

ESTIMATIVA DA ÁREA FOLIAR E QUANTIFICAÇÃO DE SINTOMAS DE DOENÇAS DO CAFEIEIRO POR SEGMENTAÇÃO DE IMAGENS DIGITAIS

Jhonata Santos Santana¹, Jamil de Almeida Baltazar², Igor Araújo Barbosa³, Josimar Cirilo Batista da Costa⁴, Jossimara Ferreira Damascena⁵, Pedro Luid de Sousa⁶

1. Dr. em Engenharia Agrícola, Engenheiro Agrônomo, Universidade Federal de Viçosa (UFV), Viçosa-MG.
2. Doutorando em Engenharia Agrícola, Engenheiro Eletricista, Universidade Federal de Viçosa (UFV), Viçosa-MG.
3. Doutorando em Engenharia Agrícola, Engenheiro Mecânico, Universidade Federal de Viçosa (UFV), Viçosa-MG.
4. Graduando em Agronomia, Centro Universitário de Ourinhos (Unifio), Ourinhos-SP.
5. Doutoranda em Agronomia, Universidade Estadual de Londrina (UEL), Londrina-PR.
6. Graduado em Agronomia, Universidade Estadual da Região Tocantina do Maranhão (UEMASUL), Imperatriz-MA.
E-mail: agro.starf@gmail.com

Recebido em: 15/05/2026 – Aprovado em: 05/06/2026 – Publicado em: 30/06/2026
DOI: 10.18677/EnciBio_2026B18

RESUMO

O monitoramento das lavouras de café é fundamental para a detecção precoce de doenças e adoção rápida de medidas de controle, evitando a propagação de patógenos e perdas produtivas que podem chegar a 50%. Entre as principais doenças destacam-se ferrugem, cercosporiose, mancha aureolada e bicho-mineiro. Tradicionalmente, a avaliação da incidência dessas doenças é feita por inspeção visual de especialistas, processo sujeito a erros e variações de interpretação. Este estudo teve como objetivo desenvolver um algoritmo em Python, utilizando as bibliotecas OpenCV, NumPy e Imutils, para estimar, por segmentação de imagens, a área total de folhas de cafeeiro e a área afetada por ferrugem, cercospora, mancha aureolada e bicho-mineiro. Foram coletadas 80 folhas com sintomas, organizadas em quatro classes, fixadas em folhas A4, numeradas e fotografadas a 40 cm de distância. O desempenho do método foi avaliado pelos coeficientes de correlação (r), concordância de Willmott (d) e índice de desempenho (c), comparando-se os resultados com medições obtidas no ImageJ. Os resultados indicaram forte ajuste entre os métodos para a maioria das avaliações, com coeficientes de determinação variando conforme o padrão sintomatológico das doenças. Conclui-se que o algoritmo desenvolvido é eficiente para estimar a área total e as regiões cloróticas e necróticas de folhas de cafeeiro afetadas por diferentes doenças.

PALAVRAS-CHAVE: Algoritmo; ImageJ; Segmentação.

LEAF AREA ESTIMATION AND QUANTIFICATION OF COFFEE DISEASE SYMPTOMS USING DIGITAL IMAGE SEGMENTATION

ABSTRACT

Monitoring coffee crops is essential for the early detection of diseases and the rapid adoption of control measures, preventing pathogen spread and yield losses that may reach 50%. Among the main diseases and pests are coffee leaf rust, cercospora leaf spot, aureolate leaf spot, and coffee leaf miner. Traditionally, the assessment of disease incidence is performed through visual inspection by specialists, a process subject to errors and interpretation variability. This study aimed to develop a Python-based algorithm using the OpenCV, NumPy, and Imutils libraries to estimate, through image segmentation, the total area of coffee leaves and the area affected by coffee leaf rust, cercospora leaf spot, aureolate leaf spot, and coffee leaf miner. A total of 80 symptomatic leaves were collected, grouped into four classes, fixed on A4 sheets, numbered, and photographed from a distance of 40 cm. Method performance was evaluated using the correlation coefficient (r), Willmott's concordance index (d), and performance index (c), comparing the results with measurements obtained using ImageJ. The results indicated strong agreement between the methods for most evaluations, with coefficients of determination varying according to the symptom patterns of the diseases. It was concluded that the developed algorithm is efficient for estimating total leaf area and the chlorotic and necrotic regions of coffee leaves affected by different diseases.

KEYWORDS: Algorithm; ImageJ; Segmentation.

INTRODUÇÃO

O monitoramento das lavouras é essencial para detecção precoce de doenças e consequente adoção de medidas de controle e prevenir perdas por conter a propagação dos vetores em meio a lavoura. O cafeeiro apresenta suscetibilidade a vários patógenos, algumas doenças como: ferrugem, cercospora e mancha de phoma podem causar perdas significativas de produtividade e qualidade (RIVAS *et al.*, 2025). A ferrugem do cafeeiro (*Coffea arabica* L.) é causada por *Hemileia vastatrix* Berk. & Br. a qual incide sobre folhas, brotações novas e raramente em frutos e os sintomas iniciais na face inferior das folhas são pequenas manchas amarelo-pálidas que se tornam amarelo alaranjadas e pulverulentas, e quando coalescem cobrem grande parte do limbo foliar (SALAZAR-NAVARRO *et al.*, 2024). A cercosporiose, causada por *Cercospora coffeicola* apresenta sintomas típicos na forma de pequenas manchas necróticas constituídas por um centro de cor clara e às vezes circundadas por um anel marrom-púrpura com bordas amarelas, dando origem ao nome mancha de olho marrom (ANDRADE *et al.*, 2021). De forma semelhante, a *Pseudomonas syringae* pv. *garcae*, agente causal da mancha aureolada, doença disseminada nas principais regiões produtoras de café do Brasil e considerada fator limitante para o cultivo em áreas favoráveis a patógenos (SILVA *et al.*, 2023).

