



Processamento de Imagens e Radiação Eletromagnética: Aplicações na Análise Nutricional de Culturas Agrícolas

**Adriano Rogério Bruno Tech
Lilian Elgalise Techio Pereira
Fernanda de Fátima da Silva Devechio
João Paulo Rodrigues Marques
Murilo Mesquita Baesso**

 **Pedro & João**
editores

2025

**Adriano Rogério Bruno Tech
Lilian Elgalise Techio Pereira
Fernanda de Fátima da Silva Deveschio
João Paulo Rodrigues Marques
Murilo Mesquita Baesso**



**PROCESSAMENTO DE IMAGENS E RADIAÇÃO
ELETROMAGNÉTICA: APLICAÇÕES NA ANÁLISE
NUTRICIONAL DE CULTURAS AGRÍCOLAS**

Copyright © Autoras e autores

Todos os direitos garantidos. Qualquer parte desta obra pode ser reproduzida, transmitida ou arquivada desde que levados em conta os direitos das autoras e dos autores.

Adriano Rogério Bruno Tech; Lilian Elgalise Techio Pereira; Fernanda de Fátima da Silva Devechio; João Paulo Rodrigues Marques; Murilo Mesquita Baesso [Orgs.]

Processamento de imagens e radiação eletromagnética: aplicações na análise nutricional de culturas agrícolas. São Carlos: Pedro & João Editores, 2025. 91p. 21 x 29,7 cm.

ISBN: 978-65-265-1920-2 [Digital]

DOI: 10.51795/9786526519202

1. Sensoriamento remoto. 2. Visão computacional. 3. Comprimento de onda. 4. Assinatura espectral de plantas. I. Título.

CDD – 636

Capa: Lilian Elgalise Techio Pereira

Ficha Catalográfica: Hélio Márcio Pajeú – CRB - 8-8828

Diagramação: Adriano Rogério Bruno Tech & Lilian Elgalise Techio Pereira

Editores: Pedro Amaro de Moura Brito & João Rodrigo de Moura Brito

Conselho Editorial da Pedro & João Editores:

Augusto Ponzio (Bari/Itália); João Wanderley Geraldi (Unicamp/Brasil); Hélio Márcio Pajeú (UFPE/Brasil); Maria Isabel de Moura (UFSCar/Brasil); Maria da Piedade Resende da Costa (UFSCar/Brasil); Valdemir Miotello (UFSCar/Brasil); Ana Cláudia Bortolozzi (UNESP/Bauru/ Brasil); Mariangela Lima de Almeida (UFES/Brasil); José Kuiava (UNIOESTE/Brasil); Marisol Barenco de Mello (UFF/Brasil); Camila Caracelli Scherma (UFFS/Brasil); Luís Fernando Soares Zuin (USP/Brasil); Ana Patrícia da Silva (UERJ/Brasil).



Pedro & João Editores

www.pedroejoaoeditores.com.br

13568-878 – São Carlos – SP

2025

Prefácio

A agricultura moderna enfrenta desafios crescentes para garantir a sustentabilidade e a produtividade, em um cenário de aumento da demanda alimentar e de recursos limitados. Uma das principais áreas de inovação nesse campo é o uso de tecnologias avançadas para o monitoramento e análise de culturas, visando uma melhor gestão de recursos e otimização dos insumos, como fertilizantes e água. Entre essas tecnologias, o processamento de imagens aliado à radiação eletromagnética tem se destacado como uma ferramenta eficaz para a geração de informações precisas e detalhadas sobre o estado nutricional das plantas.

Este livro explora a aplicabilidade do processamento de imagens na agricultura, com foco na análise da interação entre radiação eletromagnética e as folhas das plantas para identificar deficiências nutricionais. Ao longo dos capítulos, será abordado o caminho desde a captura das imagens até a extração de informações valiosas que podem guiar decisões agronômicas cruciais. O objetivo é fornecer uma compreensão clara de como essas técnicas podem ser aplicadas na prática, ajudando produtores, pesquisadores e técnicos a monitorar a saúde das culturas de forma não invasiva e precisa.

O avanço dessas técnicas é resultado da integração de diferentes áreas do conhecimento, como a física da radiação, a ciência das plantas e a ciência da computação. Ao compreender como a radiação eletromagnética interage com as folhas das plantas e como essa informação pode ser processada para gerar dados úteis, os profissionais da agricultura podem obter *insights* valiosos sobre o estado de saúde das culturas, identificando deficiências nutricionais antes que se tornem visíveis a olho nu.

A abordagem apresentada neste livro está fundamentada em uma base sólida de pesquisa e prática, proporcionando um conteúdo atualizado e relevante para aqueles que buscam soluções tecnológicas para os desafios da agricultura moderna. Além disso, o texto explora as vantagens do uso de tecnologias não invasivas para a avaliação de cultivos, contribuindo para uma agricultura mais sustentável e eficiente.

Esperamos que este livro sirva como uma fonte de conhecimento, tanto para profissionais do setor quanto para pesquisadores que desejam explorar novas fronteiras no campo da agricultura de precisão. Através da combinação de processamento de imagens e radiação eletromagnética, acreditamos que este trabalho oferece um novo olhar sobre a análise nutricional de plantas e suas aplicações no campo.

Os Autores

**A natureza é o único livro que oferece um conteúdo
valioso em todas as suas folhas.**

Johann Goethe

Sumário

CAPÍTULO 1	6
A radiação solar e os comprimentos de ondas	6
CAPÍTULO 2	21
Propriedades ópticas das folhas	21
CAPÍTULO 3	32
Processamento de Imagens: da aquisição a extração da informação	32
CAPÍTULO 4	43
Uso da análise de imagem para predição de severidade de estresse biótico	43
CAPÍTULO 5	52
Identificação de deficiência de macronutrientes em milho	52
CAPÍTULO 6	70
Identificação de deficiência de micronutrientes em milho	70
Sobre os Autores	85

CAPÍTULO 1

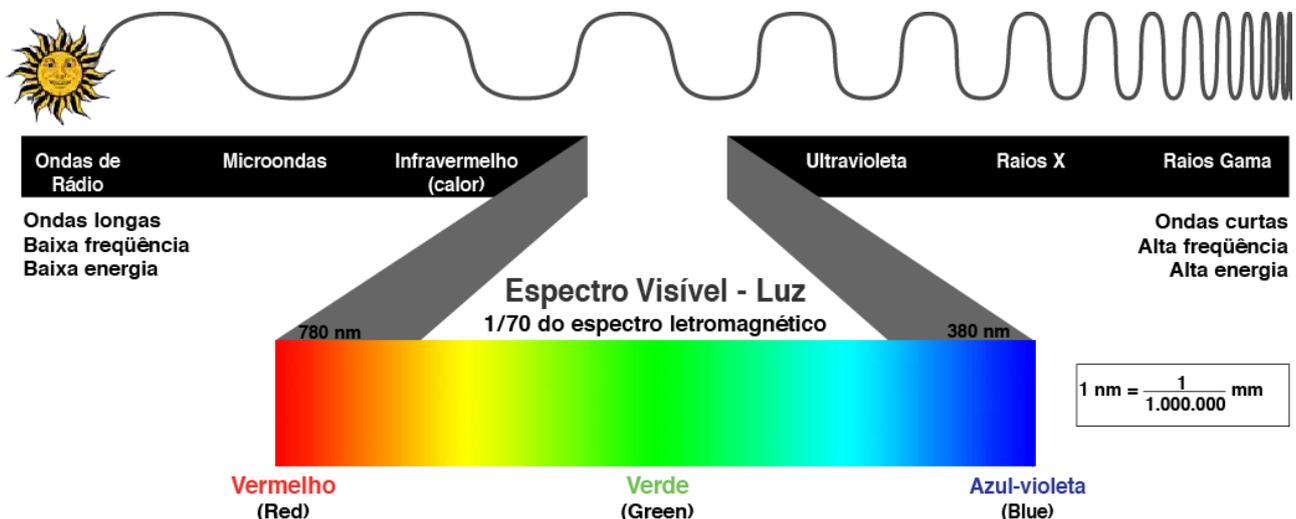
A radiação solar e os comprimentos de ondas

Adriano Rogério Bruno Tech; Aldo Ivan Céspedes Arce; João Paulo Rodrigues Marques; Murilo Mesquita Baesso; Wilson Manuel Castro Sillupu; Lilian Elgalise Techio Pereira

1. A radiação solar

A radiação solar consiste em radiação eletromagnética ou energia radiante emitida pelo sol, a qual é composta por um amplo espectro eletromagnético que provê luz e calor para o ecossistema. Espectro eletromagnético é o conjunto de frequências de uma dada fonte de radiação eletromagnética, sendo que cada uma dessas faixas de frequência possui diferentes impactos sobre o ambiente. O espectro eletromagnético da luz solar inclui ondas de rádio, microondas, infravermelho, luz visível, radiação ultravioleta (UV), raios X e raios gama, sendo a primeira caracterizada por ondas longas e de menor frequência e a última de maior frequência e com ondas curtas (FIGURA 1).

Figura 1. Espectro eletromagnético da radiação solar, com destaque para as frequências na faixa da luz visível.



Fonte: Mecanismo da visão. Disponível em: < <https://www.emaze.com/@AllORQWW> >. Acesso em: 15 abril de 2025.

Segundo Ollinger (2020), grande parte da radiação emitida pelo sol está compreendida na faixa entre 200 a 2500 nm, com pico em ~500-550 nm, que corresponde aos comprimentos de onda da luz verde-amarelada, e distribuição que,

segundo a Lei de Planck, se aproxima do espectro de emissão de um corpo negro, à aproximadamente 5800-6000°K. Todavia, nem todo o espectro da radiação solar emitida chega à superfície terrestre, estimando-se que apenas 25% efetivamente penetra a atmosfera e atinge a superfície.

Existem regiões do espectro que, ao incidir sobre a atmosfera, interagem com nuvens, gases e aerossóis e a própria superfície terrestre, e são totalmente ou parcialmente **refletidas**. A fração da radiação incidente que é refletida pela terra, ou albedo, varia no espaço e no tempo, dependendo da natureza da superfície e da inclinação do Sol.

As regiões do espectro onde a atmosfera **absorve** toda a radiação eletromagnética (atua como uma superfície opaca) ocorrem principalmente na faixa UV. Os gases estão intimamente ligados a esse processo, principalmente o ozônio (O₃), uma vez que quando uma molécula de gás absorve radiação, a energia é transformada em movimento molecular interno, detectável como aumento de temperatura e, portanto, quando ocorre a absorção dessa faixa, a radiação é convertida em calor. Na região do infravermelho, os principais gases envolvidos na absorção da radiação são o vapor de água e o dióxido de carbono (CO₂) (MORAES, 2002), enquanto menor proporção de absorção nessa faixa é verificado para o O₂, N₂O e CH₄.

Regiões do espectro eletromagnético onde a atmosfera age de forma transparente, ou seja, onde a radiação não é absorvida mas **transmitida**, compõe a radiação que chega à superfície terrestre, estando, em grande parte, na faixa espectral entre 0,3 e 0,7 μm (MORAES, 2002; OLLINGER, 2011). Assim, considerando o espectro eletromagnético da radiação solar, podem ser descritas três principais faixas relevantes (FIGURA 2): a) radiação na faixa ultravioleta (UV) que compõe cerca de 8% da radiação que atinge a superfície terrestre; b) a radiação solar na faixa do visível, também conhecida como radiação fotossinteticamente ativa (RFA), a qual corresponde a aproximadamente 43-45% da radiação que atinge a superfície terrestre; e c) a radiação na faixa do infravermelho, representando até 49% da radiação que atinge a superfície terrestre (GURJAR et al., 2017).

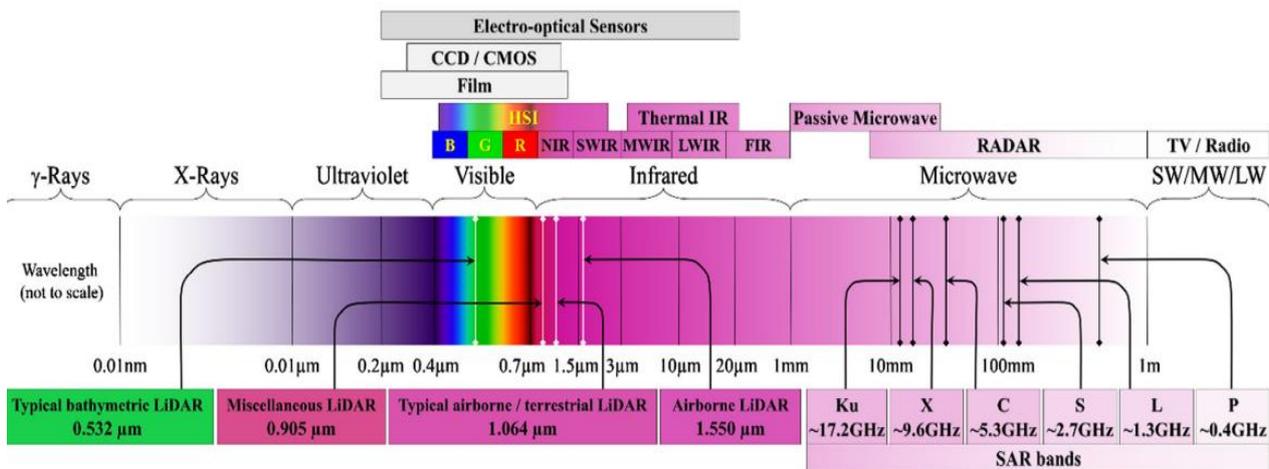
A radiação solar viaja através do vácuo do espaço e, ao entrar na atmosfera terrestre, inicia uma complexa série de interações com os componentes atmosféricos e a superfície terrestre. No espectro da radiação que passa através da atmosfera uma parte irá incidir diretamente sobre a superfície sem sofrer qualquer influência, denominada **radiação direta**, e outra parte pode ser espalhada por gotículas e nuvens, moléculas de ar e partículas de poeira, dispersando-a em todas as direções até atingir a superfície da Terra, a qual é chamada de **radiação difusa** (GURJAR et al., 2017).

“A insolação difusa é constituída de radiação solar que é espalhada ou refletida de volta para a Terra. Esta insolação difusa

é responsável pela claridade do céu durante o dia e pela iluminação de áreas que não recebem iluminação direta do sol. As características do espalhamento dependem, em grande parte, do tamanho das moléculas de gás ou aerossóis, as quais interagem com o comprimento de onda da radiação espalhada.”

Fonte: <https://fisica.ufpr.br/grimm/aposmeteo/cap2/cap2-7.html>

Figura 2. Espectro eletromagnético com destaque para as bandas utilizadas em sensoriamento remoto



Fonte: Toth & Józkw (2016)

Por exemplo, o espalhamento por partículas cujo raio é bem menor que o comprimento de onda da radiação espalhada, como o que ocorre com o espectro da luz visível espalhado por moléculas de gás da atmosfera, é dependente do comprimento de onda.

“A luz azul tem comprimento de onda menor que a luz vermelha. Conseqüentemente, a luz azul é aproximadamente 5,5 vezes mais espalhada que a luz vermelha. Além disso ela é mais espalhada que o verde, amarelo e laranja. Assim, o céu, longe do disco do sol, parece azul.

... Quando o Sol se aproxima do horizonte (no nascer e pôr do Sol) a radiação solar percorre um caminho mais longo através das moléculas de ar e, portanto, mais e mais luz azul e com menor comprimento de onda é espalhada para fora do feixe de luz, e portanto a radiação solar contém mais luz do extremo vermelho do espectro visível. Isto explica a coloração avermelhada do céu ao nascer e pôr do Sol. Este fenômeno é especialmente visível em dias

nos quais pequenas partículas de poeira ou fumaça estiverem presentes.

Quando a radiação é espalhada por partículas cujos raios se aproximam ou excedem em até 8 vezes o comprimento de onda da radiação, o espalhamento não depende do comprimento de onda. A radiação é espalhada igualmente em todos os comprimentos de onda. Partículas que compõem as nuvens (pequenos cristais de gelo ou gotículas de água) e a maior parte dos aerossóis atmosféricos espalham a luz do Sol desta maneira. Por isso, as nuvens parecem brancas, e quando a atmosfera contém grande concentração de aerossóis o céu inteiro aparece esbranquiçado.

Quando o raio das partículas é maior que 8 vezes o comprimento de onda da radiação, a distribuição angular da radiação espalhada pode ser descrita pelos princípios da ótica geométrica. O espalhamento de luz visível por gotas de nuvens, gotas de chuva e partículas de gelo pertence a este regime e produz uma variedade de fenômenos óticos como arco íris, auréolas, etc..."

Fonte: <https://fisica.ufpr.br/grimm/aposmeteo/cap2/cap2-7.html>

Segundo Monteith (1972), o processo de fotossíntese em vegetais verdes requer a absorção da energia radiante na faixa entre 0,4 a 0,7 μm e, por isso, essa faixa do espectro é chamada radiação fotossinteticamente ativa (RFA ou PAR). Na superfície terrestre, a fração da radiação recebida dentro desse espectro depende da extensão na qual a radiação solar é modificada pelos fenômenos de absorção e espalhamento. Estima-se que a fração PAR com relação a radiação solar global que chega à superfície terrestre na forma de radiação direta corresponda a ~45%. Todavia, essa estimativa ignora a contribuição da radiação difusa que é espalhada por moléculas de gases da atmosfera, a qual contém maior proporção da PAR do que a radiação direta. Assim, combinando a contribuição apropriada das radiações direta e difusa, a fração PAR com relação a radiação solar global corresponde a ~50%.

Essas ondas são invisíveis a olho nu, mas desempenham um papel crucial em inúmeros processos naturais. Por isso, a compreensão e o monitoramento de todos esses processos é essencial para o desenvolvimento de ecossistemas sustentáveis, uma vez que os dados podem ser utilizados para uma ampla diversidade de aplicações, como na produção de energia fotovoltaica e sistemas solares térmicos, detecção de poluição atmosférica, previsões climáticas, no desenvolvimento de ações e tecnologias voltadas à saúde e alimentação humana e animal, entre diversas outras.

Na agricultura, a luz solar é fator ambiental chave para o crescimento vegetal, pois é fonte de energia essencial do processo fotossintético, sendo que as mudanças em intensidade e em composição espectral direcionam todos os processos de desenvolvimento, desde a germinação de sementes, expansão foliar, florescimento e frutificação (GURJAR et al., 2017). Todavia, as interações entre a radiação incidente e as comunidades vegetais são extremamente complexas, dada a diversidade em composição botânica, tamanhos, formas, arquitetura e arranjo de folhas e colmos, além de estrutura celular diferenciada em distintos órgãos e tecidos das plantas dentro de um ecossistema (OLLINGER, 2011).

2. Visão geral das assinaturas espectrais da vegetação

A assinatura espectral é uma representação gráfica ou numérica das características únicas de reflexão, absorção ou emissão de luz por parte de um objeto ou material em diferentes comprimentos de onda do espectro eletromagnético. Essa assinatura é derivada da interação entre a radiação eletromagnética incidente e as propriedades físicas e químicas do objeto ou material.

Cada objeto ou material possui uma assinatura espectral específica, que pode variar com base em fatores como composição química, estrutura cristalina, textura superficial e condições ambientais. A análise da assinatura espectral de um objeto ou material pode fornecer informações valiosas sobre suas propriedades intrínsecas, permitindo a identificação, classificação e caracterização de diferentes alvos na paisagem terrestre.

As assinaturas espectrais são frequentemente utilizadas em sensoriamento remoto e imageamento por satélite para detectar e mapear características da superfície terrestre, como tipos de cobertura vegetal, uso do solo, recursos hídricos, áreas urbanas, entre outros. Além disso, são fundamentais em diversas aplicações científicas, agrícolas, ambientais, geológicas e de monitoramento, contribuindo para o entendimento e a gestão dos ecossistemas terrestres (Kior et al., 2024).

E agora, surge a questão fundamental: o que cada comprimento de onda nos revela? Como a interação entre diferentes comprimentos de onda pode nos auxiliar a entender melhor os processos biológicos dentro da planta? Para responder essas perguntas, é crucial compreender o que cada comprimento de onda nos mostra e as informações que eles nos fornecem. Com esse conhecimento, podemos implementar práticas de manejo otimizadas para maximizar o potencial de cada cultura.

2.1. Comprimento de Onda na faixa do Vermelho (R)

O comprimento de onda correspondente a cor vermelha é especialmente útil para avaliar a produtividade e o crescimento das plantas porque está

fortemente associada à atividade fotossintética das plantas. A luz vermelha é uma das principais faixas de luz absorvidas pela clorofila, o principal pigmento fotossintético das plantas. Aqui estão alguns pontos-chave sobre como a banda vermelha é usada para avaliar a produtividade e o crescimento das plantas:

1. Absorção de Luz Vermelha:

- A clorofila nas plantas absorve luz principalmente nas faixas de luz vermelha e azul, usando-a para realizar a fotossíntese.
- A capacidade de absorver luz vermelha é um indicador direto da presença de clorofila e, portanto, da capacidade de uma planta realizar a fotossíntese.

2. Reflexão de Luz Vermelha:

- Em uma imagem de planta, as áreas que refletem pouca luz vermelha geralmente contêm maior quantidade de clorofila e, portanto, maior capacidade de fotossíntese.
- Menor reflexão de luz vermelha indica que a planta está absorvendo essa luz para realizar a fotossíntese.

3. Índice de Vegetação por Diferencial Normalizado (NDVI):

- O NDVI é um índice comum usado para avaliar a saúde e produtividade das plantas, baseado na diferença entre a banda vermelha (R) e a banda do infravermelho próximo (NIR).
- Um NDVI alto geralmente indica uma vegetação saudável, com alta atividade fotossintética.

4. Crescimento e Desenvolvimento:

- Plantas que absorvem mais luz vermelha e têm alta atividade fotossintética tendem a crescer mais rápido e a ser mais produtivas.
- Uma planta com alta absorção de luz vermelha é capaz de produzir mais energia (na forma de glicose) a partir da fotossíntese, o que contribui para seu crescimento e desenvolvimento.

5. Monitoramento de Estresse:

- A banda vermelha pode ser usada para detectar estresses nas plantas, como deficiência de nutrientes, falta de água ou presença de pragas ou doenças.
- Plantas em estresse tendem a refletir mais luz vermelha do que plantas saudáveis, pois podem ter uma diminuição na capacidade de fotossíntese.

Em resumo, a banda vermelha é interessante para avaliar a produtividade e o crescimento das plantas porque está diretamente ligada à atividade fotossintética (Kior et al., 2024). Analisando a absorção e a reflexão da luz vermelha, é possível obter informações sobre a saúde das plantas e sua capacidade de produção. Isso é útil para monitorar plantações, identificar problemas precocemente e otimizar práticas agrícolas para maximizar a produtividade.

2.2. Comprimento de Onda na faixa do Azul (B)

A banda azul é importante para avaliar aspectos específicos da fisiologia das plantas, embora não seja diretamente ligada à fotossíntese como a banda vermelha. No entanto, ela pode fornecer informações úteis sobre a saúde e o desenvolvimento das plantas, além de detectar estresse ou outras condições adversas. Abaixo estão algumas considerações sobre a interpretação da banda azul:

1. Absorção de Luz Azul:

- A luz azul é absorvida pela clorofila e outros pigmentos, embora em menor intensidade em comparação com a luz vermelha.
- Assim como a luz vermelha, a absorção de luz azul também está relacionada à fotossíntese, embora em menor grau.

2. Reflexão de Luz Azul:

- Plantas que refletem mais luz azul geralmente indicam áreas com menor clorofila ou áreas mais estressadas.
- Uma reflexão maior de luz azul pode indicar a presença de tecido mais velho ou com menor atividade fotossintética.

3. Detecção de Estresse e Condições Adversas:

- A banda azul pode ser usada para identificar estresse hídrico ou deficiências nutricionais nas plantas.
- Um aumento na reflexão de luz azul pode ser um sinal de problemas de saúde da planta, como diminuição da fotossíntese ou problemas na estrutura das folhas.

4. Avaliação de Estrutura:

- A banda azul pode ajudar a visualizar detalhes da estrutura das folhas ou de outras partes da planta.
- Pode evidenciar características de textura e forma, que podem ser úteis para distinguir diferentes tipos de plantas ou condições de crescimento.

5. Detecção de Problemas Fitossanitários:

- Alterações na banda azul podem ser um indicador de problemas fitossanitários, como infestações de pragas ou doenças.
- As diferenças na absorção ou reflexão de luz azul podem ser usadas para detectar áreas afetadas.

2.3. Comprimento de Onda na faixa do Verde (G)

A banda verde é especialmente significativa quando se trata de analisar a fisiologia das plantas, pois a clorofila, o principal pigmento fotossintético das plantas, reflete principalmente luz verde. Aqui estão algumas considerações sobre como interpretar a banda verde em imagens de plantas:

1. Reflexão de Luz Verde:

- A banda verde é geralmente a banda com maior reflexão nas plantas, devido à presença de clorofila, que reflete a luz verde.
- Uma maior reflexão de luz verde geralmente indica uma vegetação saudável com alta concentração de clorofila.

2. Avaliação da Saúde e Vitalidade das Plantas:

- A banda verde pode ser usada para avaliar a saúde e a vitalidade das plantas, uma vez que reflete diretamente os níveis de clorofila e a eficiência fotossintética.
- Plantas com altos níveis de clorofila terão uma maior reflexão na banda verde, indicando uma alta atividade fotossintética.

3. Crescimento e Desenvolvimento:

- Uma maior reflexão de luz verde está geralmente associada a um crescimento mais saudável e rápido das plantas.
- Plantas com níveis ótimos de clorofila têm maior capacidade de produção de energia para crescer e se desenvolver.

4. Monitoramento de Estresse:

- Mudanças na reflexão de luz verde podem indicar estresse nas plantas, como deficiência de nutrientes, estresse hídrico ou ataques de pragas.
- Uma diminuição na reflexão de luz verde pode ser um sinal de que a planta está sob estresse ou enfrentando problemas de saúde.

5. Detecção de Diversidade Vegetal:

- A análise da banda verde pode ser útil para distinguir entre diferentes tipos de vegetação ou identificar áreas com maior ou menor densidade de plantas.

6. Índice de Vegetação:

- Índices de vegetação, como o NDVI, costumam usar a banda verde (ou bandas relacionadas ao infravermelho próximo (NIR)) para avaliar a densidade da vegetação e a saúde das plantas.
- Uma alta reflexão de verde em relação a outras bandas pode indicar um bom estado de saúde da vegetação.

A banda verde é uma das mais importantes para a análise de plantas, pois está diretamente relacionada à saúde, vitalidade e capacidade fotossintética das plantas. Monitorar a banda verde pode fornecer informações sobre a eficiência da produção de energia das plantas, permitindo identificar áreas saudáveis ou estressadas. Isso ajuda a monitorar o crescimento e a produtividade das plantas, além de tomar medidas corretivas precoces para otimizar o manejo agrícola e o cuidado com as plantas.

3. Processamento de Imagens e a Programação Python para Análise de Cores em Plantas

No contexto da agricultura e da zootecnia de precisão, a análise de imagens tornou-se uma ferramenta valiosa para a detecção precoce de deficiências nutricionais e outros problemas de saúde em plantas. A utilização de técnicas de processamento de imagens, aliada à programação em Python, oferece uma abordagem eficaz e acessível para a extração de informações úteis a partir de imagens digitais.

As imagens capturadas por drones, câmeras especiais e até mesmo dispositivos móveis (nível terrestre) podem fornecer uma visão detalhada das características das plantas, incluindo sua cor e textura. Através da análise das bandas de cor vermelha, verde e azul (conhecidas como bandas RGB), é possível identificar padrões sutis que indicam deficiências em nutrientes essenciais, como Nitrogênio (N), Fósforo (P) e Potássio (K).

A programação em Python oferece uma ampla gama de bibliotecas e ferramentas que facilitam o processamento e análise de imagens. Bibliotecas como OpenCV, scikit-image e NumPy permitem a manipulação eficiente de imagens digitais, enquanto técnicas de processamento de sinais e aprendizado de máquina podem ser aplicadas para extrair informações úteis das imagens.

