

ANÁLISE DA COBERTURA DE PLANTAS DANINHAS UTILIZANDO VISÃO COMPUTACIONAL

ANALYSIS OF WEED COVER USING COMPUTER VISION

 <https://doi.org/10.63330/sasciencessv6n2-112>

Submetido em: 17/07/2026 e Publicado em: 31/07/2026

SAS: e26333

Mário Cupertino da Silva Júnior

Doutor em Engenharia Agrícola
Professor Associado na Universidade Federal de Sergipe
E-mail: mariocupertino@academico.ufs.br

Francisco de Assis de Carvalho Pinto

Doutor em Engenharia Agrícola
Professor Titular na Universidade Federal de Viçosa
E-mail: facpinto@ufv.br

Daniel Marçal de Queiroz

Doutor em Engenharia Agrícola
Professor Titular na Universidade Federal de Viçosa
E-mail: queiroz@ufv.br

Gonzalo Ruiz Ruiz

Engenheiro de Telecomunicações
Colaborador da Universidade de Valladolid
E-mail: ruizx3@gmail.com

Jaime Gómez Gil

Doutor em Engenharia Telemática
Professor da Universidade de Valladolid
E-mail: jgomez@uva.es

Luis Manuel Navas Gracia

Doutor em Engenharia Agroflorestal
Professor da Universidade de Valladolid
E-mail: luismanuel.navas@uva.es

Adson Andrade Barros

Graduado em Engenharia Agrícola
Mestrando em Desenvolvimento e Meio Ambiente na Universidade Federal de Sergipe
E-mail: adsonandrade.agro@gmail.com

Luis Gustavo Figueiredo França

Doutor em Engenharia Agrícola
Professor Associado na Universidade Federal de Sergipe
E-mail: luis.franca@academico.ufs.br



Resumo

O presente estudo aborda a determinação do percentual de cobertura de plantas daninhas por meio de imagens digitais aplicadas à agricultura de precisão. Trata-se de uma pesquisa aplicada que teve como objetivo desenvolver algoritmos capazes de realizar a aquisição automática e georreferenciada de imagens e determinar o percentual de cobertura de plantas daninhas, fornecendo informações para subsidiar a aplicação localizada de herbicidas. A metodologia consistiu no desenvolvimento de algoritmos no ambiente LabVIEW para aquisição simultânea de imagens e coordenadas de GPS, processamento digital das imagens, segmentação da vegetação, identificação das linhas de cultura e cálculo da cobertura de plantas daninhas. O sistema foi avaliado em uma área experimental cultivada com feijão, utilizando imagens obtidas por câmeras RGB e infravermelho próximo (NIR), cujos resultados foram analisados por meio de matrizes de confusão, exatidão global e índice Kappa. Os resultados demonstraram que os algoritmos permitiram automatizar a aquisição e o processamento das imagens, possibilitando determinar o percentual de cobertura de plantas daninhas nas entrelinhas. As imagens obtidas pela câmera RGB apresentaram maior desempenho de classificação em relação às imagens NIR, enquanto o sistema de plantio direto favoreceu a identificação da vegetação em ambas as câmeras. Conclui-se que os algoritmos desenvolvidos mostraram-se eficientes para estimar a cobertura de plantas daninhas, constituindo uma ferramenta de apoio às práticas de agricultura de precisão.

Palavras-chave: Agricultura de precisão; Plantas daninhas; Processamento digital de imagens; Sensoriamento agrícola; Visão computacional.

Abstract

The present study addresses the determination of the percentage of weed coverage thru digital images applied to precision agriculture. This is an applied research study aimed at developing algorithms capable of performing the automatic and georeferenced acquisition of images and determining the percentage of weed coverage, providing information to support the localized application of herbicides. The methodology consisted of developing algorithms in the LabVIEW environment for the simultaneous acquisition of images and GPS coordinates, digital image processing, vegetation segmentation, identification of crop rows, and calculation of weed coverage. The system was evaluated in an experimental area cultivated with beans, using images obtained by RGB and near-infrared (NIR) cameras, whose results were analyzed thru confusion matrices, overall accuracy, and Kappa index. The results demonstrated that the algorithms allowed for the automation of image acquisition and processing, enabling the determination of the percentage of weed coverage in the interrows. The images obtained by the RGB camera showed better classification performance compared to the NIR images, while the no-till system favored the identification



of vegetation in both cameras. It is concluded that the developed algorithms proved to be efficient in estimating weed cover, constituting a support tool for precision agriculture practices.

Keywords: Agricultural sensing; Computer vision; Digital image processing; Precision agriculture; Weeds.

1 INTRODUÇÃO

O surgimento de plantas indesejadas nas áreas agrícolas pode acarretar diversos problemas sobre as plantas cultivadas, interferindo não só na produtividade, mas também em todo o sistema de produção agrícola (Baio, 2001). Estudos mostram que as plantas jovens da maioria das culturas são sensíveis à interferência de plantas daninhas, devido à forte competição por nutrientes existente entre as plantas (Ronchi *et al.*, 2003), além da competição por luz. Com isso, é importante o controle das plantas daninhas, pois estas provavelmente consumirão nutrientes essenciais ao crescimento e desenvolvimento da cultura implantada podendo afetar na sua qualidade e produtividade.

Segundo a Agência das Nações Unidas para a Agricultura e a Alimentação (FAO), as plantas daninhas são consideradas o inimigo número um dos agricultores. O prejuízo que elas causam às lavouras no mundo chega a US\$ 95 bilhões por ano, com quebra da produção. Para a FAO, se os agricultores quiserem aumentar a produtividade de suas lavouras, a primeira coisa a fazer é melhorar a luta contra as ervas daninhas (Food and Agriculture Organization of the United Nations – FAO, 2010).

Um dos meios mais eficazes para se combater o crescimento de plantas daninhas é efetuando a aplicação de herbicidas. A aplicação convencional, seja ela executada por pulverizadores autopropelidos ou por equipamentos acionados por trator, promove a aplicação a uma taxa uniforme de herbicida em toda a área, ocorrendo a deposição de produtos químicos onde não existe incidência das plantas daninhas. Isto, além de gerar gastos desnecessários, prejudica o meio ambiente, contaminando-o. Assim, utilizar a quantidade certa de produto químico e aplicá-lo somente onde há ocorrência de plantas daninhas pode auxiliar os agricultores na otimização de sua produção, melhorando a qualidade de seus produtos e reduzindo futuros problemas ambientais.

Atualmente existe uma clara tendência para a diminuição do uso de produtos químicos na agricultura, tanto devido a questões ambientais quanto para redução de custos. Tecnologias têm sido desenvolvidas para tornar os produtos agrícolas mais seguros e diminuir seus impactos negativos sobre o meio ambiente e, com isso, a agricultura de precisão surge como uma valiosa ferramenta para alcançar esta meta (Tellaeche *et al.*, 2008). A agricultura de precisão, segundo Molin (2000), pode ser definida como um elenco de tecnologias e procedimentos utilizados para que os sistemas de produção agrícolas sejam otimizados, tendo como elemento chave, o gerenciamento da variabilidade espacial da produção e os fatores a ela relacionados.



