



MARCOS PAULO MAZZEO MARIANO

**VISÃO COMPUTACIONAL APLICADA A IMAGENS DO
BIOSPECKLE LASER EM SEMENTES**

LAVRAS – MG

2026

MARCOS PAULO MAZZEO MARIANO

**VISÃO COMPUTACIONAL APLICADA A IMAGENS DO *BIOSPECKLE LASER* EM
SEMENTES**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas e Automação, área de concentração em Instrumentação, para a obtenção do título de Mestre.

Prof. Dr. Roberto Alves Braga Junior
Orientador

Prof. Dr. José Luís Contado
Coorientador

LAVRAS – MG

2026

**Ficha Catalográfica elaborada pelo Sistema de Geração
de Ficha Catalográfica da Biblioteca Universitária da UFLA, com
dados informados pelo(a) próprio(a) autor(a).**

Mariano, Marcos Paulo Mazzeo.

Visão Computacional Aplicada a Imagens do Biospeckle Laser em Sementes /
Marcos Paulo Mazzeo Mariano. - 2025.
72 p. : il.

Orientador: Roberto Alves Braga Junior

Coorientador: José Luís Contado

Dissertação (Mestrado Acadêmico) - Universidade Federal de Lavras, 2025.
Bibliografia.

1. Visão Computacional. 2. Transformada de Hough. 3. Biospeckle Laser. 4.
Glycine max. I. Braga Junior, Roberto Alves . II. Contado, José Luís. III.
Universidade Federal de Lavras. IV. Título.

MARCOS PAULO MAZZEO MARIANO

**VISÃO COMPUTACIONAL APLICADA A IMAGENS DO *BIOSPECKLE LASER* EM
SEMENTES**

COMPUTER VISION APPLIED TO BIOSPECKLE LASER IMAGES IN SEEDS

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas e Automação, área de concentração em Instrumentação, para a obtenção do título de Mestre.

APROVADA em 27 de novembro de 2025.

Dr. José Luís Contado UFLA
Dr. Ricardo Rodrigues Magalhães UFLA
Dr. José Eduardo Silva Gomes CEFET-MG

Documento assinado digitalmente
 **ROBERTO ALVES BRAGA JUNIOR**
Data: 13/03/2026 14:41:51-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Roberto Alves Braga Junior
Orientador

Prof. Dr. José Luís Contado
Co-Orientador

**LAVRAS – MG
2026**

Dedico este trabalho à memória do meu irmão Jorge Mariano, meu maior exemplo na vida.

AGRADECIMENTOS

À minha família e amigos pelo incentivo e apoio de sempre.

Ao Prof. Dr. Roberto Alves Braga Júnior, pela orientação, atenção e apoio durante todo o mestrado.

Ao Prof. Dr. José Luís Contado, pela contribuição, atenção e apoio.

À equipe de trabalho do Centro de Desenvolvimento de Instrumentação Aplicado à Agropecuária (CEDIA), em especial ao Dr. Bruno Vicentini por ter disponibilizado as imagens de sua pesquisa.

À Universidade Federal de Lavras pelas oportunidades ofertadas.

À Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) pelo apoio e fomento.

RESUMO

Nas técnicas utilizadas para análise de viabilidade e vigor de sementes, utilizando o fenômeno do *biospeckle laser*, existe a possibilidade de automatizar o processo de análise das imagens por meio de técnicas de visão computacional. O presente trabalho teve como objetivo desenvolver uma técnica de segmentação e detecção da orientação espacial de sementes de soja iluminadas pelo *biospeckle laser*. Foram utilizadas 229 imagens de sementes de soja obtidas em experimentos anteriores com o *biospeckle laser*. As imagens foram processadas no *software* ImageJ®, no qual foi desenvolvida uma macro para automatizar todo o fluxo de análise. Inicialmente, aplicou-se um filtro de suavização gaussiana para redução do ruído nas imagens. Em seguida, diferentes métodos de limiarização foram testados, selecionando-se aquele com melhor desempenho na binarização da imagem. Após a binarização, foi aplicado o algoritmo de segmentação por crescimento de região. Para a determinação da orientação espacial, foi empregada a Transformada de Hough, responsável por ajustar a elipse que melhor representava a forma segmentada da semente. Antes da aplicação às imagens reais, foi realizado um teste com objetos de geometria conhecida - rotacionados em diferentes ângulos - para verificar a precisão e a robustez da Transformada de Hough na detecção e ajuste de elipses. Os resultados comprovaram a capacidade da técnica em identificar corretamente a orientação espacial dos objetos, validando sua aplicação às imagens do *biospeckle laser* das sementes. Por fim, os ângulos calculados pela técnica desenvolvida foram comparados com medidas reais obtidas por meio de um goniômetro digital, permitindo o cálculo do erro médio. Também foi realizado um teste para avaliar a sensibilidade da técnica à rotação das sementes. O método apresentou um erro médio de 5,65% e resolução de 0,0026°, demonstrando alta precisão e robustez na detecção da orientação espacial das sementes. Conclui-se que a técnica desenvolvida é viável e confiável para a aplicação em experimentos com o *biospeckle laser* em sementes de soja, constituindo uma ferramenta promissora para análises automatizadas.

Palavras-chave: visão computacional; transformada de Hough; biospeckle laser; Glycine max.

ABSTRACT

In techniques used to analyze seed viability and vigor through the biospeckle laser phenomenon, there is a possibility of automating the image analysis process by means of computer vision techniques. This study aimed to develop a method for segmentation and detection of the spatial orientation of soybean seeds illuminated by the biospeckle laser. A total of 229 images of soybean seeds obtained from previous biospeckle laser experiments were used. The images were processed in the ImageJ® software, in which a macro was developed to automate the entire analysis workflow. Initially, a Gaussian smoothing filter was applied to reduce image noise. Then, different thresholding methods were tested, selecting the one with the best performance in image binarization. After binarization, a region-growing segmentation algorithm was applied. To determine the spatial orientation, the Hough Transform was employed to fit the ellipse that best represented the segmented seed shape. Before applying the method to real images, a test with objects of known geometry—rotated at different angles—was performed to verify the precision and robustness of the Hough Transform in detecting and fitting ellipses. The results confirmed the technique's ability to correctly identify the spatial orientation of the objects, validating its application to biospeckle laser images of seeds. Finally, the angles calculated by the developed method were compared with real measurements obtained using a digital goniometer, allowing the calculation of the mean error. A sensitivity test to seed rotation was also performed. The method presented a mean error of 5.65% and a resolution of 0.0026°, demonstrating high precision and robustness in detecting the spatial orientation of the seeds. It is concluded that the developed technique is viable and reliable for application in biospeckle laser experiments with soybean seeds, constituting a promising tool for automated analyses.

Keywords: computer vision; Hough transform; biospeckle laser; Glycine max.

INDICADORES DE IMPACTOS

A presente dissertação teve como objetivo desenvolver uma técnica de segmentação e detecção da orientação espacial de sementes de soja em imagens obtidas por meio do fenômeno do *biospeckle laser*, utilizando técnicas de visão computacional. Os resultados demonstraram a viabilidade da técnica proposta, que apresentou erro médio de 5,65% e resolução de 0,0026°, indicando elevada precisão na detecção da orientação espacial das sementes. Do ponto de vista tecnológico, o trabalho contribui para o avanço da automação em análises baseadas no *biospeckle laser*, reduzindo a subjetividade e o tempo de processamento associados a avaliações manuais e favorecendo a padronização das análises em experimentos envolvendo sementes. Sob a perspectiva econômica e produtiva, a metodologia possui potencial de aplicação em pesquisas voltadas à qualidade fisiológica de sementes agrícolas, contribuindo para o aprimoramento de métodos de avaliação de vigor e viabilidade que impactam diretamente a produtividade agrícola. Em termos sociais e territoriais, os resultados beneficiam principalmente a comunidade científica, pesquisadores, estudantes e instituições de pesquisa que atuam nas áreas de engenharia de sistemas e automação, engenharia agrícola, ciência de sementes, instrumentação científica, processamento digital de imagens e ciência de dados aplicada à agricultura. No âmbito da extensão e da política científica, o trabalho se insere principalmente na área temática “tecnologia e produção”, conforme a Política Nacional de Extensão, ao promover o desenvolvimento e a disseminação de ferramentas tecnológicas aplicáveis ao setor agropecuário. Ademais, os resultados apresentam alinhamento com os Objetivos de Desenvolvimento Sustentável da Organização das Nações Unidas, especialmente o ODS 2 – Fome Zero e Agricultura Sustentável, ao contribuir para o aprimoramento de técnicas de avaliação da qualidade de sementes e, consequentemente, para o fortalecimento da produção agrícola, e o ODS 12 – Consumo e Produção Responsáveis, ao favorecer o uso mais eficiente de insumos e recursos no sistema produtivo agrícola. Dessa forma, a técnica desenvolvida representa uma contribuição científica e tecnológica para a automação de análises em experimentos com *biospeckle laser*, com impactos potenciais na pesquisa, na inovação tecnológica e no aprimoramento das práticas de avaliação de sementes no contexto da agricultura moderna.

IMPACT INDICATORS

This dissertation aimed to develop a technique for segmentation and detection of the spatial orientation of soybean seeds in images obtained through the biospeckle laser phenomenon, using computer vision techniques. The results demonstrated the feasibility of the proposed technique, which presented a mean error of 5.65% and a resolution of 0.0026° , indicating high precision in detecting the spatial orientation of the seeds. From a technological perspective, the work contributes to the advancement of automation in biospeckle laser-based analyses, reducing subjectivity and processing time associated with manual evaluations and promoting the standardization of analyses in experiments involving seeds. From an economic and productive standpoint, the methodology has potential applications in research focused on the physiological quality of agricultural seeds, contributing to the improvement of methods for evaluating vigor and viability, which directly impact agricultural productivity. In social and territorial terms, the results mainly benefit the scientific community, researchers, students, and research institutions working in the fields of systems and automation engineering, agricultural engineering, seed science, scientific instrumentation, digital image processing, and data science applied to agriculture. Within the scope of extension and scientific policy, the work is mainly associated with the thematic area of “technology and production”, according to the Brazilian National Extension Policy, by promoting the development and dissemination of technological tools applicable to the agricultural sector. Furthermore, the results are aligned with the Sustainable Development Goals of the United Nations, especially SDG 2 – Zero Hunger and Sustainable Agriculture, by contributing to the improvement of seed quality evaluation techniques and, consequently, to the strengthening of agricultural production, and SDG 12 – Responsible Consumption and Production, by promoting a more efficient use of inputs and resources in agricultural production systems. Thus, the developed technique represents a scientific and technological contribution to the automation of analyses in biospeckle laser experiments, with potential impacts on research, technological innovation, and the improvement of seed evaluation practices in the context of modern agriculture.

LISTA DE FIGURAS

Figura 3.1 – Semente de soja de alta qualidade após o teste de tetrazólio; (A) face externa e (B) face interna com detalhe para os região vascular da semente.	20
Figura 3.2 – Demonstração do fenômeno de interferência que gera o padrão <i>speckle</i> , que ocorre quando o feixe de <i>laser</i> se dispersa em uma superfície irregular e é detectado por um sensor óptico.	22
Figura 3.3 – Padrão de <i>biospeckle laser</i> gerado em uma semente de soja.	23
Figura 3.4 – Análise gráfica de semente de soja (A) de alto e (B) de baixo vigor, ambos pelo método GAVD.	24
Figura 3.5 – <i>Datapack</i> e matriz THSP.	24
Figura 3.6 – Matrizes THSP e Coocorrência.	25
Figura 3.7 – Representação da elipse.	31
Figura 3.8 – Geometria da elipse.	32
Figura 3.9 – Elipse detectada.	33
Figura 5.1 – Resultado das análises gráfica (GAVD) e numérica (AVD) em duas sementes com diferentes orientações espaciais.	41
Figura 5.2 – (a) Imagem original e (b) após aplicação de filtro gaussiano.	42
Figura 5.3 – (a) Aplicação do método de Otsu. (b) Aplicação do método de Li.	43
Figura 5.4 – (a) Imagem monocromática (8 bits) da semente de soja obtida via <i>biospeckle laser</i> com aplicação de filtro gaussiano. (b) Aplicação da limiarização pelo método de Li.	44
Figura 5.5 – Aplicação da técnica de segmentação por crescimento de região na semente de soja obtida via <i>biospeckle laser</i> , com as bordas identificadas em amarelo.	45
Figura 5.6 – Objetos rotacionados (a ; b) e as elipses detectadas sobrepostas às figuras iniciais (c ; d).	46
Figura 5.7 – Retângulos rotacionados (a ; b) e as elipses detectadas sobrepostas às figuras iniciais (c ; d).	47
Figura 5.8 – Medição dos ângulos em que as sementes iluminadas pelo <i>biospeckle laser</i> estavam dispostas.	48
Figura 5.9 – Redimensionamento de 30% no tamanho do canvas para a detecção adequada da elipse sobre a região de interesse.	49

