

Fault Detection in Sugarcane Crop Lines Using Hough Transform

Alexsandro M. Carneiro¹, Gabriel T. H. Higa¹, Alexandre G. de O. Rodrigues¹, José M. Junior²,
and Hemerson Pistori^{1,2}

¹Universidade Católica Dom Bosco

Tamandaré Avenue, 79117-9000, Campo Grande-MS, Brazil

¹rf5974@ucdb.br

²Universidade Federal do Mato Grosso do Sul

Costa e Silva Street, 79070-000, Campo Grande-MS, Brazil

Abstract—In this work, we present an algorithm for detecting faults in sugarcane planting rows using the Hough transform, supported by image pre-processing techniques, such as binarization, morphological operators, filters, and skeletonization. Seven preprocessing calibration parameters are investigated. For the calibration and testing of the proposed method, a set of images with 589 samples, captured by UAV in an area located in Nova Andradina, MS, is presented.

I. INTRODUÇÃO

A agricultura é uma atividade estratégica desenvolvida em vários países, e está relacionada a interesses econômicos locais e globais [1], tais como a produção de alimentos e o desenvolvimento sustentável. Atualmente, a agricultura tradicional tem aberto espaço para a modernização, tornando-se a agricultura de precisão (AP), agricultura digital (AD) ou agricultura 4.0 [2]. A transição é marcada pela adoção de novas tecnologias por parte dos atores envolvidos, com o objetivo não só de aumentar a produção e reduzir custos, mas de fazê-lo de forma sustentável.

Dentre as novas tecnologias adotadas, estão as técnicas de sensoriamento remoto. Entre outros benefícios, o sensoriamento remoto permite a coleta, visualização, processamento e avaliação de dados de uma cultura em diferentes estágios, facilitando a identificação de ocorrências e gerando informações em tempo hábil para solução de problemas [3]. Alia-se ao sensoriamento remoto a visão computacional. Por meio do processamento de imagens, as técnicas da visão computacional contribuem com tarefas diversas, tais como a detecção de doenças, mapeamento, fenotipagem, contagem, detecção de falhas, previsão de rendimento e classificação [4]–[7]. Uma importante técnica da visão computacional é a transformada de Hough em seu formato parametrizado por ρ e θ [8].

No agronegócio, a transformada tem sido utilizada em conjunto com outros algoritmos, por sua capacidade de identificar linhas. Assim, por exemplo, de Oliveira *et al.* [9] investigaram estratégias para melhorar o desempenho da transformada, quando utilizada para identificar a orientação das retas em uma plantação de feijão. Bayar [10] apresenta um sistema em que a transformada é utilizada em conjunto com outras técnicas para automatizar o controle de um veículo em uma horta.

Nesse caso, a transformada foi utilizada para encontrar linhas de plantio a partir de detecções de árvores. Zheng *et al.* [11] utilizaram a transformada como parte de um sistema para dispersão automática de pesticidas em plantações de milho. Koc-San *et al.* [12] utilizaram a transformada de Hough como parte de uma estratégia para extrair árvores em imagens aéreas, obtidas por meio de VANTs, de plantações de árvores cítricas. Por fim, Jiang *et al.* [13] aplicaram a transformada para extrair linhas com o objetivo de detectar fileiras de plantação de trigo.

A cana-de-açúcar é uma das principais culturas produzidas em solo brasileiro. Segundo dados da Companhia Nacional de Abastecimento (CONAB) [14], ao final de 2022, foram computados 8.307,5 hectares de área plantada, com uma produtividade de 69.355 kg/ha e 598.345,4 toneladas produzidas. Um dos desafios para o aumento de produtividade da cana-de-açúcar é a quantificação de falhas em linhas de plantio. O método utilizado atualmente foi elaborado e aprimorado por Stolf [15] entre as décadas de 80 e 90, sendo um método manual e fisicamente exigente, por requerer que as linhas de plantio sejam percorridas para contabilização das falhas. Em geral, são consideradas falhas os segmentos sem plantação com comprimento igual ou superior a 0,5 m. O método de Stolf [15] quantifica o percentual de falhas a cada 100 m, o número de falhas, o seu tamanho, frequência e percentual de perdas.