O exemplo a seguir, demonstra de maneira simples de como usar técnicas de processamento de imagens e programação em Python para analisar os comprimentos de ondas captados pela aquisição das imagens das plantas. A detecção de deficiências nutricionais em plantas, como Nitrogênio (N), Fósforo (P) e Potássio (K), pode ser realizada por meio da análise das bandas de cores nos comprimentos de onda do vermelho (R), verde (G) e azul (B).

O código permite ao usuário carregar uma imagem no formato JPEG, processá-la e exibir a imagem original, juntamente com suas bandas de cores R, G e B. Isso fornece uma visão detalhada das características de cor da planta, permitindo a detecção de padrões sutis associados a deficiências nutricionais.

Para executar o código, basta selecionar uma imagem no formato JPEG quando solicitado. A imagem carregada será exibida juntamente com suas bandas de cores separadas, facilitando a análise visual das características de cor da planta.

A Figura 3 mostra o código implementado para separar as bandas das cores do RGB. Este código em Python pode ser executado em uma variedade de ambientes de desenvolvimento e softwares de Python. Alguns dos principais softwares de Python nos quais o código pode ser executado incluem:

1. **Anaconda:** O Anaconda é uma distribuição de Python popular que inclui uma ampla gama de bibliotecas científicas e ferramentas de análise de dados. Ele fornece um ambiente de desenvolvimento integrado (IDE) chamado Anaconda Navigator, bem como a capacidade de executar código Python em um terminal ou Jupyter Notebook.
2. **Spyder:** O Spyder é um IDE de Python especializado em análise de dados e computação científica. Ele oferece recursos avançados de edição de código, depuração e visualização de dados, tornando-o uma escolha popular para projetos de processamento de imagens e análise de cores em plantas.
3. **Jupyter Notebook:** O Jupyter Notebook é uma aplicação da web que permite criar e compartilhar documentos interativos que contêm código, visualizações e texto explicativo. Ele é amplamente utilizado em ciência de dados e análise de dados, e é uma ótima escolha para projetos que envolvem exploração de dados e análise de imagens.

Figura 3. Código em Python para extração das bandas RGB.

```
1 import cv2
2 from tkinter import Tk, filedialog
3 import matplotlib.pyplot as plt
4
5 # Função para carregar e exibir as imagens
6 def carregar_e_exibir_imagens():
7     # Configurar a janela de seleção de arquivo
8     root = Tk()
9     root.withdraw() # Ocultar a janela principal
10
11     # Solicitar ao usuário selecionar o arquivo de imagem JPEG
12     arquivo_imagem = filedialog.askopenfilename(title="Selecione a imagem JPEG",
13         filetypes=[("Imagens JPEG", "*.jpg;*.jpeg")])
14
15     if not arquivo_imagem:
16         print("Nenhuma imagem selecionada.")
17         return
18
19     try:
20         # Carregar a imagem
21         imagem = cv2.imread(arquivo_imagem)
22
23         # Converter de BGR para RGB (OpenCV lê imagens em formato BGR)
24         imagem_rgb = cv2.cvtColor(imagem, cv2.COLOR_BGR2RGB)
25
26         # Separar as bandas de cores R, G e B
27         canal_r, canal_g, canal_b = cv2.split(imagem_rgb)
28
29         # Exibir as imagens original e as bandas R, G e B
30         fig, axs = plt.subplots(2, 2, figsize=(10, 10))
31
32         axs[0, 0].imshow(imagem_rgb)
33         axs[0, 0].set_title('Imagem Original')
34         axs[0, 0].axis('off')
35
36         axs[0, 1].imshow(canal_r, cmap='Reds')
37         axs[0, 1].set_title('Banda R (Vermelho)')
38         axs[0, 1].axis('off')
39
40         axs[1, 0].imshow(canal_g, cmap='Greens')
41         axs[1, 0].set_title('Banda G (Verde)')
42         axs[1, 0].axis('off')
43
44         axs[1, 1].imshow(canal_b, cmap='Blues')
45         axs[1, 1].set_title('Banda B (Azul)')
46         axs[1, 1].axis('off')
47
48         plt.show()
49
50     except FileNotFoundError:
51         print("Arquivo não encontrado. Certifique-se de fornecer um caminho válido.")
52
53 # Chamar a função para carregar e exibir as imagens
54 carregar_e_exibir_imagens()
55
```

Fonte: Própria Autoria.

4. **Visual Studio Code (VSCode):** O Visual Studio Code é um editor de código leve e altamente personalizável que oferece suporte a uma ampla variedade de linguagens de programação, incluindo Python. Ele possui uma ampla gama de extensões disponíveis, o que o torna uma escolha versátil para desenvolvedores Python.
5. **Google Colab:** O Google Colab é uma plataforma de notebook baseada em nuvem que permite executar código Python em um ambiente de notebook interativo. Ele oferece acesso gratuito a GPUs e TPUs para acelerar a execução de código, o que pode ser útil para projetos que envolvem processamento intensivo de imagens.

Esses são apenas alguns dos principais softwares de Python nos quais o código pode ser executado. A escolha do software dependerá das preferências pessoais do usuário e dos requisitos específicos do projeto.

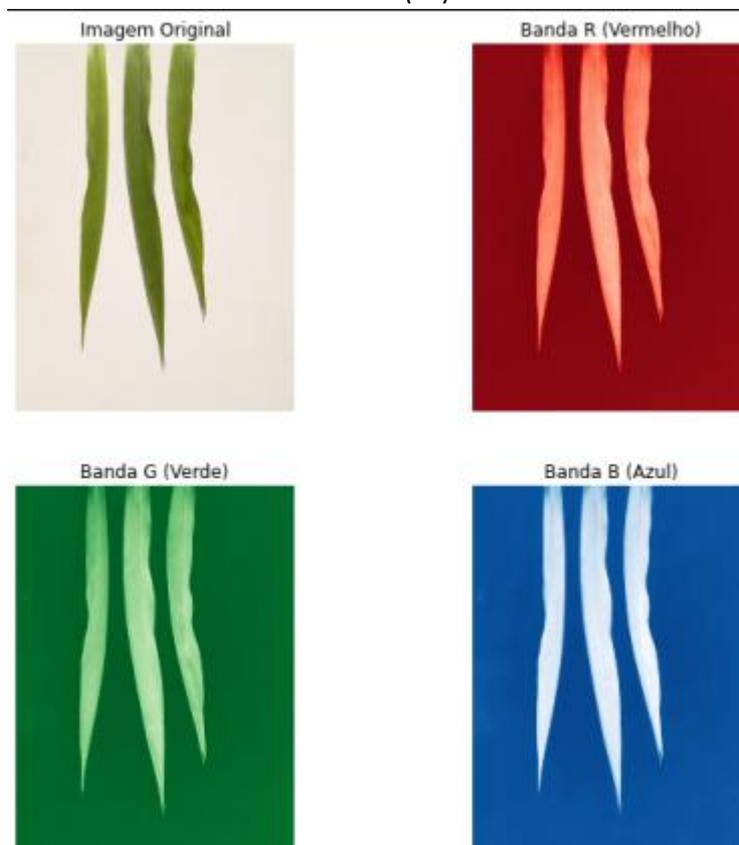
Após a execução do código, o sistema fornece as seguintes imagens, conforme Figura 4. A Figura 4 permite visualizar a imagem no formato original, bem como as bandas correspondentes ao vermelho, verde e azul. No próximo exemplo, iremos exibir o histograma das bandas de cores vermelho (R), verde (G) e azul (B) em uma única imagem. O histograma de uma imagem representa a distribuição da intensidade dos pixels em cada uma das bandas de cores. Ao exibir o histograma das três bandas em uma única imagem, podemos obter uma visão abrangente da distribuição de cores na imagem e entender melhor sua composição e características.

O histograma das bandas R, G e B permite interpretar vários aspectos da imagem:

1. **Distribuição de Cores:** O histograma mostra a distribuição das cores vermelho, verde e azul na imagem. Isso nos permite identificar quais cores são predominantes e em que intensidade estão presentes.
2. **Equilíbrio de Cores:** O histograma pode revelar se a imagem possui um equilíbrio de cores adequado ou se há um desequilíbrio em uma ou mais bandas de cores. Por exemplo, um histograma deslocado para a esquerda indica uma predominância de tons mais escuros, enquanto um histograma deslocado para a direita indica uma predominância de tons mais claros.
3. **Contraste:** A forma e a distribuição do histograma podem fornecer informações sobre o contraste da imagem. Um histograma com uma ampla distribuição de valores de intensidade indica um alto contraste, enquanto um histograma com uma distribuição mais estreita indica um baixo contraste.
4. **Correção de Exposição:** Com base no histograma, é possível ajustar a exposição da imagem para corrigir problemas de superexposição ou

subexposição. Isso pode ser feito alterando os valores de brilho e contraste ou aplicando técnicas de equalização de histograma.

Figura 4. Imagens original e nas bandas do vermelho (R), verde (V) e azul (G).



Fonte: Própria Autoria.

Ao exibir o histograma das bandas R, G e B em uma única imagem, podemos realizar uma análise visual ou de varredura eficaz da distribuição de cores na imagem e tomar decisões informadas sobre o processamento e a manipulação da imagem (FIGURA 5).

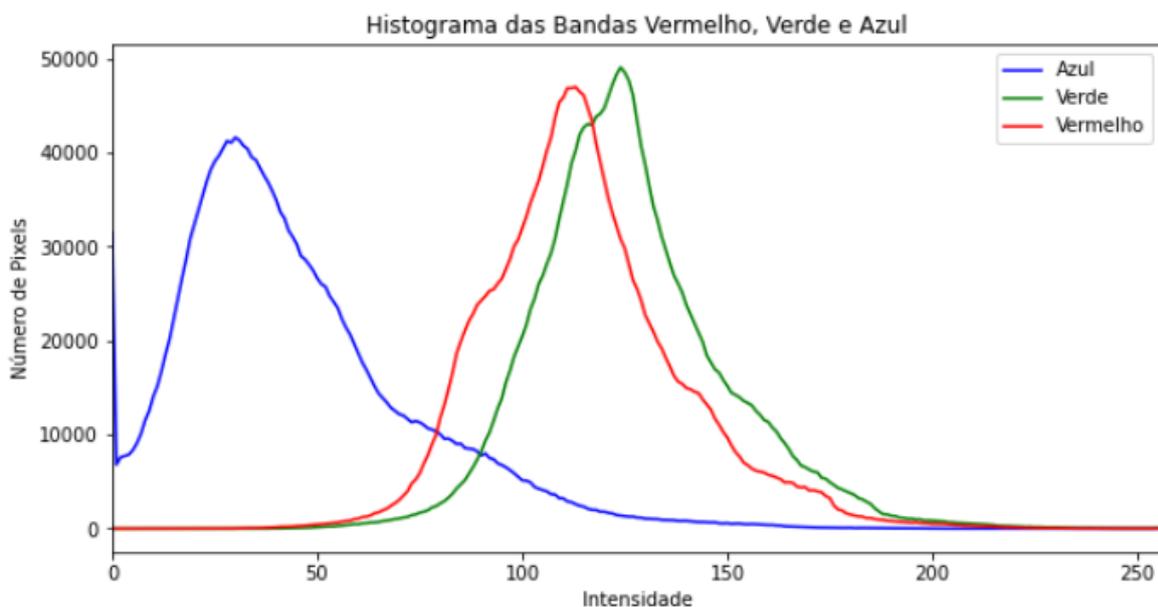
Após a execução do código, o sistema fornece a imagem de um histograma com 3 linhas, uma para a banda vermelha, outra para a banca verde e, finalmente, para a banda azul (FIGURA 6). Neste tópico, procuramos apresentar dois exemplos simples de aplicações de processamento de imagens para a extração de dados provenientes de três folhas de plantas da espécie Mavuno. Demonstramos como carregar uma imagem, exibir as bandas de cores vermelho, verde e azul, bem como visualizar o histograma dessas bandas.

Figura 5. Código para exibição do histograma das bandas R, G e B.

```
1 import cv2
2 import matplotlib.pyplot as plt
3 from tkinter import Tk, filedialog
4
5 # Função para carregar a imagem
6 def carregar_imagem():
7     root = Tk()
8     root.withdraw()
9     arquivo_imagem = filedialog.askopenfilename(title="Selecione a imagem",
10         filetypes=[("Arquivos de Imagem", "*.jpg;*.jpeg;*.png")])
11     if not arquivo_imagem:
12         print("Nenhum arquivo selecionado.")
13         return None
14     imagem = cv2.imread(arquivo_imagem)
15     return imagem
16
17 # Função para exibir o histograma das bandas R, G e B
18 def exibir_histograma(imagem):
19     hist_r = cv2.calcHist([imagem], [0], None, [256], [0, 256])
20     hist_g = cv2.calcHist([imagem], [1], None, [256], [0, 256])
21     hist_b = cv2.calcHist([imagem], [2], None, [256], [0, 256])
22     plt.figure(figsize=(10, 5))
23     plt.title("Histograma das Bandas R, G e B")
24     plt.plot(hist_r, color='red', label='R')
25     plt.plot(hist_g, color='green', label='G')
26     plt.plot(hist_b, color='blue', label='B')
27     plt.xlabel("Intensidade")
28     plt.ylabel("Frequência")
29     plt.legend()
30     plt.show()
31
32 # Função principal
33 def main():
34     imagem = carregar_imagem()
35     if imagem is not None:
36         exibir_histograma(imagem)
37
38 if __name__ == "__main__":
39     main()
```

Fonte: Própria Autoria.

Figura 6. Imagem do histograma com as representações das bandas do vermelho (R), verde (V) e azul (G).



Fonte: Própria Autoria.

Essas técnicas básicas de processamento de imagem têm uma variedade de aplicações na análise de plantas, incluindo a identificação de deficiências de nutrientes. Ao analisar as características das folhas das plantas, podemos obter insights valiosos sobre sua saúde e condição geral. É importante ressaltar que os exemplos apresentados aqui são apenas o ponto de partida para análises mais avançadas e detalhadas. O processamento de imagem oferece uma ampla gama de técnicas e ferramentas que podem ser exploradas para obter uma compreensão mais profunda das plantas e de seu ambiente.

Referências Bibliográficas

GURJAR, G.N. et al. Effect of solar radiation in crop production. p.103-115. In.: **Natural resource management for climate smart sustainable agriculture**. Arora, S.; Swami, S.; Bhan, S. (Eds.). Soil Conservation Society of India: New Deli, 2017.

JÚNIOR, H.M. **A formação das cores**: Parte 1. Blog do Gráfico. Disponível em: <<https://blogdografico.files.wordpress.com/2012/04/espectro.png>>.

KIOR, A. et al. RGB imaging as a tool for remote sensing of characteristics of terrestrial plants: A review. **Plants**, v. 13, n. 9, p. 1262, 2024.

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

MORAES, E.C. **Fundamentos do sensoriamento remoto**. Instituto Nacional de Pesquisas Espaciais, INPE, 2002. Disponível em: <http://mtc-m12.sid.inpe.br/col/sid.inpe.br/sergio/2005/06.14.12.18/doc/CAP1_ECMoraes.pdf>.

OLLINGER, S.V. Sources of variability in canopy reflectance and the convergent properties of plants. **New Phytologist**, v.189, n.2, p.375-394, 2011.

Radiação solar incidente. Disponível em: <<https://fisica.ufpr.br/grimm/aposmeteo/cap2/cap2-7.html>>.

TOTH, C.; JÓZKÓW, G. Remote sensing platforms and sensors: A survey. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 115, p. 22-36, 2016.

CAPÍTULO 2

Propriedades ópticas das folhas

João Paulo Rodrigues Marques; Adriano Rogério Bruno Tech; Lilian Elgalise Techio Pereira

O uso do sensoriamento remoto no monitoramento de pastagens tem permitido melhorias substanciais no manejo dos ecossistemas. Embora a maior parte dos trabalhos já desenvolvidos tem como foco estimativas de biomassa (REINERMANN et al., 2020), aplicações também têm sido desenvolvidas para fins de identificação precoce de deficiências nutricionais ou estresses decorrentes de variações climáticas e, em menor proporção, para identificação de pragas, espécies invasoras e doenças. O progresso já desenvolvido busca direcionar ações pontuais de manejo e identificar períodos críticos para aplicação de fertilizantes ou outras práticas agronômicas. Embora a maior parte dos trabalhos e protocolos já desenvolvidos tem por foco culturas produtoras de grãos, o conhecimento já disponível pode e deve servir como base para a ampliação das pesquisas e desenvolvimento de soluções aplicadas aos cultivos destinados ao pastejo direto ou àqueles voltados à produção de volumosos conservados, tais como silagem e feno.

A base das aplicações do sensoriamento remoto reside no fato de que a radiação solar capturada e utilizada pela vegetação dirige todo o processo fotossintético. Quando a radiação eletromagnética incide sobre a vegetação, a superfície foliar e os pigmentos fotossintéticos atuam na absorção de comprimentos de onda específicos, enquanto refletem ou transmitem outros. Uma vez que a estrutura e composição química dos tecidos foliares, assim como cada grupo de pigmentos absorve e reflete diferentes comprimentos de onda, as características de refletância espectral podem ser utilizadas para avaliar, de maneira indireta, diversos atributos da vegetação. Dessa forma, a caracterização das propriedades ópticas das folhas e suas assinaturas espectrais fornecem as informações necessárias para a definição de protocolos de manejo e adubação mais eficientes, economicamente viáveis e com mínimo impacto ambiental (SERBIN; TOWSEND, 2020).

Dentre as características estruturais dos vegetais associados às propriedades ópticas das folhas destacam-se a composição e espessura de cutícula, formato das células epidérmicas, presença ou não de tricomas não glandulares e glandulares, presença de epiderme ou hipoderme multisseriada, idioblastos cristalíferos, extensão da bainha do feixe vascular, presença de fibras e esclereídes (KARABOURNIOTIS et al., 2021). Tendo em vista a lista de caracteres estruturais que são direta ou indiretamente associados à refletância ou absorção da luz pelas folhas, promovemos a seguinte reflexão: será que todas as folhas tem a mesma eficiência

na absorção ou reflexão da luz? A resposta certamente é não. As espécies vegetais possuem variações na morfologia externa e interna das folhas, interferindo em suas propriedades ópticas e, portanto, no modo como este órgão “responde” à composição da luz que atinge a superfície foliar (BRODERSE; VOGELMANN, 2007.)

Na superfície adaxial da folha, aquela parte superior da folha que está exposta diretamente à radiação, a **epiderme** é tecido que reveste a lâmina foliar, sendo caracterizada por camadas de células epidérmicas simples e compactas (FIGURA 1) que podem conter pectinas e celulose, sendo sua composição variável com a espécie vegetal e idade do órgão.

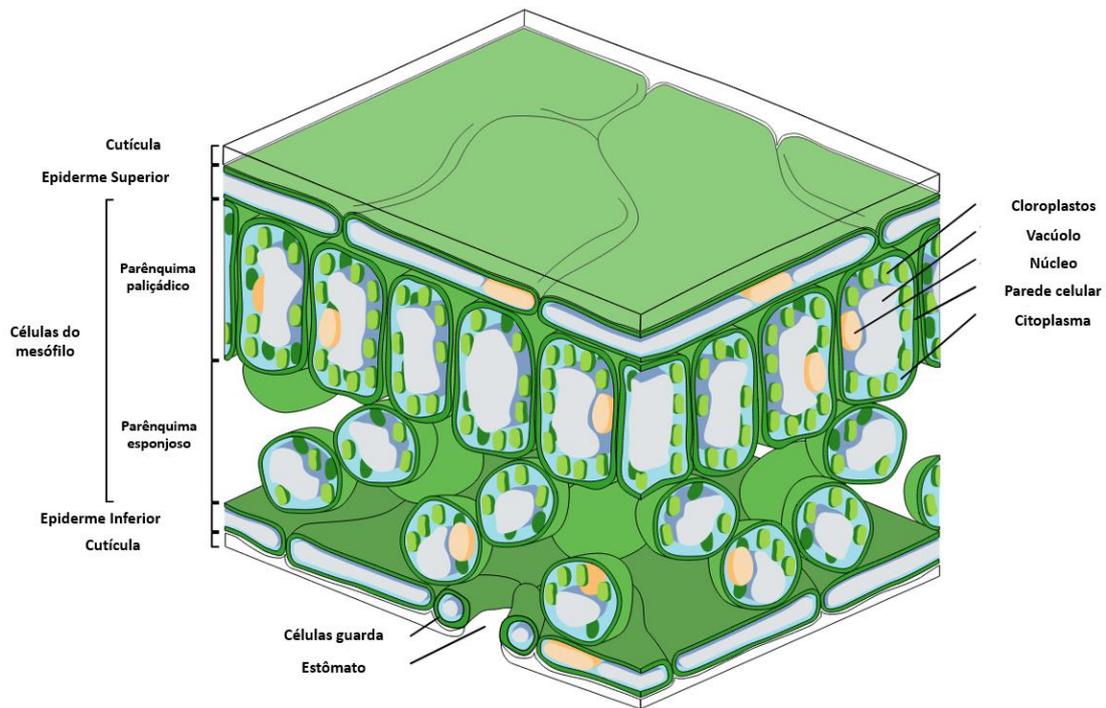
Na parede celular das células epidérmicas ocorre a presença de cutina, que pode estar impregnada à parede dessas células ou formar uma camada em cima da epiderme, denominada cutícula que pode apresentar variações em sua forma e composição, podendo ou não apresentar ceras epicuticulares (FIGURA 2A-B). Por apresentar característica lipofílica ela evita a perda de água e criando uma barreira física de proteção contra insetos e ação dos fungos e bactérias. A presença de cera também pode ocorrer, sendo esta depositada sobre a cutícula ou dentro da matriz da cutina, o que promove a variação de padrões topográficos e morfológicos (SANTOS et al., 2019).

A epiderme é constituída por uma ou mais camadas de células recobertas externamente por uma cutícula de composição majoritariamente lipofílica (cutina e ácidos graxos de cadeia longa) que são impregnados à matriz celulósica (FIGURA 2C). A cutícula é a primeira estrutura da folha que interage com a radiação solar, e desempenha um importante papel fotoprotetor devido sua habilidade de moderar os comprimentos de onda que penetram internamente os tecidos foliares, principalmente a radiação UV (SOLOVCHENKO; MERZLYAK, 2003). Segundo Ustin e Jacquemoud (2020), a refletância da superfície da folha pode ser caracterizada por dois processos, que dependem da relação entre o comprimento de onda e do raio das partículas da superfície que interceptam a radiação, conforme descrito no capítulo anterior (páginas 8 e 9): a **refletância especular** (que é refletida diretamente para fora da superfície em uma única direção) e a **refletância difusa**, que espalha a radiação em todas as direções a partir da superfície foliar.

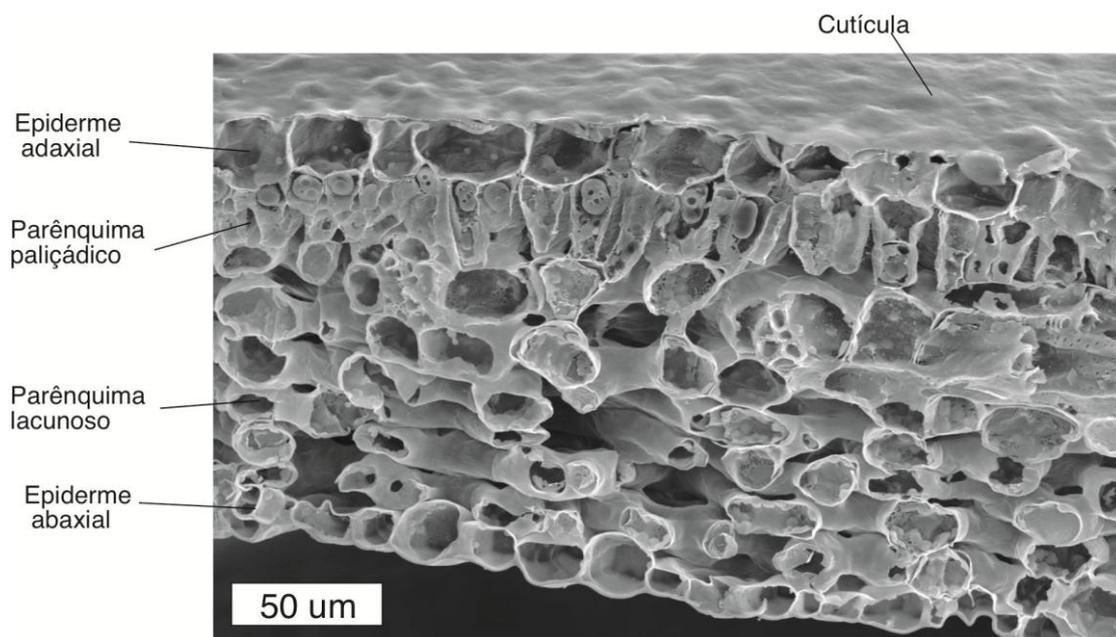
A refletância especular é determinada pela estrutura e composição química da cutícula. A cutícula reduz a penetração da radiação UV pela reflexão ou pela absorção desses comprimentos de onda pelos flavonóides e compostos fenólicos (FIGURA 2D). De forma geral, o espectro de absorção da cutícula em folhas e frutos é caracterizado pela elevada transmitância dos comprimentos de onda na faixa do visível, diminuindo a absorção da luz para os menores comprimentos de onda, sendo extremamente baixos na faixa próxima de 300 nm (SOLOVCHENKO; MERZLYAK, 2003). Ainda na camada epidérmica, células especializadas formam o **complexo estomático**, cuja função é promover as trocas gasosas entre a folha e o meio externo,

e **tricomas** (ou pêlos), que são considerados apêndices epidérmicos que podem ter função secretora e/ou protetora. Essas estruturas (estômatos e tricomas), dependendo da espécie vegetal, podem ocorrer em ambas as faces da folha ou em apenas uma delas.

Figura 1. Estrutura típica da folha de dicotiledôneas, demonstrando mesófilo assimétrico (Acima). Folha de café (*Coffea* sp.) após criofratura e analisada ao microscópio eletrônico de varredura (abaixo).

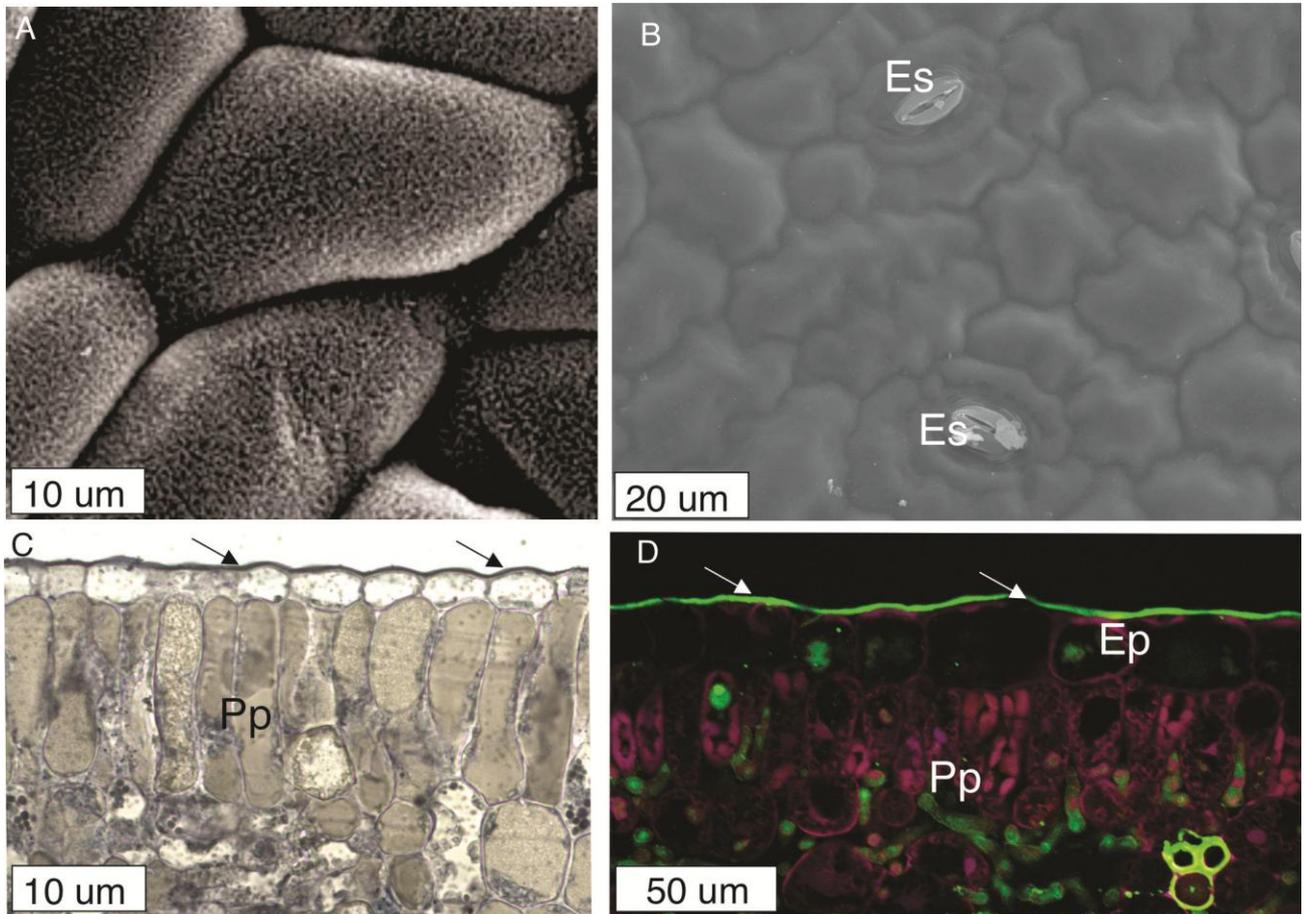


Fonte: Adaptado de https://commons.wikimedia.org/wiki/File:Leaf_Tissue_Structure.svg



Fonte: Própria Autoria.