Já o bicho-mineiro tem seu desenvolvimento e reprodução favorecidos por condições climáticas quentes e secas, que são encontradas na maioria das regiões brasileiras produtoras de café (VENZON, 2021). Quando ocorre em elevados níveis populacionais essa praga pode causar desfolha de até 70%, o que diminui a fotossíntese e pode reduzir a produtividade do café em 50% (MARTINS *et al.*, 2021;

ROSADO *et al.*, 2021). Essas minas nas folhas são ocasionadas pela praga durante a fase de larvas, transformando-se em áreas necrosadas e consequentemente mortas, com essa menor área fotossintetizadora, ocorre grande desfolha nos períodos mais prolongados de seca do ano (ORLANDO *et al.*, 2024).

Tradicionalmente, a avaliação da incidência de doenças do cafeeiro é determinada visualmente por especialistas e a qualidade desse diagnóstico depende muito do conhecimento dos especialistas humanos (ARAAF *et al.*, 2024). No entanto, a experiência humana não é facilmente adquirida por todos profissionais da atividade agrícola, e é menos acessível, especialmente no caso de pequenas propriedades em países em desenvolvimento (BATTOOL; BYUN, 2025). Além do mais, trata-se de um processo cognitivo que está sujeito a erros e imprecisões (SHOAIB *et al.*, 2025).

O reconhecimento e a classificação de sintomas de doenças em plantas por meio da aplicação de técnicas de processamento de imagens representam uma solução promissora para superar esse problema e reduzir a falta de conhecimento neste campo (NYAWOSE *et al.*, 2025). A agricultura tem acompanhado o desenvolvimento das mais diversas tecnologias, dentre elas várias pesquisas vêm sendo feitas voltadas à utilização da visão computacional na detecção de doenças em culturas isoladas, como milho, tomate, trigo, batata, frutas e hortaliças (PACAL *et al.*, 2025). Algumas técnicas utilizam métodos mais simples, enquanto outras podem seguir uma metodologia mais complexa envolvendo o uso de técnicas de Deep Learning (DL), incluindo Redes Neurais Convolucionais (CNN) (PACAL *et al.*, 2025). Entretanto, o uso de metodologias complexas como *deep Learning* e redes neurais convolucionais, para a classificação de doenças foliares requerem maior conhecimento sobre os processos complexos de estruturas de desenvolvimento de aprendizado profundo e reconhecimento de padrões. Embora as técnicas tradicionais de processamento de imagem não possuem a capacidade de identificação e rotulação automática de doenças de plantas, esta técnica quando empregada de forma eficiente fornece subsídios para que o usuário possa realizar a extração de padrões e interpretar de forma coerente os resultados.

Diversos trabalhos têm trabalhado com a detecção e classificação de doenças em plantas a partir de imagens, por exemplo Lamari (2008) introduziu uma ferramenta para avaliação da severidade de plantas chamada “Assess – avaliar”, enquanto Suarez *et al.* (2025), trabalharam em uma extensão do software de código aberto chamado *ImageJ* como método de análise de imagens de folhas para medir áreas em um estudo comparativo com ferramenta em Python. Zhang *et al.* (2017) demonstraram uma metodologia de identificação de doenças foliares em plantas de pepino. Inicialmente realizaram a segmentação de imagens de folhas doentes por agrupamento K-means, extração de características de forma e cor de informações de lesões e classificação de imagens de folhas doentes usando representação esparsa (SR), atingindo uma precisão de 85,7%. Thilagavathi *et al.*, (2020) realizaram detecção de doenças em cana-de-açúcar usando técnicas de processamento de imagens imagem, com melhoria de contraste de Adaptive Histogram Equalization (AHE), segmentação por agrupamento K-means e classificação usando o algoritmo Support Vector Machine (SVM), obtendo uma acurácia de 95%. Entretanto, há poucos trabalhos, nesse sentido, que foram desenvolvidos usando unicamente técnicas de processamento de imagens em Python em associação com a biblioteca OpenCV (SUAREZ *et al.*, 2025).

Diante disso, este estudo teve como objetivo desenvolver um algoritmo baseado em Python associado com a biblioteca OpenCV para determinar por meio

de segmentação de objetos a área de folhas de cafeeiro com e sem a presença de sintomas de infestação das doenças ferrugem, cercospora e mancha aureolada e bicho mineiro do cafeeiro.

MATERIAIS E MÉTODOS

Área de estudo e coleta das amostras

O estudo foi conduzido no Laboratório de Mecanização Agrícola da Universidade Federal de Viçosa-UFV em julho de 2025 no município de Viçosa, Minas Gerais. As folhas de cafeeiro utilizadas para a realização do estudo foram coletadas na área experimental do vale da agronomia dentro da Universidade Federal de Viçosa-UFV. A cultivar de *café arábica* instalada na área de coleta era o Catuaí vermelho, com espaçamento de 3,4 m na entrelinha e 0,8 m na linha de plantio, resultando em um estande de 3.700 plantas por hectare. Para a realização do estudo foram coletadas 80 folhas de cafeeiro com sintomas visíveis de infestação por doenças, sendo 20 folhas com sintomas de ferrugem, 20 folhas com sintomas de cercospora e 20 folhas com sintomas de infestação por mancha de aureolada e 20 folhas com sintomas de infestação por Bicho mineiro. A coleta foi realizada em diferentes posições do dossel de plantas, tomadas ao acaso da mesma área experimental.

Aquisição das imagens


Após a coleta, as folhas foram armazenadas em sacos plásticos e separadas em quatro classes conforme os sintomas das doenças. Em seguida, cada folha foi fixada individualmente em gabaritos A4 numerados de 1 a 80 e fotografada a 40 cm de distância com um smartphone Samsung Galaxy A51 (32 MP), no período da tarde, em área interna da sala do Laboratório de Mecanização Agrícola, sob iluminação artificial típica de escritório com lâmpadas fluorescentes padronizadas. Posteriormente, as folhas foram digitalizadas em sua coloração natural a 200 dpi utilizando uma impressora multifuncional HP DeskJet Ink Advantage 2376.