Atualmente, já há alguns trabalhos que abordam o problema. Rocha *et al.* [16], [17], por exemplo, discutem algumas dificuldades para a detecção de falhas em linhas, como linhas curvas e linhas rotacionadas, propondo métodos que combinam técnicas de processamento de imagens com detecção de curvas usando algoritmos como o *k-nearest neighbors*. Os autores relatam ter alcançado um erro de 1,65% [16].

Tendo-se em vista que a quantificação de falhas em linhas de plantio é uma tarefa árdua, neste artigo, avalia-se a possibilidade de usar a transformada de Hough como pivô em um sistema de visão computacional com o objetivo de quantificar as mencionadas falhas. Para isso, apresenta-se o *software CropRows*, em que um canal de processamento de imagens é implementado com essa finalidade. A técnica proposta é avaliada em um conjunto de dados formado por 589 imagens

RGB capturadas em uma usina de cana-de-açúcar localizada no município de Nova Andradina, Mato Grosso do Sul.

II. MATERIAIS E MÉTODOS

A. Banco de Imagens

As imagens utilizadas foram feitas no ano de 2020 no local já mencionado. No período da coleta, a cultura estava nos primeiros estágios, com 2 meses de plantio. As imagens foram capturadas usando um VANT modelo X8 Skywalker, equipado com uma câmera modelo Canon S110. A Figura 1 mostra a imagem aérea da localidade. A partir dessa imagem foi feito o cálculo do fator de conversão de pixels para metros, obtendo-se o valor de 0,051849. A partir da imagem aérea, foram geradas as 589 imagens de 256 x 256 que compõem o banco de imagens utilizado. A Figura 2 mostra a distribuição dos comprimentos totais de falhas no conjunto de dados produzido.



Fig. 1. Visão Aérea da Área Plantada

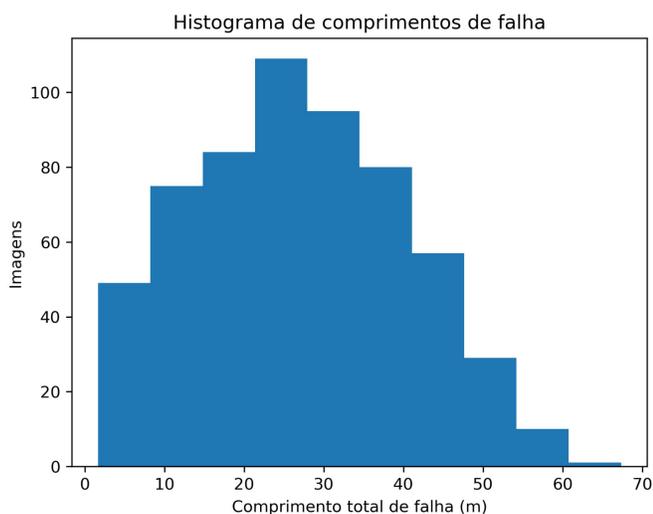


Fig. 2. Distribuição das falhas no conjunto de dados

B. Método Utilizado

As imagens obtidas foram processadas em três momentos distintos (pré-processamento, detecção de linhas de plantio, e detecção e cálculo de falhas), cujos resultados podem ser vistos na Figura 3.

Primeiramente, foi feita a suavização da imagem por meio do filtro bilateral, o que permitiu considerar a diferença de intensidade entre os pixels, mantendo as suas bordas. Assim, pôde-se enfatizar a linha de plantio. Após a etapa de suavização, a imagem foi binarizada por meio de limiares definidos para cada canal. Pixels cujos valores pertenciam ao intervalo foram considerados brancos, enquanto os outros foram zerados. Para os canais R, G e B foram definidos os seguintes intervalos, respectivamente: 0-157, 0-167 e 0-120. Nos testes preliminares usando HSV não alcançou melhoria, por este motivo foi mantido o modelo RGB. Após a binarização, foi aplicado o operador morfológico de erosão, para remover linhas verticais presentes em algumas imagens e para destacar as linhas de plantio. Por fim, o pré-processamento das imagens foi encerrado com a esqueletização, com a qual as linhas foram reduzidas à largura de 1 px.

