

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE CIÊNCIAS AGRÁRIAS DO VALE DO RIBEIRA
CAMPUS DE REGISTRO**

**“PROCESSAMENTO DIGITAL DE IMAGENS PARA IDENTIFICAÇÃO DAS
DEFICIÊNCIAS DE FÓSFORO E POTÁSSIO NA CULTURA DA BANANA”**

Trabalho Original de Pesquisa

HEBERT LUCAS CAMPOS CELESTINO

Trabalho de Graduação apresentado à
Faculdade de Ciências Agrárias do Vale do
Ribeira, Câmpus de Registro – UNESP,
para a obtenção do grau de Engenheiro
Agrônomo

Registro/ SP
Julho de 2026

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE CIÊNCIAS AGRÁRIAS DO VALE DO RIBEIRA
CAMPUS DE REGISTRO**

**“PROCESSAMENTO DIGITAL DE IMAGENS PARA IDENTIFICAÇÃO DAS
DEFICIÊNCIAS DE FÓSFORO E POTÁSSIO NA CULTURA DA BANANA”**

Trabalho Original de Pesquisa

HEBERT LUCAS CAMPOS CELESTINO

Orientadora: Profa. Dra. Silvia Helena Modenese Gorla da Silva

Trabalho de Graduação apresentado à
Faculdade de Ciências Agrárias do Vale do
Ribeira, Câmpus de Registro – UNESP,
para a obtenção do grau de Engenheiro
Agrônomo.

Registro/ SP
Julho de 2026

C392p	Celestino, Hebert Lucas Campos Processamento digital de imagens para identificação das deficiências de fósforo e potássio na cultura da banana em campo / Hebert Lucas Campos Celestino. -- Registro, 2026 38 p. Trabalho de conclusão de curso (Bacharelado - Engenharia Agrônômica) - Universidade Estadual Paulista (UNESP), Faculdade de Ciências Agrárias do Vale do Ribeira, Registro Orientadora: Sílvia Helena Modenese Gorla da Silva 1. Aprendizado de máquinas. 2. Redes neurais artificiais. 3. Diagnose nutricional de plantas. I. Título.
-------	---

CERTIFICADO

TRABALHO DE GRADUAÇÃO DO CURSO DE ENGENHARIA AGRONÔMICA

TÍTULO: "PROCESSAMENTO DIGITAL DE IMAGENS PARA IDENTIFICAÇÃO DAS DEFICIÊNCIAS DE FÓSFORO E POTÁSSIO NA CULTURA DA BANANA EM CAMPO"

ACADÊMICO: HEBERT LUCAS CAMPOS CELESTINO

ORIENTADORA: PROFA. DRA. SILVIA HELENA MODENESE GORLA DA SILVA

PERÍODO: 9º Semestre

5º Ano


Aprovado: ☒

Reprovado: ☐

COMISSÃO AVALIADORA:


(Assinaturas)

Presidente Profa. Dra. SILVIA HELENA MODENESE
GORLA DA SILVA


Cristiane Coradin

Membro Profa. Dra. CRISTIANE CORADIN

Membro Profa. Dra. JULIANA DOMINGUES LIMA


Juliana Lima

Registro, 14 / 07 / 2026.

Dedico este trabalho, primeiramente, a Deus, que tem me conduzido até a conclusão desse ciclo, à minha família pelo apoio até o presente momento. Dedico também aos meus professores e amigos que, de alguma forma, contribuíram para a realização deste sonho.

AGRADECIMENTOS

Primeiramente, agradeço a Deus pela força e sabedoria concedidas ao longo desta jornada, guiando cada passo até esta conquista.

À minha esposa, pelo amor incondicional apoio incansável e por ser meu alicerce nos momentos difíceis não deixando-me desistir.

Aos meus pais, por todos os ensinamentos e pela ajuda no decorrer desses 5 anos.

À Prof. Dra. Silvia Helena Modenese Gorla da Silva, minha orientadora, por toda a paciência compartilhando conhecimentos que foram fundamentais para o desenvolvimento deste trabalho.

À Prof. Dra. Cristiane Coradin por todo o conhecimento compartilhado nas aulas, que me ajudaram a desenvolver-me no ambiente profissional junto às cooperativas do Vale do Ribeira.

Aos meus colegas, Hebert Rodrigues, Kevin Duarte, Eduardo Cerrades, Vitor, Robert, Pedro, pela amizade, parceria e colaboração de alguma forma no desenvolvimento de diversas pesquisas que realizamos, contribuíram para a minha formação profissional e como ser humano.

Ao meu parceiro e irmão Marcos Alexandre, por todos os momentos que compartilhamos juntos, e por todo o auxílio que me deu nesses anos em que fizemos a graduação juntos.

À UNESP - Faculdade de Ciências Agrárias do Vale do Ribeira, pela formação de excelência e toda a infraestrutura que possibilitou a minha formação profissional.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela concessão de bolsa de iniciação científica (PIBIC) ao longo do curso, viabilizando o desenvolvimento de pesquisas.

Por fim, à comissão examinadora, pela disponibilidade em contribuir com críticas e sugestões que ajudaram a aprimorar este trabalho.

“Quem observa o vento nunca semeará, e
o que olha para as nuvens nunca segará”
(Bíblia Sagrada, Ecl 11.4).

RESUMO

O estado nutricional das plantas tem grande importância em estudos sobre o metabolismo, crescimento e produção das plantas, necessitando de um modelo que possa estimar a deficiência nutricional em plantas de banana, pois quando conseguimos identificar visualmente, estima-se que parte da produção já foi comprometida. Nesse aspecto, o trabalho investigou a utilização do processamento digital de imagens em conjunto com a análise de componentes principais e redes neurais artificiais como ferramentas para apoiar uma melhor identificação da deficiência nutricional, em nível de campo, para que a intervenção possa ser adotada rapidamente, reduzindo danos e prejuízos causados nas folhas de banana e produtividade geral da área. Foram coletadas imagens digitais de folhas de bananeiras sadias e com deficiência nutricional de fósforo e potássio. A seguir, extraíram-se histogramas dos componentes de cada imagem no sistema RGB (*Red*, *Green* e *Blue*) para 256 intensidades de cinza das amostras, totalizando 768 variáveis para cada amostra. Com a aplicação de técnicas de seleção de atributos a análise de componentes principais, reduziram-se as variáveis de entrada de 768 para 31 variáveis canônicas. Em seguida, considerando as variáveis canônicas, realizou a fase de classificação com os usos das redes neurais artificiais. Os valores de sensibilidade e especificidade mostram que o modelo é altamente eficiente na identificação da deficiência (sensibilidade) e com alta capacidade de identificação na ausência de deficiência no campo (especificidade). O modelo estudado na presente pesquisa demonstrou que poderá ser uma ferramenta eficaz para auxiliar na diagnose nutricional das classes de fósforo, potássio e sadia minimizando a subjetividade da diagnose visual realizada por agrônomos ou técnicos agropecuários. De maneira geral, obtivemos alta taxa de acertos, mostrando robustez do classificador gerado, evidenciada pela baixa probabilidade de classificação incorreta (15%).

Palavras-chave: aprendizado de máquinas; redes neurais artificiais, diagnose nutricional de plantas.

ABSTRACT

Plant nutritional status is crucial in studies regarding plant metabolism, growth, and yield; consequently, there is a need for a model capable of early detection of nutritional deficiencies in banana plants, as visual identification often occurs only after a portion of the yield has already been compromised. In this context, this study investigated the use of digital image processing combined with principal component analysis and artificial neural networks as tools to improve field-level identification of nutritional deficiencies. Such tools enable rapid intervention, thereby mitigating damage to banana leaves and losses in overall area productivity. Digital images were collected from healthy banana leaves and from those exhibiting phosphorus and potassium deficiencies. Subsequently, histograms of the RGB (Red, Green, and Blue) components were extracted for each image across 256 gray-level intensities, resulting in a total of 768 variables per sample. Through the application of feature selection techniques and principal component analysis, the input variables were reduced from 768 to 31 canonical variables. Next, a classification phase was conducted using artificial neural networks based on these canonical variables. Sensitivity and specificity values indicate that the model is highly efficient at identifying deficiencies (sensitivity) and highly capable of correctly identifying the absence of deficiencies in the field (specificity). The model studied here demonstrated potential as an effective tool for assisting in the nutritional diagnosis of phosphorus-deficient, potassium-deficient, and healthy plants, thereby minimizing the subjectivity inherent in visual diagnoses performed by agronomists or agricultural technicians. Overall, a high accuracy rate was achieved, demonstrating the robustness of the resulting classifier, as evidenced by the low probability of misclassification (15%).