Figura 5.10 – (a; c) Imagens do <i>biospeckle laser</i> de sementes de soja; (b; d) Elipses detectadas pela técnica aplicada nas imagens processadas.	50
Figura 5.11 – Boxplot do erro percentual entre o goniômetro e a técnica desenvolvida (n = 229 sementes).	53
Figura 5.12 – Principais fontes de erro na detecção da orientação espacial das sementes. .	54

LISTA DE TABELAS

Tabela 4.1 – Procedimentos utilizados na detecção da orientação espacial das sementes .	38
Tabela 5.1 – Resultados dos parâmetros das elipses detectadas pela Transformada de Hough.	46
Tabela 5.2 – Resultados dos parâmetros das elipses detectadas pela Transformada de Hough.	47
Tabela 5.3 – Resultados dos parâmetros das elipses detectadas pela técnica aplicada nas imagens do <i>biospeckle laser</i> de sementes de soja.	51
Tabela 5.4 – Comparação dos métodos de limiarização aplicados na determinação do ângulo de inclinação das sementes.	52
Tabela 5.5 – Teste de sensibilidade da técnica à rotação das sementes.	55
Tabela .1 – Resultados dos erros médios entre os ângulos das sementes medidos pelo goniômetro e pela técnica desenvolvida.	65

SUMÁRIO

1	INTRODUÇÃO	15
2	OBJETIVOS	17
2.1	Geral	17
2.2	Específicos	17
3	REFERENCIAL TEÓRICO	18
3.1	Qualidade semente	18
3.2	<i>Biospeckle Laser</i>	21
3.3	Visão Computacional	27
3.3.1	Transformada de Hough	31
4	MATERIAIS E MÉTODOS	35
4.1	<i>Biospeckle Laser</i>	35
4.2	Processamento das imagens	35
4.2.1	Suavização Gaussiana	35
4.2.2	Limiarização	35
4.2.3	Segmentação por crescimento de região	36
4.2.4	Transformada de Hough	36
4.2.5	Determinação dos ângulos reais das sementes	36
4.2.6	Implementação da Macro	36
4.2.7	Validação da metodologia	38
5	RESULTADOS E DISCUSSÃO	40
5.1	Análise da atividade do <i>biospeckle laser</i>	40
5.2	Aplicação do filtro gaussiano	41
5.3	Aplicação dos algoritmos de limiarização	42
5.4	Aplicação do algoritmo de segmentação por crescimento de região	44
5.5	Teste em objetos conhecidos	45
5.6	Determinação dos ângulos reais das sementes	48
5.7	Macro desenvolvida com a aplicação da Transformada de Hough	48
5.7.1	Validação da metodologia	51
6	CONCLUSÃO	56
	REFERÊNCIAS	57
	APÊNDICE A	61

APÊNDICE B	65
-------------------	----

1 INTRODUÇÃO

A agricultura é uma atividade primordial para a humanidade, disponibilizando alimentos, fibras e energia, demandas fundamentais para o desenvolvimento e manutenção da sociedade. Dentro desse campo, a produção de grãos tem um destaque especial, por ser responsável por uma parte considerável da produção agrícola mundial, que também demanda avanços tecnológicos em toda a cadeia produtiva, como o desenvolvimento de máquinas e automação; engenharia genética e agricultura de precisão.

A soja é o principal grão produzido e exportado pelo país, isso se deve à sua qualidade nutricional, facilidade de mecanização, manejo e cultivo, linha de crédito adequada e uma rede de insumos apropriada (fertilizantes, defensivos, corretivos e sementes).

Um ponto interessante a ser considerado é a distinção da finalidade de uso entre grão e semente, que, apesar de estarem configurados como um produto da mesma espécie, têm finalidades distintas. Os grãos são destinados à alimentação e à agroindústria de transformação, enquanto as sementes têm a finalidade de produzir outras plantas. Ou seja, o embrião precisa ter viabilidade e vigor suficientes para desenvolver uma plântula saudável que permita à obtenção de uma colheita satisfatória e com boa produtividade.

Para a produção agrícola ser bem-sucedida, além das condições climáticas e de planejamento serem atendidas, um aspecto fundamental que antecede aos demais é a utilização de sementes de alta qualidade, que são aquelas que possuem alta viabilidade e vigor; ausência de pragas ou doenças; ausência de danos mecânicos e qualidades genéticas que permitem resistência e produtividade.

Desta forma, como a qualidade da semente é um fator crítico para a obtenção de lavouras produtivas, o teste de qualidade das sementes torna-se fundamental. Existem diversos métodos para avaliar a qualidade das sementes, sendo alguns deles: germinação, emergência, crescimento de mudas, envelhecimento acelerado e tetrazólio. Todavia, observa-se que eles demandam um elevado tempo de análise, o envolvimento do julgamento humano, além de um grande número de sementes.

Uma alternativa desenvolvida para avaliar a viabilidade e vigor de sementes de soja é a utilização das técnicas do *biospeckle laser*, um método óptico, rápido, que mensura indiretamente a atividade metabólica da semente, sem a necessidade de utilizar reagente químico e profissional específico para julgar a sua qualidade. No processamento das imagens digitais obtidas a partir do *biospeckle laser*, existe a possibilidade de automatizar o processo de análise das

imagens por meio de técnicas de visão computacional que permitam, por exemplo, a segmentação da semente e a determinação de sua orientação espacial, fundamentais para uma análise autônoma.

Este trabalho visa desenvolver uma técnica de segmentação e detecção de orientação espacial da semente iluminada pelo *laser*. De forma específica, serão estudadas técnicas de processamento de imagens, como filtragens, e de limiarização e sua aplicação nas imagens do *biospeckle laser*. Também será estudada a aplicação da Transformada de Hough e sua habilidade para fazer o ajuste de uma elipse. Serão realizados testes em objetos conhecidos e, por fim, validação em imagens de sementes de soja iluminadas pelo *laser*.

2 OBJETIVOS

2.1 Geral

Desenvolver uma técnica de segmentação e detecção de orientação espacial da semente iluminada pelo *laser*.

2.2 Específicos

- Demonstrar a variação espacial da atividade biológica em sementes de soja por meio da técnica de *biospeckle laser*.
- Avaliar as técnicas de processamento de imagens, como filtragens; limiarização; segmentação por crescimento de região e suas aplicações nas imagens do *biospeckle laser*.
- Avaliar a capacidade da Transformada de Hough em ajustar elipses em objetos de geometria conhecida.
- Aplicar e validar a Transformada de Hough para a detecção da orientação espacial de sementes de soja em imagens de *biospeckle laser*.

3 REFERENCIAL TEÓRICO

A Agricultura tem importância fundamental na história da humanidade, fornecendo alimento, matéria-prima e energia para diversas atividades. Atualmente, o agronegócio representa um importante pilar da economia brasileira. Deste segmento, a soja tem um destaque especial, com uma produção estimada de 166 milhões de toneladas, despontando como o principal produto de exportação brasileiro, representando 18% de todas as exportações (CONAB, 2024).

O êxito na produção de soja depende de diversos fatores, tendo, como o principal, a utilização de sementes de alta qualidade, ou seja, aquelas que possuam alta viabilidade e vigor para garantia de uma boa germinação, tendo todas as condições de expressar maior desempenho e produtividade (KRZYZANOWSKI et al., 2016).

3.1 Qualidade semente

Existem diversos fatores que determinam a qualidade de uma semente, que resulta em germinação adequada em campo, como possuir um elevado potencial genético, alta viabilidade, alto vigor e não possuir danos mecânicos ou doenças (KRZYZANOWSKI; FRANÇA-NETO; HENNING, 2018).

A viabilidade biológica refere-se à capacidade de uma semente desenvolver o seu eixo embrionário, de germinar, gerando uma plântula em condições ideais (KRZYZANOWSKI et al., 2016). O vigor determina o potencial do desenvolvimento de plântulas de maneira rápida e uniforme, propiciando o desenvolvimento de plantas com maior produtividade (RAJJOU et al., 2012). Segundo Henning et al. (2010), sementes de soja com maior vigor apresentam quantidades maiores de amido, açúcares e proteínas solúveis, além de maior capacidade de mobilizar reservas durante a germinação.

Caverzan et al. (2018), realizam um experimento com a cultivar de soja DM 5958 RSF IPRO em três localidades diferentes no Rio Grande do Sul, foram analisadas sementes com diferentes níveis de vigor (90%, 75%, 63% e 48%). Verificou-se que as sementes de maior vigor (90%) produziram 1.180, 1.376 e 1.307 kg.ha⁻¹ a mais de grãos do que as áreas cultivadas com sementes de menor vigor (48%).


Na análise do desenvolvimento dos estandes de milho, verificou-se que aqueles semeados com sementes de maior vigor apresentaram maior índice de cobertura do solo, o que contribuiu para o aumento do número de grãos por espiga. Verificou-se que cada aumento de 1,0

ponto percentual no nível de vigor das sementes do lote pode proporcionar um acréscimo na produção de grãos de até 43,5 kg·ha⁻¹ (REIS et al., 2022).

Para padronizar a avaliação das sementes, foi desenvolvida pelo Ministério da Agricultura, Pecuária e Abastecimento (MAPA) a regra para avaliação de sementes (RAS), onde são estabelecidas as metodologias dos testes (BRASIL, 2009). Dentre eles, pode-se destacar o teste de germinação, que consiste em descobrir o percentual de sementes que possuem a capacidade de desenvolver plantas saudáveis (FRANÇA NETO; KRZYZANOWSKI, 2018); o teste do envelhecimento acelerado, onde as sementes são submetidas a estresse térmico, alta umidade e tempo de envelhecimento, favorecendo assim a germinação das sementes de maior vigor (TEKRONY, 2005). Outros testes utilizados na avaliação de vigor são: crescimento de mudas; condutividade elétrica e tetrazólio (MARCOS-FILHO, 2015).

Os primeiros testes demandavam um tempo elevado para a semente germinar. Para contornar esse problema, foi desenvolvido o teste químico com o sal de tetrazólio, que é mais rápido e capaz de determinar os pontos onde ocorrem atividades metabólicas e a intensidade. Nesse teste, ocorre a respiração dos tecidos vivos; os íons de H⁺ liberados são transferidos por um grupo de enzimas que interagem com o tetrazólio incolor, o qual é reduzido a um composto vermelho, estável e não difusível chamado trifênil formazan. Como resultado, consegue-se determinar a viabilidade, vigor e danos mecânicos, mensurados pela intensidade de coloração adquirida pela semente após o teste (BRASIL, 2009). Na Figura 3.1, é possível visualizar uma semente de soja de alta qualidade, após a realização do teste de tetrazólio.

Figura 3.1 – Semente de soja de alta qualidade após o teste de tetrazólio; (A) face externa e (B) face interna com detalhe para os região vascular da semente.



Fonte: (FRANÇA NETO; KRZYZANOWSKI, 2018).

Apesar de ser mais rápido que os demais testes, ele ainda necessita que as sementes fiquem acondicionadas em papel umedecido em água por 16 horas e mais 3 horas na solução de tetrazólio para que a reação ocorra, além do fato de necessitar de técnico habilitado e treinado para poder interpretar os resultados do teste.

Nos testes tradicionais, como de germinação e tetrazólio, as análises são realizadas manualmente e com uma grande quantidade de sementes, variando de 200 a 400 sementes, tornando-as cansativas, sujeitas à subjetividade e ao erro. Por conta disso, diversos autores estão desenvolvendo técnicas de aprendizado de máquina e reconhecimento de padrões para a análise das sementes (MESHRAM et al., 2021).

Medeiros et al. (2018) avaliaram a eficiência da técnica de visão computacional, por meio do *software* de processamento de imagens digitais de plântulas (SAPL), para determinação de vigor em sementes de milho. Foram comparados os resultados das imagens das plântulas, no sétimo dia, com os valores dos testes convencionais de vigor e obtiveram resultados consistentes, demonstrando que a técnica pode ser uma alternativa complementar aos testes tradicionais de vigor.

Larios et al. (2020) desenvolveram um método visando diferenciar a qualidade fisiológica de sementes de soja, analisando o seu conteúdo de nutrientes, mensurado por meio da espectroscopia de quebra induzida por *laser* (LIBS) combinada com análise multivariada e algoritmos de aprendizado de máquina. O algoritmo *Support Vector Machine* (SVM) obteve os

melhores resultados, conseguindo classificar corretamente 100% das amostras de alto vigor e 97,8% das amostras de baixo vigor.

