

**MINISTÉRIO DA EDUCAÇÃO**  
**UNIVERSIDADE FEDERAL DE PELOTAS**  
**FACULDADE DE AGRONOMIA “ELISEU MACIEL”**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA E TECNOLOGIA DE**  
**SEMENTES**

**TESE**



**INTELIGÊNCIA ARTIFICIAL E IMAGENS TERMOGRÁFICAS INFRAVERMELHA**  
**PARA AVALIAÇÃO DE SECAGEM DE SEMENTES**

Pelotas, RS

2022

ROMÁRIO DE MESQUITA PINHEIRO

**INTELIGÊNCIA ARTIFICIAL E IMAGENS TERMOGRÁFICAS INFRAVERMELHA  
PARA AVALIAÇÃO DE SECAGEM DE SEMENTES**

Tese apresentada a Universidade Federal de Pelotas, como parte das exigências do programa de Pós-Graduação em Ciências e Tecnologia de Sementes, para a obtenção do título de Doutor em Ciências.

Orientadora: Profa. Dra. Gizele Ingrid Gadotti

Pelotas, RS

2022

Universidade Federal de Pelotas / Sistema de Bibliotecas  
Catalogação na Publicação

P654i Pinheiro, Romário de Mesquita

Inteligência artificial e imagens termográficas  
infravermelha para avaliação de secagem de sementes /  
Romário de Mesquita Pinheiro ; Gizele Ingrid Gadotti,  
orientadora. — Pelotas, 2022.

100 f.

Tese (Doutorado) — Programa de Pós-Graduação em  
Ciência e Tecnologia de Sementes, Faculdade de Agronomia  
Eliseu Maciel, Universidade Federal de Pelotas, 2022.

1. Aprendizado de máquina. 2. Termografia. 3. Qualidade  
de sementes. I. Gadotti, Gizele Ingrid, orient. II. Título.

CDD : 631.521

Elaborada por Gabriela Machado Lopes CRB: 10/1842

## Romário de Mesquita Pinheiro

### INTELIGÊNCIA ARTIFICIAL E IMAGENS TERMOGRÁFICAS INFRAVERMELHA PARA AVALIAÇÃO DE SECAGEM DE SEMENTES

Defesa de tese, como requisito parcial, para obtenção do grau de doutor em Ciências, Programa de Pós-Graduação em Ciência e Tecnologia de Sementes, Universidade Federal de Pelotas.

Data da Defesa: 24/10/2022

Banca examinadora:

---

Gizele Ingrid Gadotti (Orientadora)  
Doutora em Ciências pela UFPel

---

Jerffeson Araujo Cavalcante  
Doutor em Ciências pela UFPel

---

Ricardo Scherer Pohndorf  
Doutor em Engenharia e Ciência de Alimentos pela FURG

---

Geri Eduardo Meneghello  
Doutor em Ciências pela UFPel



Documento assinado eletronicamente por **GIZELE INGRID GADOTTI, Professor do Magistério Superior**, em 24/10/2022, às 18:17, conforme horário oficial de Brasília, com fundamento no art. 4º, § 3º, do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **GERI EDUARDO MENEGHELLO, Engenheiro Agrônomo**, em 24/10/2022, às 18:21, conforme horário oficial de Brasília, com fundamento no art. 4º, § 3º, do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Jerffeson Araujo Cavalcante, Usuário Externo**, em 24/10/2022, às 18:21, conforme horário oficial de Brasília, com fundamento no art. 4º, § 3º, do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **RICARDO SCHERER POHNDORF, Professor do Magistério Superior**, em 24/10/2022, às 18:21, conforme horário oficial de Brasília, com fundamento no art. 4º, § 3º, do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site [http://sei.ufpel.edu.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](http://sei.ufpel.edu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **1913108** e o código CRC **69E78CC8**.

---

Adamo de Sousa Araújo  
Doutor em Ciências pela UFPel (Suplente)

“A nossa vida é um teste, que a gente tem que saber  
decifrar os enigmas e seguir em frente  
com cada resposta nova”.

(Ana Davis)

À família e aos amigos

Pelo apoio na conquista deste desafio.