Figura 2. Detalhe da cutícula (A-B). Eletromicrografias de varredura. C. Microscopia de luz transmitida. D. Microscopia de fluorescência. A. Cutícula de folha de soja (*Glycine max*) com ceras epicuticulares. B. Folha de café sem ceras epicuticulares. C. Teste histoquímico em folha de uva seccionada com Sudan black B para detectar substâncias lipofílicas na cutícula (setas). D. Secção transversal da folha de café excitada com comprimento de onda de 488 nm e emitindo luz verde (setas).



Fonte: Própria Autoria.

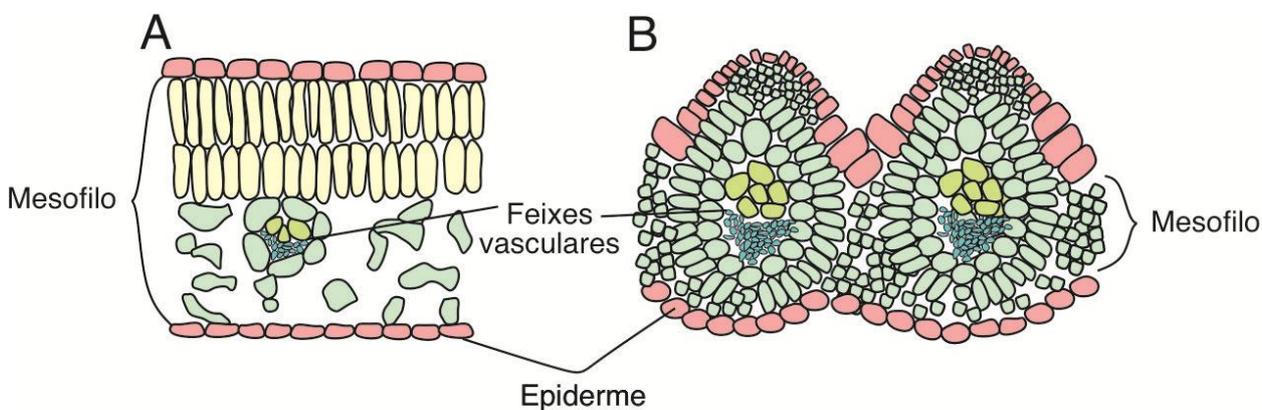
Sims e Gamon (2002) descrevem que a espessura da cutícula, a presença de cerosidade e de pêlos na superfície foliar influenciam significativamente os padrões de refletância. Essas características afetam a quantidade de radiação refletida diretamente da camada externa da folha e, portanto, que não interage com o interior da folha, de forma que menor quantidade de radiação solar penetra efetivamente os tecidos foliares (SERBIN; TOWNSEND, 2020). A presença de pêlos aumenta a refletância na faixa do visível, mas seus efeitos sobre o infravermelho próximo (NIR) são variáveis. A cerosidade da superfície foliar aumenta a refletância em todo o espectro visível e do NIR, embora o efeito seja frequentemente maior em comprimentos de onda mais curtos (SIMS; GAMON, 2002).

O **mesofilo** é o tecido fundamental localizado entre a epiderme superior e inferior, sendo o tecido especializado para o processo fotossintético. Este tecido é

composto principalmente por parênquima clorofiliano, porém, pode haver colênquima e esclerênquima, além da presença de cloroplastos e espaços intercelulares. Nas folhas de dicotiledôneas, o mesófilo se distingue em dois tipos de parênquima clorofiliano (FIGURA 1), o **parênquima paliçádico** e o **parênquima lacunoso ou esponjoso**. No parênquima paliçádico diferenciam-se células alongadas, ricas em cloroplastos, sendo este tecido o principal responsável pela realização da fotossíntese nas plantas vasculares, uma vez que a forma e o arranjo mais compacto das células propiciam condições favoráveis de exposição dos cloroplastos à luz. O parênquima esponjoso possui células dispostas frouxamente e com grandes espaços de ar entre células.

Devido a existência de um mesófilo composto por uma camada superior de células de parênquima paliçádico e um parênquima esponjoso abaixo deste, e mais próximo à epiderme inferior, o mesófilo das folhas de dicotiledôneas é chamado assimétrico ou dorsiventral. Nas monocotiledôneas aparecem outras estruturas de mesófilo, o qual pode ser simétrico, ou também chamado de homogêneo ou unifacial, uma vez que não há distinção entre o parênquima paliçádico e esponjoso (FIGURA 3), apresentando parênquima clorofiliano uniforme, constituído de um único tipo celular (RODRIGUES et al., 2015).

Figura 3. Secção transversal de folhas de dicotiledôneas (A) e monocotiledônea (B). A. Mesófilo dorsiventral com parênquima paliçádico (amarelo) e lacunoso ou esponjoso (verde). B. Presença de mesófilo homogêneo.



Fonte: Própria Autoria.

Além disso, em monocotiledôneas gramíneas também pode ser verificada a distribuição do parênquima do mesófilo de forma radiada, configurando estes tipos a chamada anatomia "Kranz". Anatomia Kranz significa "em forma de coroa", e recebe esse nome devido a estrutura radiada formada pela bainha e pelas células do mesófilo ao redor dos feixes vasculares. Segundo Rodrigues et al. (2015), a anatomia Kranz é normalmente associada a plantas que fazem fotossíntese C4. Todavia, há plantas que fazem fotossíntese C3 e possuem anatomia Kranz e, da mesma forma, há plantas com metabolismo C4 sem anatomia Kranz.

Segundo Croft e Chen (2017), espécies que possuem maior proporção de parênquima paliçádico comparativamente ao esponjoso direcionam maior quantidade da luz que penetra a folha para os pigmentos fotossintéticos, uma vez que as células do parênquima paliçádico agem como 'condutores' da radiação. A estrutura e composição química do mesofilo das folhas também afeta os padrões de refletância e, portanto, diferem amplamente entre espécies e grupos funcionais. Segundo Slaton et al. (2001), a refletância da folha na faixa do NIR (750 a 1350 nm) é afetada primariamente pela estrutura da folha (interna e externa) e a refletância na região do visível (400 a 700 nm) é determinada principalmente pelos pigmentos fotossintéticos, enquanto a água é a segunda molécula de mais intensa absorção da luz nas folhas.

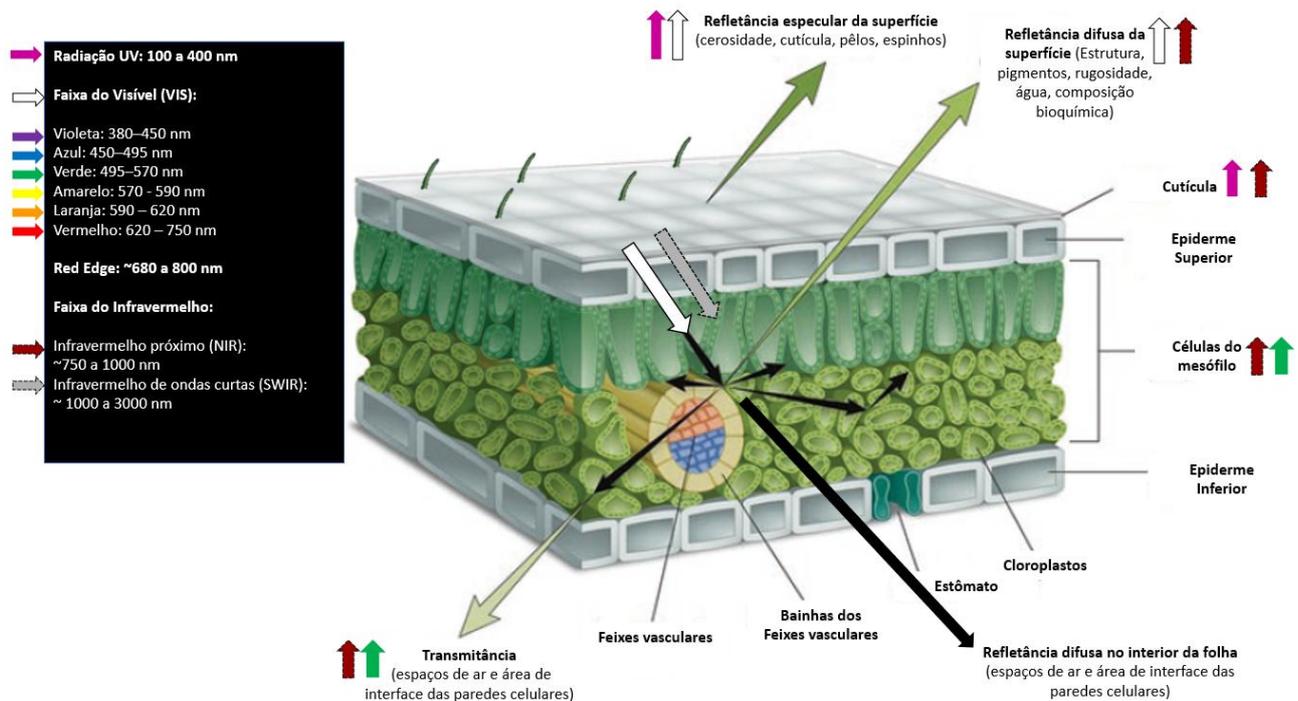
Strabeli et al. (2020) destacam que a refletância de 760 a 1300 nm é elevada, e consiste em um mecanismo para impedir o aumento da temperatura interna da folha e evitar degradação de proteínas e açúcares, sendo um processo controlado pela morfologia e estrutura interna das folhas. A refletância nessa faixa espectral é influenciada pela espessura e composição das paredes celulares e das células do mesofilo. Segundo os autores, quanto mais lacunas entre células paliçádicas e mesofilo esponjoso maior é o espalhamento interno da radiação incidente. A espessura da camada de mesofilo associada a outras propriedades, como tamanho das células dos parênquimas paliçádico e lacunoso, espessura de parede celular e teor de água na folha, podem causar maior grau de dispersão interna da luz (FIGURA 4), menor transmissão através da folha e maior absorção em alguns comprimentos de onda na faixa do visível. É importante ressaltar que a radiação difusa, resultante dos comprimentos de onda que são transmitidos através e para fora da folha, que é aquela modificada pelas propriedades internas da folha, também contém características úteis para mapear características funcionais (SIMS; GAMON, 2002; HALLIK et al., 2017).

A água absorve com maior intensidade os comprimentos de onda na faixa do infravermelho de ondas curtas (SWIR, 1000 a 3000 nm, também descrito como *middle-infrared*) com vários picos menores de absorção na faixa do NIR. Croft e Chen (2017) relatam que na região SWIR, as bandas de absorção da água se situam em ~ 1450 nm e 1950 nm, com picos menos intensos verificados em ~980 nm e 1150 nm. Como muitas outras propriedades da vegetação são co-reguladas pelo status de água da planta, os efeitos da seca ou da reduzida concentração de água nos tecidos pode se manifestar na região do visível ou do NIR.

Segundo Ustin e Jacquemoud (2020), em folhas com status hídrico adequado, uma vez que não existem moléculas que absorvem fortemente os comprimentos de onda na faixa do NIR, as folhas refletem ou transmitem a maior parte dessa radiação (FIGURA 4). Ainda, uma pequena característica de absorção é verificada em ~1800 nm, a qual é atribuída a celulose e outros compostos estruturais. Todavia, em situações de estresse hídrico, a degradação de pigmentos

afeta a refletância na região do espectro visível, e as mudanças nas propriedades de refração das células do mesófilo afetam a intensidade de espalhamento interno da radiação na faixa do NIR (CROFT; CHEN, 2017).

Figura 4. Desenho esquemático demonstrando os padrões de refletância da folha em diferentes comprimentos de onda. Setas coloridas ao lado de cada estrutura indicam a refletância preferencial de um dado comprimento de onda.



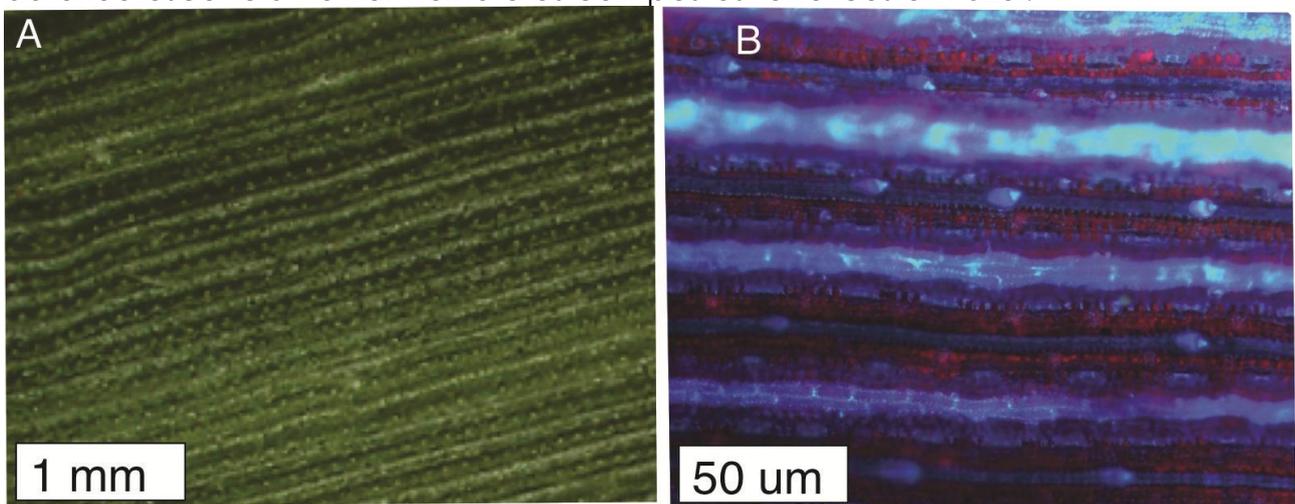
Fonte: Adaptado de Serbin & Townsend (2020).

Na folha, os cloroplastos são ricos em pigmentos fotossintéticos, que são os principais responsáveis pelas etapas de absorção da luz e transferência de elétrons da fotossíntese (MU; CHEN, 2021). Todavia, os padrões de refletância na faixa do visível e no espectro do NIR são regulados pelas propriedades ópticas decorrentes da estrutura das folhas (externa e interna) e pela concentração e distribuição de pigmentos fotossintéticos (HALLIK et al., 2017). Com relação aos pigmentos fotossintéticos, a absorção da radiação solar nas folhas é realizada principalmente pelas clorofilas *a* e *b*, que são um grupo de pigmentos naturais considerados componentes bioquímicos chave no aparato molecular responsável pela fotossíntese. A clorofila '*a*' é a forma mais abundante no grupo das clorofilas em organismos fotossintéticos, embora as clorofilas '*b*', '*c*' e '*d*', os carotenóides e as ficobilinas também estejam envolvidos na fotossíntese. Todavia, as clorofilas '*c*', '*d*' e as ficobilinas são encontradas especialmente em algas e cianobactérias. As clorofilas '*a*' e '*b*' são os principais pigmentos envolvidos na fotossíntese em vegetais, e estão distribuídas na forma de complexos pigmento-proteínas (MU; CHEN, 2021). As clorofilas expressam picos de absorção nas faixas do vermelho para a clorofila *a*,

com máxima absorvância em ~660-680 nm, e azul para a clorofila *b*, em ~450 nm (SIMS; GAMON, 2002; HUETE, 2004).

Um tipo de análise usada em estudos anatômicos e histoquímicos é tirar vantagem das propriedades de emissão de autofluorescência dos componentes orgânicos presentes nas folhas quando excitados com comprimentos de onda adequado (MARQUES; SOARES, 2021). Quando folhas são excitadas com luz UV, por exemplo, uma ampla gama de comprimentos de onda são emitidas. Uma folha clorofilada de braquiária (*Urochloa* spp.) após ser excitada com luz UV emite luz vermelha e azul, indicando presença de clorofila e fenóis, respectivamente (FIGURA 5).

Figura 5. Análise da superfície de uma folha de braquiária (*Urochloa* spp.) clorofilada. A. Visão geral da superfície abaxial. B. Análise da folha excitada com luz UV (390 nm) e observada ao microscópio de epifluorescência. A clorofila emite autofluorescência no vermelho e os compostos fenólicos em azul.



Fonte: Própria Autoria.

Os principais pigmentos do grupo dos carotenóides em folhas verdes das plantas terrestres são o alfa e beta-caroteno, luteína, zeaxantina, violaxantina, anteraxantina e neoxantina (HALLIK et al., 2017). Os carotenóides são capazes de absorver os comprimentos de onda que não são diretamente utilizados pelas clorofilas. Esses pigmentos atuam na fotossíntese através da transferência da energia de excitação dos elétrons para as clorofilas, ampliando o espectro da radiação útil ao processo fotossintético e, por isso, atuam como pigmentos acessórios. Os carotenóides absorvem a radiação na faixa do verde-azul (~400 a 500 nm), e transferem a energia de excitação dos elétrons para as clorofilas. Ao mesmo tempo, quando a energia da radiação incidente excede o requerido para a fotossíntese, os carotenóides dissipam o excesso de energia absorvida, evitando danos ao aparato fotossintético (SIMS; GAMON, 2002). Em algumas espécies vegetais, as antocianinas também atuam protegendo as folhas do excesso de energia, incluído aquela proveniente da radiação UV, e seus picos de absorção ocorrem na faixa de

~530-550 nm, refletindo fortemente os comprimentos de onda na faixa do vermelho (CROFT; CHEN, 2017).

As funções dos diferentes carotenóides está amplamente relacionada com sua exata localização no aparato fotossintético (HALLIK et al., 2017). Como já destacado anteriormente, no interior dos cloroplastos das plantas, os pigmentos estão organizados em complexos pigmentos-proteínas (MU; CHEN, 2021). Segundo Hallik et al. (2017), as proteínas coordenam a orientação e a distância entre pigmentos e, portanto, desempenham um papel crucial no espectro de absorção e refletância das clorofilas e carotenóides. Mesmo pequenas mudanças em um único aminoácido nas proteínas de ligação ao pigmento possuem notáveis efeitos nas propriedades espectrais dos complexos pigmentos-proteínas. Croft e Chen (2017) relatam que a absorção dos comprimentos de onda na faixa azul promovida pelos carotenóides se sobrepõe ao espectro de absorção das clorofilas, de forma que esta faixa do espectro não é considerada útil para estimativas da concentração de clorofilas.

No senso comum, o qual foi questionado por Virtanen et al. (2020), a percepção de um maior grau de 'esverdeamento' das folhas tem sido atribuída à refletância do verde pelas clorofilas. Todavia, Terashima et al. (2009) e Moriwaki et al. (2019) demonstram que a luz verde pode ser absorvida tão ou até mais eficientemente quanto a luz azul e vermelha. Isso ocorre através de um fino ajuste interno da folha, o qual cria um gradiente no espectro de absorção da luz visível que permite o uso eficiente da luz verde tanto pelas clorofilas, particularmente naquelas alocadas nos parênquimas mais internos da folha, quanto por carotenóides e outros pigmentos. Virtanen et al. (2020) concluem que a luz verde está mais sujeita ao espalhamento interno na folha, sendo difusamente refletida a partir das paredes celulares. Moriwaki et al. (2019) descrevem que, durante a aclimação de plantas de *Solanum lycopersicum* 'Santa Clara' (tomate) ao sombreamento e recebendo doses crescentes de N, é possível verificar células do parênquima paliçádico mais alongadas e aumento na concentração de clorofila, o que promove maior absorção da luz verde.

Croft e Chen (2017) destacam que diferentes combinações entre características da estrutura externa e interna da folha, composição química dos tecidos e proporção entre os distintos pigmentos podem produzir resposta espectral similar. Portanto, embora certas propriedades espectrais isoladas das diferentes estruturas e pigmentos seja relativamente bem conhecidas, quando se analisam os padrões de refletância *in vivo* das folhas, todas essas estruturas interagem, tornando a interpretação da refletância espectral sob uma dada condição de manejo, em um ambiente heterogêneo típico das pastagens, uma tarefa extremamente complexa.

Referências Bibliográficas

- BRODERSEN, C.R.; VOGELMANN, T.C. Do epidermal lens cells facilitate the absorptance of diffuse light? **American Journal of Botany**, v.94, n.7, p.1061–1066. 2007.
- CROFT, H.; CHEN, J.M. Leaf pigment content. p. 117-142. In.: **Reference module in earth systems and environmental sciences: Comprehensive remote sensing**. Liang, S. (Ed.). Elsevier: Oxford. 2018.
- HALLIK, L. et al. Generality of relationships between leaf pigment contents and spectral vegetation indices in Mallorca (Spain). **Regional Environmental Change**, v. 17, n. 7, p. 2097-2109, 2017.
- HUETE, A.R. Remote sensing for environmental monitoring. p. 183-206. In.: **Environmental monitoring and characterization**. Artiola; J.F.; Pepper, I.L.; Brusseau, M.L. (Eds.). Elsevier: Oxford. 2004.
- KARABOURNIOTIS, G. et al. The optical properties of leaf structural elements and their contribution to photosynthetic performance and photoprotection. **Plants**, v.10, n.7, p.1455, 2021.
- MARQUES, J.P.R.; SOARES, M.K.M. **Manual de técnicas aplicadas à histopatologia vegetal**. 1. ed. FEALQ: Piracicaba, 2021.140 p.
- MORIWAKI, T. et al. Nitrogen-improved photosynthesis quantum yield is driven by increased thylakoid density, enhancing green light absorption. **Plant Science**, v. 278, p. 1-11, 2019.
- MU, X.; CHEN, Y. The physiological response of photosynthesis to nitrogen deficiency. **Plant Physiology and Biochemistry**, v. 158, p. 76-82, 2021.
- REINERMANN, S. et al. Remote sensing of grassland production and management. A review. **Remote Sensing**, v. 12, n. 12, p. 1949, 2020.
- RODRIGUES, A.C. et al. **Anatomia Vegetal**. Florianópolis: Biologia/EaD/UFSC, 2015. 152p.
- SANTOS, I.B. et al. The *Eucalyptus* cuticular waxes contribute in preformed defense against *Austropuccinia psidii*. **Frontiers in Plant Science**, v.9, Article 1978, 2019.
- SERBIN, S.P.; TOWNSEND, P.A. Scaling Functional Traits from Leaves to Canopies. p. 43-82. In.: **Remote sensing of plant biodiversity**. Cavender-Bares, J.; Gamon, J.A.; Townsend, P.A. (Eds.). Springer Nature: Switzerland, 2020.
- SIMS, D.A.; GAMON, J.A. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. **Remote Sensing of Environment**, v. 81, n. 2-3, p. 337-354, 2002.
- SLATON, M.R. et al. Estimating near-infrared leaf reflectance from leaf structural characteristics. **American Journal of Botany**, v. 88, n. 2, p. 278-284, 2001.

SOLOVCHENKO, A.; MERZLYAK, M. Optical properties and contribution of cuticle to UV protection in plants: experiments with apple fruit. **Photochemical & Photobiological Sciences**, v. 2, n. 8, p. 861-866, 2003.

STRABELI, T.F. et al. Conteúdo relativo de água afeta o comportamento espectral de folhas de *Eucalyptus* spp. **Scientia Forestalis**, v.48, n.128, e3326, 2020.

TERASHIMA, I. et al. Green light drives leaf photosynthesis more efficiently than red light in strong white light: revisiting the enigmatic question of why leaves are green. **Plant and Cell Physiology**, v. 50, n. 4, p. 684-697, 2009.

USTIN, S.L.; JACQUEMOUD, S. How the optical properties of leaves modify the absorption and scattering of energy and enhance leaf functionality. p. 349-384. In.: **Remote sensing of plant biodiversity**. Cavender-Bares, J.; Gamon, J.A.; Townsend, P.A. (Eds.). Springer Nature: Switzerland, 2020.

VIRTANEN, O. et al. Chlorophyll does not reflect green light: How to correct a misconception. **Journal of Biological Education**, p. 1-8, 2020.

CAPÍTULO 3

Processamento de Imagens: da aquisição a extração da informação

Ronilson Martins Silva; Isabel Felizardo Chambingo; Wilson Manuel Castro Sillupu; Murilo Mesquita Baesso; Lilian Elgalise Techio Pereira; Adriano Rogério Bruno Tech

1. Introdução

O processamento de imagens digitais tem desempenhado um papel fundamental em uma variedade de campos, desde a medicina e vigilância até a automação industrial e análise de dados. À medida que as tecnologias avançam, a necessidade de interpretar e extrair informações significativas a partir de imagens tornou-se cada vez mais crucial (GONZALEZ; WOODS, 2018).

Os smartphones convencionais equipados com câmeras digitais têm sido uma opção de baixo custo e com potencial ainda a ser explorado na agricultura de precisão (MENDES et al., 2020). O processamento de imagens pode ser utilizado na agricultura, no desenvolvimento de softwares para os mais diversos fins, como o acompanhamento e reconhecimento de folhas, caules, frutos doentes, tamanho e porcentagem de uma determinada área afetada por vários tipos de doenças (REDDY; REDDY; SUJATHA, 2020).

Este capítulo explora as etapas essenciais envolvidas no processamento de imagens, desde a aquisição inicial até a extração final de dados relevantes. Com o crescimento exponencial no volume de dados de imagem e a complexidade dos sistemas de captura, a importância de técnicas robustas e eficientes de processamento de imagens não pode ser subestimada. Assim, o objetivo deste capítulo é servir como base para a compreensão das ferramentas e técnicas que permitem uma análise detalhada de imagens, abrindo caminho para inovações em diversas áreas do conhecimento.

2. Aquisição de Imagens

A aquisição de imagens é o primeiro passo no processo de processamento de imagens e envolve a captura de dados visuais por meio de sensores e dispositivos (XIA et al., 2023). As fontes de imagens variam amplamente, incluindo câmeras digitais, scanners, satélites, e microscópios, cada uma com suas especificidades e aplicações. Imagens podem ser adquiridas em diferentes formatos, como RGB (Red, Green, Blue), escala de cinza, imagens térmicas, entre outros (WANG et al., 2014).

A escolha do tipo de imagem e das configurações de *hardware*, como a resolução e a taxa de quadros, impacta diretamente na qualidade da análise subsequente (SZELISKI, 2022). Por exemplo, imagens com alta resolução podem oferecer mais detalhes, mas também exigem maior poder de processamento e armazenamento. A aquisição precisa e adequada é fundamental, pois os dados capturados nesta etapa determinam a base sobre a qual todas as operações de processamento serão realizadas (BAESSO et al., 2023).

