



VIII Congresso Internacional
de Gestão e Tecnologias

DESENVOLVIMENTO DE MÓDULO COMPUTACIONAL AUTOMATIZADO PARA IDENTIFICAÇÃO DE DEFICIÊNCIAS NUTRICIONAIS POR MEIO DE IMAGENS DE FOLHAS DE CAJUEIRO.

DESARROLLO DE UN MÓDULO COMPUTACIONAL AUTOMATIZADO PARA LA IDENTIFICACIÓN DE DEFICIENCIAS NUTRICIONALES MEDIANTE IMÁGENES DE HOJAS DE ANACARDO.

DEVELOPMENT OF AN AUTOMATED COMPUTATIONAL MODULE FOR IDENTIFYING NUTRITIONAL DEFICIENCIES USING IMAGES OF CASHEW LEAVES.

Apresentação: Comunicação Oral

Bruno Silva¹; Lucas Dutra²; Afrânio Araújo³ Alessandra Pacheco⁴

DOI: <https://doi.org/10.31692/2596-0857.VIIICOINTERPDVGT.0089>

RESUMO

O cajueiro (*Anacardium occidentale*), originário da América do Sul, é uma cultura de grande relevância econômica e social, especialmente na região Nordeste do Brasil, responsável por mais de 95% da produção nacional (Embrapa, 2024). A importância da cultura do cajueiro advém principalmente dos diversos produtos derivados da castanha e do pedúnculo, além da geração de empregos diretos e indiretos. No entanto, para garantir a qualidade do cultivo, é fundamental abordar os fatores que afetam a produtividade, como as deficiências nutricionais (Haag et al., 1975).

Com o aumento do uso de tecnologias digitais na agricultura, o presente trabalho propõe o desenvolvimento de um módulo computacional automatizado para identificar deficiências nutricionais em folhas de cajueiro por meio da análise digital de imagens. O sistema realiza o pré-processamento das imagens e aplica algoritmos de processamento digital de imagens (PDI) para destacar características visuais indicativas de deficiências, como necroses e cloroses. A análise emprega diversos canais e espaços

¹ Curso Técnico Integrado em Informática, EAJ/UFRN, bruno.ferreira.098@ufrn.edu.br

² Curso Técnico Integrado em Informática, EAJ/UFRN, lucasdeoliveiradutra@gmail.com

³ Doutor, EAJ/UFRN, afraniocesar2013@gmail.com

⁴ Doutora, EAJ/UFRN, alemendes@gmail.com



de cor, incluindo RGB, HSV e LAB, para identificar padrões associados a deficiências nutricionais específicas, como nitrogênio e potássio.

Os resultados mostraram uma acurácia de 83,33% na identificação de deficiências de nitrogênio, enquanto a identificação de potássio apresentou uma acurácia de 17,5%, indicando a necessidade de aprimorar o algoritmo para deficiências menos evidentes. O módulo desenvolvido visa reduzir o trabalho manual na análise nutricional e promover intervenções rápidas e eficazes, sendo particularmente útil para pequenos produtores com acesso limitado à assistência técnica especializada. Essa abordagem contribui para o avanço das práticas agrícolas automatizadas e para a melhoria da qualidade do cultivo do cajueiro.

Palavras-Chave: PDI, deficiências nutricionais, cajueiro, nutrição de plantas.

RESUMEN

El anacardo (*Anacardium occidentale*), originario de América del Sur, es un cultivo de gran relevancia económica y social, especialmente en la región Nordeste de Brasil, responsable de más del 95% de la producción nacional (Embrapa, 2024). La importancia del cultivo del anacardo proviene principalmente de los diversos productos derivados de la nuez y el tallo, además de la generación de empleos directos e indirectos. Sin embargo, para garantizar la calidad de los cultivos, es esencial abordar los factores que afectan la productividad, como las deficiencias nutricionales (Haag et al., 1975).

Con el uso cada vez mayor de tecnologías digitales en la agricultura, el presente trabajo propone el desarrollo de un módulo computacional automatizado para identificar deficiencias nutricionales en hojas de anacardo a través del análisis de imágenes digitales. El sistema preprocesa imágenes y aplica algoritmos de procesamiento de imágenes digitales (PDI) para resaltar características visuales indicativas de deficiencias, como necrosis y clorosis. El análisis emplea múltiples canales y espacios de color, incluidos RGB, HSV y LAB, para identificar patrones asociados con deficiencias nutricionales específicas, como nitrógeno y potasio.

Los resultados mostraron una precisión del 83,33% en la identificación de deficiencias de nitrógeno, mientras que la identificación de potasio mostró una precisión del 17,5%, lo que indica la necesidad de mejorar el algoritmo para deficiencias menos obvias. El módulo desarrollado tiene como objetivo reducir el trabajo manual en el análisis nutricional y promover intervenciones rápidas y efectivas, siendo particularmente útil para pequeños productores con acceso limitado a asistencia técnica especializada. Este enfoque contribuye al avance de las prácticas agrícolas automatizadas y a mejorar la calidad del cultivo de anacardos.

Palabras Clave: PID, deficiencias nutricionales, anacardo, nutrición vegetal.