Desenvolvimento do algoritmo em linguagem Python usando a biblioteca OpenCV

Para realizar o processamento das imagens e quantificar a (% de área) da folha de cafeeiro com sintomas da infestação das doenças foi desenvolvido um programa utilizando linguagem de programação Python juntamente com a bibliotecas do *OpenCV*, *Numpy* e *Imutils*, no *Jupyter Notebook* do ambiente *Anaconda 3*.

As etapas de processamento realizadas pelo programa foram as seguintes: primeiramente o programa realiza a mudança do canal de cores de BGR para GRAY, transformando a imagem em tons de cinza, variando de 0 a 255, totalizando 256 tons de cinza. Em seguida, foi empregado um filtro gaussiano de 5x5 para remover alguns detalhes e logo depois aplicado o *Canny* para detectar as bordas da folha, seguida de uma limiarização binária, com um *threshold* com o valor do limiar de 100. Posteriormente o algoritmo realizou o desenho dos contornos recortando e mudando a perspectiva da imagem, detectando os quatro cantos a partir dos quadrados de marcação e a partir desses quatro pontos ajustando a perspectiva e o tamanho da imagem para um retângulo de 200 mm de largura x 250 mm de altura, de acordo com a Figura 1.


FIGURA 1. Imagem original (a), Imagem segmentada (b), detecção dos contornos para recorte e mudança de perspectiva (c).



Fonte: Autores (2026)

Na etapa seguinte, figura 2, o programa realizou a mudança do canal de cores *RGB* para *GRAY*, fazendo uma nova a limiarização com o valor do limiar de 100, da nova imagem recortada com perspectiva corrigida para detecção da área foliar, o algoritmo realizou o cálculo da relação de tamanho entre pixel e milímetro e o mesmo tempo eliminou os quadrados de marcação da imagem (Figura 2).


FIGURA 2. Imagem recortada e com perspectiva ajustada (a), mudança de RGB para tons de cinza (b), imagem limiarizada (c).



Fonte: Autores (2026)

Na próxima etapa, figura 3, o programa realizou a mudança do sistema de cores *RGB* para *Lab*, e depois fez a separação (split) dos canais *Lab*, e utiliza a banda *A*, e aplicou uma nova limiarização com o valor do limiar de 125, para detecção da área saudável. O valor do limiar foi definido empiricamente após testes preliminares visando maximizar a segmentação entre regiões saudáveis e lesionadas. Na última etapa o algoritmo realizou o cálculo de área total da folha e da área saudável em mm^2 e depois fez a subtração dos valores para encontrar a área infestada pela doença (Figura 3).

FIGURA 3. Imagem recortada e com perspectiva ajustada (a), mudança de RGB para Lab (b), imagem limiarizada com o valor de 125 (c).



Fonte: Autores (2026)

Estimativas das áreas com o ImageJ

Na próxima etapa, as imagens das folhas de cafeeiro em gabarito digitalizadas pela impressora em sua coloração natural, foram submetidas ao software *ImageJ* (ABRAMOFF *et al.*, 2004) para o cálculo das áreas com e sem a presença de sintomas de infestação das doenças.

Para o cálculo das áreas foliares no ImageJ, a imagem foi importada para o software por meio da ferramenta *File > Open*, em seguida, foi definida para imagem de 8 bits, por meio do comando *Image > Type*. Na etapa seguinte foi utilizado a ferramenta *Analyse > Set Scale* para colocar a imagem em sua escala real e em seguida foi usado a ferramenta *Analyse > Measure* para o cálculo das áreas. No próximo passo, foi realizada a conversão dos resultados em pixels, para unidade de medida em mm².

Análise dos dados

Os dados referentes às áreas foliares com sintomas de infestação, obtidos por com o programa desenvolvido em linguagem Python e ImageJ, foram organizados em uma planilha eletrônica do software Excel[®].

Com intuito de correlacionar o desempenho do método testado (programa desenvolvido em linguagem Python em comparação ao método padrão (ImageJ) foi empregado o teste estatístico sugerido por Willmott (1981), que utiliza o índice de concordância “d”, que permite observar a dispersão dos valores obtidos por um método qualquer em comparação ao modelo padrão (ImageJ), Equação (1). Além disso, foram empregados outros índices estatísticos como o coeficiente de Pearson (r) e o índice de confiança ou indicador de desempenho, designado pela letra (c), que reúne os coeficientes “r” e “d”, conforme as Equações (2) e (3) descritas abaixo. As análises de regressão foram realizadas com o programa Excel.

$$c = r.d \quad (3)$$

Pi - Área foliar obtida com o programa desenvolvido em linguagem Python (mm²); P - Média da Área foliar obtida com o programa desenvolvido em linguagem Python (mm²); Oi - Área foliar obtida com ImageJ (mm²); O - Média da Área foliar obtida com ImageJ (mm²). O índice de confiança ou desempenho varia de 0 quando não há nenhuma concordância entre os métodos a 1,0, quando há perfeita concordância

entre os métodos, qualificando o desempenho dos modelos testados segundo a Tabela 1.

TABELA 1. Qualificação do índice desempenho (c), segundo Camargo e Sentelhas (1997).

