo e abrangência espacial, especialmente em áreas extensas e heterogêneas (ASSAD; SANO, 1998).

Dessa forma, torna-se necessário o uso de ferramentas que possibilitem avaliações mais rápidas, precisas e espacialmente contínuas, como o geoprocessamento e o sensoriamento remoto.

### **2.2 Geoprocessamento aplicado à agricultura**


O geoprocessamento compreende um conjunto de técnicas destinadas à coleta, armazenamento, processamento e análise de dados georreferenciados, sendo amplamente utilizado em estudos agrícolas para análise espacial de variáveis ambientais e produtivas (CÂMARA *et al.*, 2004).

Na agricultura, essas técnicas permitem identificar padrões espaciais de produtividade, relevo, solo e vegetação, contribuindo para a agricultura de precisão e para o manejo localizado das culturas (ROSA, 2005). No contexto da cafeicultura, o geoprocessamento e o sensoriamento remoto têm sido utilizados para o monitoramento espacial e caracterização de lavouras, por meio da integração de dados espectrais e geográficos em processos de análise de variabilidade da produção e do ambiente (ALVES *et al.*, 2016).

### **2.3 Espectros**

O espectro eletromagnético é uma divisão didática da distribuição da radiação eletromagnética pelas distintas regiões, organizado de acordo com o comprimento de onda e frequência de onda (ABREU, K. M. P. e COUTINHO, L. M., 2014). Na Figura 1 fica claro que a frequência de onda, maior ou menor, é relativa ao número de repetições desta por unidade de tempo, conforme o comprimento de onda é a distância entre os picos. (FLORENZANO, 2002; MOREIRA, 2005; WENG, 2010).

Figura 1 – Representação do espectro eletromagnético



Fonte: Florenzano, 2002.

O uso do sensoriamento remoto voltado para o estudo e monitoramento da vegetação já é consolidado, sendo amplamente aplicado na identificação, classificação e no monitoramento de comunidades vegetais através de suas características espectrais (CLEMENTINO, 2025).

O Índice de Vegetação por Diferença Normalizada (NDVI), por exemplo, é usual na detecção da atividade fotossintética e monitoramento de mudanças na cobertura vegetal em resposta a processos ambientais, como alterações climáticas, degradação do solo e práticas de manejo, conforme afirmam Rouse *et al.* (1974) e Fernandes *et al.* (2018).

Os índices espectrais estão diretamente ligados aos espectros eletromagnéticos, tendo como finalidade destacar uma característica específica. No âmbito agrônomo, os índices espectrais são indicadores de processos metabólicos. Tomando-se por base a refletância na região do espectro eletromagnético em que os pigmentos absorvem mais fortemente a radiação, foram desenvolvidos índices para monitorar a biomassa, a fenologia, as condições fisiológicas e a deficiência de nutrientes, especialmente nitrogênio (PRADO, 2023).

## 2.4 Aprendizado de máquinas (*Random Forest*)

O algoritmo *Random Forest* (RF) destaca-se na literatura por sua robustez em lidar com a alta dimensionalidade dos dados e por sua capacidade intrínseca de captar interações não lineares entre variáveis, o que se revela fundamental no contexto da cafeicultura de montanha. Nas regiões montanhosas, o monitoramento radiométrico enfrenta desafios severos, uma vez que o relevo acidentado e as áreas fragmentadas causam sombras e distorções espectrais que dificultam a interpretação dos alvos. Conforme ressaltam Santos *et al.* (2011) e Pires (2016), nessas condições a resposta espectral pode ser drasticamente reduzida ou perdida, exigindo modelos matemáticos capazes de processar relações complexas entre a reflectância da vegetação, o sombreamento do dossel e o ruído do solo.

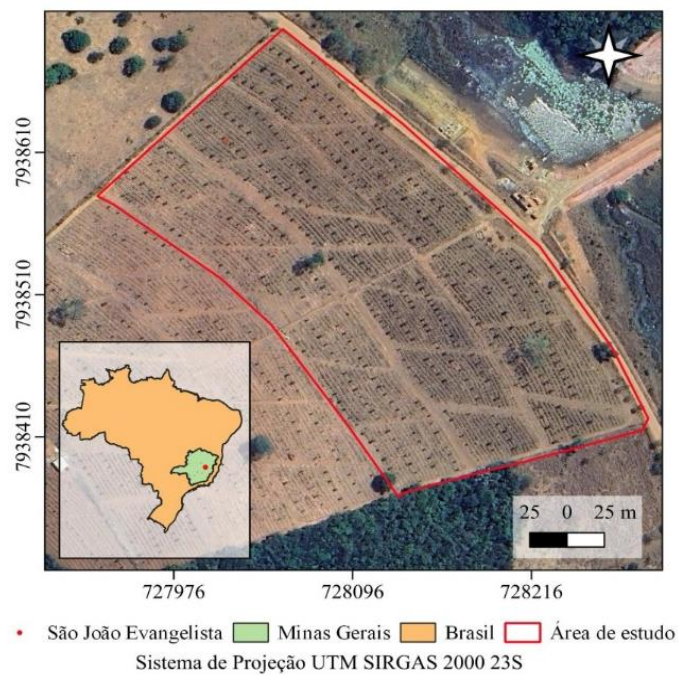
A eficácia do RF nessas áreas decorre de sua estrutura como um classificador combinatorial que utiliza reamostragem *bootstrapping* para treinar múltiplas árvores de decisão, selecionando os atributos mais relevantes para minimizar erros estatísticos. Martello *et al.* (2022) comprovou essa superioridade ao utilizarem o RF para prever a variabilidade espacial da produtividade do café arábica, obtendo resultados significativamente mais precisos ( $R^2 = 0,93$ ) do que os métodos de regressão linear múltipla, que muitas vezes falham em capturar a dinâmica não linear imposta pelo ciclo fenológico e pelas variações ambientais das encostas.

### 3. MATERIAL E MÉTODOS

#### 3.1 Área de estudo

A pesquisa desenvolvida foi realizada em propriedade rural no município de São João Evangelista, Minas Gerais (Latitude: 18°32'52"S Longitude: 42°45'35"W e Altitude de 698m) (Figura 2). O experimento foi conduzido em área implantada no ano de 2022 (Figura 3), utilizando a cultivar Arara, estabelecida em espaçamento de 2,8 × 0,6 metros entre linhas e plantas, respectivamente. O sistema de cultivo foi conduzido em consórcio com mogno africano, implantado no espaçamento de 14 × 5 metros. Em relação ao manejo hídrico, foi realizado por meio de irrigação com lâmina de 40 mm.

Figura 2. Localização da área de estudo.



Fonte: Elaborado pela autora, 2026.

Figura 3. Implementação da cultura em 12 abr. 2022.

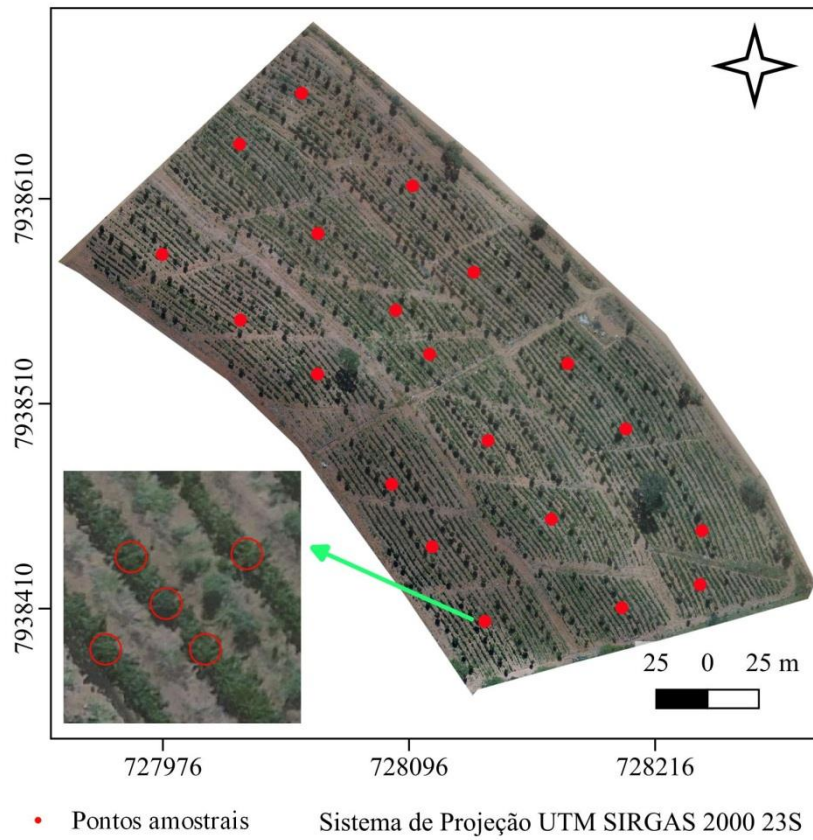


Fonte: autora, 2022.

