

UNIVERSIDADE NOVE DE JULHO – UNINOVE
PPGI
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA E GESTÃO DO
CONHECIMENTO

ELI VEIGA JUNIOR

MÉTODO BASEADO EM ANÁLISE DE IMAGENS SPECKLE E APRENDIZAGEM
PROFUNDA PARA IDENTIFICAÇÃO DO DEFEITO GERMINADO NA INSPEÇÃO
VISUAL DA QUALIDADE DE GRÃOS DE FEIJÃO

SÃO PAULO
2023

UNIVERSIDADE NOVE DE JULHO – UNINOVE
PPGI
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA E GESTÃO DO
CONHECIMENTO

ELI VEIGA JUNIOR

MÉTODO BASEADO EM ANÁLISE DE IMAGENS SPECKLE E APRENDIZAGEM
PROFUNDA PARA IDENTIFICAÇÃO DO DEFEITO GERMINADO NA INSPEÇÃO
VISUAL DA QUALIDADE DE GRÃOS DE FEIJÃO

Dissertação apresentada ao Programa de Pós-Graduação em Informática e Gestão do conhecimento da Universidade Nove de Julho - UNINOVE, como requisito parcial para a obtenção do título de Mestre em Informática.

Orientador: Prof. Dr. Sidnei Alves de Araújo
Coorientador: Prof. Dr. Alessandro M. Deana

SÃO PAULO

2023

UNINOVE



Universidade Nove de Julho

PARECER – EXAME DE DEFESA

Parecer da Comissão Examinadora designada para o exame de defesa do Programa de Pós-Graduação em Informática e Gestão do Conhecimento a qual se submeteu o aluno Eli Veiga Junior.

Tendo examinado o trabalho apresentado para obtenção do título de "Mestre em Informática e Gestão do Conhecimento", com Dissertação intitulada "MÉTODO BASEADO EM ANÁLISE DE IMAGENS SPECKLE E APRENDIZAGEM PROFUNDA PARA IDENTIFICAÇÃO DO DEFEITO GERMINADO NA INSPEÇÃO VISUAL DA QUALIDADE DE GRÃOS DE FEIJÃO", a Comissão Examinadora considerou o trabalho:

☒ Aprovado


☐ Aprovado condicionalmente

☐ Reprovado com direito a novo exame


☐ Reprovado

EXAMINADORES


Prof. Dr. Sidnei Alves de Araújo - PPGI/Uninove (Orientador)



Prof. Dr. Alessandro Melo Deana – PPGI/Uninove (Coorientador/ Membro Interno)



Prof. Dr. Renato Araujo Prates - PPGB/UNINOVE (Membro Externo)



Prof. Dr. Peterson Adriano Belan - PPGI/UNINOVE (Membro Interno)



São Paulo, 28 de junho de 2023

Veiga Junior, Eli.

Método baseado em análise de imagens speckle e aprendizagem profunda para identificação do defeito germinado na inspeção visual da qualidade de grãos de feijão. / Eli Veiga Junior. 2023.

74 f.

Dissertação (Mestrado) - Universidade Nove de Julho - UNINOVE, São Paulo, 2023.

Orientador (a): Prof. Dr. Sidnei Alves de Araújo.

1. Grão. 2. Feijão. 3. Germinado. 4. Visão computacional. 5. Speckle. 6. Inteligência artificial.

I. Araújo, Sidnei Alves de. II. Título.

CDU 004

DEDICATÓRIA

Dedico este trabalho primeiramente a Deus, por ser essencial em minha vida, autor de meu destino, meu guia, socorro presente na hora da angústia, aos meus pais “*in memoriam*” Eli Veiga e Albertina Domingas de Oliveira Diniz, que sem dúvida alguma seriam as pessoas mais orgulhosas por este momento ímpar.

AGRADECIMENTOS

Ao meu orientador, Prof. Dr. Sidnei Alves Araújo, por todo o engajamento com esta dissertação, e por estar sempre disposto a esclarecer dúvidas e ajudar-me a finalizar mais esta etapa com sucesso.

Ao meu coorientador, Prof. Dr. Alessandro Melo Deana, pelo total apoio nas pesquisas realizadas no Laboratório de Óptica e Visão Inteligente (LOVI).

A todos professores do corpo docente do PPGI da Universidade Nove de Julho pelo apoio e pela oportunidade concedida em bolsa de estudos.

E, finalmente, agradeço o apoio do Programa de Suporte a Pós-Graduação de Instituições de Ensino Particulares (PROSUP) da CAPES.

RESUMO

A inspeção visual automática de grãos agrícolas pode trazer um diferencial competitivo para as empresas, pois possibilita maior padronização dos resultados levando à obtenção de produtos com maior qualidade e, portanto, com maior valor agregado. Atualmente a inspeção visual de grãos de feijão é conduzida de forma manual visando a determinação do Grupo, Classe e Tipo do produto. O termo "Grupo" é utilizado para se referir à espécie botânica, enquanto a "Classe" é uma classificação do feijão com base na coloração da película e o "Tipo" está relacionado às características qualitativas do produto, sendo determinado de acordo com os defeitos encontrados na amostra, entre os quais estão: partidos, carunchados, ardidos, mofados e germinados, que na sua fase avançada o grão apresenta radícula (broto) visível. O defeito germinado em sua fase inicial é detectado somente por métodos invasivos, partindo o grão para conseguir visualizar. Como alternativa, existem métodos não invasivos na literatura baseados em análise *speckle* que já são usados em muitas áreas, inclusive na área agrícola para análise de viabilidade de sementes para o plantio. Neste trabalho é apresentado um método que combina análise de imagens *speckle* e redes neurais de aprendizagem profunda para identificar o defeito germinado em sua fase inicial nos grãos de feijão, que geralmente passariam despercebidos pela visão humana. Primeiro, foram comparados os mapas gerados pela Análise de Contraste Espacial do *Laser Speckle* (LASCA) e pela, Análise de Contraste Temporal do *Laser Speckle* (LASTCA). Posteriormente, janelas de 50×50 *pixels* foram extraídas dos mapas LASTCA, que apresentaram os melhores resultados, e submetidas a uma Rede Neural Convolucional (RNC) que as classificou para indicar a existência do defeito germinado nos grãos analisados. O método proposto foi capaz de identificar o defeito com acurácia de 92,33% e com alta sensibilidade (98,21%), demonstrando a sua aplicabilidade no processo de inspeção visual da qualidade do feijão na agroindústria.

Palavras-chave: grão, feijão, germinado, visão computacional, *speckle*, inteligência artificial.

ABSTRACT

The automatic visual inspection of agricultural grains can bring a competitive differential for companies, because it allows a higher standardization of the results leading to the obtainment of products with higher quality and, therefore, with higher added value. Currently the visual inspection of bean grains is conducted manually in order to determine the Group, Class and Type of the product. The term "Group" is used to refer to the botanical species, while the "Class" is a classification of beans based on the color of the skin and the "Type" is related to the qualitative characteristics of the product, being determined according to the defects found in the sample, among which are: broken, careworn, burnt, moldy and sprouted, which in its advanced stage the grain presents visible radicle (sprout). The germinated defect in its initial phase is only detected by invasive methods, breaking the grain to get visualization. As an alternative, there are non-invasive methods in the literature based on speckle analysis that are already used in many areas, including agriculture, to analyze seed viability for planting. In this paper a method is presented that combines speckle image analysis and deep learning neural networks to identify the germinated defect in its early stage in bean grains, which would usually go unnoticed by human vision. First, the maps generated by Laser Spatial Speckle Contrast Analysis (LASCA) and by, Laser Temporal Speckle Contrast Analysis (LASTCA) were compared. Subsequently, 50×50 pixel windows were extracted from the LASTCA maps, which showed the best results, and submitted to a Convolutional Neural Network (CNN) that classified them to indicate the existence of the germinated defect in the analyzed grains. The proposed method was able to identify the defect with an accuracy of 92.33% and with high sensitivity (98.21%), demonstrating its applicability in the process of visual inspection of bean quality in agribusiness.

Keywords: grain, bean, germinated, computer vision, speckle, artificial intelligence.

LISTA DE ILUSTRAÇÕES

Figura 1 – Inspeção visual manual.....	25
Figura 2 – Fluxograma do processo de inspeção da qualidade do feijão.....	26
Figura 3 – Grãos germinados.....	28
Figura 4 – Sistema de visão computacional (SVC).....	29
Figura 5 – Padrão de <i>speckle</i>	31
Figura 6 – Padrão de <i>speckle</i> no grão de feijão germinado.....	32
Figura 7 – Diagrama esquemático do funcionamento do método LASCA.....	34
Figura 8 – Diagrama esquemático do funcionamento do método LASTCA.....	35
Figura 9 – Relação entre IA, ML, DL.....	36
Figura 10 – Arquitetura de uma RNC.....	38
Figura 11 – Equipamento para aquisição de imagens.....	40
Figura 12 – Imagens capturadas.....	41
Figura 13 – Imagens com tempos de germinação distintos.....	42
Figura 14 – Diagrama do método proposto.....	43
Figura 15 – Amostras de treinamento (ampliadas) de 50×50 pixels do defeito germinado.....	44
Figura 16 – Amostras de treinamento (ampliadas) de 50×50 pixels sem defeito (normal).....	44
Figura 17 – Arquitetura da RNC proposta.....	45
Figura 18 – Mapas de contraste espacial LASCA gerados com lotes de 30 frames.....	48
Figura 19 – Mapas de contraste temporal LASTCA gerados com lotes de 120 frames.....	49
Figura 20 – Performance da RNC nas fases de treinamento e validação.....	51
Figura 21 – Reconhecimento dos padrões pela RNC.....	52
Figura 22 – Matrizes de confusão obtidas nos testes com a RNC.....	53
Figura 23 – Acurácia e sensibilidade do método proposto para os diferentes tempos de germinação.....	54

LISTA DE TABELAS

Tabela 1 – Conjuntos de subimagens empregados no treinamento da RNC....44

Tabela 2 – Conjuntos de subimagens para avaliação do desempenho da RNC considerando diferentes tempos de germinação.....44

LISTA DE SIGLAS

AVD	<i>Absolute Values Difference</i>
AVI	<i>Audio Video Interleave</i>
BA	<i>Biospeckle Activity</i>
bOCT	<i>biospeckle Tomografia Coerente Óptica</i>
C	Colunas
CCD	<i>Charge Coupled Device</i>
CNNs	<i>Convolutional Neural Networks</i>
CONAB	Companhia Nacional de Abastecimento
DL	<i>Deep Learning</i>
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
EM	Espectro Eletromagnético
F	<i>Frames</i>
FTHSP	<i>Full-field Time History of Speckle Pattern</i>
h	horas
IA	Inteligência Artificial
J	Janelas
LASCA	<i>Laser Speckle Contrast Analysis</i>
LASTCA	<i>Laser Speckle Temporal Contrast Analysis</i>
L	Linhas
LOVI	Laboratório de Visão e Óptica Inteligente
MAPA	Ministério da Agricultura, Pecuária e Abastecimento
ML	<i>Machine Learning</i>
MI	Momento de Inércia
MP	Minuto Rural

ms	milissegundos
P	Profundidade
RNC	Rede Neural Convolucional
ROI	<i>Region Of Interest</i>
SVC	Sistema de Visão Computacional
Zn	Zinco

SUMÁRIO

1. INTRODUÇÃO	15
1.1. Contextualização do tema.....	15
1.2. Trabalhos correlatos e lacunas de pesquisa.....	17
1.3. Objetivos.....	22
1.3.1 Objetivo geral	22
1.3.2 Objetivos específicos	22
1.4. Justificativa	23
1.5. Limitações da pesquisa.....	23
2. FUNDAMENTAÇÃO TEÓRICA	25
2.1. Inspeção visual da qualidade do feijão no Brasil	25
2.2. Defeitos encontrados nos grãos de feijão	27
2.2.1 Defeito germinado.....	27
2.3. Visão computacional	28
2.4. <i>Speckle</i> e <i>Biospeckle</i>	31
2.4.1. Análise de Contraste do Laser <i>Speckle</i> (LASCA)	33
2.4.2. Análise de Contraste Temporal do Laser <i>Speckle</i> (LASTCA)	35
2.5. Inteligência Artificial	36
2.5.1. <i>Machine Learning</i> e <i>Deep Learning</i>	37
2.5.2. Redes Neurais Convolucionais (RNCs)	38
3. MATERIAIS E MÉTODOS	40
3.1. Aquisição das imagens	40
3.1.1 Base de imagens.....	41
3.2. Método proposto para detecção do defeito germinado	43
3.3. Procedimento para condução dos experimentos e avaliação de resultados.....	45

4. RESULTADOS E DISCUSSÃO	47
4.1. Análises LASCA e LASTCA	47
4.2. Identificação do defeito germinado usando o método proposto	50
5. CONCLUSÕES E TRABALHOS FUTUROS	55
REFERÊNCIAS.....	56
APÊNDICES	63
I. Código fonte para a construção dos mapas de contraste espacial LASCA	63
II. Código fonte para a construção dos mapas de contraste temporal LASTCA	66
III. Código fonte para reconhecimento dos grãos germinados com a RNC ...	69
IV. Código fonte para avaliação do desempenho da RNC na identificação do defeito germinado.....	73
V. Código fonte para avaliação do desempenho da RNC considerando diferentes tempos de germinação.....	74

1. INTRODUÇÃO

1.1. Contextualização do tema

O feijão comum, conhecido cientificamente como *Phaseolus vulgaris* L., é uma leguminosa amplamente pesquisada na América Latina, desempenha um papel fundamental na alimentação da população, sendo considerada a principal fonte de proteína. Sua importância alimentar está associada a diversos fatores, sendo um deles o custo de produção mais baixo em comparação com a proteína animal (BONETT, 2007).