Dedico

## **AGRADECIMENTOS**

Como expressar um sentimento de amor e carinho nesse momento para agradecer e explicar a grandeza de certos gestos. Este trabalho é fruto de muitos sentimentos, e também discussões. Mais do que listar pessoas e agradecê-las, gostaria que cada uma delas soubesse que foram determinantes para que o meu objetivo fosse alcançado.

Primeiramente agradeço a Deus por me conceder vida e saúde e por ter me permitido vivenciar esta experiência e colocar em meu caminho todas estas pessoas tão especiais, cada uma a seu modo.

Aos meus pais, Antônia de Mesquita e Elojo Pinheiro e meus irmãos Clescio e Ana Katrine pelo amor, carinho e por sempre estarem me apoiando mesmo distante.

À Universidade Federal de Pelotas que nestes quatros anos se tornou minha segunda casa.

Ao Laboratório de Agrotecnologia, com toda sua equipe pelo apoio na realização dos trabalhos.

A todos os docentes pelos conhecimentos transmitidos.

Ao Coordenador do PPG C&T de Sementes, Tiago Pedó pelo apoio concedido.

A minha orientadora, Dra. Gizele Ingrid Gadotti, pela oportunidade e conhecimentos transmitidos. Como também sua dedicação e profissionalismo na condução dos trabalhos realizados.

Aos meus amigos e colegas, Andrea Martins, Rafael Timm, Jacques Barcelos, Robson Marques, Fernanda Sedrez e Celso Sena pelas contribuições tanto nas atividades laboratoriais, quanto de disciplinas e também a todos os serviços prestados. E pelos bons e maus momentos vividos durante esses anos.

A Empresa fabricante do equipamento agrícola estudado, pelo auxílio do uso dos dados e da câmera termográfica e pelo vínculo deixado.

A minha família e a todos que de alguma forma contribuíram para a realização deste trabalho.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001

## RESUMO

PINHEIRO, R. M. **Inteligência artificial e imagens termográficas infravermelha para avaliação de secagem de sementes.** 2022. 100 f. Tese (Doutorado em Ciências) - Programa de Pós-Graduação em Ciências e Tecnologia de Sementes, Faculdade de Agronomia Eliseu Maciel - Universidade federal de Pelotas, Pelotas, 2022.

Reduzir perdas e aumentar a produtividade são dois fatores que precisam ser superados. A ciência e tecnologia de sementes consiste no papel importante para impulsionar o alto rendimento produtivo das culturas agrícolas. Com isso, busca-se através de inserção da tecnologia, resultados promissores com métodos eficazes na solução dos problemas gerados na cadeia sementeira. O objetivo deste trabalho foi avaliar o uso de inovações tecnológicas como aprendizado de máquina não supervisionado no desempenho de equipamento agrícola e a termografia infravermelha no processo de secagem de sementes. Para avaliar o desempenho de secagem em secadores por inteligência artificial foram coletados dados de secadores convectivos, com base em: i) total de secadores trabalhados; ii) tempo de duração de secagem (horas); iii) percentual de umidade na entrada e saída do produto (%); e iv) diferenças de umidade entres ambas (%). Foi utilizado modelos de treinamento *Filtered Clusterer*, *K-means* e filtro *Resample*, para agrupar dados com base em suas similaridades. O algoritmo juntamente com os filtros demonstrou ser eficiente na classificação não supervisionada, identificando e minimizando similaridade inter-cluster do sistema fixo definindo em classes distintas dentro do conjunto de dados. Para analisar os efeitos da eficiência de secagem com o uso de secador com formato octógono e dimensões 6,65 x 2,50 x 3,25 m, com capacidade de 17 t, foi utilizado uma câmera térmica na faixa espectral de 7,5-13  $\mu\text{m}$ , sendo considerado a radiação por três frações dependentes do comprimento de onda, absorvância (a), refletividade (r) e transmitância (t), onde foi possível identificar falhas problemáticas de temperatura durante a secagem. Conclui-se que ambas as tecnologias são promissoras para avaliar o processo de secagem facilitando a interpretação dos dados e a detecção de termogramas.