### 3.2 Composição amostral

A composição da malha amostral baseou-se na seleção aleatória de 20 pontos de controle distribuídos na área de estudo, respeitando-se um distanciamento mínimo de 20 metros entre eles (Figura 4). O posicionamento geográfico de cada ponto foi determinado com o auxílio de um receptor GNSS RTK (Figura 5), instalado na planta de café mais próxima à coordenada sorteada. A partir desta planta central, estruturou-se uma unidade amostral composta por cinco indivíduos: além do exemplar central, foram selecionadas duas plantas na mesma linha de cultivo — posicionadas à direita e à esquerda, após o intervalo de duas plantas de distância do centro — e duas plantas localizadas nas linhas adjacentes, situadas imediatamente à frente e atrás do ponto de referência. Este delineamento resultou em uma coleta total de 100 plantas, organizadas em grupos de cinco por ponto amostral.

Figura 4. Distribuição espacial dos pontos amostrais.



Fonte: Elaborado pela autora, 2026.

Figura 5. Coleta de ponto em receptor GNSS RTK.



Fonte: Elaborado pela autora, 2025.

A coleta dos frutos para a determinação da produtividade foi executada por meio do método de derriça manual individualizada em cada uma das 100 plantas que integraram a malha amostral. O procedimento consistiu no desprendimento total dos frutos de cada espécime, seguido pelo recolhimento do material para a etapa de mensuração. A quantificação foi realizada através da medição do volume de café em estágio cereja obtido por planta.

### 3.3 Componente espectral

Foram utilizadas imagens do satélite CBERS-4A (China–Brazil Earth Resources Satellite), obtidas pelo satélite em 14 de setembro de 2024. O CBERS-4A integra o programa de cooperação sino-brasileiro para observação da Terra, sendo destinado ao monitoramento ambiental, agrícola e territorial, fornecendo imagens multiespectrais e pancromáticas de média e alta resolução espacial (INPE, 2023).

Tabela 1. Especificações técnicas do sensor WPM (CBERS-4A)

Parâmetro Técnico	Descrição / Valor
Resolução Espacial	8 m (Multiespectral) e 2 m (Pancromática)
Resolução Radiométrica	10 bits (1.024 níveis de cinza)
Resolução Temporal (Revisita)	31 dias
Faixa de Cobertura (Swath)	92 km
Altitude da Órbita	628,6 km
Banda 1 (Azul)	0,45 – 0,52 $\mu\text{m}$
Banda 2 (Verde)	0,52 – 0,59 $\mu\text{m}$
Banda 3 (Vermelho)	0,63 – 0,69 $\mu\text{m}$
Banda 4 (Infravermelho Próximo)	0,77 – 0,89 $\mu\text{m}$
Banda 5 (Pancromática)	0,45 – 0,90 $\mu\text{m}$

Fonte: Elaborado pela autora, 2026.

A escolha da cena referente ao mês de setembro fundamentou-se na maior probabilidade estatística de obtenção de imagens com reduzida ou nula cobertura de nuvens na região de estudo. Ademais, a literatura especializada indica que o comportamento espectral do cafeeiro, especificamente no período que antecede e compreende a florada, apresenta sensibilidade a diversos fatores bióticos e fisiológicos da cultura. Nesse sentido, Silva *et al.* (2021), demonstram que as respostas espectrais registradas nessa janela temporal guardam

correlação direta com as estimativas de produtividade, validando o uso do sensoriamento remoto como um indicador robusto do potencial produtivo da safra.

### 3.3.1 *Fusão de imagens*

Com o intuito de integrar o detalhamento geométrico da banda pancromática, que possui 2 metros de resolução, à informação espectral das bandas multiespectrais de 8 metros, empregou-se o método *Simple Pansharpening* por meio da Transformação de Brovey. Conforme explicam Alcaras, Parente e Vallario (2021), esta técnica fundamenta-se em um algoritmo de proporção aritmética que normaliza as bandas multiespectrais em relação à intensidade luminosa total (ou imagem pancromática sintética) e, subsequentemente, multiplica o resultado pelos valores de reflectância da banda pancromática.

A aplicação da Transformação de Brovey é particularmente vantajosa para a visualização e discriminação de alvos intra-talhão, uma vez que preserva o contraste relativo das cores ao mesmo tempo em que eleva a resolução espacial para 2 metros.

### 3.3.2 *Índices espectrais*

A partir das imagens fusionadas, foram calculados índices espectrais amplamente utilizados em estudos de vegetação e produtividade agrícola. Os índices foram obtidos por meio de operações matemáticas aplicadas às bandas espectrais.

O Índice de Vegetação por Diferença Normalizada (NDVI) (Equação 1) foi empregado como um indicador do vigor vegetativo e da densidade das folhas, permitindo diagnosticar o estado de saúde da planta a partir de sua atividade fotossintética.

$$NDVI = \frac{NIR - Red}{NIR + Red} \quad (1)$$

Dada a arquitetura da cultura cafeeira, que frequentemente apresenta solo exposto entre as linhas de plantio, utilizou-se o Índice de Vegetação Ajustado ao Solo (SAVI) (Equação 2). Este índice introduz um fator de ajuste (L), comumente fixado em 0,5, para minimizar o ruído proveniente do substrato e garantir que o vigor medido seja representativo da biomassa do café.

$$SAVI = \left( \frac{NIR - Red}{NIR + Red + L} \right) \times (1 + L) \quad (2)$$

Para a avaliação de distúrbios que afetam a retenção hídrica, calculou-se o Índice de Diferença Normalizada da Água (NDWI), utilizando a relação entre as bandas do verde (G) e do infravermelho próximo (NIR) (Equação 3). A escolha deste índice baseia-se na premissa de que distúrbios biológicos tendem a interagir diretamente com a capacidade das plantas na retenção de água e na manutenção da turgidez celular, alterando sua resposta espectral nestas faixas.

$$NDWI = \frac{Green - NIR}{Green + NIR} \quad (3)$$

O Índice Alterado Visualmente em Resposta ao Visível (VARI) foi aplicado para estimar a proporção de vegetação verde utilizando exclusivamente as bandas da região do visível — verde (G), vermelho (Red) e azul (Blue) (Equação 4). O VARI fornece uma medida de "verdor" que apresenta baixa sensibilidade a variações atmosféricas, sendo definido pela relação:

$$VARI = \frac{Green - Red}{Green + Red - Blue} \quad (4)$$

### 3.4 Estatística descritiva

A fim de correlacionar a variabilidade da produtividade observada em campo com as respostas radiométricas capturadas pelo satélite, os dados foram estratificados por meio do critério de quartis. Essa divisão da distribuição da amostra em quatro grupos distintos de produtividade facilitou a discriminação do comportamento espectral, estratégia similar à adotada por Campos (2005), que utilizou o agrupamento de lavouras em faixas de produtividade (baixa, moderada e alta) para identificar a variabilidade espacial por meio de índices espectrais. A análise estatística descritiva desses grupos foi estruturada através da construção de diagramas de caixa (*boxplots*), os quais possibilitaram a visualização da distribuição, da mediana e da dispersão dos valores espectrais e radiométricos dentro de cada classe de rendimento.