Segundo Shiratsuchi (2001), informações da variabilidade espacial de fatores como fertilidades, umidade, produtividade, pragas, doenças, plantas daninhas, etc. devem ser analisadas com um nível maior de detalhamento para a racionalização e otimização das práticas de manejo agrícolas.

Na agricultura, a utilização de sistemas de visão artificial tem-se tornado interessante, principalmente para reduzir aplicação localizada de herbicidas, onde sistemas de controle de plantas daninhas baseado em visão estão sendo desenvolvidos para pulverizar especificamente em tempo real áreas infestadas (Gée *et al.*, 2008).

Técnicas de sensoriamento remoto e de processamento digital de imagens podem ser utilizadas para calcular o percentual de cobertura de plantas daninhas. Este cálculo pode tornar-se uma ferramenta útil para informar regiões de alta incidência de plantas, bem como regiões de ausência, e auxiliar na aplicação localizada de herbicidas. Entretanto, pode ser que dependendo da localização das câmeras e do tamanho da área retratada pelas imagens, seja difícil imagear toda a área. Logo, surge como solução, o uso de amostras da área e a construção de mapas do percentual da infestação, com o auxílio de técnicas de estatística espacial.

O objetivo do presente trabalho foi desenvolver algoritmos para capturar imagens georreferenciadas e determinar o percentual da cobertura de plantas daninhas.

2 MATERIAIS E MÉTODOS

Algoritmos com as funções de adquirir imagens e coordenadas de GPS simultaneamente e automaticamente, além de efetuar o processamento e análise das imagens foram implementados no software LabView, versão 8.6, da National Instruments. Estes algoritmos foram desenvolvidos por meio de uma parceria entre o laboratório PROVISAGRO (Projeto de Máquina e Visão Artificial na Agricultura) do Departamento de Engenharia Agrícola (DEA) da Universidade Federal de Viçosa e o Grupo de Investigación Reconocido de Tecnologías Avanzadas para el Desarrollo Rural Sostenible (GIR-TADRUS) do Departamento de Ingeniería Agrícola y Forestal (DIAF) da Escuela Técnica Superior de Ingenierías Agrarias (ETSIAA) da Universidad de Valladolid, campus de Palencia.

O software LabView é composto de duas partes, o painel de controle e o diagrama de blocos. No painel de controle, localizam-se os botões de controle, acionamento e de ajustes e também os campos de visualização dos resultados e das imagens, os gráficos e indicadores, entre outros. No diagrama de blocos, desenvolvem-se os algoritmos, os quais são construídos por meio do fluxo de dados entre blocos. Este fluxo de dados ocorre sempre da esquerda para a direita. Os diagramas de blocos do sistema desenvolvido estão apresentados nos Apêndices A e D.

Os algoritmos foram divididos em duas partes, de “Aquisição dos dados” e a de “Processamento das imagens”, sendo que a primeira foi dividida em transformação dos sistemas de coordenadas e ajuste de



parâmetros na tela de aquisição dos dados. A segunda parte foi dividida em três tópicos, que começou pela transformação das imagens coloridas em imagem índice, em seguida o processo de limiarização junto com a eliminação de ruídos nas imagens, e por fim a identificação das linhas de cultura e cálculo da porcentagem da cobertura de plantas daninhas.

2.1 AQUISIÇÃO DOS DADOS

O algoritmo desta parte promovia a captura automática e simultânea de duas imagens, coloridas e/ou monocromáticas, e as coordenadas geográficas de um ponto. Estas imagens retratavam a mesma cena e as coordenadas geográficas eram referentes ao ponto central da área comum a estas duas imagens.

O receptor GPS recebia informação dos satélites e as transmitia para o microcomputador, em um formato padronizado pelos fabricantes, ou seja, um protocolo. No presente trabalho o sistema proposto foi preparado para trabalhar com o protocolo NMEA (0183). Este protocolo possui várias sentenças de informações, entretanto utilizou-se somente a sentença RMC (Recommended Minimum Specific GPS/TRANSIT Data) que continha todos os dados necessários: latitude, hemisfério Norte ou Sul, longitude, hemisfério Leste ou Oeste e velocidade.

2.1.1 Transformação do sistema de coordenadas

As coordenadas capturadas estavam em latitude e longitude, entretanto, para possibilitar a construção futura de mapas em um plano cartesiano, implementou-se no sistema uma função para converter o sistema de coordenadas geográficas, em graus, para UTM (Projeção Universal Transversal de Mercator), em metros. Para efetuar essa conversão utilizaram-se as equações de Coticchia-Surace, de acordo com Espinosa *et al.* (2007), as quais são baseadas no elipsoide do *datum* WGS84.

Para iniciar o processo de transformação, foi necessário calcular alguns parâmetros do elipsoide como a segunda excentricidade (e') e o raio polar de curvatura (c), representados respectivamente pelas equações 1 e 2.

$$e' = \frac{\sqrt{a^2 - b^2}}{a} \quad (1)$$

$$c = \frac{a^2}{b} \quad (2)$$

em que “a” refere-se ao tamanho do semieixo maior da terra no elipsoide WGS84 e tem valor igual a 6.378.388 metros; e “b”, ao tamanho do semieixo menor da terra neste elipsoide e tem valor igual a 6.356.911,94613 metros.



Outro parâmetro calculado foi o fuso da projeção UTM que as coordenadas pertencem, conforme a equação 3. O valor do fuso é um número inteiro entre 1 e 60, pois nesta projeção, a Terra é dividida em 60 fusos, sendo que cada fuso possui 6° de longitude.

$$\text{fuso} = \left(\frac{\lambda}{6} + 31 \right) \quad (3)$$

em que λ é o valor em graus decimais da longitude (este valor tem sinal positivo se a coordenada estiver localizada no hemisfério leste e sinal negativo se estiver no hemisfério oeste). O valor final do fuso utilizado na equação 4 é o valor arredondado para o número inteiro mais próximo.

O próximo passo foi obter o meridiano central do fuso (λ_0), que é a linha que passa verticalmente no meio do fuso. Este meridiano é calculado de acordo com a equação 4.

$$\lambda_0 = (6 \text{ fuso}) - 183 \quad (4)$$

O último parâmetro calculado antes da utilização das equações de Coticchia-Surace foi a distância angular ($\Delta\lambda$), em radianos, entre a longitude do ponto (λ) e o meridiano central do fuso (λ_0) conforme a equação 5.

$$\Delta\lambda = \frac{(\lambda - \lambda_0) \pi}{180} \quad (5)$$

As equações de Coticchia-Surace são utilizadas para calcular as coordenadas UTM X e Y de acordo com as equações 6 e 7.

$$X = \zeta v \left(1 + \frac{\xi}{3} \right) + 500.000 \quad (6)$$

$$Y = \eta v(1 + \xi) + B_\phi \quad (7)$$

em que os parâmetros ζ , v , ξ , η e B_ϕ foram calculados segundo as equações do diagrama de blocos da Figura 1, sendo que “ ϕ ” é o valor da latitude em radianos. No hemisfério sul é necessário adicionar o valor 10.000.000 ao resultado de “Y”.