Keywords: machine learning; artificial neural networks, nutritional diagnosis of plants.

LISTA DE FIGURAS

Figura 1 – Sintomas característicos da deficiência nutricional de K na folha da bananeira	21
Figura 2 – Sintomas característicos da deficiência nutricional de P na folha da bananeira	23
Figura 3 – Arquitetura da RNA multicamadas utilizadas na fase de validação.....	31
Figura 4 – Curvas ROC por classe. As curvas 1, 2, 3 representam respectivamente o comportamento das classes Sadia (1), Potássio (2) e Fósforo(3).....	32

LISTA DE TABELAS

Tabela 1 – Redistribuição dos nutrientes e os órgãos onde os sintomas de deficiência ocorrem primeiro	25
Tabela 2 – Matriz de confusão das classes de deficiências nutricionais de potássio, fósforo e sódio para a fase de validação	30
Tabela 3 – Matriz de confusão para diagnóstico da sensibilidade e especificidade de deficiência nutricional para a fase de validação	32

LISTA DE SIGLAS E ABREVIATURAS

ACP	Análise de Componentes Principais
AM	Aprendizado de Máquina
B	<i>Blue</i>
FAO	Organização das Nações Unidas para Agricultura e Alimentação
G	<i>Green</i>
IA	Inteligência Artificial
IBGE	Instituto Brasileiro de Geografia e Estatística
PAP	Pontuações Amarelas e Pequenas
PDI	Processamento digital de imagens
R	<i>Red</i>
RNA	Redes Neurais Artificiais

SUMÁRIO

1	INTRODUÇÃO	12
2	REVISÃO DE LITERATURA.....	15
2.1	Redes neurais artificiais	15
2.2	Processamento digital de imagens	16
2.3	Análise de componentes principais.....	18
2.4	Deficiência nutricional de Potássio	20
2.5	Deficiência nutricional Fósforo	21
2.6	Diagnose visual.....	23
3	MATERIAL E MÉTODOS	26
4	RESULTADOS E DISCUSSÃO	29
5	CONCLUSÃO	33
	REFERÊNCIAS	34

1 INTRODUÇÃO

A cultura da banana (*Musa spp.*) consolida-se como uma das atividades agrícolas de maior relevância global, desempenhando papel estratégico na segurança alimentar e na geração de renda, especialmente em países em desenvolvimento. De acordo com a *Food and Agriculture Organization* (FAO, 2026), em 2025 a banana foi a fruta mais comercializada e consumida no mundo em volume, sendo cultivada em mais de 135 países e servindo como alimento básico para milhões de pessoas. No cenário brasileiro, a cultura reafirma sua importância, dados do IBGE (2026) indicam que em 2025 o Brasil se manteve entre os maiores produtores mundiais, com produção superior a 6,8 milhões de toneladas anuais distribuídas por todas as regiões do país.

Segundo dados da EMBRAPA (2026), em 2024, o estado de São Paulo exerceu liderança absoluta na produção nacional com área colhida (ha) de 45.250, produzindo 963.642 toneladas, obtendo rendimento médio de 21,30 (t/ha). Segundo o SEBRAE (2026), em 2025, o Vale do Ribeira destacou-se como o principal polo produtor, responsável por uma fatia superior a 15% da oferta nacional de bananas, o que movimenta a economia local através de uma extensa cadeia de pequenos, médios e grandes produtores.

Para manter a competitividade e a sustentabilidade desse setor, a busca por sistemas mais eficientes é constante. A produtividade da bananeira é intrinsecamente ligada ao manejo nutricional, visto que a planta exige um suprimento equilibrado de elementos minerais para seu pleno desenvolvimento, uma vez que a deficiência de um único nutriente essencial pode limitar todo o seu potencial produtivo (Prado, 2021).

A literatura científica apresenta um número ainda limitado de estudos focados na aplicação de técnicas de visão artificial especificamente para o diagnóstico da nutrição da cultura da banana. No entanto, os trabalhos existentes indicam um potencial promissor.

Um estudo relevante, conduzido por Silva (2011), demonstrou a eficácia da visão artificial na avaliação do estado nutricional de plantas de milho em relação aos macronutrientes secundários cálcio (Ca), magnésio (Mg) e enxofre (S). O autor concluiu que a análise do terço médio da folha nova (+2), no estágio de desenvolvimento V4 do milho, proporciona informações cruciais para a identificação do *status* nutricional. Esta constatação sugere a viabilidade de realizar um diagnóstico

de deficiência nutricional em um momento anterior ao método tradicional de coleta da "folha-índice" atualmente recomendado, permitindo uma correção mais precoce do desequilíbrio e mitigando o impacto da deficiência na produtividade.

O potássio (K) destaca-se como o macronutriente mais extraído pela cultura, desempenhando funções vitais na regulação osmótica, na ativação enzimática e no transporte de fotoassimilados para o enchimento de frutos (Malavolta, 2006). Na cultura da bananeira, o K é o macronutriente mais demandado. O desequilíbrio nutricional, como a relação desfavorável entre potássio e magnésio (K/Mg), é um fator etiológico bem documentado para a ocorrência do "Azul da Bananeira" (ou P.A.P. – Pontuações Amarelas e Pequenas), descrito inicialmente por Brun (1952). Esta fitopatia nutricional é conhecida por causar uma significativa redução na produtividade.

Por outro lado, o fósforo (P), embora exigido em menores quantidades em comparação ao K, é essencial para o estabelecimento do sistema radicular, atuando como componente estrutural de moléculas de alta energia, como o ATP, sendo fundamental para o metabolismo energético celular (Taiz *et al.*, 2017).

O uso de sistemas baseados em processamento digital de imagem (PDI) e técnicas de inteligência artificial (IA), como redes neurais artificiais (RNA), oferecem uma alternativa promissora para a resolução de problemas na agricultura.

Para otimizar o manejo da adubação e a identificação precoce de sintomas de deficiência nutricional, é fundamental o conhecimento dos padrões característicos de deficiência de cada nutriente. Essas tecnologias viabilizam a detecção e o mapeamento de estresses abióticos, como deficiências nutricionais em estágios incipientes (subclínicos), antes que os sintomas visuais se manifestem claramente na folha a detecção antecipada permite intervenções mais eficazes, reduzindo perdas na produção (Rodrigues; Silva, 2021).

O desenvolvimento saudável da bananeira exige o suprimento adequado de 17 nutrientes essenciais, sendo os provenientes do solo (elementos minerais) cruciais e frequentemente dependentes de estratégias de fertilização. Desses, carbono, hidrogênio e oxigênio (C, H, O) são obtidos do ar e da água, compondo cerca de 95% da matéria seca vegetal. Os demais são divididos em macronutrientes e micronutrientes, cuja disponibilidade no solo, especialmente em regiões tropicais de baixa fertilidade, geralmente requer suplementação via adubação. Cada elemento mineral exerce funções bioquímicas e fisiológicas específicas, influenciando

diretamente o crescimento da planta, a qualidade dos frutos e a resistência a fitopatógenos (Malavolta, 1980).

Os elementos minerais absorvidos pela planta desempenham papéis multifuncionais e insubstituíveis em sua fisiologia. Essas funções englobam desde a atuação como componentes estruturais de biomoléculas essenciais, a participação como constituintes de enzimas-chave, até o papel de ativadores enzimáticos, otimizando a velocidade das reações metabólicas. Tais processos são cruciais para garantir o pleno crescimento, o desenvolvimento morfológico e, em última instância, a produtividade agrônômica da cultura (Taiz *et al.*, 2017).