### 3.5 Modelagem preditiva

Para a modelagem preditiva da produtividade cafeeira, aplicou-se o algoritmo de aprendizado de máquina *Random Forest* (RF), estruturado com um conjunto de 100 árvores de decisão para a condução da regressão dos dados. No delineamento estatístico, as bandas espectrais e os índices de vegetação calculados foram estabelecidos como variáveis independentes (preditoras), enquanto os dados de volume colhidos em campo configuraram a variável dependente do modelo. A arquitetura do algoritmo permitiu a determinação do grau de importância de cada variável, fornecendo uma análise hierárquica da contribuição de cada componente espectral para a precisão da estimativa.

A validação da capacidade preditiva e da estabilidade do modelo foi realizada por meio do método *Leave-One-Out Cross-Validation* (LOOCV). Segundo Zanella (2024), este procedimento de validação cruzada, que consiste em treinar o algoritmo utilizando todas as amostras exceto uma, repetindo o ciclo até que cada ponto da malha amostral tenha sido utilizado como teste, é especialmente indicado para assegurar a robustez estatística em estudos com bases de dados de dimensões controladas.

#### 4. RESULTADOS E DISCUSSÕES

Os resultados demonstram que o talhão possui um teto produtivo elevado, porém distribuído de forma irregular. Essa característica é frequentemente reportada na literatura científica, Pires (2016) ressalta que os fatores climáticos, como temperatura e precipitação, exercem controle direto sobre estádios fenológicos críticos, como a floração e a granação dos frutos, interferindo significativamente na resposta espectral e no rendimento final da cultura. Essa interação dinâmica entre o meio físico e a fenologia acarreta mudanças na geometria de iluminação das plantas, aumentando a variabilidade do comportamento espectral observado via sensoriamento remoto. Logo, os resultados mostram que enquanto a média geral se estabeleceu em 32,23 sc ha<sup>-1</sup>, a dispersão dos dados, evidenciada por um coeficiente de variação (CV) de 51,77%, expõe a existência de manchas de produtividade contrastantes (Tabela 2).

Tabela 2. Estatística descritiva da produtividade em 2025

Parâmetro	L.planta <sup>-1</sup>	Sc.ha <sup>-1</sup>
Média	2,60	32,23
Mediana	2,60	32,24
Desvio Padrão	1,35	16,68
Mínimo	0,30	3,72
Máximo	5,90	73,16
CV (%)	51,77%	51,77%


Fonte: Elaborado pela autora, 2026.

A ocorrência de uma variação dessa magnitude (CV acima de 50%) é comum em lavouras cafeeiras e pode estar fortemente associada ao efeito de bienalidade da produção, em que as plantas alternam anos de alta e baixa carga pendente (BARBOSA *et al.*, 2021).

A análise por quartis permitiu quantificar esse gradiente: as plantas situadas no quartil superior (Q4) expressaram um vigor quase quatro vezes superior ao do quartil inferior (Q1), com produtividades de 4,45 L planta<sup>-1</sup> (~55,2 sc ha<sup>-1</sup>) contra 1,05 L planta<sup>-1</sup> (~13,0 sc ha<sup>-1</sup>), respectivamente (Figura 6). Esses dados sugerem que, embora a área possua capacidade genética e ambiental para altas produtividades, fatores limitantes localizados estão restringindo o pleno desenvolvimento de parcelas significativas da lavoura, ratificando a

importância de se delimitar zonas de baixo e alto rendimento para a aplicação de práticas de manejo sítio-específico (MARTELLO *et al.*, 2022).

Figura 6. *Boxplot* dos quartis em função da produtividade

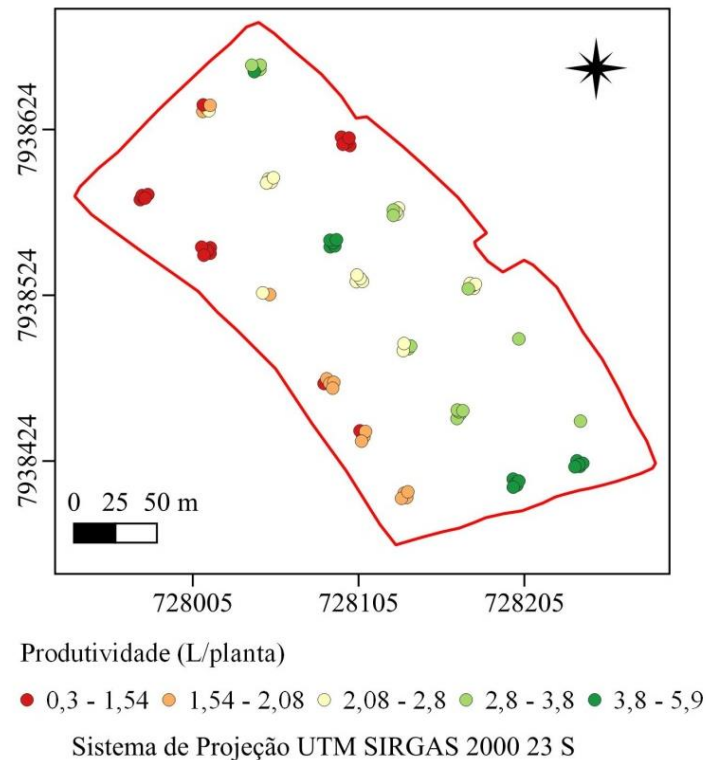


Fonte: Elaborado pela autora, 2026.

Especialmente, nota-se que as zonas de menor produtividade (Q1) coincidiram com as áreas de maior altitude do terreno. Esse comportamento corrobora estudos prévios demonstrando que a altitude exerce um papel significativo sobre o desempenho agrônomo do café; maiores altitudes tendem a apresentar temperaturas mais amenas, o que ocasiona uma taxa mais lenta de acúmulo de unidades térmicas e, conseqüentemente, afeta o acúmulo de fotossimilados e a produtividade das plantas nesses locais (CEBALLOS-SIERRA; DALL'ERBA, 2021).

Em contrapartida, o quartil de maior produtividade (Q4) concentrou-se na porção central tendendo a sudeste da área. A variabilidade interna desses grupos extremos merece destaque: tanto nas zonas de baixa (Q1) quanto nas de alta produtividade (Q4), observou-se uma oscilação significativa entre plantas vizinhas (Figura 7), um fenômeno espacial que reafirma a heterogeneidade inerente aos atributos estruturais e produtivos de uma lavoura cafeeira mesmo em pequenas distâncias (FERRAZ *et al.*, 2017). Sendo assim, o método de análise centroide permite caracterizar plantas de maior produtividade acumulada e estabilidade produtiva ao longo do tempo (ROCHA, *et al.* 2015).

Figura 7. Distribuição espacial dos quartis em função da produtividade



Fonte: Elaborado pela autora, 2026.