Diante da expressiva demanda do mercado por feijão, as agroindústrias têm direcionado seus investimentos rumo a avançadas inovações tecnológicas, impulsionadas pela imperiosa necessidade de manter uma posição competitiva no atual cenário socioeconômico. Essas iniciativas visam, primordialmente, satisfazer as mutáveis preferências dos consumidores, ao mesmo tempo em que se comprometem com a produção de alimentos seguros e de excelência. A implementação dessas inovações tecnológicas tem proporcionado às empresas a minimização de desperdícios, a maximização dos ganhos, a otimização da produtividade em uma escala ampla, a conquista de novos mercados e o aprimoramento da performance organizacional. (NASCIMENTO; GAVRON; BITTENCOURT, 2017).

A automatização de processos produtivos no setor agrícola vem sendo, nos últimos anos, de suma importância para o desenvolvimento do setor e tem se tornado imprescindível com o advento da agricultura de precisão e da agroindústria 4.0, as quais têm como premissa o emprego das novas tecnologias visando otimizar a tomada de decisões e melhorar os processos de produção, para obtenção de produtos com maior qualidade e que respeitem o meio ambiente (MASSRUHÁ; LEITE, 2017).

As tarefas de inspeção da qualidade de produtos agrícolas visam assegurar que eles estejam livres de odores anormais, umidade, corpos estranhos, impurezas, infestações de pragas e danos mecânicos, garantindo que cheguem em plenas condições até o consumidor (MAPA, 2015; EMBRAPA, 2008).

A inspeção visual de grãos de feijão, por exemplo, é conduzida de forma manual a partir de uma amostra de no mínimo 1 Kg extraída de um lote do produto. Para tanto, primeiro separam-se os objetos estranhos como insetos, pedras e impurezas, utilizando-se uma peneira de crivos circulares com cinco milímetros de diâmetro. Depois disso, determina-se o Grupo, a Classe e o Tipo do feijão. O Grupo está relacionado à espécie botânica; a Classe é determinada de acordo com a coloração das películas dos grãos (Preto, Branco, Cores ou Misturado), independente do grupo. Por fim, o Tipo é definido de acordo com os limites máximos de tolerância de defeitos (partidos, ardidos, mofados, carunchados, impurezas, matérias estranhas e germinados) encontrados na amostra inspecionada (EMBRAPA, 2008).

O defeito germinado em sua fase inicial é detectado somente por métodos invasivos partindo o grão para conseguir visualizar, tornando impróprios para o consumo após essas análises. Assim, apesar da visão computacional (área da ciência da computação responsável por extrair, analisar e interpretar automaticamente o conteúdo de imagens digitais) desempenhar um papel importante na detecção de doenças e pragas, na previsão da safra e na avaliação não invasiva de características como qualidade, aparência e volume, ela por si só, assim como a visão humana, não é capaz de detectar o defeito germinado.

Uma alternativa não invasiva, são os métodos de análise *speckle* que já estão sendo usados na agricultura, com finalidade de detectar o melhor momento da germinação e viabilidade das sementes para o plantio.

Conforme mencionado por Rabal e Braga (2018), quando uma superfície com textura óptica rugosa é exposta à luz coerente (formada por ondas eletromagnéticas com a mesma frequência e direção e que mantêm relação de fase constante entre si), como a emitida por um *laser*, a luz dispersa exibe uma distribuição de intensidade característica, resultando em uma aparência granulada na superfície. Essa estrutura granular consiste em regiões escuras e claras de diferentes formas, distribuídas de maneira aleatória, sem qualquer conexão óbvia com as propriedades visíveis da superfície. Esse padrão de distribuição de intensidade, também observado quando a luz coerente atravessa um meio com variações aleatórias no índice de refração, é conhecido como padrão de *speckle*. Quando o *speckle* é aplicado em materiais com superfícies opticamente rugosa e que possuem algum tipo de atividade, ele pode ser denominado *biospeckle*.

É nesse contexto que se insere o presente trabalho, com a proposição de um método não invasivo que emprega visão computacional, técnicas de análise *speckle* e de inteligência artificial para identificar o defeito germinado em grãos de feijão, mesmo em sua fase inicial.

1.2. Trabalhos correlatos e lacunas de pesquisa

Nesta seção é apresentada a revisão da literatura sobre análise e inspeção visual automática de grãos e sementes agrícolas com o uso da técnica *biospeckle*, buscando mapear e sintetizar como o tema tem sido tratado, principalmente nos últimos 5 anos.

Silva *et al.* (2018) propuseram estudar o tratamento de patógenos com o bioprotetor em sementes de milho imediatamente após e durante o armazenamento. As sementes de milho foram analisadas por meio de teste de germinação, testes de vigor, e a viabilidade das sementes tratadas foi verificada através do *biospeckle*. Os bioprotetores possuem fungos antagonistas que produzem metabólitos e enzimas que irão evitar a proliferação de fungos fitopatogênicos. Os testes foram realizados com o tratamento a fim de avaliar o potencial fisiológico causado pelo tratamento com o bioprotetor. As porcentagens de germinação de 93,0%, 87,5% e 87,5%, respectivamente, mostraram que todas as sementes de milho estavam acima do requisito mínimo para comercialização, que é 85%. Analisando os testes de vigor e sanidade, verificou-se que o melhor tratamento foi no dia zero. Entre as sementes analisadas por meio do *biospeckle*, utilizando a técnica de análise de contraste de *speckle a laser* (LASCA), foi possível identificar a atividade dos fungos.

Peixoto *et al.* (2018) utilizaram o *laser biospeckle* para identificar a atividade microbiana nas sementes de milho, por meio de mapas de atividade gerados pela análise de contraste *speckle a laser* (LASCA). As sementes com maior atividade biológica devido à presença de fungos apresentaram menores níveis de cinza, e as sementes com menor incidência de fungos apresentaram níveis mais altos de cinza. Os níveis de cinza nas imagens obtidas através do LASCA indicaram maior ou menor atividade biológica. Dessa forma, a pesquisa envolvendo termoterapia conseguiu ser feita variando a temperatura e o tempo de exposição para obter valores que reduzam consideravelmente os agentes patogênicos e preservem a

qualidade, a fim de manter os valores de germinação e vigor aceitáveis para comercialização.

Xia *et al.* (2019) fizeram uma revisão sobre tecnologias emergentes e suas principais aplicações na detecção de viabilidade de sementes que é de grande importância nas características de qualidade, refletindo o potencial de germinação das sementes antes do cultivo, venda e plantio. Com base nas tendências observadas; espectroscopia no infravermelho próximo, imagens hiperespectrais e multiespectrais, espectroscopia Raman, termografia infravermelha e métodos de imagem de raios-X suaves, obtiveram uma conclusão de que sistemas de avaliação não destrutiva baseados em óptica e/ou imagem têm sido gradativamente investigados e empregados na inspeção de qualidade externa e interna de sementes nos últimos anos. E que essas técnicas não invasivas são ferramentas rápidas, precisas, confiáveis e simples para avaliar a viabilidade de sementes.

Singh *et al.* (2020) demonstraram o uso de uma técnica de *biospeckle a laser* para a caracterização de tratamentos de *priming*, que é um dos tratamentos pré-semeadura bem estabelecidos e de baixo custo para melhorar as propriedades de germinação e produtividade de sementes. Para caracterizar o efeito do *priming*, as sementes tratadas foram iluminadas por um feixe de *laser* filtrado espacialmente. Os padrões sucessivos de manchas dinâmicas resultantes foram capturados usando uma câmera CCD (*Charge Coupled Device*) e analisados. Ambos, histogramas não normalizados e um método de indexação robusto baseado em ajuste gaussiano foram usados para avaliar o mapeamento qualitativo e quantitativo da dinamicidade. O efeito de diferentes tratamentos de condicionamento no comportamento de embebição das sementes foi avaliado e os resultados foram comparados com o teste padrão de germinação. A atividade do *biospeckle* foi fortemente correlacionada com a porcentagem de germinação ($R = 0,88$, $p < 0,01$) e negativamente correlacionada com o tempo médio de germinação ($R = -0,92$, $p < 0,01$). Os resultados obtidos demonstram que o *biospeckle a laser* pode ser utilizado de forma vantajosa como uma ferramenta eficiente, automatizada, rápida e não destrutiva para avaliar tratamentos de *priming* de sementes. Além disso, a configuração proposta é extremamente simples, de baixo custo, envolve escaneamento não mecânico e é altamente estável.

Kurokawa *et al.* (2020) desenvolveram um método utilizando a análise de imagem baseada no fenômeno *biospeckle* que consiste em obter um vídeo de 10

segundos de um *laser* focado em grãos de *Moringa oleífera*. Este vídeo é dividido em *frames*, utilizando uma rotina computacional em *Matlab* e, em seguida, a sequência de imagens é processada utilizando o programa computacional denominado *ImageJ*. Os resultados são expressos em termos de matriz de correlação modificada e Momento de Inércia (MI). Paralelamente, é realizada uma análise de umidade utilizando a metodologia tradicional empregando equipamentos convencionais de aquecimento a 130 °C. Ao correlacionar os valores de MI e umidade, foi possível determinar o teor de umidade por meio de um método indireto.

Contado e Júnior (2020) propuseram medir a viabilidade de sementes de Angico-Vermelho durante as primeiras 72 horas de germinação utilizando o *biospeckle laser* com análise numérica. Os resultados obtidos no primeiro experimento permitiram o acompanhamento da atividade biológica ao longo das 72 horas de germinação, mostrando alta atividade celular na região do embrião já nas primeiras 4 horas de germinação. No segundo experimento, os resultados mostraram maior atividade biológica nas sementes maduras quando comparadas às imaturas durante as primeiras 4 horas de germinação, detalhando também a atividade biológica em diferentes áreas da semente de Angico-Vermelho, relatando uma maior atividade biológica na região do eixo embrionário quando comparado ao endosperma. Em conclusão, a técnica de *biospeckle laser* com análise numérica de diferença de valores absolutos (AVD) pode ser utilizada para investigar a germinação de Angico-Vermelho já nas primeiras 4 horas de germinação, dispensando os métodos tradicionais.

Singh *et al.* (2021) utilizaram *biospeckle* para estudar a viabilidade das sementes de feijão vermelho. Grupos de sementes (viável e não viável) foram proporcionadas condições de germinação semelhantes para os mesmos tempo. As imagens da atividade para cada grupo foram gravadas através de uma câmara CCD e processadas usando técnicas do momento de inércia (MI) e diferença do valor absoluto (AVD). Os resultados obtidos de forma conclusiva estabeleceu a análise de *biospeckle* como uma ferramenta eficiente para avaliar a viabilidade de feijões, sendo possível distinguir diferentes atividades biológicas e não biológicas nas amostras quando iluminadas por uma fonte *laser* altamente coerente e não invasiva.

Silva *et al.* (2021) aplicaram uma técnica de avaliação ultrarrápida para monitorar o efeito de concentrações crescentes de Zinco (Zn) na germinação de sementes de lentilha. Um incremento significativo do contraste *biospeckle*

Tomografia Coerente Óptica (bOCT) foi observado para duas menores concentrações de Zn de 5 e 10 mg/L, mostrando atividade interna promovida das sementes, indicando o efeito micronutriente do Zn em baixas concentrações. Assim, o método proposto foi capaz de observar o efeito micronutriente do Zn em um estágio inicial antes da germinação. Assim, a técnica de bOCT proposta é mais confiável e capaz de observar a alteração da atividade interna de sementes de lentilha ao vivo, em um estágio inicial antes da germinação sob a exposição de Zn, como agente externo em nosso estudo. Portanto, o método proposto pode ser usado como uma técnica de avaliação ultrarrápida para observar o estresse ambiental na germinação de sementes e no crescimento de plantas sob qualquer estressor externo.

De acordo com Zanco *et al.* (2021), a análise de sementes é frequentemente conduzida por meio de amostras destrutivas, utilizando métodos que consomem tempo. Além disso, são comumente aplicados tratamentos, que desempenham um papel predominante na avaliação do vigor das sementes. No entanto, em seu estudo, buscaram explorar o uso de tecnologias biofotônicas, como o *scanner* de plasma frio (GDV) e o *speckle laser* (BSL), para examinar a germinação de sementes de feijão *azuki* tratadas com ultradiluições (UHD). A análise das imagens das sementes foi realizada antes e depois da germinação, por meio de técnicas específicas, como a Análise de Dimensão Fractal Conectada Local (LCFD) e o Padrão *Speckle* de Histórico de Tempo (THSP). As imagens capturadas pelo *speckle laser* (BSL) apresentaram sinais mais evidentes em comparação às imagens obtidas pelo *scanner* de plasma frio (GDV), com uma taxa média de precisão de 89% (BSL) em contraste com 87% (GDV). Esses resultados indicam a efetividade das tecnologias biofotônicas na detecção e avaliação dos efeitos das ultradiluições nas sementes de feijão *azuki*.