Vivas et al. (2017) avaliaram a técnica do *biospeckle laser* em sementes de *Coffea arabica* e sua relação com a viabilidade de mudas. A técnica do BSL foi capaz de mensurar a atividade biológica das sementes e estimar a sua qualidade em apenas 6 dias após a embebição, um período bem menor que os testes tradicionais, que levam cerca de 30 dias.


A técnica de *biospeckle laser* (BSL) surge como uma alternativa viável para a análise de sementes, possibilitando avaliações não destrutivas, rápida aquisição das imagens e *Setup* relativamente simples. Além disso, substitui métodos tradicionais que são mais trabalhosos, custosos e subjetivos, como os testes de germinação e tetrazólio (XING et al., 2023).

3.2 *Biospeckle Laser*

O *laser* foi desenvolvido na década de 1960 e, nas décadas seguintes, teve sua aplicação estendida para diversos segmentos, em função de suas características, como a coerência da luz, que resulta em padrões de interferência, como o padrão *speckle* (Braga Júnior, 2017).

O padrão *speckle* do *laser* é detectado pela luz refletida da amostra, que precisa apresentar uma superfície irregular para que ocorra a interferência, como observado na Figura 3.2. Este padrão vem sendo utilizado para aplicações em diversos segmentos, desde agricultura à medicina, devido à sua sensibilidade e à possibilidade de medir atividades biológicas e não biológicas (YOUSSEF et al., 2019). Quando voltado para medir a atividade biológica, ou seja, situações dinâmicas, é denominado *laser speckle* dinâmico ou *biospeckle laser*, sendo que este padrão dinâmico representa os dados sobre a movimentação do objeto em estudo (AIZU; ASAKURA, 1991).


Figura 3.2 – Demonstração do fenômeno de interferência que gera o padrão *speckle*, que ocorre quando o feixe de *laser* se dispersa em uma superfície irregular e é detectado por um sensor óptico.



Fonte: (BRAGA et al., 2025).

Segundo Braga et al. (2025) o método do BSL tornou-se interessante ao setor de sementes por ser uma técnica que mensura de forma indireta, rápida e objetiva, sem a necessidade de testes químicos e sem precisar de uma grande quantidade de sementes, como é o caso dos testes de vigor tradicionais. Esse processo, no entanto, requer um preparo adequado para cada tipo de semente analisada, pois cada espécie demanda um preparo próprio na fase de embebição para o início do processo germinativo e na definição da região da semente que será iluminada. Na Figura 3.3 está representado o padrão de *biospeckle laser* gerado em uma semente de soja.

Figura 3.3 – Padrão de *biospeckle laser* gerado em uma semente de soja.




Fonte: (SOUZA SOBRINHO, 2023).

Na análise gráfica do *biospeckle laser* é gerado, como resultado, um mapa da atividade biológica da semente. Um dos métodos utilizados é o *Graphic Absolute Value of the Differences Method* (GAVD) (BRAGA; RIVERA; MOREIRA, 2016). Nele, procede-se com o somatório da diferença absoluta dos níveis de cinza entre os mesmos *pixels* nas imagens subsequentes e realiza-se a normalização deste somatório pela quantidade de imagens utilizadas, conforme apresentado na equação 3.1, onde: I_k = representa o valor da intensidade no instante k ; I_{k+1} = representa o nível de intensidade no instante $k + 1$ e $NTIMES$ representa a quantidade de imagens utilizadas na análise. (BRAGA et al., 2011).

$$GAVD = \frac{1}{NTIMES - 1} \sum_{K=1}^{NTIMES-1} |I_K - I_{K+1}| \quad (3.1)$$

Na Figura 3.4, é apresentado o resultado do método gráfico (GAVD) aplicado em uma semente de soja de alto (a) e baixo vigor (b). A escala, expressa em unidades arbitrárias (u.a.), representa uma grandeza adimensional, variando do azul para o vermelho, representando baixa e alta atividade biológica, respectivamente, e as unidades dos eixos x e y são em *pixels* (px). Para este processamento, é utilizado o algoritmo do *Biospeckle Laser Tool Library* (BSLTL) (Braga Junior; RIVERA, 2019).


Figura 3.4 – Análise gráfica de semente de soja (A) de alto e (B) de baixo vigor, ambos pelo método GAVD.



Fonte: elaboração própria.

Os métodos numéricos são utilizados quando se deseja analisar o nível de atividade em uma região homogênea da imagem, retornando um resultado numérico (adimensional) como resposta. A primeira etapa da análise numérica consiste em empregar a técnica do *Time History Speckle Pattern* (THSP) (XU, Z.; JOENATHAN, C.; KHORONA, 1995), uma matriz composta pelos mesmos *pixels* selecionados de k imagens do objeto, sendo cada coluna a representação desses mesmos pontos nas imagens subsequentes no tempo (ARIZAGA; TRIVI; RABAL, 1999), apresentada na Figura 3.5.

Figura 3.5 – Datapack e matriz THSP.




Fonte: (BRAGA; RIVERA; MOREIRA, 2016).

Em seguida, é montada a matriz de coocorrência (HARALICK; SHANMUGAM; DINS-TEIN, 1973), que representa o número de vezes em que ocorre um salto de intensidade de quaisquer *pixels* consecutivos na matriz THSP; possui 256 linhas e 256 colunas, assim contabi-

lizando todos os saltos de intensidade possíveis na imagem de 8 bits, ou seja, com 256 níveis de cinza. Na Figura 3.6 é apresentada uma matriz THSP com 486 pontos selecionados do conjunto (*datapack*) de imagens para formar a linha e as 128 imagens consecutivas no tempo, representando as colunas. A matriz de coocorrência é apresentada com uma paleta de cores destacando a quantidade de saltos de intensidade ocorridos.

Figura 3.6 – Matrizes THSP e Coocorrência.



Fonte: (BRAGA; RIVERA; MOREIRA, 2016).

O método AVD - *Absolute Value of the Differences* calcula o valor numérico das diferenças absolutas, apresentado na equação 3.2, onde M_{ij} representa a matriz de coocorrência normalizada; $I_k = i$ representa o valor da intensidade no instante k e $I_{k+1} = j$ representa o nível de intensidade no instante $k + 1$ (BRAGA et al., 2011).

$$AVD = \sum_{i,j} M_{ij} |i - j| \quad (3.2)$$

Existem trabalhos utilizando o *biospeckle laser* em diversos segmentos, como o teor de água nas folhas de café (BOTEGA et al., 2009); crescimento de raízes (BRAGA et al., 2009); na pecuária para avaliar a viabilidade de sêmen de bovinos (CARVALHO et al., 2009). A técnica também tem sido aplicada na análise de frutos, carnes, na avaliação da viabilidade e do vigor em sementes, além da identificação da presença de fungos (PANDISELVAM et al., 2020).

Braga Júnior et al. (2020) durante um estudo em sementes *Coffea arábica* (cultivar Catuaí Vermelho 144), expostas à aplicação de campos magnéticos constantes (10 a 28 mT) com o intuito de reduzir o período de germinação, utilizaram as técnicas do *biospeckle laser* para medir a atividade biológica após 6 dias de tratamento e obtiveram diferenças significativas com

os índices numéricos do *Inertia Moment* (IM) e *Absolute Value of the Differences* (AVD) em relação às sementes que não passaram pelo tratamento.

Contado, Silva e Braga Júnior (2020) avaliaram a viabilidade de sementes de Angico-vermelho (*Anadenanthera colubrina*) nas primeiras 72 horas de germinação, utilizando a técnica do *biospeckle laser*, por meio do método numérico do AVD. Foi constatado que, já nas primeiras 4 horas após o processo de germinação, o BSL foi capaz de medir a atividade metabólica e em quais regiões da semente ela estava ocorrendo. Dessa forma, demonstrou-se que o BSL foi capaz de substituir os testes tradicionais de viabilidade.

Rahmanian et al. (2020) em um estudo avaliando os efeitos do resfriamento e congelamento em frutos de laranja, durante um período de 16 horas em quatro tratamentos (temperatura ambiente; 1°C; -7°C e -20°C), utilizaram as técnicas do *biospeckle laser* para medir a atividade biológica e classificar os danos causados pelas técnicas de resfriamento, por meio do método gráfico Fujii e por método numérico com as informações extraídas da Matriz de Coocorrência (COM). Por meio da COM, foram extraídos atributos e utilizados em uma Rede Neural Artificial (RNA), que foi capaz de classificar 100% dos danos causados pelo congelamento dos frutos. Foi constatado que o BSL, em ambos os métodos, conseguiu acompanhar a atividade biológica no resfriamento e congelamento nos tecidos dos frutos, corroborando que a técnica é capaz de ser uma alternativa aos métodos padrão de avaliação de congelamento de laranjas.

Singh et al. (2021) desenvolveram um sensor utilizando *biospeckle laser* para identificar e avaliar a extensão das lesões causadas pelo fungo *Macrophomina phaseoli* em plantas de soja. Utilizando o *Time History Speckle Pattern* (THSP) aplicado no método numérico do AVD e comparando os resultados da técnica com as análises visuais das lesões nas plantas, concluiu-se que a técnica do BSL foi capaz de identificar lesões no caule das plantas, por meio do incremento de atividade biológica, antes mesmo que fossem perceptíveis ao olho nu, evidenciando, assim, a sensibilidade e eficácia da técnica em identificar a doença, mesmo em seus estágios iniciais.

SOUZA SOBRINHO (2023) avaliou o método do *biospeckle laser* em sua capacidade de diferenciar lotes de sementes de soja com diferentes níveis de qualidade fisiológica. Foram utilizadas 12 amostras de sementes, que passaram por um período prévio de embebição de 8 horas, e foram submetidas aos testes tradicionais. Para análise do BSL, foram registradas 512 imagens por semente, que posteriormente foram processadas pelo método gráfico *Graphic Absolute Value of the Differences* (GAVD), que gerou o mapa de atividades das sementes; e pelo

método numérico *Numerical Analysis of the Average Difference* (NUMAD), que produziu um índice numérico, representando o nível de atividade metabólica das sementes. Os resultados indicaram que o método *biospeckle laser* foi capaz de diferenciar as sementes com diferentes níveis de qualidade fisiológica, apresentando forte correlação entre os valores obtidos pelo NUMAD e os resultados dos testes tradicionais de vigor.

VICENTINI et al. (2024) desenvolveram um sistema portátil para execução da técnica do *biospeckle laser* em sementes, como uma alternativa aos sistemas laboratoriais, que ficam restritos aos laboratórios de física óptica (no presente estudo, ocupava um volume de 6,99 m³). Para o desenvolvimento do *setup* portátil, foi utilizado um *laser* de diodo, com comprimento de onda de 635 nm e potência de 5 mW; um filtro neutro para regular a intensidade luminosa do *laser*; espuma para amortecimento das vibrações na estrutura e um microscópio digital portátil para aquisição das imagens, e o volume ocupado pelo sistema foi de apenas 0,04 m³. Foram avaliadas, em ambos os sistemas, 229 sementes de soja de alto vigor e 229 sementes de baixo vigor pelo método gráfico GAVD e pelo método numérico AVD. Foi constatado que o sistema portátil obteve o mesmo desempenho que o sistema padrão laboratorial, não diferindo estatisticamente os valores entre os sistemas. Os autores concluíram, assim, que o sistema portátil pode ser uma alternativa aos sistemas tradicionais e pode tornar a técnica do BSL mais acessível aos laboratórios de análise de sementes.

3.3 Visão Computacional

A visão computacional é uma área do conhecimento que reúne os campos do processamento digital de imagens e inteligência artificial por meio de algoritmos que extraem informações da imagem, de modo a interpretar os objetos contidos nela, simulando a visão humana. Possui diversas aplicações, como nas áreas de medicina, agricultura, astronomia, engenharia, entre outras (NETO; GONZAGA, 2012). Na agricultura, tem sido utilizada na visão em robôs, sensores acoplados a tratores, em máquinas para aplicações de fertilizantes e pesticidas, na detecção de obstáculos e na qualidade de produtos agrícolas e alimentícios (FRACAROLLI et al., 2020).

Segundo Oyama et al. (2012) dentre os desafios listados no segmento da visão computacional está a extração de informação adequada dos descritores de forma da imagem e a demanda computacional para a realização dos cálculos matemáticos, que não deve ser elevada,

de maneira que inviabilize determinadas análises, como as usadas em veículos autônomos e robôs industriais, entre outros.