Um suprimento nutricional equilibrado é fator determinante para o fortalecimento dos mecanismos de defesa da planta, elevando sua resistência à estresses bióticos, como o ataque de pragas e a incidência de doenças.

Por outro lado, o manejo inadequado da nutrição, seja pela insuficiência (deficiência) ou pela superabundância (excesso/toxidez) de qualquer nutriente nos tecidos vegetais, desencadeia uma série de alterações bioquímicas e celulares. Essas disfunções se manifestam visualmente por meio de sintomas específicos e comprometem severamente o desenvolvimento normal das estruturas da planta, afetando negativamente as partes vegetativas (folhas, caules), reprodutivas (flores, frutos), (Almeida; Costa, 2022).

As técnicas de AM, são caracterizadas pela capacidade de aprendizado autônomo e adaptação (Mitchell, 1997), configuram-se como uma alternativa atraente para abordar a complexidade inerente ao diagnóstico de desordens nutricionais. Diversas pesquisas têm contribuído para a definição da eficácia dos métodos de AM na resolução de problemas relacionados à identificação de anomalias foliares, com destaque particular para as aplicações envolvendo o PDI (Pereira *et al.*, 2023).

Experiências prévias em projetos de iniciação científica, indicam que a identificação de certas deficiências nutricionais é mais facilmente realizada por meio da observação *in situ*. Portanto, aprimorar a capacidade de detecção precoce no campo (*early field detection*) representa um aspecto de grande relevância que merece aprofundamento na presente pesquisa.

Assim, o presente trabalho teve como objetivo investigar a aplicação do PDI, com aplicação dos RNA e da ACP na identificação de deficiência nutricional em folhas de bananeira, a partir de imagens digitais retiradas no campo com deficiências de fósforo e potássio e em folhas bem nutridas.

2 REVISÃO DE LITERATURA

2.1 Redes neurais artificiais

As RNA são técnicas de IA que buscam implementar modelos matemáticos que se assemelhem às estruturas biológicas (Braga; Ludemir; Carvalho, 2000). Assim, as RNA apresentam capacidade de adaptação dos seus parâmetros como resultado que advém da interação com o meio externo. Sua melhora é gradativa no seu desempenho na busca da solução de um determinado problema (Ferneda, 2006).

Estudos sobre RNA avaliando atividade cerebral tiveram início na década de 40, com o trabalho pioneiro de McCulloch e Pitts (1943). De acordo com Haykin (1999), McCulloch era psiquiatra e neurocientista, enquanto Pitt foi matemático. Juntos, propuseram um modelo de cálculos lógicos para redes neurais com o objetivo de integrar conhecimentos da neurofisiologia com a lógica matemática. Este trabalho marcou o surgimento das pesquisas em RNA e deu origem à inteligência artificial (IA).

O funcionamento de uma RNA difere das redes biológicas, mas pode-se observar similaridades que imitam o processamento básico de informações que ocorre nos neurônios e resume-se em três etapas: entrada, processamento e saída (Braga; Ludemir; Carvalho, 2000).

A entrada dos dados é fornecida à RNA por meio de diferentes fontes, como imagens, valores de sensores ou variáveis. Nos processos biológicos, essa etapa corresponde à captação de informações por meio dos sentidos humanos, visão, audição, olfato, paladar e/ou tato, que fornecem os estímulos iniciais ao sistema nervoso (Faceli *et al.*, 2021).

Os dados passam por múltiplas camadas de neurônios artificiais. Cada neurônio realiza cálculos com base em pesos e funções de ativação, permitindo a extração de padrões e a relação entre variáveis. Este processo assemelha-se ao funcionamento de um neurônio biológico que, por meio de uma rede interconectada, transmite e processa impulsos nervosos através de conexões sinápticas, acumulando, integrando e transformando informações ao longo do tempo (Goodfellow; Bengio; Courville, 2019).

Na saída, a rede fornece um resultado com base nos padrões de seu aprendizado durante os treinamentos. De forma muito parecida, o conhecimento humano é adquirido por um processo contínuo de aprendizado. Nas RNA, a

aprendizagem é a principal responsável pelo ajuste dos pesos das conexões entre os neurônios, sendo essa adaptação muito importante para o desempenho do modelo.

O treinamento da RNA pode ser realizado de duas formas diferentes: supervisionado e não supervisionado. No aprendizado não supervisionado, a rede recebe dados sem interferência e busca organizar e processar os dados para gerar uma resposta. O aprendizado supervisionado é feito com a definição dos dados de entrada previamente classificados e espera-se que, no final do treinamento, se obtenha o resultado proposto inicialmente (Hayhin, 2001).

A arquitetura mais conhecida e mais utilizada nas RNA é o Perceptron Multicamadas (*Multilayer Perceptron* – MLP) (Modenese-Gorla da Silva, 2008). Esse modelo é formado pelos neurônios das camadas de entrada, intermediárias e de saída, operando com funções de ativação não-lineares. O processo de aprendizado é geralmente implementado por meio de algoritmos *backpropagation*, responsáveis por ajustar os pesos das redes com base no erro entre o valor predito e o real, utilizando o método do gradiente descendente.

Buscando soluções para análise sintomatológica e diagnóstico de deficiência nutricional, Santos e Pereira (2025) estudaram o modelo de redes neurais convolucionais visando a realizar um diagnóstico rápido e preciso em campo.

Outro trabalho, desenvolvido por Ribeiro *et al.* (2025), utilizou alguns modelos de aprendizado de máquinas, entre eles a RNA, para identificar qual iria apresentar maior taxa de acertos e maior habilidade de prever a área foliar da batata-doce, visando à substituição de técnicas destrutivas tradicionais.

2.2 Processamento digital de imagens

O processamento digital de imagens (PDI) refere-se ao conjunto de técnicas e algoritmos empregados para manipular e extrair informações de imagens digitais, as quais são representadas por matrizes de pixels. Cada pixel contém informações específicas que representam a estrutura visual retratada (Gonzales; Woods, 2010).

Atualmente, com o avanço da agricultura digital, o uso do PDI tem se tornado de ampla utilidade para a identificação de padrões e elaboração de projetos de monitoramento agrícola mais precisos, contribuindo significativamente para o manejo das culturas e tomada de decisões no campo.

Estudos recentes demonstram o potencial do uso de PDI para automatizar tarefas que tradicionalmente dependem de análise visual subjetiva, como classificação de sementes, avaliação nutricional de folhas e detecção de doenças.

Souza Jr. *et al.* (2018) desenvolveram uma abordagem baseada em aprendizado de máquina para classificação de vigor de sementes de soja a partir de imagens digitais, utilizando um pipeline completo de análise visual com acurácia superior a 80%. O estudo mostra que a combinação entre extração de atributos e modelos de classificação para aplicações agrícolas com grande volume de dados e variabilidade visual pode ser uma ferramenta indispensável para a automação no campo.

Além disso, Silva (2021) usou o PDI para avaliar o estado nutricional de rúcula com diferentes doses de nitrogênio, e embora a detecção precoce da deficiência apresente limitações, o PDI conseguiu detectar padrões nas folhas mais velhas após 20 dias de tratamento, mostrando a utilidade em fases mais avançadas do estresse nutricional. O modelo apresentou bom desempenho em ambientes com iluminação variável, demonstrando a aplicabilidade no campo.

Há uma sequência de etapas para a aplicação do processamento digital de imagens que são: aquisição e digitalização, pré-processamento, segmentação, extração de atributos e análise de imagens. A aquisição e digitalização consistem na captura de uma imagem por meio de um sensor (câmera digital, drone ou satélite) e conversão para o formato digital.

A qualidade de aquisição influencia diretamente todas as etapas subsequentes (Modenese-Gorla da Silva, 2008; Gonzales; Woods, 2010). O pré-processamento visa melhorar a qualidade da imagem e prepará-la para as próximas etapas. Inclui operações como remoção de ruídos, realce de contraste, correção de brilho, equalização de histogramas, entre outras (Modenese-Gorla da Silva, 2008; Gonzales; Woods, 2010).