Após o pré-processamento, a transformada de Hough foi aplicada na imagem esqueletizada com o objetivo de detectar linhas de plantio e calcular a sua direção principal. Para a aplicação da transformada, foi adotado um limiar inicial (H_1 , vide Tabela I), o qual foi dividido pela metade sempre que a transformada falhava em encontrar uma linha, até um máximo de quatro tentativas. Após a primeira busca, o ângulo mais frequente foi separado e uma segunda transformada de Hough, limitada a um intervalo centralizado no ângulo mais frequente, foi aplicada para procurar por linhas que receberam menos votos.

A partir das retas encontradas pela transformada de Hough, as linhas de plantio foram definidas por meio da distância entre linhas. Para calcular a distância, duas estratégias foram consideradas. A primeira consiste em usar uma distância previamente calculada. A segunda consiste em medir as distâncias entre todas as linhas detectadas tomadas em pares, e utilizar a distância mais comum como a distância entre duas linhas de plantio. Para esta segunda estratégia, foi definido um limiar mínimo de distância entre duas linhas.

Com as linhas de plantio encontradas, passou-se à fase de detecção de falhas. Para isso, a imagem original foi novamente binarizada, desta vez com os seguintes limiares para R, G e B. São eles, respectivamente: 0-147, 0-145 e 0-126. Esses valores foram escolhidos por serem menos restritivos na segmentação de pixels verdes, que representam segmentos não falhos nas linhas de plantio. A seguir, foram aplicados dois operadores morfológicos sobre a imagem binarizada, para engrossar as linhas de plantio binarizadas: fechamento e dilatação.

Para detecção de falhas, foi utilizado um operador AND bit a bit. A imagem binarizada utilizada foi invertida, de forma que o valor zero foi atribuído aos pixels da linha de plantio sem falhas, e o valor 255 foi atribuído ao solo. A seguir, o

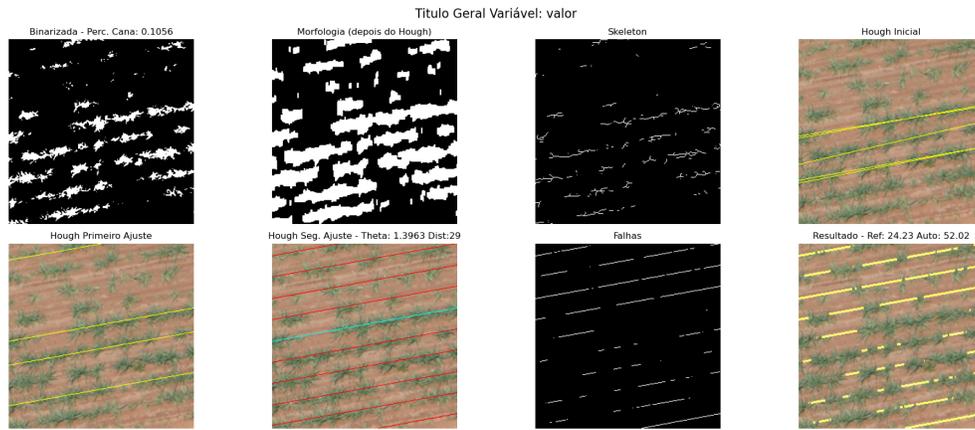


Fig. 3. Exemplo de Detecção de Falhas CropRows.

operador foi aplicado entre duas imagens: aquela contendo os pixels correspondentes às linhas (255) e ao solo (0), e a imagem binarizada. Ao aplicar o operador mencionado, foram zerados todos os pixels cujo valor não era máximo (255) para ambos, linha de plantio e solo. Um pixel representante de solo sobre uma linha de plantio é, na estratégia descrita, uma falha de plantio. O comprimento efetivo da falha de plantio foi calculado a partir do fator de conversão. Na sequência, foi calculado o percentual de falhas.