Como apresentado por Milano e Honorato (2010), as etapas de um sistema de visão computacional podem ser divididas em:

- Fase de aquisição da imagem: Etapa de captura da imagem pela câmera, podem ser capturada uma única ou um conjunto de imagens;
- Pré-processamento: É aplicado algum processamento prévio para identificação futura de alguma característica de interesse na imagem, como detecção de bordas, linhas, etc;
- Extração de características: Etapa de extração de atributos da imagem, como bordas, figuras geométricas, dentre outros;
- Detecção e segmentação: Nesta fase são identificados e segmentados os objetos de interesse na imagem para posterior análise específica.
- Processamento de alto nível: Utilização de técnicas de inteligência artificial para validação de dados, determinação de parâmetros e classificação das características da imagem.

No pré-processamento, existem as técnicas de filtragem da imagem, que realizam a operação de convolução, que pode ser definida como uma multiplicação de matrizes, com o objetivo de realizar alguma modificação na imagem original; uma delas é a imagem e a outra é a matriz ou máscara de convolução, geralmente menor, que percorre os *pixels* da imagem, realizando a multiplicação, ponto a ponto, dos *pixels* sob a máscara de convolução, e o resultado corresponde à soma da multiplicação de cada *pixel* (GONZALEZ; WOODS, 2002).

Dentre as técnicas de filtragem, existe o filtro de suavização gaussiana, que utiliza uma máscara gerada a partir da função gaussiana bidimensional. Esta máscara de convolução faz a média ponderada entre o *pixel* analisado e seus *pixels* vizinhos, com determinado valor de desvio padrão como parâmetro, que define os *pixels* da vizinhança que serão processados, definindo um peso maior para os *pixels* da vizinhança próxima, conforme a equação abaixo 3.3, com o objetivo de suavizar a imagem original, filtrando as pequenas mudanças de intensidade entre os *pixels* (GONZALEZ; WOODS, 2018).

$$G(x,y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (3.3)$$

onde:

- $G(x,y)$ = valor do filtro gaussiano no ponto (x,y) ;
- σ = desvio padrão da distribuição gaussiana;
- x,y = coordenadas relativas ao centro da máscara.

Na extração de características, existem as técnicas de limiarização. Segundo Gonzalez e Woods (2002) a operação de limiarização, uma técnica de processamento ponto a ponto, consiste na definição de um limiar (T) de nível de cinza para binarização de uma imagem inicial $f(x, y)$. Acima deste limiar, é aplicado o valor igual a 1 - mais claro - e abaixo, valor igual a 0 - mais escuro - na imagem de saída $g(x, y)$, como apresentado abaixo:

$$g(x,y) = \begin{cases} 1, & \text{se } f(x,y) > T \\ 0, & \text{se } f(x,y) \leq T \end{cases}$$

Dentre essas técnicas, o método clássico de Otsu é bastante difundido; ele se baseia na variância entre classes do histograma (objeto e fundo), maximizando a variância entre classes e minimizando a variância dentro das classes, sendo indicado para imagens que possuam distribuições bimodais bem definidas (OTSU, 1979). Outra técnica, que apresenta a vantagem de ser menos sensível aos ruídos na imagem, é o método de limiarização de Li (LI; LEE, 1993). Ele se baseia na técnica da redução da entropia cruzada - medida estatística de divergência entre distribuições de frequência - entre a imagem original e a imagem binarizada, estabelecendo inicialmente um limiar T_{old} , baseado na média dos *pixels* da imagem. A seguir, o algoritmo determina um novo limiar T_{new} , calculando os logaritmos naturais das médias dos *pixels* do fundo e do objeto (sendo $\mu_a \leq T$ e $\mu_b > T$), conforme a equação abaixo 3.4, e são realizadas iterações até que a diferença entre T_{new} e T_{old} seja muito pequena, ocorrendo a convergência, e assim é determinado o limiar ideal nas imagens.

$$T_{new} = \left\lfloor \frac{\mu_b - \mu_a}{\ln \mu_b - \ln \mu_a} \right\rfloor \quad (3.4)$$

onde:

- μ_a = média de intensidade dos *pixels* do fundo;
- μ_b = média de intensidade dos *pixels* do objeto.

Na fase de detecção e segmentação, existe a técnica de segmentação por crescimento de região, que procede com uma análise baseada em um critério pré-determinado, como intensidade ou cor de um conjunto de *pixels* iniciais escolhidos, e a partir desse parâmetro é realizada a varredura na imagem buscando identificar os *pixels* vizinhos aos pontos iniciais definidos que possuam as mesmas características e os adicionando à região, prosseguindo com a análise nos próximos *pixels* vizinhos, realizando essa operação até quando o critério continuar atendido nos *pixels* conectados à região (GONZALEZ; WOODS, 2009).

O aprendizado de máquina, um ramo da inteligência artificial, é voltado para o reconhecimento de padrões e para o desenvolvimento de sistemas capazes de aprender com dados prévios. Por meio do uso de redes neurais, os algoritmos são treinados com conjuntos de dados, tornando-se aptos a realizar inferências. Entre suas principais vantagens está a capacidade de melhorar continuamente o desempenho à medida que são expostos a dados mais extensos e variados. Essa forma de aprendizado pode ser dividida em três categorias principais: supervisionado, não supervisionado e por reforço (SWAMYNATHAN, 2019).

O aprendizado profundo é um subcampo do aprendizado de máquina que emprega algoritmos avançados com a finalidade de expandir a capacidade das máquinas, permitindo que seu desempenho se aproxime do comportamento cognitivo humano. Essa técnica tem sido muito utilizada para solucionar desafios nas áreas de visão computacional, processamento de sinais sonoros e análise de textos (SWAMYNATHAN, 2019). As *redes neurais convolucionais* (CNNs) representam um dos principais exemplos dessa abordagem, sendo amplamente utilizadas em processos de classificação de imagens pela sua eficiência. Dentre os modelos mais sofisticados, destacam-se as *redes neurais convolucionais profundas* (DCNNs), reconhecidas atualmente como a principal referência em aplicações de visão computacional (FRACAROLLI et al., 2020).


Dentre os trabalhos utilizando visão computacional na agricultura, temos, como exemplos, aplicações em: classificação de tomate (LIU et al., 2019); classificação de café robusta (COSTA et al., 2020); contagem e colheita de frutos no campo (CHITHRA; HENILA, 2021); identificação de doenças em plantas (ASHOK et al., 2020) e defeitos e doenças em frutos (ATHIRAJA; VIJAYAKUMAR, 2021).

3.3.1 Transformada de Hough

Foi desenvolvida por Paul Hough em 1962 para detecção de linhas em imagens binarizadas; posteriormente, foi aplicada também para encontrar círculos, elipses e outras formas geométricas que possam ser parametrizadas. A Transformada de Hough detecta pontos na imagem, mesmo contendo ruídos e descontinuidades, traça uma reta para cada ponto e os representa em um espaço de parâmetros discretizado, denominado espaço (ou acumulador) de Hough. (NETO; GONZAGA, 2012).

Para a detecção da elipse utilizando a Transformada de Hough é necessário determinar cinco parâmetros que definem a elipse, como pode ser observado na Figura 3.7.

Figura 3.7 – Representação da elipse.



Fonte: (CONCI, 2015).

Abaixo é apresentada a fórmula da elipse (3.5) para qualquer posição, sendo (x_0, y_0) as coordenadas; a e b o eixo maior e menor da elipse e α a inclinação em relação ao eixo x .

$$\frac{(x_0 \cos \alpha + y_0 \sin \alpha)^2}{a^2} + \frac{(x_0 \sin \alpha - y_0 \cos \alpha)^2}{b^2} = 1 \quad (3.5)$$

A determinação de cinco parâmetros na Transformada de Hough - um acumulador de cinco dimensões - é computacionalmente impraticável, portanto, são definidas algumas estratégias e restrições, como decompor esse espaço penta-dimensional em subespaços de menores dimensões, para assim poder calcular as elipses.

Yonghong e Qiang (2002) desenvolveram um método que estipula um tamanho para o eixo maior da elipse, e para cada par de *pixels* (x_1, y_1) e (x_2, y_2) candidatos a vértices do eixo

maior, são determinados os outros parâmetros por meio das seguintes equações: o centro da elipse (3.6, 3.7); metade do comprimento do eixo maior (3.8) e a inclinação (3.9).

$$x_0 = \frac{(x_1 + x_2)}{2} \quad (3.6)$$


$$y_0 = \frac{(y_1 + y_2)}{2} \quad (3.7)$$

$$a = \frac{[(x_2 - x_1)^2 + (y_2 - y_1)^2]^{1/2}}{2} \quad (3.8)$$

$$\alpha = \arctan \left[\frac{(y_2 - y_1)}{(x_2 - x_1)} \right] \quad (3.9)$$

Para calcular o parâmetro restante - eixo menor da elipse - é utilizado outro ponto (x, y) , que pode ser observado na Figura 3.8.

Figura 3.8 – Geometria da elipse.



Fonte: (YONGHONG; QIANG, 2002).

Esse ponto deve seguir algumas restrições, como a distância entre (x, y) e (x_0, y_0) ser menor que a distância entre (x_1, y_1) e (x_0, y_0) ou entre (x_2, y_2) e (x_0, y_0) . Assim, é calculada a metade do comprimento do eixo menor da elipse pela equação:


$$b^2 = \frac{(a^2 d^2 \sin^2 \tau)}{(a^2 - d^2 \cos^2 \tau)} \quad (3.10)$$

Sendo $\cos \tau$ dado pela seguinte equação:

$$\cos\tau = \frac{(a^2 + d^2 - f^2)}{(2ad)} \quad (3.11)$$

Desse modo, calcula-se, para cada terceiro ponto (x,y) , a metade do comprimento do eixo menor da elipse e armazena os valores em acumulador unidimensional. Quando a contagem dos votos no acumulador atinge um máximo local, é determinado o valor do possível eixo menor. Após a identificação, o algoritmo sobrepõe a elipse detectada sobre a real. Na Figura 3.9 é apresentada a detecção de uma elipse. Por esse método requerer apenas um acumulador unidimensional e por não realizar cálculos complexos, economiza-se muita capacidade computacional, apresentando essas vantagens em relação aos outros métodos (YONGHONG; QIANG, 2002).

Figura 3.9 – Elipse detectada.



Fonte: (CONCI, 2015).

Khadanga e Jain (2020) utilizaram a Transformada de Hough Circular para a identificação e segmentação de copas de árvores, com o objetivo de quantificar o número de árvores em imagens aéreas, obtidas pelo Google Earth, nas bandas do espectro visível vermelho, verde e azul (RGB). Na metodologia, foi utilizado o índice de reflectância espectral GRVI (*Green-Red Vegetation Index*) para definir um limiar e realçar as áreas com cobertura vegetal e, posteriormente, aplicar a Transformada de Hough para detectar as copas, que nas imagens aéreas aproximam-se de formas circulares. As rotinas foram implementadas utilizando o MATLAB, onde foram extraídas as médias das bandas espectrais vermelho, verde e azul dos objetos encon-

trados e suas características geométricas, como área, perímetro e circularidade. Como critério auxiliar para classificação das copas reais, foi utilizado o parâmetro da circularidade, sendo que valores abaixo de 0,29 eram excluídos da contagem. Na análise de imagens realizada em dois cenários: bairro residencial e em campo agrícola, o algoritmo conseguiu identificar corretamente 81% e 95% das copas, respectivamente, indicando uma boa acurácia dos resultados.

Fukada et al. (2023) em seu trabalho para estimar o crescimento de tomates (caules, cachos de flores e pontos de crescimento do tomateiro), desenvolveram um dispositivo para a captura de imagens das plantas, utilizando um Raspberry Pi com o acoplamento de uma câmera e servomotores para movimentação e detecção das imagens em diferentes ângulos; e para o processamento das imagens e extração dos parâmetros, foi utilizada a rede neural convolucional YOLOv5. Na etapa seguinte do processamento, foi utilizada a Transformada de Hough para a detecção de esferas utilizadas no tomateiro como unidades de referência de medida e, assim, converter os parâmetros do crescimento da planta (em *pixels*) para unidade métrica. O sistema desenvolvido conseguiu calcular o diâmetro do caule com um erro menor que 10% e reduziu o tempo de medição tradicional dos parâmetros (medidos no paquímetro) em 80%.

4 MATERIAIS E MÉTODOS

Para a aplicação das técnicas de visão computacional, foram utilizadas 229 imagens do *biospeckle laser* de sementes de soja, obtidas no ano de 2023 no âmbito do trabalho de VICENTINI et al. (2024), que foi desenvolvido no Centro de Desenvolvimento de Instrumentação Aplicada à Agricultura - CEDIA, da Universidade Federal de Lavras - UFLA.