ABSTRACT

The cashew tree (*Anacardium occidentale*), originally from South America, is a crop of great economic and social importance, especially in the Northeast region of Brazil, responsible for more than 95% of national production (Embrapa, 2024). The importance of cashew cultivation comes mainly from the various products derived from the nut and the peduncle, in addition to the generation of direct and indirect jobs. However, to ensure crop quality, it is essential to address factors that affect productivity, such as nutritional deficiencies (Haag et al., 1975).

With the increasing use of digital technologies in agriculture, this work proposes the development of an automated computational module to identify nutritional deficiencies in cashew leaves through digital image analysis. The system preprocesses the images and applies digital image processing (DIP) algorithms to highlight visual characteristics indicative of deficiencies, such as necrosis and chlorosis. The analysis uses multiple channels and color spaces, including RGB, HSV, and LAB, to identify patterns associated with specific nutritional deficiencies, such as nitrogen and potassium. The results showed an accuracy of 83.33% in identifying nitrogen deficiencies, while potassium identification showed an accuracy of 17.5%, indicating the need to improve the algorithm for less evident deficiencies. The developed module aims to reduce manual work in nutritional analysis and promote fast and effective interventions, being particularly useful for small producers with limited access to specialized technical

assistance. This approach contributes to the advancement of automated agricultural practices and to improving the quality of cashew cultivation.

Keywords: DIP, nutritional deficiencies, cashew tree, plant nutrition.

INTRODUÇÃO

O cajueiro (*Anacardium occidentale*), originária da América do Sul, é de grande importância em várias regiões tropicais do planeta; no Brasil, essa cultura se encontra especialmente na região nordeste, onde mais de 98% da área é ocupada por ela (Crisóstomo et al., 2019). A sua principal importância ao redor do planeta e, conseqüentemente, no nordeste Brasileiro, deve-se, principalmente, à diversidade de derivados da castanha e do pedúnculo do caju. Estes, por sua vez, possuem um alto valor nutricional: a castanha crua é fonte de vários minerais e diversas vitaminas. Já o pseudofruto (caju), apresenta altos teores de ácido ascórbico (vitamina C), por exemplo, vitamina diretamente ligada à prevenção de doenças como o escorbuto, além de ser um potente antioxidante, promovendo o retardo do envelhecimento celular (Sousa et al., 2021).

Ademais, vale ressaltar que essa cultura demonstra alta importância social no Brasil, que traduz-se pelo número de empregos diretos gerados: 35 mil no campo e 15 mil na indústria, além de 250 mil empregos indiretos nos dois segmentos (Embrapa, 2022).

Contudo, é notória a importância do cajueiro em diversos aspectos, o que demonstra a necessidade de um cultivo de qualidade. Mas, diversos fatores podem afetar diretamente o cultivo dessa espécie, como as deficiências nutricionais, às quais o cajueiro também está suscetível (Haag et al., 1975), como a de NPK (nitrogênio, fósforo e potássio). A insuficiência desses nutrientes pode ter um impacto significativo no desenvolvimento das plantas, levando, por exemplo, ao retardo no crescimento (Silva et al, 2006), dificuldades para a produção de alimento por meio da fotossíntese (AGROTÉCNICO, 2024), e a menor tolerância a pragas e doenças (Cultivar News, 2014).

"Logo, a detecção eficiente desta carência é de grande valia para o setor agrícola, pois possibilita o conhecimento inicial para a correção do problema, conservando assim a produção da cultura" (Faquin, 2002).

Ademais, existem diversos métodos para detectar a carência de nutrientes em plantas, como a diagnose foliar e visual, destacando-se como os mais comuns. A diagnose foliar envolve a análise do limbo da folha para determinar a concentração adequada de nutrientes, realizada em

diferentes estágios de crescimento da cultura. Por sua vez, a diagnose visual avalia características como textura, dimensão e coloração de partes vegetais (folhas, raízes, frutos, etc.) a fim de identificar um padrão reconhecível (Faquin, 2002). Tipicamente, tais métodos são executados manualmente por profissionais. No entanto, quando a quantidade de amostras a serem avaliadas é elevada, a precisão na detecção das deficiências tende a diminuir, além de aumentar o tempo necessário para a análise.

Nesse cenário, surge uma crescente utilização de tecnologias para proporcionar uma melhor produção de alimentos. Dentre as metodologias possíveis, soluções tecnológicas que visam a automatização e otimização de processos manuais no contexto das ciências agrárias é uma tendência crescente.

Por sua vez, sistemas computacionais que utilizam PDI destacam-se por sua eficiência, como demonstrado em diversas aplicações, principalmente para a avaliação qualitativa, como ocorre nos cultivos de soja (Júnior et al., 2010), milho (Medeiros et al., 2019), feijão (Kara et al., 2013). Essas abordagens inovadoras para análise foliar em plantas permitem uma avaliação mais eficiente e precisa do estado nutricional destas, facilitando a identificação de deficiências e a tomada de decisões para o manejo adequado das culturas. Além disso, essas soluções tecnológicas promovem a sustentabilidade ao reduzir o uso excessivo de insumos e promover o aumento da produtividade.

FUNDAMENTAÇÃO TEÓRICA

Este campo apresenta artigos e pesquisas relacionadas ao trabalho realizado, e está organizado em:

- Processamento digital de imagem.
- Identificação de deficiências nutricionais em plantas.