A segmentação consiste na separação da imagem em regiões ou objetos de interesse. É uma etapa que permite isolar atributos específicos, como áreas afetadas por doenças em folhas ou frutos. Pode-se utilizar técnicas como limiarização, segmentação por cor, binarização ou métodos baseados em bordas (Modenese-Gorla da Silva, 2008; Gonzales; Woods, 2010).

A extração de atributos é a fase em que são obtidas informações qualitativas e quantitativas das regiões segmentadas. Os atributos podem ser de cor, textura, forma,

entre outros, e são necessários para a análise (Gonzales; Woods, 2010). Com base nos atributos extraídos, a imagem, ou uma parte desta, passa por processo de classificação por meio de algoritmos de AM (Modenese-Gorla da Silva, 2008).

De forma geral, os estudos analisados indicam que o PDI, associado ao AM, tem um alto potencial na detecção de sintomas, desde que haja atenção quanto à qualidade da imagem, padronização da coleta de dados e validação com modelo adequado.

A partir disso, pode-se afirmar que o PDI no monitoramento de deficiência nutricional, especialmente nos estádios iniciais, pode ser uma ferramenta para driblar a subjetividade e a variação das condições ambientais e o olho humano, buscando entregar um melhor resultado sem subjetividade do sintoma final.

2.3 Análise de componentes principais (ACP)

Segundo Johnson e Winchern (2002), a análise de componentes principais (ACP) é uma técnica estatística multivariada usada para reduzir o número de dimensões em grandes conjuntos de dados complexos e interrelacioná-los, mantendo a variabilidade original da informação.

Desenvolvida por Pearson (1901), a ACP tem por objetivo transformar um conjunto de variáveis possivelmente correlacionadas entre si em um novo conjunto de variáveis não correlacionadas, chamadas de componentes principais. As ACP são caracterizadas por uma combinação linear das variáveis originais, ordenadas de forma que os componentes principais explicam a maior variância dos dados, seguidos pelo segundo, e assim por diante.

Há casos em que as variáveis possuem uma alta correlação entre si; isso permite que 80 ou 90% da variância explicada dos dados originais possa ficar acumulada nos dois ou três primeiros componentes principais, de maneira que se pode obter uma redução considerável da dimensão dos dados sem perda da informação (Modenese-Gorla da Silva, 2008).

Após a extração dos atributos, a ACP permite reduzir a dimensão dos dados de entrada antes de serem direcionados para a classificação, otimizando o desempenho e reduzindo o tempo computacional.

A ACP é uma técnica muito útil quando se trabalha com imagens digitais na agricultura.

Em um estudo, Souza (2023) aplicou ACP para reduzir a dimensão dos atributos extraídos de imagens de soja, classificadas por vigor. O uso da técnica permitiu melhor desempenho do modelo, com maior taxa de acertos e redução do tempo na fase de processamento. Semelhantemente, Silva (2021), utilizou ACP na análise de imagens de rúcula com diferentes níveis de nitrogênio e demonstrou que a técnica reduziu substancialmente o número de variáveis, otimizando o processamento. Santi *et al.* (2012) aplicou com sucesso a ACP para reduzir a dimensionalidade dos dados e interpretar os padrões de variabilidade espacial e temporal do índice de maturação do amendoim, assim como suas relações com propriedades do solo e atributos espectrais.

Os procedimentos para obtenção dos componentes principais seguem as seguintes etapas (Messetti, 2007; Modenese-Gorla da Silva, 2008): a padronização dos dados, cálculo da matriz de covariância ou correlação, cálculo dos autovalores e autovetores, e projeção dos dados. A padronização dos dados é utilizada para evitar que variáveis originais com escalas maiores não enviesem os componentes principais; os dados devem passar por processo de normalização para obter média nula e variância unitária. Na sequência, é feito o cálculo da matriz de covariância ou correlação. Caso a padronização dos dados não seja necessária, a matriz de covariância corresponde à matriz de correlação das variáveis originais. Calculam-se os pares de autovalor e autovetor da matriz gerada a partir do cálculo da matriz de covariância ou correlação. São ordenados em ordem decrescente de autovalores. Os autovalores indicam a variância explicada por cada componente, e os autovetores definem a direção dos componentes no espaço. Por fim, os dados são projetados a partir dos autovalores (componentes principais) e são eliminados os que são desprezíveis com relação à variância total dos dados originais.

Dado o resultado dos estudos apresentados, a ACP é uma ferramenta essencial para o tratamento de dados baseado em PDI e aprendizado de máquina, pois reduz o número de variáveis sem comprometer a representatividade e a precisão dos resultados e otimiza o processo de análise e classificação.

2.4 Deficiência nutricional de Potássio

O K é o elemento mais abundante nas bananeiras, sendo absorvido em altas quantidades pelas raízes. Possui importante função no estado energético da planta, na translocação e armazenamento de fotoassimilados e na manutenção da água nos tecidos vegetais. O K não faz parte de nenhuma estrutura ou molécula orgânica na planta, como o N e o P, que são constituintes de proteínas, ácidos nucleicos, fosfolipídios, ATP, entre outros. O íon K encontra-se predominantemente como cátion livre ou como cátion absorvido e pode ser facilmente deslocado das células ou dos tecidos da planta (Lindhauer, 1985).

A alta mobilidade na planta explica as principais funções e características do K como o principal cátion que atua na neutralização de cargas e como o mais importante e ativo componente inorgânico osmótico (Clarkson; Hanson, 1980).

O K atua em muitos processos fisiológicos no vegetal (Marchner, 1995): ativa mais de 60 sistemas enzimáticos (sintetases, desidrogenases, transferases, oxidoredutases, cinases); atua na fotossíntese favorece um alto estado de abertura e fechamento dos estômatos, promove a absorção de água, regula a translocação de nutrientes na planta, favorece o transporte e armazenamento de carboidratos, incrementa a absorção de N e a síntese de proteínas e participa da síntese de amido nas folhas.

A adequada nutrição do K promove também, qualitativamente, incrementos nos teores de proteínas e de amidos nos grãos e frutos, possibilitando também maiores períodos de armazenamento, como banana, tomate, cebola, entre outros (Usherwood, 1985; Koo, 1985; Mengel, 1997, Silva, 2022).

Quando os níveis de K estão baixos no solo, pode-se identificar visualmente os sinais típicos, pois a folha é o órgão da planta que melhor reflete o estado nutricional da planta.

Na Figura 1 pode-se observar os sintomas característicos da deficiência nutricional de K na folha da bananeira no campo.



Figura 1 – Sintomas característicos da deficiência nutricional de K na folha da bananeira
Fonte: o autor (2026).

2.5 Deficiência nutricional Fósforo

O P é o macronutriente menos absorvido pela bananeira, mas é considerado um elemento fundamental para a síntese de moléculas, como o DNA, RNA, ATP, NADPH e fosfolipídios das membranas plasmáticas em todos os seres vivos do planeta. Desempenha papel crucial em processos que sustentam a vida das plantas como por exemplo, fotossíntese, respiração, metabolismo de carboidratos, fixação de N_2 e ativação de proteínas por meio de fosforilações (Poirier; Bucher, 2002; Vance *et al.*, 2003). Depois do N, o P é o macronutriente que mais tem limitado o crescimento das plantas devido ao seu baixo suprimento em muitos solos na agricultura nacional.

O P representa aproximadamente 0,2% da matéria seca das plantas (Epstein, 1972).

A crosta terrestre é constituída por cerca de 0,12% de P, cujas maiores reservas encontram-se em sedimentos marinhos, solos, fosfatos inorgânicos dissolvidos nos oceanos e rochas com minerais, como apatita (Souza, 2021).

No solo o P pode ser encontrado em diferentes formas, cuja predominância depende de fatores, como manejo e tipo de solo.