4.1 *Biospeckle Laser*

Foi realizado um teste com o objetivo de demonstrar que o nível da atividade biológica medida pelo *biospeckle* varia espacialmente, conforme a região analisada da semente. Para tanto, foram analisadas duas sementes com características geométricas e níveis de atividade biológica semelhantes, dispostas espacialmente com uma diferença de 5° (semente **a** = 153° e semente **b** = 158°) e definida a mesma coordenada em ambas as imagens para a leitura da atividade biológica na região do eixo embrionário da semente. Para a realização do teste, foram empregados os métodos gráfico (GAVD) e numérico (AVD), onde foram processadas 64 imagens de cada semente, utilizando a plataforma *online Biospeckle Laser on Clouds* (BRAGA; GODINHO, 2023).

4.2 Processamento das imagens

As imagens foram processadas no *software* ImageJ® (IMAGEJ, 2023), por ser uma plataforma versátil, de fácil visualização das instruções adotadas e amplamente utilizada no campo da visão computacional. Nas seções abaixo, são apresentadas as técnicas utilizadas em cada etapa de processamento das imagens.

4.2.1 Suavização Gaussiana

Foi aplicado um filtro de suavização gaussiana no pré-processamento do conjunto das imagens obtidas do *biospeckle*. Foi selecionado o valor do parâmetro de desvio padrão $\sigma = 3$.

4.2.2 Limiarização

Foram avaliadas diferentes técnicas de limiarização (Padrão, Huang, IJ_IsoData, Intermodos, IsoData, Li, Média, Erro Mínimo, Mínimo, Momentos, Otsu, Percentil, Entropia de

Rényi e Triângulo) com o objetivo de encontrar aquela que apresentasse o melhor resultado na binarização do conjunto de imagens do *biospeckle laser*, capaz de identificar adequadamente o formato das sementes. Após a definição da técnica empregada, ela foi aplicada em todas as imagens.

4.2.3 Segmentação por crescimento de região

Após a aplicação do algoritmo de limiarização, com as imagens binarizadas e os *pixels* que compreendem a região da semente destacados na imagem, foi empregada a técnica da segmentação por crescimento de região. Para o início da varredura do algoritmo, foi utilizado, como critério inicial, o *pixel* com nível de cinza igual a 255 pertencente à área da semente, fixando o ponto central da imagem como coordenada.

4.2.4 Transformada de Hough

Foi implementada a Transformada de Hough, por meio de um teste em objetos de geometria conhecida para verificar sua habilidade para fazer o ajuste de uma elipse adequadamente em diferentes situações e analisar a robustez da técnica. No ImageJ, foram geradas uma elipse e um retângulo ideais, em imagens binarizadas, que foram rotacionados em ângulos conhecidos de 0°, 15°, 30°, 45°, 60°, 75° e 90°, e analisada a precisão com que a técnica foi capaz de detectar os ângulos de inclinação (α) das elipses encontradas nas diferentes situações. Após o teste com os objetos conhecidos, foi aplicada a Transformada de Hough nas imagens do *biospeckle* de sementes de soja, implementada por meio de uma macro.

4.2.5 Determinação dos ângulos reais das sementes

Para a determinação da orientação espacial das sementes de soja nas imagens do *biospeckle laser*, foi utilizado um goniômetro digital *online* (GINIFAB, n.d.). Foi realizada a medição do ângulo real (°) em que estavam dispostas as 229 sementes nas imagens analisadas, e utilizado o eixo maior da semente como referência para a medida.

4.2.6 Implementação da Macro

Foi desenvolvida, no ImageJ, uma macro destinada à implementação dos algoritmos de visão computacional para a detecção automática da orientação espacial das sementes. A macro

implementada foi organizada em 4 etapas principais. Na primeira delas, foi realizada a configuração inicial, onde foram definidos os caminhos das pastas e diretórios. Na segunda etapa, devido ao fato do ImageJ realizar a leitura dos arquivos como *strings*, em formato alfanumérico (*AM1.bmp*, *AM10.bmp*, *AM100.bmp...*), foi realizada uma ordenação numérica para a leitura sequencial correta das imagens (*AM1.bmp*, *AM2.bmp*, *AM3.bmp...*). Na sequência, foi realizado o processamento principal, com a implementação dos algoritmos de visão computacional; em conjunto, foi aplicada a função *Batch mode* para desativar as atualizações gráficas durante o processamento das imagens para obter ganho operacional e foi aplicado redimensionamento de 30% no canvas. Foi implementada uma condicional que, caso ocorresse algum problema na detecção da semente durante a etapa de segmentação ou ajuste da elipse, uma mensagem de erro informa qual imagem teve problema. Durante o processamento das imagens, um *Log* apresentou os ângulos calculados e indicou quando o processamento foi concluído. Por fim, foram salvas as elipses detectadas nas imagens processadas (em formato Bitmap) e os resultados foram exportados no formato CSV. Na Tabela 4.1 estão listadas as instruções implementadas na macro.

Tabela 4.1 – Procedimentos utilizados na detecção da orientação espacial das sementes

Sequência de procedimentos executados pela macro

- 1: Define diretório de entrada das imagens e pasta de saída.
- 2: Cria pasta de saída, caso não exista.
- 3: Lista arquivos do diretório de entrada.
- 4: Ordena arquivos numericamente pelo índice extraído do nome.
- 5: Ativa processamento em lote (batch mode).
- 6: **for** cada imagem do conjunto **do**
- 7: Abre imagem.
- 8: Aplica filtro Gaussiano ($\sigma = 3$).
- 9: Aplica algoritmo de limiarização.
- 10: Converte em máscara binária.
- 11: Redimensiona área do *canvas*.
- 12: Aplica algoritmo de segmentação.
- 13: **if** nenhum objeto for encontrado **then**
- 14: Salva imagem com erro e passa para a próxima.
- 15: **end if**
- 16: Aplica a Transformada de Hough.
- 17: Mede parâmetros da elipse detectada.
- 18: Desenha a elipse encontrada.
- 19: Salva imagem processada e resultados.
- 20: **end for**
- 21: Exporta resultados finais para arquivo CSV.
- 22: Encerra o processamento.

Fonte: elaboração própria.

4.2.7 Validação da metodologia

Foi detectado o erro médio (equação 4.1) entre os ângulos reais das sementes - medidos no goniômetro digital - e aqueles encontrados pela técnica desenvolvida. Foi realizado também um teste para determinar a sensibilidade da técnica à rotação das sementes, realizando, no ImageJ, pequenas rotações (1° , $0,1^\circ$, $0,01^\circ$, ...) nas imagens originais do *biospeckle* e verificando até qual valor de rotação mínima a técnica foi capaz de medir a diferença na orientação espacial das sementes.

$$Em(\%) = \frac{1}{N} \sum_{i=1}^N \left(\frac{|\alpha_i^{\text{real}} - \alpha_i^{\text{Hough}}|}{\alpha_i^{\text{real}}} \right) \times 100 \quad (4.1)$$

onde:

- N = número total de sementes;
- α_i^{real} = ângulo i -ésimo medido pelo goniômetro;


- α_i^{Hough} = ângulo i -ésimo determinado pela Transformada de Hough.

5 RESULTADOS E DISCUSSÃO

5.1 Análise da atividade do *biospeckle laser*

Os resultados numéricos medidos pelo método do AVD foram: semente **a** = 23,33 e semente **b** = 19,29 (adimensional), como pode ser observado na Figura 5.1. Deste modo, ficou demonstrado que o nível da atividade biológica medida pelo *biospeckle* varia espacialmente nas sementes e, portanto, sementes em diferentes orientações espaciais podem apresentar diferenças na atividade medida. Cabe salientar que se tratam de sementes distintas, ainda que com características geométricas e níveis de atividade biológica semelhantes, admitindo-se que diferenças intrínsecas entre elas possam contribuir para a variação observada nos valores de atividade mensurada na região analisada. Ainda assim, os resultados reforçam que o padrão de atividade biológica captado pelo *biospeckle* apresenta variação espacial nas sementes. Isso denota a importância da determinação da orientação espacial das sementes no desenvolvimento de sistemas para análises autônomas da atividade do *biospeckle laser*, definindo com precisão o ângulo das sementes para proceder com a leitura na região de interesse.

Figura 5.1 – Resultado das análises gráfica (GAVD) e numérica (AVD) em duas sementes com diferentes orientações espaciais.




Fonte: elaboração própria.

5.2 Aplicação do filtro gaussiano

O filtro gaussiano implementado com o desvio padrão $\sigma = 3$ foi adequado para filtrar as pequenas mudanças de intensidade dos níveis de cinza das imagens, conseguindo reduzir o ruído nas imagens monocromáticas obtidas do *biospeckle laser*, suavizando-as, conforme pode ser observado na Figura 5.2 e possibilitou, na sequência, a aplicação do algoritmo de binarização de maneira mais efetiva.

Figura 5.2 – (a) Imagem original e (b) após aplicação de filtro gaussiano.




Fonte: elaboração própria.

5.3 Aplicação dos algoritmos de limiarização

Os resultados obtidos pelos métodos de Otsu (**a**) e de Li (**b**) são apresentados na Figura 5.3, com os resultados gráficos da limiarização sobrepostos, em vermelho, às imagens das sementes.

Figura 5.3 – (a) Aplicação do método de Otsu. (b) Aplicação do método de Li.




Fonte: elaboração própria.

Como o conjunto de imagens do *biospeckle laser* apresentou uma sobreposição das classes do histograma, o limiar encontrado pelo método de Otsu ($T = 47$) não conseguiu separar corretamente as duas regiões, resultando na perda de parte da informação do objeto, em especial a região inferior do cotilédone da semente. Já o método de Li é mais robusto para distribuições complexas de classes de histograma (LI; LEE, 1993), portanto, mesmo havendo sobreposição das classes, ele obteve um bom resultado na binarização da semente, encontrando o limiar ($T = 29$) que separou corretamente as classes do histograma, gerando uma máscara adequada sobre toda a região da semente. Desse modo, o método de Li foi selecionado como padrão no proces-

samento das imagens.

Na Figura 5.4 é apresentado o resultado da binarização pelo método de Li, que encontrou o limiar $T = 41$ na imagem de 256 níveis de cinza da semente de soja obtida via *biospeckle laser*.

Figura 5.4 – (a) Imagem monocromática (8 bits) da semente de soja obtida via *biospeckle laser* com aplicação de filtro gaussiano. (b) Aplicação da limiarização pelo método de Li.




Fonte: elaboração própria.

5.4 Aplicação do algoritmo de segmentação por crescimento de região

O resultado da aplicação da técnica pode ser observado na Figura 5.5.

Figura 5.5 – Aplicação da técnica de segmentação por crescimento de região na semente de soja obtida via *biospeckle laser*, com as bordas identificadas em amarelo.




Fonte: elaboração própria.

O algoritmo conseguiu separar adequadamente a região binarizada do restante da imagem, com os *pixels* pertencentes à região segmentados e identificadas as bordas, que forneceram as delimitações para prosseguir com a aplicação da Transformada de Hough na detecção da elipse que melhor se ajusta ao formato das sementes. A qualidade desta segmentação ficou diretamente relacionada à qualidade da limiarização na etapa anterior, com as bordas coincidindo com as delimitações da região binarizada da semente.

5.5 Teste em objetos conhecidos

O resultado gráfico do teste é apresentado na Figura 5.6, com a inserção do goniômetro digital (GINIFAB), indicando a orientação do objeto conhecido e, em sequência, o resultado após a aplicação da Transformada de Hough, com a elipse detectada sobreposta à figura original.

Figura 5.6 – Objetos rotacionados (a; b) e as elipses detectadas sobrepostas às figuras iniciais (c; d).



Fonte: elaboração própria.

Na Tabela 5.1, são apresentados os resultados dos parâmetros das elipses detectadas pela Transformada de Hough. A primeira coluna corresponde aos ângulos de rotação aplicados às elipses, enquanto a última coluna apresenta os ângulos de inclinação (α) detectados. As demais colunas apresentam, respectivamente: a área da elipse detectada, em *pixels* quadrados (px^2); as coordenadas do centro da elipse (X e Y), em *pixels* (px); e os comprimentos dos eixos maior e menor da elipse, em *pixels* (px).


Tabela 5.1 – Resultados dos parâmetros das elipses detectadas pela Transformada de Hough.

Rotação (°)	Área (px^2)	X (px)	Y (px)	Maior (px)	Menor (px)	Ângulo Detectado (°)
0	49.988	253,000	239,000	357,660	177,953	0,000
15	49.393	248,720	240,337	355,988	176,661	15,000
30	49.441	244,889	242,789	356,241	176,707	30,007
45	49.448	241,835	246,142	356,204	176,751	44,997
60	49.447	239,765	250,071	356,233	176,732	59,992
75	49.445	238,815	254,475	356,254	176,715	74,982
90	49.988	239,000	259,000	357,660	177,953	90,000

Fonte: elaboração própria.

O resultado gráfico do teste com o retângulo é apresentado na Figura 5.7 e na Tabela 5.2 são apresentados os resultados dos parâmetros das elipses detectadas pela Transformada de Hough.