Assim, a fase de aquisição de imagens é fundamental para garantir que os dados capturados sejam de alta qualidade e adequados para as etapas subsequentes de processamento. Vários fatores precisam ser controlados rigorosamente para garantir que a imagem adquirida contenha todas as informações necessárias e que possíveis interferências ou ruídos sejam minimizados (SZELISKI, 2022). Diante disso, Bertolini et al. (2021) discutiram diversos fatores a serem cuidadosamente padronizados no momento da captura, incluindo as configurações do dispositivo de captura e condições de iluminação, tais como em pleno sol ou em sombra, dias nublados, horários de aquisição, uso de fontes de iluminação externas e o tipo de fonte.

Dentre esses elementos fundamentais que devem ser controlados para minimizar os ruídos na aquisição de imagens, temos:

- 1. Controle de Luz:** A iluminação é um dos aspectos mais críticos na aquisição de imagens. Uma iluminação inadequada pode causar sombras indesejadas, brilho excessivo ou regiões sub expostas, afetando negativamente a qualidade da imagem. É essencial utilizar uma fonte de luz uniforme e bem distribuída. Lâmpadas de luz difusa ou *setups* de iluminação controlada podem ajudar a evitar sombras e reflexos. A intensidade de branco precisa ser ajustada para garantir que a imagem não fique saturada e que os detalhes sejam preservados (KATAEV; DADONOVA; EFREMENKO, 2021).

- 2. Distância de Aquisição:** A distância entre a câmera e o objeto a ser capturado deve ser consistentemente mantida. Variações na distância podem alterar a perspectiva e o tamanho aparente dos objetos, complicando o processamento posterior. Dispositivos de montagem fixos e mesas de coleta padronizadas são comumente utilizados para garantir a uniformidade na captura de imagens (SONKA; HLAVAC; BOYLE, 2014).

- 3. Mesa de Coleta e Vidro Transparente:** Uma mesa de coleta devidamente projetada, muitas vezes equipada com um vidro transparente, é utilizada para suportar o objeto a ser capturado. É crucial que o vidro não produza reflexos de luz que possam interferir na qualidade da imagem. Para evitar isso, vidros com revestimentos antirreflexos são preferidos (TECH et al., 2018)

4. Extensões e Formatos de Arquivo: A escolha do formato de arquivo para salvar as imagens adquiridas é importante para equilibrar a qualidade da imagem e a eficiência de armazenamento. Formatos como JPEG, PNG e TIFF são comumente utilizados, cada um com suas vantagens. O formato JPEG, por exemplo, oferece uma boa compressão, mas pode perder qualidade, enquanto o TIFF é preferido para armazenamento sem perdas, mantendo todos os detalhes da imagem (SOLOMON; BRECKON, 2013).

5. Resolução: A resolução da imagem deve ser adequada ao nível de detalhe necessário para a aplicação. Resoluções mais altas capturam mais detalhes, mas também geram arquivos maiores que exigem mais recursos de processamento e armazenamento (BURGER; BURGE, 2016).

6. Intensidade de Branco e Flash: A configuração da intensidade de branco (*white balance*) é essencial para garantir que as cores capturadas sejam precisas. O uso de *flash* deve ser bem controlado, pois pode criar reflexos ou iluminar excessivamente certas áreas da imagem, distorcendo a captura (GONZALEZ; WOODS, 2018).

3. Pré-processamento

O pré-processamento de imagens é uma fase crítica que visa preparar a imagem bruta para análises mais detalhadas. Um dos principais objetivos dessa etapa é a remoção de ruídos, que podem distorcer os resultados finais. Técnicas comuns para a correção de ruídos incluem o uso de filtros como o filtro mediano, gaussiano, e de média (MEIRA, 2020).

Além da redução de ruído, o ajuste de contraste é essencial para melhorar a visibilidade dos detalhes importantes na imagem. A equalização de histograma, por exemplo, é uma técnica amplamente utilizada para redistribuir os níveis de intensidade da imagem, aumentando o contraste. Outro aspecto importante do pré-processamento é a correção de iluminação, que compensa variações indesejadas na iluminação da cena. Por fim, operações geométricas, como redimensionamento e rotação, são aplicadas para alinhar e padronizar as imagens, facilitando a análise posterior (SONKA; HLAVAC; BOYLE, 2014).

Desta forma, o pré-processamento de imagens é uma etapa importante em processamento de imagens, pois visa preparar a imagem para o processamento e análise subsequentes, melhorando a qualidade e a usabilidade dos dados capturados. Esta fase inclui a aplicação de diferentes tipos de filtros e correções para remover ruídos e distorções e, dentre eles podemos citar:

1. Filtros Passa-Baixa e Passa-Alta: Os filtros passa-baixa (low-pass) e passa-alta (high-pass) são usados para modificar a frequência espacial da imagem. Filtros passa-baixa, como o filtro de média ou gaussiano, suavizam a imagem, removendo ruídos e detalhes finos, mas também podem causar borramento. Eles são úteis em situações onde se deseja destacar as grandes estruturas da imagem, minimizando interferências de detalhes menores. Por outro lado, os filtros passa-alta são usados para realçar as bordas e os detalhes finos, enfatizando as mudanças rápidas na intensidade. Esses filtros são importantes para a detecção de bordas e para o aprimoramento de detalhes específicos (DAHL; MUNTAL; ANDERSEN, 2023).

2. Correções de Distorções: As distorções na imagem, como a distorção de barril ou de almofada, podem ocorrer devido a limitações das lentes ou a imperfeições na configuração da câmera. Técnicas de correção geométrica são aplicadas para retificar essas distorções, assegurando que a imagem resultante seja uma representação fiel da cena original (LI et al., 2024).

3. Filtro Gaussiano: Um dos filtros passa-baixa mais utilizados é o filtro gaussiano, que aplica uma função gaussiana à imagem para suavizar a intensidade dos pixels. Este filtro é eficaz na remoção de ruídos de alta frequência enquanto preserva as bordas da imagem. É amplamente utilizado como um pré-processamento antes de etapas como a segmentação (GONZALEZ; WOODS, 2018).

4. Processamento de Imagens

O processamento de imagens abrange uma série de operações que transformam a imagem pré-processada em uma forma que facilita a extração de informações significativas. A segmentação é uma das técnicas mais importantes nesta fase, pois divide a imagem em regiões ou objetos de interesse (GONZALEZ; WOODS, 2018).

Existem várias abordagens para segmentação, incluindo o thresholding, que separa objetos com base em níveis de intensidade, e a segmentação baseada em bordas, que utiliza contornos para definir limites. Outra técnica crucial é a binarização, que converte a imagem em uma representação binária, facilitando a detecção de formas e padrões (SOLOMON; BRECKON, 2013).

Métodos como o de Otsu e a binarização adaptativa são frequentemente utilizados para essa finalidade. A detecção de bordas é outro componente vital do processamento de imagens, onde operadores como Sobel, Canny, e Laplaciano

são aplicados para identificar contornos significativos, que podem representar limites entre diferentes objetos ou regiões dentro da imagem (GONZALEZ; WOODS, 2018).

Esta etapa, portanto, inclui várias operações, desde a conversão de cores até a binarização, cada uma com um papel específico na preparação da imagem para a extração de dados (BURGER; BURGE, 2016).

A seguir, as etapas de processamento que as imagens passam para que possamos identificar e extrair a região de interesse.

- 1. Conversão para RGB:** As imagens digitais são frequentemente capturadas no formato RGB, que utiliza três canais (vermelho, verde e azul) para representar cores. O processamento inicial pode envolver a separação desses canais para análise individual ou a manipulação das cores para realçar certas características da imagem (GONZALEZ; WOODS, 2018; JAIN, 1989).
- 2. Conversão para Tons de Cinza:** A conversão de uma imagem RGB para escala de cinza é uma etapa comum que reduz a complexidade da imagem ao transformar os três canais de cor em um único canal de intensidade. Isso facilita o processamento subsequente, como a detecção de bordas e a binarização. A conversão é feita calculando uma média ponderada das intensidades dos canais RGB, resultando em uma imagem onde os valores de pixel variam do preto (0) ao branco (255) (BURGER; BURGE, 2016).
- 3. Binarização:** A binarização é o processo de converter a imagem em escala de cinza em uma imagem binária, onde os pixels são representados por apenas dois valores: preto e branco. Isso é feito aplicando um limiar (threshold), onde todos os pixels com intensidade acima do limiar são definidos como brancos, e abaixo, como pretos. Métodos como o de Otsu e a binarização adaptativa são comumente usados para determinar o limiar ideal, especialmente em imagens com iluminação não uniforme (GONZALEZ; WOODS, 2018).
- 4. Determinação da Região de Interesse (ROI):** A Região de Interesse (ROI) é uma área específica da imagem que contém os dados mais relevantes para a análise. A identificação precisa da ROI é crucial para garantir que o processamento e a análise subsequentes se concentrem nas partes mais importantes da imagem, ignorando os dados irrelevantes. A ROI pode ser determinada por meio de técnicas de segmentação, onde algoritmos de clustering, segmentação baseada em bordas ou regiões são aplicados para isolar a área de interesse. Mais informações serão apresentadas no próximo tópico (SZELISKI, 2022).

5. Extração de Características

Após o processamento da imagem, a próxima etapa é a extração de características, onde são identificados e quantificados atributos específicos da imagem (SZELISKI, 2022).

A região de interesse (ROI) é uma área específica da imagem que contém informações relevantes para a análise, e sua identificação precisa é crucial. A extração de atributos envolve a obtenção de informações como forma, textura, e cor, que são fundamentais para a classificação e reconhecimento de padrões (JAIN, 1989).

Por exemplo, a análise de textura pode utilizar matrizes de coocorrência de níveis de cinza (GLCM) para descrever padrões de intensidade na imagem. Descritores de imagem, como HOG (*Histogram of Oriented Gradients*), LBP (Local Binary Patterns), e SURF/SIFT, são utilizados para representar as características da imagem de forma compacta e eficiente, facilitando a análise comparativa e o reconhecimento de padrões (SZELISKI, 2022).

Assim, a determinação da Região de Interesse (ROI) é uma etapa importantíssima no processamento de imagens, pois permite focar a análise nas áreas que contêm informações relevantes, ignorando o resto da imagem. A correta delimitação da ROI pode melhorar significativamente a eficiência e a precisão do processamento subsequente. Diversos métodos e técnicas podem ser aplicados para identificar e delimitar a ROI (ZHU; HUANG, 2012):

1. Segmentação por Limiarização (Thresholding): A segmentação por limiarização é uma técnica simples e amplamente utilizada para a determinação da ROI, especialmente em imagens com contraste bem definido entre o objeto de interesse e o fundo. Esta técnica envolve a aplicação de um valor de limiar (*threshold*) para separar os pixels da imagem em duas categorias: aqueles que pertencem à ROI e aqueles que pertencem ao fundo. Métodos avançados, como a limiarização de Otsu, calculam automaticamente o valor de limiar ideal, maximizando a separação entre as classes de pixels (GONZALEZ; WOODS, 2018).

2. Segmentação por Detecção de Bordas: A detecção de bordas é outra técnica comum para a delimitação da ROI. Operadores de detecção de bordas, como Sobel, Canny ou Laplaciano, são usados para identificar áreas da imagem onde há mudanças abruptas na intensidade dos pixels, indicando a presença de contornos ou fronteiras. Esses contornos podem ser usados para delinear a ROI, isolando objetos ou regiões de interesse dentro da imagem. O operador Canny, em particular, é muito eficaz, pois combina a detecção de bordas com a supressão de ruído e a rastreabilidade de bordas contínuas (GONZALEZ; WOODS, 2018).

3. Segmentação por Regiões (Region Growing): A segmentação por crescimento de regiões é uma técnica que agrupa pixels com propriedades semelhantes (como intensidade ou cor) para formar regiões conectadas que representam a ROI. O processo começa a partir de "sementes" (pixels iniciais selecionados) e expande a região até que todos os pixels adjacentes que atendem a um critério de similaridade sejam incluídos. Esta técnica é especialmente útil quando a ROI não possui bordas bem definidas, mas é homogênea em termos de suas características (GONZALEZ; WOODS, 2018).

4. Segmentação por Watershed: A segmentação por *Watershed* é baseada em um conceito da morfologia matemática e é particularmente útil para segmentar imagens que contêm regiões de interesse próximas ou conectadas. A técnica trata a imagem como uma topografia, onde os valores de intensidade representam altitudes. O algoritmo então "inunda" a imagem a partir de mínimos locais, com as linhas de separação formadas nas cristas entre bacias adjacentes, correspondendo às bordas da ROI. Este método é eficaz para segmentar regiões complexas, embora possa ser sensível ao ruído, exigindo um pré-processamento adequado (SONKA; HLAVAC; BOYLE, 2014).

5. Segmentação Baseada em Clustering (K-means, Mean-Shift): Técnicas de clustering, como K-means e Mean-Shift, são usadas para agrupar pixels em clusters com características semelhantes, como cor ou textura. K-means, por exemplo, particiona os pixels em k clusters, minimizando a variação dentro de cada cluster. Os clusters que representam a ROI são então selecionados com base em critérios pré-definidos. Mean-Shift é outra técnica de clustering não paramétrica que agrupa os pixels com base na densidade do espaço de características, o que pode ser útil para detectar ROIs em imagens com padrões complexos (SZELISKI, 2022).

6. Segmentação por Modelos de Contorno Ativo (Active Contour Models): Também conhecidos como "snakes", os modelos de contorno ativo são utilizados para refinar a delimitação da ROI ao longo de suas bordas. Essa técnica inicializa um contorno próximo da região de interesse e ajusta iterativamente o contorno para se encaixar nas bordas reais da ROI, minimizando uma função de energia que leva em conta a suavidade do contorno e a correspondência com as bordas detectadas na imagem. É especialmente eficaz em situações onde as bordas da ROI são suaves ou difíceis de segmentar diretamente (CASELLES; KIMMEL; SAPIRO, 1997).

7. Aprendizado de Máquina e Redes Neurais Convolucionais (CNNs): Nos casos mais avançados, técnicas de aprendizado de máquina, como Redes Neurais Convolucionais (CNNs), são utilizadas para identificar e delimitar a ROI com alta precisão. CNNs podem ser treinadas em conjuntos de dados

rotulados para aprender a reconhecer automaticamente as regiões de interesse com base em características complexas da imagem. Esta abordagem é particularmente poderosa em aplicações que envolvem grandes volumes de dados e onde a ROI apresenta variações significativas entre diferentes imagens (KAMILARIS; PRENAFETA-BOLDÚ, 2018).

Cada uma dessas técnicas pode ser escolhida ou combinada de acordo com as características específicas da imagem e os requisitos da aplicação. A determinação precisa da ROI é um passo essencial para garantir que a análise subsequente seja focada nas áreas mais importantes da imagem, maximizando a relevância dos dados extraídos (GONZALEZ; WOODS, 2018).

O processamento de imagens encontra aplicação em diversas áreas, onde a extração de informações visuais é essencial para a tomada de decisões. No campo do reconhecimento facial, por exemplo, permite a identificação de indivíduos em grandes bases de dados, com aplicações em segurança e controle de acesso (LEITE; GAMBARATO, 2022). Na indústria, o processamento de imagens é utilizado para a inspeção de qualidade, onde falhas em produtos são detectadas automaticamente através da análise de imagens de alta resolução (YAQOOB et al., 2021). Na medicina ele é fundamental para o diagnóstico, permitindo a visualização e análise de estruturas internas do corpo humano com precisão (HUNT et al., 2021).

Recentemente a Universidade Federal de Pelotas realizou um projeto denominado: Processamento de imagens para identificação de defeitos no arroz. O mesmo investigou a separação de grãos defeituosos através de análise de cores, usando o sistema RGB para melhor contraste. Esse processo automatizado tem sido valioso para melhorar a qualidade da classificação de grãos, principalmente em estágios pós-colheita (MONTEIRO et al., 2018).

Oliveira et al. (2021) focaram seu estudo na caracterização morfológica de sementes de tomate por meio de processamento de imagens, especialmente na avaliação da emergência de raízes primárias. O principal objetivo foi usar parâmetros morfológicos capturados por imagens digitais para medir o vigor das sementes, algo essencial para prever o desempenho das plantas no campo. Os pesquisadores utilizaram técnicas avançadas de processamento de imagens e aprendizado de máquina para identificar e quantificar características como o comprimento da raiz e sua taxa de crescimento. Esses dados permitiram uma análise precisa da qualidade das sementes, auxiliando na otimização dos processos de pós-colheita, como armazenamento e beneficiamento (RUSS, 2011).

Estudos feitos por Fonseca, Locatelli e Silva Filho (2018) e Passos (2021) fazem referência ao uso de NDVI e EVI, informações que são informações em forma de imagens obtidas por meio de satélite, em suas pesquisas sobre: NDVI aplicado na detecção de degradação de pastagens cultivadas e Índices de refletância, NDVI

e EVI como indicadores de níveis de degradação das pastagens tropicais, respectivamente.

A análise de imagens com o índice NDVI permite uma visão detalhada da saúde das pastagens, uma vez que esse índice mede a densidade da vegetação. Quando aplicado corretamente, ele consegue diferenciar áreas saudáveis de pastagens das que estão degradadas, fornecendo informações valiosas para intervenções de manejo, como recuperação do solo. Contudo, desafios como o tratamento de grandes volumes de dados, a necessidade de processamento em tempo real e a integração com técnicas de aprendizado de máquina continuam a impulsionar a pesquisa e o desenvolvimento de novas soluções no campo do processamento de imagens.

7. Considerações Finais

Neste capítulo, foram abordadas as etapas fundamentais do processamento de imagens, desde a aquisição até a extração de dados. Cada etapa desempenha um papel crucial na construção de sistemas robustos e eficientes para a análise de imagens, com aplicações que vão desde a medicina até a automação industrial.

À medida que novas tecnologias emergem, o campo do processamento de imagens continua a evoluir, incorporando técnicas de inteligência artificial e aprendizado profundo para lidar com desafios cada vez mais complexos. O futuro do processamento de imagens promete inovações significativas, impulsionadas pela crescente demanda por sistemas que possam interpretar e agir sobre informações visuais com precisão e eficiência.

Referências Bibliográficas

BAESSO, M. et al. Deep learning-based model for classification of bean nitrogen status using digital canopy imaging. **Engenharia Agrícola**, v. 43, n. 2, e20230068, 2023.

BURGER, W.; BURGE, M. J. **Digital Image Processing: An Algorithmic Introduction Unisg Java**. 2. ed. London: Springer, 2016. 811p.

CASSELLES, V.; KIMMEL, R.; SAPIRO, G. Geodesic Active Contours. **International Journal of Computer Vision**, v. 22, p. 61-79, 1997.

DAHL, N. J.; MUNTAL, P. L.; ANDERSEN, M. A. E. Time-Based High-Pass, Low-Pass, Shelf, and Notch Filters. **Elektronika ir elektrotechnika**. v. 29, n. 6, p. 33-40, 2023.

FONSECA, E. L; LOCATELLI,M; SILVA FILHO, E.P. NDVI aplicado na detecção de degradação de pastagens cultivadas. **Revista Franco-Brasileira de Geografia**, n.35, 2018.

GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**. 4. ed. New York: Pearson, 2018. 1168p.

HUNT, B.; RUIZ, A.J.; POGUE, B.W. Smartphone-based imaging systems for medical applications: a critical review. **Journal of Biomedical Optics**, v. 26, n. 4, p. 040902-040902, 2021.

JAIN, A. K. **Fundamentals of Digital Image Processing**. Englewood Cliffs: Prentice-Hall, 1989. 569p.

JENSEN, J. R. **Remote Sensing of the Environment: An Earth Resource Perspective**. 2. ed. Upper Saddle River: Pearson Prentice Hall, 2007. 592p.

KAMILARIS, A.; PRENAFETA-BOLDÚ, F.X. Deep learning in agriculture: a survey. **Computers and Electronics in Agriculture**, v. 47, p. 70-90, 2018.

KATAEV, M. Y.; DADONOVA, M. M.; EFREMENKO, D. S. On the deformation and frequency analyses of SARS-CoV-2 at nanoscale. **Light & Engineering**, v. 29, n. 2, p. 50-58, 2021.

LEITE, A. B. G. G; GAMBARATO. V.T.S. Inteligência Artificial Aplicada ao Processamento de Imagem Diagnostica. **Tekhme e Iagod**, Botucatu, v.13, n.3, p. 104-114, 2022.

LI, S. C. et al. An efficient deep learning-based framework for image distortion correction. **Visual Computer**, v. 40, n. 10, p. 6955–6967, 2024.

MEIRA, L. A. **USPLeaf: software de processamento digital de imagens para obtenção da área foliar em espécies forrageiras**. 80 f. Dissertação (Mestrado em Gestão e Inovação na Indústria Animal) - Faculdade de Zootecnia e Engenharia de Alimentos, Universidade de São Paulo, Pirassununga, 2020.

MENDES, J. et al. Smartphone applications targeting precision agriculture practices: a systematic review. **Agronomy**, (S. 1.), v. 10, n. 6, p. 855, 2020.

MONTEIRO, R.C.M. et al. Processamento de imagens para identificação de defeitos no arroz. 4ª semana integrada UFPLE 2018. **XXVII Congresso de Iniciação Científica**, 2018.

OLIVEIRA, G. R. F. et al. Parâmetros morfológicos de processamento de imagens para caracterização da emergência da raiz primária na avaliação do vigor de sementes de tomate. **Journal of Seed Science**, v. 43, 2021.

PASSOS, A. O. **Índices de refletância, NDVI e EVI como indicadores de níveis de degradação das pastagens tropicais**. 2021. 52 p. Dissertação (Mestrado em Ciências Ambientais) — Universidade Estadual Paulista, Jaboticabal, 2021.

REDDY, K. A.; REDDY, N. V. M. C.; SUJATHA, S. Precision method for pest detection in plants using the clustering algorithm in image processing. In: **2020 International Conference on communication and signal processing (ICCSP) 2020**, Anais [...].: IEEE, 2020, p. 894-897.

RUSS, J. C. **The Image Processing Handbook**. 6. ed. Boca Raton: CRC Press, 2011. 885p.

SOLOMON, C.; BRECKON, T. **Fundamentos do processamento digital de imagens. Uma Abordagem Prática com Exemplos em Matlab**. 3ªed. São Paulo: LTC, 2013. 306p.

SONKA, M.; HLAVAC, V.; BOYLE, R. **Image Processing, Analysis, and Machine Vision**. 4. ed. Boston: Cengage Learning, 2014. 920p.

SZELISKI, R. **Computer Vision: Algorithms and Applications**. 2. ed. London: Springer, 2022. 925p.

TECH, A. R. B. et al. Methods of image acquisition and software development for leaf area measurements in pastures. **Computers and Electronics in Agriculture**, v. 153, p. 278-284, 2018.

XIA, W. et al. Tool wear image on-machine detection based on trajectory planning of 6-DOF serial robot driven by digital Twin. **International Journal of Advanced Manufacturing Technology**, v.125, n.7-8, p. 3761-3775, 2023.

YAQOOB, M.; SHARMA, S.; AGGARWAL, P. Imaging techniques in agro-industry and their applications, a review. **Journal of Food Measurement and Characterization**, v. 15, p. 2329-2343, 2021.

WANG, Y. et al. Estimating rice chlorophyll content and leaf nitrogen concentration with a digital still color camera under natural light. **Plant Methods**, v. 10, n. 1, p. 36, 2014.

ZHU, Y.; HUANG, C. An improved median filtering algorithm for image noise reduction. **Physics Procedia**, v.25, p. 609–616, 2012.

Uso da análise de imagem para predição de severidade de estresse biótico

João Paulo Rodrigues Marques; Murilo Mesquita Baesso; Adriano Rogério Bruno Tech

1. Introdução

O crescente desenvolvimento de métodos estatísticos e computacionais tem ressaltado enormes possibilidades de uso de ferramentas de Machine Learning (ML) em substituição à determinadas análises laboratoriais ou como ferramenta de suporte para tomada de decisões, sendo considerados métodos promissores para identificação de padrões, classificação ou predição de parâmetros (KARTAL; OZVEREN, 2021). Segundo Liakos et al. (2018), os métodos de ML envolvem um processo de aprendizagem com o objetivo de aprender a partir de uma “experiência” (dados de treinamento) a fim de realizar uma tarefa. Segundo os autores, as tarefas associadas ao ML são classificadas em uma ampla gama de categorias, normalmente associadas ao tipo de aprendizagem (supervisionada ou não supervisionada) e modelos de aprendizagem (classificação, regressão, agrupamento ou redução de dimensionalidade) empregados.

A redução de dimensionalidade é uma análise executada normalmente antes da aplicação de modelos de classificação ou regressão, com o objetivo de prover dados de entrada mais compactos e reduzir a representação dimensional do banco de dados, mas preservando o maior número possível de informações a partir do banco de dados original. Dentre os algoritmos mais utilizados para tal finalidade, destacam-se a análise de componentes principais, regressão parcial de mínimos quadrados e análise de discriminante linear (LIAKOS et al., 2018).

Por sua vez, os algoritmos com aprendizado supervisionado são aqueles que apresentam um conjunto de dados de entrada e de saída conhecidos, que serão treinados para uma resposta generalizada para outros dados de entrada, e são aqueles mais amplamente empregados para aplicações na agricultura e ambientes de produção animal (GARCÍA et al., 2020).

Entre as principais vantagens do uso de ML frente a outros métodos estatísticos tradicionais estão: i. não envolvem suposições sobre a distribuição dos dados; ii. permitem estimar relações não lineares complexas a partir de uma grande quantidade de dados ou variáveis de forma rápida; e iii) ampla habilidade de generalização com maior acurácia (MORAIS et al., 2021).

Revisões de literatura realizadas por Liakos et al. (2018) e Morais et al. (2021) apontam os principais modelos de ML atualmente utilizados na agricultura e para estimativas de biomassa em pastagens, dentre os quais destacam-se as redes neurais artificiais (RNA's), máquinas de vetores de suporte (ou support vector machine, SVM) e random forest (RF), embora uma infinidade de algoritmos vinculados a cada modelo esteja disponível. Esses autores ressaltam que não há evidências de que um dado algoritmo expresse desempenho superior para uma determinada tarefa, mas indicam que a fonte de dados e o tamanho do banco de dados consistem nos principais fatores que afetam a capacidade preditiva e de generalização dos modelos.

2. Uso da análise de imagem para predição de estresses bióticos

De acordo com Shoaib et al. (2023) houve um aumento significativo nos esforços para o desenvolvimento de sistemas baseados em Machine Learning (ML) e Deep Learning (DL) visando obter processo de avaliação da severidade de doenças. Basicamente, as etapas para análise de imagem e detecção de doença são as seguintes: i) captura da imagem original; ii) classificação da lesão (fungo, bactéria, vírus etc); iii) detecção por meio de algoritmo e iv) segmentação. O sistema de classificação, detecção e segmentação das lesões por meio de imagens digitais pode alterar o modo como identificamos, diagnosticamos e gerenciamos os estresses bióticos no campo (AKBAR et al., 2022).

Na literatura recente 2015 - 2022, tem sido abordados diferentes métodos para estudo e diagnose de lesões em plantas: Convolutional Neural Networks (CNNs), Transfer learning with CNNs, Multitasking learning networks, Deconvolution-guided VGNet (DGVGNet), e métodos tradicionais como inspeção manual e com microscópio (SHOAIB et al., 2023). Comparando com as demais o método tradicional são mais baratas e de fácil acesso ao público, principalmente aquele com baixo acesso a tecnologia, porém tem a desvantagem de demandarem muito tempo e o fato de haver erro de análise ou subjetividade dependendo do observador. Neste sentido, métodos fomentados à luz da Inteligência artificial vem agregar à demanda por estudos de desenvolvimento de sistemas inteligentes para análise da severidade de estresses bióticos.

A avaliação da severidade de doenças no século XX era feita com o auxílio da escala diagramática, como a proposta por Eskes (1989) para estudo da ferrugem do cafeeiro. Porém, alguns aplicativos de fácil acesso já se encontram disponíveis e com o uso do programa Leaf Doctor (PETHYBRIDGE; NELSON, 2015).