O P no solo pode ser dividido em quatro categorias: P na forma iônica e em compostos na solução do solo; P absorvido na superfície dos constituintes minerais do solo; minerais cristalinos e amorfos de P; e P componentes da matéria orgânica (Silva, 2022, p.45).

Os valores de pH para dissociação do H_3PO_4 em H_2PO_4^- e HPO_4^{2-} são de, respectivamente, 2,1 e 7,2 ou seja, abaixo de pH 6, a maior parte do P da solução do solo está de forma de H_2PO_4^- , usualmente denominado P inorgânico (Pi), (Rech, 2020, p.24).

Devido ao seu comportamento químico, o P apresenta baixa mobilidade e disponibilidade no solo. Assim, a captação de P tem grande dependência de que as plantas explorem um grande volume do solo pelas raízes. Sistemas radiculares mais extensos tornam maior a área de contato entre as raízes e o solo, com capacidade de explorar diferentes camadas do solo. Para íons pouco móveis, como o fosfato, a absorção está com frequência relacionada ao comprimento radicular (Valadão, 2014).

O P é um dos macronutrientes mais críticos para a cultura da banana, desempenhando um papel vital desde o estabelecimento da muda até a colheita (Borges *et al.*, 2006).

Além de atuar diretamente na transferência de energia celular ATP, o fósforo estimula a divisão celular, o que acelera o crescimento do pseudocaule e melhora a resistência estrutural da bananeira (Marschner, 2012).

Na fase reprodutiva, a presença adequada do elemento P é determinante para a emissão de inflorescências vigorosas e para o enchimento dos frutos, resultando em cachos maiores, mais pesados e com melhor padrão comercial (Natale *et al.*, 2008).

Na Figura 2 pode-se observar os sintomas característicos da deficiência nutricional de P na folha da bananeira no campo.



Figura 2 – Sintomas característicos da deficiência nutricional de P na folha da bananeira
Fonte: o autor (2026).

2.6 Diagnose visual

A diagnose visual consiste em comparar visualmente o aspecto (coloração, tamanho e forma) das amostras com um padrão característico. O órgão de comparação é a folha, pois é aquela que melhor reflete o estado nutricional da planta. Nas folhas ocorrem os principais processos metabólicos do vegetal. A folha é o órgão da planta mais sensível às variações nutricionais (Malavolta; Vitti; Oliveira, 1997).

Se houver falta ou excesso de nutrientes, os sintomas manifestarão visualmente com sinais típicos para o determinado elemento. O motivo pelo qual o sintoma é típico do elemento deve-se ao fato de que um determinado nutriente exerce a mesma função em qualquer tipo de planta (Malavolta 2006).

Deve-se ressaltar que, o sintoma de deficiência ou toxidez é o último passo de uma sequência de problemas metabólicos irreversíveis e quando aparece de forma generalizada nas plantas, sua produção já foi comprometida. Em alguns casos, a produção e o crescimento são limitados, sem que a sintomatologia típica se manifeste. Nestes casos, chama-se “fome ou toxidez oculta” e ocorre quando a carência ou excesso de nutrientes são mais leves (Malavolta 2006).

A sequência de anormalidades que conduz aos sintomas visíveis da deficiência ou excesso de um dado elemento pode ser resumida (Malavolta; Vitti; Oliveira, 1997) como falta ou excesso (1), alteração molecular (2), lesão subcelular (3), alteração celular (4), modificação no tecido (5) e manifestação visível = sintoma típico do elemento (6).

A diagnose visual é um método muito usado e o seu conhecimento é de suma importância na atividade profissional do agrônomo ou técnico agropecuários, mas a mesma apresenta limitações, tal como, sintomas de origem nutricional que podem ser confundidos com outros gerados por fatores não nutricionais, o que dificulta o diagnóstico (Faquin, 2002).

Fatores bióticos e abióticos podem induzir sintomas parecidos com os nutricionais, como ataque de pragas, doenças, climáticos, físicos do solo e toxidez por produtos químicos. Portanto, para se fazer a diagnose visual deve-se sempre considerar indicações, que minimize a possibilidade de enganos no diagnóstico. Diferentemente dos fatores não nutricionais, os sintomas de deficiência nutricional possuem duas características exclusivas, simetria – sintomas de deficiência nutricional aparecem de maneira simétrica na folha e entre folhas do mesmo par ou próximas ao ramo e aparecem independente da face de exposição da planta e gradiente – refere-se às diferenças na coloração entre folhas velhas e folhas novas do ramo, devido à redistribuição dos nutrientes na planta (Malavolta, 2006).

A Tabela 1 mostra que se o nutriente for móvel, em condições de carência, a planta promove sua remobilização das folhas velhas para as folhas mais novas ou frutos e o sintomas se manifestam nas folhas mais velhas. Para nutrientes imóveis, os sintomas ocorrem nas folhas mais novas. Alguns nutrientes promovem sintomas muito parecidos entre si e o gradiente é uma importante ferramenta para um diagnóstico mais seguro.

Tabela 1 – Redistribuição dos nutrientes e os órgãos onde os sintomas de deficiência ocorrem primeiro

Nutriente	Redistribuição	Sintomas visuais de deficiência ocorre
N, P, K e Mg	Móveis	Folhas velhas
S, Cu, Fe, Mn, Zn, e Mo	Pouco móveis	Folhas novas
B e Ca	Imóveis	Folhas novas e meristemáticas

Fonte: Malavolta (2006).

3 MATERIAL E MÉTODOS

A coleta das folhas foi realizada entre janeiro e setembro de 2025. Em propriedade particular com plantio comercial na cidade de Miracatu-SP, com coordenadas geográficas 24°20'06" S e 47°22'27" W com altitude que variam de 365 a 450 metros acima do nível do mar.

Definiu-se que as coletas das folhas seriam feitas em plantas que se encontravam em estágio de florescimento, o que equivale à retirada de amostras para análise química de plantas na terceira folha, conforme definiu Moreira (1987).

As mudas de banana foram plantadas nessa área no dia vinte de junho de 2000, com espaçamento de 2,5x3 metros, com estande de 1333 plantas por hectare.

Para obtenção das folhas com deficiência, foi realizado passeio entre plantas e escolheram-se as que manifestassem sintomas de deficiências para selecioná-las. Foram coletadas 5 amostras de folhas para cada deficiência e definiu-se um protocolo para captura das imagens para manter uma padronização e minimizar erros produzidos por elementos não relacionados à deficiência nutricional proposto por (Modenese-Gorla da Silva, 2008).

Para a identificação dos sintomas, foram utilizadas técnicas de PDI, a partir de um método composto por quatro fases distintas de operacionalização: coleta e digitalização das amostras, segmentação e extração dos histogramas das imagens, seleção de atributos e, por fim a classificação (Modenese-Gorla da Silva, 2008).

Para cada uma das classes estudadas (manifestações de deficiências encontradas de P, K e mais a classe sadia), foram coletadas 150 amostras digitais de forma geométrica quadrada de 100 x 100 pixels, utilizando o software ImageJ para cada classe.

A partir dos arquivos construídos, na sequência procedeu-se com a segmentação e organização da distribuição de frequência das intensidades de cores dos pixels. Para tal, foram utilizadas ferramentas computacionais desenvolvidas em (Modenese-Gorla da Silva, 2008), que decompõem cada imagem nos três componentes de cores do sistema RGB (*Red* = vermelho, *Green* = verde e *Blue* = azul). Cada imagem de entrada gerou 3 arquivos de texto, um para cada componente de imagem (RGB), contendo a distribuição de frequência da intensidade dos níveis de cinza (256 níveis). Para a edição da base geral de dados, juntaram-se os três arquivos textos de cada amostra, adicionando um atributo de rótulo da classe. Assim, cada

imagem passou a ter 769 ($3 \times 256 + 1$) variáveis para representá-la, ou seja, a frequência de cada nível de cinza para cada um dos componentes de cores RGB, representando as 768 variáveis de entrada e uma variável de saída, a classe de cada imagem ou exemplo.