2.1.2 Ajuste de parâmetros na tela de aquisição do SVA

Para iniciar o funcionamento do sistema, foi necessário ajustar alguns parâmetros para os dados poderem ser adquiridos no tempo e espaçamento desejados e proporcionar imagens de melhor qualidade.



Esses parâmetros são a distância entre os pontos capturados e o tempo de exposição do sensor à luz pelo obturador eletrônico (electronics shutter). A distância entre pontos ajustada era comparada com a distância calculada a partir do GPS, por meio da velocidade de deslocamento. A velocidade de deslocamento era um dado recebido junto com as coordenadas, e tinha seu valor atualizado a cada segundo. Portanto, de posse do valor do tempo decorrido e da velocidade de deslocamento, calculava-se a distância entre pontos, e quando esta era igual ao valor da distância ajustada capturava-se as imagens e as coordenadas. Já o obturador eletrônico podia ser definido manualmente, atribuindo um valor a esse parâmetro e avaliando visualmente a qualidade da imagem capturada, ou automaticamente mediante o cálculo da quantidade de pixels saturados com valores de 255, e verificação da faixa aceitável para essa quantidade, definida pela observação das imagens em testes preliminares. Portanto, ao capturar as imagens, calculava-se a quantidade de pixels com valor 255 e verificava se o valor pertencia à faixa desejável, caso contrário aumentava ou diminuía o valor do tempo de exposição à luz.

2.2 PROCESSAMENTO DAS IMAGENS

2.2.1 Transformação das imagens RGB em imagens ExG

Após a aquisição, as imagens foram transformadas do espaço RGB em imagens índice monocromática, para aumentar o contraste entre as plantas e o solo de fundo, ou seja, destacar a vegetação dos outros elementos da cena (solo, pedras, palha, etc.). Para cada pixel das imagens índice foi atribuído um valor definido pelo índice excesso de verde (ExG) utilizando as bandas R, G e B de acordo com Woebbecke et al. (1995). Este índice foi calculado por meio da equação 8.

$$ExG = 2g - r - b \quad (8)$$

Em que, r , g e b são os valores digitais normalizados de R, G e B, respectivamente, de acordo com as equações 9, 10 e 11.

$$r = \frac{R}{R + G + B} \quad (9)$$

$$g = \frac{G}{R + G + B} \quad (10)$$


$$b = \frac{B}{R + G + B} \quad (11)$$



Em que R, G e B são os valores digitais de cada pixel das imagens coloridas nas bandas vermelho, verde e azul, respectivamente.

As imagens NIR, como são monocromáticas, não passaram por essa etapa de transformação, portanto foram limiarizadas diretamente.

Figura 1. Diagrama de blocos das equações que descrevem os parâmetros ζ , v , ξ , η e B_Φ .



Fonte: Autores (2026).



2.2.2 Processo de limiarização ou binarização

Em seguida foi realizado o processo de limiarização das imagens índice e nas imagens infravermelho próximo (NIR). Assim, para cada imagem, por meio do seu histograma, foi obtido um limiar T para o valor do *pixel*, calculado pelo método automático de limiarização iterativo apresentado por Yang *et al.* (2001), que segmentou a imagem em duas classes, plantas (planta daninha e cultura) e solo (resto da imagem). Este método iterativo assume que o valor do limiar ótimo é a média dos valores médios dos *pixels* das duas classes de um histograma bimodal.

Cada *pixel* que teve valor digital maior que o limiar T foi rotulado com o valor 255 (cor branca), os quais correspondiam à classe das plantas (daninhas e cultura), já os *pixels* que tiveram valor digital menor que o limiar T adquiriram o valor digital 0 (cor preta), correspondendo à classe solo e outros (pedras, palha, etc.).

2.2.3 Remoção de ruídos

Após a obtenção das imagens limiarizadas (binárias) utilizou-se as operações morfológicas OPEN e CLOSE fornecidas pelo LabView para atuar como filtros e remover os ruídos presentes nas imagens. Estas operações são referentes à abertura e fechamento das imagens, respectivamente. A operação de abertura consiste na aplicação sucessiva das operações de erosão e de dilatação e tem como resultado a eliminação de pontos isolados, ou seja, pequenos objetos podem desaparecer ou serem divididos. Já a operação de fechamento consiste na aplicação sucessiva das operações de dilatação e de erosão, promovendo a eliminação de espaços isolados, resultando no preenchimento de pequenos buracos, podendo unir objetos próximos. A aplicação consecutiva destas duas operações de abertura e fechamento faz com que os ruídos sejam eliminados sem a alteração do tamanho dos objetos.

A erosão e a dilatação são operações orientadas pela vizinhança. A vizinhança, neste caso, é definida por uma pequena imagem binária, denominada elemento estruturante, que percorre a imagem de entrada, preservando ou invertendo o pixel central da vizinhança, na imagem de saída, em função de seus vizinhos.

Para efetuar estas duas operações utilizou-se um elemento estruturante de dimensão 3 x 3. O centro deste elemento percorria pixel a pixel da imagem, e os oito pixels ao redor definia a alteração ou não do pixel central. Na dilatação, para cada pixel preto (fundo) posicionado no centro do elemento estruturante, na imagem binária de entrada, se houver pelo menos um vizinho branco (objeto), o pixel central é invertido na imagem de saída. Assim, os objetos crescem em área, podendo até se unir, e o fundo e os buracos nos objetos diminuem, sendo até mesmo eliminados. Na erosão, para cada pixel branco (objeto) posicionado no centro do elemento estruturante, na imagem binária de entrada, se houver pelo menos um vizinho preto (fundo), o pixel é invertido na imagem de saída. De modo que os objetos diminuam ou sejam eliminados, crescendo o fundo e os buracos (Gomes, 2001).




2.2.4 Determinação da porcentagem da cobertura de plantas daninhas

Para efetuar a determinação da porcentagem da cobertura de plantas daninhas, primeiramente, criou-se uma função que identificava o ângulo de inclinação das linhas de cultura nas imagens limiarizadas, utilizando a transformada de Hough. Isto foi necessário, pois dependendo da movimentação das câmeras em relação às linhas de cultura, estas podem estar em diversas direções nas imagens. Segundo Gée et al. (2008), dentre os principais algoritmos de detecção de linhas em imagens digitais esta técnica é considerada como uma das mais robustas.

Para a aplicação da transformada de Hough, foi utilizada a metodologia proposta por Duda e Hart (1972), os quais utilizaram o sistema de coordenadas polares para representação de uma linha reta, sendo esta parametrizada pela distância perpendicular (ρ) da origem à reta no plano x-y (plano da imagem), e pelo ângulo (θ) com a normal (eixo x) (Figura 2). Assim todo ponto (x, y) de uma reta satisfaz a equação 12.

$$x \cos \theta + y \sin \theta = \rho \quad (12)$$

Figura 2. Representação dos parâmetros de uma equação de reta em coordenada polar.