Thakur *et al.* (2022) apresentaram a técnica de *biospeckle* para analisar o impacto dos regimes de temperatura e teor de umidade inicial nas características de germinação de sementes de soja. Um método é proposto para avaliar os valores de ângulo do registro e tamanho do *speckle* para padronização dos parâmetros experimentais. Além disso, para aumentar a precisão da técnica, um novo procedimento baseado em *full-field time history of speckle pattern* (FTHSP) para quantificação numérica da atividade de *biospeckle* (BA) é proposto. Correlação positiva significativa ($p < 0,01$) entre BA e testes de germinação padrão comprovam a aplicabilidade da análise de *biospeckle* como uma ferramenta eficiente para avaliar

rapidamente o impacto da temperatura e do teor de umidade inicial nas características de germinação das sementes. Além disso, também foi descoberto que tanto o ângulo de gravação quanto o tamanho do padrão de granulado do speckle afetam a qualidade das imagens que influenciam a precisão geral da análise.

Ao analisar os estudos observa-se que os autores Silva *et al.* (2018), Peixoto *et al.* (2018), Xia *et al.* (2019) e Singh *et al.* (2020) demonstram que o *biospeckle* a *laser* pode ser utilizado de forma vantajosa como uma ferramenta eficiente e não destrutiva para avaliar tratamentos de *priming* em sementes para melhorar as propriedades de germinação e produtividade. Além disso, é uma solução extremamente simples, de baixo custo para agropecuária, envolve escaneamento não mecânico e é altamente estável. Já os autores Kurokawa *et al.* (2020) e Contado, de Faria e Júnior (2020) chegam à conclusão, que a técnica de *biospeckle* com análise numérica pode ser utilizada para acompanhar a atividade biológica ao longo da germinação. Os autores Singh *et al.* (2021) e Thakur *et al.* (2022), realizaram uma análise com *biospeckle* para monitorar o processo de germinação, verificando a viabilidade e vigor das sementes de feijão e soja, a técnica não invasiva apresentou grande potencial.

Estudos mais antigos, porém relevantes na literatura como o de BRAGA *et al.* (2005) e RABELO *et al.* (2011) constataram com *biospeckle* que as atividades dos fungos eram diferentes para as sementes de feijão que foram inoculados comparado com aqueles que não foram inoculados. Os resultados mostraram que métodos baseados em *biospeckle* é capaz de distinguir facilmente as sementes de feijão contaminadas e não contaminadas por fungos. Já RODRIGUES (2007) analisou o uso da técnica de *biospeckle* para diferenciar tecidos vivos de tecidos mortos em sementes de feijão, visando contribuir para o desenvolvimento de uma metodologia para análise de vigor e viabilidade em sementes no plantio.

Belan (2020), desenvolveu um sistema de visão computacional (SVC) para inspeção da qualidade de grãos de feijão, capaz de detectar alguns defeitos (carunchados, quebrados, ardidos e mofados) e localizar espacialmente os grãos na imagem analisada mesmo que estejam colados uns aos outros.. Contudo, o SVC proposto por eles não detecta o defeito germinado em sua fase inicial. De acordo com Zanco *et al.* (2021), a análise de sementes é frequentemente conduzida por meio de amostras destrutivas, utilizando métodos que consomem tempo. Além

disso, são comumente aplicados tratamentos, que desempenham um papel predominante na avaliação do vigor das sementes.

Segundo Massruhá *et al.* (2020), embora haja um crescente interesse e esforço na implantação da agricultura digital e do subsequente avanço da agricultura 4.0 em direção à agricultura 5.0, ainda existem desafios a serem enfrentados e superados nesse contexto. Não obstante, apesar de existir na literatura várias abordagens para avaliar a viabilidade de sementes para o plantio e, mesmo com o avanço da visão computacional na indústria 4.0, ainda existem lacunas de pesquisas no que tange a detecção de defeitos na inspeção visual automática de grãos de feijão pós colheita. Uma delas é a carência da utilização do *speckle* combinada com inteligência artificial para composição de métodos não invasivos para fornecer dados precisos sobre atividades biológicas nos grãos que possam indicar alguns dos defeitos.

1.3. Objetivos

1.3.1 Objetivo geral

Desenvolver um método computacional que combina análise de imagens *speckle* e redes neurais de aprendizagem profunda para identificar grãos de feijão germinados, mesmo em fase inicial.

1.3.2 Objetivos específicos

- Identificar e comparar os principais métodos de análise *speckle* aplicados em sementes e grãos encontrados na literatura.
- Realizar uma análise *speckle* da germinação nos grãos de feijão considerando diferentes períodos de tempo (24, 12, 6 e 0 horas), usando técnicas conhecidas na literatura.
- Propor um método que combina a análise *speckle* com uma rede neural convolucional (RNC) para interpretar os padrões das atividades biológicas verificadas no interior dos grãos, visando identificar os germinados.

1.4. Justificativa

Para detectar se existe ou não o defeito germinado no feijão a olho nú, é necessário partir o grão, danificando assim a amostra.

As técnicas de análise *speckle* é um exemplo de uso do *laser* em materiais biológicos que, além de não danificar a amostra por ser não invasiva, vem sendo reconhecida especialmente pela sua capacidade de mensuração da atividade biológica em tecidos, a partir do padrão de interferência dinâmico gerado pela iluminação desses materiais pelo *laser* (BOTEGA, 2009).

Para aplicar a análise *speckle* na amostra, é necessário utilizar métodos que possibilitam detectar movimentação em materiais biológicos. Apesar de existirem diversos métodos, optou-se por utilizar na presente pesquisa os métodos LASCA e LASTCA por serem os mais empregados na literatura e pela facilidade de implementação e aplicação dos mesmos, no treinamento da RNC.

Sendo assim, é possível detectar através de imagens *speckle* se existe alguma atividade inicial de germinação no grão de feijão, que é considerado pelo Ministério da Agricultura, Pecuária e Abastecimento (MAPA), como um dos defeitos graves, ou seja, “aqueles cuja presença na amostra ou incidência sobre o grão compromete seriamente a aparência, conservação e qualidade do produto, restringindo ou inviabilizando o uso do mesmo” (EMBRAPA, 2012). Em adição, para diferenciar de forma automática tecidos vivos de tecidos mortos em grãos de feijão, foi empregada uma RNC, que é uma técnica de IA do estado da arte que vem apresentando excelentes resultados no estado no reconhecimento de padrões em imagens.

Assim, esta pesquisa visando contribuir no desenvolvimento de uma metodologia para analisar a qualidade visual dos grãos, que é um parâmetro bastante relevante para sua comercialização, podendo impactar o valor final do produto.

1.5. Limitações da pesquisa

Essa pesquisa foi realizada com o objetivo de desenvolver uma metodologia para detectar um defeito específico. É fundamental reconhecer que, como em

qualquer outra pesquisa, este estudo possui suas próprias limitações. Alguns desses aspectos restritivos são mencionados a seguir, o que abre novas perspectivas e possibilidades para futuros trabalhos na área investigada.

- Apenas o defeito germinado em fase inicial em grãos de feijão foi considerado nesta pesquisa.
- Foram conduzidas investigações exclusivamente nos períodos de 0, 6, 12 e 24 horas para analisar os processos de germinação dos grãos.
- Foram considerados para avaliação somente os feijões classificados como Carioca, uma vez que eles representam 70% dos grãos de feijão consumidos no Brasil (SOUZA *et al.*, 2013). Essa predominância ressalta a importância de focar nessa variedade específica de feijão brasileiro.

2. FUNDAMENTAÇÃO TEÓRICA

2.1. Inspeção visual da qualidade do feijão no Brasil


As características visuais desempenham um papel fundamental na determinação dos preços de mercado e na escolha dos consumidores quando se trata de produtos agrícolas, incluindo os grãos de feijão. No Brasil, a avaliação da qualidade do feijão é predominantemente realizada de forma manual (Figura 1), seguindo os procedimentos operacionais estabelecidos pelo Ministério da Agricultura, Pecuária e Abastecimento (MAPA) (Figura 2). Esses procedimentos orientam como classificar o feijão em grupos, com base na espécie botânica, em classes, levando em consideração a coloração das cascas dos grãos, e em tipos, de acordo com os defeitos presentes na amostra (BELAN, 2019).

Figura 1 – Inspeção visual manual



Fonte: Diário Agrícola, 2023

Figura 2 - Fluxograma do processo de inspeção da qualidade do feijão



Fonte: EMBRAPA, 2012

Para iniciar o processo de classificação do feijão, é necessário realizar a calibração da balança e garantir a limpeza adequada de todos os equipamentos envolvidos. Uma amostra mínima de 1 kg deve ser selecionada e verificada cuidadosamente em busca de insetos vivos, como carunchos e outras pragas comuns em grãos armazenados. Após confirmar que o produto está em condições adequadas, a amostra destinada à classificação deve ser homogeneizada e reduzida por quarteamento até atingir pelo menos 250 g.

Com a amostra quarteada em mãos, é necessário separar as matérias estranhas e impurezas presentes. Além disso, uma subamostra deve ser obtida, também por meio do processo de quarteamento, para determinar o teor de umidade do feijão. Outra subamostra, contendo aproximadamente 100 g, será utilizada para determinar a classe do feijão (Comum - Grupo I ou Caupi - Grupo II), levando em consideração a coloração do tegumento (película) do grão.

Posteriormente, a subamostra é recomposta para realizar a análise dos grãos avariados, incluindo aqueles que se apresentam mofados, ardidos, germinados, carunchados e atacados por lagartas das vagens, além de grãos danificados ou amassados. Também são analisados os grãos partidos (bandinhas) e quebrados (pedaços), tanto os saudáveis quanto os imaturos.

Após essa etapa, cada defeito é separado e pesado individualmente. Os defeitos podem ser classificados como graves, quando restringem ou inviabilizam o uso do produto, ou leves, quando não restringem significativamente a utilização. Com base em uma tabela de tolerância preestabelecida, é possível categorizar o feijão e emitir um certificado de classificação, finalizando assim o processo (EMBRAPA, 2012).

2.2. Defeitos encontrados nos grãos de feijão

Os defeitos encontrados nos grãos de feijão podem ser classificados como leves ou graves. Os defeitos leves não afetam significativamente a aparência, conservação e qualidade dos grãos, sendo ainda adequados para consumo. Esses defeitos incluem grãos amassados, danificados, imaturos, quebrados e partidos (bandinhas).

Por outro lado, os defeitos graves comprometem consideravelmente a aparência, conservação e qualidade dos grãos, levando os consumidores a restringir ou evitar seu consumo. Esses defeitos abrangem grãos ardidos, mofados, carunchados e atacados por lagartas das vagens, além de apresentarem impurezas, matérias estranhas e estarem germinados (EMBRAPA, 2012), o qual é considerado neste trabalho e descrito a seguir.

2.2.1 Defeito germinado

O grão germinado (Figura 3) é caracterizado pelo início visível de germinação, podendo ocorrer tanto em grãos inteiros quanto partidos. A germinação ocorre devido à presença de umidade e calor excessivos. No processo de inspeção visual da qualidade, considera-se como grão germinado aquele que apresenta uma radícula (broto) visível, independentemente do tamanho ou estágio

de desenvolvimento (EMBRAPA, 2012).

Figura 3 – Grãos germinados



Fonte: Autor


2.3. Visão computacional

Campos como a visão computacional utilizam computadores para simular a capacidade visual humana. A visão é considerada o sentido mais avançado que possuímos, e, portanto, não é surpreendente que as imagens desempenhem um papel fundamental na percepção humana. No entanto, ao contrário dos seres humanos, que estão limitados à faixa visual do espectro eletromagnético (EM), os dispositivos de processamento de imagens abrangem quase todo o espectro EM, desde as ondas gama de alta frequência até as ondas de rádio de baixa frequência. Eles têm a capacidade de trabalhar com imagens provenientes de fontes que os seres humanos normalmente não associariam com imagens, como por exemplo, ultrassom, microscopia eletrônica e imagens *speckle* geradas por computador (GONZALEZ & WOODS, 2000).

A área de processamento de imagens desperta cada vez mais interesse devido à sua capacidade de possibilitar uma ampla gama de aplicações em duas categorias distintas. A primeira categoria diz respeito ao aprimoramento de informações visuais para interpretação humana, enquanto a segunda envolve a análise automática de informações extraídas de uma cena por meio de computação. Um Sistema de Visão Computacional (SVC) é um sistema computadorizado

projetado para adquirir, processar e interpretar imagens correspondentes a cenas reais (GONZALEZ & WOODS, 2000). Para ilustrar, a Figura 4 apresenta um diagrama de blocos esquemático de um SVC. A seguir, serão explicadas as principais etapas desse sistema, considerando a resolução de um problema prático específico (MARQUES FILHO, 1999).