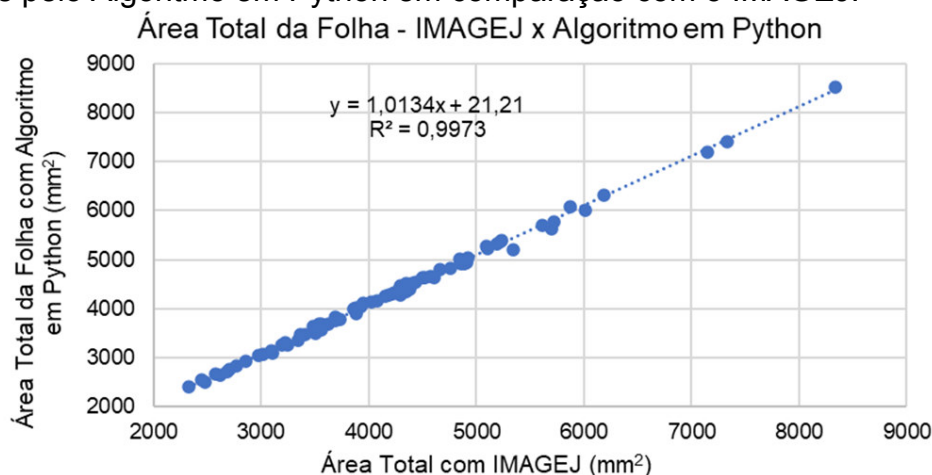
C	Desempenho
> 0,90	Ótimo
0,81 a 0,90	Muito Bom
0,71 a 0,80	Bom
0,51 a 0,70	Mediano
0,41 a 0,50	Sufrível
0,31 a 0,40	Mau
≤ 0,30	Péssimo

Fonte: Camargo e Sentelhas (1997)

RESULTADOS E DISCUSSÕES

Os Gráficos 1, 2, 3, 4, 5 e 6 apresentam os resultados da análise de regressão para estimativa da área total e doente das folhas de cafeeiro. As áreas obtidas pelo algoritmo desenvolvido em linguagem Python foram comparadas com medições realizadas no ImageJ, apresentando comportamento linear entre os métodos. Os coeficientes de determinação (R^2) variaram conforme a doença avaliada, indicando diferentes capacidades explicativas do modelo (ROUSTAEI et al., 2024). A Figura 4 apresenta a análise de regressão de 80 observações de área foliar obtidas pelos diferentes métodos estudados.

FIGURA 4. Equação de regressão entre os valores de Área Total da Folha estimadas pelo Algoritmo em Python em comparação com o IMAGEJ.



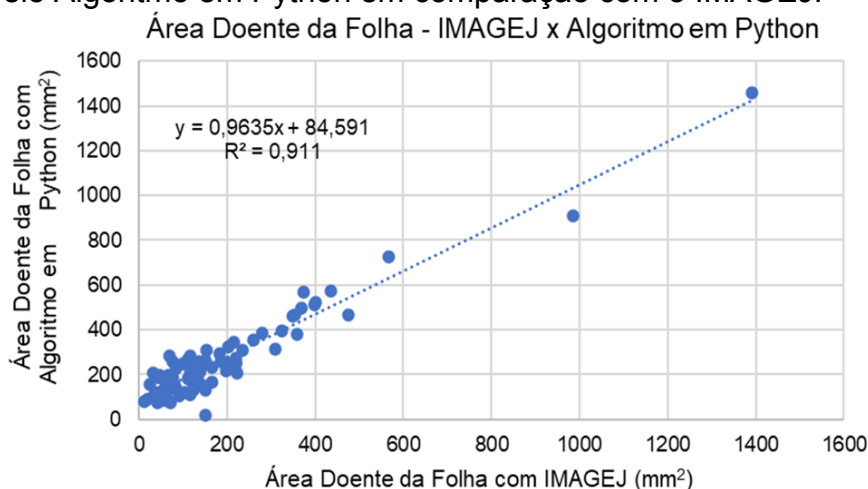
Fonte: Autores (2026)

Observa-se na análise da Figura 4 que os valores de área foliar obtidos pelo algoritmo desenvolvido em linguagem Python apresentaram forte ajuste em relação aos valores estimados com o ImageJ, com coeficiente de determinação (R^2) superior a 0,99. Esse resultado demonstra que as técnicas de processamento de imagens

empregadas, associadas ao ajuste automático de escala e perspectiva utilizando os gabaritos em folha A4, foram eficientes na estimativa da área foliar. Semelhante à abordagem adotada neste estudo, Satti et al. (2013) desenvolveram uma técnica de identificação de folhas baseada em etapas de pré-processamento, extração de características e classificação.

A Figura 5 apresenta a análise de regressão de 80 observações da quantificação da área foliar doente, correspondente às regiões cloróticas e necróticas de folhas de café com sintomas das quatro doenças avaliadas, obtidas pelos diferentes métodos estudados.

FIGURA 5. Equação de regressão entre os valores de Área doente da Folha estimadas pelo Algoritmo em Python em comparação com o IMAGEJ.

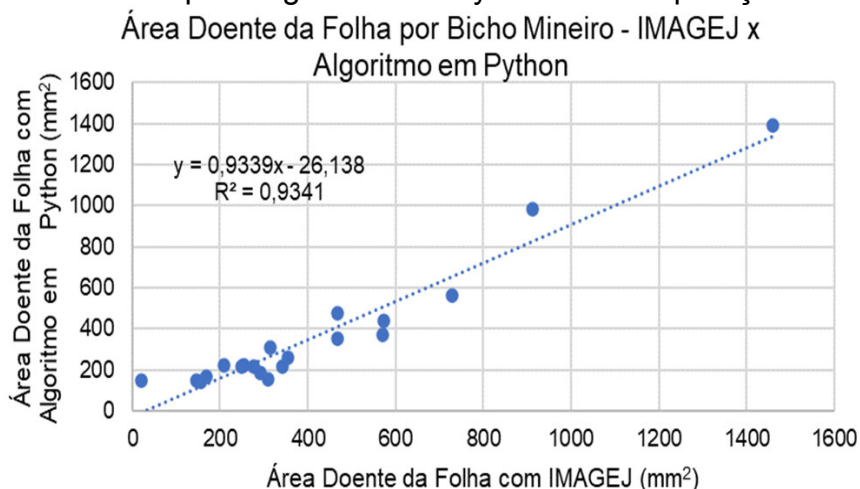


Fonte: Autores (2026).