Fonte: Autores (2026).

O princípio desta técnica é a transformação dos pontos que representam objetos (pixels diferente de zero) do plano original x-y da imagem binária para o plano dos parâmetros ρ - θ . Portanto, pela equação 12, cada ponto (x, y) na imagem binária referente a objeto, gera uma curva senoidal em ρ - θ . Desta maneira, as curvas de pontos colineares na imagem binária se interceptam em um mesmo ponto em ρ - θ . Identificando estes valores de ρ e θ e utilizando novamente a equação 12 é possível localizar linhas na imagem pelos valores de x e y encontrados. Sendo assim, o algoritmo desenvolvido aplicava esta técnica e encontrava todos os valores de ρ e θ referentes aos pontos de interseções em cada imagem. Para evitar favorecimento de direções nas imagens, este algoritmo foi aplicado em uma máscara circular criada na parte central da imagem. Um esquema representativo destes passos para a identificação do ângulo de inclinação das linhas de cultura nas imagens pode ser visualizado pela Figura 3.



Observou-se em todas as imagens testadas que o ponto referente ao maior valor de interseções era representado por um ρ e θ que informava, corretamente, a posição e o ângulo de uma linha de cultura na imagem, ou seja, não era uma linha gerada por ruídos.

Figura 3. Esquema representativo do processo de aplicação da máscara circular na imagem binária filtrada, da construção do gráfico $\rho \times \theta$ e identificação do ângulo de inclinação das linhas de cultura.




Fonte: Autores (2026).

Portanto, o próximo passo consistiu em localizar as linhas de cultura para separá-las dos espaços entrelinhas. Para realizar esta localização, efetuou-se, primeiramente, a rotação das imagens, com base na inclinação determinada pela transformada de Hough, para deixar as linhas de cultura sempre posicionadas na vertical. Para efetuar a rotação, foi utilizada uma função disponível do LabView, sendo que a função de interpolação utilizada para reposicionar os pixels das imagens foi a bilinear.

Após a rotação das imagens foi construída uma função para recortar a parte comum nas duas imagens capturadas simultaneamente e para que as linhas de cultura tivessem o mesmo tamanho nesta parte comum, pois quando há linhas inclinadas e a imagem é rotacionada existirão linhas na vertical de diversos tamanhos. O valor desse recorte vai depender do tamanho das imagens e das distâncias entre as câmeras, ou seja, da área de sobreposição das duas imagens simultâneas. O processo de rotação e recorte das imagens está ilustrado por um esboço presente na Figura 4.

Figura 4. Etapas de rotação e recorte das imagens binárias.



Fonte: Autores (2026).




Por fim, com as linhas de cultura posicionadas verticalmente nas imagens, a última etapa se baseou em localizar e separar as linhas de cultura. Para efetuar este passo, foi implementada uma função que transformava as imagens em um sinal que representava a quantidade de pixels que indicava a presença de planta, por cada coluna. A partir da análise desse sinal, era possível identificar a posição e a largura das linhas de cultura, pois observando os picos do sinal verificou-se que estes representavam as linhas de cultura e os vales o espaço das entrelinhas. Consequentemente, os distúrbios ocorridos nos picos do sinal eram proporcionados principalmente pelas falhas e irregularidades das linhas de cultura e os distúrbios nos vales eram basicamente referentes à presença de plantas daninhas.

Para localizar e definir a largura das linhas de cultura em cada imagem calculou-se a média total do sinal e traçou-se a linha horizontal referente a este valor e atribuiu-se os limites das linhas de cultura às colunas da imagem referente aos pontos de interseções do sinal com esta linha horizontal.

Ao definir a posição e a largura das linhas de cultura efetuou-se a separação destas do espaço entrelinhas e calculou-se o percentual referente à cobertura das plantas daninhas em cada imagem, pela contagem dos pixels que as representavam. Assumiu-se que todas as plantas nas linhas identificadas eram culturas e nas entrelinhas eram plantas daninhas. A Figura 5 ilustra este processo de identificação das linhas de cultura das imagens.

Figura 5. Etapas do processo de identificação e separação das linhas de cultura e construção das imagens só com linhas de cultura e só com os espaços entrelinhas.



Fonte: Autores (2026).

Os valores de percentuais da cobertura das plantas daninhas e seus respectivos valores de coordenadas foram gravados em um arquivo de dados para serem utilizados posteriormente na construção de mapas da cobertura de infestação de plantas daninhas de toda a área.



2.3 AVALIAÇÃO DOS ALGORITMOS DE PROCESSAMENTO DE IMAGENS

Para avaliar o processamento das imagens realizou-se um estudo em uma área experimental de 0,8 hectares, pertencente à Universidade Federal de Viçosa (UFV) na cidade de Coimbra, MG. Esta área estava sob manejo de irrigação constituído por um pivô central, e a cultura implantada era feijão, cultivar ouro vermelho, utilizando os sistemas de plantio direto e convencional, cada um ocupando metade da área.

Utilizaram-se duas câmeras do modelo STH-DCSG-VAR/-C, sendo uma monocromática e outra colorida, compondo um sistema de aquisição de imagens. Estas câmeras capturaram duas imagens, simultaneamente, da mesma cena. Na câmera monocromática foi acoplado um filtro passa alta com início no comprimento de onda de 695 nm, para limitar a faixa do espectro que sensibiliza o sensor da câmera somente na faixa do infravermelho próximo (NIR). Com isso foram obtidas imagens da banda do NIR e imagens coloridas, que contém as bandas R (vermelho), G (verde) e B (azul).

As câmeras foram conectadas a um microcomputador portátil por meio de cabos com 10 m de comprimento conectados em uma placa de aquisição de imagens PCMCIA IEEE 1394, que fez a interface das câmeras com o microcomputador. Para o funcionamento das câmeras foi utilizada uma bateria de 12 Vcc conectada à placa PCMCIA. O padrão das lentes utilizadas foi o C-mount com a distância focal de 2,8 mm e as imagens foram salvas no formato BMP (Bitmap) com dimensão de 480(V) x 640(H) pixels, utilizando o software SRI's Small Vision System (SVS), que controla as câmeras, fornecido pelo próprio fabricante das câmeras. O sensor das câmeras, formador das imagens, foi o imageador CMOS MT9V022 no formato de 1/3". Estas câmeras foram posicionadas na estrutura móvel de um pivô central, na parte superior do mesmo, tendo suas lentes voltadas para baixo, focalizando o alvo (linhas de cultivo e entrelinhas).

Na realização desta avaliação ainda não havia sido implementada a interface do sistema automático de aquisição de imagens, por isso utilizou-se o programa de computador SVS, para adquirir as imagens.

Com isso, ao longo de toda a área foram obtidas, aleatoriamente, 10 imagens da banda do NIR e 10 imagens coloridas, em cada sistema de plantio. Essas imagens foram processadas e as respectivas imagens binárias filtradas foram geradas para poder ser efetuado o processo de avaliação.