C. Desenho Experimental

Dadas as técnicas utilizadas, descritas na subseção anterior, valores diferentes para sete parâmetros, apresentados na Tabela I, foram avaliados. Para a execução do experimento, o banco de imagens foi separado em conjuntos de treinamento (10%), isto é, escolha de parâmetros funcionais, e teste (90%). Como métrica de desempenho, foi utilizado o erro absoluto entre as medidas de falha e não falha entre as medidas manuais e as medidas automáticas dadas pelo sistema proposto. Esta etapa permitiu a identificação e análise de cada parâmetro do sistema, bem como o seu impacto para o problema (identificação das linhas e posteriormente falhas). Após a escolha dos valores para os parâmetros, procedeu-se ao teste do método utilizado. Para análise dos resultados, foram gerados, entre outros, boxplots, histogramas e gráficos de dispersão discutidos com maiores detalhes nas próximas seções.

III. RESULTADOS E DISCUSSÕES

As Figuras 4, 5 e 6 mostram boxplots do erro absoluto obtido sobre o conjunto de treinamento, para cada valor avaliado de SS e SC, Rho e EV. A Tabela II mostra os valores escolhidos para cada parâmetro. Ao analisar os resultados, identificou-se que o parâmetro SS com valor 4 apresenta a mediana com valores mais bem distribuídos, considerados os valores de SC que flutuam entre 0, 5, 10 e 20, além de um baixo erro absoluto. Além disso, é com SS igual a 4 que SC tem o menor erro absoluto e a menor amplitude interquartil. O mesmo raciocínio foi aplicado para EV e RHO. Para RHO,