A terceira fase da metodologia, referente à seleção de atributos, consistiu na aplicação de uma técnica multivariada para a seleção de variáveis quanto ao grau de importância na classificação dos sintomas, visando diminuir o número expressivo de variáveis de entrada e, assim, facilitar computacionalmente o treinamento das RNA na fase de categorização das imagens. Para isto, foi utilizada a técnica multivariada de dados expressa na análise de ACP que permite a redução substancial do espaço paramétrico, praticamente, sem prejuízo da informação biológica contida na variabilidade das respostas (Hotteling, 1936; Johnson; Wichern, 2004). A ferramenta computacional selecionada para aplicação da ACP foi o software Weka® (Witten; Frank, 1999). A Weka® é uma ferramenta para AM (Mitchell, 1997) desenvolvida na Universidade de Waikato, na Nova Zelândia, escrita em linguagem JAVA, com código aberto, que permite alterações nas funções a serem utilizadas, bem como a 45 inserção de implementações não suportadas. A operacionalização da Weka® é de domínio público disponível no endereço eletrônico: <http://www.cs.waikato.ac.nz/ml/weka>.

Por último, finalizando a metodologia realizou-se na etapa de classificação. Nesta etapa, utilizou-se a técnica de RNA para classificação dos referidos padrões coletados. Foram utilizadas RNA *Perceptron* multicamadas, treinadas com o algoritmo *backpropagation* com termo *momentum* (Haykin, 1999) adotando-se como taxa de aprendizado e termo *momentum* os valores iguais a 0,2 e 0,3, respectivamente, seguindo a recomendação de (Modenese-Gorla da Silva, 2008). A taxa de aprendizado representa a aceleração do aprendizado, ou seja, controla a velocidade de atualização dos pesos. Por sua vez, o termo *momentum* é uma constante que ajuda na atualização dos pesos, de maneira a contribuir para não se estacionar em mínimos locais. Nesta fase de classificação, também utilizou-se a ferramenta Weka®. Toda a execução da experimentação computacional foi realizada em um microcomputador com multiprocessadores, com 16 Gbytes de memória RAM e 1 Tbytes de memória auxiliar.

Continuando o procedimento operacional, para verificar a validação (consistência) do experimento, foram utilizados alguns procedimentos e técnicas

convencionais de confiabilidade. No caso de tarefas de classificação, uma medida comumente utilizada é a frequência (taxa) de erro do classificador h , também conhecida como probabilidade (taxa) de classificação incorreta ou errônea. A probabilidade clássica do erro é obtida utilizando a expressão,

$$e(h) = \frac{1}{n} \sum_{i=1}^n (y_i \neq f(x_i)) \quad (1)$$

a qual acumula as discordâncias entre a classe original de cada amostra com o rótulo atribuído pelo classificador induzido ponderada pelo total de amostras. Utilizando a função indicadora, tem-se que, se a indicação de classificação tiver concordância, há uma classificação correta, ou seja, expressão lógica verdadeira, e, neste caso, o contador indica o valor 1; caso contrário, expressão lógica falsa, e o valor indicado consiste em 0. O procedimento é repetido para todas as amostras e o operador matemático vai acumulando o resultado até o número n de unidades amostrais. O complemento da probabilidade de erro é tomado como a precisão do classificador (Baranauskas, 2000).

Para obter uma estimativa não viciada de erro do classificador, utilizou-se técnicas de amostragem para manipulação dos conjuntos de treinamento e teste. Neste trabalho, considerou-se a metodologia *r-fold cross-validation* (Efron; Gong, 1983), que divide o conjunto de dados total, de tamanho n , em r partes mutuamente exclusivas (*folds*) de tamanhos iguais a n/r amostras. As amostras nos $(r-1)$ *folds* são usadas para treinamento e a hipótese induzida e testada no *fold* remanescente. Este processo é repetido r vezes, cada vez considerando um *fold* diferente para teste. O erro no *cross-validation* é a média dos erros calculados em cada um dos r *folds* de teste (Baranauskas, 2000).

Após o teste do classificador induzido, pode visualizar uma matriz de confusão, com acertos e erros médios gerados pelo classificador para cada uma das classes estudadas.

Para validação da deficiência nutricional, realizou-se análise de solo para obtenção dos valores e confirmação se realmente estava com a deficiência nutricional avaliada.

4 RESULTADOS E DISCUSSÃO

A Tabela 2 apresenta a matriz de confusão com a média dos conjuntos de testes e o resultado para o modelo da RNA no experimento.

Tabela 2 – Matriz de confusão das classes de deficiências nutricionais de potássio, fósforo e sadia para a fase de validação

Destino Origem	Sadia	Potássio	Fosforo	Total
Sadia	145	2	3	150
Potássio	0	118	32	150
Fosforo	0	32	118	150

Fonte: o autor (2026).

De acordo com a análise da matriz de confusão, pode-se observar variações das taxas de acertos para cada classe. A sadia foi a classe que obteve o melhor desempenho, com taxas de acertos de 96,7%. A classe potássio teve precisão de 78,7%. E a classe fósforo também obteve precisão de 78,7%, indicando sobreposição com a classe potássio e menor distinção nos padrões extraídos devido à similaridade dos atributos extraídos.

Nota-se um padrão de erros. Em muitas instâncias, as classes fósforo e potássio apresentaram confusão considerável. Isso pode estar relacionado ao fato de haver grande semelhança visual entre essas categorias, ou mesmo à necessidade de aprimorar o conjunto de atributos, as ACP, para elevar o nível de discriminação entre as 31 classes que foram selecionadas. Escudero, Calvo e Bejarano (2021) também relataram dificuldade de discriminação entre as classes intermediárias devido à sobreposição com dados semelhantes, o que dificulta encontrar um método de classificação que possa separar classes corretamente sem que elas tenham confusão entre si.

Na Figura 3 pode-se observar a arquitetura da RNA multicamadas utilizadas na fase de validação.




Figura 3 – Arquitetura da RNA multicamadas utilizadas na fase de validação. Os traços verdes do gráfico são os neurônios da camada de entrada (os componentes principais), os pontos vermelhos os neurônios da camada intermediária e os amarelos os neurônios da camada de saída, que são as classes

Fonte: o autor (2026).

Os conjuntos de testes na fase de validação obtiveram acurácia média de 84,7 %. A estatística Kappa obtida foi de 0,77, o que indica um nível alto de concordância entre as classificações previstas pela rede e as classificações reais. Os resultados superam a acurácias de 32% reportadas por Silva (2021) para detecção de deficiência de N precocemente em rúcula, e ficou acima da acurácia de 81% de Silva (2008) para Sigatoka Negra, possivelmente devidos à maior variabilidade nas imagens de campo.

O erro absoluto médio foi de 0,1086 e a raiz do erro quadrático médio foi de 0,3013, indicando dispersão moderada dos erros em relação aos valores reais. Modenese-Gorla da Silva, (2008) obteve erro médio de 19%. Isso sugere que o trabalho obteve melhor capacidade preditiva do modelo.

Para uma interpretação da capacidade de discriminação da sensibilidade e especificidade do modelo, foram geradas as curvas ROC para cada classe avaliada, conforme a Figura 4.




Figura 4 – Curvas ROC por classe. As curvas 1, 2, 3 representam respectivamente o comportamento das classes Sadia (1), Potássio (2) e Fósforo(3)

Fonte: o autor (2026).

A partir da interpretação das curvas ROC, observa-se que as classes avaliadas obtiveram altos valores de sensibilidade e especificidade, o que mostra que o modelo é altamente eficiente na identificação da deficiência (sensibilidade) e com alta capacidade de identificação na ausência de deficiência no campo (especificidade).

A Tabela 3 apresenta a matriz de confusão com os valores de acertos e erros das classes sadias e com deficiência para cálculos de sensibilidade e especificidade.

Tabela 3 – Matriz de confusão para diagnóstico da sensibilidade e especificidade de deficiência nutricional para a fase de validação

Matriz de confusão	Deficiência (Valores Preditos)
	Sadia Deficiência
Positivo	b 145 a 300
Negativo	d 5 c 0

Fonte: o autor (2026).