—Vale ressaltar a escassa diversidade de pesquisas científicas e de artigos de referência relacionados à identificação e análise de deficiências nutricionais—

Processamento digital de imagem

O processamento digital de imagem possui uma variedade de aplicações práticas, possuindo uma enorme versatilidade, tanto na segmentação de imagens, identificando e separando objetos, quanto no reconhecimento de palavras e fotos, digitalizando elas e até em

recuperação de imagens baseadas em conteúdo, procurando imagens com base em características visuais (de Queiroz et al., 2006).

É comum que as imagens sejam alteradas para melhorar seu conteúdo e obter informações precisas (VALE, 2014). Essas alterações são feitas por meio das etapas do Processamento Digital de Imagens (PDI).

Essas etapas acontecem em uma ordem específica, ou seja, você não pode passar de uma etapa para outra sem concluir a anterior. No entanto, nem todos os sistemas de PDI cumprem todas essas etapas, pois a aplicação delas depende do projeto em desenvolvimento e do propósito final (SILVA, K. 2017).

Trabalhos relacionados:

- Autor: da Silva, S. H. M. G. (2019). Objetivo: usar aprendizado de máquina para identificação de deficiências nutricionais em bananeiras.
- Autor: Silva, P. H. S. (2021). Objetivo: dar um diagnóstico nutricional da rúcula para nitrogênio a partir do processamento digital de imagens.
- Autor: Silva, F. A. (2015). Objetivo: aplicar o pré-processamento de imagens para otimização do reconhecimento de padrões na detecção de deficiência nutricional em espécies vegetais.
- Autor: Medeiros, L. N. (2018). Objetivo: analisar danos foliares em cajueiros através do processamento digital de imagens

Análise de deficiências nutricionais em plantas

Para que uma planta cresça bem e saudável, é necessário que seja feita uma gestão nutricional adequada, necessitando de uma abordagem abrangente para o diagnóstico nutricional, combinando observação visual, análise de solo, ensaios de adubação e, mais importante, análise foliar. Ademais, existem limitações em relação à diagnose visual, pois ela apenas consegue detectar deficiências severas que já estão impactando o crescimento e a produção (Rodrigues et al., 2002).

Trabalhos relacionados:

- Autor: Wilcox, G. E. (1976). Objetivo: identificar e corrigir deficiências nutricionais do feijão.
- Autor: Fageria, N. K. (2006). Objetivo: identificar e corrigir deficiências nutricionais do arroz.
- Autor: CRUZ, E. D. S (1981). Objetivo: identificar deficiências nutricionais no guaraná.

METODOLOGIA

Esta seção demonstra as etapas de desenvolvimento para que este projeto seja concluído, elas estão organizadas nos seguintes tópicos principais:

- Sistema de PDI
- Aquisição de dados e imagens
- Desenvolvimento do algoritmo

Sistema de PDI

Assim como em diversos projetos é utilizado a tecnologia do Processamento Digital de Imagens (PDI), neste trabalho, além de ter sido utilizado o PDI - composto por quatro etapas distintas de operacionalização (MODENESE-GORLA DA SILVA, 2008): aquisição do banco de imagens, pré-processamento, análise das características e classificação -, também houve uma última etapa que foi a de interpretação e exibição.

Sistema de PDI (Pré-processamento)

Essa é caracterizada como a fase mais importante do PDI, pois esta é a base para facilitar todo o código, deixando as partes de análise e classificação mais simples.

Nesta 1º etapa, são utilizadas técnicas de: redimensionamento das imagens, segmentação - ou remoção do fundo -, dilatação e erosão (correção de danos), com os objetivos de melhorar a qualidade da imagem original e destacar uma parte ou objeto de interesse na folha.


A etapa de redimensionamento das imagens tem o propósito de estabelecer uma resolução relativamente semelhante entre as imagens inseridas para o funcionamento adequado

do algoritmo, independentemente da resolução original da imagem inserida pelo usuário, para que este não precise se preocupar acerca da resolução da imagem que irá inserir.

A partir de testes realizados pelos pesquisadores, determinou-se que todas as imagens passariam a ter, igualmente, a mesma altura, 500 px. Sendo a largura, conforme explicado no parágrafo anterior, variada entre as imagens.

Devido ao processo de aquisição das imagens (com a folha da planta sobre a superfície da folha de ofício ou cartolina brancas), a imagem adquirida apresenta um fundo, ou background, no qual, se presente durante o processamento das imagens, pode prejudicar na etapa de extração de características relevantes para a identificação e classificação das deficiências nutricionais. Diante disso, fez-se necessário dedicar uma parte relativamente considerável do tempo destinado à realização do projeto para os pesquisadores desenvolverem uma função capaz de remover o fundo das imagens.

Figura 1 - folha sem segmentação (a), folha com segmentação(b)



Fonte: Autores

Devido a etapa de segmentação, a imagem pode apresentar alguma perda de pixels importantes, podendo acarretar em um erro na classificação. Para contornar este problema, é feito uma “recuperação” de pixels. Para isso, foram utilizadas as técnicas de dilatação e erosão.

A técnica da dilatação, por sua vez, consegue restaurar pixels que foram perdidos a partir dos que estão em sua proximidade. Já a erosão, serve para apagar parte da borda dos objetos,

para que não reste nenhum ruído ou zona desinteressante na imagem resultante. A erosão é feita logo após a dilatação, para que esta não restaure pixels que deveriam ser apagados.