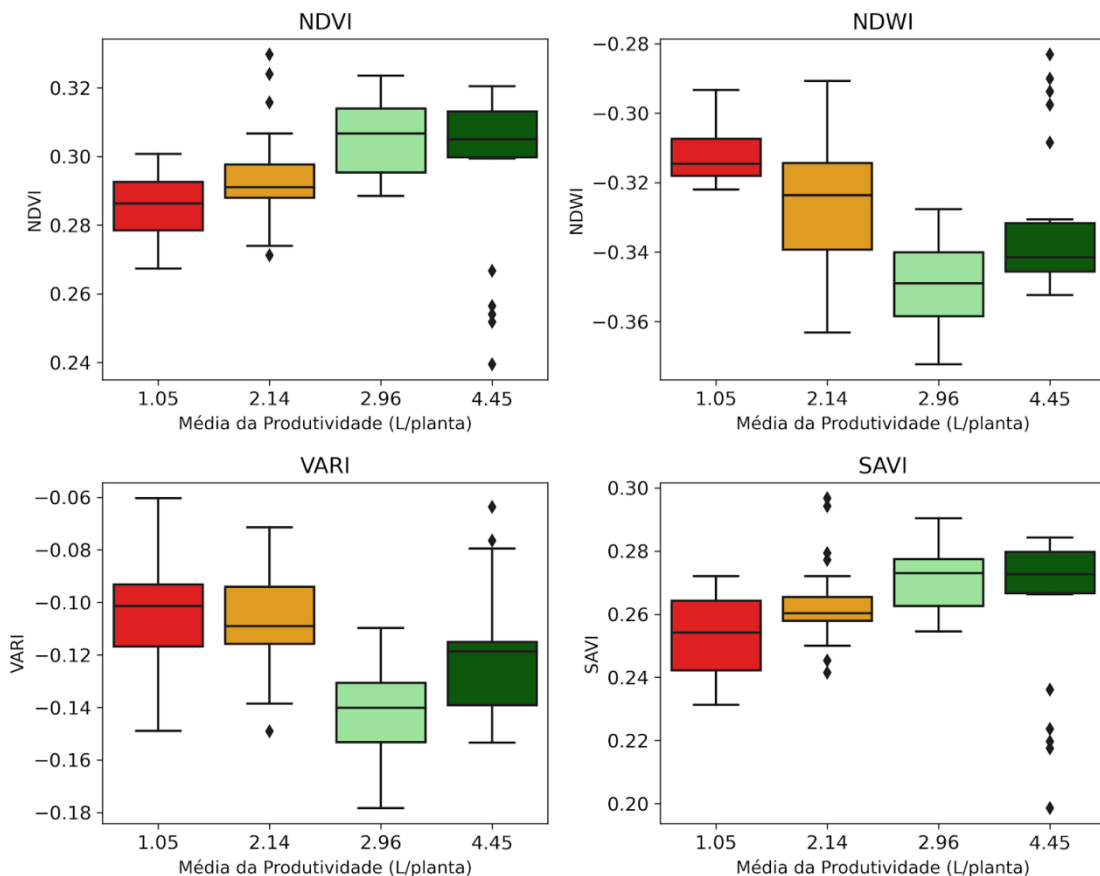
Esses resultados refletem o estágio atual de desenvolvimento da lavoura, que conta com pouco mais de três anos de idade. Nesta fase de formação e primeira produção expressiva, é comum que o estande de plantas ainda não tenha atingido a plena estabilidade produtiva. Fatores como o replantio de mudas — muitas vezes necessário devido a falhas no pegamento inicial — criam um descompasso fenológico na lavoura, visto que pequenas partes da área replantadas geram uma variação direta na estrutura das plantas e em seus respectivos estádios fenológicos locais (ABREU JÚNIOR *et al.*, 2022). Nessas condições, plantas mais jovens e menos produtivas convivem lado a lado com as plantas originais mais desenvolvidas, sendo que essa diferença de idade afeta diretamente o dossel, gerando variações no índice de área foliar e nas assinaturas espectrais e fisiológicas da cultura (CHEMURA; MUTANGA, 2017; MANOEL; ROSA; QUEIROZ, 2024).

Além disso, o próprio manejo de implantação e os ajustes de fertilidade do solo, necessários para adequar a área a patamares de alta produtividade, demandam tempo para homogeneizar a resposta da cultura, uma vez que o monitoramento da nutrição mineral e a sua interação com o ambiente são determinantes para a expressão espacial da produtividade do café (ALVES *et al.*, 2022). Portanto, a variabilidade observada não indica necessariamente uma limitação permanente do solo, mas sim um reflexo da dinâmica temporal de

estabelecimento da lavoura cafeeira, evidenciando os impactos iniciais característicos de uma planta perene, cujas dinâmicas de transplante afetam o vigor e a uniformidade nos primeiros ciclos de desenvolvimento no campo (BENTO *et al.*, 2022).

A análise dos índices de vegetação revelou uma coerência fisiológica com os dados de produtividade. De modo geral, as plantas situadas nos quartis de maior produção apresentaram assinaturas espectrais típicas de vegetação vigorosa, caracterizadas por maiores valores de NDVI e SAVI, e menores valores de NDWI (mais negativos) (Figura 8). Esse padrão corrobora a premissa de que a maior produtividade está associada a um maior volume de biomassa foliar sadia e metabolicamente ativa, afirmam Picoli *et al.* (2009).

Figura 8. *Boxplot* dos quartis em função dos índices espectrais



Fonte: Elaborado pela autora, 2026.

Observou-se, contudo, que a sensibilidade dos índices variou conforme a classe de produtividade. O NDVI apresentou, em média, menor variabilidade global (CV ~5,8%) quando comparado ao NDWI (CV ~6,2%), sugerindo que o índice de água (NDWI) pode ser mais suscetível a oscilações sutis nas condições de campo ou ruídos de fundo do que o índice

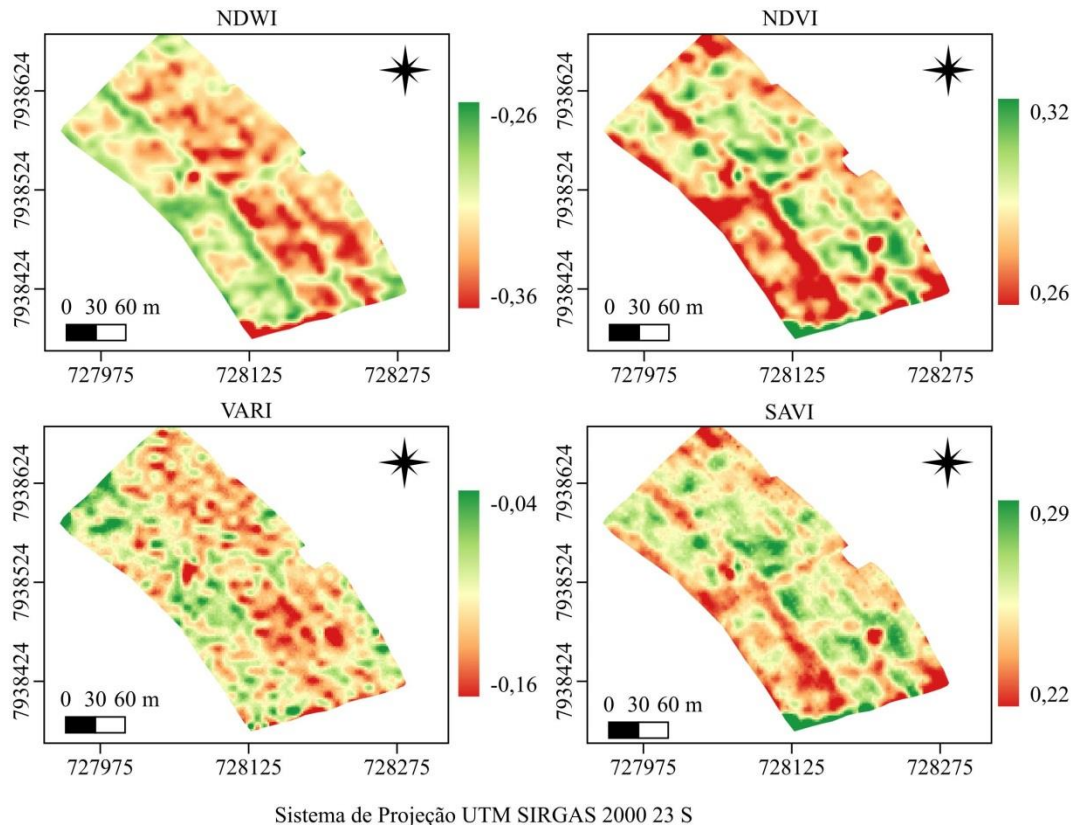
de vegetação padrão. Nascimento (2019) afirma ser a variável mais importante na estimativa de produtividade do cafeeiro através do *Random Forest*, uma vez que é sensível ao conteúdo de água no dossel e à umidade presente no solo. Assim, a maior variação e suscetibilidade a ruídos do NDWI reflete a complexidade do ambiente agrícola do café, onde o sinal captado sofre forte interferência da refletância do solo ao fundo dependendo da arquitetura e grau de fechamento das plantas (CHEMURA *et al.*, 2018).