Figura 4 – Sistema de visão computacional (SVC)



Fonte: MARQUES FILHO, 1999

- **Domínio do problema e resultado:** O domínio deste problema está relacionado ao conjunto de imagens, e o objetivo do Sistema de Visão Computacional (SVC) é realizar a leitura e análise das imagens presentes nesse conjunto e apresentar o resultado. Nesta pesquisa, por exemplo, o resultado esperado é uma sequência de imagens classificadas como "com defeito" ou "sem defeito". (MARQUES FILHO, 1999);
- **Aquisição da imagem:** Consiste no primeiro passo de um SVC e requer um sensor e um digitalizador. O sensor é responsável por converter informações ópticas em sinais elétricos, enquanto o digitalizador transforma a imagem analógica em formato digital (GONZALEZ &

WOODS, 2000; MARQUES FILHO, 1999);


- **Pré-processamento:** A imagem obtida na etapa anterior pode conter imperfeições, como ruídos e problemas de contraste e brilho. A finalidade do pré-processamento é melhorar a qualidade da imagem, visando prepará-la para as etapas de processamento seguintes (GONZALEZ & WOODS, 2000; MARQUES FILHO, 1999);
- **Segmentação:** A principal função desta é dividir uma imagem em unidades significativas, ou seja, nos objetos de interesse presentes nela. No contexto deste trabalho, a segmentação tem como objetivo a separação exclusiva dos grãos presentes na imagem, visando sua classificação e detecção de possíveis defeitos. Embora seja uma tarefa simples de descrever, sua implementação pode ser uma das mais complexas. Além disso, o sucesso das etapas seguintes depende fortemente da segmentação (GONZALEZ & WOODS, 2000; MARQUES FILHO, 1999);
- **Extração de características:** Nessa etapa busca-se extrair características das imagens resultantes da segmentação por meio de mecanismos descritores, os quais são responsáveis por fornecer uma representação numérica precisa de cada objeto. É fundamental que esses descritores sejam organizados em uma estrutura de dados adequada ao algoritmo de reconhecimento (GONZALEZ & WOODS, 2000; MARQUES FILHO, 1999);
- **Reconhecimento e interpretação:** Nessa etapa final do sistema, ocorre o processo de atribuição de rótulos aos objetos segmentados com base em suas características expressas pelos descritores. Em outras palavras, esta etapa envolve a atribuição de significado a um conjunto de objetos previamente reconhecidos (GONZALEZ & WOODS, 2000; MARQUES FILHO, 1999);
- **Base do conhecimento:** Todas as tarefas mencionadas nas etapas anteriores pressupõem a existência de conhecimento prévio sobre o problema a ser solucionado, o qual é armazenado em uma base de conhecimento. O tamanho e a complexidade dessa base podem variar consideravelmente. Idealmente, essa base de conhecimento deve, além

de orientar o funcionamento de cada etapa individualmente, permitir a retroalimentação entre elas. No entanto, a integração completa entre as diversas etapas por meio da base de conhecimento ainda é um desafio e por isso não está presente na maioria dos SVCs existentes. Por fim, é importante observar que nem todos os SVCs requerem todas as etapas (GONZALEZ & WOODS, 2000; MARQUES FILHO, 1999).

2.4. *Speckle e Biospeckle*

O *speckle* e *biospeckle laser* é uma das técnicas capazes de analisar o comportamento de alguns materiais quando a luz *laser* é incidida sobre eles. *Speckle* representa um fenômeno óptico causado pela interferência de frentes de ondas eletromagnéticas que sofreram dispersão após a interação com um meio físico. A imagem de interferência formada é similar a um conjunto de granulados claros e escuros criando um efeito que na língua inglesa é comumente conhecido como *speckle*, sendo o termo mais usado para se referir a este fenômeno, que só é observado se a luz que produz a iluminação for uma luz coerente, como é o caso do *laser*. O agrupamento desses *speckles* é usualmente chamado de padrão de *speckle* (Figura 5) (RODRIGUES, 2007).


Figura 5 – Padrão de *speckle*



Fonte: DAINTY (2013)

Quando uma superfície é iluminada, pode-se considerar que cada ponto absorve e reemite a luz, atuando como uma fonte de ondas esféricas semelhantes a teoria ondulatória da luz de Huygens (1885) que postula a propagação da luz na forma de ondas. A amplitude complexa das ondas espalhadas em um determinado ponto do espaço é obtida pela soma das amplitudes das contribuições de cada ponto presente na superfície. A amplitude total varia entre zero e um valor máximo determinado pelas magnitudes e fases das amplitudes individuais. Ao variar a posição de um ponto de observação dentro do campo de luz espalhada pela superfície, a amplitude resultante e, conseqüentemente, a intensidade assumem valores aleatórios. Essa variação aleatória na intensidade é responsável pela formação do padrão de *speckle* em objetos iluminados (Figura 6) (RODRIGUES, 2007).

Figura 6 – Padrão de *speckle* no grão de feijão germinado



Fonte: Autor

Os fenômenos ópticos relacionados ao *speckle laser* dinâmico ocorrem no momento em que o *laser* se dispersa sobre uma determinada superfície, e esta, por sua vez, apresenta uma determinada atividade. Ao atingir uma superfície que possui estruturas que se movimentam, os dispersores de luz, ocorre a reflexão da luz de forma difusa. Na superfície e próximo da superfície de materiais biológicos os feixes de luz são refletidos aleatoriamente e os caminhos percorridos pelos raios refletidos são em todos os planos de observação (DAINTY, 1975).

O *biospeckle* (ou *speckle* dinâmico) é uma expressão temporal do padrão de *speckle* com os granulados variando o nível de intensidade e sua forma, fazendo

com que a imagem estática passe a ter mudanças. O *biospeckle* também pode ser visto como um fenômeno óptico de interferência que ocorre quando a luz coerente incide em materiais cujas superfícies possuem algum tipo de atividade biológica. O *speckle* dinâmico é amplamente reconhecido como uma ferramenta valiosa para auxiliar estudos em várias áreas do conhecimento, incluindo a Agronomia. Em particular, pode ser utilizado na avaliação do potencial germinativo de sementes. Se os elementos espalhadores presentes na superfície estiverem em movimento, o padrão *speckle* resultante também irá evoluir ao longo do tempo, o que é conhecido como *speckle* dinâmico. O método possui ainda a vantagem de ser não destrutivo e não invasivo, sem necessitar de grande estabilidade mecânica ou térmica e complexidades inerentes a grande parte das técnicas ópticas mais usuais (SILVA, 2007).

2.4.1. Análise de Contraste do Laser *Speckle* (LASCA)

O método LASCA (*Laser Speckle Contrast Analysis*) proposto por Briers e Webster (1996) que consegue sem a necessidade de equipamento caro, ou muito poder computacional indicar maior ou menor atividade biológica através dos níveis de cinza nas imagens obtidas (PEIXOTO *et al.*, 2018). Esta é uma técnica não invasiva, o método é baseado no uso de estatísticas de primeira ordem extraindo a distribuição de níveis de cinza em uma imagem, especificamente o contraste do *speckle laser*.

A principal técnica de obtenção dos granulados ópticos baseia-se em iluminar a superfície de interesse com uma fonte de luz coerente e capturar essa imagem através de uma câmera. Em sistema de computação, uma imagem digital pode ser transformada em uma matriz numérica, de acordo com a intensidade encontrada em cada *pixel*, onde os dados coletados podem ser tratados e processados de forma quantitativa (KOSHOJI, 2014).

A idéia básica do método LASCA consiste em dividir os *pixels* do registro da imagem em células quadradas e calcular o contraste em seu interior. Em seguida, esses valores são atribuídos aos *pixels* centrais das células correspondentes e uma nova imagem é construída, formando uma mapa de contrastes, cujas dimensões (número de linhas: L e número de colunas: C) dependem das dimensões da janela


(J×J) considerada no cômputo do mapa.

A Figura 7 mostra uma visão geral esquemática da forma como o contraste é calculado no LASCA:


- Configuração LASCA com recursos de laser e sensores de dispositivos de carga acoplado para captar a imagem digital.
- Visão geral esquemática de uma configuração LASCA, com os quadrados sendo *pixels* de uma imagem, o contraste em *pixel* (i, j) (cinza escuro) é determinado calculando a razão do desvio padrão dos *pixels* na área de *pixel* cinza claro n×n para o valor médio dos *pixels* nesta área.
- Equação 1 do cálculo espacial do contraste LASCA e cálculo temporal do contrastaste LASTCA, o contraste de *speckle* (**C**) é normalmente definido como a relação entre o desvio padrão (**σ**) da intensidade e a intensidade da média (**I**) do padrão *speckle*:

$$C_{i,j} = \frac{\sigma_{ij}}{\langle I_{ij} \rangle} \quad (1)$$

Figura 7 – Diagrama esquemático do funcionamento do método LASCA
(a) aquisição, (b) mapa de contraste, (c) etapas de processamento



Fonte: DRAIJER *et al.* (2009), adaptado pelo autor



Fonte: Autor


2.4.2. Análise de Contraste Temporal do Laser *Speckle* (LASTCA)

O método LASTCA, ou análise de contraste temporal, consiste na construção de um mapa através do cálculo do contraste das intensidades de cada *pixel* ao longo do tempo (SILVA, 2007). A Figura 8 ilustra uma visão geral esquemática da forma como o contraste é calculado no tempo.


É gerado um mapa de contraste temporal a partir das variações de intensidade em cada *pixel*. O valor de cada *pixel* do mapa é obtido com base na do cálculo dos *pixels* (i, j) no tempo utilizando a Equação 1:

Figura 8 – Diagrama esquemático do funcionamento do método LASTCA

(a) mapa de contraste, (b) etapas de processamento



Fonte: DRAIJER *et al.* (2009), adaptado pelo autor



Fonte: Autor


Ressalta-se que o número de mapas LASTCA gerados é a razão entre o número de *frames* contidos no arquivo AVI de entrada (P) e o número de *frames* (F) considerados no cômputo de um mapa LASTCA.

2.5. Inteligência Artificial

Russel e Norvig (2010), define Inteligência Artificial (IA) como o estudo de agentes que recebem percepções do ambiente e executam ações. Um agente racional é aquele que age de modo a alcançar o melhor resultado ou, quando houver incerteza, o melhor resultado esperado. Todos os programas de computador fazem alguma coisa, mas espera-se que os agentes de computador façam mais: operar autonomamente, perceber seu ambiente, persistir por um período de tempo prolongado, adaptar-se a mudanças, criar e perseguir objetivos.

Para que todo esse processo aconteça, no entanto, é necessário aplicar diferentes tecnologias como, ML (*Machine Learning*) ou DL (*Deep Learning*) para que possam, conferir à máquina a capacidade de realizarem tarefas como os seres humanos. Conceitualmente, o DL é um subconjunto de técnicas do ML, enquanto o ML é um subconjunto das técnicas de IA (KHAN *et al.*, 2021), ilustrado na Figura 9.

Figura 9 – Relação entre IA, ML e DL



Fonte: Autor

2.5.1. Machine Learning e Deep Learning

Machine Learning, ou aprendizado de máquina envolve a programação de computadores para otimizar um critério de desempenho utilizando dados de exemplo ou experiências passadas. É realizado por meio de um modelo definido com parâmetros, e o aprendizado consiste na execução de um programa de computador para otimizar esses parâmetros utilizando dados de treinamento ou experiências anteriores. O modelo pode ser usado para fazer previsões futuras (modelo preditivo), obter conhecimento dos dados (modelo descritivo) ou ambos. No aprendizado de máquina, a teoria da estatística é empregada na construção de modelos matemáticos, uma vez que a tarefa principal é fazer inferências a partir de uma amostra. A ciência da computação desempenha um papel fundamental, tanto no treinamento quanto na inferência. No treinamento, são necessários algoritmos eficientes para resolver problemas de otimização, além de lidar com o armazenamento e processamento de grandes quantidades de dados. Após o aprendizado do modelo, é crucial ter uma representação eficiente e uma solução algorítmica eficiente para a inferência. Em determinadas aplicações, a eficiência do algoritmo de aprendizado ou inferência, ou seja, sua complexidade de espaço e tempo, pode ser tão importante quanto sua precisão preditiva (ALPAYDIN, 2020).


Deep Learning ou aprendizado profundo permite que modelos computacionais (modelos neurais) compostos por várias camadas de processamento aprendam representações de dados com vários níveis de abstração. Esses métodos melhoraram drasticamente o estado da arte em reconhecimento de fala, reconhecimento visual de objetos, detecção de objetos e muitos outros domínios. O aprendizado profundo descobre estruturas complexas em grandes conjuntos de dados usando o algoritmo de retropropagação para indicar como uma máquina deve alterar seus parâmetros internos que são usados para calcular a representação em cada camada a partir da representação na camada anterior. As redes convolucionais profundas trouxeram avanços no processamento de imagens, vídeo, fala e áudio, enquanto as redes recorrentes se destacaram no processamento de dados sequenciais, como o texto e a fala (LECUN; BENGIO; HILTON, 2015).