Figura 5.7 – Retângulos rotacionados (a; b) e as elipses detectadas sobrepostas às figuras iniciais (c; d).



Fonte: elaboração própria.

Tabela 5.2 – Resultados dos parâmetros das elipses detectadas pela Transformada de Hough.

Rotação (°)	Área (px ²)	X (px)	Y (px)	Maior (px)	Menor (px)	Ângulo Detectado (°)
0	49.856	252,000	225,000	351,846	180,416	0,000
15	49.399	244,103	227,096	350,673	179,360	15,012
30	49.390	237,038	231,151	350,658	179,335	30,001
45	49.432	231,244	236,756	350,930	179,349	45,000
60	49.386	227,138	243,966	350,651	179,324	60,000
75	49.392	225,008	251,848	350,704	179,319	74,987
90	49.856	225,000	260,000	351,846	180,416	90,000

Fonte: elaboração própria.


Ficou demonstrado que a Transformada de Hough foi capaz de ajustar adequadamente uma elipse sobre os diferentes objetos analisados, em todas as orientações espaciais em que

foram dispostos, encontrando os ângulos de inclinação (α) das elipses com elevada precisão em relação aos ângulos dos objetos rotacionados, demonstrando, assim, a robustez da técnica na detecção da orientação espacial dos objetos.

5.6 Determinação dos ângulos reais das sementes

Os resultados da medição dos ângulos em que estavam dispostas as sementes, utilizando o goniômetro digital (GINIFAB), ficaram sujeitos à subjetividade do observador na definição dos pontos de análise para a determinação do eixo maior das sementes e também do limite de resolução da ferramenta. Na Figura 5.8 são apresentados os resultados dos ângulos medidos.

Figura 5.8 – Medição dos ângulos em que as sementes iluminadas pelo *biospeckle laser* estavam dispostas.



Fonte: elaboração própria.


5.7 Macro desenvolvida com a aplicação da Transformada de Hough

A macro desenvolvida conseguiu automatizar e padronizar as análises, garantindo maior reprodutibilidade dos resultados, possibilitando que as mesmas instruções fossem aplicadas ao conjunto de imagens, otimizando o processamento. O código completo encontra-se no apêndice

A função *Batch mode* para desativar as atualizações gráficas durante o processamento das imagens proporcionou maior eficiência computacional, processando rapidamente o conjunto de imagens ($\approx 0,18$ s por imagem). Após a implementação do algoritmo de limiarização, o redimensionamento de 30% no canvas evitou perdas de informação nas imagens, devido ao

fato de que algumas sementes tinham dimensões maiores e não ficaram totalmente enquadradas durante a captura das imagens, resultando em cortes na região dos cotilédones. Com essa ampliação, evitou-se que a detecção da elipse pela Transformada de Hough sobre a região de interesse ficasse restrita à dimensão original da imagem, como pode ser observado na Figura 5.9.


Figura 5.9 – Redimensionamento de 30% no tamanho do canvas para a detecção adequada da elipse sobre a região de interesse.



Fonte: elaboração própria.

O resultado final das técnicas aplicadas na determinação da orientação espacial das sementes de soja nas imagens do *biospeckle laser* pode ser observado na Figura 5.10, com a elipse detectada pela Transformada de Hough sobreposta à semente segmentada.

Figura 5.10 – (a; c) Imagens do *biospeckle laser* de sementes de soja; (b; d) Elipses detectadas pela técnica aplicada nas imagens processadas.



Fonte: elaboração própria.

Na primeira semente (Figura 5.10a, com o respectivo resultado apresentado na Figura 5.10b), é possível verificar a precisão na detecção da técnica, com a elipse ajustada coincidindo com a região da semente e encontrando o mesmo ângulo que o medido pelo goniômetro digital (121°), sendo a diferença nas casas decimais em virtude do limite de resolução do goniômetro. Na segunda semente (Figura 5.10c, com o resultado apresentado na Figura 5.10d), ficou demonstrado que a Transformada de Hough detecta a elipse que melhor se ajusta à região segmentada, englobando parte da região do eixo embrionário da semente, o que resultou em uma pequena diferença entre o ângulo medido no goniômetro (147,00°) e aquele encontrado pela técnica (142,93°).

Na Tabela 5.3 são apresentados os resultados gerados pela macro dos parâmetros das elipses detectadas pela técnica durante o processamento das imagens. Na primeira coluna está a respectiva imagem processada e na última coluna estão os ângulos de inclinação (α) das

elipses detectadas. No apêndice estão os resultados de todos os ângulos obtidos pela técnica desenvolvida e os ângulos de referência, medidos no goniômetro digital.

Tabela 5.3 – Resultados dos parâmetros das elipses detectadas pela técnica aplicada nas imagens do *biospeckle laser* de sementes de soja.

Imagem	Área (px ²)	X	Y	Maior (px)	Menor (px)	Ângulo Detectado (°)
AM1.bmp	104.585	437,493	310,916	424,103	313,985	108,361
AM2.bmp	90.873	457,574	326,614	412,433	280,538	128,474
AM3.bmp	110.316	461,270	340,258	496,582	282,851	130,736
AM4.bmp	119.435	431,887	342,479	482,885	314,918	120,141
AM5.bmp	111.531	443,597	342,406	490,989	289,224	123,116
⋮	⋮	⋮	⋮	⋮	⋮	⋮
AM225.bmp	101.349	452,432	310,236	470,829	274,073	135,951
AM226.bmp	117.304	447,711	313,427	471,487	316,777	129,032
AM227.bmp	100.865	421,557	328,755	410,560	312,805	142,765
AM228.bmp	94.593	425,000	349,188	407,107	295,843	151,698
AM229.bmp	101.033	418,421	318,967	402,734	319,415	144,676

Fonte: elaboração própria.

5.7.1 Validação da metodologia

O ângulo real médio das 229 sementes, medido pelo goniômetro digital, foi de 145,72° e o ângulo médio encontrado pela técnica desenvolvida foi de 137,43°, sendo o erro médio de 5,65% (apêndice). Este erro médio foi obtido utilizando, na etapa de limiarização, o filtro de Li, que obteve o melhor resultado. Na Tabela 5.4 constam também os erros médios encontrados utilizando outros filtros de limiarização.


Tabela 5.4 – Comparação dos métodos de limiarização aplicados na determinação do ângulo de inclinação das sementes.

Filtros de Limiarização	Ângulo Médio Obtido	Erro médio (%)
Goniômetro (referência)	145,72°	–
Li	137,43°	5,65%
Triângulo	136,99°	5,97%
Huang	136,88°	6,03%
Mínimo	136,79°	6,08%
Média	135,74°	6,79%
Otsu	135,29°	7,17%
IsoData	135,28°	7,18%
Padrão	135,24°	7,21%
IJ_IsoData	135,24°	7,21%
Erro Mínimo	134,88°	7,39%
Intermodos	134,50°	7,62%
Momentos	131,56°	9,83%
Percentil	126,89°	12,86%
Entropia de Rényi	118,26°	19,23%

Fonte: elaboração própria.

Na Figura 5.11 é apresentado o boxplot da distribuição do erro percentual. Observa-se que os erros apresentaram distribuição predominantemente concentrada entre 3,79% (Q1) e 7,30% (Q3), com mediana de 5,38%. O intervalo interquartil (IQR) de 3,51% demonstra uma dispersão moderada entre os quartis, o que indicou uma boa consistência nos resultados obtidos. O limite inferior foi de 0,04% e o limite superior de 11,5%. O maior valor de *outlier* encontrado foi de 16,16%. Esse comportamento demonstra que a maioria da amostra apresentou erros baixos e próximos entre si, com poucos casos de erro mais elevado. Assim, a técnica demonstrou boa estabilidade e reprodutibilidade.


Figura 5.11 – Boxplot do erro percentual entre o goniômetro e a técnica desenvolvida (n = 229 sementes).



Fonte: elaboração própria.

Uma fonte de erro observada (*outliers*) foi associada às sementes que apresentam alguma região sub-iluminada, como observado na Figura 5.12a, com o respectivo resultado apresentado na Figura 5.12b, na porção inferior do cotilédone. Nessas situações, o filtro de limiarização não conseguiu separar adequadamente a semente do fundo da imagem, resultando na perda de informação na etapa de segmentação. Consequentemente, a região segmentada apresentou uma conformação distinta, e a elipse ajustada pela Transformada de Hough — que utiliza as bordas dessa região como referência — identificou uma orientação espacial diferente da real, gerando um erro de 16,16%. Outra fonte de erro foi verificada em sementes com formato mais irregular ou assimétrico e naquelas em que a radícula se encontrava muito afastada dos cotilédones, conforme ilustrado na Figura 5.12c, com o resultado correspondente apresentado na Figura 5.12d. Como o algoritmo calcula a elipse que melhor se ajusta à região segmentada, ele englobou o cotilédone da semente e parte do eixo embrionário. Esse ajuste provocou uma diferença entre o ângulo calculado e o ângulo real, resultando em um erro de 10,25%.

Figura 5.12 – Principais fontes de erro na detecção da orientação espacial das sementes.



Fonte: elaboração própria.

No trabalho de Ghimire et al. (2023) sobre fenotipagem de sementes de soja utilizando técnicas de visão computacional em imagens RGB, foi encontrado um erro percentual de 4% em medições de área projetada das sementes. Assim, o erro médio de 5,65% observado no presente método situa-se dentro de uma faixa adequada para aplicações de visão computacional em sementes. Logo, pode-se inferir que o método alcançou uma precisão adequada e demonstra boa aplicabilidade para o contexto de análise de sementes.

Os resultados do teste que avaliou a sensibilidade da técnica à rotação das sementes são apresentados na Tabela 5.5. O método foi capaz de detectar pequenas rotações com precisão sub-grau, até o limite de 0,0026°, o que evidencia a robustez da técnica na determinação da

orientação espacial das sementes, mesmo diante de variações angulares mínimas.

Tabela 5.5 – Teste de sensibilidade da técnica à rotação das sementes.

Rotação (°)	Ângulo médio calculado (°)	Diferença (°)
Sem rotação	137,4300	0,0000
1,0000	136,4713	0,9587
0,1000	137,3349	0,1027
0,0100	137,4290	0,0119
0,0050	137,4306	0,0047
0,0040	137,4309	0,0039
0,0030	137,4293	0,0014
0,0029	137,4290	0,0011
0,0028	137,4290	0,0011
0,0027	137,4298	0,0002
0,0026	137,4299	0,0001
0,0025	137,4300	0,0000

Fonte: elaboração própria.

6 CONCLUSÃO

O presente trabalho atingiu os objetivos propostos, resultando no desenvolvimento de uma técnica eficiente para a segmentação e detecção da orientação espacial de sementes de soja iluminadas pelo *laser*.

A aplicação de técnicas de visão computacional mostrou-se eficaz para a identificação das regiões correspondentes às sementes nas imagens do *biospeckle laser*, fornecendo bases consistentes na etapa subsequente de análise geométrica.

A Transformada de Hough demonstrou-se uma ferramenta robusta para o ajuste de elipses, possibilitando, juntamente com a macro desenvolvida, a determinação da orientação espacial das sementes de forma automatizada. Os testes realizados com objetos de geometria conhecida confirmaram a precisão da técnica, e sua posterior aplicação em imagens do *biospeckle laser* de sementes de soja evidenciou a capacidade do algoritmo em lidar com formas naturais, ainda que apresentem variações morfológicas e regiões de menor iluminação.

O erro médio encontrado na detecção foi de 5,65%, um valor adequado para sistemas de visão computacional aplicados a sementes. A resolução da técnica foi de $0,0026^\circ$, o que demonstrou a alta sensibilidade do método. Esses resultados demonstram que a técnica desenvolvida é viável e confiável na análise da orientação espacial de sementes de soja em experimentos com o *biospeckle laser*.

Por fim, o método proposto representa um avanço na automação da análise de imagens do *biospeckle laser*, contribuindo para a redução do tempo de processamento e da subjetividade das avaliações manuais.

Como proposta para trabalhos futuros, sugere-se a integração de técnicas de reconhecimento de padrões à metodologia desenvolvida. Assim, uma vez conhecida a orientação espacial das sementes, o sistema poderia realizar o reconhecimento automático entre a semente analisada e o modelo de referência, considerando sua posição real na imagem. Essa abordagem permitiria uma interpretação mais precisa da atividade do *biospeckle*, evitando leituras incorretas de sementes rebatidas ou invertidas. A combinação da detecção da orientação espacial e do reconhecimento de padrões poderá aprimorar a precisão e a robustez das análises automatizadas em experimentos futuros.