Sistema de PDI (Análise das características)

A análise das características presentes na folha do cajueiro constitui a parte mais relevante do projeto como um todo, pois é a base para a identificação e classificação de deficiências nutricionais presentes na planta. Nesse passo, fez-se necessário o estudo e aprofundamento no assunto para a análise dos descritores, a fim da descoberta de características relevantes que sirvam no processo de classificação e na resolução dos objetivos requeridos. Como fruto destes estudos, foram observadas algumas características que visualmente se manifestam na lâmina foliar que demonstram determinadas deficiências nutricionais.

Para as deficiências de potássio, nitrogênio e fósforo, no cajueiro, observa-se: "[...] (potássio) apresentam uma leve clorose nas bordas. Ao contrário do N, os sintomas desenvolvem-se lentamente. Em estágio desenvolvido, a clorose avança para o limbo da folha, permanecendo verde apenas a base, numa espécie de V invertido. [...] (nitrogênio) Os sintomas são os primeiros a se manifestarem, com as folhas mais velhas tornando-se cloróticas da região apical para o limbo. Em face da mobilidade do nitrogênio, a carência começa nas folhas mais velhas, com as mais novas mantendo-se verdes em consequência da redistribuição, que é um processo relativamente rápido no caso do N. [...] (fósforo) As folhas mais velhas apresentam inicialmente uma coloração verde-escura e, em estágio mais avançado, tornam-se verde-opacas e caem" (MINHAS FRUTAS, 2017).

Figura 2 - folhas de cajueiro com deficiências de potássio



Fonte: Autores

Figura 3 - folhas de cajueiro com deficiências de nitrogênio



Fonte: Adaptado de BLOGGER GOOGLE USERCONTENT. Imagem ilustrativa sobre a deficiência de nitrogênio no cajueiro. Disponível [aqui](#) <Acesso em: 27 ago. 2024.>

Figura 4 - folhas de cajueiro com deficiências de fósforo



Fonte: Adaptado de GOOGLE USERCONTENT. Imagem ilustrativa sobre a deficiência nutricional de fósforo em folhas de cajueiro. Disponível [aqui](#) <Acesso em: 27 ago. 2024>.

Sistema de PDI (Classificação)

Essa etapa se refere à última fase da elaboração do algoritmo que se entende por back-end. Por sua vez, é preciso, nessa etapa, dos algoritmos que são responsáveis pelo pré-processamento e pela análise e extração de características relevantes das imagens das folhas do cajueiro. Para essa etapa, foi construído uma função que, com base nas características

extraídas anteriormente (na etapa de análise das características), analisa os dados obtidos e os relaciona com determinada deficiência nutricional.

Aquisição de imagens

A fase de aquisição de imagens é a primeira etapa para a construção de um projeto que envolve o processamento digital de imagens (GONZALEZ; WOODS, 2000), sendo a base para as posteriores. Com isso, pode-se afirmar que é uma das etapas mais importantes para o desenvolvimento de um projeto que utiliza técnicas como PDI, o que, conseqüentemente, demanda bastante tempo.

Inicialmente, foi recomendado aos pesquisadores, por meio do especialista, o cultivo de diversas plantas da cultura em questão - cajueiro -, nas quais, dentre estas, com adubo químico, 4 seriam adubadas com todos os nutrientes necessários (a saber: potássio, nitrogênio, fósforo, FTE, cálcio e enxofre), 4 plantas seriam adubadas com nitrogênio, fósforo, FTE, cálcio e enxofre (para ser, nestas, demonstrado a deficiência de potássio), 4 plantas seriam adubadas com potássio, fósforo, FTE, cálcio e enxofre (para ser, nestas, demonstrado a deficiência de nitrogênio), em 4 seriam adubadas com potássio, nitrogênio, FTE, cálcio e enxofre (para ser, nestas, demonstrado a deficiência de fósforo) e, por fim, 4 seriam adubadas com potássio, nitrogênio, fósforo, cálcio e enxofre (para ser, nestas, demonstrado a deficiência de micronutrientes). Para o projeto, os pesquisadores seguiram a recomendação, mas ao invés de ser trabalhado com 4 amostras com deficiências de FTE, as amostras com deficiência de N, P, K e saudáveis receberam uma a mais em sua quantidade (passando a ser 5 amostras em cada situação nutricional). Para o plantio, os pesquisadores reuniram, aproximadamente, 20 baldes de 15kg de margarina. Em seguida, compraram areia lavada e, para retirar as impurezas que ainda poderiam estar presentes, lavaram à mão toda a areia que viria a ser necessária. Depois, compraram as castanhas e, quando a areia já estava seca e nos seus respectivos baldes, elas foram plantadas. Todos os dias os bolsistas regavam e adubavam as mudas. Porém, devido ao plantio ser feito próximo ao período de recesso escolar anual, todas as pequenas mudas foram levadas da EAJ - onde elas inicialmente estavam - para a casa de um dos pesquisadores - Lucas. Poucos dias depois do transporte, as plantas começaram a apresentar sinais de excesso de água e, logo, morreram. Contudo, as primeiras amostras resultaram em algumas poucas imagens de deficiência de potássio claras e, também, algumas saudáveis. Os pesquisadores tentaram plantar outras amostras, mas estas não

resultaram em amostras interessantes, devido à má irrigação ou má adubação das amostras. Logo, foi abandonada a ideia de plantar as mudas pela falta de disponibilidade dos pesquisadores, tempo, e falhas recorrentes, e buscaram desenvolver bancos de imagens a partir de fotos de folhas de cajueiro já existentes. Para este projeto, foram produzidos três bancos de imagens com padrões e períodos distintos.