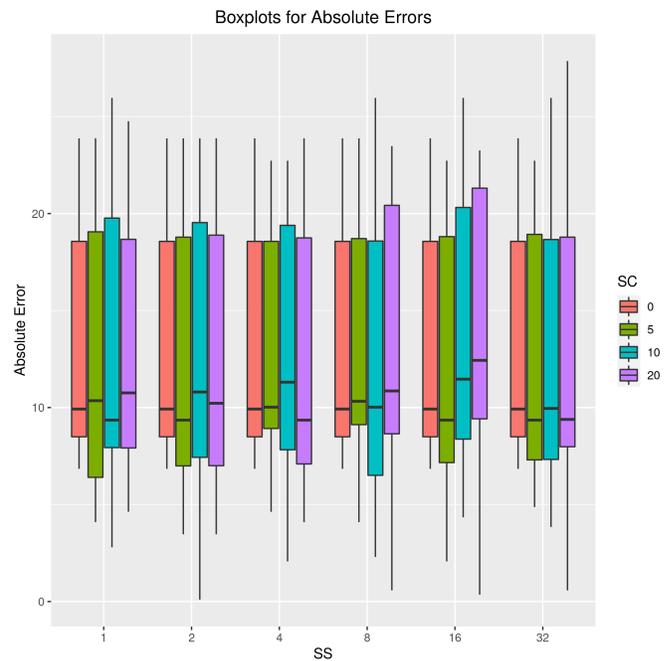


Fig. 4. Conjunto de valores para ajustar SS e SC

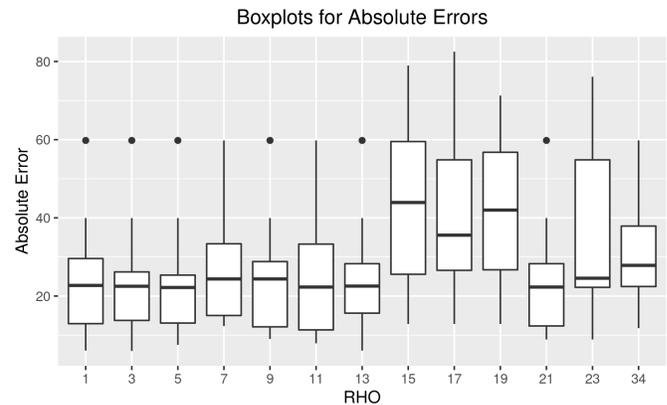


Fig. 5. Conjunto de valores para ajustar RHO

TABLE I

CONJUNTO DE VALORES USADOS DE FORMA ALEATÓRIA PARA CADA PARÂMETRO VARIADO, SENDO ELES: **SS** - *sigma space* (SUAVIZAÇÃO BILATERAL); **SC** - *sigma color* (SUAVIZAÇÃO BILATERAL); **HM** - VALOR MÍNIMO PARA MATIZ NA SEGMENTAÇÃO NO ESPAÇO HSV; **BM** - VALOR MÁXIMO PARA BRILHO NA SEGMENTAÇÃO NO ESPAÇO HSV; **EV** - EROSIÃO VERTICAL; **RHO** - DISTÂNCIA MÍNIMA ENTRE AS LINHAS NO ESPAÇO DE HOUGH; E **H1** - LIMIAR DE UTILIZADO NA PRIMEIRA APLICAÇÃO DA TRANSFORMADA DE HOUGH.

Parâmetros	Valores Testados
SS	1 2 4 8 16 32
SC	0 5 10 20
HM	10 20 40 80 160 255
BM	130 150 170 190 210
EV	1 3 5 7 9
RHO	1 3 5 7 9 11 13 15 17 19 21 23 34
H1	20 30 40 50 70

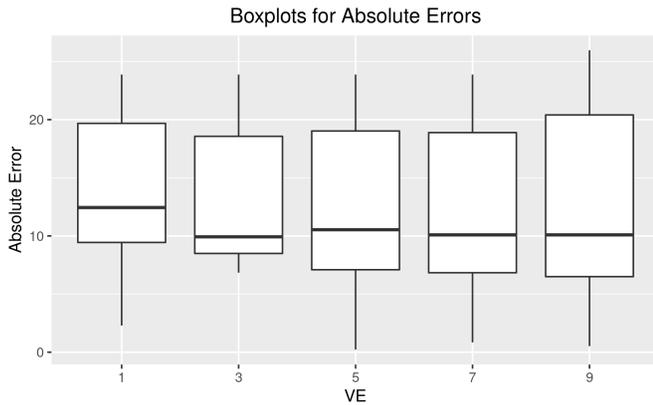


Fig. 6. Conjunto de valores para ajustar EV

o valor 34 obteve um Erro Absoluto igual a 25, porém com amplitude interquartil que absorve uma maior ocorrência nas linhas de plantio e sem apresentar resultados irregulares. Para EV, por uma análise semelhante, optou-se pelo valor 5.

A Figura 7 mostra os boxplots do erro obtido nos conjuntos de treinamento e teste com os parâmetros escolhidos. Em teste, obteve-se um erro absoluto médio (diferença entre a medida manual e a automática em metros) de 19,78 ($\pm 14,18$). A mediana do erro absoluto foi 17,86 (IQR = 22,94).

TABLE II
VALORES SELECIONADOS USANDO OS BOXPLOTS DE AJUSTE DE PARÂMETROS

Param.	Descrição	Melhor Valor
SS	Sigma Space	4
SC	Sigma Color	5
HM	Hui Mínimo	160
BM	Brilho Máximo	340
EV	Erosão Vertical	5
Rho	Limiar Rho	11
H1	1° Limiar Hough	80

Pode-se observar pela Figura 7 que os erros absolutos obtidos nos conjuntos de treinamento e teste foram semelhantes, sugerindo que a escolha dos parâmetros, feita em 10% do conjunto de dados, foi adequada para todo o conjunto.