Um ponto crucial desta análise foi a comparação entre os índices que utilizam a banda do infravermelho próximo (NIR) — como NDVI, SAVI e NDWI — e o índice VARI, que opera exclusivamente no espectro visível. A ausência do NIR no cálculo do VARI resultou em uma menor capacidade de discriminação entre as classes de produtividade, especialmente nos níveis inferiores. Enquanto o NDVI e o SAVI conseguiram diferenciar claramente o primeiro quartil (Q1) do segundo (Q2), o índice VARI apresentou médias praticamente estagnadas entre esses grupos (diferença de médias  $< 0,001$ ), falhando em capturar a variabilidade produtiva nessas zonas. Índices baseados estritamente em bandas do visível (RGB) frequentemente carecem de sensibilidade suficiente para detectar variações agrônômicas complexas ou estresses estruturais no dossel cafeeiro, possuindo desempenho inferior quando comparados aos índices que incorporam o infravermelho. Segundo Ponzoni, Shimabukuro e Kuplich (2012), essa limitação decorre do fato de que a refletância na região do visível é controlada essencialmente pela absorção dos pigmentos fotossintetizantes, enquanto a região do infravermelho próximo (NIR) é sensível às variações na estrutura celular interna da folha e ao espalhamento múltiplo entre as camadas do dossel.

Esse comportamento evidencia a importância determinante da banda do NIR para o monitoramento cafeeiro. A banda infravermelho próximo não é absorvida pela clorofila. Em vez disso, sua refletância está diretamente associada à estrutura interna das folhas. (MARTINS, J. A. e SARGENTELLI, V. 2021). Portanto, a banda do NIR avalia com precisão as condições de turgor, a sanidade do parênquima foliar e a densidade volumétrica da planta (SILVA *et al.*, 2021; VILELA *et al.*, 2023). Ela fornece informações estruturais e fisiológicas sobre o vigor da cultura que não são perceptíveis apenas pelas mudanças superficiais de cor (região do visível) captadas pelo VARI. Desse modo, a incapacidade do VARI em segregar eficientemente as zonas de manejo reforça que a caracterização da produtividade nesta área depende fundamentalmente de sensores capazes de captar a resposta espectral além do visível.

A consistência entre os dados espectrais e a produtividade observada em campo não se limitou apenas aos valores estatísticos globais, mas manifestou-se também na distribuição espacial das variáveis (Figura 9).

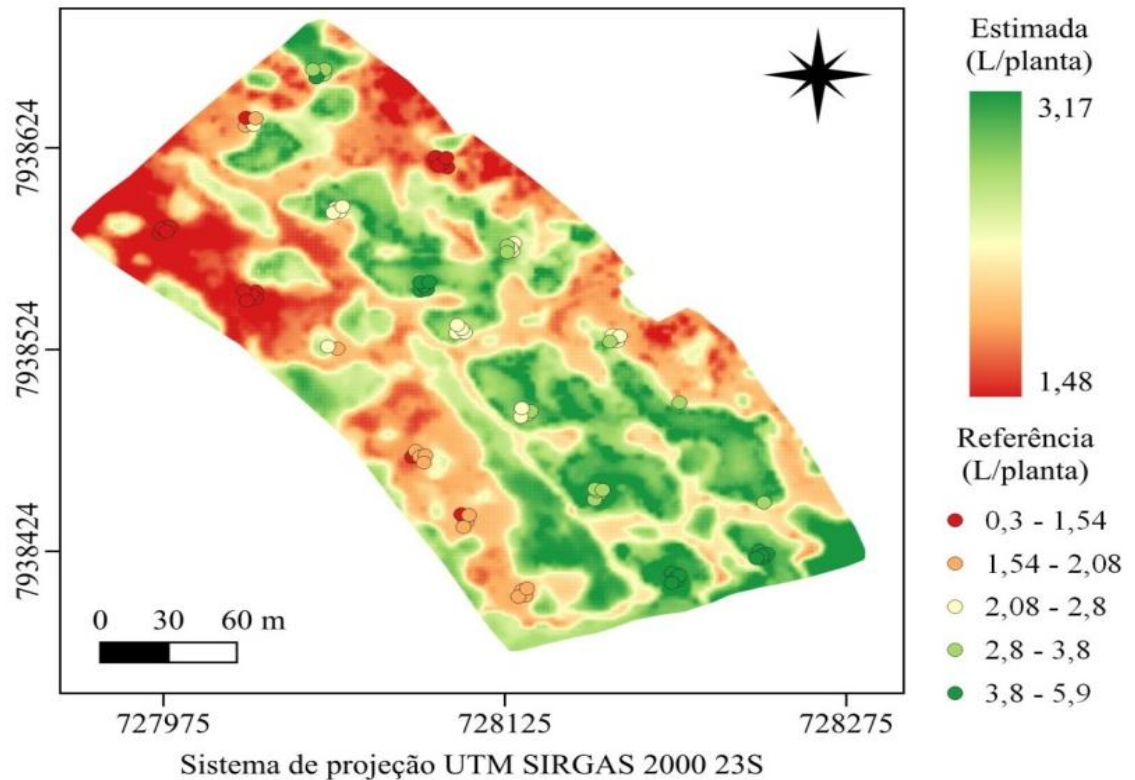
Figura 9. Distribuição espacial dos índices espectrais



Fonte: Elaborado pela autora, 2026.

Verificou-se que as zonas identificadas pelas imagens como de alto vigor vegetativo, caracterizadas por maiores valores de NDVI e SAVI, coincidiram geograficamente com os pontos de maior rendimento de grãos, confirmando que a assinatura e a refletância do dossel traduzem a variabilidade espacial do potencial produtivo da cultura (NOGUEIRA; MOREIRA; VOLPATO, 2018; MARTELLO *et al.*, 2022). A utilização de índices de vegetação possibilita a avaliação quantitativa da biomassa e da área foliar, nesse contexto, o rendimento final de grãos do cafeeiro apresenta uma dependência direta desses parâmetros biofísicos (Figura 10). Ramirez e Zullo Júnior (2010) ressaltam que o uso de modelos baseados em índices espectrais para determinar o índice de área foliar e a porcentagem de biomassa fornece indicativos precisos da produtividade da cultura.

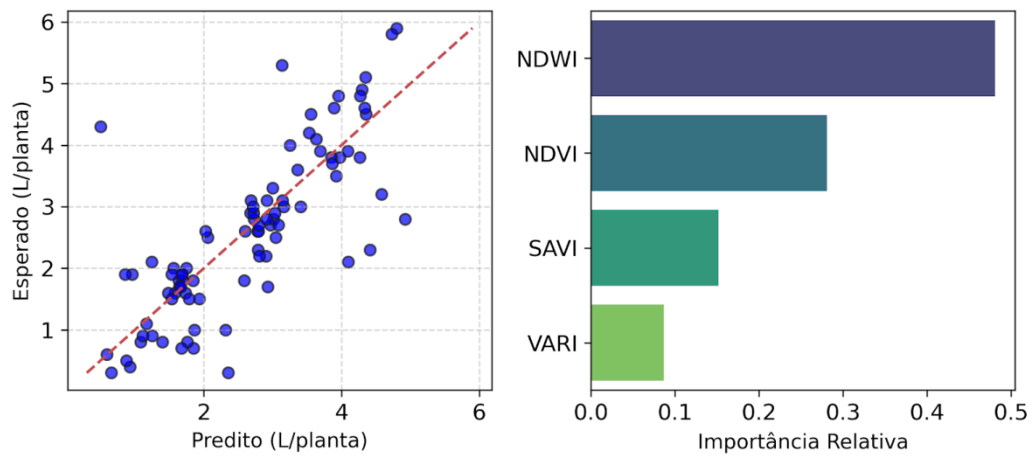
Figura 10. Mapa comparativo entre produtividade de referência e estimada



Fonte: Elaborado pela autora, 2026.