3. Estudo de caso da ferrugem do café

O café é uma bebida apreciada e degustada mundo afora. No Brasil, cerca de 95% da população bebe e se beneficia das propriedades do café, que atua na redução da perda da memória e fortalecimento da imunidade (ALBERO et al., 2021). O estado de São Paulo é o terceiro maior produtor de café, ficando atrás de Minas Gerais e Espírito Santo, primeiro e segundo produtores respectivamente (CONAB, 2025).

O Brasil segue como o maior consumidor dos cafés nacionais sendo, ainda, o maior produtor e exportador de café e o segundo em consumo mundial, ficando apenas atrás dos EUA (ABIC, 2024). A demanda externa associada a fatores climáticos e preços favoráveis permitiu uma exportação recorde de café no Brasil em 2024, com aumentos de mais de 28% em relação a 2023 (CONAB, 2025).

A ferrugem do cafeeiro (FIGURA 1), causada pelo fungo *Hemileia vastrix*, é uma das mais importantes doenças que minam a produtividade dos cafezais. Ela pode causar perda de 35-50% na produtividade dependendo a região e condições climáticas (ZAMBOLIM, 2016).

Figura 1. Superfície abaxial de folhas de cafeeiro com lesões de ferrugem.



Fonte: Própria Autoria.

O fungo desenvolve apressório sobre os estômatos e pode penetrar junto à câmara subestomática em 24 h.a.i. Após a penetração, forma-se uma hifa primária junto às células-guarda dos estômatos seguida da colonização dos espaços intercelulares onde serão formadas as células-mãe do haustório. Os detalhes do

processo de penetração foram descritos por Silva et al. (2006). Essa sequência de eventos culmina com o estabelecimento da relação parasitária, seguida da formação de pústulas onde o fungo forma seus esporos (PATRÍCIO; OLIVEIRA, 2014).

3.1. Utilização de Técnicas de Processamento de Imagens e Machine Learning na Previsão de Doenças do Café

A utilização de técnicas de processamento de imagens e machine learning tem se mostrado promissora para auxiliar produtores e gestores no desenvolvimento de métodos eficazes para a previsão de doenças, como a ferrugem do café. A combinação dessas tecnologias permite a identificação precoce de sintomas da doença nas plantas, possibilitando intervenções rápidas e precisas para minimizar os danos.

O processamento de imagens permite a captura de detalhes sutis nas folhas do cafeeiro que podem indicar o início de uma infecção por *Hemileia vastatrix*. Imagens de alta resolução podem ser analisadas para detectar padrões de coloração, textura e formato que são característicos da ferrugem do café. Essas imagens podem ser coletadas através de drones ou câmeras instaladas em plantações, garantindo um monitoramento contínuo e abrangente.

Por outro lado, algoritmos de machine learning, treinados com grandes conjuntos de dados de imagens de folhas saudáveis e infectadas, são capazes de aprender a diferenciar entre plantas afetadas e não afetadas com alta precisão. Modelos como Redes Neurais Convolucionais (CNNs) são especialmente eficazes para tarefas de reconhecimento de padrões em imagens. Uma vez treinados, esses modelos podem processar novas imagens em tempo real, fornecendo diagnósticos imediatos aos produtores.

A integração dessas tecnologias na rotina de manejo dos cafezais oferece vários benefícios:

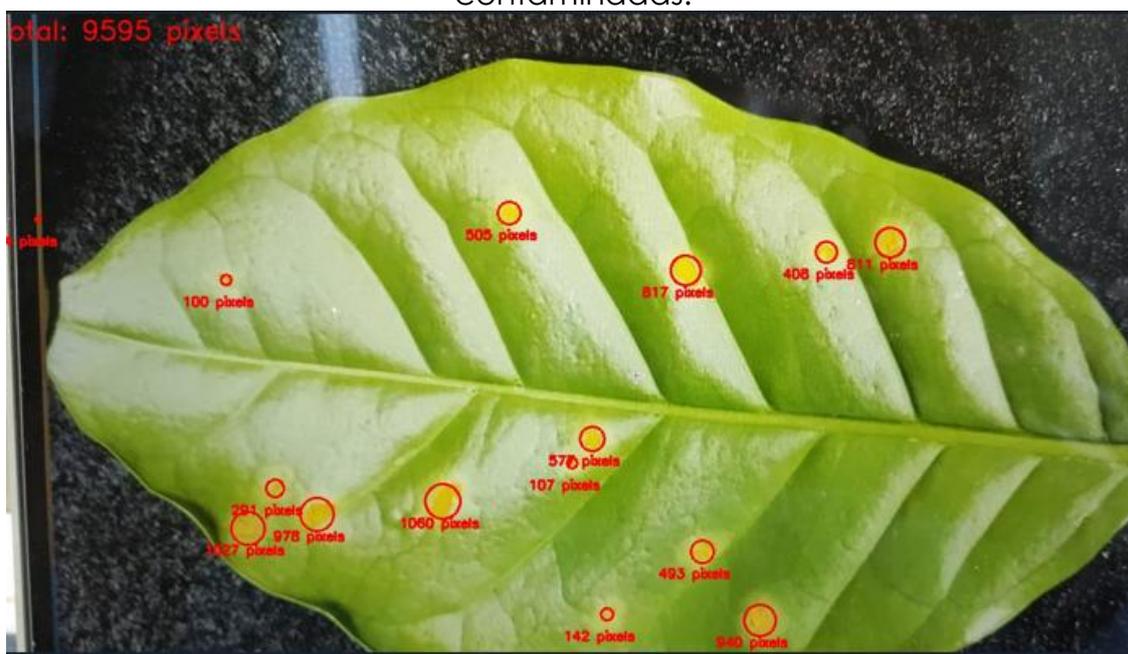
1. **Detecção Precoce:** Identificação de sintomas antes que a doença se espalhe, permitindo intervenções mais eficazes.
2. **Redução de Perdas:** Minimização das perdas de produtividade causadas pela ferrugem do café, ao tratar a doença nas fases iniciais.
3. **Eficiência Operacional:** Automatização do monitoramento das plantações, reduzindo a necessidade de inspeções manuais intensivas.
4. **Decisões Informadas:** Dados precisos e em tempo real auxiliam os gestores na tomada de decisões estratégicas sobre o manejo da cultura.

Dessa forma, a aplicação dessas tecnologias emergentes se configura como uma ferramenta poderosa na luta contra a ferrugem do café, auxiliando na manutenção da produtividade e qualidade dos cafezais brasileiros.

Utilizando um software implementado em Python aplicado a técnicas de processamento de imagens é possível identificar as áreas lesionadas e extrair as suas características ou padrão (feature). Com esses dados torna-se possível aplicar técnicas de machine learning para identificar as regiões lesionadas das áreas saudáveis do limbo foliar, determinar a sua severidade de modo ágil e tratar o talhão com as plantas infectadas de modo precoce antes que se espalhem por toda a área de cultivo.

A Figura 2 permite visualizar a atuação do software delimitando as áreas contaminadas, bem como o seus tamanhos em pixels, por meio de contagem de pixels.

Figura 2. Áreas demarcadas pelo software identificando as áreas contaminadas.



Fonte: Própria Autoria.

Com os dados das áreas contaminadas podemos utilizar algumas técnicas de machine learning para prever a doença e, tentar reduzir o tempo de atuação para que outros pés não sejam contaminados.

3.2. Processo de Detecção da Área Contaminada

O processo de detecção da área contaminada por ferrugem do café utilizando técnicas de processamento de imagens envolve várias etapas, desde a

captura das imagens até a extração dos pixels que refletem as regiões contaminadas. A seguir está uma descrição detalhada de cada etapa realizada pelo software para a detecção de áreas contaminadas.

3.2.1 Captura de Imagens

A primeira etapa consiste na captura de imagens das folhas do cafeeiro. Essas imagens podem ser obtidas através de drones equipados com câmeras de alta resolução, câmeras fixas instaladas na plantação ou até mesmo câmeras de smartphones para pequenos estudos. A qualidade das imagens é crucial para a eficácia do processamento subsequente.

3.2.2 Pré-processamento das Imagens

As imagens capturadas frequentemente precisam passar por um pré-processamento para melhorar a qualidade e facilitar a análise. As técnicas de pré-processamento podem incluir:

1. **Redimensionamento:** Ajustar o tamanho da imagem para um padrão específico.
2. **Correção de Cor:** Ajustar o balanço de cores para garantir que as cores das folhas sejam realistas.
3. **Filtragem:** Aplicar filtros para reduzir o ruído e realçar as características importantes.
4. **Normalização:** Ajustar a intensidade dos pixels para um intervalo comum.

3.2.3 Segmentação da Imagem

A segmentação da imagem é a etapa onde a imagem é dividida em diferentes regiões ou segmentos. No contexto da ferrugem do café, a segmentação visa isolar as áreas potencialmente contaminadas, região de interesse (ROI), do resto da imagem. Métodos comuns de segmentação incluem:

1. **Segmentação por Limiarização:** Aplicar um limite de intensidade para separar os pixels que representam a doença.
2. **Segmentação Baseada em Cor:** Utilizar a cor característica das áreas contaminadas (geralmente tons de amarelo e laranja) para segmentar a imagem.
3. **Segmentação Baseada em Regiões:** Detectar e agrupar pixels conectados que têm características semelhantes.

3.2.4 Extração de Características

Após a segmentação, as características das áreas contaminadas são extraídas. Essas características podem incluir:

1. **Textura:** Medir a rugosidade, suavidade e padrão das áreas segmentadas.
2. **Cor:** Analisar os valores de cor para confirmar a presença da doença.
3. **Forma:** Determinar a forma e o tamanho das manchas de ferrugem para distinguir de outras possíveis anomalias.

3.2.5 Classificação

Nesta etapa, um modelo de machine learning é utilizado para classificar as áreas segmentadas como contaminadas ou saudáveis. Modelos comuns incluem:

1. **Redes Neurais Convolucionais (CNNs):** Especialmente eficazes para o reconhecimento de padrões em imagens.
2. **Máquinas de Vetores de Suporte (SVMs):** Usadas para a classificação de alta dimensionalidade.
3. **K-Nearest Neighbors (kNN):** Para a classificação baseada na proximidade dos pontos de dados.

O modelo é treinado com um conjunto de dados de imagens rotuladas (saudáveis e contaminadas), e então aplicado para classificar novas imagens.

3.2.6 Extração dos Pixels Contaminados

Uma vez que as áreas contaminadas são identificadas, os pixels correspondentes são extraídos para análise posterior. Esse processo envolve:

1. **Máscara Binária:** Criar uma máscara binária onde os pixels contaminados são marcados como 1 (branco) e os saudáveis como 0 (preto).
2. **Superposição da Máscara:** Aplicar a máscara binária à imagem original para isolar e visualizar apenas os pixels contaminados.
3. **Análise Quantitativa:** Medir a extensão da contaminação, como a porcentagem da área foliar afetada.

3.2.7 Visualização e Relatórios

Finalmente, os resultados são visualizados e relatórios são gerados. Isso pode incluir:

1. **Mapas de Calor:** Visualizações que mostram a intensidade da contaminação em diferentes partes da plantação.
2. **Relatórios Detalhados:** Documentos que fornecem uma análise quantitativa da contaminação, incluindo gráficos e tabelas.
3. **Alertas em Tempo Real:** Notificações automáticas para os gestores da plantação sobre a detecção de contaminação.

A utilização de técnicas de processamento de imagens e machine learning para a detecção de áreas contaminadas pela ferrugem do café oferece uma abordagem eficaz e eficiente para o monitoramento e gestão de doenças nas plantações. Essas tecnologias permitem uma detecção precoce e precisa, possibilitando intervenções rápidas e estratégicas, reduzindo assim as perdas e melhorando a produtividade e a qualidade dos cafezais.

Referências Bibliográficas

ABIC. Associação Brasileira da Indústria de Café. Desempenho da Produção e do Consumo Interno. Disponível em: <<https://estatisticas.abic.com.br/estatisticas/indicadores-da-industria/indicadores-da-industria-de-cafe-2024/>>. Acesso em 17 de abril de 2025.

AKBAR, M. et al. An effective deep learning approach for the classification of Bacteriosis in peach leave. **Frontiers in plant science**, v. 13, 1064854, 2022.

ALBERO, B. A. S. et al. Café e Saúde Humana: Uma Revisão Bibliográfica. Revista Higei@ - Revista Científica de Saúde, v. 3, n. 5, 2021.

COMPANHIA NACIONAL DE ABASTECIMENTO (CONAB). 2025. Acompanhamento da safra brasileira de café, v. 11 – Safra 2024, n.4. Quarto levantamento, Brasília, p. 1-53, 2025.

ESKES, A.B. Resistance. In: Khushalappa, A.C.; Eskes, A.B. 1989. **Coffee rust: epidemiology, resistance and management**. Boca Raton: CRC Press. p.16-80.

GARCIA, R. et al. A systematic literature review on the use of machine learning in precision livestock farming. **Computers and Electronics in Agriculture**, v. 179, 105826, 2020.

KARTAL, F.; ÖZVEREN, U. An improved machine learning approach to estimate hemicellulose, cellulose, and lignin in biomass. **Carbohydrate Polymer Technologies and Applications**, v. 2, 100148, 2021.

LIAKOS, K. G. et al. Machine learning in agriculture: A review. **Sensors**, v. 18, n. 8, 2674, 2018.

MORAIS, T. G. et al. The use of machine learning methods to estimate aboveground biomass of grasslands: A review. **Ecological Indicators**, v.130, 108081, 2021.

PATRÍCIO, F. R. A.; OLIVEIRA, E. G. Desafios do manejo no controle de doenças do café. **Visão Agrícola**, n. 12, p. 51 – 54, 2014.

PETHYBRIDGE, S. J.; NELSON, S. C. Leaf Doctor: A new portable application for quantifying plant disease severity. **Plant Disease**, v. 99, n. 10, p. 1310-1316, 2015.

SILVA, H.S. A. et al. **Microrganismos endofíticos: potencial de uso como agentes de biocontrole da ferrugem do cafeeiro**. Boletim de Pesquisa e Desenvolvimento 38. Jaguariúna: Embrapa Meio Ambiente, 2006. 25p.

SHOAIB, M. et al. An advanced deep learning models-based plant disease detection: A review of recent research. **Frontiers in Plant Science**, v. 14, 1158933, 2023.

ZAMBOLIM, L. Current status and management of coffee leaf rust in Brazil. **Tropical plant pathology**, v. 41, p. 1-8, 2016.

Identificação de deficiência de macronutrientes em milho

Fernanda de Fátima da Silva Devechio; Ronilson Martins Silva; Liliane Maria Romualdo Altão; Pedro Henrique Cerqueira Luz; Valdo Rodrigues Herling

1. A cultura do milho no agronegócio

O milho (*Zea mays* L.) é um alimento básico importante que tem impactos culturais, econômicos, ambientais e nutricionais no mundo. Além de ser uma cultura fundamental para a nutrição humana, tem alta demanda devido aos investimentos globais em ração animal e etanol para biocombustível (TANUMIHARDJO et al., 2020).

Conforme dados da FAO (2024), em 2022 o cultivo de milho alcançou uma área global de 246,6 milhões de hectares, resultando em uma produção total de 1,44 bilhão de toneladas, com produtividade média de 5,84 toneladas por hectare. No Brasil, a safra de milho referente ao ciclo 2023/2024 está estimada em cerca de 114,1 milhões de toneladas, distribuídas entre duas safras e cultivadas em aproximadamente 20,8 milhões de hectares, com produtividade média de 5,48 t/ha (CONAB, 2024). Apesar de próxima à média mundial, a produtividade brasileira ainda é inferior à registrada em países como o Chile e os Estados Unidos, que apresentam médias de 11,0 e 10,9 t/ha, respectivamente.

Segundo Tanumihardjo et al. (2020), alcançar maior produtividade de forma sustentável na cultura do milho depende de investimentos contínuos em tecnologias agrícolas, como o aprimoramento genético, a maior oferta de nutrientes e a adoção de estratégias que assegurem a nutrição vegetal e a conservação da fertilidade do solo. O avanço nas práticas agrícolas é considerado essencial para promover o desenvolvimento econômico e social, contribuindo, inclusive, para a redução da pobreza. Além disso, características do solo como profundidade, teor de umidade, fertilidade e equilíbrio nutricional influenciam diretamente tanto a produtividade quanto a qualidade do milho produzido.

A adubação inadequada esgota o solo, resultando em culturas deficientes em nutrientes. Desenvolver práticas eficazes de manejo da fertilidade do solo e nutrição mineral do milho é essencial para mitigar os impactos no crescimento e rendimento da cultura (MANZEKE et al., 2012).

2. Uso de fertilizantes e nutrição mineral do milho

A agricultura brasileira é fortemente dependente do uso de fertilizantes, respondendo por aproximadamente 8,5% do consumo mundial desses insumos. Isso se deve, em grande parte, à baixa fertilidade natural dos solos tropicais predominantes no país. Essa dependência, somada à alta taxa de importação e à concentração do setor em termos geográficos e comerciais, torna a economia nacional suscetível às flutuações do mercado internacional de fertilizantes (CALIGARIS et al., 2022). Além disso, os fertilizantes representam entre 30% e 40% dos custos variáveis na produção de grãos, variando conforme a cultura e a região produtora (CONAB, 2023). Nesse sentido, pesquisas que influenciem uma agricultura com uso racional de fertilizantes e ecologicamente sustentável buscam apresentar meios, com os quais podemos prezar pela eficiência nutricional.

Diversos autores, ao pesquisar impactos de níveis de nutrientes em culturas de grãos, encontraram correlação direta entre a deficiência nutricional e redução de produção de matéria seca (GASPAROTTO, 2014; PEREIRA et al., 2014; SILVA et al., 2014; ROMUALDO et al., 2014; LUZ, et al., 2018; DEVECHIO et al., 2022). Dessa forma, conhecer a dinâmica dos nutrientes nos vegetais é importante para atingir produtividades satisfatórias e para a utilização de práticas agrícolas de manejo que priorizem a racionalidade na utilização de recursos.

Aumentar a eficiência no aproveitamento dos nutrientes dentro dos sistemas agrícolas é fundamental para diminuir a dependência de fertilizantes, cujos custos são elevados tanto economicamente quanto em termos de impacto ambiental (CROTTY et al., 2014).

Uma planta é considerada deficiente em determinado nutriente quando sua concentração nos tecidos vegetais está abaixo do nível necessário para um crescimento satisfatório. A chamada concentração crítica corresponde ao teor mínimo do nutriente no tecido vegetal em que se obtém cerca de 90% do rendimento máximo ou o crescimento ideal da planta (MARSCHNER, 2012).

Em folhas de milho, os teores considerados adequados de macronutrientes, medidos em gramas por quilograma (g kg^{-1}), situam-se nas seguintes faixas: nitrogênio (N) entre 27 e 35, fósforo (P) de 1,9 a 3,5, potássio (K) de 17 a 30, cálcio (Ca) entre 2,5 e 6,0, magnésio (Mg) de 1,5 a 4,0 e enxofre (S) entre 1,5 e 3,0 (CANTARELLA et al., 2022).

A elaboração de programas de adubação para culturas agrícolas exige, inicialmente, a compreensão dos efeitos que a carência de nutrientes pode causar no crescimento e no desenvolvimento das plantas. Reconhecer os sintomas associados às deficiências nutricionais é essencial para diagnosticar e corrigir eventuais desequilíbrios, promovendo intervenções mais precisas, com menor desperdício de insumos e reduzido impacto ambiental (SILVA et al., 2009).

3. Sintomatologia de deficiência nutricional no milho

Cada nutriente exerce funções específicas e indispensáveis no metabolismo vegetal (MALAVOLTA, 2006). Quando algum elemento essencial está em quantidade inadequada no ambiente ou sua forma de presença reduz sua disponibilidade para as plantas, ocorrem alterações metabólicas nas células decorrentes dessa carência (EPSTEIN; BLOOM, 2006).

Tais alterações costumam se manifestar por meio de sinais visíveis, como cloroses, necroses foliares, redução no crescimento ou outras irregularidades. A forma como esses sintomas se expressam varia conforme a intensidade da deficiência, a espécie, cultivar ou variedade da planta, além das condições ambientais (MALAVOLTA, 2006).

Com isso, os métodos convencionais para identificar deficiências nutricionais incluem a observação visual dos sintomas e a análise química das folhas. A seguir, serão descritos os principais sinais visuais de deficiência dos macronutrientes na cultura do milho.

a) Nitrogênio

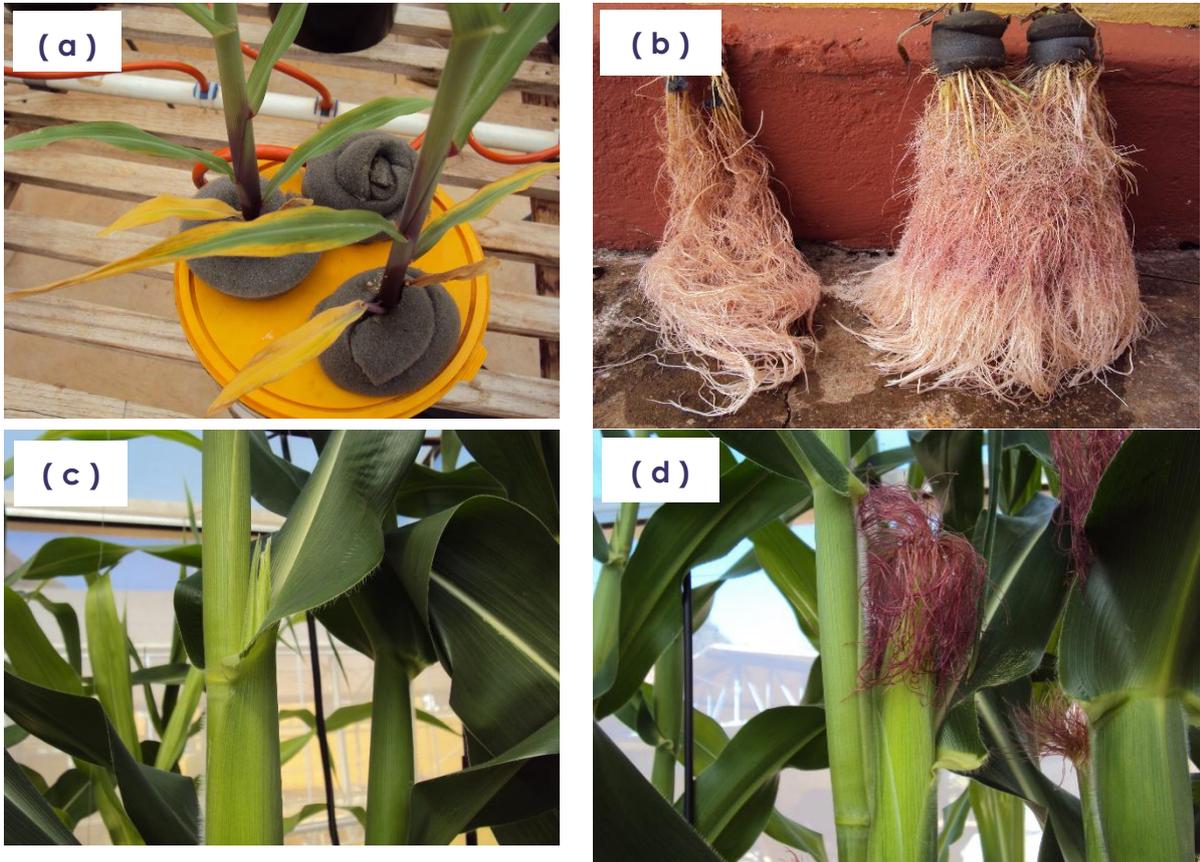
O nitrogênio (N) é um dos nutrientes necessários para o desenvolvimento das plantas, sendo essencial para o crescimento, a produtividade e a qualidade das culturas. Frequentemente, é o principal fator limitante do crescimento vegetal (TANUMIHARDJO et al., 2020).

A carência de nitrogênio costuma surgir durante fases de crescimento acelerado (MARSCHNER, 2012), provocando desenvolvimento lento e reduzido. Um dos sintomas típicos é a clorose em forma de "V" invertido nas folhas mais velhas (Figura 1a), que pode evoluir para necrose, iniciando nas áreas afetadas e avançando ao longo da nervura central (ROMUALDO et al., 2018).

Como o N é um elemento móvel dentro da planta, ele é remobilizado das folhas mais velhas para os tecidos em desenvolvimento, o que explica o surgimento inicial dos sintomas nessas folhas (EPSTEIN; BLOOM, 2006). A clorose observada resulta da função estrutural do nitrogênio na molécula de clorofila, impactando negativamente a fotossíntese (MALAVOLTA, 2006; HAVLIN et al., 2005).

Na deficiência de N para o milho, o sistema radicular da cultura também é prejudicado (Figura 1b), o que acaba restringindo o volume de raízes ocupando o solo e conseqüentemente a absorção de água e dos demais nutrientes. Logo há redução do tamanho de espigas e produtividade da cultura (FIGURAS 1c e 1d) (SILVA, 2015).

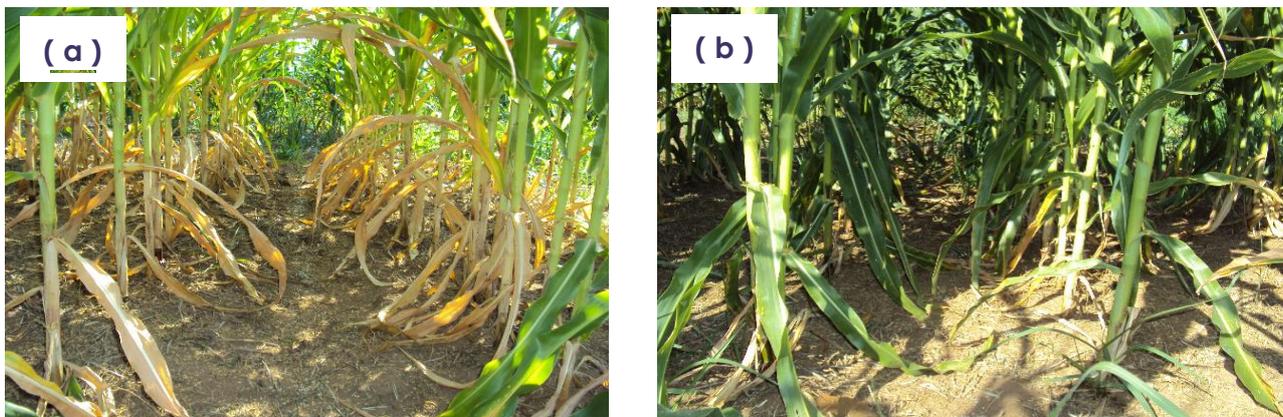
Figura 1. Sintomas visuais de deficiência de nitrogênio em milho: (a) folhas basais no estágio V4 cultivadas com apenas 20% da concentração ideal de N na solução nutritiva; (b) sistema radicular de plantas no estágio R1, comparando o desenvolvimento sob 5% (à esquerda) e 100% (à direita) da dose recomendada de N; (c) espiga de milho formada sob condição de 20% de N; (d) espiga desenvolvida com 100% da concentração de N na solução nutritiva.



Fonte: Silva (2015).

Também é possível observar a senescência precoce nas folhas mais velhas do milho, caracterizada pelo enfraquecimento das plantas, além de um amarelecimento generalizado nas folhas em casos de deficiência de nitrogênio na adubação (DEVECHIO et al., 2023) (FIGURA 2).

Figura 2. Requeima" das folhas mais velhas de milho em campo devido à deficiência de nitrogênio na adubação (a), em comparação com as folhas mais velhas de milho que receberam adubação completa no estágio R1 (b).



Fonte: Devecchio et al. (2023).

Esse sintoma ocorre porque o nitrogênio é um nutriente móvel dentro da planta. Quando há deficiência desse nutriente, ele é translocado das partes mais velhas para as mais jovens. Assim, os primeiros sintomas de carência surgem nas folhas mais antigas, o que no milho é conhecido como "requeima" das folhas basais (COELHO et al., 2005).

b) Fósforo

A deficiência de fósforo nas plantas resulta em crescimento reduzido, folhas estreitas, clorose e o surgimento de manchas arroxeadas nas folhas mais velhas (FIGURA 3a), que podem progredir para necrose (ROMUALDO, 2013). Segundo Taiz e Zeiger (2009), as manchas roxas observadas em plantas com deficiência de fósforo são causadas pelo acúmulo excessivo de antocianina, devido ao acúmulo de fotoassimilados nos tecidos vegetais.