No primeiro banco, foi utilizado um fundo azul e obtido 230 imagens a partir de quatro dispositivos diferentes, essa aquisição foi considerada um teste, a fim de iniciar um esqueleto do pré-processamento, por tanto, ela não teve tantas exigências, além da necessidade da folha ser fotografada de cima para baixo com a folha do cajueiro na centralidade do fundo.

O segundo banco de imagens já apresentou várias mudanças devido a problemas encontrados no primeiro - com o fundo azul, parte das extremidades das folhas do cajueiro ficam azuladas, devido ao efeito de reflexão luminosa, o que pode, gravemente, influenciar no processo futuro de identificação e classificação das deficiências. O 2º banco foi feito com a exigência de um fundo branco, para corrigir o erro anterior e, além disso, foi tirada em um ambiente sem uma alta iluminação (já que algumas fotos da primeira aquisição tinham muitas sombras e partes das folhas ficavam “estouradas” - ou extremamente iluminadas, sendo impossível ver a real informação presente naquele local da folha - após a segmentação), neste 2º banco, foi obtido um total de 160 imagens tiradas por três aparelhos distintos.

O terceiro e último banco de imagens contou com uma maior quantidade de imagens, 233, e uma maior variedade de dispositivos, seis. Suas especificações foram quase as mesmas da segunda aquisição, apenas adicionando a variedade da posição das folhas do cajueiro no fundo, para fins de testes e melhoramento do código em situações variadas.

Desenvolvimento do sistema

Este item é dividido entre dois sistemas, o de backend e o de frontend. Para integrar esses dois sistemas em um único, foi utilizado, inicialmente, uma biblioteca da linguagem de programação python, chamada “pyinstaller”. O arquivo resultante funcionou no sistema operacional (S.O) Windows, mas apresentou erros ao ser testado no S.O linux, mais especificamente, o POP!_OS. Por essa razão, a biblioteca foi substituída por outra, chamada “CX_Freeze”, que funcionou corretamente ao integrar o código fonte do algoritmo com a interface gráfica utilizada em um único arquivo executável, para ambos os sistemas operacionais

testados. A vantagem deste arquivo é a desnecessidade do usuário ter as bibliotecas utilizadas na programação ou sequer a linguagem python instalada no seu dispositivo.

Desenvolvimento do sistema (Backend)

Para que um algoritmo seja produzido, faz-se necessário o uso de uma linguagem de programação. O algoritmo desenvolvido para o desenvolvimento do projeto apresentado por este documento foi a linguagem “python”, pois é uma linguagem que apresenta grande disponibilidade de recursos ao se tratar do processamento digital de imagens. Ademais, com o intuito de facilitar o desenvolvimento, o backend foi segmentado em três códigos com tarefas distintas - que se comunicam entre si - para que o objetivo do sistema seja concluído. Dentre os 3 algoritmos desenvolvidos, há o código de remoção de fundo ou segmentação, o main ou principal e, por fim, o responsável pela classificação. É importante ressaltar que, após todos os algoritmos serem desenvolvidos e testados corretamente, estes foram unificados em apenas um código que contém diversas funções.

Para que a imagem sem fundo (figura 1b) fosse obtida, o algoritmo seguiu os seguintes passos: primeiramente, redimensionou a imagem, para o código apresentar o mesmo funcionamento (ou semelhante) em imagens de diversas resoluções. Em seguida, foi desenvolvido um código que conta com um algoritmo que ajusta o contraste da imagem (para melhor nitidez de cores) e detecta as bordas da folha do cajueiro (objeto principal), identificando seus contornos. Depois disso, preenche os contornos obtidos para distinguir a área que não faz parte do fundo. Acerca do preenchimento do objeto com base em suas bordas, o algoritmo tenta, primeiramente, preencher utilizando a função “fillPoly”, da biblioteca OpenCV. Porém, para prevenir possíveis erros na função (os testes indicam que estes aparecem), devido, por exemplo, a má formação dos contornos, o código conta com um algoritmo que preenche as bordas, desde a primeira aparição de verde em cada linha (pois as bordas são marcadas com a cor verde) até a última delas - este método pode fazer com que as imagens apresentem um mal preenchimento do objeto, por isso, o algoritmo tenta, primeiramente, preencher as bordas com o método fillPoly. Para saber se utiliza um ou outro, o algoritmo utiliza, primeiramente, o 1º método abordado. Logo, faz uma contagem dos pixels verdes e dos pixels que correspondem ao total na imagem e, a partir desses valores, verifica se os pixels verdes estão em baixa proporção com o total; se sim, aplicar o 2º método. Se não, é porque o 1º método funcionou corretamente e preenche os pixels

do objeto. Após isso, o algoritmo converte a imagem para escala de cinza a imagem, converte o que, na máscara de pixels verdes era verde para branco na nova imagem cinza, realiza, nesta, operações de dilatações e erosões, para corrigir pequenos desvios da folha do cajueiro e, por fim, substituiu o fundo da imagem por preto, deixando apenas o objeto principal visível.