Os resultados demonstram alta capacidade do modelo em diagnóstico, mostrando que de acordo com os valores de sensibilidade ($a/(a+c)$) 1 e especificidade ($d/(b+d)$) 0,967, o modelo é altamente eficiente na identificação da deficiência

(sensibilidade) e tem altas taxas de acertos na identificação da ausência da deficiência (especificidade).

O modelo proposto mostra-se como uma ferramenta promissora no que diz respeito em fornecer conhecimento para um sistema de identificação automática. Esse sistema poderá ser instalado em um dispositivo eletrônico que detectará a deficiência nutricional, transferindo as informações das coletas para o monitoramento automático. O dispositivo poderá ser implementado com baixo custo, tornando-se acessível não só a grandes, mas também a pequenos e médios produtores, de maneira a evidenciar a importância destacada pela aplicação prática deste trabalho e tornando-se um importante instrumento para identificação precoce das deficiências de fósforo e potássio no campo sem que haja uma porcentagem significativa de remediação no mesmo ciclo produtivo. Diante disso, abre-se a perspectiva para o desenvolvimento futuro de um aplicativo para celular (mobile), o qual permitirá aos produtores realizarem esse diagnóstico em tempo real diretamente de seus smartphone de forma prática no campo.

Para validação da deficiência nutricional, realizou-se análise de solo para obtenção dos dados e comprovação se realmente estava com deficiência de P e K na área de coleta apresentando os seguintes resultados a seguir: K $0,6 \text{ mmol/dm}^3$ e P 12 mg/dm^3 .

Os teores de K estavam em situação crítica no local em que realizamos a coleta. No solo os teores de K deveriam estar entre $3,0$ a $5,0 \text{ mmol/dm}^3$ evidenciando que provavelmente as folhas estavam com deficiência nutricional de K. A faixa ideal para o fósforo deveria estar em 30 a 40 mg/dm^3 demonstrando que o P estava em níveis baixos Borges et al. (2012).

5 CONCLUSÕES

As maiores frequências de acertos do modelo foram para as classes que mais interessam ao diagnóstico da deficiência, mostrando a robustez do classificador gerado, evidenciada pela baixa probabilidade de classificação incorreta.

Os valores de sensibilidade e especificidade mostram que o modelo é altamente eficiente na identificação da deficiência (sensibilidade) e com alta capacidade de identificação na ausência de deficiência no campo (especificidade).

O modelo proposto mostra-se como uma ferramenta promissora no que diz respeito em fornecer conhecimento para um sistema de identificação automática.

REFERÊNCIAS

- ALMEIDA, R. F.; COSTA, M. G. Fisiologia do estresse vegetal: respostas morfológicas e anatômicas sob condições adversas. **Revista Brasileira de Botânica**, Curitiba, v. 18, n. 3, p. 204-219, 2022.
- BARANAUSKAS, J. A. **Introdução ao aprendizado supervisionado de máquinas**. 2000. Tese (Doutorado em Ciências da Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Paulo, 2000.
- BORGES, A. L.; SILVA, J. T. A.; CALHEIROS, H. C. Adubação, calagem e nutrição. In: BORGES, A. L.; SOUZA, L. S. (eds.). **O cultivo da bananeira**. Cruz das Almas: Embrapa Mandioca e Fruticultura Tropical, 2006. p. 113-138.
- BRAGA, A. P.; LURDEMIR, T. B.; CARVALHO, A. C. P. L. F. **Redes neurais artificiais**: teoria e aplicações. 2. ed. Rio de Janeiro: LTC, 2011. 262 p.
- BRUN, J. Le “bleu” du bananier en Guinée Française. **Fruits**, v. 7, n. 7, p. 324-329, 1952. Disponível em: https://agritrop.cirad.fr/457210/1/document_457210.pdf. Acesso em: 12 mar. 2026.
- CLARKSON, D. T.; HANSON, J. B. The mineral nutrition of Higher plants. **Annual Review of Plant Physiology**, v. 31, n. 1, p. 239-298, jun. 1980. Disponível em: <https://www.annualreviews.org/content/journals/10.1146/annurev.pp.31.060180.001323>. Acesso em: 12 mar. 2026.
- EFRON, B.; GONG, G. A leisurely Look at the bootstrap, the jackknife, and cross-validation. **The American Statistician**, Washington, v. 37, n. 1, p. 36-48, fev. 1983. Disponível em: <https://users.cla.umn.edu/~nwaller/prelim/efronbootjackcrossv.pdf>. Acesso em: 12 mar. 2026.
- EMBRAPA MANDIOCA E FRUTICULTURA. **Produção brasileira de banana em 2024**. Cruz das Almas: Embrapa Mandioca e Fruticultura, 2025. Disponível em: https://www.cnpmf.embrapa.br/Base_de_Dados/index_pdf/dados/brasil/banana/b1_banana.pdf. Acesso em: 4 jul. 2026.
- EPSTEIN, E. **Mineral nutrition of plants**: principles and perspectives. 1st ed. New York: John Wiley & Sons, 1972.
- ESCUDERO, C. A.; CALVO, A. F.; BEJARANO, A. Black Sigatoka classification using convolutional neural networks. **International Journal of Machine Learning and Computing**, v. 11, n. 4, p. 323-326, jul. 2021. Disponível em: <https://www.ijml.org/vol11/1055-T3017.pdf>. Acesso em: 12 mar. 2026.
- FACELI, K. *et al.* **Inteligência Artificial**: uma abordagem de aprendizado de máquina. 2. ed. Rio de Janeiro: LTC, 2021.
- Faquin, V. **Diagnose do estado nutricional das plantas**. Lavras: UFLA/FAEPE, 2002.

FERNEDA, E. Redes neurais e sua aplicação em sistemas de recuperação de informação. **Ciência da Informação**, Brasília, v. 35, n. 1, p. 25-30, jan./jun. 2006. Disponível em: <https://www.scielo.br/j/ci/a/SQ9myjZWLxnyXfstXMgCdcH/?format=pdf&lang=pt>. Acesso em: 24 maio 2026.

FOOD AND AGRICULTURE ORGANIZATION. **Banana market review**: preliminary results 2023. Roma: FAO, 2024. Disponível em: <https://www.fao.org/markets-and-trade/publications/en/>. Acesso em: 12 mar. 2026.

FOOD AND AGRICULTURE ORGANIZATION. **Crops and livestock products**. Statistic Division. Roma: FAO, 2022. Disponível em: <https://www.fao.org/faostat/en/#data/QCL/visualize>. Acesso em: 24 maio 2026.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**: aprendizado profundo. Tradução: Alessandro B. A. L. Ribeiro. Rio de Janeiro: Alta Books, 2019.

HAYKIN, S. **Neural Networks**: a comprehensive foundation. New York: MacMillan, 1999. 696 p.

HAYKIN, S. **Redes Neurais**: princípios e prática. 2. ed. Porto Alegre: Bookman, 2001.

HOTTELING, H. Simplified calculation of principal components. **Psychometrika**, Williamsburg, v. 1, n. 1, p. 27-35, mar. 1936. Disponível em: http://cda.psych.uiuc.edu/psychometrika_highly_cited_articles/hotelling_1936.pdf. Acesso em: 12 mar. 2026.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Levantamento Sistemático da Produção Agrícola**: Pesquisa Mensal de Previsão e Acompanhamento das Safras Agrícolas no Ano Civil. Rio de Janeiro: IBGE, 2024. Disponível em: <https://www.ibge.gov.br/estatisticas/economicas/agricultura-e-pecuaria/9215-levantamento-sistematico-da-producao-agricola.html>. Acesso em: 12 mar. 2026.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Produção de banana**. Rio de Janeiro: IBGE, 2022. Disponível em: [https://ftp.ibge.gov.br/Producao_Agricola/Levantamento_Sistematico_da_Producao_Agricola_\[mensal\]/Fasciculo_Indicadores_IBGE/2022/estProdAgri_202212.pdf](https://ftp.ibge.gov.br/Producao_Agricola/Levantamento_Sistematico_da_Producao_Agricola_[mensal]/Fasciculo_Indicadores_IBGE/2022/estProdAgri_202212.pdf). Acesso em: 20 maio 2025.