2.5.2. Redes Neurais Convolucionais (RNCs)

As redes neurais convolucionais (RNCs), também conhecidas como CNNs (*Convolutional Neural Networks*), são um tipo especializado de rede neural de aprendizagem profunda para processamento de dados que possui uma topologia conhecida como grade. As redes convolucionais têm sido tremendamente bem-sucedidas em aplicações práticas. O nome “rede neural convolucional” indica que a rede emprega uma operação matemática chamada convolução. A convolução é um tipo especializado de operação linear. As redes convolucionais são simplesmente redes neurais que usam convolução no lugar da multiplicação geral da matriz em pelo menos uma de suas camadas (GOODFELLOW; BENGIO; COURVILLE, 2016).

As RNCs são compostas por uma sequência de camadas, cada uma com uma função específica na propagação do sinal de entrada. A Figura 10 apresenta a arquitetura de uma RNC, destacando os três principais tipos de camadas: convolucionais, *pooling* e totalmente conectadas.

Figura 10 – Arquitetura de uma RNC



Fonte: ARAÚJO et al. (2017), adaptado pelo autor

As camadas convolucionais nas redes neurais consistem em conjuntos de filtros que recebem um volume de entrada. Cada filtro possui uma dimensão reduzida, mas se estende por toda a profundidade do volume de entrada. Durante o treinamento da rede, esses filtros são ajustados para detectar características relevantes. Após a camada convolucional, é comum ter uma camada de *pooling*, que tem como objetivo reduzir progressivamente a dimensão espacial do volume de entrada. Por fim, as saídas das camadas convolucionais e de *pooling* representam

as características extraídas da imagem de entrada, as quais são utilizadas pelas camadas totalmente conectadas para realizar a classificação da imagem em uma classe pré-determinada (ARAÚJO *et al.*, 2017).

Além das camadas mencionadas anteriormente, a última camada da rede neural desempenha o papel de função de ativação. Essa função recebe um vetor de valores como entrada e gera a distribuição probabilística da imagem de entrada em relação às classes nas quais a rede foi treinada. Uma técnica comumente utilizada entre as camadas totalmente conectadas é chamada de *dropout*, que tem o objetivo de reduzir o tempo de treinamento e evitar o *overfitting*. Essa técnica consiste em remover aleatoriamente, a cada iteração de treinamento, uma determinada porcentagem de neurônios de uma camada e, em seguida, readicioná-los na iteração seguinte. Essa abordagem confere à rede a capacidade de aprender atributos mais robustos, uma vez que um neurônio não pode depender exclusivamente da presença específica de outros neurônios (ARAÚJO *et al.*, 2017).

Neste trabalho empregou-se a arquitetura de RNC disponível na biblioteca *Keras* da plataforma *TensorFlow*, escrita na linguagem *Python*, que oferece a possibilidade de utilização de GPU (*Graphics Processing Unit*).


3. MATERIAIS E MÉTODOS

Neste capítulo é apresentado o aparato utilizado para aquisição de imagens *speckle*, a base de imagens produzida e o método proposto para detecção do defeito germinado.

3.1. Aquisição das imagens

O ambiente de aquisição de imagens é ilustrado na Figura 11. Essa montagem foi realizada sobre uma mesa óptica *Nexus*, na qual as amostras foram posicionadas em um suporte personalizado, cerca de 1 metro distante do *laser*.

Figura 11 – Equipamento para aquisição de imagens



Fonte: Autor

O feixe do *laser* foi expandido por um sistema óptico composto por lentes. A determinação da distância entre a fonte do *laser* e a amostra levou em consideração a relação entre a fonte do *laser* e o sistema óptico disponível, visando obter um equilíbrio adequado para a homogeneidade da iluminação em toda a amostra, bem como um brilho suficiente para sensibilizar o sensor do sistema fotográfico (GAVINHO, 2019). As amostras foram capturadas por uma câmera CCD utilizando o *software Thorlabs*.


3.1.1 Base de imagens

Os grãos de feijão foram colocados em um recipiente transparente sobre um algodão umedecido com água permanecendo assim por diferentes períodos de tempo: 24, 12 e 6 horas. Vale ressaltar que uma amostra de grão sem defeito (normal) não foi submetida a esse processo (0 hora de umedecimento).

Para cada estágio de germinação das amostras, três grãos foram selecionados, e partir deles foram geradas três imagens TIFF (*Tag Image File Format*). Além disso, foi produzido um arquivo de vídeo no formato AVI (*Audio Video Interleave*) para cada um desses grãos selecionados. O vídeo tem a duração de 2 minutos, com uma taxa de 25 *frames* por segundo, totalizando 3.000 *frames*.


As imagens foram capturadas com resolução de 1280×1024 *pixels* (Figura 12a). No entanto, para evitar processamento desnecessário de áreas irrelevantes, apenas as Regiões de Interesse (*Regions of Interest* - ROI) foram selecionadas e processadas (Figura 12b). Essas áreas correspondem às regiões dos grãos, como ilustra a Figura 12c. A Figura 13 ilustra as imagens *speckle* geradas através das amostras de feijão com tempos diferentes de germinação.

Figura 12 – Imagens capturadas



Fonte: Autor

Figura 13 – Imagens *speckle* com tempos de germinação distintos




Fonte: Autor

3.2. Método proposto para detecção do defeito germinado

O método proposto recebe como entrada um conjunto de imagens *speckle* armazenadas em um arquivo AVI (*frames* de um vídeo), como ilustrado no diagrama da Figura 14. No primeiro passo de processamento, é separada a banda R de cada imagem (*frame*). No segundo passo é aplicada a técnica LASTCA (que apresentou os melhores resultados na comparação com LASCA) no conjunto de imagens representando a banda R dos *frames*, obtendo-se os mapas LASTCA.

Figura 14 – Diagrama do método proposto



Fonte: Autor

Então, os mapas LASTCA são divididos em janelas ou subimagens de (50×50 *pixels*), como ilustrado na Figura 15 (defeito germinado), e 16 (sem defeito, ou seja, normal), as quais são submetidas à RNC treinada para ela predizer à qual classe pertence cada janela. Nos experimentos considerando 2 classes (normal e defeito), utilizamos um total 1200 subimagens, distribuídas nos 4 estágios de germinação (0, 6, 12 e 24 horas). Com o intuito de expandir o conjunto de dados original, empregamos um método de aumento de dados que resultou na geração de 4800 subimagens adicionais, igualmente distribuídas nos mesmos 4 estágios de germinação, resultando em um total de 6000 subimagens. Esse método permite a geração de novas amostras por meio de transformações como rotação e espelhamento aplicadas nas imagens originais. Para garantir o balanceamento entre as classes durante o treinamento, foi considerado o mesmo número de subimagens para cada estágio de germinação, conforme apresentado na Tabela 1.

Na Tabela 2, são apresentadas as quantidades de subimagens e os diferentes tempos de germinação considerados para a avaliação do limiar de tempo mais eficiente para a detecção do defeito germinado.

Tabela 1 – Conjuntos de subimagens empregados no treinamento da RNC

Estágios de germinação	Classes				N° total de subimagens
	Normal	Defeito (germinado)			
	0h	6h	12h	24h	
Sem aumento de dados	300	300	300	300	1200
Com aumento de dados	1200	1200	1200	1200	4800


Fonte: Autor

Tabela 2 – Conjuntos de subimagens para avaliação do desempenho da RNC considerando diferentes tempos de germinação

Classes	Tempos de germinação	Subimagens	N° total de subimagens
Normal	0h	1500	3000
Germinado	6h	1500	
Normal	0h	1500	3000
Germinado	12h	1500	
Normal	0h	1500	3000
Germinado	24h	1500	

Fonte: Autor

Figura 15 - Amostras de treinamento (ampliadas) de 50 × 50 *pixels* do defeito germinado




Fonte: Autor

Figura 16 - Amostras de treinamento (ampliadas) de 50 × 50 *pixels* sem defeito (normal)



Fonte: Autor

A arquitetura da (RNC) foi implementada com duas camadas de convolução, seguidas por duas camadas de *pooling*, além das camadas totalmente conectadas, conforme ilustrado na Figura 17. Foram feitos dois treinamentos da rede: um considerando um total de 20 épocas sem a utilização de aumento de dados, e o outro considerando aumento de dados, e que ocorreu ao longo de 100 épocas.



Fonte: Autor

Após os treinamentos realizados considerando os conjuntos de subimagens de 50×50 *pixels*, apresentados na Tabela 1, os modelos treinados foram salvos em arquivos para serem utilizados nas previsões empregando as imagens separadas para os testes e avaliação de desempenho do método proposto.

3.3. Procedimento para condução dos experimentos e avaliação de resultados

Na realização dos experimentos, 70% das imagens de cada conjunto foram utilizadas para treinamento, 15% para validação e 15% para os testes com a RNC treinada.

Para aplicar o aumento de dados, foram empregadas as operações de rotação e espelhamento. Por meio dessa técnica, foi possível quintuplicar a base de subimagens utilizada no treinamento, enriquecendo o conjunto de dados e melhorando a capacidade da rede de generalizar padrões.

Os resultados obtidos pelo método proposto neste trabalho, para o conjunto de subimagens separadas para os testes foram mensurados com base na acurácia e sensibilidade, e são descritas respectivamente pelas Equações 2 e 3, a seguir,

$$Acurácia = \frac{VP + VN}{VP + FP + FN + VN} \quad (2)$$

$$Sensibilidade = \frac{VP}{VP + FN} \quad (3)$$

nas quais:

- Verdadeiro Positivo (VP): ocorre quando a classificação é feita corretamente.
- Falso Positivo (FP): ocorre quando a classificação do padrão analisado foi predita incorretamente.
- Verdadeiro Negativo (VN): ocorre quando não se encontra um padrão não procurado na imagem.
- Falso Negativo (FN): ocorre quando não se encontra um padrão procurado na imagem.

É importante destacar que todos os códigos fonte, em linguagem *Python*, das implementações das técnicas de análise *speckle* (LASCA, LASTCA), da RNC e das métricas de avaliação estão apresentados nos apêndices I a V.

4. RESULTADOS E DISCUSSÃO

Nas subseções 4.1 e 4.2 a seguir são descritos os resultados obtidos nos experimentos comparativos entre LASCA e LASTCA, bem como nos experimentos computacionais conduzidos com abordagem proposta para identificar o defeito germinado nos grãos de feijão.


4.1. Análises LASCA e LASTCA

Foram conduzidos experimentos objetivando analisar as diferenças entre as técnicas de análise por contraste do *laser speckle* (LASCA) e análise por contraste temporal do *laser speckle* (LASTCA), na caracterização dos grãos germinados.

Na Figura 18 são apresentados os mapas LASCA considerando 24, 12, 6 e 0 horas de germinação, usando cores falsas, que é uma técnica para facilitar a compreensão visual e melhorar a interpretação sobre a germinação a partir dos padrões de contraste apresentados nos mapas LASCA.

É relevante salientar que na metodologia LASCA, a interpretação dos mapas é levemente diferente daquela utilizada nos mapas gerados pelo método LASTCA. É importante compreender que estamos lidando com um mapa de contrastes, nos quais a imagem final reflete as variações espaciais de intensidade na região mapeada. Desse modo, uma região mais ativa exibirá um contraste mais baixo, resultando em valores menores na imagem final do mapa LASCA. Nesse mapa, tons mais azulados indicam maior atividade em comparação a áreas com tons mais esverdeados. Em outras palavras, nas regiões onde as partículas têm maior velocidade, o contraste é reduzido, tornando essas áreas mais escuras no mapa final. Por outro lado, em locais de menor circulação, o contraste é maior, resultando em áreas mais claras (SILVA, 2007).

Figura 18 – Mapa de contraste espacial LASCA gerados com lotes de 30 *frames*



Fonte: Autor


Os mapas gerados pelo método LASTCA, apresentados na Figura 19, correspondem às variações temporais de intensidades em conjuntos de 120 *frames* extraídos de um arquivo AVI. Nessas imagens podemos verificar que a região azulada possui maior nível de atividade, comparada com a região esverdeada, que, por sua vez, não manifesta nenhum indício de atividade. Neste método uma zona mais ativa apresenta contraste mais altos e, portanto aparece com maior valor na imagem final.

O mapa de cores falsas da Figura 19 evidencia as zonas de maior circulação através de regiões azuladas e menor circulação nas regiões esverdeadas indicando

os pontos de germinação em atividade.

A grande vantagem do LASTCA em relação ao LASCA, é a eliminação do ruído provocado pelo contraste espacial, pois, como pode ser observado na Figura 19 os valores de intensidade no mapa final só dependem das flutuações de intensidade de cada *pixel* ao longo do tempo. Porém, é importante ter uma grande coleção com centenas de imagens para aplicar a técnica LASTCA (SILVA, 2007).

Figura 19 – Mapa de contraste temporal LASTCA gerados com lotes de 120 *frames*



Fonte: Autor

Entre os dois métodos apresentados, o LASCA obteve uma boa visualização da germinação dos grãos nos *frames* capturados em 24, 12 e 6 horas. No entanto, nos *frames* capturados com 0 hora, foram observados ruídos que dificultaram a distinção entre os grãos normais e germinados, devido as suas similaridades visuais. Fica evidente que o método LASTCA proporcionou melhores resultados apresentando menor quantidade de ruídos, maior clareza e facilidade de interpretação visual, especialmente na diferenciação entre grãos germinados e os não germinados nos mapas *speckle* gerados a partir de 120 *frames*.