Como mencionado anteriormente, o código, como um todo, foi dividido em 3 partes importantes. Os mais importantes, desses dois, são os códigos de segmentação e extração de características e de classificação das deficiências, estes são os que verdadeiramente apresentam funcionalidades que atuam diretamente no processamento digital das imagens. Por sua vez, para integrar o código de segmentação ao de extração e classificação, os pesquisadores desenvolveram o código principal, ou Main. E, também, para ser o lugar de desenvolvimento da interface gráfica e, posteriormente, o escopo geral do código, onde todos os demais foram unificados.

O código feito para a extração de características relevantes e, com base nelas, a classificação das deficiências, foi construído com base nos dados obtidos pela análise das características das folhas. Muitas técnicas foram pensadas e brevemente estudadas para a realização dessa etapa, que os pesquisadores consideram a mais importante, como, por exemplo, o aprendizado de máquina (machine learning) ou a lógica fuzzy. Porém, devido ao tempo e a falta de recursos disponíveis (como a pouca quantidade de imagens relevantes para um banco maior), a melhor solução encontrada foi a de identificar, na imagem, os pixels que correspondem as necroses e cloroses, para que, a partir disso, fosse possível classificar as imagens em suas respectivas deficiências. Para extrair esses dados, os estudantes observaram uma grande diversidade de canais de cores diferentes encontrados no python, os canais e espaços de cores estudados foram: RGB (Red, Green, Blue), HSV (Hue, Saturation, Value), HLS (Hue, Lightness, Saturation), LAB (Luminance, Axis, Baxis) YCrCb (Luminance, Chrominance Red, Chrominance Blue), LUV (Luminance, Chrominance Component U, Chrominance Component V), XYZ (X Component, Y Component, Z Component) e YUV (Luminance, Chrominance Component U, Chrominance Component V) - algumas letras representam nomes semelhantes em vários canais, como mostrado, mas não necessariamente o mesmo canal de cor. O estudo desses canais teve o objetivo de identificar as áreas onde as necroses e cloroses ficavam mais destacadas.

Para identificar a necrose, o algoritmo realiza uma operação de subtração entre o canal “V” da imagem LUV e o canal “A” da imagem LAB. Após isso, o código transforma todos os pixels que são iguais a 0 (preto) em 255 (branco) - pois na subtração, os pixels que correspondem às necroses tendem a se igualar a 0 e, para realizar a próxima etapa, a de correção de erros, é mais recomendável que o objeto esteja inteiramente branco e o fundo, preto. O resultado dessa operação passa por uma erosão para eliminar ruídos e garantir que apenas as regiões significativas sejam consideradas. A imagem resultante apresenta os pixels que correspondem às necroses como branco e, os que não, como preto.

Para identificar clorose, o processo é um pouco mais complexo. Diante da análise de diversos canais, os pesquisadores decidiram, aqui, trabalhar com o canal “H” do espaço HSV e com o canal “R” do RGB. Ao invés de realizar uma subtração entre os canais, é realizado, aqui, uma adição. Por causa da adição entre estes canais, os pixels que correspondem a clorose na imagem original, aqui, tendem a obter um valor acima de 230 (em uma escala de 0 - 255, utilizada classicamente no PDI). A partir disso, o código eleva todos os pixels que são maiores que 230 para 255 e, os que são menores que 230, são rebaixados à 0. Após um processo de correção de erros na imagem resultante (dilatação e erosão), o algoritmo deixa, na imagem, apenas o seu maior objeto (que tende a corresponder a área de clorose). A imagem resultante apresenta os pixels que correspondiam a clorose, como 255, ou branco e, o que não é clorose (ou áreas menores), como 0, ou preto.

Com base na quantidade de pixels de necrose e na quantidade de pixels de clorose, é realizada, posteriormente, a classificação. Se as médias dos valores de vermelho e verde na imagem forem significativamente maiores do que a do azul, é identificado um déficit de nitrogênio (nessa condição, a folha inserida ao código é, provavelmente, uma folha muito amarelada, induzindo-se o pensamento de que a folha apresenta a deficiência de nitrogênio). Se a quantidade de necrose e clorose for significativa, a folha é classificada como deficiente em potássio. Para outras condições, entende-se que a amostra não demonstra as deficiências de potássio ou nitrogênio, podendo apresentar doenças, outras deficiências nutricionais ou serem saudáveis.

Desenvolvimento do sistema (Frontend)