Observa-se na análise da Figura 5 que, considerando 80 observações de área foliar doente obtidas pelo algoritmo desenvolvido em linguagem Python para as quatro classes de doenças avaliadas, o coeficiente de determinação obtido em comparação ao ImageJ foi superior a 0,90 ($R^2 = 0,911$), com os pontos adequadamente ajustados à reta de regressão. Esse resultado demonstra a eficiência do algoritmo na estimativa das regiões cloróticas e necróticas de folhas de café afetadas por diferentes doenças. De forma semelhante, Zhang et al. (2017) desenvolveram uma aplicação para identificação de doenças foliares em pepino utilizando agrupamento k-means e extração de características de cor e forma, alcançando precisão de 85,7%.

Com o objetivo de caracterizar o desempenho do algoritmo na estimativa das áreas cloróticas e necrosadas, os testes foram aplicados em quatro doenças com sintomas distintos. Os resultados das análises de regressão estão apresentados nas Figuras 6, 7, 8 e 9. A Figura 6 apresenta a análise de regressão da quantificação das regiões cloróticas e necróticas em folhas de café com sintomas de infestação por bicho-mineiro (*Leucoptera coffella*), obtidas pelos diferentes métodos avaliados.

FIGURA 6. Equação de regressão entre os valores da Área Doente da Folha por Bicho Mineiro estimadas pelo Algoritmo em Python em comparação com o IMAGEJ.

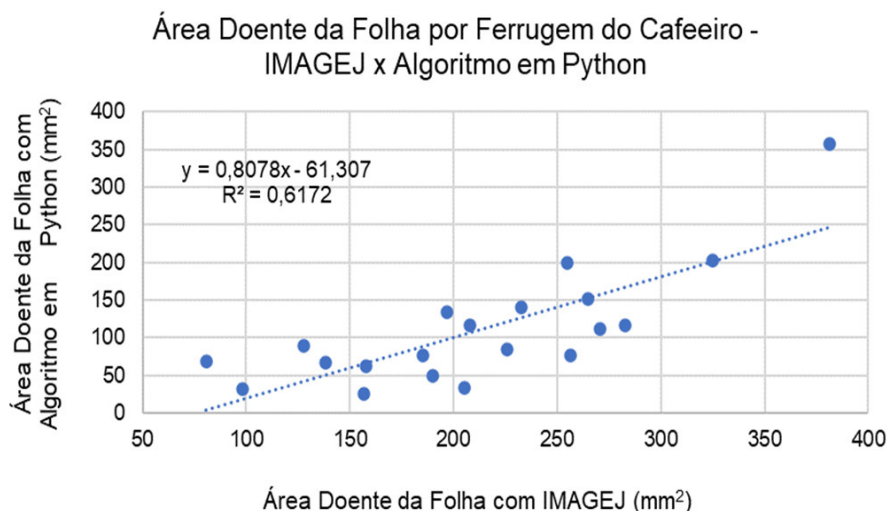


Fonte: Autores (2026).

Observa-se na Figura 6, que para as folhas com sintomas de ataque por Bicho mineiro, a análise de regressão da área estimada com o programa desenvolvido em Python, em comparação com o valor obtido pelo ImageJ, apresentou coeficiente de determinação superior a 0,90 ($R^2 = 0,933$), o mais elevado entre as quatro doenças avaliadas. Este resultado pode ser atribuído ao fato que as duas metodologias estudadas apresentam potencial semelhante em discriminar regiões necrosadas de regiões saudáveis, pois nos sintomas de folhas infestadas por bicho mineiro é nítida as áreas necrosadas e mortas quando afetadas pelo inseto. Nesse caso não houve clorose, mas sim uma transição brusca entre área doente e área saudável, o que facilita sua identificação e quantificação, conforme apresentado na Figura 6.

A Figura 7 apresenta a análise de regressão da quantificação das regiões cloróticas (amarelas) e necróticas em 20 folhas de cafeeiro com sintomas de infestação por ferrugem do cafeeiro (*Hemileia vastatrix*), obtidas pelos diferentes métodos estudados.

FIGURA 7. Equação de regressão entre os valores da Área Doente da Folha por ferrugem do cafeeiro estimadas pelo Algoritmo em Python em comparação com o IMAGEJ.

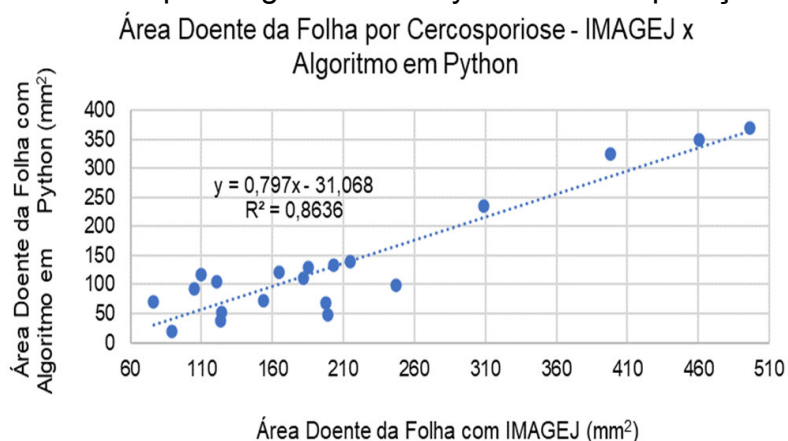


Fonte: Autores (2026).

A análise da Figura 7 demonstra que não houve ajuste satisfatório do coeficiente de determinação (R^2) entre os valores estimados pelo algoritmo desenvolvido em linguagem Python e aqueles obtidos pelo ImageJ para os sintomas de ferrugem do cafeeiro. Esse resultado pode estar relacionado à dificuldade do ImageJ em delimitar pequenas manchas de coloração amarelo-pálida ou amarelo-alaranjada, típicas da ferrugem, principalmente nos estágios iniciais da infestação. Em contrapartida, as técnicas de processamento de imagens empregadas no algoritmo em Python apresentaram maior eficiência na segmentação dessas regiões, resultando em diferenças na estimativa da área foliar e, conseqüentemente, em menor valor de R^2 .