Fornasieri Filho (1992) aponta que, em condições de baixa disponibilidade de fósforo, as plantas de milho apresentam crescimento retardado desde os primeiros estádios de desenvolvimento, com colmos e folhas assumindo coloração arroxeadas.

Figura 3. Sintomas de deficiência de fósforo nas folhas de milho aos 23 DAE (a, b e c). Comparação entre as folhas de milho que não receberam fósforo (a) e aquelas com a dose completa de fósforo (b) aos 31 DAE. Desenvolvimento do sistema radicular das plantas de milho sob omissão completa de fósforo (c) e com adubação completa de fósforo na solução nutritiva aos 59 DAE.



Fonte: Romualdo (2013).

Segundo Coelho et al. (2002), os primeiros sinais de deficiência de fósforo em plantas de milho geralmente surgem quando as plantas ainda são jovens. A sintomatologia inicial é marcada pela coloração arroxeada das folhas, e os colmos apresentam-se frágeis e finos.

O sistema radicular da cultura do milho é intensamente restringido em situação de deficiência de P (FIGURAS 3c e 3d) (ROMUALDO, 2013). O fósforo atua na constituição do ATP, fornecendo energia para todos os processos bioquímicos e fisiológicos da planta e crescimento radicular (MARSCHNER, 2012).

De acordo com Malavolta (2006), a deficiência de fósforo afeta o crescimento das plantas, pois esse nutriente está envolvido em funções estruturais e nos processos de transferência e armazenamento de energia, impactando diversos processos metabólicos, como a síntese de proteínas e ácidos nucleicos.

c) Potássio

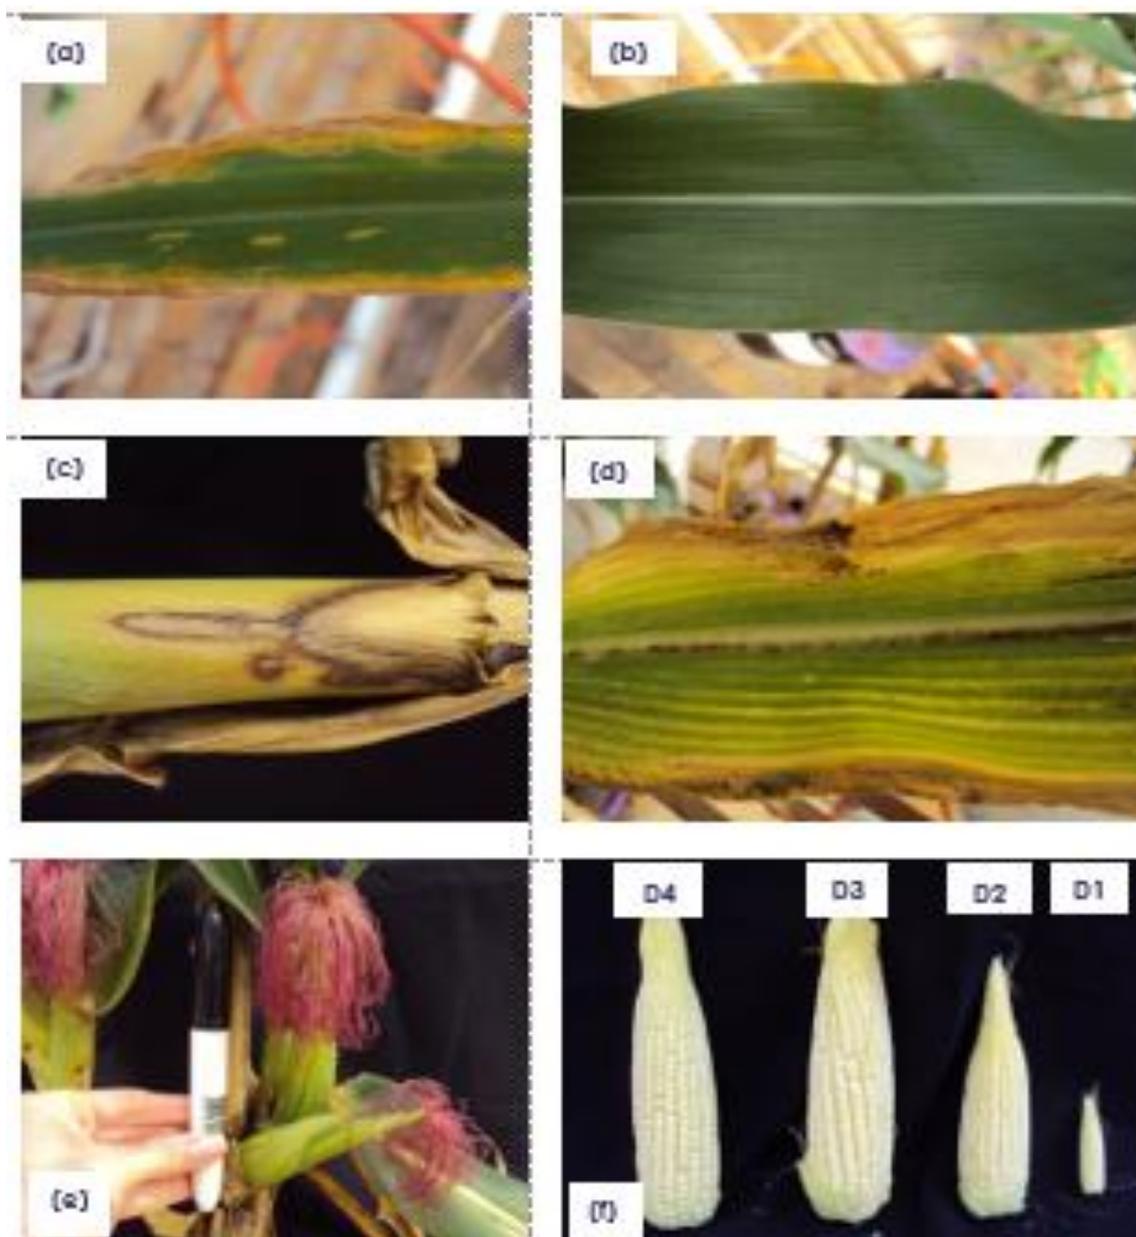
O potássio (K) é o segundo macronutriente mais abundante nas plantas, perdendo apenas para o nitrogênio, com sua maior absorção ocorrendo durante o desenvolvimento vegetativo, o que indica uma maior demanda por K na fase inicial, sendo essencial para o "arranque" da planta (COELHO, 2007). Conforme Cantarella et al. (2022) e Malavolta (2006), os primeiros sinais de deficiência de K surgem nas folhas mais velhas, caracterizando-se por clorose, seguida de necrose nas margens e pontas das folhas (FIGURA 4a), além de uma redução no crescimento das plantas e do sistema radicular.

Esses sintomas são atribuídos à importante função do K na fotossíntese das plantas (ROMHELD; KIRKBY, 2010). Segundo Zhao et al. (2001), a manutenção da fotossíntese depende do K, e sua deficiência reduz a atividade fotossintética e o teor de clorofila. Szczerba et al. (2009) destacam que o K desempenha papéis essenciais tanto nos processos bioquímicos quanto biofísicos das plantas.

Outro sinal típico de deficiência de K é o surgimento de manchas marrons ao longo da nervura das folhas mais velhas e dos colmos quando ocorre omissão total de K (FIGURAS 4c e 4d) (SILVA, 2015; ROMUALDO, 2013).

De acordo com Malavolta e Crocomo (1982), nas áreas afetadas pela falta de K (bordas, nervuras e pontas das folhas mais velhas), ocorre o acúmulo de putrescina, um composto fitotóxico originado de aminoácidos básicos. Em plantas com deficiência de K, a síntese de proteínas é prejudicada e há acúmulo desses aminoácidos, o que resulta em um aumento considerável nos níveis de putrescina.

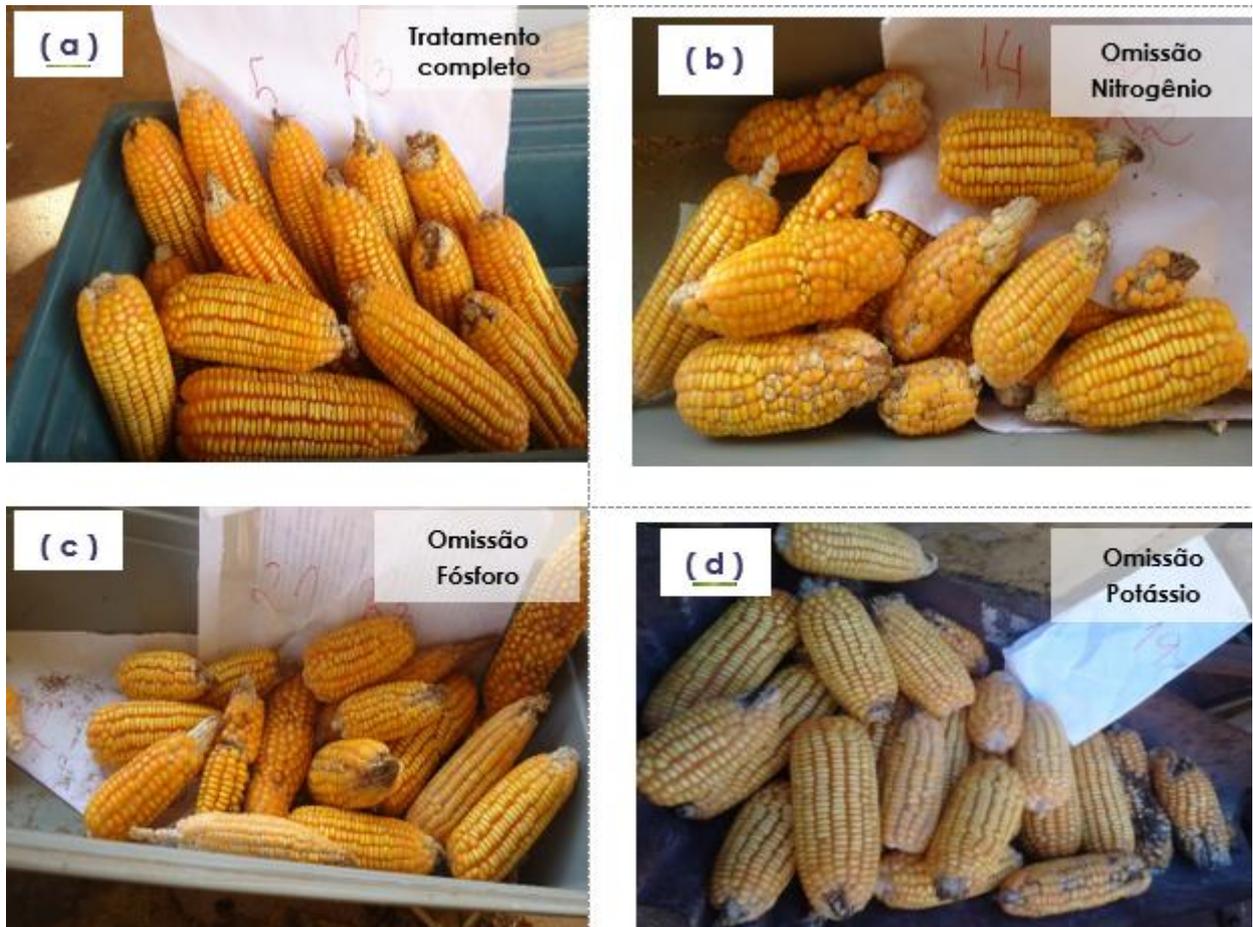
Figura 4. Folha mais velha de plantas de milho com deficiência de potássio (5% de K na solução nutritiva – Dose 1 “D1”) (a), em comparação com a folha de uma planta sem deficiência (b) no estágio V8. Acúmulo de putrescina no colmo (c) e na folha mais velha (d), além de embonecamento (e) das plantas de milho no estágio R1, cultivadas com a Dose 1 (D1). Embonecamento (f) nas plantas de milho submetidas a diferentes doses de potássio na solução nutritiva (SILVA, 2015). As doses de potássio D1, D2, D3 e D4 correspondem a 5%, 20%, 60% e 100% da quantidade total de K na solução nutritiva.



Fonte: Silva (2015).

Os sinais visíveis de carência nutricional afetam diretamente a produtividade das culturas, como evidenciado por Silva (2015) e Romualdo (2013) (FIGURAS 4a, 4b; FIGURA 5).

Figura 5. Características das espigas de milho sem deficiência nutricional (a) comparadas com espigas de plantas com omissão de Nitrogênio(b), de Fósforo (c) e de Potássio (d).



Fonte: Romualdo (2013).

d) Cálcio

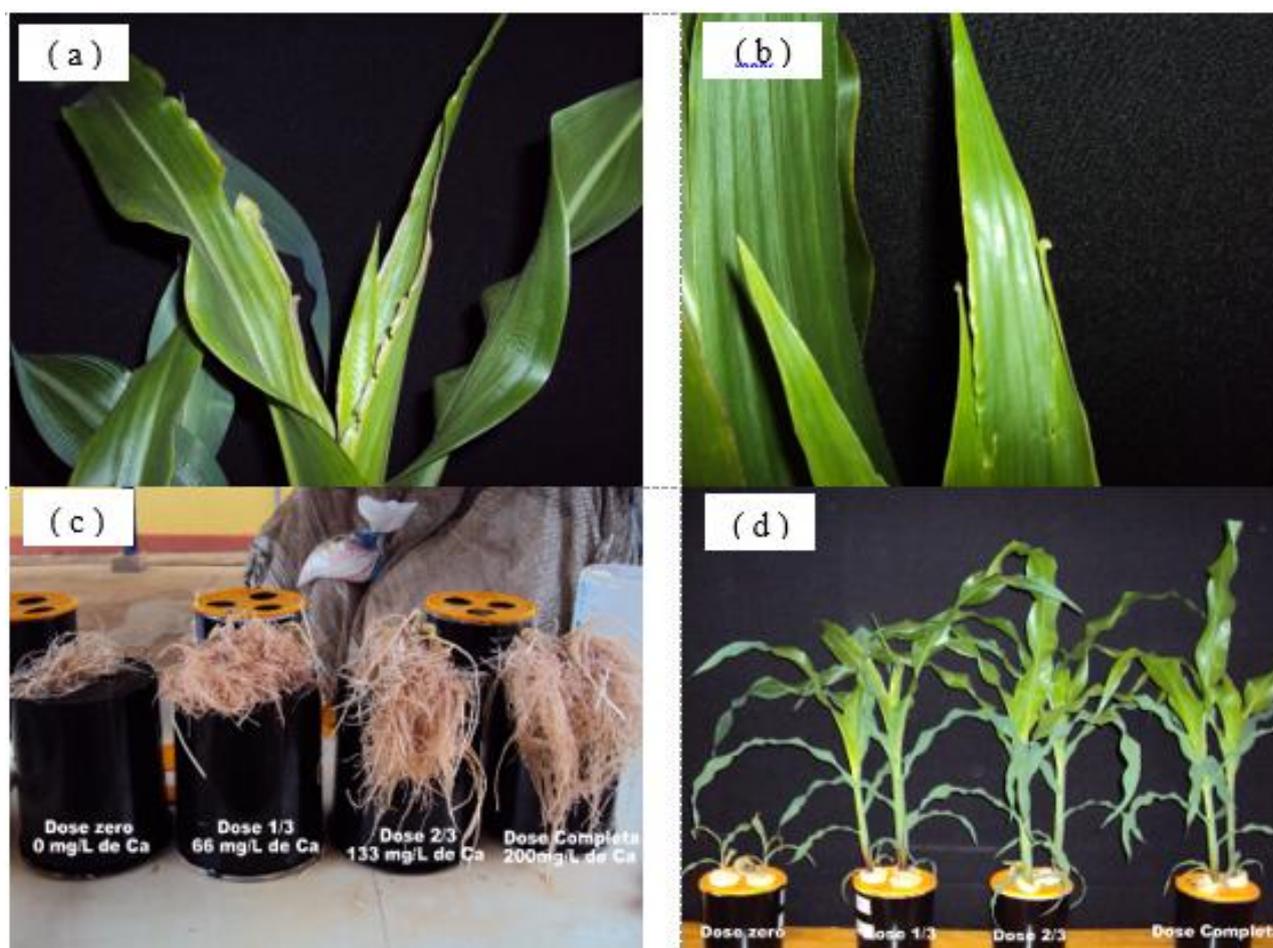
Em plantas com deficiência de cálcio, os primeiros sinais surgem nas folhas mais novas e nas regiões meristemáticas, apresentando deformações nas bordas das folhas, um sintoma conhecido como dilaceramento (DEVECHIO et al., 2022). Isso ocorre porque essas regiões têm alta demanda por cálcio, e o nutriente, uma vez fixado nos tecidos mais antigos, não é redistribuído eficientemente para as partes em crescimento ativo (EPSTEIN; BLOOM, 2006).

Um dos sintomas mais marcantes é a necrose na extremidade dos primórdios foliares, que evolui para uma morte descendente característica (DEVECHIO et al., 2022).

O cálcio é fundamental para a estabilidade estrutural e funcional das membranas celulares e da parede celular. Quando há deficiência, há comprometimento da integridade das membranas, levando ao extravasamento

do conteúdo citoplasmático, à desorganização da compartimentação celular e à redução da ligação do cálcio com a pectina da parede celular (MALAVOLTA, 2006) (FIGURA 6).

Figura 6. Dilaceramento das bordas das folhas de milho, conhecidas como dilaceramento, observadas em plantas cultivadas com 1/3 da dose recomendada de cálcio (a) e com 2/3 da dose (b), aos 29 dias após a emergência (DAE). Indícios de deficiência de cálcio também são visíveis nas raízes (c) e na parte aérea (d) de plantas no estágio V4, expostas a diferentes concentrações de cálcio na solução nutritiva (da esquerda para a direita: ausência total, 1/3 da dose, 2/3 da dose e dose completa do nutriente).



Fonte: Devecchio et al. (2022); Silva (2011)

e) Magnésio

Em plantas com deficiência de magnésio, observa-se inicialmente nas folhas mais velhas uma clorose entre as nervuras, que permanecem esverdeadas, além de curvatura do ápice da lâmina foliar para baixo (SILVA et al., 2014), conforme ilustrado na Figura 7.

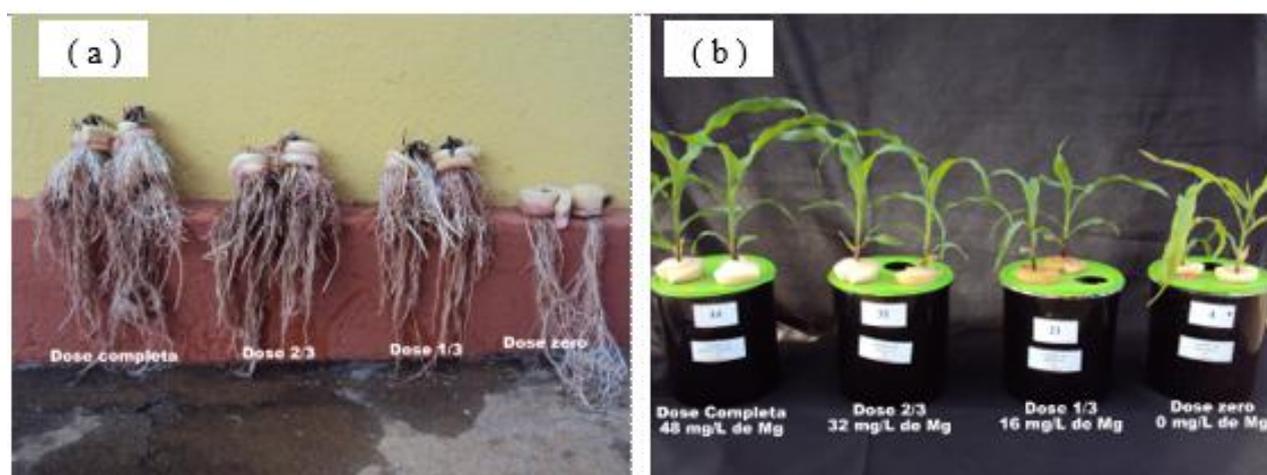
Figura 7. Sintomas visuais de deficiência de magnésio em milho cultivado sem o fornecimento do nutriente na solução nutritiva, observados aos 28 dias (a) e aos 48 dias após a emergência (DAE) (b).



Fonte: Silva (2011) e Silva et al. (2014)

Ao contrário do cálcio, o magnésio possui alta mobilidade dentro da planta, sendo facilmente transferido das folhas mais velhas para os tecidos jovens em desenvolvimento. Por isso, os sinais de deficiência manifestam-se inicialmente nas folhas maduras (EPSTEIN; BLOOM, 2006). A clorose avança em direção ao ápice da folha, que pode adquirir coloração bronzeada e evoluir para necrose (FIGURA 8).

Figura 8. Sintomas de deficiência de magnésio observados nas raízes de plantas de milho no estágio V6 (a) e na parte aérea aos 15 dias após a emergência (b), cultivadas com diferentes concentrações de magnésio na solução nutritiva, variando da dose completa à ausência total do nutriente (da esquerda para a direita: dose completa, 2/3, 1/3 e zero).



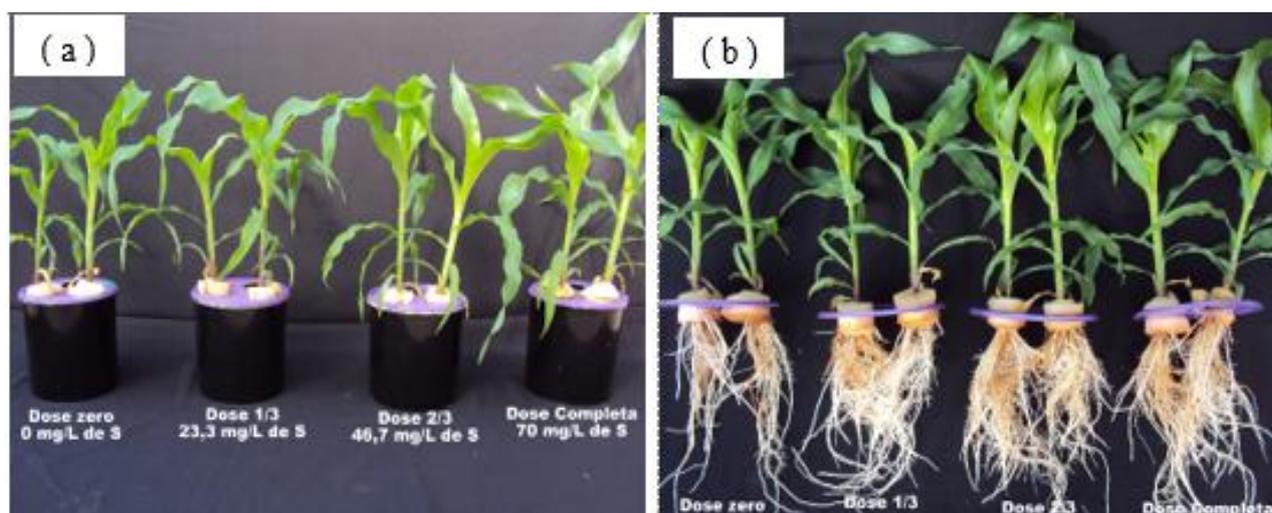
Fonte: Silva (2011)

De acordo com Fontes (2004), a deficiência de magnésio em plantas pode provocar o surgimento de manchas amareladas e necrosadas, com tonalidade marrom, especialmente nas folhas mais velhas. Além disso, a ausência desse nutriente resulta em significativa limitação no crescimento tanto das raízes (Figura 8a) quanto da parte aérea (Figura 8b), conforme relatado por Silva et al. (2014).

f) Enxofre

O enxofre, assim como o nitrogênio, é fundamental na formação de aminoácidos e proteínas, estando diretamente envolvido na composição desses compostos essenciais ao metabolismo vegetal (MARSCHNER, 2012), e tem alta mobilidade no floema, manifestando os sintomas iniciais nas folhas mais novas (EPSTEIN; BLOOM, 2006) (FIGURA 9).

Figura 9. Alterações visuais provocadas pela deficiência de enxofre podem ser observadas na parte aérea (a, c) e no sistema radicular (b, d) de plantas de milho cultivadas sob diferentes concentrações de enxofre na solução nutritiva (dispostas da esquerda para a direita: ausência total, 1/3, 2/3 e dose integral de enxofre), avaliadas aos 26 dias após a emergência (a, b) e aos 59 dias após a emergência (c, d).



Fonte: Silva (2011).

Segundo Malavolta (2006), a carência de enxofre nas plantas compromete seu desenvolvimento, já que esse nutriente está envolvido na formação de proteínas. Além disso, sua deficiência pode afetar a firmeza da planta, uma vez que o enxofre contribui para a síntese de enzimas, vitaminas e compostos de defesa, além de influenciar negativamente o valor nutricional das plantas por interferir na formação dos grãos (MALAVOLTA; MORAES, 2007).

4. Tecnologias para identificação da deficiência nutricional

A identificação da deficiência nutricional em plantas tem sido amplamente utilizada e discutida, no intuito de possibilitar intervenções mais precisas em sistemas

de produção vegetal, por meio de práticas de manejo e adubação (URANO et al., 2006).

A análise química foliar para identificar deficiências nutricionais é um processo dispendioso e demorado, além de, em muitos casos, ser ineficaz para corrigir a deficiência dentro do ciclo de cultivo (BAESSO et al., 2023). Outro aspecto importante é o estágio de desenvolvimento da planta, pois, caso a deficiência seja detectada em uma fase avançada, pode ser tarde para realizar uma correção eficaz no mesmo ciclo produtivo (WU et al., 2007).

Portanto, os testes que medem a concentração de nutrientes nas folhas têm a desvantagem de não permitir correções rápidas, sendo úteis apenas para identificar deficiências ou excessos em estágios específicos do desenvolvimento da planta (ARGENTA et al., 2002). A utilização da análise química foliar para avaliação nutricional apresenta limitações que devem ser levadas em consideração ao se adotar essa técnica (SALVADOR et al., 1999).

A diagnose visual, embora mais prática e rápida, também tem suas limitações e pode ser imprecisa, gerando erros na interpretação (BAESSO et al., 2007). A deficiência de um nutriente geralmente se torna visível apenas após uma série de eventos, conforme descrito por Malavolta (2006). Frequentemente, a detecção visual só ocorre quando a deficiência já está em um estágio avançado, o que pode comprometer uma parte significativa da produção. Além disso, em estágios mais avançados de crescimento, os sintomas de deficiência de vários nutrientes podem ser semelhantes, dificultando o diagnóstico (FONTES, 2004).

Dessa forma, o desenvolvimento de novas tecnologias para identificar deficiências nutricionais de maneira antecipada e precisa pode ser fundamental para otimizar a adubação e melhorar a eficiência produtiva nas culturas.

Redes Neurais Convolucionais (CNN), técnica no domínio do Deep Learning, tem sido aplicadas em várias áreas do conhecimento, incluindo as ciências agrícolas (KAMILARIS et al., 2017). Modelos baseados em CNN demonstram potencial para abordar problemas complexos com precisão e rapidez, desde que haja conjuntos de dados suficientemente grandes que definam o problema (KAMILARIS; PRENAFETA-BOLDÚ, 2018).

Percebe-se grande aplicabilidade para utilização de imagens digitais para reconhecimento de padrões nas plantas. Pesquisas recentes sobre métodos de inteligência artificial (IA) aplicados a modelos de previsão e classificação de plantas vem demonstrando resultados positivos. Gokulnath e UshaDevi (2017) empregaram técnicas de aprendizado de máquina para a detecção automática de doenças de plantas. Escalante et al. (2019) usaram imagens RGB com CNN para estimar a adubação com nitrogênio.