Ao realizar análises de contraste espacial usando LASCA, é essencial levar em consideração a relação sinal-ruído na interpretação dos mapas. Isso se deve ao cálculo do desvio-padrão relativo às intensidades em uma determinada região. É possível visualizar nos mapas LASCA (Figura 18) que a região do feijão sem germinação (0h) também aparece levemente ativa. Assim, uma análise desatenta pode levar à uma interpretação errônea de atividade nesses locais (falso positivo).

Em contrapartida, no mapa LASTCA (Figura 19) observa-se que o feijão que não foi submetido a germinação aparece corretamente com baixa atividade. Isso se deve ao fato do mapa ser gerado a partir de um acúmulo de imagens no tempo.


4.2. Identificação do defeito germinado usando o método proposto

Os modelos de treinamento e validação foram baseados nos mapas gerados pelo método LASTCA a partir de 120 *frames*, devido aos melhores resultados obtidos nos experimentos realizados com esse parâmetro.


Nos experimentos realizados com o conjunto de subimagens de testes de 50×50 *pixels* extraídas dos mapas LASTCA, observamos uma melhoria significativa no reconhecimento dos padrões pela RNC com o conjunto gerado com o uso de aumento de dados. Essa melhoria pode ser observada na Figura 20. Alguns resultados da classificação com o uso de aumento de dados estão ilustrados na Figura 21, na qual os grãos normais são representados pela classe 0 enquanto os grãos com defeitos (germinados) são representados pela classe 1.

Figura 20 – Performance da RNC nas fases de treinamento e validação

(a) Sem aumento de dados




acurácia (validation accuracy): 0.8633




perda de validação (validation loss): 0.3620

(b) Com aumento de dados




acurácia (validation accuracy): 0.9332



perda de validação (validation loss): 0.2243

Fonte: Autor

Figura 21 – Reconhecimento dos padrões pela RNC



Classe real: [0 1 0 1 1 1 1 1 1 1 1 0 1 0 1 1 1 1 0 0 1 1 1 1 0 1 1 0 0 1]

Classe predita: [0 1 0 1 1 1 1 1 1 1 1 0 1 0 1 1 1 1 0 0 1 1 1 1 0 1 1 0 0 1]


Fonte: Autor

As matrizes de confusão representadas na Figura 22 são compostas por quatro quadrantes diferentes;

- Quadrante superior esquerdo: Verdadeiro Negativo (VN)
- Quadrante superior direito: Falso Positivo (FP)
- Quadrante inferior esquerdo: Falso Negativo (FN)
- Quadrante inferior direito: Verdadeiro Positivo (VP)

Elas ilustram os acertos e erros do método em relação a cada classe, tanto para a RNC treinada sem o aumento de dados quanto para a RNC treinada com aumento de dados. Sem o aumento de dados, o método obteve uma acurácia de 91,67%, com 165 predições corretas em um total de 180 testes. Já com o aumento de dados, a acurácia alcançada foi de 92,33%, com 831 predições corretas em um total de 900 testes.

Figura 22 – Matrizes de confusão obtidas nos testes com a RNC




Fonte: Autor

Os resultados demonstram ainda que o método possui uma alta sensibilidade. Sem o aumento de dados, foram corretamente identificados 133 amostras de grãos defeituosos dentre as 135 analisadas (98,51%). Com o aumento de dados, o método também alcançou alta sensibilidade (98,21%), identificando corretamente 660 amostras de grãos defeituosos das 672 avaliadas.

O gráfico apresentado na Figura 23 ilustra os resultados do método considerando os tempos de germinação avaliados nesta pesquisa. Os resultados evidenciam um desempenho significativamente melhor do classificador para os grãos com tempos de germinação mais longos.

Figura 23 – Acurácia e sensibilidade do método proposto para os diferentes tempos de germinação



Fonte: Autor

Além disso, é importante ressaltar a eficácia do método ao realizar boas predições para os períodos analisados. Isso indica que o classificador (RNC) é capaz de lidar com variações de tempo de germinação de forma confiável, proporcionando uma ferramenta promissora para identificar o defeito de germinação em diferentes cenários.

5. CONCLUSÕES E TRABALHOS FUTUROS

Neste trabalho explorou-se a análise *speckle* combinada com redes neurais convolucionais (RNC) para identificar grãos de feijão em diferentes fases de germinação, que é um dos defeitos considerados na inspeção visual da qualidade do produto.

Para tanto, primeiro comparou-se as técnicas LASCA e LASTCA, as quais são amplamente utilizadas na análise *speckle*. Nas comparações, o LASTCA, que consiste na construção de um mapa através do cálculo do contraste das intensidades de cada *pixel* ao longo do tempo, propiciou uma melhor visualização da germinação nos grãos de feijão analisados. Assim, ele foi usado como um extrator de padrões a serem classificados pelas RNC.

A combinação da análise *speckle* com RNC permitiu o desenvolvimento de um método computacional para análise objetiva e de baixo custo para agroindústria, se comparado com o custo de equipamentos normalmente empregados em processos automáticos de inspeção visual da qualidade de produtos agrícolas.

Nos experimentos conduzidos, sem e com o uso do aumento de dados, o método alcançou altos percentuais de acurácia (91,67% e 92,33%) e de sensibilidade (98,51% e 98,21%) na identificação de grãos germinados, indicando o seu potencial para caracterização de defeitos no processo de inspeção visual de grãos de feijão na agroindústria. Contudo, é importante mencionar que para aumentar a viabilidade e escalabilidade, o método depende de um *hardware* compacto contemplando *laser*, câmera e um processador, que pode ser fonte de inspiração para trabalhos futuros de pesquisa nas áreas de engenharia e computação.

Ainda como proposta de trabalhos futuros, sugere-se realizar experimentos com variedades de feijões com colorações diferentes, tais como o preto, mulato e branco, a fim de avaliar se a coloração da película interfere no computo dos mapas *speckle*. Ademais, seria importante realizar uma comparação dos resultados mediante a aplicação de mapas *speckle* gerados a partir de imagens capturadas durante longos períodos de germinação, e considerando diferentes parâmetros como tamanho do *pixel* e tempo de exposição da câmera, tamanho de janelas no LASCA, número de *frames* no LASTCA, entre outros.

REFERÊNCIAS

AIZU, Yoshihisa; ASAKURA, Toshimitsu. Bio-speckles. **Trends in optics**, p. 27-49, 1996.

ALPAYDIN, Ethem. **Introduction to machine learning**. MIT press, 2020.

ARAÚJO, Sidnei Alves de; PESSOTA, Jorge Henrique; KIM, Hae Yong. Beans quality inspection using correlation-based granulometry. **Engineering Applications of Artificial Intelligence**, v. 40, p. 84-94, 2015.

ARAÚJO, F. H. D.; CARNEIRO, A. C.; SILVA, R. R. V; MEDEIROS, F. N. S.; USHIZIMA, D. M. Redes neurais convolucionais com tensorflow: Teoria e prática. **SOCIEDADE BRASILEIRA DE COMPUTAÇÃO. III Escola Regional de Informática do Piauí. Livro Anais-Artigos e Minicursos**, v. 1, p. 382-406, 2017.

BELAN, Peterson Adriano. Sistema de visão computacional para inspeção da qualidade de grãos de feijão. 2019.

BELAN, P. A., de MACEDO, R. A. G., ALVES, W. A. L., SANTANA, J. C. C., & ARAUJO, S. A. Machine vision system for quality inspection of beans. **The International Journal of Advanced Manufacturing Technology**, v. 111, p. 3421-3435, 2020.

BONETT, L. P., BAUMGARTNER, M. D. S. T., KLEIN, Â. C., & da SILVA, L. I. Compostos nutricionais e fatores antinutricionais do feijão comum (*Phaseolus vulgaris* L.). *Arquivos de Ciências da Saúde da Unipar*, v. 11, n. 3, 2007.

BOTEGA, J. V. L. **Viabilidade de métodos óticos para identificação de conteúdo de água de folha de cafeeiros**. Tese de doutorado. Universidade Federal de Lavras (UFLA). MG, 2009. 99 p.

BRAGA Jr, R. A., RABELO, G. F., GRANATO, L. R., SANTOS, E. F., MACHADO, J. C., ARIZAGA, R., RABAL, H.J. & TRIVI, M. Detection of fungi in beans by the laser biospeckle technique. **Biosystems engineering**, v. 91, n. 4, p. 465-469, 2005.

BRAGA, R. A., DUPUY, L., PASQUAL, M., & CARDOSO, R. R. Live biospeckle laser imaging of root tissues. **European biophysics journal**, v. 38, n. 5, p. 679-686, 2009.

BRIERS, J. David; WEBSTER, Sian. Laser speckle contrast analysis (LASCA): a non-scanning, full-field technique for monitoring capillary blood flow. **Journal of biomedical optics**, v. 1, n. 2, p. 174-179, 1996.

BROSNAN, T.; SUN, D.-W. Quality inspection and grading of agricultural and food products by computer vision systems - A review. **Computers and Electronics in Agriculture**, v. 36, n. 2–3, p. 193–213, 2002.

CONAB - **Acompanhamento da Safra Brasileira**. Disponível em: <<https://www.conab.gov.br/info-agro/safras>>. Acesso de maio - julho 2020.

CONTADO, José Luís; DE FARIA SILVA, Caroline; JÚNIOR, Roberto Alves Braga. Biospeckle Laser para Monitoramento da Germinação de Sementes de Angico-Vermelho. **Engenharia Teórica e Aplicada**, v. 4, n. 4, pág. 1 a 9, 2020.

DAINTY, J. C. Statistics of normal and anomalous speckle patterns. *Journal of the Optical Society of America*, New York, v. 65, n. 10, p. 1190-1190, 1975.

DAINTY, J. Christopher (Ed.). Laser speckle and related phenomena. **Springer science & business Media**, 2013.

Diário Agrícola – Agroplanning. Disponível em <<https://www.agroplanning.com.br/2023/05/10/sao-paulo-inaugura-laboratorio-de-medicao-de-umidade-de-graos/>>, Acesso em 08 junho 2023.

DIGITAL. In: **JC na Escola Ciência, Tecnologia e Sociedade**: Mobilizar o Conhecimento para Alimentar o Brasil, São Paulo, Brasil. Anais... São Paulo, Brasil: 2017.

DRAIJER, M., HONDEBRINK, E., VAN LEEUWEN, T., & STEENBERGEN, W. Review of laser speckle contrast techniques for visualizing tissue perfusion. **Lasers in medical science**, v. 24, n. 4, p. 639-651, 2009.

DVORÁK P.; MENZE B.H. Local structure prediction with convolutional neural networks for multimodal brain tumor segmentation. In: International MICCAI workshop on medical computer vision. Springer, Cham, p. 59-71, 2015.

EMBRAPA – **Manual de Classificação do Feijão Instrução Normativa nº 12**, de 28 de março de 2008. [s.l.: s.n.], 2012. Disponível em: <www.cnpaf.embrapa.br>.

EMIS - ISI Emerging Markets Group Company. **Global Dry Beans Market** (2020-2025). Disponível em: <https://www.emis.com/pt>. Acesso em: 13 nov. 2020.

GAVINHO, Luciano Gillieron. Visão computacional aplicada em imagens Speckle para o diagnóstico de lesões de cárie. 2019.

GONZALEZ, Rafael C.; WOODS, Richard E. **Processamento de imagens digitais**. Editora Pearson, 2000.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep learning**. MIT press, 2016.

HUYGENS, Christiaan. *Traité de la lumière*. Gressner & Schramm, 1885.

JONAS DE SOUZA, T. E. G. A.; CÂMARA, Carlos Eduardo. ANÁLISE DE UM ALGORITMO DESENVOLVIDO PARA SOLUÇÃO DE DEEP LEARNING UTILIZANDO REDES NEURAIS CONVOLUCIONAIS PARA DIFERENCIAR GATOS DE CACHORROS. **Revista de Ubiquidade**, v. 2, n. 2, p. 29-63, 2019.

KERAS_DOCUMENTATION. Documentation. Disponível em: <[https:// keras.io](https://keras.io)>. Acesso em: 10 de abril de 2023.

KHAN, P., KADER, M. F., ISLAM, S. R., RAHMAN, A. B., KAMAL, M. S., TOHA, M. U., & KWAK, K. S. Machine learning and deep learning approaches for brain disease diagnosis: principles and recent advances. **IEEE Access**, v. 9, p. 37622-37655, 2021.

KILIÇ, K.; BOYACL, I. H.; KÖKSEL, H.; KÜSMENOGLU, I. A Classification system for beans using computer vision system and artificial neural networks, **Journal of Food Engineering**. v. 78, n.3, p. 897-904, 2007.

KOSHOJI, Nelson Hideyoshi. **Detecção de erosão dental utilizando análise de espalhamento de luz coerente-speckle**. 2014.

KUROKAWA E SILVA, G., AGUIAR, R. H., OLIVEIRA, R. A. D., & FABBRO, I. M. D.. Determinação indireta de umidade usando a técnica de biospeckle. **Revista Ciência Agronômica**, v. 51, 2020.

LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. REVIEW. **NATURE**, v. 521, 2015.

MAPA – **Ministério da Agricultura Pecuária e Abastecimento**. disponível em: <<http://www.agricultura.gov.br/>>, Acesso em: 04 maio 2018.

MARQUES FILHO, Ogê; NETO, Hugo Vieira. **Processamento digital de imagens**. Brasport, 1999.

MASSRUHÁ, Silvia Maria Fonseca Silveira; LEITE, MA de A. Agro 4.0-rumo à agricultura digital. 2017.

MASSRUHÁ, S. M. F. S., LEITE, M. D. A., OLIVEIRA, S. D. M., MEIRA, C. A. A., LUCHIARI JUNIOR, A., & BOLFE, E. L. Agricultura digital: pesquisa, desenvolvimento e inovação nas cadeias produtivas. 2020.

MATPLOTLIB_DOCUMENTATION. Disponível em: < <https://matplotlib.org/stable/>>. Acesso em: 01 de agosto de 2023.

NASCIMENTO, Revenli Fernanda; GAVRON, Adriane Bonfim; BITTENCOURT, Juliana Vitória Messias. Inovações tecnológicas na cadeia produtiva de feijão. **Revista Stricto Sensu**, v. 2, n. 1, 2017.

PATIL, N. K.; YADAHALLI, R. M.; PUJARI, J. Comparison between HSV and YCbCr Color Model Color-Texture based Classification of the Food Grains. **International Journal of Computer Applications**, v. 34, n. 4, p. 51–57, 2011.

PEIXOTO, L. S., PEREIRA, G. M. S., FUJII, A. K., PARISI, J. J. D., AGUIAR, R. H. Sementes de Milho Submetidas à Termoterapia e Analisadas por Dynamic Speckle. **Revista de Ciência e Tecnologia Agrícola B**, v. 8, n. 2, pág. 115-121, 2018.

PESANTE-SANTANA, J. A.; WOLDSTAD, Jeffrey C. Quality inspection task in modern manufacturing. In: **International Encyclopedia of Ergonomics**, W. Karwowski (ed), yaylor and Francis, London, 2000.

RABAL, Hector J.; BRAGA JR, Roberto A. (Ed.). Dynamic laser speckle and applications. CRC press, 2018.

RABELO, G. F., ENES, A. M., JUNIOR, R. A. B., & DAL FABBRO, I. M. Frequency response of biospeckle laser images of bean seeds contaminated by fungi. **Biosystems engineering**, v. 110, n. 3, p. 297-301, 2011.

RODRIGUES, Silvestre. **Efeito Estocástico em Speckle Dinâmico**. Universidade Estadual de Campinas, UNICAMP, Brasil, 2007.

RUSSELL, Stuart J.; NORVIG, P. **Artificial intelligence a modern approach**. Pearson Education, Inc., 2010.

SANTOS, T. T., BARBEDO, J. G. A., TERNES, S., CAMARGO NETO, J., KOENIGKAN, L. V., & DE SOUZA, K. X. S. Visão computacional aplicada na agricultura. 2020.

SILVA, Emerson R. **Estudo das Propriedades do Biospeckle e suas Aplicações**. Universidade de São Paulo, USP, Brasil, 2007.

SILVA, G. M., PEIXOTO, L. S., FUJII, A. K., PARISI, J. J. D., AGUIAR, R. H., & FRACAROLLI, J. A. Avaliação de sementes de milho tratadas com Trichodermil® por meio de biospeckle. **Journal of Agricultural Science and Technology**, v. 8, p. 175-187, 2018.

SILVA, Y. S. K. de., RAJAGOPALAN, U.M., KADONO, H., & LI, D. Fenotipagem positiva e negativa de concentrações crescentes de Zn por Tomografia de Coerência Óptica Biospeckle no monitoramento rápido da germinação de sementes de lentilha (*Lens culinaris*) e crescimento de plântulas. **Plant Stress**, v. 2, p. 100041, 2021.

SINGH, P., CHATTERJEE, A., BHATIA, V., & PRAKASH, S. Aplicação da análise de biospeckle a laser para avaliação de tratamentos de condicionamento de sementes. **Computadores e Eletrônica na Agricultura**, v. 169, p. 105212, 2020.

SINGH, P., CHATTERJEE, A., BHATIA, V., & PRAKASH, S. Viability Assessment of Kidney Bean Seed (*Phaseolus Vulgaris* sp.) Using Robust Biospeckle Indexing Technique. In: **Computational Mathematics, Nanoelectronics, and Astrophysics: CMNA 2018, Indore, India, November 1–3**. Singapore: Springer Singapore, 2021. p. 189-195.

SKLEARN_DOCUMENTATION. Disponível em: < <https://scikit-learn.org/stable/>>. Acesso em: 15 de maio de 2023.

SOUZA, T. L. P. O.; PEREIRA, H. S.; FARIA, L. C.; WENDLAND, A.; COSTA, J. G. C.; ABREU, A. F. B.; DIAS, J. L. C.; MAGALDI, M. C. S.; SOUSA, N. P.; PELOSO, M. J. D.; MELO, L. C. **Common bean cultivars from Embrapa and partners available for 2013.** Disponível em:<<http://ainfo.cnptia.embrapa.br/digital/bitstream/item/97404/1/comunicadotecnico-211.pdf>>. Acesso em: 1 mar. 2018.

THAKUR, P. S., CHATTERJEE, A., RAJPUT, L. S., RANA, S., BHATIA, V., & PRAKASH, S. Técnica de biospeckle a laser para caracterizar o impacto da temperatura e do teor de umidade inicial na germinação de sementes. **Óptica e Lasers em Engenharia**, v. 153, p. 106999, 2022.

TENSORFLOW – **Treine sua primeira rede neural: classificação básica.** disponível em: <<https://www.tensorflow.org/tutorials/keras/classification?hl=pt-br>>, Acesso em: 10 abril 2023.

TENSORFLOW_DOCUMENTATION. Documentation. Disponível em: <<https://www.tensorflow.org>>. Acesso em: 10 de abril de 2023.

XIA, Y., XU, Y., LI, J., ZHANG, C., & FAN, S. **Avanços recentes em técnicas emergentes para detecção não destrutiva da viabilidade de sementes: Uma revisão.** *Inteligência Artificial na Agricultura*, v. 1, p. 35-47, 2019.

ZANCO, J.J., BOFF, P., WERNER, S.S. e BOFF, M.I.C. Biofotótica em sementes de feijão azuki tratadas com ultradiluições. **Pesquisa, Sociedade e Desenvolvimento**, v. 10, n. 2, pág. e26110212462-e26110212462, 2021.

APÊNDICES

Os códigos fonte desenvolvidos ao longo dessa pesquisa estão listados nos apêndices a seguir.

I. Código fonte para a construção dos mapas de contraste espacial LASCA

```
!pip install moviepy
!pip install opencv-python
import cv2 as cv
import numpy as np
np.seterr(divide='ignore', invalid='ignore')
import os
from matplotlib import pyplot as plt
from pathlib import WindowsPath
from moviepy.editor import *
PATH = '/content/drive/MyDrive/Lab/'
LISTA_MAPALASCA = []
count = 1
N = 30
stop = N
start = 0
vidcap = cv.VideoCapture(PATH+'6h/3_0.avi')
numFrames = int(vidcap.get(cv.CAP_PROP_FRAME_COUNT))
kernel = np.ones((2,2),np.uint8)
for x in range(1):
    vidcap.set(cv.CAP_PROP_POS_FRAMES, x)
    _, imgBGR = vidcap.read()
    imgRGB = cv.cvtColor(imgBGR, cv.COLOR_BGR2RGB)
    r, g, b = cv.split(imgRGB)
    imgR = r
    imgGray = cv.cvtColor(imgR, cv.COLOR_BGR2RGB)
    img = cv.GaussianBlur(imgR, (9, 9), 0)
    img = cv.medianBlur(img, 9)
    ret,thresh = cv.threshold(img,32,255,0)
    thresh = cv.morphologyEx(thresh, cv.MORPH_GRADIENT, kernel)
    thresh = cv.dilate(thresh,kernel,iterations = 5)
    plt.imshow(thresh)
    contours,hierarchy = cv.findContours(thresh, cv.RETR_EXTERNAL, cv.CHAIN_APPROX_NONE)
```

```

if len(contours)>0:
    cv.drawContours(imgRGB, contours, -1, (0, 255, 0), 5)
    c = max(contours, key = cv.contourArea)
    x,y,w,h = cv.boundingRect(c)
    cv.rectangle(imgRGB,(x,y),(x+w,y+h),(0, 0, 255),5)
    linStart = y
    linEnd = y+h
    colStart = x
    colEnd = x+w
    ROI = imgRGB[linStart:linEnd, colStart:colEnd]
    lin, col = ROI.shape[:2]
plt.imshow(ROI)
plt.show()
plt.imshow(imgGray[linStart:linEnd, colStart:colEnd])
plt.show()
while stop <= numFrames:
    for x in np.arange(start,stop):
        vidcap.set(cv.CAP_PROP_POS_FRAMES, x)
        _, imgBGR = vidcap.read()
        imgRGB = cv.cvtColor(imgBGR, cv.COLOR_BGR2RGB)
        r, g, b = cv.split(imgRGB)
        imgR = r
        imgGray = cv.cvtColor(imgR, cv.COLOR_BGR2RGB)
        ROI = imgR[linStart:linEnd, colStart:colEnd]
        x, y = ROI.shape[:2]
        ordem = 4
        lin = x // ordem
        col = y // ordem
        MAPALASCA = np.zeros((lin,col))
        for i in range(lin):
            for j in range(col):
                celula = ROI[i*ordem:i*ordem+ordem, j*ordem:j*ordem+ordem]
                media = celula.mean()
                w = (celula - media) ** 2
                dp = (w.sum() / (ordem*ordem - 1))**0.5
                MAPALASCA[i][j] = (dp/media)
        LISTA_MAPALASCA.append(MAPALASCA)
        plt.imshow(MAPALASCA, cmap='gist_ncar')
        plt.axis('off')
        plt.savefig(str(count) + "_lasca.png")

```



```

stop = stop + N
start = start + N
count += 1
figura = plt.figure(figsize=(20,20))
for i in range(25):
    figura.add_subplot(5, 5, i + 1)
    plt.imshow(LISTA_MAPALASCA[i], cmap='gist_ncar')
    plt.axis('off')
plt.show()
clipsLastca = []
i = 1
while i < count:
    nome_img = str(i)+'_lasca.png'
    clipLastca = ImageClip(nome_img).set_duration(0.50)
    clipsLastca.append(clipLastca)
    i=i+1
video_clipLastca = concatenate_videoclips(clipsLastca, method='compose')
video_clipLastca.ipython_display(width=360, fps=24)

```

Fonte: adaptado de SILVA (2007)

II. Código fonte para a construção dos mapas de contraste temporal LASTCA

```
vidcap = cv.VideoCapture(PATH+'0h/2_3.avi')
numFrames = int(vidcap.get(cv.CAP_PROP_FRAME_COUNT))
kernel = np.ones((2,2),np.uint8)
LISTA_MAPALASTCA = []
N = 120
stop = N
start = 0
count = 1
for x in range(1):
    vidcap.set(cv.CAP_PROP_POS_FRAMES, x)
    _, imgBGR = vidcap.read()
    imgRGB = cv.cvtColor(imgBGR, cv.COLOR_BGR2RGB)
    r, g, b = cv.split(imgRGB)
    imgR = r
    imgGray = cv.cvtColor(imgR, cv.COLOR_BGR2RGB)
    img = cv.GaussianBlur(imgR, (9, 9), 0)
    img = cv.medianBlur(img, 9)
    ret,thresh = cv.threshold(img,32,255,0)
    thresh = cv.morphologyEx(thresh, cv.MORPH_GRADIENT, kernel)
    thresh = cv.dilate(thresh,kernel,iterations = 5)
    plt.imshow(thresh)
    contours,hierarchy = cv.findContours(thresh, cv.RETR_EXTERNAL,
cv.CHAIN_APPROX_NONE)
    if len(contours)>0:
        cv.drawContours(imgRGB, contours, -1, (0, 255, 0), 5)
        c = max(contours, key = cv.contourArea)
        x,y,w,h = cv.boundingRect(c)
        cv.rectangle(imgRGB,(x,y),(x+w,y+h),(0, 0, 255),5)
        linStart = y
        linEnd = y+h
        colStart = x
        colEnd = x+w
        ROI = imgRGB[linStart:linEnd, colStart:colEnd]
        lin, col = ROI.shape[:2]
    plt.imshow(ROI)
    plt.show()
    plt.imshow(imgGray[linStart:linEnd, colStart:colEnd])
    plt.show()
```

```

while stop <= numFrames:
    IM = np.zeros((lin, col), dtype=int)
    I2 = np.zeros((lin, col), dtype=int)
    I = np.zeros((lin, col), dtype=int)
    for x in np.arange(start, stop):
        vidcap.set(cv.CAP_PROP_POS_FRAMES, x)
        _, imgBGR = vidcap.read()
        imgRGB = cv.cvtColor(imgBGR, cv.COLOR_BGR2RGB)
        r, g, b = cv.split(imgRGB)
        imgR = b
        ROI = imgR[linStart:linEnd, colStart:colEnd]
        imgGray = cv.cvtColor(ROI, cv.COLOR_BGR2RGB)
        lin, col = ROI.shape[:2]
        I = ROI
        IM = IM + I
    IM = IM / N
    for x in np.arange(start, stop):
        vidcap.set(cv.CAP_PROP_POS_FRAMES, x)
        _, imgBGR = vidcap.read()
        imgRGB = cv.cvtColor(imgBGR, cv.COLOR_BGR2RGB)
        r, g, b = cv.split(imgRGB)
        imgR = b
        ROI = imgR[linStart:linEnd, colStart:colEnd]
        imgGray = cv.cvtColor(ROI, cv.COLOR_BGR2RGB)
        lin, col = ROI.shape[:2]
        I = ROI
        I2 = I2 + ((I - IM) ** 2)
    MAPALASTCA = np.sqrt(I2) / IM
    LISTA_MAPALASTCA.append(MAPALASTCA)
    plt.imshow(MAPALASTCA, cmap='gist_ncar')
    plt.axis('off')
    plt.savefig(str(count) + "_lastca.png")
    stop = stop + N
    start = start + N
    count += 1
figura = plt.figure(figsize=(20,20))
for i in range(25):
    figura.add_subplot(5,5,i + 1)
    plt.imshow(LISTA_MAPALASTCA[i], cmap='gist_ncar')
    plt.axis('off')