Diferentemente dos resultados obtidos neste estudo, Guo *et al.* (2014) utilizaram recursos de textura e cor com abordagem Bayesiana para reconhecer diferentes doenças foliares, obtendo taxas de precisão entre 84,4% e 94,0%. A Figura 8 apresenta a análise de regressão da quantificação das regiões cloróticas e necróticas em folhas de cafeeiro com sintomas de Cercosporiose, obtidas pelos diferentes métodos avaliados.

FIGURA 8. Equação de regressão entre os valores da Área Doente da Folha por Cercosporiose estimadas pelo Algoritmo em Python em comparação com o IMAGEJ.

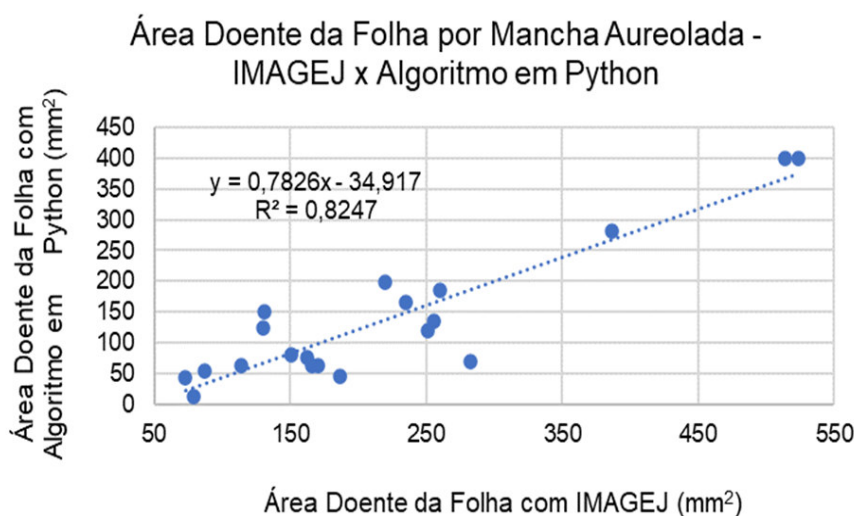


Fonte: Autores (2026).

O coeficiente de determinação (R^2) obtido para folhas com sintomas de Cercosporiose foi de 0,86. Esse resultado pode estar relacionado à dificuldade do software ImageJ em delimitar com precisão os sintomas da doença, caracterizados por manchas circulares castanhas com centro branco-acinzentado e halo amarelado. O ImageJ apresentou boa eficiência na identificação de regiões necróticas escuras, porém menor precisão na delimitação das áreas cloróticas do halo amarelado. Em contrapartida, o algoritmo desenvolvido em linguagem Python mostrou maior eficiência na segmentação tanto das regiões cloróticas quanto das necróticas, o que resultou em diferenças na estimativa da área afetada e, conseqüentemente, em menor valor de R^2 .

Segundo Shafay *et al.* (2025), a segmentação de regiões doentes em folhas agrícolas é desafiadora devido à variabilidade ambiental e às limitações de generalização dos métodos de detecção. A Figura 9 apresenta a análise de regressão da quantificação das regiões cloróticas e necróticas em folhas de cafeeiro com sintomas de mancha aureolada, obtidas pelos diferentes métodos avaliados.

FIGURA 9. Equação de regressão entre os valores da Área Doente da Folha por Mancha Aureolada estimadas pelo Algoritmo em Python em comparação com o IMAGEJ.



Fonte: Autores (2026).

O coeficiente de determinação (R^2) obtido entre os dois métodos para folhas com sintomas de mancha aureolada do cafeeiro foi de 0,8247. Esse resultado pode estar relacionado à dificuldade do software ImageJ em delimitar com precisão os sintomas da doença, que em alguns casos se assemelham à Cercosporiose, caracterizando-se por manchas necróticas pardas envolvidas por halo amarelado. Nessas condições, com transições entre regiões saudáveis e manchas cloróticas, o software apresenta menor precisão na segmentação das áreas lesionadas. Devido à semelhança entre os sintomas de mancha aureolada e Cercosporiose, era esperado que os valores de R^2 fossem próximos entre esses testes.

De modo geral, os resultados mostraram que o ajuste do coeficiente de determinação varia conforme as características dos sintomas avaliados. Em doenças com manchas necróticas bem definidas, como o Bicho Mineiro, os dois métodos apresentaram desempenho semelhante. Já em doenças com manchas cloróticas pouco acentuadas ou pálidas, o ImageJ apresentou menor precisão em comparação ao software desenvolvido em linguagem Python.

Entretanto, segundo Khoshvaght *et al.* (2025), o uso isolado do coeficiente de determinação (R^2) não é suficiente para avaliar o desempenho dos métodos, pois métricas únicas não representam totalmente as discrepâncias entre valores observados e estimados. Assim, uma segunda avaliação foi realizada utilizando os coeficientes de correlação “r”, concordância “d” de Willmott e o índice de desempenho “c”, apresentados na Tabela 2.

TABELA 2. Qualificação do índice desempenho (c) dos testes de comparação IMAGEJ x Algoritmo em Python.

Teste de Comparação	r	c	Desempenho
Área Total da Folha	1	1	Ótimo
Área Doente da Folha	0,95	0,90	Muito Bom
Área Doente da Folha por Bicho Mineiro	0,97	0,94	Muito Bom
Área Doente da Folha por Ferrugem do Cafeeiro	0,79	0,50	Sofrível
Área Doente da Folha por Cercosporiose	0,93	0,80	Bom
Área Doente da Folha por Mancha Aureolada	0,91	0,77	Bom

Fonte: Autores (2026)

De acordo com a Tabela 2, a comparação da área total das folhas estimada pelo software desenvolvido em linguagem Python apresentou desempenho “ótimo”, com índice de confiança igual a 1. Na avaliação da área doente das folhas, considerando as quatro classes de doenças, o desempenho foi classificado como “Muito Bom” em relação ao ImageJ, com coeficiente de correlação “r” de 0,95 e índice de confiança “c” de 0,90.