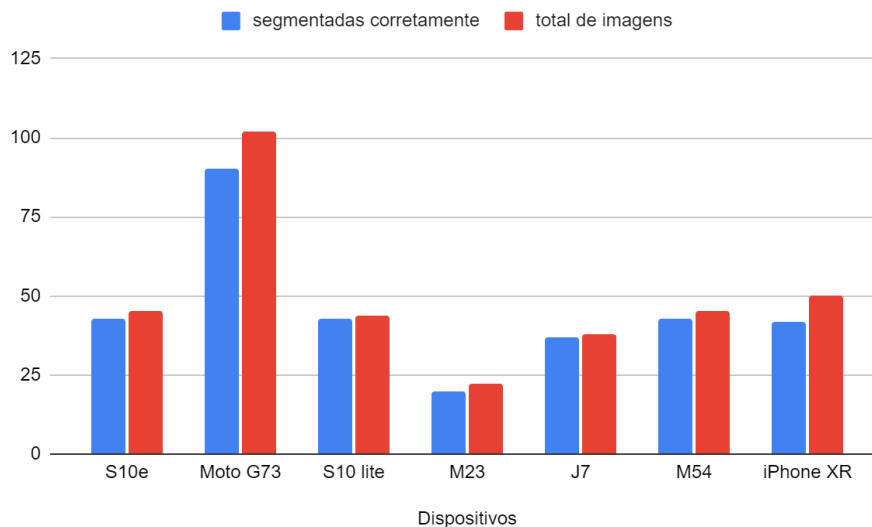
De forma prática, a etapa do desenvolvimento da interface gráfica foi a última etapa do desenvolvimento do software. Para facilitar a interação do usuário com o programa, os pesquisadores concordaram em criar uma interface gráfica para o software desenvolvido. A interface gráfica, devido ao tempo, não apresenta funções muito complexas, tão somente: título da aba; título da aplicação; um botão para o usuário carregar a imagem e, após a imagem ser carregada, uma mensagem que exibe a deficiência (em que o resultado não é absoluto, mas uma probabilidade, devido a eficácia abaixo de 100% do software). Acerca do algoritmo responsável para a criação do frontend, foi, também, utilizado o python. Para tal, foi utilizada a biblioteca “Tkinter”, que é voltada para o desenvolvimento deste tipo de software.

RESULTADOS E DISCUSSÃO

Para a extração final de dados, foi utilizado um banco com 345 imagens (resultado entre o 2º e 3º banco de imagens obtidos, conforme o item 3.2, sendo, nesse banco resultante, removidas algumas imagens irrelevantes, como as imagens tiradas pelo dispositivo Tablet Galaxy A7 - do 2º banco -, devido às suas imagens muito escuras), tiradas a partir de 7 dispositivos distintos (os modelos dos dispositivos usados são: Galaxy S10e, Moto G73, Galaxy S10 lite, Galaxy M23, Galaxy J7 Prime, Galaxy M54 e iPhone XR). Os resultados dos testes foram divididos em dois códigos, o de segmentação e de classificação.

Das 345 fotos, o algoritmo de segmentação desenvolvido obteve uma taxa de funcionalidade aproximada de 92,17%, tendo separado o fundo da imagem corretamente (é interessante ressaltar que, em algumas imagens, foram deixados alguns resquícios de fundo, mas que os pesquisadores inferiram ser irrelevantes) em 318 imagens, sendo elas 43 das 45 tiradas pelo S10e, 90 das 102 pelo Moto G73, 43 das 44 do S10 lite, 20 das 22 do M23, 37 das 38 do J7 Prime, 43 das 45 do M54 e 42 das 50 do iPhone XR (tabela 1).

Tabela 1 - imagens tiradas X segmentadas corretamente



Fonte: Autores

Tabela 2 - porcentagem de acurácia na segmentação

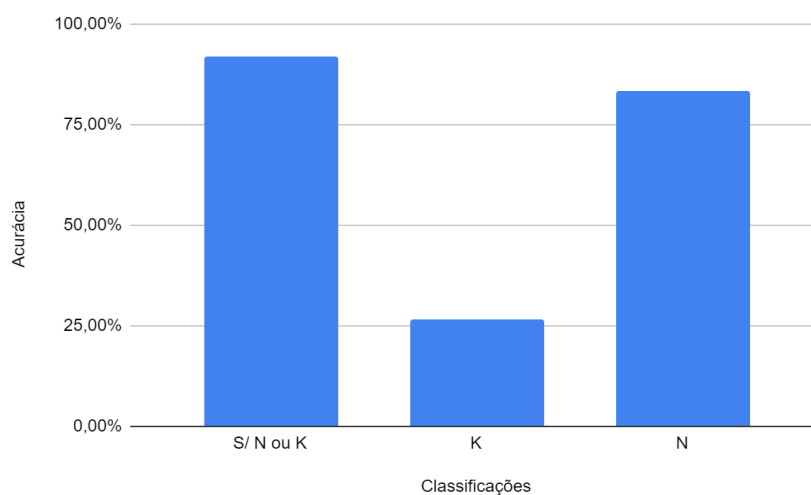
DISPOSITIVO	% DE ACERTO
S10e	95,55%
Moto G73	88,23%
S10 lite	97,72%
M23	90,90%
J7	97,36%
M54	95,55%
iPhone XR	84%
TOTAL	92,17%

Fonte: Autores

Por sua vez, grande parte do banco era formado por folhas saudáveis ou que apresentavam doenças. Mas, para calcular a acurácia do código de identificação e classificação de deficiências nutricionais, enviamos o 3º banco, tão somente, para um dos especialistas classificar, dentre diversas imagens do 3º banco, quais possuíam deficiência de potássio,

nitrogênio ou fósforo. Além disso, também utilizamos, para fins de testes, algumas imagens obtidas através da internet. Dentre todas as mencionadas, 40 foram identificadas, através do especialista, possuindo deficiência de potássio (além de 5 imagens que foram obtidas da internet). Das 45 folhas com déficit de potássio, 5 eram explícitas (em estado avançado) e foram identificadas corretamente. Por sua vez, as outras 40, que eram implícitas (em estado inicial) ou misturadas (com outras doenças e/ou deficiências), o algoritmo acabou falhando em classificá-las, tendo uma acurácia de apenas 17,5%. Para as de nitrogênio, houve uma acurácia de 83,33%, tendo sido identificado corretamente 5 das 6 imagens obtidas. Ademais, ainda foram classificadas erroneamente como portadoras da falta de potássio ou nitrogênio, um total de 21 imagens, ou 7,97%.