A avaliação do modelo de regressão *Random Forest*, utilizando índices espectrais derivados de imagens com resolução espacial de 8 metros obtidas em setembro, demonstrou uma capacidade preditiva satisfatória para condições de campo. O uso de algoritmos de aprendizado de máquina, tem se destacado amplamente na literatura pela sua superioridade em lidar com as relações complexas e não lineares inerentes aos dados espectrais para estimativa de safra cafeeira, frequentemente superando a acurácia dos métodos tradicionais de regressão linear. Segundo Souza *et al.* (2016), esses algoritmos demonstram um desempenho de excelência na análise de bases de dados de sensoriamento remoto que apresentam grande complexidade. O modelo alcançou um coeficiente de determinação ( $R^2$ ) de 0,61, com um erro médio absoluto (MAE) de  $0,51 \text{ L.planta}^{-1}$ , o que corresponde a uma margem de erro de aproximadamente  $6,3 \text{ sc.ha}^{-1}$  (Figura 11).

Figura 11. Modelo regressão *Random Forest* e importância das variáveis na predição da produtividade do cafeeiro



Fonte: Elaborado pela autora, 2026.

Considerando a complexidade dos fatores bióticos e abióticos — além das interações com clima, solo e a própria planta — que influenciam fortemente e resultam na alta variabilidade espacial da produção cafeeira (MARTELLO *et al.*, 2022), obter uma explicação de 61% da variabilidade produtiva apenas com dados espectrais orbitais é um resultado robusto. O erro de  $\sim 6$  sc ha<sup>-1</sup> situa-se dentro de limites aceitáveis para o planejamento operacional, muitas vezes comparável ao erro inerente das estimativas amostrais manuais convencionais, porém com a imensa vantagem de possibilitar uma varredura contínua e total da área, gerando informações em alta densidade que refletem as manchas do talhão de forma muito mais fidedigna do que coletas isoladas (BARBOSA *et al.*, 2021; MARTELLO *et al.*, 2022).

A grande relevância destes resultados reside na antecedência da informação. A obtenção de dados em setembro é amplamente validada por estudos prévios, pois esse período coincide com fases fenológicas cruciais, como o repouso/quebra de dormência, a florada e a fase de "chumbinho", cujas respostas espectrais e de vigor vegetativo apresentam os maiores potenciais preditivos para a safra seguinte (NOGUEIRA; MOREIRA; VOLPATO, 2018; SILVA *et al.*, 2021). Ao obter uma estimativa confiável do potencial produtivo com essa antecedência — período que antecede o enchimento de grãos e as principais adubações do período chuvoso —, o produtor ganha uma ferramenta estratégica inestimável para o manejo da próxima safra. A identificação precoce das zonas de alto e baixo potencial permite a transição de um manejo convencional para a Agricultura de Precisão (AP), cujo objetivo central, segundo Queiroz *et al.* (2000), é aumentar a eficiência produtiva com base no manejo

diferenciado de áreas. Essa abordagem viabiliza intervenções específicas fundamentais para a cafeicultura moderna, superando as limitações dos métodos tradicionais que tratam a lavoura como homogênea.

Dentre essas intervenções, destaca-se o planejamento de irrigações focadas, essencial para corrigir deficiências hídricas e favorecer uma floração mais abundante e uniforme. Conforme ressaltam Fraga Júnior *et al.* (2018), o manejo hídrico localizado é uma estratégia eficaz para mitigar efeitos climáticos negativos e otimizar o uso da água. Paralelamente, a identificação da variabilidade espacial permite a aplicação em taxas variáveis de corretivos e fertilizantes. De acordo com Silva e Alves (2013) e Molin, Amaral e Colaço (2015), essa tecnologia utiliza mapas georreferenciados para igualar as doses de insumos às necessidades objetivas da cultura em cada ponto do talhão, reduzindo custos e minimizando impactos ambientais.

Um dos achados mais relevantes deste estudo foi o protagonismo do índice NDWI, que se destacou como a variável de maior peso na predição da produtividade. Este resultado lança luz sobre a importância da banda do verde na formulação de índices — como o NDWI, que pode expressar a relação normalizada da refletância verde com a do infravermelho próximo —, frequentemente subutilizada em monitoramentos agrícolas convencionais que priorizam quase exclusivamente a banda do vermelho, que corresponde à região do espectro fortemente absorvida pela clorofila A e B durante o processo fotossintético, conforme afirmaram Victório *et. al* (2007).

O ganho preditivo obtido com a inclusão do verde sugere que, para a cultura do café nesta fase fenológica, a resposta espectral associada ao conteúdo de umidade, à sanidade e à estrutura foliar captada nesta faixa do espectro revela-se tão ou mais sensível e informativa do que a biomassa fotossintética tradicionalmente medida pelo NDVI (MARTELLO *et al.*, 2022; VILELA *et al.*, 2024).

Ao comparar o desempenho deste modelo ( $R^2 = 0,61$ ) com outros trabalhos recentes de estimativa de safra, observa-se uma superioridade nos resultados, muitas vezes não alcançada em estudos similares. Esse êxito deve ser atribuído, primeiramente, à densidade amostral adotada, uma vez que a obtenção de dados de alta densidade reflete a variabilidade da área de forma muito mais fidedigna (MARTELLO *et al.*, 2022). O uso de 100 pontos de amostragem georreferenciados permitiu que o algoritmo *Random Forest* — reconhecido por sua capacidade de lidar com dados complexos e modelar relações não-lineares (BREIMAN, 2001) — compreendesse com profundidade o padrão entre a resposta espectral e a

produtividade real, superando as limitações de modelos treinados com bases de dados escassas (ABREU JÚNIOR *et al.*, 2022).

Por fim, é imperativo ressaltar o papel da resolução espacial. A utilização de imagens fusionadas em 2 metros foi determinante para garantir a pureza da resposta espectral, diferentemente de estudos que utilizam sensores gratuitos de resolução espacial mais ampla, como Sentinel-2 (10 m) ou Landsat (30 m), onde ocorre o fenômeno da mistura espectral. O uso de alta resolução evita que um único pixel contenha a média da reflectância de diferentes elementos, conforme explicam Ponzoni e Shimabukuro (2012) e Rosa *et al.* (2010), em sensores de resolução moderada, o valor do pixel é o resultado da integração das energias refletidas por diversos alvos dentro do campo de visada (*Instantaneous Field of View* - IFOV), o que acaba mascarando os detalhes e a diversidade real da área cultivada.

Na cafeicultura, essa complexidade é acentuada pelo sistema de plantio. De acordo com Moreira *et al.* (2004) e Bispo (2014), a resposta espectral do café é fortemente influenciada pelo solo exposto devido ao espaçamento entre as linhas, resultando em pixels "mistos" que combinam a reflectância da vegetação, do ruído de fundo do solo e do sombreamento interno do dossel. Além disso, Santos *et al.* (2011) e Pires (2016) ressaltam que, em regiões montanhosas, as distorções causadas por sombras podem reduzir ou anular a resposta espectral em pixels de baixa resolução, reforçando a necessidade de produtos de maior resolução espacial para assegurar a integridade dos dados radiométricos.

## 5. CONCLUSÃO

Os resultados deste estudo demonstram que a integração de índices espectrais, derivados de imagens orbitais multiespectrais de alta resolução, com o algoritmo de aprendizado de máquina *Random Forest* constitui uma metodologia eficaz para a estimativa e o mapeamento da variabilidade espacial da produtividade na cultura do café. Ademais, constatou-se que o período fenológico de repouso vegetativo e pré-florada (setembro) configura a janela temporal para a aquisição dos dados espectrais, garantindo a antecedência preditiva necessária para o planejamento estratégico da safra.

Conclui-se, portanto, que a abordagem não destrutiva delineada fornece bases tecnológicas para a transição do manejo convencional para a agricultura de precisão. A geração de mapas de potencial produtivo em alta densidade viabiliza a adoção de intervenções sítio-específicas — tais como a aplicação de fertilizantes em taxa variável e o delineamento de podas seletivas —, otimizando a alocação de recursos operacionais e mitigando os impactos negativos inerentes à heterogeneidade espacial e à bienalidade do talhão.