Para os sintomas de Bicho Mineiro, o desempenho também foi “Muito Bom” (“r” = 0,97; “c” = 0,94). Já para Ferrugem do Cafeeiro, as limitações do ImageJ na delimitação das lesões resultaram em desempenho “Sofrível” (“c” = 0,50). Para Cercosporiose e Mancha Aureolada, os desempenhos foram classificados como “Bom”, com índices de confiança de 0,80 e 0,77, respectivamente, possivelmente devido à semelhança entre os sintomas dessas doenças.

Entretanto, algumas limitações deste estudo devem ser consideradas, uma vez que as imagens foram obtidas em ambiente controlado, com iluminação artificial e fundo padronizado, condições que favoreceram a segmentação das regiões lesionadas. Assim, a aplicação do método em condições de campo pode apresentar desafios relacionados à variabilidade de iluminação, sombras, sobreposição de folhas e sintomas avançados de infestação. Dessa forma, estudos futuros devem avaliar o desempenho do algoritmo em condições reais de campo para ampliar sua robustez e aplicabilidade.

CONCLUSÕES

O programa desenvolvido em Python apresentou excelente desempenho na estimativa da área foliar total e das áreas doentes, com forte concordância em relação ao ImageJ ($R^2 > 0,99$ para área total e $R^2 > 0,90$ para áreas doentes). O método mostrou-se eficiente na identificação de regiões cloróticas e necróticas, com destaque para a detecção de danos causados pelo bicho-mineiro, que apresentou o maior ajuste ($R^2 = 0,933$). Além disso, observou-se que o algoritmo proposto apresentou maior sensibilidade na identificação de sintomas cloróticos iniciais quando comparado ao ImageJ.

REFERÊNCIAS

ABRAMOFF, M.; MAGALHÃES, P.; RAM, S. Image processing with ImageJ. **Biophotonics Int.** v.11, 36–42p. 2004. Disponível em: <https://imagej.net/ij/docs/pdfs/Image_Processing_with_ImageJ.pdf>.

ANDRADE, C. C.; RESENDE, M. L. V.; MOREIRA, S. I.; MATHIONI, S. M.; BOTELHO, D.; *et al.*; Infection process and defense response of two distinct symptoms of *Cercospora* leaf spot in coffee leaves. **Phytoparasitica**, v. 49, n. 4, p. 727-737, 2021. Disponível em: <<https://link.springer.com/article/10.1007/s12600-021-00902-2>>. doi: 10.1007/s12600-021-00902-2

ARAAF, R. T.; MINN, A.; & AHAMED, T. Coffee leaf rust disease detection and implementation of an edge device for pruning infected leaves via deep learning algorithms. **Sensors**, v. 24, n. 24, p. 8018, 2024. Disponível em: <<https://www.mdpi.com/1424-8220/24/24/8018>>. doi: 10.3390/s24248018

BATOOL, A.; BYUN, Y. C. Revolutionizing plant disease diagnosis through vision-based intelligence and next-generation computing. **Computers and Electrical Engineering**, v. 128, p. 110695, 2025. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S004579062500638X>>. doi: 10.1016/j.compeleceng.2025.110695

CAMARGO, A. P.; SENTELHAS, P. C. Evaluation of the performance of different methods of estimating potential evapotranspiration in the State of São Paulo, Brazil. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.5, n.1, p.89-97, 1997. Disponível em: <[http://www.leb.esalq.usp.br/agmfacil/artigos/artigos_sentelhas_1997/1997_RB_Agro_5\(1\)_89-97_ETPM%E9todosSP.pdf](http://www.leb.esalq.usp.br/agmfacil/artigos/artigos_sentelhas_1997/1997_RB_Agro_5(1)_89-97_ETPM%E9todosSP.pdf)>.

GUO, P.; LIU, T.; LI, N. Design of automatic recognition of cucumber disease image. **Information Technology International Journal**, v. 13, n. 13, p. 2129, 2014. Disponível em: <<https://scialert.net/abstract/?doi=itj.2014.2129.2136>>. doi: 10.3923/itj.2014.2129.2136

LAMARI, L. ASSESS 2.0: Image Analysis Software for Plant Disease Quantification. **American Phytopathological Society**, St. Paul, MN. 2008. Disponível em: <<https://www.scirp.org/reference/referencespapers?referenceid=1593566>>.

KHOSHVAGHT, H.; PERMALA, R. R.; RAZMJOU, A., KHIADANI, M. A critical review on selecting performance evaluation metrics for supervised machine learning models in wastewater quality prediction. **Journal of Environmental Chemical Engineering**, v. 13, n. 6, p. 119675, 2025. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2213343725043714>>. doi:10.1016/j.jece.2025.119675

MARTINS, R. N.; PINTO, F. D. A. C.; QUEIROZ, D. M.; VALENTE, D. S. M, FIM ROSAS, J. T. A novel vegetation index for coffee ripeness monitoring using aerial imagery. **Remote Sensing**, v. 13, n. 2, p. 263, 2021. Disponível em: <<https://www.mdpi.com/2072-4292/13/2/263>>. doi: 10.3390/rs13020263

NYAWOSE, T., MASWANGANYI, R. C., KHUMALO, P. A review on the detection of plant disease using machine learning and deep learning approaches. **Journal of Imaging**, v. 11, n. 10, p. 326, 2025. Disponível em: <<https://www.mdpi.com/2313-433X/11/10/326>>. doi: 10.3390/jimaging11100326