**Palavras-chave:** aprendizado de máquina, qualidade de sementes, termografia.



## ABSTRACT

PINHEIRO, R. M. **Artificial intelligence and infrared thermographic images for evaluation of seed drying**. 2022. 65 f. Thesis (Doctorate in Science) - Graduate Program in Seed Science and Technology, Faculty of Agronomy Eliseu Maciel - Federal University of Pelotas, Pelotas, 2022.

Reducing losses and increasing productivity are two factors that need to be overcome. Seed science and technology are essential in boosting the high productive yield of crops. With this, it is sought through the insertion of technology, promising results with practical methods in solving the problems generated in the seed chain. The objective of this work was to evaluate the use of technological innovations through machine learning and infrared thermography in the seed drying process. Data from convective dryers were collected to evaluate the drying performance in machine learning dryers, based on: i) the total number of dryers worked; ii) drying duration time (hours); iii) the percentage of moisture at the entrance and exit of the product (%), and iv) differences in humidity between both (%). Filtered Clusterer, K-means, and Resample filter training models were used to group data based on their similarities. The algorithm and the filters proved efficient in unsupervised classification, identifying and minimizing the fixed system's inter-cluster similarity and defining distinct classes within the data set. To analyze the effects of drying efficiency using a thermal camera with a spectral range of 7.5-13  $\mu\text{m}$ , radiation by three wavelength-dependent fractions, absorbance (a), reflectivity (r), and transmittance (t). The dryer measuring 6.65 x 2.50 x 3.25 m was used, with a 17 t octagon shape. Where it was possible to identify problematic temperature failures during drying, it is concluded that both technologies are promising for evaluating the drying process, facilitating data interpretation, and detecting thermograms.

**Keywords:** machine learning, seed quality, thermography.

## LISTA DE TABELAS

### CAPÍTULO III

- Tabela 1** - Resultados do agrupamento de dados para os sistemas de secagem de acordo com as variáveis estabelecidas em modelo padrão de avaliação. T. secadores é o total de secadores necessário para execução do trabalho, conforme predição do algoritmo, 2022 ..... 65
- Tabela 2** - Mineração de dados realizada com dois sistemas (fixo e móvel) juntos utilizando filtro Resample e os algoritmos "*Filtered Clustereer*" + "*K-Means*". T. secadores é o total de secadores necessário para execução do trabalho, conforme predição do algoritmo. .... 68
- Tabela 3** - Mineração de dados realizada com o sistema 1 (fixo) utilizando filtro "*Resample*". T. secadores é o total de secadores necessário para execução do trabalho, conforme predição do algoritmo" ..... 69
- Tabela 4** - Mineração de dados realizada com o sistema 2 (móvel) utilizando filtro "Resample". T. secadores é o total de secadores necessário para execução do trabalho, conforme predição do algoritmo ..... 70

### CAPÍTULO IV

- Tabela 1** - Oscilações de temperaturas em três diferentes gradientes de imagem termográficas capturadas durante o processo de secagem. T. = temperatura; V. S. = velocidade de saída do ar entre a camada de sementes; T. S. = tempo de secagem; V. E.= velocidade de entrada do ar na câmara de secagem. Pd= pressão dinâmica, F= Fluxo e V. C. velocidade dentro da câmara de secagem. ....81

## LISTA DE FIGURAS

### CAPÍTULO I

**Figura 1** - O processo de segmentação e seleção da técnica de aprendizado de máquinas gerando uma árvore de decisão e rede neural em lotes de sementes. .... 37

## **CAPÍTULO II**

**Figura 1** - Esquema para preparação de amostra para sementes de espécies não conhecidas e utilização do processamento de imagens como ferramentas para inteligência artificial..... 50

## **CAPÍTULO III**

**Figura 1** - Esquematização dos sistemas de secagem, onde o equipamento agrícola fica instalado. (fonte: adaptação de Daurana Oliveira) ..... 62

**Figura 2** - Representa a proximidade entre os pares de dados calculados com diferentes noções de distância entre as variáveis. [0] diferença entre secador fixo e móvel ou cluster 1 e cluster 2: [1] total de secadores (unidade); [2] duração de secagem (h); [3] umidade de entrada (%); [4] umidade saída (%) e [5] diferença de secagem entre o sistema fixo e móvel (%) ..... 66