Romualdo et al. (2014) propuseram um sistema de visão artificial para analisar e interpretar imagens RGB (vermelho, modelo de cor verde e azul) e identificar a deficiência de nitrogênio (N) em vários estádios de desenvolvimento da cultura do milho. Pesquisas recentes utilizaram técnicas de análise de imagens digitais para identificação de deficiência de magnésio (SILVA et al., 2014), de cálcio (DEVECHIO et al., 2022) e de boro (LUZ et al., 2018) em folhas de milho. Confalonieri et al. (2015) utilizaram uma variação do índice DGCI (Dark Green Colour Index) para estimar níveis de N em folhas usando imagens RGB, produzindo um erro quadrático médio de 14,9% para estimativa de N. Baesso et al. (2023) utilizaram um modelo de aprendizagem para classificação do status de nitrogênio do feijão usando imagens digitais. Mancin et al. (2022) utilizaram a visão computacional para classificação do estado nutricional de nitrogênio no capim Xaraés e concluíram que o método fornece uma ferramenta rápida e econômica para definição de época e dose de adubação nitrogenada na pastagem.

Silva et al. (2014), ao investigarem métodos para identificar a deficiência de magnésio (Mg) em um híbrido de milho, constataram que a análise de imagens digitais coloridas foi eficaz para diagnosticar as doses do nutriente, apresentando uma taxa de acerto de 75,5% no estágio V4 (quando as quatro primeiras folhas estão completamente desenvolvidas). Romualdo et al. (2014), em uma pesquisa similar focada na deficiência de nitrogênio (N) em milho, também utilizaram imagens digitais coloridas e observaram altas taxas de precisão nos métodos aplicados, com acertos de 82,5% no estágio V4 e 96,5% no estágio R1. Baesso et al. (2007) exploraram o uso de índices espectrais provenientes de imagens digitais coloridas para analisar a resposta de feijoeiros a diferentes doses de nitrogênio.

A aplicação de ferramentas tecnológicas que utilizem o processamento de imagem combinada com inteligência artificial, permite ao produtor identificar o estado nutricional da cultura, oferecendo uma alternativa viável para a extração de características nutricionais da planta. Essa ferramenta possibilitará a estimativa do status de nutriente, contribuindo para a tomada de decisões sobre possíveis intervenções e ajustes no manejo e adubação.

Referências Bibliográficas

- ARGENTA, G. et al. Parâmetros de planta como indicadores do nível de nitrogênio na cultura do milho. **Pesquisa Agropecuária Brasileira**, v.37, n.4, p.519-527, 2002.
- BAESSO, M. M. et al. Status nutricional de nitrogênio no feijoeiro utilizando imagens digitais coloridas. **Engenharia Agrícola**, v.27, n.2, p.520-528, 2007.

BAESSO, M. M. et al. Deep learning-based model for classification of bean nitrogen status using digital canopy imaging. **Engenharia Agrícola**, v. 43, n. 2, e20230068, 2023.

CALIGARIS, B. S. A. et al. A importância do Plano Nacional de Fertilizantes para o Futuro do Agronegócio e do Brasil. **Revista de Política Agrícola**, ano 31, n. 1, p. 03-08, 2022.

CANTARELLA, H. et al. **Boletim 100: Recomendações de adubação e calagem para o estado de São Paulo**. Campinas: Instituto Agronômico, 2022. 489p.

COELHO, A. M. et al. **Cultura do milho: diagnose foliar do estado nutricional da planta**. Circular técnica 45, Sete Lagoas: EMBRAPA Milho e Sorgo. 2002.

COELHO, A. M. et al. Nitrogênio mineral no solo e índice de clorofila na folha como indicadores da necessidade de nitrogênio para o milho. In: **SIMPÓSIO INTERNACIONAL DE AGRICULTURA DE PRECISÃO**. Sete Lagoas. Anais. Sete Lagoas: Embrapa Milho e Sorgo: UFV: SBEA: CIGR, 2005. 6p. CD-ROM.

COELHO, A. M. **Manejo da adubação nitrogenada na cultura do milho**. Circular Técnica 96. Sete Lagoas: Embrapa Milho e Sorgo, 2007. 11 p.

CONAB - Companhia Nacional de Abastecimento. **Participação dos fertilizantes nos custos de produção**. MT Econômico, 2023. Disponível em: <https://matogrossoeconomico.com.br/agronegocio-mato-grosso/participacao-dos-fertilizantes-nos-custos-de-producao-chega-a-37-em-mt-aponta-conab/>. Acesso em: 16 abr. 2025.

CONAB - Companhia Nacional de Abastecimento. **Acompanhamento da safra brasileira: grãos**. Companhia Nacional de Abastecimento. Brasília: Conab, 2024. Disponível em: <<http://www.conab.gov.br>>. Acesso em 9 jul. 2024.

CONFALONIERI, R. et al. Melhorando as estimativas de conteúdo de nitrogênio em plantas in vivo a partir de imagens digitais: veracidade e precisão de uma nova abordagem em comparação com outros métodos e dispositivos comerciais. **Engenharia de Biosistemas**, v.135, n. 15, p. 21–30, 2015.

CROTTY, F. V. et al. Impact of Using Alternative Forages on the Nutrient Value within Slurry and Its Implications for Forage Productivity in Agricultural Systems. **Plos One**. v.9, n.5, e97516, 2014.

DEVECHIO, F.F.S. et al. Calcium deficiency diagnosis in maize leaves using imaging methods based on texture analysis. **Journal of Agricultural Science**, v. 14, n.3, 2022.

DEVECHIO, F.F.S. et al. Use of image analysis to detect nutrient deficiencies in maize cultivated in the field subjected to omission of nitrogen. **Brazilian Journal of Animal and Environmental Research**, v.6, n.1, p. 177-188, 2023.

EPSTEIN, E; BLOOM, A.J. **Nutrição mineral das plantas: princípios e perspectivas**. 2.ed. Tradução de Maria Edna Tenório Nunes. Londrina: Editora Planta, 2006. 403p.

ESCALANTE, H. J. et al. Barley yield and fertilization analysis from UAV imagery: a deep learning approach. **International Journal of Remote Sensing**, v. 40, n. 7, p. 2493-2516, 2019.

FAO – **Food and Agriculture Organization of the United Nations**. Disponível em: <<http://faostat.fao.org>>. Acesso em 9 jul. 2024.

FONTES, P. C. R. **Diagnóstico do estado nutricional das plantas**. Viçosa: Editora UFV (Universidade Federal de Viçosa), 2004. 122p.

FORNASIERI FILHO, D. **A cultura do milho**. Jaboticabal: FUNEP, 1992. 273p.

GASPAROTTO, A. C. **Obtenção de imagens digitais e espectrometria da cultura do milho e sua relação com produtividade em diferentes doses de nitrogênio**. 107 f. 2014. Dissertação (Mestrado em Agronomia) - Universidade Estadual de Maringá, Maringá, PR.

GOKULNATH, B.; USHADEVI, G. A survey on plant disease prediction using machine learning and deep learning techniques. **Inteligencia Artificial**. v. 22, n. 63, p.10-19, 2017.

HAVLIN, J. L. et al. **Soil Fertility and Nutrient Management: An Introduction to Nutrient Management**. Upper Saddle River, NJ: Pearson/Prentice Hall. 2005. 515p.

KAMILARIS, A.; KARTAKOULLIS, A.; PRENAFETA-BOLDÚ, F.X. A review on the practice of big data analysis in agriculture. **Computers and Electronics in Agriculture**, v. 143, p. 23-37, 2017.

KAMILARIS, A.; PRENAFETA-BOLDÚ, F.X. Deep learning in agriculture: a survey. **Computers and Electronics in Agriculture**, v. 47, p. 70-90, 2018.

LUZ, P. H. C. et al. Boron deficiency precisely identified on growth stage V4 of maize crop using texture image analysis. **Communications in Soil Science and Plant Analysis**, v.49, p.159-169. 2018.

MALAVOLTA, E. **Manual de nutrição de plantas**. São Paulo: Agronômica Ceres, 2006. 638p.

MALAVOLTA, E.; MORAES; M.F. Fundamentos do nitrogênio e do enxofre na nutrição mineral de plantas cultivadas. In: YAMADA, T.; ABDALLA, S.R.S.; VITTI, G.C (Ed.). **Nitrogênio e enxofre na agricultura brasileira**. Piracicaba: Internacional Plant Nutrition Institute – Brasil, 2007. p.189-249.

MALAVOLTA, E.; CROCOMO, O. J. O potássio e a planta. In: **Potássio na Agricultura Brasileira**, Londrina, 1982. Anais, Piracicaba, Instituto Da Potassa e Fosfato: Institute Internacional da Potassa, p.95-162, 1982.

MANCIN, W. R. et al. The use of computer vision to classify Xaraés grass according to nutritional status in nitrogen. **Revista Ciência Agronômica**, v. 53, art. e20207797, p. 1–12, 2022.

MANZEKE, G.M., MAPFUMO, P., MTAMBANENGWE, F. Soil fertility management effects on maize productivity and grain zinc content in smallholder farming systems of Zimbabwe. **Plant Soil**. v. 361, p.57–69, 2012.

MARSCHNER, H. **Mineral nutrition of higher plants**. 3.ed London: Elsevier, 2012. 643p.

PEREIRA, R. G. et al. Rendimento do sorgo granífero adubado com nitrogênio e fósforo no semiárido brasileiro. **Revista Brasileira de Milho e Sorgo**, v. 13, n. 3, p. 285-299, 2014.

ROMHELD, V.; KIRKBY, E. A. Research on potassium in agriculture: Needs and prospects. **Plant & Soil**, v.335, p.155–180, 2010.

ROMUALDO, L. M. **Utilização da visão artificial para diagnose nutricional de nitrogênio, fósforo, potássio e manganês em milho**. 150 f. Tese (Doutorado) – Faculdade de Zootecnia e Engenharia de Alimentos – Universidade de São Paulo. Departamento de Zootecnia. Área de Concentração: Qualidade e produtividade animal. 2013.

ROMUALDO, L. M. et al. Use of artificial vision techniques for diagnostic of nitrogen nutritional status in maize plants. **Computer Electronics Agriculture**, v. 104, p. 63–70, 2014.

ROMUALDO, L. M. et al. Spectral indexes for identification of nitrogen deficiency in maize. **Revista Ciência Agronômica**, v. 49, n. 2, p. 183-191, 2018.

SALVADOR, J.O.; MOREIRA, A.; MURAOKA, T. Efeito da omissão combinada de N, P, K e S nos teores foliares de macronutrientes em mudas de goiabeira. **Scientia Agrícola**, v.56, n.2, p. 501-507, 1999.

SZCZERBA, M.W.; BRITTO, D.T.; KRONZUCKER, H.J. K⁺ transport in plants: Physiology and molecular biology. **Journal of Plant Physiology**. v.166, p.447-466, 2009.

SILVA, E. B. et al. Visual symptoms of nutrient deficiency in physic nut. **Pesquisa Agropecuária Brasileira**, v. 44, n. 4, p. 392–397, 2009.

SILVA, F. F. **Sistema de visão artificial para a identificação da nutrição de milho submetido a níveis de cálcio, magnésio e enxofre**. 143 f. Dissertação (Mestrado) – Faculdade de Zootecnia e Engenharia de Alimentos – Universidade de São Paulo.

Departamento de Zootecnia. Área de Concentração: Qualidade e produtividade animal. 2011.

SILVA, F. F. et al. A diagnostic tool for magnesium nutrition in maize based on image analysis of different leaf sections. **Crop Science**, v.54, p.738-745, 2014.

SILVA, F. F. **Reconhecimento de padrões de nutrição para nitrogênio e potássio em híbridos de milho por análise de imagens**. 161 f. Tese (Doutorado) – Faculdade de Zootecnia e Engenharia de Alimentos – Universidade de São Paulo. Departamento de Zootecnia. Área de Concentração: Qualidade e produtividade animal. 2015.

TAIZ, L.; ZEIGER, E. **Fisiologia vegetal**. Porto Alegre: Artmed. 2009. 848p.

TANUMIHARDJO, S. A. et al. Maize agro-food systems to ensure food and nutrition security in reference to the Sustainable Development. **Global Food Security**, v.25, 100327, 2020.

URANO, E. O. M. et al. Avaliação do estado nutricional da soja. **Pesquisa Agropecuária Brasileira**. v.41, n.9, p.1421-1428, 2006.

ZHAO, D.; OOSTERHUIS, D. M.; BEDNARZ, C. W. Influence of potassium deficiency on photosynthesis, chlorophyll content, and chloroplast ultrastructure of cotton plants. **Photosynthetica**. v.39, p.103–109, 2001.

WU, J. et al. Comparison of petiole nitrate concentrations, SPAD chlorophyll readings, and QuickBird satellite imagery in detecting nitrogen status of potato canopies. **Field Crops Research**, v.101, n.1, p.96-103, 2007.

Identificação de deficiência de micronutrientes em milho

Ronilson Martins Silva; Mário Antônio Marin; Liliane Maria Romualdo Altão; Pedro Henrique Cerqueira Luz; Fernanda de Fátima da Silva Devechio

1. Introdução

A produção agrícola de qualidade elevada é essencial para o crescimento econômico e social sustentável de um país, sendo essencial para satisfazer a demanda global de alimentos. No entanto, vários fatores como a nutrição da planta, ambiente e clima podem afetar negativamente o rendimento e a qualidade das culturas (BERA et al., 2024).

O milho (*Zea mays* L.) é uma das culturas mais relevantes em termos econômicos e sociais, sendo também uma das que mais demandam fertilizantes. O manejo inadequado dos nutrientes do solo pode gerar sérios danos às plantas, resultando em prejuízos financeiros significativos (BERA et al., 2024). A insuficiência de nutrientes é um fator crítico que limita o rendimento da produção de grãos, e, portanto, é essencial manter a planta adequadamente nutrida para maximizar seu desenvolvimento (RAMBO et al., 2004).

Com o aumento da demanda por proteínas de origem animal, há uma crescente procura por milho, o que intensifica os desafios em atender a essa necessidade. A concorrência com outras culturas por espaços agrícolas, junto à expectativa de expansão dos mercados internacionais para o cereal e seus subprodutos, destaca a importância de pesquisas que busquem aumentar a eficiência da produção e a competitividade no mercado (ALVAREZ et al., 2006).

Após a globalização, os objetivos de aumentar a produtividade agrícola e reduzir os custos de produção se tornaram essenciais. A combinação do potencial genético das plantas com o uso eficiente de nutrientes pode atingir esses dois objetivos (HORN et al., 2006).

Maximizar a eficiência no uso de nutrientes é fundamental para reduzir a dependência de fertilizantes, que são elevados em custo e impacto ambiental (CROTTY et al., 2014).

Compreender como e onde a deficiência de nutrientes impacta a produção de grãos é vital para uma gestão mais eficiente das necessidades nutricionais das culturas (LORDKAEW et al., 2011).

O desenvolvimento de métodos mais eficazes para avaliar o estado nutricional das plantas, combinado com a necessidade de melhorar a eficiência no uso dos nutrientes do solo ou aplicados por meio de fertilização, visando a maximização da produtividade das culturas, tem impulsionado a busca por novas tecnologias, tanto sob a ótica agrônômica quanto econômica e ambiental.

Nesse contexto, o uso de métodos que possibilitem a detecção precisa e rápida do estado nutricional das plantas, sem depender da análise visual humana, torna-se uma ferramenta valiosa para o manejo da nutrição do milho. Isso facilita o fornecimento de fertilização dentro do mesmo ciclo de cultivo, algo que, com os métodos atuais de diagnóstico visual ou análise química de tecidos, se mostra difícil, dispendioso e demorado, além de tornar impossível a correção da deficiência no mesmo ciclo da cultura (SILVA, 2011).

2. Cultura do milho

O milho ocupa uma posição de destaque entre as principais culturas de cereais no mundo (PENG et al., 2013), com a produção global saltando de 820 milhões de toneladas em 2009 para 1,44 bilhão de toneladas em 2022 (FAO, 2024).

Considerado um dos pilares da agricultura, o milho é um insumo fundamental para o agronegócio, utilizado principalmente na alimentação animal, tanto in natura quanto na forma de farelo, ração ou silagem (PINAZZA, 1993). Seu grande potencial produtivo de matéria seca, aliado à capacidade de gerar grãos nutritivos, torna-o um excelente volumoso para animais (ALVAREZ et al., 2006). No âmbito humano, o milho é utilizado na fabricação de mais de 500 produtos derivados (NOGUEIRA JÚNIOR et al., 1987), e desempenha papel crucial em diversos setores industriais, com grande relevância socioeconômica em várias regiões do mundo.

O aumento da produção de milho é essencial para suprir as crescentes demandas por alimentação animal e biocombustíveis, visto que o cereal é matéria-prima para a produção de inúmeros produtos e também para as cadeias produtivas de suínos e aves, que consomem aproximadamente 70% do milho mundial (CHEN et al., 2011). O desenvolvimento da produção e do mercado do milho deve ser compreendido dentro do contexto das cadeias produtivas e dos sistemas agro-industriais (EMBRAPA, 2004).

Em comparação com outras culturas, o milho tem apresentado avanços consideráveis nas áreas de ecologia, fisiologia e nutrição, proporcionando uma melhor compreensão das suas interações com o ambiente de cultivo (FANCELLI, 2010).

Para alcançar seu pleno potencial produtivo, o milho exige que suas necessidades nutricionais sejam atendidas adequadamente, dado o alto consumo de nutrientes do solo (AMARAL FILHO et al., 2005). Assim, é essencial garantir que a planta esteja sempre bem nutrida. O ambiente de cultivo é o principal fator determinante para o desempenho e produtividade do milho, independentemente da tecnologia utilizada (FANCELLI, 2010). O uso de cultivares mais produtivos e adaptados às condições locais é uma estratégia eficaz para aumentar a produtividade da cultura sem demandar grandes investimentos financeiros (FORNASIERI FILHO, 1992).

3. Nutrição mineral do milho

A obtenção de alta produtividade depende diretamente de uma nutrição equilibrada. Sabe-se que plantas bem nutridas não só apresentam maior resistência a doenças, mas também são capazes de atingir seu potencial máximo de produção (OLIVEIRA; CALDAS, 2004). O sucesso em termos de produtividade é, em grande parte, consequência de um suprimento adequado, distribuição eficiente e acúmulo de nutrientes pela planta (FONTES et al., 2005).

A cultura do milho é frequentemente classificada como altamente exigente em relação à fertilidade do solo para alcançar seu rendimento máximo (PAPONOV; ENGELS, 2003). Como resultado, o milho é uma das culturas mais dependentes do uso de fertilizantes, sendo essencial que haja um equilíbrio adequado entre a disponibilidade de nutrientes no solo e o seu acúmulo nas plantas, o que impacta diretamente no desenvolvimento da cultura (BONFIM-SILVA; MONTEIRO, 2010).

Portanto, a falta de nutrientes necessários é um dos principais fatores que limitam o rendimento de grãos do milho (RAMBO et al., 2004). Coelho (2006) enfatiza que a cultura do milho é especialmente sensível à deficiência de micronutrientes como Zinco (Zn), seguido de Cobre (Cu), Ferro (Fe) e Manganês (Mn).

Além disso, estudos de Jamami et al. (2006) alertam que o uso crescente de calcário e fertilizantes fosfatados, visando aumentar a produtividade, pode contribuir significativamente para a insolubilização de micronutrientes, como Boro (B) e Zinco (Zn). Por isso, é fundamental usar corretivos e fertilizantes de maneira racional para garantir o sucesso da produção (HEINRICHS et al., 2008).

A deficiência de nutrientes nas fases iniciais de crescimento compromete o desenvolvimento das plantas e resulta em rendimentos reduzidos na colheita (ABEYWARDANA et al., 2023). Por isso, é essencial estimar corretamente a quantidade de fertilizante a ser aplicada no solo para atender às necessidades nutricionais da cultura (BAESSO et al., 2007).

Nos últimos anos, a agricultura tem enfrentado mudanças significativas devido ao aumento dos custos de produção, o que impacta a rentabilidade das culturas, especialmente para grãos como o milho. A adubação é um dos principais fatores que influenciam a produtividade e a sustentabilidade da atividade agrícola. O uso de fertilizantes pela cultura do milho tem aumentado consideravelmente, acompanhando o aumento da sua produtividade (ARAÚJO et al., 2008).

O monitoramento das necessidades nutricionais da cultura e do seu estado nutricional é um fator de grande importância para o sucesso do processo produtivo. No entanto, com os custos elevados dos fertilizantes, é necessário otimizar seu uso (DIAS et al., 2004).

De acordo com Ferreira et al. (2024), cada nutriente segue um padrão específico de absorção. No caso do híbrido Pioneer® 30F35, cerca de 50% dos micronutrientes, como Boro (B), Ferro (Fe), Zinco (Zn) e Manganês (Mn), são absorvidos antes do florescimento, enquanto o Cobre (Cu) é absorvido em maior quantidade após esse estágio.

Conhecer o comportamento da planta no uso de nutrientes é fundamental para ajustar o sistema de cultivo, otimizando a eficiência no aproveitamento desses nutrientes (VIANA, 2007).

3.1. Avaliação nutricional da cultura do milho

A avaliação do estado nutricional das plantas tem sido amplamente utilizada para proporcionar intervenções mais precisas nos sistemas de produção agrícola, especialmente por meio de práticas de manejo e adubação (URANO et al., 2006). O monitoramento dos níveis de nutrientes nas plantas de milho visa diagnosticar a necessidade de aplicação de fertilizantes, uma vez que a utilização excessiva de nutrientes pode levar à contaminação das águas superficiais e subterrâneas (ARGENTA et al., 2002).

Uma das abordagens para detectar deficiências nutricionais é a análise química das folhas, permitindo determinar os teores de nutrientes presentes nas plantas (REIS et al., 2006). O princípio fundamental deste método é que as folhas desempenham um papel central nos processos fisiológicos e metabólicos das plantas, e, por isso, o conteúdo mineral nelas presente deve estar diretamente relacionado com o desenvolvimento e aumento da produção (MALAVOLTA, 2006). Contudo, na prática, realizar uma série de amostragens e análises para identificar as necessidades nutricionais das plantas em curto prazo é uma tarefa complexa (REIS et al., 2006).

Além disso, para realizar esse diagnóstico, são geralmente determinadas as concentrações dos nutrientes na matéria seca das folhas em condições de laboratório, o que envolve métodos analíticos demorados e dispendiosos (GUIMARÃES et al., 1999).

Outro método comum para detectar deficiências nutricionais é a diagnose visual, embora sua precisão seja limitada e sujeita a erros (BAESSO et al., 2007). Os sintomas visíveis de deficiências surgem no final de uma cadeia de eventos que se inicia com mudanças moleculares e celulares, afetando finalmente os tecidos, o que pode ser observado nas folhas e frutos (MALAVOLTA, 2006).

A diagnose visual baseia-se no conhecimento dos sintomas exibidos pelas plantas quando um nutriente está em quantidade insuficiente ou excessiva. Compara-se o aspecto das folhas ou outros órgãos da planta com um padrão previamente estabelecido. A amostra pode ser uma planta isolada ou um conjunto de plantas, e o padrão é formado por plantas com nutrição adequada, cultivadas em condições controladas. A análise visual se concentra em determinados órgãos, como as folhas, que geralmente refletem de forma mais evidente o estado nutricional da cultura, respondendo diretamente à variação na disponibilidade de nutrientes do solo ou da adubação (BÜLL, 1993).

Os sintomas visuais de deficiências ou excessos de nutrientes se baseiam no princípio de que cada elemento exerce a mesma função em todas as plantas (MALAVOLTA, 2006). Quando um nutriente está deficiente, a planta manifesta esse desequilíbrio por meio de alterações visíveis, principalmente nas folhas, como mudança na coloração e no tamanho (RAMOS et al., 2009).

Além disso, os sintomas tendem a aparecer nas folhas mais velhas ou mais novas, dependendo da mobilidade do nutriente na planta. Para nutrientes móveis, que são redistribuídos pela planta, os sintomas tendem a ser mais intensos nas folhas mais velhas. Por outro lado, nutrientes com mobilidade limitada ou nula apresentam sintomas mais pronunciados nas folhas novas (MALAVOLTA, 2006).

No milho, as faixas adequadas de teores de micronutrientes nas folhas, expressas em miligramas por quilograma (mg kg^{-1}), são as seguintes: 7-17 para o Boro (B), 6-15 para o Cobre (Cu), 70-200 para o Ferro (Fe), 40-100 para o Manganês (Mn), 0,10-0,20 para o Molibdênio (Mo) e 20-50 para o Zinco (Zn) (CANTARELLA et al., 2022).

3.2. Sintomas visuais de deficiência de micronutrientes

O boro (B) é essencial para diversos processos nas plantas, incluindo o alongamento celular, a síntese de ácidos nucleicos, a regulação das respostas hormonais e o funcionamento das membranas celulares (SHELP, 1993). Quando a planta de milho sofre deficiência desse nutriente, os sintomas mais comuns incluem faixas alongadas e aquosas ou transparentes nas folhas jovens, que eventualmente se tornam brancas ou secas. O ponto de crescimento pode morrer, levando a uma polinização inadequada. As espigas, ao se desenvolverem, podem apresentar faixas marrons de cortiça na base dos grãos, além de falhas no preenchimento dos grãos (MALAVOLTA; DANTAS, 1987). No final do ciclo, as folhas podem apresentar coloração avermelhada, as espigas tendem a ser menores e com falhas na granação. Além disso, os grãos nas extremidades das espigas podem exibir características de cortiça (FANCELLI, 2009). Outros sinais de deficiência incluem vincos salientes no limbo foliar e a gelatinização do colmo (LUZ et al., 2018) (FIGURA 1a).

Figura 1. Sintomas visuais de deficiência de boro (a), cobre (b), ferro (c), zinco (d) em milho.



Fonte: Própria Autoria

O boro (B) é considerado um nutriente de mobilidade limitada nas plantas, o que faz com que os sintomas de sua deficiência se manifestem principalmente nas partes mais jovens da planta (TAIZ; ZEIGER, 2009). Esse elemento também influencia a absorção de cálcio, e os primeiros sinais de sua carência incluem o retardamento do crescimento das raízes e folhas jovens com coloração verde-clara na base.

Com o tempo, as folhas se tornam enroladas, e o sistema caulinar começa a morrer a partir da gema terminal (RAVEN et al., 2007).

O cobre (Cu) desempenha papel crucial nas enzimas que participam das reações redox, sendo capaz de alternar entre os estados de Cu^+ e Cu^{2+} (TAIZ; ZEIGER, 2009). Ele está envolvido na produção de fenóis e quinonas, na assimilação do nitrogênio e na síntese proteica (FANCELLI, 2009). A deficiência de cobre no milho é geralmente indicada pelo amarelecimento das folhas após seu desdobramento, encurvamento das extremidades e necrose nas margens das folhas (FIGURA 1b), além de colmos frágeis (MALAVOLTA; DANTAS, 1987). Também foi observado que a falta de cobre pode aumentar a vulnerabilidade do milho a doenças como a cercosporiose e a mancha branca (FANCELLI, 2009).

O ferro (Fe) é vital para a composição de enzimas envolvidas nas reações de transferência de elétrons (TAIZ; ZEIGER, 2009). Ele participa de processos como fotossíntese, respiração, fixação do nitrogênio, e síntese de lignina, entre outros (MALAVOLTA, 2006). Assim como a deficiência de magnésio, a carência de ferro resulta em clorose entre as nervuras, mas ao contrário do Mg, os sintomas aparecem primeiro nas folhas mais jovens devido à sua baixa mobilidade dentro da planta. Quando a deficiência é severa, as nervuras podem se tornar cloróticas, fazendo com que toda a folha se torne branca (TAIZ; ZEIGER, 2009) (FIGURA 1c).

O manganês (Mn) é um cofator e ativador de várias enzimas importantes para a planta, além de ser essencial para as reações de oxi-redução na fotossíntese (DECHEN et al., 1991; MALAVOLTA, 2006). Ele também é fundamental para a defesa contra doenças, ajudando na síntese de lignina e outros compostos fenólicos (MARSCHNER, 2012; MALAVOLTA, 2006). Quando em déficit, o manganês provoca clorose internerval nas folhas novas, formando um padrão reticulado nas nervuras. Em casos mais graves, podem surgir faixas brancas no tecido clorótico, que podem necrosar e se soltar (FERREIRA, 2012).