JOHNSON, R. A.; WINCHERN, D. W. **Applied multivariate statistical analysis**. 5. ed. New York: Pearson Prentice Hall, 2004. 773 p.

JOHNSON, R.; WINCHERN, D. **Applied Multivariate Statistical Analysis**. 5. ed. Englewood Cliffs: Prentice-Hall, 2002. Cap. 8.

LINDHAUER, M. G. The role of potassium in the plant with emphasis on stress conditions (water, temperature, salinity). *In*: POTASSIUM SYMPOSIUM, 1985, Pretoria. **Anais [...]**. Pretoria: International Potash Institute and Fertilizer Society of South Africa, 1985. p. 95-113.

- MALAVOLTA, E. **Elementos de nutrição mineral de plantas**. São Paulo: Ceres, 1980. 251 p.
- MALAVOLTA, E. **Manual de nutrição mineral de plantas**. Piracicaba: Ceres, 2006. 631 p.
- MALAVOLTA, E.; VITTI, G. C.; OLIVEIRA, S. A. **Avaliação do estado nutricional das plantas: princípios e aplicações**. 2. ed. Piracicaba: POTAFOS, 1997. 319 p.
- MARSCHNER, H. **Mineral nutrition of higher plants**. 2. ed. London: Academic Press, 1995. 889 p.
- MARSCHNER, H. **Marschner's mineral nutrition of higher plants**. 3. ed. San Diego: Academic Press, 2012.
- McCULLOCH, W. S.; PITTS, W. A Logical Calculus of the Ideas Immanent in Nervous Activity. **Bulletin of Mathematical Biophysics**, New York, US, v.5: p.115 – 133, 1943.
- MENGEL, K (1997) Agronomic measures for better utilization of soil and fertilizer phosphste. *European Journal of Agronomy*, v.7, p. 221-233.
- MESSETI, A. V. L. **Utilização de técnicas multivariadas na avaliação da divergência genética de populações de girassol (*Helianthus annuus*, L.)**. Tese de Doutorado: Energia na Agricultura, FCA, 2007. 87p.
- MITCHELL, T. M. **Machine learning**. Boston: McGraw Hill, 1997. 414 p.
- MOREIRA, R. S. **Banana: teoria e prática de cultivo**. Campinas: Fundação Cargill, 1987. 335 p.
- NATALE, W. *et al.* Nutrição e adubação de fruteiras tropicais. **Revista Brasileira de Fruticultura**, Jaboticabal, v. 30, n. 2, p. 534-555, 2008.
- PRADO, R. M. **Nutrição de plantas**. 2. ed. Jaboticabal: FCAV, 2021.
- Pearson, K. (1901). **Análise de componentes principais**. *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science*, 6, 559
- PEREIRA, M. A. *et al.* Redes neurais convolucionais e visão artificial na diagnose precoce de estresse nutricional em *Zea mays*. **Engenharia Agrícola**, Jaboticabal, v. 43, n. 2, 2023.
- POIRIER, Y.; BUCHER, M. Phosphate transporter. *In*: PLAXTON, W. C.; LAMBERS, H. **Homesostasis in arabidopsis**. Arabidopsis Book, 2002, p. e0024. DOI: 10.1104/tab.0024.
- RECH, I. **Dinâmica de fósforo em Latossolo submetido à aplicação de fosfato líquido e granulado**. 2020. Dissertação (Mestrado em Ciência do Solo) – Faculdade de Agronomia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2020.
- RIBEIRO, J. E. S. *et al.* Non-destructive methods based on machine learning for the prediction of sweet potato leaf area: a comparative approach. **IEEE Access**, v. 13, p.

47389-47405, mar. 2025. Disponível em: <https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=10925361>. Acesso em: 20 jun. 2026.

RODRIGUES, M. A.; SILVA, J. R. Sensoriamento remoto aplicado à identificação precoce de estresse nutricional em culturas agrícolas. **Revista Brasileira de Agricultura de Precisão**, v. 8, n. 2, p. 45-58, 2021.

SANTI, A. L. *et al.* Análise de componentes principais de atributos químicos e físicos do solo que limitam a produtividade de grãos. **Pesquisa Agropecuária Brasileira**, v. 47, n. 9, p. 1346-1357, 2012. DOI: 10.1590/S1678-3921.pab2012.v47.11238.

SERVIÇO BRASILEIRO DE APOIO ÀS MICRO E PEQUENAS EMPRESAS. **Perfil da Bananicultura no Vale do Ribeira**: Boletim de Inteligência de Mercado e Potencial Econômico. São Paulo: SEBRAE, 2025. Disponível em: <https://www.sebrae.com.br/sites/PortalSebrae/ufs/sp>. Acesso em: 12 mar. 2026.

SILVA, F. F. **Avaliação do estado nutricional para Ca, Mg e S em plantas de milho através da técnica de visão artificial**. 2011. Dissertação (Mestrado em Nutrição Vegetal) – Faculdade de Zootecnia e Engenharia de Alimentos, Universidade de São Paulo, Pirassununga, 2011.

SILVA, João Carlos. **Química e Fertilidade do Solo**. 2. ed. Viçosa: Editora UFV, 2022.

SILVA, Roberto. **Nutrição mineral e pós-colheita de frutos**. 2. ed. Piracicaba: ESALQ, 2022.

MODENESE-GORLA DA SILVA, **Processamento digital de imagens para identificação da sigatoka negra em bananais utilizando análise de componentes principais e redes neurais artificiais**. 2008. Tese (Doutorado em Energia na Agricultura) – Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Botucatu, 2008.

SILVA, P. H. S. **Diagnóstico nutricional da rúcula para nitrogênio com processamento digital de imagens**. São Paulo: Universidade Estadual Paulista (Unesp), 2021.

SOUZA, Carlos Alberto de. **Química e Fertilidade do Solo**. 3. ed. Viçosa: Editora UFV, 2021.

BRESSAN, Rafael S.; DE SOUZA JÚNIOR, Marcelo; PEREIRA, Douglas F.; BUGATTI, Pedro H.; SAITO, Priscila T. M.. SoyRetrieval - **Técnicas de Aprendizado e Recuperação de Imagens para Análise do Vigor de Sementes de Soja**. In: SEMINÁRIO INTEGRADO DE SOFTWARE E HARDWARE (SEMISH), 45. , 2018, Natal. **Anais [...]**. Porto Alegre: Sociedade Brasileira de Computação, 2018 . p. 83-94. ISSN 2595-6205. DOI: <https://doi.org/10.5753/semish.2018.3434>.

TAIZ, L. *et al.* **Fisiologia e desenvolvimento vegetal**. 6. ed. Porto Alegre: Artmed, 2017.

USHERWOOD, N. R. The role of potassium in crop quality. *In*: MUNSON, R. S. (ed.). **Potassium in agriculture**. Madison: American Society of Agronomy, Crop Science Society of America, Soil Science Society of America, 1985. p. 489-513.

VALADÃO, F. C. A. **Dinâmica do fósforo e crescimento radicular do milho em sistema plantio direto**. 2014. Tese (Doutorado em Agricultura Tropical) – Faculdade de Agronomia e Medicina Veterinária, Universidade Federal de Mato Grosso, Cuiabá, 2014.

VANCE, C.P., Uhde-Stone, C., Allan, D.L, 2003. Phosphorus acquisition and use, critical adaptations by plants for securing a nonrenewable resource. *New Phyt.* 157, 423-447 von Uexküll, H.R., Mutert, E., 1995. Global extent, development and economic impact of acid soils. *Plant Soil* 171, 1-5.

WITTEN, I. H.; FRANK, E. **Data mining**: practical machine learning tools and techniques with java implementations. 2. ed. San Francisco: Morgan Kaufmann, 1999. 558 p.