REFERÊNCIAS

- AIZU, Y.; ASAKURA, T. Bio-speckle application blood flow. **Optics & Laser Technology**, v. 23, n. 4, 1991.
- ARIZAGA, R.; TRIVI, M.; RABAL, H. Speckle time evolution characterization by the co-occurrence matrix analysis. **Optics and Laser Technology**, v. 31, n. 2, p. 163–169, 1999. ISSN 00303992.
- ASHOK, S. et al. Tomato leaf disease detection using deep learning techniques. **Proceedings of the 5th International Conference on Communication and Electronics Systems, ICCES 2020**, n. Icces, p. 979–983, 2020.
- ATHIRAJA, A.; VIJAYAKUMAR, P. Banana disease diagnosis using computer vision and machine learning methods. **Journal of Ambient Intelligence and Humanized Computing**, Springer Berlin Heidelberg, v. 12, n. 6, p. 6537–6556, 2021. ISSN 18685145. Disponível em: <<https://doi.org/10.1007/s12652-020-02273-8>>.
- BOTEGA, J. V. et al. Avaliação da interferência do laser no material biológico vivo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, 2009. ISSN 14154366.
- Braga Júnior, R. A. Quando o ruído tornou-se informação: O estado da arte do biospeckle laser. **Ciencia e Agrotecnologia**, v. 41, n. 4, p. 359–366, 2017. ISSN 19811829.
- Braga Júnior, R. A. et al. Magnetic field in coffee seed germination. **Ciencia e Agrotecnologia**, v. 44, p. 1–10, 2020. ISSN 19811829.
- Braga Junior, R. A.; RIVERA, F. P. **Bio-Speckle Laser Tool Library**. 2019. Disponível em: <<http://www.nongnu.org/bsltl/index.html>>. Acesso em: 05 abr. 2024.
- BRAGA, R.; GODINHO, R. **Biospeckle Laser On Clouds**. 2023. Disponível em: <https://www.bslonclouds.com/landing_analysis.php>. Acesso em: 08 fev. 2025.
- BRAGA, R. A. et al. Analysis of Seed Vigor Using the Biospeckle Laser Technique. **AgriEngineering**, v. 7, n. 1, p. 1–14, 2025. ISSN 26247402.
- BRAGA, R. A. et al. Live biospeckle laser imaging of root tissues. **European Biophysics Journal**, 2009. ISSN 01757571.
- BRAGA, R. A. et al. Evaluation of activity through dynamic laser speckle using the absolute value of the differences. **Optics Communications**, Elsevier B.V., v. 284, n. 2, p. 646–650, 2011. ISSN 00304018. Disponível em: <<http://dx.doi.org/10.1016/j.optcom.2010.09.064>>.
- BRAGA, R. A. J.; RIVERA, F. P.; MOREIRA, J. **A Practical Guide to Biospeckle Laser Analysis. Theory and Software**. [S.l.: s.n.], 2016. 160 p. ISSN 03635023. ISBN 0363-5023.
- BRASIL. **Regras para análise de sementes**. [S.l.: s.n.], 2009. 399 p. ISBN 9788599851708.
- CARVALHO, P. H. et al. Motility parameters assessment of bovine frozen semen by biospeckle laser (BSL) system. **Biosystems Engineering**, v. 102, n. 1, p. 31–35, 2009. ISSN 15375110.
- CAVERZAN, A. et al. How does seed vigor affect soybean yield components? **Agronomy Journal**, v. 110, n. 4, p. 1318–1327, 2018. ISSN 14350645.

CHITHRA, P.; HENILA, M. Apple fruit sorting using novel thresholding and area calculation algorithms. **Soft Computing**, Springer Berlin Heidelberg, v. 25, n. 1, p. 431–445, 2021. ISSN 14337479. Disponível em: <<https://doi.org/10.1007/s00500-020-05158-2>>.

CONAB. Acompanhamento da Safra Brasileira 2023/2024. **Companhia Nacional de Abastecimento (CONAB)**, v. 11, n. 2318 6852, p. 110, 2024. Disponível em: <<https://www.conab.gov.br/info-agro/safras/>>.

CONCI, A. **Reconhecimento de Padroes: Transformada de Hough**. 2015. 95 p. Disponível em: <<http://www.ic.uff.br/~aconci/aula-9-2015-AI.p>>.

CONTADO, J. L.; SILVA, C. D. F.; Braga Júnior, R. A. Biospeckle Laser To Monitor the Germination of Angico-Vermelho Seeds. **Theoretical and Applied Engineering**, v. 4, n. 4, p. 1–9, 2020.

COSTA, A. G. et al. Classification of robusta coffee fruits at different maturation stages using colorimetric characteristics. **Engenharia Agrícola**, v. 40, n. 4, p. 518–525, 2020. ISSN 18094430.

FRACAROLLI, J. A. et al. Computer vision applied to food and agricultural products. **Revista Ciencia Agronomica**, v. 51, n. 5, p. 1–20, 2020. ISSN 18066690.

FRANÇA NETO, J. D. B.; KRZYZANOWSKI, F. C. Metodologia do teste de tetrazólio em sementes de soja. **Embrapa Soja**, p. 108, 2018.

FUKADA, K. et al. An Automatic Tomato Growth Analysis System Using YOLO Transfer Learning. **Applied Sciences (Switzerland)**, v. 13, n. 12, 2023. ISSN 20763417.

GHIMIRE, A. et al. Automatic evaluation of soybean seed traits using rgb image data and a python algorithm. **Plants**, v. 12, n. 17, p. 3078, 2023.

GINIFAB. **Online Protractor: angle measuring tool**. n.d. Disponível em: <https://www.ginifab.com/feeds/angle_measurement/online_protractor.pt.php>. Acesso em: 03 mar. 2025.

GONZALEZ, R. C.; WOODS, R. E. **Digital image processing (2nd edition)**. [S.l.: s.n.], 2002. ISBN 0201180758.

GONZALEZ, R. C.; WOODS, R. E. **Processamento digital de imagem**. [S.l.: s.n.], 2009. v. 10. 624 p. ISSN 978-8576054016. ISBN 8576054019.

GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**. 4. ed. New York: Pearson, 2018.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. **IEEE Transactions on Systems, Man, and Cybernetics**, SMC-3, n. 6, p. 610–621, nov. 1973.

HENNING, F. A. et al. Chemical composition and reserve mobilization in soybean seeds with high and low vigor. **Bragantia**, v. 69, n. 3, p. 727–734, 2010. ISSN 16784499.

IMAGEJ. **ImageJ: image processing and analysis in Java**. Bethesda: U. S. National Institutes of Health, 2023. Disponível em: <<https://imagej.nih.gov/ij/>>. Acesso em: 04 abr. 2025.

KHADANGA, G.; JAIN, K. Tree Census Using Circular Hough Transform and GRVI. **Procedia Computer Science**, Elsevier B.V., v. 171, p. 389–394, 2020. ISSN 18770509. Disponível em: <<https://doi.org/10.1016/j.procs.2020.04.040>>.

KRZYŻANOWSKI, F. et al. Tecnologia da produção de semente de soja de alta qualidade. 2016. ISSN 2176-2937.

KRZYŻANOWSKI, F. C.; FRANÇA-NETO, J. d. B.; HENNING, A. A. **A alta qualidade da semente de soja: fator importante para a produção da cultura**. Londrina, PR, 2018. 24 p. (Circular Técnica, 136). Acesso aberto. Disponível em: <<http://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/1091765>>.

LARIOS, G. S. et al. Laser-Induced Breakdown Spectroscopy as a Powerful Tool for Distinguishing High- and Low-Vigor Soybean Seed Lots. **Food Analytical Methods**, Food Analytical Methods, v. 13, n. 9, p. 1691–1698, 2020. ISSN 1936976X.

LI, C. H.; LEE, C. K. Minimum cross entropy thresholding. **Pattern Recognition**, v. 26, n. 4, p. 617–625, 1993. ISSN 00313203.

LIU, L. et al. Design of a tomato classifier based on machine vision. **PLoS ONE**, v. 14, n. 7, 2019. ISSN 19326203.

MARCOS-FILHO, J. Seed vigor testing: An overview of the past, present and future perspective. **Scientia Agricola**, v. 72, n. 4, p. 363–374, 2015. ISSN 1678992X.

MEDEIROS, A. D. de et al. Computer Vision as a Complementary Method to Vigour Analysis in Maize Seeds. **Journal of Experimental Agriculture International**, v. 25, n. 5, p. 1–8, 2018.

MESHRAM, V. et al. Machine learning in agriculture domain: A state-of-art survey. **Artificial Intelligence in the Life Sciences**, Elsevier B.V., v. 1, n. October, p. 100010, 2021. ISSN 26673185. Disponível em: <<https://doi.org/10.1016/j.ailsci.2021.100010>>.

MILANO, D.; HONORATO, L. B. Visão computacional. p. 1–7, 2010. Disponível em: <http://www.ft.unicamp.br/liag/wp/monografias/monografias/2010{_}IA{_}FT{_}UNI>.

NETO, H. V.; GONZAGA, A. **Avanços em Visão Computacional**. [S.l.: s.n.], 2012. ISBN 9788564619098.

OTSU, N. A threshold selection method from gray-level histograms. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 9, n. 1, p. 62–66, 1979.

OYAMA, P. I. d. C. et al. Sistema para Classificação Automática de Café em Grãos por Cor e Forma Através de Imagens Digitais. **Avanços em Visão Computacional**, p. 119–140, 2012.

PANDISELVAM, R. et al. Biospeckle laser technique – A novel non-destructive approach for food quality and safety detection. **Trends in Food Science and Technology**, Elsevier, v. 97, n. June 2019, p. 1–13, 2020. ISSN 09242244. Disponível em: <<https://doi.org/10.1016/j.tifs.2019.12.028>>.

RAHMANIAN, A. et al. Application of biospeckle laser imaging for early detection of chilling and freezing disorders in orange. **Postharvest Biology and Technology**, Elsevier, v. 162, n. July 2019, p. 111118, 2020. ISSN 09255214. Disponível em: <<https://doi.org/10.1016/j.postharvbio.2020.111118>>.

RAJJOU, L. et al. Seed germination and vigor. **Annual Review of Plant Biology**, v. 63, p. 507–533, 2012. ISSN 15435008.

REIS, V. U. V. et al. Vigor of maize seeds and its effects on plant stand establishment, crop development and grain yield. **Journal of Seed Science**, v. 44, p. 1–12, 2022. ISSN 23171537.

SINGH, P. et al. Biospeckle-based sensor for characterization of charcoal rot (*Macrophomina phaseolina* (Tassi) goid) disease in soybean (*Glycine max* (L.) Merr.) crop. **IEEE Access**, v. 9, p. 31562–31574, 2021. ISSN 21693536.

SOUZA SOBRINHO, A. F. de. Avaliação da qualidade fisiológica de sementes de soja por meio do biospeckle laser. 2023. 45 p. Tese (Doutorado em Engenharia Agrícola)–Universidade Federal de Lavras, Lavras, 2023. **Tese (Doutorado em Engenharia Agrícola)–Universidade Federal de Lavras, Lavras, 2023.**, p. 45, 2023. Disponível em: <<http://repositorio.ufla.br/handle/1/57059>>.

SWAMYNATHAN, M. **Mastering Machine Learning with Python in Six Steps**. [S.l.: s.n.], 2019. ISBN 9781484249468.

TEKRONY, D. M. Accelerated aging test: Principles and procedures. **Seed Technology**, [Association of Official Seed Analysts, Society of Commercial Seed Technologists (SCST)], v. 27, n. 1, p. 135–146, 2005. ISSN 10960724. Disponível em: <<http://www.jstor.org/stable/23433228>>.

VICENTINI, B. et al. SISTEMA PORTÁTIL DO BIOSPECKLE LASER PARA ANÁLISE DE SEMENTES. p. 1–4, 2024. Disponível em: <<https://conbea.org.br/anais/publicacoes/conbea-2024/anais-2024/agricultura-digital-ad-3/3929-sistema-portatil-do-biospeckle-laser-para-analise-de-sementes/file>>.

VIVAS, P. G. et al. Biospeckle activity in coffee seeds is associated non-destructively with seedling quality. **Annals of Applied Biology**, 2017. ISSN 17447348.

XING, M. et al. Physiological Alterations and Nondestructive Test Methods of Crop Seed Vigor: A Comprehensive Review. **Agriculture (Switzerland)**, v. 13, n. 3, p. 1–25, 2023. ISSN 20770472.

XU, Z.; JOENATHAN, C.; KHORONA, B. M. K. Temporal and spatial properties of the time-varying speckles of botanical specimens. **Optical Engineering**, v. 34, n. 5, p. 1487, 1995. ISSN 0091-3286.