A avaliação do sistema de processamento das imagens tomou como referência as imagens RGB, pela razão destas possuírem melhor visualização das feições (cultura, plantas daninhas, solo, palhada, etc.).

Sendo assim, em cada uma das imagens RGB foram escolhidos 100 pontos (pixels) aleatórios, e os mesmos pontos foram localizados nas respectivas imagens binárias filtradas geradas tanto pela própria imagem RGB quanto pela imagem NIR. Estes pontos foram comparados, de forma a verificar se o pixel escolhido na imagem de referência (RGB) condizia com o pixel processado nas imagens binárias (planta ou não-planta), sendo que planta refere-se à cultura; e planta daninha e não-planta referem-se às outras



feições. Por fim, calculou-se a matriz de confusão, utilizando o total de erros e acertos das 10 imagens, para cada sistema de plantio e tipo de câmera.

A matriz de confusão ou matriz de erro é uma matriz quadrática de números que expressam a quantidade de unidades amostrais, associada a uma dada categoria durante o processo de classificação efetuado e à categoria real a que pertencem essas unidades. A matriz de erros é uma forma útil para representar a exatidão, uma vez que as exatidões das diferentes classes estão claramente descritas, mostrando os erros de comissão e de omissão presentes na classificação de Congalton (1991). Este autor cita que a exatidão global, pode ser calculada dividindo-se o total de amostras corretamente classificadas (a diagonal da matriz de erros) pelo número total de amostras na matriz. A Tabela 1 exemplifica a matriz de erro calculada neste estudo.

Tabela 1. Exemplo da matriz de confusão calculada para cada sistema de plantio e tipo de câmera.

Valor estimado	Valor de referência		Erros de inclusão (%)
	Planta	Não Planta	
Planta	Número de pontos referentes a plantas classificados como planta (PP)	Número de pontos referentes a não-planta classificados como planta (NPP)	$\frac{(NPP)}{(PP) + (NPP)}$
Não-planta	Número de pontos referentes a plantas classificados como não-planta (PNP)	Número de pontos referentes a não-planta classificados como não-planta (NPNP)	$\frac{(PNP)}{(PNP) + (NPNP)}$
Erros de omissão (%)	$\frac{(PNP)}{(PP) + (PNP)}$	$\frac{(NPP)}{(NPP) + (NPNP)}$	Exatidão global (%) $\frac{(PP) + (NPNP)}{(PP) + (NPP) + (PNP) + (NPNP)}$

Fonte: Autores (2026).

O erro de omissão é o erro em que o objeto não é classificado na classe à qual ele pertence e o erro de inclusão é o erro onde o objeto é incluído em uma classe a que ele não pertence.

Para mensurar o desempenho da classificação em cada sistema de plantio e tipo de câmera foi determinada a exatidão global e o índice Kappa, descrito por Hudson e Ramm (1987). O índice Kappa, diferentemente da exatidão global, utiliza todos os dados da matriz de erro na sua fórmula, conforme a equação 13.

$$\hat{K} = \frac{n \sum_{i=1}^c x_{ii} - \sum_{i=1}^c x_{i\oplus} x_{\oplus i}}{n^2 - \sum_{i=1}^c x_{i\oplus} x_{\oplus i}} \quad (13)$$

em que $\hat{K}$ é a estimativa do coeficiente Kappa; x_{ii} , valor na linha i e coluna i (diagonal) da matriz de erros; $x_{i\oplus}$, total da linha i; $x_{\oplus i}$, total da coluna i; n, número total de amostras; e c, número total de classes.



Kappa igual a zero significa que o acerto obtido pelo classificador é igual ao acerto por acaso. Valores positivos de Kappa ocorrem quando o acerto for maior que o acaso, enquanto os negativos ocorrem quando o acerto é pior do que uma classificação por acaso.


3 RESULTADOS E DISCUSSÃO

3.1 AQUISIÇÃO DOS DADOS

Na Figura 6, é apresentada a tela do painel de controle referente ao algoritmo da parte de aquisição dos dados. Esta tela é composta de 33 dispositivos entre botões de acionamento e controle, campos e led's indicadores, gráficos e telas de visualização das imagens, sendo que todos estes foram numerados e suas respectivas funcionalidades estão descritas na Tabela 2.

Antes de iniciar a aquisição dos dados, é necessário selecionar adequadamente as portas seriais que o GPS e as câmeras estão conectados e definir o sistema de separação de casas decimais, que vai depender do sistema numérico do computador utilizado. Os diretórios e nomes dos arquivos também precisam ser escolhidos para que os dados possam ser armazenados corretamente. Por fim, é necessário definir de quantos em quantos metros serão capturados os dados e os valores iniciais do obturador eletrônico das câmeras, para qualquer que seja a opção do modo de ajuste deste parâmetro: manual ou automática. Após estes ajustes, basta pressionar os botões que ligam as câmeras, representados pelos números 13 e 18, e ativar o botão Capturar Dados (número 22) ou pressionar a tecla F5, e esperar que o led de validação dos dados do GPS (número 3), confirme o recebimento completo dos dados deste dispositivo. O acionamento do GPS se inicia ao selecionar na tela do painel de controle, a porta serial a qual este dispositivo está conectado.

Figura 6. Tela do painel de controle referente à aquisição dos dados.



Fonte: Autores (2026).



Tabela 2. Função de cada dispositivo presente na tela do painel de controle da aquisição de dados.

Dispositivos	Descrição da função de cada dispositivo
1	Seleciona a porta serial que o GPS foi conectado
2	Campo de visualização dos dados lidos pelo GPS – sentença RMC
3	Led indicador se os dados recebidos do GPS são válidos
4	Velocidade de deslocamento do GPS em metros/segundo
5	Seleciona o diretório e o nome desejado do arquivo para salvar as coordenadas UTM
6	Campo contendo a hora e a data de cada coordenada recebida
7	Coordenada UTM – X em metros
8	Coordenada UTM – Y em metros
9	Seleciona o sistema de separação de decimais – Brasileiro/Espanhol (,) ou Americano (.)
10	Mensagem de erro da configuração da porta serial do GPS
11	Mensagem de erro da leitura dos dados do GPS
12	Seleciona a porta serial que a câmera 1 foi conectada
13	Botão que liga ou desliga a câmera 1
14	Seleciona diretório e o nome desejado para salvar as imagens da câmera 1
15	Mensagem de erro da comunicação e aquisição das imagens com a câmera 1
16	Mensagem de erro do encerramento de captura da câmera 1
17	Seleciona a porta serial que a câmera 2 foi conectada
18	Botão que liga ou desliga a câmera 2
19	Seleciona diretório e o nome desejado para salvar as imagens da câmera 2
20	Mensagem de erro na comunicação e aquisição das imagens com a câmera 2
21	Mensagem de erro do encerramento de captura da câmera 2
22	Botão ou tecla F5 que liga ou desliga a captura automática dos dados
23	Campo que informa o número da imagem que esta sendo capturada
24	Distância entre os pontos capturados em metros
25	Obturador eletrônico (SHUTTER) referente à câmera 1
26	Obturador eletrônico (SHUTTER) referente à câmera 2
27	Botão que liga ou desliga a função automática do SHUTTER
28	Led que indica se houve ou não captura de dados
29	Gráfico de visualização dos pontos capturados na área
30	Visualização da imagem adquirida pela câmera 1
31	Visualização da imagem adquirida pela câmera 2
32	Botão que zera o número das imagens
33	Para a aquisição dos dados

Fonte: Autores (2026).