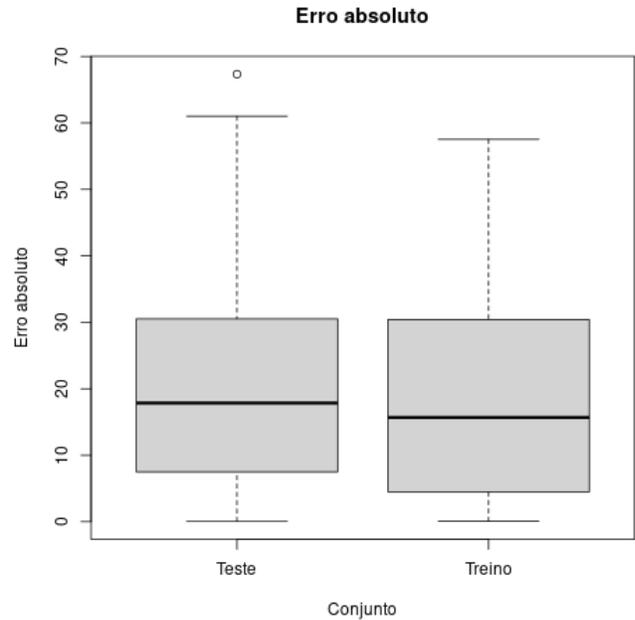


Fig. 7. Erro Absoluto por DataSet



Fig. 8. Exemplo de detecção de falhas, onde há linhas e falhas de aproximadamente 0.5 m nas bordas da imagem

Com relação à transformada de Hough, foi possível identificar um bom desempenho em algumas situações. Imagens com linhas de plantio bem definidas, seja com grande presença de cana-de-açúcar e poucas linhas com falhas, ou até mesmo imagens com falhas um pouco maiores, desde que com linhas de plantio bem definidas, foram situações em que o método conseguiu detectar os pontos de falha e calcular seus comprimentos. A Figura 8 mostra um exemplo de detecção bem-sucedida.

Na Figura 9, é possível ver a dispersão de erros absolutos em função do comprimento manual. Pode-se argumentar que o método utilizado consegue detectar melhor as falhas mais comuns na base de dados, especificamente aquelas cujos tamanhos encontra-se entre 10-20, 25-30, 35 e em alguns casos acima de 40. É importante notar a presença de pontos sobre a diagonal. Trata-se de imagens em que o método falhou em

encontrar as linhas de plantio, necessárias para calcular as falhas. A Figura 10 mostra uma dessas situações, em que pode ser vista uma área cujas linhas de plantio, em sua maioria, apresentam falhas vastas. De forma geral, o desempenho do método é baixo em algumas situações. A primeira delas ocorre nas imagens onde não há linhas de plantio bem definidas (ausência da cana-de-açúcar), na sequência quando há linhas com falhas muito pequenas, e, em alguns casos, quando há uma combinação das duas situações anteriores.

Por meio da análise da Figura 10 e de outras semelhantes, omitidas por brevidade, vê-se que o algoritmo é capaz de realizar o pré-processamento, porém a transformada de Hough se mostra incapaz de pegar a maior parte das linhas. Uma razão para o baixo desempenho ocorrido nestes casos é que a binarização e os operadores morfológicos não destacam bem o contraste entre a cultura e o solo. Isso sugere que outras técnicas de segmentação da cana-de-açúcar podem melhorar o resultado geral do método.

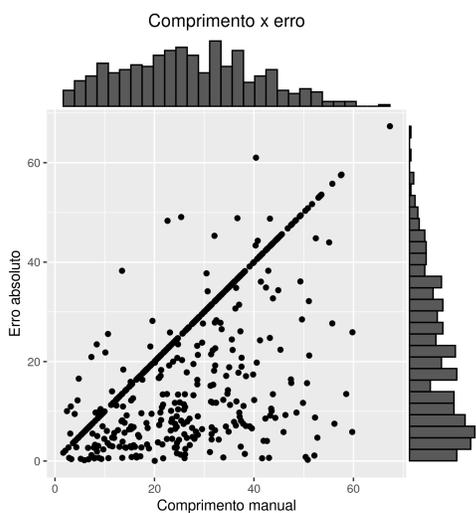


Fig. 9. Dispersão de erros em função do comprimento manual.