## REFERÊNCIAS

- ABREU JÚNIOR, C. A. M. de; MARTINS, G. D.; XAVIER, L. C. M., Estimating coffee plant yield based on multispectral images and machine learning models. **Agronomy**, v. 12, n. 12, p. 3195, 2022.
- ABREU, K. M. P.; COUTINHO, L. M., Sensoriamento remoto aplicado ao estudo da vegetação com ênfase em índice de vegetação e métricas da paisagem. **Revista Vértices**, [S. l.], v. 16, n. 1, p. 177–202, 2014. DOI: 10.5935/1809-2667.20140012. Disponível em: <https://editoraessentia.iff.edu.br/index.php/vertices/article/view/1809-2667.20140012>. Acesso em: 13 jan. 2026.
- ALCARAS, E.; PARENTE, C.; VALLARIO, A., Automation of Pan-Sharpning Methods for Pléiades Images Using GIS Basic Functions. **Remote Sensing**, Basel, v. 13, n. 8, p. 1550, abr. 2021.
- ALVES, H. M. R. *et al.* Caracterização e monitoramento espectral de áreas cafeeicultoras no Brasil. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XLI-B8, p. 801–803, 2016.
- ALVES, M. C. *et al.* The role of machine learning on Arabica coffee crop yield based on remote sensing and mineral nutrition monitoring. **Biosystems Engineering**, v. 221, p. 81-104, 2022.
- ASSAD, E. D.; SANO, E. E. Sistema de informações geográficas: aplicações na agricultura. Brasília: **Embrapa**, 1998. Disponível em: <https://livimagens.sct.embrapa.br/amostras/00064290.pdf>. Acesso em: 09 jan. 2026.
- BARBOSA, B. D. S.; FERRAZ, G. A. e S.; COSTA, L. *et al.* Yield prediction of coffee crop based on aerial images. **Smart Agricultural Technology**, v. 1, p. 100010, 2021.
- BARBOSA, B. D. S.; FERRAZ, G. A. e S.; SANTOS, L. M. dos *et al.* Application of RGB images obtained by UAV in coffee farming. **Remote Sensing**, v. 13, n. 12, p. 2397, 2021. Disponível em <https://www.mdpi.com/2072-4292/13/12/2397>. Acesso em: 11 jan. 2026.
- BENTO, N. L. *et al.* Estimate and Temporal Monitoring of Height and Diameter of the Canopy of Recently Transplanted Coffee by a Remotely Piloted Aircraft System. **AgriEngineering**, v. 4, n. 1, p. 207-215, 2022.
- BERNARDES, T.; MOREIRA, M. A.; ADAMI, M. *et al.* Monitoring biennial bearing effect on coffee yield using MODIS remote sensing imagery. **Remote Sensing**, v. 4, n. 8, p. 2492-2509, 2012. Disponível em: <https://www.mdpi.com/2072-4292/4/9/2492>. Acesso em: 09 jan. 2026.
- BISPO, R. C.; Bialidade e mapeamento de café através de séries temporais de imagens MODIS. 2014. 99 f. Dissertação (Mestrado em Sensoriamento Remoto) – **Instituto Nacional de Pesquisas Espaciais (INPE)**, São José dos Campos, 2014.

BRASIL. Companhia Nacional de Abastecimento (CONAB). **4º Levantamento de Café – Safra 2025**. 2025. Disponível em: <https://www.gov.br/conab/pt-br/atuacao/informacoes-agropecuarias/safras/safra-de-cafe/4o-levantamento-de-cafe-safra-2025/4o-levantamento-de-cafe-safra-2025>. Acesso em: 8 dez. 2025.

BREIMAN, L. “**Random forests**. *Machine Learning*”, v. 45, n. 1, p. 5–32, 2001.

BOLAÑOS, J.; CORRALES, J.C.; CAMPO, L.V. Feasibility of Early Yield Prediction per Coffee Tree Based on Multispectral Aerial Imagery: Case of Arabica Coffee Crops in Cauca-Colombia. **Remote Sensing**, Basel, v. 15, n. 282, 2023.

CÂMARA, G. Análise espacial de dados geográficos. Brasília: **Embrapa**, 2004.

CAMARGO, A. P.; CAMARGO, M. B. P. **Definição e esquematização das fases fenológicas do cafeeiro arábica nas condições tropicais do Brasil**. *Bragantia*, Campinas, v. 60, n. 1, p. 65-68, 2001. Disponível em: <https://doi.org/10.1590/S0006-87052001000100008>. Acesso em: 28 dez. 2025.

CAMPOS, D. S.; **Análise da variabilidade espacial da produtividade na cafeicultura de montanha com uso de técnicas de sensoriamento remoto**. 2005. 63 f. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Federal de Viçosa, Viçosa, 2005.

CEBALLOS-SIERRA, F.; DALL'ERBA, S. The effect of climate variability on Colombian coffee productivity: A dynamic panel data approach. **Agricultural Systems**, v. 190, p. 103126, 2021.

CHEMURA, A.; MUTANGA, O. Developing detailed age-specific thematic maps for coffee (*Coffea arabica* L.) in heterogeneous agricultural landscapes using random forests applied on Landsat 8 multispectral sensor. **Geocarto International**, v. 32, n. 7, p. 759-776, 2017.

Disponível em:

[https://www.researchgate.net/publication/301483986\\_Developing\\_detailed\\_age-specific\\_thematic\\_maps\\_for\\_coffee\\_Coffea\\_arabica\\_L\\_in\\_heterogeneous\\_agricultural\\_landscapes\\_using\\_random\\_forests\\_applied\\_on\\_Landsat\\_8\\_multispectral\\_sensor](https://www.researchgate.net/publication/301483986_Developing_detailed_age-specific_thematic_maps_for_coffee_Coffea_arabica_L_in_heterogeneous_agricultural_landscapes_using_random_forests_applied_on_Landsat_8_multispectral_sensor). Acesso em: 09 jan. 2026.

CHEMURA, A.; MUTANGA, O.; ODINDI, J.; KUTYWAYO, D. Mapping spatial variability of foliar nitrogen in coffee (*Coffea arabica* L.) plantations with multispectral Sentinel-2 MSI data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 138, p. 1-11, 2018.

CLEMENTINO, F. S. Estimativa da diversidade espectral de tipologias florestais utilizando imagens hiperespectrais orbitais do sensor EnMAP. 2025. 65 p. IBI:

8JMKD2USNRW34T/4DBM7MP. (sid.inpr.br/mtc-m12e/2025/04.19.15.08-TDI).

Dissertação (Mestrado em Sensoriamento Remoto) – **Instituto Nacional de Pesquisas Espaciais (INPE)**, São José dos Campos, 2025. Disponível em:

<http://urlib.net/ibi/8JMKD2USNRW34T/4DBM7MP>. Acesso em 7 fev. 2025.

FAGUNDES, R. B.; **Sensoriamento remoto e redes neurais na estimativa da produtividade do café arábica na Bahia**. 2025. 107 f. Dissertação (Mestrado em Agricultura de Precisão) – Universidade Federal de Santa Maria, Santa Maria, RS, 2025.

FERNANDES, P. J. F.; VICENS, R. S.; FURTADO, L. Comparação de algoritmos de filtragem em séries temporais de NDVI/MODIS. **Revista Brasileira de Cartografia**, v. 70, n. 3, p. 867–905, 2018. 1, 23

FERRAZ, G. A. S.; SILVA, F. M.; OLIVEIRA, M. S.; CUSTÓDIO, A. A. P.; FERRAZ, P. F. P. Spatial variability of plant attributes of a coffee crop / Variabilidade espacial dos atributos da planta de uma lavoura cafeeira. **Revista Ciência Agronômica**, v. 48, n. 1, p. 81-91, 2017.

FLORENZANO, T.G. Imagens de satélite para estudos ambientais. São Paulo: **Oficina de Textos**, 2002. 97p.

FRAGA JÚNIOR, E. F. et al. Manejo da irrigação do cafeeiro com água magnetizada. **Coffee Science**, Lavras, v. 13, n. 4, p. 450-460, 2018.