3.2 PROCESSAMENTO DAS IMAGENS

3.2.1 Transformação das imagens RGB em ExG, limiarização e aplicação das operações morfológicas OPEN e CLOSE

A Figura 7 apresenta os resultados desta etapa do processamento das imagens, na tela do painel de controle, que teve início com a transformação das imagens RGB em imagens índice de excesso de verde (ExG). Em seguida, efetuou-se o cálculo do limiar iterativo automático baseado no histograma da imagem ExG e a limiarização. Após este processo de limiarização ocorreu a aplicação das operações morfológicas de abertura e fechamento (*OPEN* e *CLOSE*) para a remoção de ruídos.



Figura 7. Tela do painel de controle da parte inicial do processamento de imagens referente ao processo de limiarização das imagens.




Fonte: Autores (2026).

Se forem capturadas imagens monocromáticas, como no caso das câmeras infravermelhas, os passos para limiarização são os mesmos, só não havendo a necessidade de transformar em imagem índice ExG.

A Figura 8 apresenta um destaque do efeito das operações morfológicas nas imagens limiarizadas, onde os ruídos gerados pelo processo de limiarização foram retirados.

Figura 8. Destaque do efeito das operações morfológicas na remoção dos ruídos gerados pela limiarização.



Fonte: Autores (2026).




Consideraram-se ruídos pixels isolados classificados opostamente à feição pertencente a sua localização, ou seja, um pixel isolado classificado como planta presente nas entrelinhas ou um pixel isolado classificado como fundo presente na cultura.

3.2.2 Identificação do ângulo de inclinação das linhas de cultura nas imagens e rotação das imagens

Os resultados desta etapa de processamento das imagens estão apresentados na tela do painel de controle da Figura 9. Esta tela contém inicialmente a imagem limiarizada filtrada e a imagem resultante após a aplicação da máscara circular. Em seguida, após o cálculo da transformada de Hough, apresentou-se nesta mesma tela o gráfico Rho (ρ) x Teta (θ), e os valores de Teta e Rho, os quais indicam o ponto no gráfico com o maior número de interseções, e o valor ângulo de rotação das imagens, para posicionar as linhas de cultura na vertical. Por fim, também foi apresentada a imagem rotacionada baseada no ângulo Teta, obtido pela transformada de Hough; e a imagem recortada, para que as linhas de cultura ficassem com o mesmo tamanho em toda a imagem. Nesta imagem recortada é que será efetuado o cálculo da porcentagem da cobertura de plantas daninhas nas entrelinhas na etapa seguinte. Nesta tela são disponibilizados os cálculos de porcentagem de toda a vegetação presente na imagem inicial desta etapa de processamento (imagem limiarizada e filtrada) e na imagem final (imagem recortada) para a observação das alterações, no percentual de pixels referente às plantas daninhas e cultura, decorrentes nesta etapa de processamento.

Figura 9. Tela do painel de controle referente à identificação do ângulo de inclinação das linhas de cultura pela Transformada de Hough e rotação das imagens.



Fonte: Autores (2026).



O gráfico Rho (ρ) x Teta (θ) foi apresentado para auxiliar na identificação do valor do ângulo de inclinação das linhas de cultura, denominado de “Teta máximo”, que é o ângulo referente ao ponto com o maior número de interseções das curvas. Este ângulo se localiza na região do gráfico com maior intensidade da cor branca. As Figuras 10a, 10b e 10c apresentam três imagens com diferentes ângulos de inclinação das linhas de cultura e o respectivo gráfico de Rho x Teta com a região das maiores interseções das curvas em destaque e o valor do ângulo referente ao ponto com maior número de interseções.


3.2.3 Segmentação das linhas de cultura e cálculo da porcentagem da cobertura de plantas daninhas

Os resultados desta última etapa de processamento das imagens podem ser visualizados pela tela do painel de controle da Figura 11. Primeiramente as imagens limiarizadas e recortadas pela etapa anterior foram apresentadas juntamente com seu respectivo sinal da quantidade de pixels com valor 1 (referente a plantas) por cada coluna da imagem. A partir desse sinal foi possível visualizar a representação de cada linha de cultura e dos espaços entrelinhas de toda a imagem, bem como a representação dos efeitos ocasionados pelas irregularidades, como as falhas nas linhas de cultura, a alta presença de plantas daninhas nas entrelinhas e os diferentes tamanhos e larguras das linhas de cultura. Os limites entre as linhas de cultura e os espaços das entrelinhas, representados no sinal pelas linhas verticais vermelhas, foram obtidos pelas interseções da linha da média total do sinal (linha horizontal amarela) com o próprio sinal. Toda parte do sinal acima desta linha horizontal representava as linhas cultura, e abaixo representavam os espaços das entrelinhas.

Também foram apresentadas as imagens resultantes deste processo de segmentação, que foram as imagens contendo somente as linhas de cultura e contendo somente os espaços das entrelinhas e os valores de porcentagem da cobertura de plantas daninhas, da cobertura referente à cultura e da cobertura da vegetação total.




Figura 10. Imagens limiarizadas e filtradas com os respectivos gráficos de Rho x Teta, com a região das maiores interseções das curvas em destaque e o valor do ângulo no ponto de maior interseção das curvas, sendo este Teta igual a 45° (a), 32° (b) e 135° (c).



Fonte: Autores (2026).



Figura 11. Tela do painel de controle da segmentação das linhas de cultura e determinação do percentual da cobertura de plantas daninhas.




Fonte: Autores (2026).

As Figuras 12 a 15 apresentam alguns exemplos dos problemas mais comuns ocorridos nesta etapa do processamento, sendo compostas pelas partes (a) e (b). Na parte (a) estão contidas imagens limiarizadas, filtradas e recortadas pelas etapas anteriores junto com seu respectivo sinal da quantidade de *pixels* referente a plantas por coluna. Na parte (b) estão apresentadas as duas imagens resultantes do processo de segmentação das linhas de cultura.