IV. CONCLUSÃO

Nesta pesquisa, foi apresentado um método de cálculo automático de falhas em linhas de plantio de cana-de-açúcar. O método gira em torno da transformada de Hough, fazendo uso de técnicas de processamento de imagem - binarização, operadores morfológicos, filtros, segmentação e esqueletização - para auxiliar a detecção de linhas de plantio. Além disso, foi apresentado um conjunto de dados, utilizado para investigação de sete parâmetros relativos às técnicas utilizadas, e para o teste do método.

Pesquisas futuras podem obter melhores resultados investigando diferentes técnicas de segmentação. Por exemplo, o uso de redes de segmentação semântica, explorar outros espaços de cores e formas de limiarização escolhendo diferentes canais, sendo estas novas alternativas que contribuam com a binarização e detecção de linhas de plantio. Uma possibilidade existente é a integração de técnicas de aprendizado profundo

formando um modelo híbrido com a transformada de Hough. Outras questões em aberto são a quantificação de falhas menores, e a melhoria da eficiência para que a técnica seja viável. A aplicação de um novo banco de imagem que reflita uma nova área com a cultura em outro estágio, desde que o mesmo não ultrapasse o período de perfilamento. Estas ações validam a generalização dos parâmetros do algoritmo e o seu desempenho, potencializando a melhor correção (manejo da cultura, replantio entre outras) da cultura.

ACKNOWLEDGMENT

Este trabalho recebeu apoio financeiro da Universidade Católica Dom Bosco (UCDB) e da Fundação de Apoio e Desenvolvimento da Educação, Ciência e Tecnologia do Estado de Mato Grosso do Sul, FUNDECT. Alguns dos autores foram agraciados com Bolsas do Conselho Nacional de Desenvolvimento Científico e Tecnológico, CNPq e da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, CAPES

REFERENCES

- [1] M. H. Saleem, J. Potgieter, and K. M. Arif, "Automation in Agriculture by Machine and Deep Learning Techniques: A Review of Recent Developments," vol. 22, no. 6, pp. 2053–2091, 2021. [Online]. Available: <https://doi.org/10.1007/s11119-021-09806-x>
- [2] M. De Clercq, A. Vats, and A. Biel, "Agriculture 4.0: The future of farming technology," *Proceedings of the World Government Summit, Dubai, UAE*, pp. 11–13, 2018.
- [3] S. Khanal, K. KC, J. P. Fulton, S. Shearer, and E. Ozkan, "Remote sensing in agriculture—accomplishments, limitations, and opportunities," *Remote Sensing*, vol. 12, no. 22, 2020. [Online]. Available: <https://www.mdpi.com/2072-4292/12/22/3783>
- [4] D. M. Bulanon, T. Hestand, C. Nogales, B. Allen, and J. Colwell, *Machine Vision System for Orchard Management*. Cham: Springer International Publishing, 2020, pp. 197–240. [Online]. Available: https://doi.org/10.1007/978-3-030-22587-2_7
- [5] E. Mavridou, E. Vrochidou, G. A. Papakostas, T. Pachidis, and V. G. Kaburlasos, "Machine vision systems in precision agriculture for crop farming," *Journal of Imaging*, vol. 5, no. 12, p. 89, 2019.
- [6] D. I. Patrício and R. Rieder, "Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review," *Computers and Electronics in Agriculture*, vol. 153, pp. 69–81, 2018. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0168169918305829>
- [7] A. Wang, W. Zhang, and X. Wei, "A review on weed detection using ground-based machine vision and image processing techniques," *Computers and Electronics in Agriculture*, vol. 158, pp. 226–240, 2019. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0168169918317150>
- [8] R. O. Duda and P. E. Hart, "Use of the hough transformation to detect lines and curves in pictures," *Communications of the ACM*, vol. 15, no. 1, pp. 11–15, 1972.
- [9] C. S. de Oliveira, G. D. F. a, J. P. H. Sansão, L. A. Mozelli, and M. C. da Silva Jr, "Determinação da orientação em linhas de cultura: investigando métodos de processamento de imagens para aplicação na agricultura de precisão," in *Workshop of Undergraduate Works (WUW) in SIBGRAPI 2012 (XXV Conference on Graphics, Patterns and Images)*, J. P. P. A. Paiva, Ed., Ouro Preto, MG, Brazil, august 2012. [Online]. Available: <http://www.decom.ufop.br/sibgrapi2012/index.php/call/wuw>
- [10] G. Bayar, "The use of hough transform method and knot-like turning for motion planning and control of an autonomous agricultural vehicle," *Agriculture*, vol. 13, no. 1, 2023. [Online]. Available: <https://www.mdpi.com/2077-0472/13/1/92>
- [11] K. Zheng, X. Zhao, C. Han, Y. He, C. Zhai, and C. Zhao, "Design and experiment of an automatic row-oriented spraying system based on machine vision for early-stage maize crops," *Agriculture*, vol. 13, no. 3, 2023.