```

```
plt.show()
clipsLastca = []
i = 1
while i < count:
    nome_img = str(i)+'_lastca.png'
    clipLastca = ImageClip(nome_img).set_duration(0.50)
    clipsLastca.append(clipLastca)
    i=i+1
video_clipLastca = concatenate_videoclips(clipsLastca, method='compose')
video_clipLastca.ipynon_display(width=360, fps=24)
```

Fonte: adaptado de SILVA (2007)

III. Código fonte para reconhecimento dos grãos germinados com a RNC

```
!pip install tensorflow
import os
import matplotlib.pyplot as plt
import tensorflow as tf
dataset_dir = os.path.join(os.getcwd(), PATH)
dataset_train_dir = os.path.join(dataset_dir, 'train')
dataset_train_normal_len = len(os.listdir(os.path.join(dataset_train_dir, 'normal')))
dataset_train_defect_len = len(os.listdir(os.path.join(dataset_train_dir, 'defect')))
dataset_validation_dir = os.path.join(dataset_dir, 'validation')
dataset_validation_normal_len = len(os.listdir(os.path.join(dataset_validation_dir, 'normal')))
dataset_validation_defect_len = len(os.listdir(os.path.join(dataset_validation_dir, 'defect')))
print('Train normal: %s' % dataset_train_normal_len)
print('Train defect: %s' % dataset_train_defect_len)
print('Validation normal: %s' % dataset_validation_normal_len)
print('Validation defect: %s' % dataset_validation_defect_len)
image_width = 50
image_height = 50
image_color_channel = 3
image_color_channel_size = 255
image_size = (image_width, image_height)
image_shape = image_size + (image_color_channel,)
batch_size = 900
epochs = 100
learning_rate = 0.0001
class_names = ['normal', 'defect']
dataset_train = tf.keras.preprocessing.image_dataset_from_directory(
    dataset_train_dir,
    image_size = image_size,
    batch_size = batch_size,
    shuffle = True
)
dataset_validation = tf.keras.preprocessing.image_dataset_from_directory(
    dataset_validation_dir,
    image_size = (image_width, image_height),
    batch_size = batch_size,
    shuffle = True
)
```

```

dataset_validation_cardinality = tf.data.experimental.cardinality(dataset_validation)
dataset_validation_batches = dataset_validation_cardinality // 3
dataset_test = dataset_validation.take(dataset_validation_batches)
dataset_validation = dataset_validation.skip(dataset_validation_batches)
print('Validation Dataset Cardinality: %d' % tf.data.experimental.cardinality(dataset_validation))
print('Test Dataset Cardinality: %d' % tf.data.experimental.cardinality(dataset_test))
autotune = tf.data.AUTOTUNE
dataset_train = dataset_train.prefetch(buffer_size = autotune)
dataset_validation = dataset_validation.prefetch(buffer_size = autotune)
dataset_test = dataset_validation.prefetch(buffer_size = autotune)
def plot_dataset(dataset):
    plt.gcf().clear()
    plt.figure(figsize = (10, 10))
    for features, labels in dataset.take(1):
        for i in range(9):
            plt.subplot(3, 3, i + 1)
            plt.axis('off')
            plt.imshow(features[i].numpy().astype('uint8'))
            plt.title(class_names[labels[i]])
plot_dataset(dataset_train)
plot_dataset(dataset_validation)
plot_dataset(dataset_test)
data_augmentation = tf.keras.models.Sequential([
    tf.keras.layers.experimental.preprocessing.RandomFlip('horizontal'),
    tf.keras.layers.experimental.preprocessing.RandomFlip('vertical'),
    tf.keras.layers.experimental.preprocessing.RandomRotation(0.90),
])
def plot_dataset_data_augmentation(dataset):
    plt.gcf().clear()
    plt.figure(figsize = (10, 10))
    for features, _ in dataset.take(1):
        feature = features[0]
        for i in range(9):
            feature_data_augmentation = data_augmentation(tf.expand_dims(feature, 0))
            plt.subplot(3, 3, i + 1)
            plt.axis('off')
            plt.imshow(feature_data_augmentation[0] / image_color_channel_size)
plot_dataset_data_augmentation(dataset_train)
rescaling = tf.keras.layers.experimental.preprocessing.Rescaling(
    1. / (image_color_channel_size / 2.), offset = -1, input_shape = image_shape)

```

```

model_transfer_learning = tf.keras.applications.MobileNetV2(
    input_shape = image_shape,
    include_top = False,
    weights = 'imagenet'
)
model_transfer_learning.trainable = False
model_transfer_learning.summary()
early_stopping = tf.keras.callbacks.EarlyStopping(monitor = 'loss', patience = 6)
model = tf.keras.models.Sequential([
    rescaling,
    data_augmentation,
    model_transfer_learning,
    tf.keras.layers.GlobalAveragePooling2D(),
    tf.keras.layers.Dropout(0.2),
    tf.keras.layers.Dense(1, activation = 'sigmoid')
])
model.compile(
    optimizer = tf.keras.optimizers.Adam(learning_rate = learning_rate),
    loss = tf.keras.losses.BinaryCrossentropy(),
    metrics = ['accuracy']
)
model.summary()
history = model.fit(
    dataset_train,
    validation_data = dataset_validation,
    epochs = epochs,
    callbacks = [
        early_stopping
    ]
)
def plot_model():
    accuracy = history.history['accuracy']
    val_accuracy = history.history['val_accuracy']
    loss = history.history['loss']
    val_loss = history.history['val_loss']
    epochs_range = range(epochs)
    plt.gcf().clear()
    plt.figure(figsize = (15, 8))
    plt.subplot(1, 2, 1)
    plt.title('Training and Validation Accuracy')

```

```

plt.plot(epochs_range, accuracy, label = 'Training Accuracy')
plt.plot(epochs_range, val_accuracy, label = 'Validation Accuracy')
plt.legend(loc = 'lower right')
plt.subplot(1, 2, 2)
plt.title('Training and Validation Loss')
plt.plot(epochs_range, loss, label = 'Training Loss')
plt.plot(epochs_range, val_loss, label = 'Validation Loss')
plt.legend(loc = 'lower right')
plt.show()
plot_model()
dataset_test_loss, dataset_test_accuracy = model.evaluate(dataset_test)
print('Dataset Test Loss:  %s' % dataset_test_loss)
print('Dataset Test Accuracy: %s' % dataset_test_accuracy)
def plot_dataset_predictions(dataset):
    features, labels = dataset_test.as_numpy_iterator().next()
    predictions = model.predict_on_batch(features).flatten()
    predictions = tf.where(predictions < 0.5, 0, 1)
    print('Labels:  %s' % labels)
    print('Predictions: %s' % predictions.numpy())
    plt.gcf().clear()
    plt.figure(figsize = (10, 10))
    for i in range(9):
        plt.subplot(3, 3, i + 1)
        plt.axis('off')
        plt.imshow(features[i].astype('uint8'))
        plt.title(class_names[predictions[i]])
plot_dataset_predictions(dataset_test)
def predict(image_file):
    image = tf.keras.preprocessing.image.load_img(image_file, target_size = image_size)
    image = tf.keras.preprocessing.image.img_to_array(image)
    image = tf.expand_dims(image, 0)
    prediction = model.predict(image)[0][0]
    print('Prediction: {0} | {1}'.format(prediction, ('defect' if prediction < 0.5 else 'normal')))

```

Fonte: adaptado de *TensorFlow* (2023)

IV. Código fonte para avaliação do desempenho da RNC na identificação do defeito germinado

```
from sklearn.metrics import confusion_matrix, ConfusionMatrixDisplay

# 0 defeito, 1 normal

valores_reais = [1, 0, 1, 1, 1, 0, 1, 1, 1, 1, 1, 1, 1, 1, 1, 0, 1, 1, 1, 1, 1, 1, 0, 1, 1, 1, 0, 1, 1, 1, 1,
1, 1, 1, 1,
1, 1, 1, 0, 1, 1, 1, 1, 1, 0, 0, 0, 1, 1, 1, 1, 1, 1, 0, 1, 1, 0, 0, 1, 1, 0, 1, 1, 0, 0, 0, 1, 1, 1, 0, 1,
1, 0, 1, 1, 0, 1, 0, 0, 1, 1, 1, 0, 1, 1, 1, 1, 1, 1, 0, 1, 1, 0, 1, 1, 1, 1, 1, 0, 1, 0, 1, 1, 1, 1, 1,
1, 1, 0, 0, 1, 0, 1, 0, 1, 1, 1, 1, 1, 0, 1, 1, 0, 0, 1, 1, 0, 0, 1, 1, 0, 1, 1, 1, 0, 1, 1, 1, 0, 1, 1, 1, 1,
1, 1, 1, 1, 0, 1, 1, 1, 1, 0, 0, 1, 0, 1, 1, 1, 1, 1, 0, 1, 1, 1, 1, 1, 1, 0, 1, 1, 1, 0, 1, 0, 1]

valores_preditos = [1, 0, 1, 1, 1, 0, 1, 1, 1, 1, 1, 1, 1, 1, 1, 0, 1, 1, 1, 1, 0, 1, 1, 0, 0, 1, 1, 0, 1, 1, 1,
1, 1, 1, 1, 1,
1, 1, 1, 0, 1, 1, 1, 1, 1, 1, 0, 0, 0, 1, 1, 1, 1, 1, 1, 0, 1, 1, 0, 0, 1, 1, 0, 0, 0, 1, 1, 1, 0, 1,
1, 1, 1, 1, 0, 1, 1, 1, 1, 1, 1, 0, 1, 1, 1, 1, 1, 1, 1, 0, 1, 1, 1, 1, 1, 1, 1, 0, 1, 0, 1, 1, 1, 1, 1,
1, 1, 1, 1, 1, 0, 1, 0, 1, 1, 1, 1, 1, 0, 1, 1, 0, 1, 1, 1, 1, 0, 1, 1, 0, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1,
1, 1, 1, 1, 0, 1, 1, 1, 1, 0, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 0, 1, 0, 1]

cm = confusion_matrix(valores_reais, valores_preditos, labels=[0,1])
cm_display = ConfusionMatrixDisplay(cm).plot()
```

Fonte: adaptado de *SkLearn* (2023)

V. Código fonte para avaliação do desempenho da RNC considerando diferentes tempos de germinação

```
def LblPercentage(metrics):
    for i in metrics:
        h = i.get_height()
        ax.annotate('{}'.format(h),
                    xy = (i.get_x()+i.get_width()/2,h),
                    xytext = (0,3),
                    textcoords = 'offset points',
                    ha = 'center',
                    fontsize = 10)

x = np.arange(4)
tempoGerminacao = ['6h', '12h', '24h', 'Todos períodos']
acuracia = [61.11, 77.77, 78.22, 92.33]
sensibilidade = [76.23, 88.15, 98.14, 98.21]
width = 0.35
fig, ax = plt.subplots()

metrics_accuracy = ax.bar(x-0.2, acuracia, width, color='blue')
metrics_sensitivity = ax.bar(x+0.2, sensibilidade, width, color='purple')

plt.xticks(x, tempoGerminacao, fontsize = 10)
ax.set_xlabel('Tempos de germinação', fontsize = 10)
ax.set_ylabel('Porcentagem (%)', fontsize = 10)
ax.set_title('Performance das Métricas', fontsize = 10)
plt.legend(["Acurácia", "Sensibilidade"], fontsize = 10)
LblPercentage(metrics_accuracy)
LblPercentage(metrics_sensitivity)

plt.plot(x, acuracia, marker = 'o', linestyle='--', color='cyan')
plt.plot(x+0.4, sensibilidade, marker = 'o', linestyle='--',
color='pink')
plt.show()
```

Fonte: adaptado de *Matplotlib* (2023)