Com as linhas de cultura posicionadas verticalmente nas imagens, estas linhas foram representadas por uma faixa de colunas, e essa faixa foi determinada conforme a estratégia de segmentação adota, pelos pontos de interseção do respectivo sinal com a linha media total do sinal. Logo, as linhas de cultura separadas nas imagens possuíam um formato retangular. Entretanto, as linhas de cultura não possuem um formato regular e conseqüentemente, quando estas foram segmentadas com retângulos, algumas partes das suas bordas ficaram contidas no espaço das entrelinhas, sendo classificadas como plantas daninhas, conforme o exemplo da Figura 12b, afetando nos cálculos da porcentagem da cobertura das plantas daninhas. Para uma melhor visualização deste tipo de problema, destacou-se a região em torno de uma linha de cultura por meio de um retângulo amarelo (Figura 12a); e o semicírculo referente a esta linha no gráfico, pela seta amarela também presente na Figura 12a. Esta mesma região foi destacada por um retângulo amarelo nas imagens contendo somente as linhas de cultura e somente as entrelinhas (Figura 12b).



Figura 12. Exemplo do problema de segmentação retangular das linhas de cultura, (a) contém a imagem limiarizada filtrada e o seu respectivo sinal da quantidade de *pixels* referentes às plantas por coluna e (b) contém as imagens somente com as linhas de cultura e somente com as entrelinhas.




Fonte: Autores (2026).

A Figura 13 apresenta um exemplo para o problema gerado na segmentação das linhas de cultura, ocasionado pela ausência de plantas. Esta figura possui na parte (a), a imagem limiarizada filtrada onde foi destacada, por um retângulo amarelo, a região em torno de uma linha de cultura contendo falhas pela ausência de plantas.



Figura 13. Exemplo do problema gerado pela ausência de plantas nas linhas de cultura, (a) contém a imagem limiarizada filtrada e o seu respectivo sinal da quantidade de *pixels* referentes às plantas por coluna e (b) contém as imagens somente com as linhas de cultura e somente com as entrelinhas.



Fonte: Autores (2026).

Pelo gráfico da Figura 13a é possível visualizar o efeito da falta de plantas nas linhas de cultura no sinal gerado, especificamente, no semiciclo apontado pela seta amarela, que representa a linha de cultura destacada na imagem limiarizada. A falta de plantas gerou uma diminuição no semiciclo destacado. Como as limitações das linhas de cultura, indicadas no sinal pelas linhas verticais vermelhas, são obtidas pela interseção do sinal com a linha da média total do sinal (linha horizontal amarela), a segmentação atribuiu uma menor área a esta linha de cultura, ocasionando uma maior presença de plantas da cultura (bordas) no espaço das entrelinhas. Esta diminuição de área da linha de cultura, bem como o aumento das bordas da cultura nas entrelinhas pode ser visualizada com destaque pela Figura 13b, nas regiões delimitadas pelo retângulo amarelo.

A Figura 14 apresenta um exemplo do que pode acontecer quando é alta a incidência de plantas daninhas no espaço das entrelinhas, chegando até a juntar as linhas de cultura, o que dificulta o discernimento entre cultura e planta daninha, prejudicando a segmentação das linhas de cultura e ocasionando mais erros ao cálculo da porcentagem da cobertura de plantas daninhas.


Um espaço entrelinhas, contendo alta infestação de plantas daninhas, foi destacado na Figura 14a, por um retângulo vermelho. As plantas daninhas, em algumas partes deste trecho, uniram-se às duas linhas



de cultura. Este fato teve um efeito de minimizar o semiciclo abaixo da linha média (vale) no sinal, indicado pela seta amarela (Figura 14a). Esta minimização do vale pode fazer com que esta região do sinal ultrapasse a linha média total do sinal e como consequência disso a faixa da entrelinha será considerada como linha de cultura.

Neste exemplo, também se pode visualizar, pela Figura 14b, que quanto mais plantas daninhas existirem nas entrelinhas, mais difícil será de encontrar a divisão entre linhas de cultura e entrelinhas.

Figura 14. Exemplo do problema gerado pela alta infestação de plantas daninhas nas entrelinhas, (a) contém a imagem limiarizada filtrada e o seu respectivo sinal da quantidade de *pixels* referentes às plantas por coluna e (b) contém as imagens somente com as linhas de cultura e somente com as entrelinhas.




Fonte: Autores (2026).

A Figura 15 apresenta um enfoque das irregularidades das linhas de cultura, onde em uma mesma imagem é possível encontrar, linhas com larguras diferentes. Sendo assim, na Figura 15a, destacaram-se duas linhas de cultura, envoltas por dois retângulos amarelos. Estas duas linhas possuem larguras bem distintas mesmo estando próximas na área cultivada, e esta diferença pode ser percebida pelo respectivo sinal também presente nesta mesma figura.



Figura 15. Exemplo do efeito de diferentes larguras entre as linhas de cultura em uma mesma imagem, (a) contém a imagem limiarizada filtrada e o seu respectivo sinal da quantidade de *pixels* referentes às plantas por coluna e (b) contém as imagens somente com as linhas de cultura e somente com as entrelinhas.



Fonte: Autores (2026).

As duas linhas de cultura destacadas na imagem 15a tiveram seus semiciclos indicados no sinal pelas setas amarelas, evidenciando este fato pela forma do sinal, pois a diminuição da largura das linhas gera a diminuição da largura do sinal. Entretanto, como o tamanho das linhas de cultura a serem segmentadas depende da média total do sinal, essa diferença entre larguras das linhas de cultura dentro de uma mesma imagem afetará no processo de segmentação, ocasionando um aumento das bordas das linhas de cultura nos espaços das entrelinhas, conforme ilustra a Figura 15b nas regiões destacadas pelos retângulos amarelos. A linha de cultura mais fina, no processo de segmentação, foi representada por uma faixa de colunas menor ainda, o que proporcionou maior quantidade de bordas nos espaços das entrelinhas ao redor desta linha de cultura.

3.3 RESULTADOS DA AVALIAÇÃO DO PROCESSAMENTO DAS IMAGENS

As matrizes de confusão obtidas em cada sistema de plantio e tipo de câmera estão apresentadas nas Tabelas de 3 a 6.



Tabela 3. Matriz de confusão referente à câmera RGB no plantio convencional

Valor estimado	Valor de referência		Erros de inclusão (%)
	Planta	Não Planta	
Planta	491	5	1
Não-planta	169	335	34
Erros de omissão (%)	26	1	Exatidão global (%) 83

Fonte: Autores (2026).

Tabela 4. Matriz de confusão referente à câmera NIR no plantio convencional

Valor estimado	Valor de referência		Erros de inclusão (%)
	Planta	Não Planta	
Planta	286	18	6
Não-planta	374	322	54
Erros de omissão (%)	57	5	Exatidão global (%) 61

Fonte: Autores (2026).

Tabela 5. Matriz de confusão referente à câmera RGB no plantio direto

Valor estimado	Valor de referência		Erros de inclusão (%)
	Planta	Não Planta	
Planta	518	0	0
Não-planta	142	340	29
Erros de omissão (%)	22	0	Exatidão global (%) 86

Fonte: Autores (2026).

Tabela 6. Matriz de confusão referente à câmera NIR no plantio direto

Valor estimado	Valor de referência		Erros de inclusão (%)
	Planta	Não Planta	
Planta	374	30	7
Não-planta	286	310	48
Erros de omissão (%)	43	9	Exatidão global (%) 68

Fonte: Autores (2026).