YONGHONG, X.; QIANG, J. A new efficient ellipse detection method. **Proceedings - International Conference on Pattern Recognition**, v. 16, n. 2, p. 957–960, 2002. ISSN 10514651.

YOUSSEF, D. et al. Biospeckle local contrast analysis for surface roughness study of articular cartilage. **Optik**, Elsevier, v. 183, n. December 2018, p. 55–64, 2019. ISSN 00304026. Disponível em: <<https://doi.org/10.1016/j.ijleo.2019.02.026>>.

APÊNDICE A

Código .1 – Macro desenvolvida no *ImageJ* para detecção automática da orientação espacial das sementes, com o código comentado e dividido em etapas.

```

1  // === CONFIGURAÇÃO INICIAL ===
2  path = "C:/Users/.../SEMENTES.BIOSPECKLE/";
3  outputPath = "C:/Users/.../RESULTADOS/";
4  File.makeDirectory(outputPath);
5  list = getFileList(path);
6  pi_val = 3.141592653589793;
7
8  // === ORDENAÇÃO NUMÉRICA DOS ARQUIVOS ===
9  n = list.length;
10 indexes = newArray(n);
11 numbers = newArray(n);
12
13 // Extrai o número de cada nome
14 for (i = 0; i < n; i++) {
15     name = list[i];
16     name = replace(name, "AM", "");
17     name = replace(name, ".bmp", "");
18     numbers[i] = parseInt(name);
19     indexes[i] = i;
20 }
21 // Ordena usando Bubble sort com base nos números
22 for (i = 0; i < n-1; i++) {
23     for (j = i+1; j < n; j++) {
24         if (numbers[i] > numbers[j]) {
25             // Troca números
26             tempNum = numbers[i];
27             numbers[i] = numbers[j];
28             numbers[j] = tempNum;
29             // Troca índices
30             tempIdx = indexes[i];
31             indexes[i] = indexes[j];

```

```

32         indexes[j] = tempIdx;
33     }
34 }
35 }
36
37 // === PROCESSAMENTO PRINCIPAL ===
38 setBatchMode(true); // Desativa atualizações gráficas
39 setOption("BlackBackground", true);
40 run("Clear Results");
41
42 // Processa na nova ordem
43 for (k = 0; k < n; k++) {
44     i = indexes[k];
45     filename = list[i];
46     open(path + filename);
47     title = getTitle();
48     print("\nProcessando: " + title);
49
50     // Pré-processamento da imagem
51     run("Gaussian Blur...", "sigma=3");
52     // Limiarização da imagem
53     setAutoThreshold("Li dark");
54     run("Convert to Mask");
55     // Redimensiona o tamanho do canvas em 30%
56     run("Canvas Size...", "width=832 height=624 position=Center");
57     // Segmentação por crescimento de região
58     doWand(416, 312);
59     if (selectionType() == -1) {
60         print(" Erro: Não foi possível selecionar objeto em " + title);
61         saveAs("BMP", outputPath + "ERRO_" + filename);
62         close();
63         continue;
64     }
65     // Transformada de Hough

```

```

66     run("Fit Ellipse");
67     run("Measure");
68     if (nResults() == 0) {
69         print(" Erro: Nenhuma medição obtida em " + title);
70         close(); continue; }
71
72     // Extrai dados da elipse
73     last = nResults() - 1;
74     x = getResult("X", last);
75     y = getResult("Y", last);
76     major = getResult("Major", last);
77     angle = getResult("Angle", last);
78     theta = -angle * pi_val / 180;
79     dx = (major / 2) * cos(theta);
80     dy = (major / 2) * sin(theta);
81     x1 = x - dx; y1 = y - dy;
82     x2 = x + dx; y2 = y + dy;
83
84     // Desenha elipse
85     setForegroundColor(128,128,128);
86     run("Draw");
87     // Desenha o eixo maior
88     makeLine(x1, y1, x2, y2);
89     run("Draw");
90     // Adiciona o nome da imagem à tabela de resultados
91     setResult("Imagem", last, title);
92     // Exibe o ângulo
93     angle = getResult("Angle", last);
94     print(" Ângulo calculado: " + angle);
95     //Salva imagem com elipse
96     saveAs("BMP", outputPath + filename);
97     close();
98 }
99

```

```
100 // === EXPORTAÇÃO DOS RESULTADOS ===  
101 selectWindow("Results");  
102 saveAs("Measurements", outputPath + "resultados.csv");  
103 setBatchMode(false);  
104 print("Processamento concluído!");
```

APÊNDICE B

Tabela .1 – Resultados dos erros médios entre os ângulos das sementes medidos pelo goniômetro e pela técnica desenvolvida.

Semente	Ângulo Goniômetro	Ângulo Obtido	Erro
1	119	108,361	8,94%
2	130	128,474	1,17%
3	138	130,736	5,26%
4	122	120,141	1,52%
5	132	123,116	6,73%
6	147	140,312	4,55%
7	138	127,965	7,27%
8	156	148,461	4,83%
9	153	135,487	11,45%
10	126	123,161	2,25%
11	160	147,242	7,97%
12	152	141,064	7,19%
13	130	124,953	3,88%
14	151	138,712	8,14%
15	143	134,223	6,14%
16	140	129,522	7,48%
17	157	133,033	15,27%
18	144	135,802	5,69%
19	133	126,45	4,92%
20	146	135,89	6,92%
21	150	128,598	14,27%
22	154	140,393	8,84%
23	131	125,414	4,26%
24	139	131,754	5,21%
25	151	145,571	3,60%
26	143	135,209	5,45%
27	147	135,652	7,72%
28	138	131,873	4,44%
29	153	137,325	10,25%

Continuação da Tabela de Resultados

Semente	Ângulo Goniômetro	Ângulo Obtido	Erro
30	158	144,916	8,28%
31	141	136,018	3,53%
32	147	138,787	5,59%
33	141	134,872	4,35%
34	150	142,374	5,08%
35	150	132,882	11,41%
36	152	131,305	13,62%
37	157	144,931	7,69%
38	157	131,63	16,16%
39	151	139,732	7,46%
40	138	127,449	7,65%
41	162	146,175	9,77%
42	169	153,5	9,17%
43	143	135,01	5,59%
44	154	134,11	12,92%
45	149	135,586	9,00%
46	134	128,951	3,77%
47	135	122,092	9,56%
48	155	142,225	8,24%
49	145	133,694	7,80%
50	146	133,558	8,52%
51	151	138,613	8,20%
52	153	133,601	12,68%
53	142	139,469	1,78%
54	136	120,76	11,21%
55	138	130,935	5,12%
56	140	135,979	2,87%
57	144	133,156	7,53%
58	144	138,144	4,07%
59	152	139,452	8,26%
60	151	139,09	7,89%
61	156	141,498	9,30%

Continuação da Tabela de Resultados

Semente	Ângulo Goniômetro	Ângulo Obtido	Erro
62	151	137,207	9,13%
63	140	134,233	4,12%
64	136	129,779	4,57%
65	150	141,709	5,53%
66	145	136,943	5,56%
67	143	134,079	6,24%
68	147	141,985	3,41%
69	153	139,395	8,89%
70	150	143,967	4,02%
71	154	144,498	6,17%
72	152	139,364	8,31%
73	152	141,908	6,64%
74	144	136,215	5,41%
75	157	150,879	3,90%
76	153	141,854	7,28%
77	151	144,297	4,44%
78	149	141,367	5,12%
79	161	151,621	5,83%
80	145	136,199	6,07%
81	136	132,91	2,27%
82	161	152,283	5,41%
83	151	138,72	8,13%
84	146	139,818	4,23%
85	152	139,212	8,41%
86	140	136,928	2,19%
87	149	141,931	4,74%
88	153	144,606	5,49%
89	150	132,795	11,47%
90	143	140,083	2,04%
91	162	147,048	9,23%
92	146	137,805	5,61%
93	148	139,806	5,54%

Continuação da Tabela de Resultados

Semente	Ângulo Goniômetro	Ângulo Obtido	Erro
94	142	127,782	10,01%
95	133	125,286	5,80%
96	137	134,123	2,10%
97	143	133,397	6,72%
98	136	127,868	5,98%
99	129	120,155	6,86%
100	139	135,698	2,38%
101	138	134,043	2,87%
102	134	129,316	3,50%
103	137	128,855	5,95%
104	150	143,604	4,26%
105	155	138,963	10,35%
106	141	134,09	4,90%
107	154	145,644	5,43%
108	139	133,365	4,05%
109	149	139,501	6,38%
110	141	135,396	3,97%
111	141	133,505	5,32%
112	142	135,747	4,40%
113	145	139,484	3,80%
114	147	136,136	7,39%
115	147	141,672	3,62%
116	146	134,5	7,88%
117	150	142,64	4,91%
118	144	140,208	2,63%
119	139	132,217	4,88%
120	154	143,464	6,84%
121	155	143,73	7,27%
122	150	146,035	2,64%
123	148	147,787	0,14%
124	147	137,392	6,54%
125	148	143,479	3,05%

Continuação da Tabela de Resultados

Semente	Ângulo Goniômetro	Ângulo Obtido	Erro
126	142	135,946	4,26%
127	143	137,711	3,70%
128	157	146,032	6,99%
129	153	147,442	3,63%
130	152	138,508	8,88%
131	156	139,282	10,72%
132	158	150,59	4,69%
133	144	139,128	3,38%
134	151	142,496	5,63%
135	143	139,51	2,44%
136	155	150,725	2,76%
137	149	141,64	4,94%
138	138	133,911	2,96%
139	144	138,545	3,79%
140	147	141,354	3,84%
141	152	143,109	5,85%
142	133	129,034	2,98%
143	133	125,182	5,88%
144	142	132,977	6,35%
145	145	138,335	4,60%
146	141	136,23	3,38%
147	159	144,784	8,94%
148	147	138,551	5,75%
149	132	127,917	3,09%
150	137	131,478	4,03%
151	155	146,544	5,46%
152	141	133,124	5,59%
153	137	132,639	3,18%
154	124	121,27	2,20%
155	145	138,134	4,74%
156	145	140,363	3,20%
157	150	143,918	4,05%

Continuação da Tabela de Resultados

Semente	Ângulo Goniômetro	Ângulo Obtido	Erro
158	147	140,356	4,52%
159	147	139,314	5,23%
160	145	138,261	4,65%
161	149	145,024	2,67%
162	136	128,219	5,72%
163	149	142,33	4,48%
164	142	138,14	2,72%
165	147	142,926	2,77%
166	152	143,823	5,38%
167	141	138,049	2,09%
168	131	128,359	2,02%
169	158	146,629	7,20%
170	148	145,871	1,44%
171	145	141,94	2,11%
172	149	143,584	3,63%
173	148	142,504	3,71%
174	139	143,259	3,06%
175	145	135,099	6,83%
176	141	138,232	1,96%
177	156	144,488	7,38%
178	150	143,597	4,27%
179	154	146,056	5,16%
180	147	142,082	3,35%
181	153	144,613	5,48%
182	151	144,613	4,23%
183	143	135,365	5,34%
184	149	143,074	3,98%
185	145	139,707	3,65%
186	145	141,474	2,43%
187	137	134,208	2,04%
188	121	121,631	0,52%
189	139	124,182	10,66%

Continuação da Tabela de Resultados

Semente	Ângulo Goniômetro	Ângulo Obtido	Erro
190	140	137,122	2,06%
191	130	125,817	3,22%
192	144	134,074	6,89%
193	142	130,704	7,95%
194	148	140,744	4,90%
195	136	127,604	6,17%
196	146	135,312	7,32%
197	150	141,755	5,50%
198	148	139,8	5,54%
199	153	140,091	8,44%
200	148	142,767	3,54%
201	153	143,746	6,05%
202	157	144,65	7,87%
203	131	128,758	1,71%
204	146	135,467	7,21%
205	139	133,217	4,16%
206	144	135,962	5,58%
207	154	143,887	6,57%
208	146	133,788	8,36%
209	148	141,543	4,36%
210	158	145,605	7,84%
211	154	140,77	8,59%
212	155	144,88	6,53%
213	153	144,88	5,31%
214	151	142,442	5,67%
215	131	128,41	1,98%
216	149	137,373	7,80%
217	143	136,481	4,56%
218	138	129,869	5,89%
219	140	135,554	3,18%
220	153	145,53	4,88%
221	143	131,857	7,79%

Continuação da Tabela de Resultados

Semente	Ângulo Goniômetro	Ângulo Obtido	Erro
222	148	139,343	5,85%
223	148	141,152	4,63%
224	137	131,053	4,34%
225	136	135,951	0,04%
226	135	129,032	4,42%
227	154	142,765	7,30%
228	159	151,698	4,59%
229	148	144,676	2,25%
Médias	145,72°	137,43°	5,65%