**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE)**. CBERS-4A: características e aplicações. São José dos Campos: INPE, 2023. Disponível em: <https://www.gov.br/inpe/pt-br/assuntos/cbers>. Acesso em: 10 set. 2025.

MANOEL, M. C.; ROSA, M. R.; QUEIROZ, A. P. de. Analysis of the Biennial Productivity of Arabica Coffee with Google Earth Engine in the Northeast Region of São Paulo, Brazil. **Remote Sensing**, v. 16, n. 20, p. 3833, 2024. Disponível em: <https://doi.org/10.3390/rs16203833>. Acesso em: 16 jan. 2026.

MARTELLO, M.; MOLIN, J. P.; WEI, M. C. F. *et al.* Coffee-Yield Estimation Using High-Resolution Time-Series Satellite Images and Machine Learning. **AgriEngineering**, v. 4, n. 4, p. 888-902, 2022.

MARTINS, J. A. e SARGENTELLI, V. “INFRAVERMELHO PRÓXIMO NA AVALIAÇÃO QUANTITATIVA FOLIAR” **Revista Prospectus**, v. 3, n. 1, p. 33-55, Fev/Ago, 2021

MIFTAHUDDIN, Y.; RAIS, R.; Classification of Roasted Coffee Beans with Principal Component Analysis and Random Forest. **E3S Web of Conferences**, [s. l.], v. 484, n. 02009, 2024. Disponível em: <https://doi.org/10.1051/e3sconf/202448402009>. Acesso em: 16 jan. 2026.

MOLIN, J. P.; AMARAL, L. R.; COLAÇO, A. F. **Agricultura de precisão**. São Paulo: Oficina de Textos, 2015. 153 p. Disponível em chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/<https://www.bibliotecaagptea.org.br/agricultura/precisao/livros/AGRICULTURA%20DE%20PRECISAO%20-%20OFICINA%20DE%20TEXTOS.pdf>. Acesso em: 17 dez. 2025.

MOREIRA, M. A.; ADAMI, R.; RUDORFF, B. F. T.; Análise espectral e temporal da cultura do café em imagens Landsat. **Pesquisa Agropecuária Brasileira**, Brasília, v. 39, n. 3, p. 223-231, mar. 2004.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. Viçosa: Ed. UFV, 2005. 320p.

Nascimento, A. L. (2019). “**Estimativa de produtividade de café por meio de métodos de machine learning**”. Universidade Federal de Viçosa, Viçosa 2019.

NOGUEIRA, S. M. C.; MOREIRA, M. A.; VOLPATO, M. M. L. Relationship between coffee crop productivity and vegetation indexes derived from OLI / Landsat-8 sensor data with and without topographic correction. **Engenharia Agrícola**, v. 38, n. 3, p. 387-394, 2018. Disponível em: <https://doi.org/10.1590/1809-4430-Eng.Agric.v38n3p387-394/2018>. Acesso em 29 jan. 2026.

PICOLI, M. Cristina Araujo; RUDORFF, B. F. T.; RIZZI, R.; GIAROLLA, A.; **Índice de vegetação do sensor MODIS na estimativa da produtividade agrícola da cana-de-açúcar**. Bragantia, Campinas, v. 68, n. 3, p. 789-795, 2009.

PIRES, M. S. de O.; **Monitoramento de lavouras de cafeeiro sob diferentes sistemas de irrigação por radiometria orbital**. 2016. 121 f. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Federal de Lavras, Lavras, 2016.

PRADO, E. V. Fenotipagem de plantas por meios digitais. **Revista Gestão em Foco**, 15 ed. 107. Amparo, São Paulo, 2023.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, M. T. **Sensoriamento remoto da vegetação**. 2. ed. São Paulo: Oficina de Textos, 2012.

QUEIROZ, D. M. et al. Agricultura de precisão na produção de grãos. In: BORÉM, A. et al. (ed.). **Agricultura de Precisão**. Viçosa: UFV, 2000. p. 1-41.

RAMIREZ, G. M.; ZULLO JÚNIOR, J. Estimativa de parâmetros biofísicos de plantios de café a partir de imagens orbitais de alta resolução espacial. **Engenharia Agrícola**, Jaboticabal, v. 30, n. 2, p. 303-316, mar./abr. 2010. Disponível em: <https://doi.org/10.1590/S0100-69162010000300011> Acesso em: 17 dez. 2025.

ROCHA, R. R.; RAMALHO, A. R.; TEIXEIRA, A. L.; SOUZA, F. F.; CRUZ, C. D. “Adaptabilidade e estabilidade da produção de café beneficiado em *Coffea canefora*”. **Ciência Rural**, Santa Maria, v.45, n.9, p.1531-1537, set, 2015.

ROSA, R. **Geotecnologias na geografia aplicada**. Uberlândia: EDUFU, 2005. P 81-90.

ROSA, Viviane Gomes Cardoso da et al.; Estimativa da produtividade de café com base em um modelo agrometeorológico-espectral. **Pesquisa Agropecuária Brasileira**, Brasília, v. 45, n. 12, p. 1478-1488, dez. 2010.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. **Monitoring vegetation systems in the Great Plains with ERTS**. Washington: NASA, 1974. 309 p. 1, 10. Disponível em <https://ntrs.nasa.gov/citations/19740022614>. Acesso em 03 jan. 2026.

SANTOS, J. S. et al. Dificuldades no mapeamento de áreas cafeeiras: uma abordagem espectral. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15., 2011, Curitiba. **Anais...** São José dos Campos: INPE, 2011. p. 101-108.

SILVA, S. A.; ALVES, M. C. Cafeicultura de Precisão. **Informe Agropecuário**, Belo Horizonte, v. 34, n. 277, p. 17-26, 2013.

SILVA, P. A. de A.; ALVES, M. de C.; SILVA, F. M. da; FIGUEIREDO, V. C. Coffee yield estimation by Landsat-8 imagery considering shading effects of planting row's orientation in

center pivot. **Remote Sensing Applications: Society and Environment**, v. 24, p. 100613, 2021.

SOUZA, Carolina Gusmão *et al.* Algoritmos de aprendizagem de máquina e variáveis de sensoriamento remoto para o mapeamento da cafeicultura. **Boletim de Ciências Geodésicas**, Curitiba, v. 22, n. 4, p. 751-773, out./dez. 2016. Disponível em: <https://doi.org/10.1590/S1982-21702016000400043>. Acesso em: 08 jan. 2026.

VICTORIO, C. P.; KUSTER, R. M.; LAGE, L. S. “Qualidade de Luz e Produção de Pigmentos Fotossintéticos em Plantas *In Vitro* de *Phyllanthus tenellus* Roxb” **Revista Brasileira de Biociências**, Porto Alegre, v. 5, supl. 2, p. 213-215, jul. 2007.

VILELA, E. F. *et al.* New Spectral Index and Machine Learning Models for Detecting Coffee Leaf Miner Infestation Using Sentinel-2 Multispectral Imagery. **Agriculture**, v. 13, n. 2, p. 388, 2023.

VILELA, E. F.; CASTRO, G. D. M. de; MARIN, D. B.; Remote Monitoring of Coffee Leaf Miner Infestation Using Machine Learning. **AgriEngineering**, v. 6, n. 3, p. 1697-1711, 2024.

WENG, Q. Remote Sensing and GIS Integration: Theories, Methods, and Applications. **New York: McGraw-Hill**, 2010. 397p. Disponível em: [chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/https://faculty.ksu.edu.sa/sites/default/files/remote\\_sensing\\_and\\_gis\\_integration.pdf](chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/https://faculty.ksu.edu.sa/sites/default/files/remote_sensing_and_gis_integration.pdf). Acesso em: 9 jan. 2026.

ZANELLA, M. A. *et al.* Coffee yield prediction using high-resolution satellite imagery and crop nutritional status in Southeast Brazil. **Remote Sensing Applications: Society and Environment**, Amsterdam, v. 33, 101092, 2024.