É possível observar em relação aos tipos de câmeras, que os maiores valores de exatidão global foram atribuídos às imagens processadas da câmera RGB independente do sistema de plantio. Em relação ao tipo de sistema de plantio os maiores valores de exatidão global foram atribuídos ao sistema de plantio direto em ambas as câmeras utilizadas. Isto indica que a câmera RGB obteve maior potencial em diferenciar plantas de não-planta do que a câmera NIR e que o sistema de plantio direto favoreceu esta diferenciação nas duas câmeras.


Os valores do índice Kappa foram respectivamente, 0,65 e 0,30, para as câmeras RGB e NIR no sistema de plantio convencional e 0,71 e 0,40, para as câmeras RGB e NIR no sistema de plantio direto. Estes valores indicam que todas as classificações entre planta e não-planta pelo processamento das imagens foram melhores que uma classificação ao acaso e ainda reforçam o potencial da câmera RGB em detectar planta e não-planta e o favorecimento nesta detecção com o uso do sistema de plantio direto. Segundo os critérios utilizados por Landis e Koch (1977), na avaliação dos valores obtidos de Kappa, a classificação atribuída à câmera RGB, em ambos os sistemas de plantio, apresentou uma performance muito boa. Já a classificação atribuída à câmera NIR nos dois sistemas de plantio, apresentou um desempenho razoável.



Durante o processamento das imagens observou-se que as imagens geradas pela câmera NIR foram menos capazes em diferenciar planta das demais feições presentes na imagem, independente do sistema de plantio, ocasionando um maior erro no processo de limiarização. A Figura 16 apresenta um exemplo que justifica esse fato. Nela foi realizada uma comparação entre uma imagem RGB sob o sistema de plantio direto (Figura 16a), a sua respectiva imagem limiarizada filtrada (Figura 16b) e a imagem limiarizada filtrada da mesma área, entretanto, capturada simultaneamente pela câmera NIR (Figura 16c). A imagem RGB foi utilizada como referência nessa comparação, pois possui melhor retratação da cena em questão do que a imagem NIR.

As regiões em destaque, pelos círculos vermelhos, representam a mesma região em todas as imagens. Esta região do círculo contém uma pequena reboleira de plantas daninhas entre duas linhas cultura. Esta reboleira na imagem da Figura 16c obteve maior tamanho do que na imagem RGB, além de ter unido as duas linhas de cultura. Já na Figura 16b esta mesma reboleira teve um tamanho mais próximo da realidade, como apresentado pela imagem RGB. Além disso, pode-se observar outro fato na área contida no círculo vermelho da imagem limiarizada da Figura 16c, onde uma parte da palhada foi classificada como planta daninha, comprovando assim uma superestimação na classificação dos *pixels* em plantas pelas imagens NIR, o que justifica o valor de erro médio mais alto.

Figura 16. Exemplo do efeito do processamento nas imagens RGB e NIR.



Fonte: Autores (2026).



Por fim, pode-se deduzir que a câmera RGB seria a mais indicada para a confecção dos mapas de percentual da cobertura de plantas daninhas e que o sistema de plantio direto seria o sistema mais favorável a identificação das linhas de cultura e da cobertura das plantas daninhas.

4 CONCLUSÃO

Os algoritmos desenvolvidos promoveram a captura de imagens e coordenadas simultaneamente e automaticamente e a determinação da porcentagem da cobertura de plantas daninhas nas entrelinhas.

O tipo da câmera utilizada influenciou diretamente no desempenho dos algoritmos do processamento das imagens para obtenção da porcentagem da cobertura de plantas daninhas nas entrelinhas.

REFERÊNCIAS

- BAIO, F.H.R. **Aplicação localizada de defensivos baseada na variabilidade espacial das plantas daninhas**. 2001. 113 f. Dissertação (Mestrado em Agronomia) – Escola Superior de Agricultura Luiz de Queiroz, Piracicaba, SP.
- CONGALTON, R.G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, n. 37, p. 35-46, 1991.
- DUDA, R.O.; HART, P.E. Use of the Hough transformation to detect lines and curves in pictures. **Communicationsofthe ACM**, v. 15, n. 1, p. 11-15, 1972.
- ESPINOSA, A.T.; PONCE, A.J.R.; REYES, M.M. Desarrollo de *software* para el manejo de información catastral. **ReportesTécnicosenIngeniería del Software**, v. 9, n. 1, p. 1-13, 2007.
- FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS – FAO. Disponível em: <<http://www.fao.org/news/story/en/item/29402/icode/>>. Acessoem: 11 jan. 2010.
- GÉE, C.; BOSSU, J.; JONES, G.; TRUCHETET, F. Crop/weed discrimination in perspective agronomic images. **ComputersandElectronics in Agriculture**, v. 60, p. 49-59, 2008.
- GOMES, O.F.M. **Processamento e análise de imagens aplicados à caracterização automática de materiais**. 2001. 151 f. Dissertação (Mestrado em Ciências da Engenharia Metalúrgica) – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, RJ.
- HUDSON, W.D.; RAMM, C.W. Correct formulation of the kappa coefficient of agreement. **Photogrammetric Engineering & Remote Sensing**, v. 53, n. 4, p. 421-422, 1987.
- LANDIS, J.R.; KOCH, G.G. The measurement of observer agreement for categorical data. **Biometrics**, v. 33, n. 1, p. 159-174, 1977.
- MOLIN, J.P. Agricultura de precisão: fundamentos e estado atual da arte. In: CÂMARA, G.M. **Soja: tecnologia da produção II**. Piracicaba: ESALQ/Departamento de Produção Vegetal, 2000. p. 423-437.



RONCHI, C.P.; TERRA, A.A.; SILVA, A.A.; FERREIRA, L.R. Acúmulo de nutrientes pelo cafeeiro sob interferência de plantas daninhas. **Planta Daninha**, v. 21, n. 2, p. 219-227, 2003.

SHIRATSUCHI, L.S. **Mapeamento da variabilidade espacial das plantas daninhas com a utilização de ferramentas da agricultura de precisão**. 2001. 96 f. Dissertação (Mestrado em Agronomia) – Escola Superior de Agricultura Luiz de Queiroz, Piracicaba, SP.

TELLAECHE, A.; BURGOSARTIZZU, X.P.; PAJARES, G.; RIBEIRO, A.; FERNÁNDEZ-QUINTANILLA, C. A new vision-based approach to differential spraying in precision agriculture. **Computers and Electronics in Agriculture**, v. 60, p. 144-155, 2008.

WOEBBECKE, D.M.; MEYER, G.E.; VON BARGEN, K.; MORTENSEN, D.A. Color indices for weed identification under various soil, residue, and lighting conditions. **Transactions of the ASAE**, v. 38, n. 1, p. 259-269, 1995.

YANG, X.; BEYENAL, H.; GARY, H.; LEWANDOWSKI, Z. Evaluation of biofilm image thresholding methods. **WaterResearch**, v. 35, p. 1149-1158, 2001.