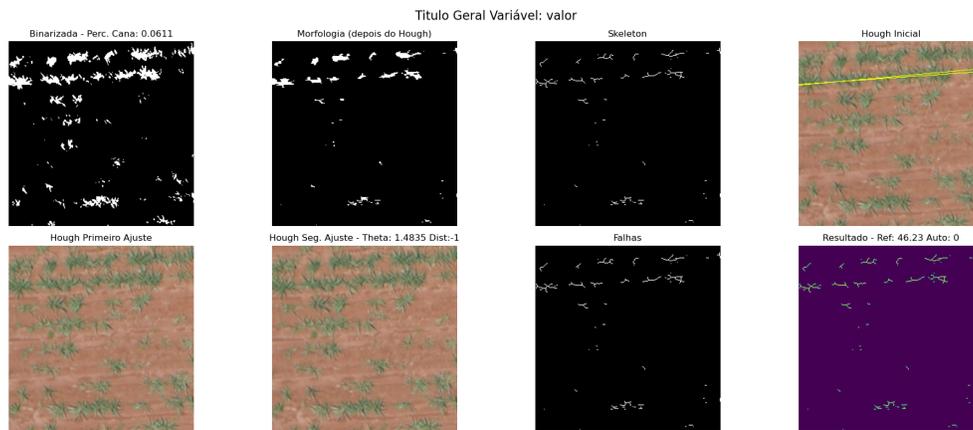


Fig. 10. Exemplo de detecção malsucedida do CropRows.

- [12] D. Koc-San, S. Selim, N. Aslan, and B. T. San, "Automatic citrus tree extraction from uav images and digital surface models using circular hough transform," *Computers and Electronics in Agriculture*, vol. 150, pp. 289–301, 2018. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0168169918302928>
- [13] G. Jiang, X. Wang, Z. Wang, and H. Liu, "Wheat rows detection at the early growth stage based on hough transform and vanishing point," *Computers and Electronics in Agriculture*, vol. 123, pp. 211–223, 2016. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0168169916300254>
- [14] C. C. N. D. ABASTECIMENTO, "Acompanhamento da safra brasileira de cana-de-açúcar," Disponível em: <https://www.conab.gov.br>. Acesso em: 02 abril 2023, Agosto 2022, Brasília DF V.0 n. 2.
- [15] R. Stolf, "Methodology for gap evaluation on sugarcane lines," *STAB Piracicaba*, vol. 4, pp. 12–20, 1986.
- [16] B. M. Rocha, G. da Silva Vieira, A. U. Fonseca, H. Pedrini, N. M. de Sousa, and F. Soares, "Evaluation and detection of gaps in curved sugarcane planting lines in aerial images," in *2020 IEEE Canadian conference on electrical and computer engineering (CCECE)*. IEEE, 2020, pp. 1–4.
- [17] B. Moraes Rocha, A. Ueslei da Fonseca, H. Pedrini, and F. Soares, "Automatic detection and evaluation of sugarcane planting rows in aerial images," *Information Processing in Agriculture*, 2022.