O zinco (Zn) é essencial para muitas enzimas, além de estar envolvido na biossíntese de clorofila e na produção de ácido indol acético, uma auxina que auxilia no crescimento da planta. Assim como o ferro e o cobre, o zinco também participa das reações redox (TAIZ; ZEIGER, 2009). No milho, o zinco é importante para o crescimento da planta, ativação de enzimas e formação dos grãos. A deficiência de zinco resulta em folhas esbranquiçadas perto da região do cartucho, crescimento reduzido da planta, encurtamento dos internódios e faixas brancas ou amareladas entre as nervuras principais (FIGURA 1d). Esses sintomas podem ser seguidos por necrose e coloração roxa, com folhas novas mostrando coloração esbranquiçada ou amarela pálida e internódios curtos (MALAVOLTA; DANTAS, 1987; MALAVOLTA, 2006).

Embora os sintomas visuais de deficiência nutricional no milho sejam bem descritos na literatura, a sua identificação a campo depende da experiência do

observador e, mesmo assim, quando o sintoma de deficiência nutricional é visível a olho nu, parte significativa da produção já está comprometida.

Desta forma, a produção agrícola poderia ser melhorada para o crescimento agrícola se as deficiências nutricionais das plantas fossem identificadas e detectadas em fases iniciais. Portanto, o monitoramento contínuo da nutrição de planta é muito importante para lidar com o estresse da planta (BERA et al., 2024).

3.3. Inteligência artificial para identificação de deficiência nutricional nutricional no milho

A agricultura do futuro visa aumento de produtividade e qualidade dos produtos, bem como redução de custos e otimização do uso consciente de insumos. A inteligência artificial aliada à visão computacional permite automatizar as operações de campo, colheita e pós-colheita, contribuindo para o desenvolvimento do novo ramo da indústria Agrícola 4.0 (PALLOTTINO et al., 2019).

Agrotecnologia e agricultura de precisão, também conhecida por agricultura digital, surgiram como novos campos científicos que utilizam dados abordagens intensas para impulsionar a produtividade agrícola e, ao mesmo tempo, minimizar o seu impacto ambiental (LIAKOS et al. 2018).

Devido à subjetividade envolvida nas análises químicas ou na diagnose visual, que podem resultar em erros de interpretação, principalmente pela semelhança entre os sintomas das deficiências nutricionais, surgiu a ideia de utilizar sistemas de inteligência artificial para a análise de imagens digitais e a identificação dessas deficiências nas plantas. O objetivo é criar métodos e uma infraestrutura computacional de visão artificial para detectar deficiências nutricionais nas plantas de milho, por meio da análise das superfícies das folhas, além de propor o desenvolvimento de herbários digitais inteligentes (SILVA, 2011).

Os dados gerados nas operações agrícolas modernas são fornecidos por uma variedade de sensores diferentes que permitir uma melhor compreensão do ambiente operacional, levando a resultados mais precisos e mais rápidos para a tomada de decisão (LIAKOS et al. 2018).

A utilização de sensores tem possibilitado a coleta de grandes volumes de dados sem prejudicar as plantas, resultando na redução do tempo necessário para análises e nos custos envolvidos. Esses sensores detectam ondas eletromagnéticas associadas a novas técnicas de processamento de imagens, que, por sua vez, são aplicadas na criação de sistemas inteligentes, promovendo o avanço da Agricultura 4.0 (FRACAROLLI et al., 2020).

A análise de imagens digitais envolve o reconhecimento de cenas para gerar características dimensionais, como áreas ou comprimentos de objetos, além de atributos como padrões de cor e textura. Esses dados são medidos por métodos que avaliam a contagem ou a frequência dos elementos formadores da imagem, conhecidos como "pixels" (TEIXEIRA et al., 2006). Sistemas de visão computacional, ou inteligência artificial, podem ser definidos como conjuntos de métodos e técnicas capazes de interpretar imagens por meio de sistemas computacionais, permitindo que máquinas realizem tarefas anteriormente executadas por seres humanos, associando observações, interpretações e soluções para problemas cotidianos (GOLAPUDI, 2019).

A interpretação de imagens digitais passa por várias etapas: aquisição, segmentação, extração de características e classificação/identificação (BRUNO, 2000; GONZALEZ; WOODS, 1993). Cada deficiência nutricional nas folhas de plantas resulta em efeitos específicos, como perda de pigmentação, necrose, redução do crescimento e alteração na textura da superfície. Os sistemas de inteligência artificial visam identificar essas características e associá-las a deficiências nutricionais.

Estudos recentes têm explorado a identificação automatizada e a classificação de deficiências nutricionais nas plantas utilizando inteligência artificial (BARBEDO, 2019). A análise de imagens das folhas de milho foi aplicada na identificação da deficiência de boro, com taxas de acerto de 88,75% e 92,75% nas folhas jovens nos estádios V4 e V7, respectivamente (LUZ et al., 2018).

Técnicas de aprendizado de máquina (Machine Learning - ML) têm sido empregadas na análise de imagens digitais de plantas, proporcionando novas oportunidades para compreender, quantificar e entender processos intensivos de dados em ambientes agrícolas (LIAKOS et al., 2018). Métodos de aprendizagem profunda, como redes neurais convolucionais (CNN) associadas a redes convolucionais gráficas, têm sido utilizados para a detecção automatizada de doenças e deficiências nutricionais nas plantas (BERA et al., 2024).

O aprimoramento dos parâmetros de planta conhecidos, além do desenvolvimento de novos indicadores para o manejo da adubação, são essenciais para aumentar a eficiência do uso de fertilizantes, reduzir os custos de produção, otimizar a rentabilidade do produtor e minimizar a contaminação do solo e da água (RAMBO et al., 2004). Por exemplo, Mattiello et al. (2015) indicaram que adaptações anatômicas e fisiológicas no híbrido BRS1010 podem ser detectadas antes mesmo dos sintomas visuais da deficiência de zinco. Os autores sugerem que, como os sintomas geralmente surgem nas folhas jovens, ajustes nos métodos de amostragem são necessários, dependendo do nutriente. Dessa forma, acredita-se que o sistema de visão artificial pode ser uma ferramenta útil para avaliar o estado nutricional das plantas de milho em diferentes níveis de nutrientes,

contribuindo para a melhoria da eficiência da adubação e fornecendo informações valiosas para o manejo dessa cultura.

4. Conclusão

A identificação nutricional das culturas, especialmente do milho, desempenha um papel crucial na agricultura moderna, promovendo o uso eficiente de fertilizantes. Uma nutrição equilibrada das plantas é fundamental não apenas para alcançar o máximo rendimento e qualidade dos produtos agrícolas, mas também para reduzir os impactos ambientais, como a lixiviação de nutrientes nos corpos d'água e a emissão de gases de efeito estufa. No entanto, os métodos convencionais de avaliação nutricional, como a análise química das folhas e a diagnose visual, possuem limitações consideráveis. A análise química, embora precisa, é um processo caro, demorado e requer laboratórios especializados, o que muitas vezes limita sua aplicação em larga escala, além de diagnóstico tardio. Já a diagnose visual, apesar de mais acessível, depende da experiência do observador e pode levar a diagnósticos tardios ou equivocados, comprometendo a eficiência no manejo nutricional.

Nesse cenário, a inteligência artificial (IA) se apresenta como uma solução promissora para a detecção de deficiências nutricionais em plantas, oferecendo uma abordagem rápida, precisa e de fácil acesso. A IA é capaz de processar grandes quantidades de dados em tempo real, identificar padrões sutis que não seriam percebidos pelo olho humano e fornecer orientações precisas para corrigir deficiências. Contudo, a implementação da IA na agricultura enfrenta obstáculos consideráveis. A obtenção e rotulagem de dados de alta qualidade são essenciais para o treinamento eficaz dos modelos de IA, mas podem ser prejudicadas pela variabilidade das condições de campo e pela complexidade das interações entre os nutrientes. Além disso, a adoção generalizada da IA demanda investimentos em infraestrutura tecnológica, além da capacitação de agricultores e técnicos no uso dessas novas ferramentas.

Assim, a identificação nutricional eficiente, juntamente com o uso de tecnologias avançadas como a inteligência artificial, tem o potencial de transformar o manejo de fertilizantes na agricultura, tornando-o mais preciso, sustentável e acessível. No entanto, para que esses benefícios sejam totalmente aproveitados, é necessário superar os desafios técnicos e práticos, garantindo que a inovação tecnológica esteja em sintonia com as necessidades e capacidades dos produtores.

Referências Bibliográficas

ABEYWARDANA, L. et al. Advanced coating on *Zea mays* seeds using modified hydroxyapatite nanoparticles as a plant nutrient delivery system for enhanced plant growth. **Current Science**, v.124, n.5, p. 599-606, 2023.

ALVAREZ, C.G.D; PINHO, R.G.V.; BORGES, I.D. Avaliação de características agronômicas e de produção de forragem e grãos de milho em diferentes densidades de semeadura e espaçamentos entre linhas. **Ciência e Agrotecnologia**, v. 30, p. 402-408, 2006.

AMARAL FILHO, J. P .R. et al. Espaçamento, densidade populacional e adubação nitrogenada na cultura do milho. **Revista Brasileira de Ciência do Solo**, v. 29, p. 467-473, 2005.

ARAÚJO, F. F. et al. Desenvolvimento do milho e fertilidade do solo após aplicação de lodo de curtume e fosforita. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 12, p. 507-511, 2008.

BAESSO, M. M. et al. Determinação do "status" nutricional de nitrogênio no feijoeiro utilizando imagens digitais coloridas. **Engenharia Agrícola**, v. 27, p. 520-528, 2007.

BARBEDO, J. G. A. Detection of nutrition deficiencies in plants using proximal images and machine learning: A review. **Computers and Electronics in Agriculture**, v. 162, p. 482-492, 2019.

BERA, A., BHATTACHARJEE, D., KREJCAR, O. PND-Net: plant nutrition deficiency and disease classification using graph convolutional network. **Scientific Reports**, v. 14, n. 1, p. 15537, 2024.

BONFIM-SILVA, E. M.; MONTEIRO, F. A. Nitrogênio e enxofre na adubação e em folhas diagnósticas e raízes do capim braquiária em degradação. **Revista Brasileira de Zootecnia**, v. 39, p.1641-1649, 2010.

BRUNO, O. M. **Paralelismo em visão natural e artificial**. 2000. Tese (Doutorado) – Instituto de Física de São Carlos, Universidade de São Paulo. São Carlos, 2000.

BÜLL, L. T. Nutrição mineral do milho. In: Büll, L. T.; Cantarella, H. **Cultura do milho: fatores que afetam a produtividade**. Piracicaba: POTAFOS, 1993. p.63-145.

CANTARELLA, H. et al. **Boletim 100: Recomendações de adubação e calagem para o estado de São Paulo**. Campinas: Instituto Agrônomo, 2022. 489p.

CHEN, X.P. et al. Integrated soil-crop system management for food security. **Proceedings of the National Academy of Sciences**, v. 108, n. 16, p. 6399-6404, 2011.

COELHO, A. M. Nutrição mineral e diagnose do estado nutricional do milho. In: SILVA, A. A.; CRUZ, J. C. (org.). **Milho: tecnologia e produtividade**. Sete Lagoas: Embrapa Milho e Sorgo, 2006. p. 263–293.

CROTTY, F. V. et al. The Impact of Using Alternative Forages on the Nutrient Value within Slurry and Its Implications for Forage Productivity in Agricultural Systems. **Plos One**, p. 9, 2014.

DECHEN, A. R.; HAAG, H. P.; CARMELLO, Q. A. C. Funções dos micronutrientes nas plantas. In: Ferreira, M. E; Cruz, M. C. P. (eds), **Micronutrientes na agricultura**, p.1-34. POTAFOS, Piracicaba, 1991.

DIAS, T. J. et al. Composição foliar de macronutrientes em maracujazeiro-amarelo e fertilidade do solo em função do número de ramos laterais por planta. **Anais do Curso de Pós-graduação em Manejo de Solo e Água**, v. 26, p.81-97, 2004.

EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária. **Tecnologias de produção de soja: região central do Brasil 2005**. Londrina Embrapa Soja, 2004. 239p.

FANCELLI, A.L. Milho. In: Prochnow, L.I.; Casarin, V.; Stipp, S.R. **Boas práticas para uso eficiente de fertilizantes**. Piracicaba: International Plant Nutrition Institute, p.39-93, 2010.

FANCELLI, A. L. Influência da nutrição na ocorrência de doenças de plantas. In: FANCELLI, A. L.; DOURADO NETO, D. **Milho. Manejo e Adubação**. Piracicaba: USP/ESALQ/LPV, p.1-35, 2008.

FANCELLI, A. L. Nutrição e adubação de milho. In: Fancelli, A. L.; Dourado Neto, D. **Milho. Manejo e produtividade**. Piracicaba: USP/ESALQ/LPV, p.60-97, 2009.

FAO – Food and Agriculture Organization of the United Nations. Disponível em: <<http://faostat.fao.org>>. Acess jul 2024.

FERREIRA, M. M. M. Sintomas de deficiência de macro e micronutrientes de plantas de milho híbrido BRS 1010. **Revista Agroambiente**, v. 6, n. 1, p. 74-83, 2012.

FERREIRA, A.C.M. et al. Absorption, partitioning, and export of nutrients by phenological stage in maize cultivated in Eastern Maranhão, Brazil. **Journal of Plant Nutrition**, v. 47, n. 2, p. 240-256, 2024.

FONTES, P. C. R.; DIAS, E. N.; GRAÇA, R. N. Acúmulo de nutrientes e método para estimar doses de nitrogênio e de potássio na fertirrigação do pimentão. **Horticultura Brasileira** v. 23, n. 2, p. 275-280, 2005.

FORNASIERI FILHO, D. **A cultura do milho**. Jaboticabal: FUNEP, 1992. 273p.

FRACAROLLI, J. A. et al. Computer vision applied to food and agricultural products. **Revista Ciência Agronômica**, v.51, Special Agriculture 4.0, e20207749, 2020.

GOLLAPUDI, S. **Learn Computer Vision Using OpenCV: With Deep Learning CNNs and RNNs**, Berkeley, CA: Apress, 2019.

GONZALEZ, R. C. WOODS, R. E. **Digital Image Processing**. Addison-Wesley, 1993.

GUIMARÃES, T.G. et al. Teores de clorofila determinados por medidor portátil e sua relação com formas de nitrogênio em folhas de tomateiro cultivados em dois tipos de solo. **Bragantia**, v. 58, n. 1, p. 209-216, 1999.

HORN, D. et al. Nutrient uptake kinetics and morphological traits of roots of maize cultivars with contrasting genetic variability. **Revista Brasileira de Ciência do Solo**, v. 30, p. 77-85, 2006.

HEINRICH, R. et al. Atributos químicos do solo e produção do feijoeiro com a aplicação de calcário e manganês. **Revista Brasileira de Ciência do Solo**, v. 32, p. 1157-1164, 2008.

JAMAMI, N. et al. Resposta da cultura do milho (*Zea mays* L.) à aplicação de boro e de zinco no solo. **Acta Scientiarum**. Agronomy, v. 28, n. 1, p. 1-7, 2006.

LORDKAEW, S. et al. Boron deficiency in maize. **Plant and Soil**, v. 342, p. 207-220, 2011.

LUZ, P. H. C. et al. Boron deficiency precisely identified on growth stage V4 of maize crop using texture image analysis. **Communications in Soil Science and Plant Analysis**, v. 49, n. 2, p. 159-169, 2018.

LIAKOS, K.G. et al. Machine Learning in Agriculture: A Review. **Sensors**, v. 18, n. 8, p. 2674, 2018.

MALAVOLTA, E. **Manual de nutrição de plantas**. São Paulo: Agronômica Ceres, 2006. 638p.

MALAVOLTA, E.; DANTAS, J. P. Nutrição e adubação do milho. In: Paterniani, E; Viegas, G. P., ed. **Melhoramento e produção do milho**. 2.ed. Campinas, Fundação Cargill, v.2. p.541-93. 1987.

MARSCHNER, H. **Mineral nutrition of higher plants**. 3.ed London: Elsevier, 2012. 643p.

MATTIELLO, E. M. et al. Zinc deficiency affects physiological and anatomical characteristics in maize leaves. **Journal of plant physiology**, v. 183, p. 138-143, 2015.

NOGUEIRA-JÚNIOR, S.; NOGUEIRA, E. A.; TSUNECHIRO, A. **Considerações sobre a agroindústria do milho**. São Paulo: Instituto de Economia Agrícola, 1987. 18p. (IEA Relatório de Pesquisa, 27).

OLIVEIRA, A. M. G.; CALDAS, R. C. Produção do mamoeiro em função de adubação com nitrogênio, fósforo e potássio. **Revista Brasileira de Fruticultura**, Revista Brasileira de Fruticultura, v. 26, p. 160-163, 2004.

PALLOTTINO, F. et al. Optoelectronic proximal sensing vehicle-mounted technologies in precision agriculture: A review. **Computers and Electronics in Agriculture**, v. 162, p. 859-873, 2019.

PAPONOV, I.A.; ENGELS, C. Effect of nitrogen supply on leaf traits related to photosynthesis during grain filling in two maize genotypes with different N efficiency. **Journal of Plant Nutrition and Soil Science**, v. 166, n. 6, p. 756-763, 2003.

PENG, Y. et al. Determination of the critical soil mineral nitrogen concentration for maximizing maize grain yield. **Plant and soil**, v. 372, p. 41-51, 2013.

PINAZZA, L. A. Perspectivas da cultura do milho e do sorgo no Brasil. In: Büll, L. T.; Cantarella, H. **Cultura do milho: fatores que afetam a produtividade**. Piracicaba: POTAFOS, p.1-10. 1993.

SAHA, P.K.; UDUPA, J. K. Optimum image thresholding via class uncertainty and region homogeneity. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v.23, n.7, p.689-706, 2001.

RAMBO, L. et al. Parâmetros de planta para aprimorar o manejo da adubação nitrogenada de cobertura em milho. **Ciência Rural**, v. 34, p. 1637-1645, 2004.

RAMOS, M. J. M. et al. Sintomas visuais de deficiência de macronutrientes e de boro em abacaxizeiro 'imperial'. **Revista Brasileira de Fruticultura**, v. 31, p. 252-256, 2009.

RAVEN, P. H.; EVERT, R. F.; EICHHORN, S. E. **Biologia Vegetal**. Rio de Janeiro: Guanabara Koogan, 7ª edição, 2007. 830p.

REIS, A. R. et al. Metodologia e técnicas experimentais diagnóstico da exigência do cafeeiro em nitrogênio pela utilização do medidor portátil de clorofila. **Bragantia**, v. 65, p.163-171, 2006.

SILVA, F. F. **Sistema de visão artificial para a identificação da nutrição de milho submetido a níveis de cálcio, magnésio e enxofre**. Pirassununga, 2011, 143p. Dissertação (Mestrado) – Faculdade de Zootecnia e Engenharia de Alimentos, Universidade de São Paulo.

SHELP, B. J. Physiology and biochemistry of boron in plants. In: (ed.) GUPTA, U. C. **Boron and its role in crop production**. CRC Press. Boca Raton, p. 53-85, 1993.

TAIZ, L.; ZEIGER, E. **Fisiologia vegetal**. Porto Alegre: Artmed. 2009. 848p.

TEIXEIRA, E.F.; CICERO, S. M.; DOURADO NETO, D. Análise de imagens digitais de plântulas para avaliação do vigor de sementes de milho. **Revista Brasileira de Sementes**, v. 28, p. 159-167, 2006.

URANO, E. O. M. et al. Avaliação do estado nutricional da soja. **Pesquisa Agropecuária Brasileira**, v. 41, p. 1421-1428, 2006.

VIANA, E. M. **Interação de nitrogênio e potássio na nutrição, no teor de clorofila e na atividade da redutase do nitrato em plantas de trigo**. 2007. 95f. Dissertação (Mestrado) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo. Piracicaba, 2007.

Sobre os Autores



Adriano Rogério Bruno Tech

Professor do Departamento de Ciências Básicas (ZAB), Faculdade de Zootecnia e Engenharia de Alimentos (FZEA), Universidade de São Paulo (USP). Doutor em Zootecnia (FZEA/USP), Mestre em Sistemas de Informação pela Pontifícia Universidade Católica de Campinas (PUCCAMP/SP) e Bacharel em Engenharia de Agrimensura (FEAP/SP).

Ministra aulas nos cursos de Zootecnia, Engenharia de Alimentos e Engenharia de Biosistemas, além de atuar como professor e orientador nos Programas de Pós-Graduação em Gestão e Inovação na Indústria Animal (Mestrado Profissional) (FZEA/USP), no Programa de Ciências da Engenharia Ambiental (EESC/USP) e no Programa de Zootecnia.

Trabalha com automação de ambientes produtivos, processamento digital de imagens, inteligência artificial, instrumentação eletrônica e tecnologia e sistemas de informação. Coordenador do Laboratório de Tecnologia e Sistemas de Informação (LTSI/FZEA/USP).

Bolsista de Produtividade em Desenvolvimento Tecnológico e Extensão Inovadora (CNPq - DT 2). Coordenador do Grupo de Pesquisa em Monitoramento de ambientes, pastagens e grandes cultivos (MAPAG, CNPq).

E-mail: adriano.tech@usp.br



Fernanda de Fátima da Silva Devechio

Professora Doutora do Departamento de Zootecnia (ZAZ) da Faculdade de Zootecnia e Engenharia de Alimentos (FZEA) da Universidade de São Paulo (USP), na área de Solos. Engenheira Agrônoma, formada em 2007 pela Faculdade de Ciências Agrárias e Veterinárias de Jaboticabal (FCAV/UNESP). Mestre e Doutora em Ciências pela Universidade de São Paulo (USP/FZEA) (2009-2015).

Finalizou o Pós-Doutorado em 2024 na FZEA/USP, na área de uso da inteligência artificial para identificação de deficiência nutricional na cultura do milho. Realizou projetos de Iniciação Científica com financiamentos CNPq e FAPESP na graduação, além de bolsa e auxílio pesquisa FAPESP na pós-graduação. Foi docente do curso de Engenharia Agrônoma no Centro Universitário Octávio Bastos (UNIFEOB) em São João da Boa Vista (SP) de 2014 a 2024, onde participou também como coordenadora do curso de graduação em Engenharia Agrônoma e da coordenação da Pós-Graduação de 2016 a 2024.

Ingressou como Professora Contratada em 2021 e como Professora Doutora I em 2023 no Departamento de Zootecnia da FZEA/USP, na área de Ciência de Solos, ministrando atualmente as disciplinas de Adubos e Adubação; Agrometeorologia; Fertilidade e Adubação do Solo; Solos; e Planejamento e Conservação do Uso da Terra, para o curso de Graduação em Zootecnia, bem como a disciplina de Morfofisiologia e Nutrição Mineral de Plantas de Interesse Zootécnico para a Pós-Graduação em Zootecnia da FZEA/USP.

Atua nas linhas de pesquisa em “Inteligência artificial para identificação de deficiência nutricional em plantas” e “Fertilidade do solo e adubação de plantas forrageiras”, com orientação de alunos de iniciação científica e coorientação de alunos de pós-graduação.

E-mail: ferdefatima@usp.br



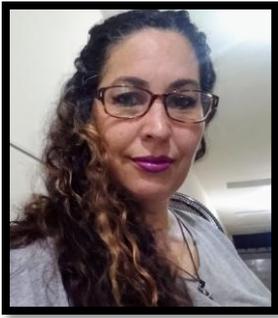
Murilo Mesquita Baesso

Professor do Departamento de Engenharia de Biosistemas (ZEB), Faculdade de Zootecnia e Engenharia de Alimentos (FZEA), Universidade de São Paulo (USP). Possui formação em Agronomia pela Universidade Federal Rural da Amazônia (2001), Mestre em Engenharia Agrícola pela Universidade Federal de Viçosa (2005), seguido pela obtenção do grau de Doutor em Engenharia Agrícola também pela Universidade Federal de Viçosa (2009). Atualmente, exerce a função de Professor Livre Docente na Universidade de São Paulo (USP), especificamente no Campus de Pirassununga.

Liderou a Comissão de Cultura e Extensão Universitária da FZEA, além de ter assumido a presidência da Câmara de Cursos da Pró-reitora de Cultura e Extensão da Universidade de São Paulo (USP). Atualmente, ocupa a posição de chefe do Departamento de Engenharia de Biosistemas da FZEA/USP.

Tem experiência na área de Engenharia Agrícola, com ênfase em máquinas e mecanização agrícola, análise de imagens e agricultura de precisão, atuando principalmente nos seguintes temas: otimização de operações de máquinas, detecção de falhas, classificação de imagens, previsão de demanda e rendimento agrícola, controle inteligente de equipamentos, manutenção preditiva, sensoriamento remoto e rede neural artificial.

E-mail: baesso@usp.br



Lilian Elgalise Techio Pereira

Professora do Departamento de Zootecnia (ZAZ) da Faculdade de Zootecnia e Engenharia de Alimentos (FZEA) da Universidade de São Paulo (USP). Doutora em Zootecnia e Pastagens (ESALQ/USP), Mestre em Zootecnia e Pastagens (ESALQ/USP) e Bacharel em Zootecnia (UFMS). Realizou pesquisa no exterior (BPE, FAPESP) entre 2016 e 2017 na Massey University, Palmerston North, Nova Zelândia.

Ministra aulas nos cursos de Zootecnia e Medicina Veterinária, além de atuar como professora e orientadora nos Programas de Pós-Graduação em Gestão e Inovação na Indústria Animal (Mestrado Profissional) (FZEA/USP) e no Programa de Pós-Graduação em Zootecnia (FZEA/USP).

Trabalha com atividades e projetos ligados a pastagens e forragicultura, a extensão Universitária e possui interesse em metodologias de aprendizagem ativa voltadas ao Ensino Superior. É Coordenadora do Grupo de Pesquisa em Forragicultura e Pastagens (GEFEP/FZEA/USP) e Coordenadora do Grupo de Pesquisa em Monitoramento de ambientes, pastagens e grandes cultivos (MAPAG, CNPq).

E-mail: ltechio@usp.br



João Paulo Rodrigues Marques

Professor do Departamento de Ciências Básicas (ZAB), Faculdade de Zootecnia e Engenharia de Alimentos (FZEA), Universidade de São Paulo (USP). Possui graduação em Ciências Biológicas pela Universidade Metodista de Piracicaba (2005), mestrado e doutorado em Ciências: Fisiologia e Bioquímica de Plantas pela Escola Superior de Agricultura Luiz de Queiroz (2006 - 2012). Realizou pós-doutorado pelo Departamento de Genética da ESALQ/USP e desenvolveu Bolsa de Estágio e Pesquisa no Exterior (BEPE/FAPESP) junto ao Agricultural Center, Louisiana State University. Realizou um segundo pós-doutorado no Centro de Energia Nuclear na Agricultura (2018-2020).

Atuou como docente da UNESP Campus Botucatu e atualmente é Professor de Botânica da Faculdade de Zootecnia e Engenharia de Alimentos (FZEA/USP). Auta na PPG da Fitopatologia da ESALQ e na PPG em Zootecnia da FZEA.

Tem experiência na área de Botânica, com ênfase em Anatomia Vegetal, atuando principalmente no seguinte tema: histopatologia, histoquímica, paredes celulares, ultraestrutura da interação planta-patógeno, histolocalização de genes de defesa, técnicas em microscopia ótica e eletrônica e imuno-marcação.

E-mail: jprmarques@usp.br

Grupo de Pesquisa registrado junto ao CNPq



Laboratórios da Faculdade de Zootecnia e Engenharia de Alimentos (FZEA/USP) participantes do Livro

Laboratório de Tecnologia e Sistemas de Informação (LTSI)

Grupo de Estudos em Forragicultura e Pastagens (GEFEP)

Grupo de Estudos em Botânica Aplicada (GEBAP)- Laboratório de Botânica Aplicada (LABAP)

Grupo de Pesquisa das Agrárias (GPA) – Laboratório de análise de solo das Agrárias

Laboratório de Máquinas Agrícolas e Agricultura de Precisão (LAMAP)





Processamento de Imagens e Radiação Eletromagnética: Aplicações na Análise Nutricional de Culturas Agrícolas

**Adriano Rogério Bruno Tech
Lilian Elgalise Techio Pereira
Fernanda de Fátima da Silva Deveschio
João Paulo Rodrigues Marques
Murilo Mesquita Baesso**