Tabela 3 - Classificação X Acurácia



•Fonte: Autores

CONCLUSÕES

Para este trabalho, foi implementado um método já conhecido –diagnose visual foliar (Rodrigues et al.,2002)–, porém útil, para identificar duas das principais deficiências nutricionais (N e K). Contudo, o principal objetivo da aplicação desenvolvida foi acelerar o processo de identificação conhecido com base na análise foliar, a partir do processamento digital de imagens (PDI), uma vez que o cajueiro não está suscetível apenas a uma deficiência nutricional de forma isolada, mas pode apresentar outras simultaneamente, o que pode dificultar tanto os trabalhos de classificação manuais quanto os automatizados, que são realizados por meio da diagnose visual (MALAVOLTA, 2006).

Entretanto, devido ao tempo e, principalmente, à falta de um banco de imagens verdadeiramente relevante (com muitas imagens que apresentassem as amostras deficientes e saudáveis), não foi possível atingir o objetivo esperado. Como mostrado nos resultados, a acurácia no processo de classificação cai significativamente quando o software é testado em imagens que contenham não somente a deficiência em questão.

Além disso, a cultura do cajueiro está altamente suscetível a diversas doenças (de Araújo Vianna, 2022), o que reduz ainda mais a acurácia da aplicação. Diante disso, pode-se afirmar que é preferível, apesar do tempo envolvido com o desenvolvimento deste projeto, a análise foliar realizada por um profissional da área.

Porém, apesar do módulo computacional desenvolvido não ter alcançado a acurácia esperada, ele ainda possui utilidade prática no campo. A identificação de deficiências nutricionais é uma tarefa desafiadora, tanto para especialistas quanto para sistemas automatizados. No entanto, ao permitir que o módulo assumas tarefas mais simples e repetitivas, ele pode acelerar o processo e liberar o especialista para focar nas análises mais complexas, que exigem maior expertise.

Como sugestões para futuros trabalhos, recomenda-se o desenvolvimento deste software com base em um banco de imagens relativamente grande que, inicialmente, apresente as deficiências nutricionais de forma isolada, contendo estágios iniciais, médios e avançados das deficiências. Além disso, sugere-se o desenvolvimento de um software que identifique sinais de doenças no cajueiro, permitindo assim a integração dos dois algoritmos, criando uma aplicação que possa ser verdadeiramente mais funcional.

Ademais, sugere-se também, para desenvolvedores que disponham de tempo e recursos, desenvolver o software com processamento das imagens com base em machine learning ou lógica fuzzy, para obter melhores resultados.

REFERÊNCIAS

ADAMI, M. et al. Estimativa de área foliar de soja usando imagens digitais e dimensões foliares. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO

CRISÓSTOMO, L. A. et al. Cultivo do cajueiro anão precoce: Aspectos fito técnicos com ênfase na adubação e na irrigação. Embrapa CNPAT. v. 65, e1676-6601, p.1-8, 2003.

Haag H.P., Sarruge J.R., de Oliveira GD, Dechen A.R. (1975) Nutrição mineral do cajueiro (*Anacardium occidentale* L.): I-deficiência dos macronutrientes-nota prévia. Anais da Escola Superior da ESA Luiz de Queiroz. 32: 185-190.

JÚNIOR, A. C. de N. et al. Detecção automática da Área foliar danificada da soja através de imagens digitais. In: Conference on Graphics, Patterns and Images (SIBGRAPI). 2009.

OLIVEIRA, V. H. Taniguchi, C. A. K. Crisostomo, A. L. Nutrição mineral do cajueiro. Embrapa Agroindústria Tropical, v. 2, e1677-1915, p. 1-44, 2013.

Pujari J. D., Yakkundimath R, Byadgi, A. S. (2015) Image processing based detection of fungal diseases in plants. Proc Comput Sci 46(Icict 2014):18021808. <https://doi.org/10.1016/j.procs.2015.02.137>.

RAMOS, D. A. et al. A cultura do caju. Brasília: SPI, 1996. 96p. Coleção Plantar, 34.

Shimabukuro, Y. E.; Mello, E. M. K.; Moreira, J. C.; Duarte, V. Segmentação e classificação da imagem sombra do modelo de mistura para mapear desflorestamento na Amazônia. São José dos Campos, INPE, 1997, 16 p. (INPE 6147- PUD/029).

VENTURIERI, A., SANTOS, J.R.dos. Técnicas de classificação de imagens para análise de cobertura vegetal. In: ASSAD, E.D., SANO, E.E. Sistema de informações geográficas aplicações na agricultura. 2 ed. Brasília: Embrapa, 1998. p. 351 - 371.

MODENESE-GORLA DA SILVA, S. H. Processamento digital de imagens para identificação da sigatoka negra em bananais utilizando análise de componentes principais e redes neurais artificiais. Tese de Doutorado: Energia na Agricultura, FCA, 2008. 83p.

RODRIGUES, M. et al. Avaliação do estado nutricional do dendezeiro: análise foliar. 2002.