ORLANDO, V. S. W.; GALO, M. D. L. B. T.; MARTINS, G. D.; LINGUA, A. M.; ASSIS, G. A.; *et al.*; Hyperspectral Characterization of Coffee Leaf Miner (*Leucoptera coffeella*)(Lepidoptera: Lyonetiidae) Infestation Levels: A Detailed Analysis. **Agriculture**, v. 14, n. 12, p. 2173, 2024. Disponível em: <<https://www.mdpi.com/2077-0472/14/12/2173>>. doi: 10.3390/agriculture14122173

PACAL, I.; KUNDURACIOGLU, I.; ALMA, M. H.; DEVECI, M.; KADRY, S.; *et al.*; systematic review of deep learning techniques for plant diseases. **Artificial Intelligence Review**, v. 57, n. 11, p. 304, 2024. Disponível em: <<https://www.mdpi.com/2077-0472/14/12/2173>>. doi: 10.3390/agriculture14122173

<<https://link.springer.com/article/10.1007/s10462-024-10944-7>>.
10.1007/s10462-024-10944-7

doi:

RIVAS, R. E. G.; MELO, R. S.; SAIDE, S. M.; BACKES, A. R.; FERNANDES, H. C. Rust Detection in Coffee Leaves Using Otsu's Method and Mathematical Morphology. **Revista de Informática Teórica e Aplicada**, v. 32, n. 1, p. 212-219, 2025. Disponível em: <<https://sol.sbc.org.br/index.php/wvc/article/view/34039>>. doi:10.22456/2175-2745.143458

ROSADO, M. C.; ARAÚJO, G. J.; PALLINI, A.; VENZON, M. Cover crop intercropping increases biological control in coffee crops. **Biological Control**, v. 160, p. 104675, 2021. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S1049964421001456>>. doi:10.1016/j.biocontrol.2021.104675

ROUSTAEI, N. Application and interpretation of linear-regression analysis. **Medical Hypothesis, Discovery and Innovation in Ophthalmology**, v. 13, n. 3, p. 151, 2024. Disponível em: <<https://mehdijournal.com/index.php/mehdiophthalmol/article/view/1198>>. doi:10.51329/mehdiophthal1506

SALAZAR-NAVARRO, A.; RUIZ-VALDIVIEZO, V.; JOYA-DÁVILA, J.; GONZALEZ-MENDOZA, D. Coffee leaf rust (*Hemileia vastatrix*) disease in coffee plants and perspectives by the disease control. **Phyton Int J Exp Bot**, v. 93, p. 923-49, 2024. Disponível em: <<https://www.sciencedirect.com/org/science/article/pii/S0031945724000078>>. doi:10.32604/phyton.2024.049612

SATTI, V.; SATYA, A.; SHARMA, S. An automatic leaf recognition system for plant identification using machine vision technology. **International Journal of Engineering Science Technologies**, v. 5, n. 4, p. 874, 2013. Disponível em: <https://www.researchgate.net/publication/282148402_An_automatic_leaf_recognition_system_for_plant_identification_using_machine_vision_technology>.

SHAFAY, M.; HASSAN, T.; OWAIS, M.; HUSSAIN, I.; KHAWAJA, S. G., *et al.*; Recent advances in plant disease detection: challenges and opportunities. **Plant Methods**, v. 21, n. 1, p. 140, 2025. Disponível em: <<https://link.springer.com/article/10.1186/s13007-025-01450-0>>. doi: 10.1186/s13007-025-01450-0

SHOAIB, M.; SADEGHI-NIARAKI, A.; ALI, F.; HUSSAIN, I.; KHALID, S. Leveraging deep learning for plant disease and pest detection: a comprehensive review and future directions. **Frontiers in Plant Science**, v. 16, p. 1538163, 2025. Disponível em: <<https://www.frontiersin.org/journals/plant-science/articles/10.3389/fpls.2025.1538163/full>>. doi:10.3389/fpls.2025.1538163

SILVA, E. C.; RODRIGUES, L. M.; VILA, M. M.; & BALCÃO, V. M. Newly isolated phages preying on *Pseudomonas syringae* pv. *garcae*: In vitro and ex vivo inactivation studies in coffee plant leaves. **Enzyme and Microbial Technology**, v. 2026

171, p. 110325, 2023. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0141022923001333>>. doi: /10.1016/j.enzmictec.2023.110325

SUAREZ, E.; BLASER, M.; SUTTON, M. Automating Leaf Area Measurement in Citrus: The development and validation of a python-based tool. **Applied Sciences**, v. 15, n. 17, p. 9750, 2025. Disponível em: <<https://www.mdpi.com/2076-3417/15/17/9750>>. doi:10.3390/app15179750

THILAGAVATHI, K.; KAVITHA, K.; PRABA, R. D.; ARINA, S. V.; SAHANA, R. C. 2020. Detection of Diseases in Sugarcane Using Image Processing Techniques. **Bioscience Biotechnology Research Communications, Special Issue**, n. 11, p. 109-115, 2020. Disponível em: <https://www.researchgate.net/publication/358262183_Detection_of_Diseases_in_Sugarcane_Using_Image_Processing_Techniques_Classification>.doi:10.21786/bbrc/13.11/24

VENZON, M. Agro-ecological management of coffee pests in Brazil. **Frontiers in Sustainable Food Systems**, v. 5, p. 721117, 2021. Disponível em: <<https://www.frontiersin.org/journals/sustainable-food-systems/articles/10.3389/fsufs.2021.721117/full>>. doi:10.3389/fsufs.2021.721117

WILLMOTT, C. J. **On the validation of models. Physical Geography**, v. 2, p.184–194, 1981. Disponível em: <<https://www.scirp.org/reference/referencespapers?referenceid=2649830>>. doi:10.1080/02723646.1981.10642213

ZHANG, S.; WU, X.; YOU, Z.; ZHANG, L. Leaf image based cucumber disease recognition using sparse representation classification. **Computers and Electronics in Agriculture**, v. 134, p. 135-141, 2017. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0168169917300820>>. doi: 10.1016/j.compag.2017.01.014