**Figura 3** - Comportamento dos dados com divisão inter-cluster em relação ao agrupamento no sistema fixo ( $K_1$  e  $K_2$ ) e móvel ( $K_3$ ). [0] diferença entre secador fixo e móvel ou cluster 1 e cluster 2: [1] total de secadores (unidade); [2] duração de secagem (h); [3] umidade de entrada (%); [4] umidade saída (%) e [5] diferença de secagem entre o sistema fixo e móvel (%).  $d$ - Distância dimensional entre os pontos;  $K$ - Agrupamento.. 67

## **CAPÍTULO IV**

**Figura 1** - Desenho esquemático do secador avaliado neste estudo, (A) secador com corte lateral em azul são os complementos de entrada de ar nas turbinas; (B) corte do secador mostrando saída de dentro do secador para as turbinas; (C) corte com vista para a descarga e janelas para manutenção no interior do secador; (E) vista superior..... 76

- Figura 2** - Comportamento do gradiente de temperatura (°C) em secadores fixo durante o seu funcionamento..... 78
- Figura 3** - Representação da imagem térmica conforme as dimensões do equipamento agrícola, no qual apresenta temperaturas médias (média de pixels) em diferentes pontos do secador durante o processo de secagem. A parte horizontal compreende o comprimento (HS= parte horizontal superior, HM = Horizontal mediana e HI= Horizontal inferior) e vertical se relaciona com a altura do secador (parte vertical frontal= VF entrada de ar pelas turbinas, vertical mediana = VM e vertical posterior = VP, compreende a região de descarga dos produtos) ..... 80
- Figura 4** - Imagens termográficas capturas em secador convectivo. A- Maior pico de temperatura com 36,9 °C; B- Identificação de vários pontos de temperatura média, mínima e máxima; C- Identificação do ponto mais homogêneo..... 83
- Figura 5** - Diferença na temperatura quando direcionado a câmera térmica para o objeto alvo específico, estando no mesmo ponto: (A) a câmera direcionada para capturar a parede e na (B) foi especificamente as sementes demarcada no retângulo..... 84

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	15
<b>2 REVISÃO DE LITERATURA</b> .....	18
2.1 AGRICULTURA DIGITAL.....	18
2.2 INOVAÇÕES TECNOLÓGICA NO SETOR DE SEMENTES.....	19
2.3 INOVAÇÃO NO PROCESSO DE SECAGEM DE SEMENTES .....	21
2.4 INTELIGÊNCIA ARTIFICIAL NA AVALIAÇÃO DE PÓS-COLHEITA DE SEMENTES .....	23
2.5 MODELOS DE APRENDIZADO DE MÁQUINAS .....	24
2.6 MINERAÇÃO DE DADOS.....	25
2.7 IMAGEM TÉRMICA NA AVALIAÇÃO DA QUALIDADE DE SEMENTES ..	26
<b>3 CAPÍTULO I - INTELIGÊNCIA ARTIFICIAL NA AGRICULTURA COM APLICABILIDADE NO SETOR SEMENTEIRO</b> .....	28
3.1 INTRODUÇÃO .....	28
3.2 METODOLOGIA .....	29
3.3 REFERENCIAL TEÓRICO .....	30
3.4 CONSIDERAÇÕES FINAIS.....	38
3.5 REFERÊNCIAS .....	38
<b>4 CAPÍTULO II - PROCESSAMENTO DE IMAGENS COMO FERRAMENTA IMPORTANTE PARA INTELIGÊNCIA ARTIFICIAL NO SETOR DE SEMENTES</b> .....	43
4.1 INTRODUÇÃO .....	43
4.2 METODOLOGIA .....	45
4.3 REFERENCIAL TEÓRICO.....	45
4.4 CONSIDERAÇÕES FINAIS.....	52
4.5 REFERÊNCIAS.....	53
<b>5 CAPÍTULO III - TÉCNICA DE MINERAÇÃO DE DADOS NÃO SUPERVISIONADO NO PROCESSO DE SECAGEM DE SEMENTES</b> .....	60
5.1 INTRODUÇÃO .....	60
5.2 MATERIAL E METODOS .....	61
5.3 RESULTADOS.....	65

5.4 DISCUSSÃO.....	73
<b>6 CAPÍTULO IV - IMAGEM TÉRMICA PARA DETECTAR O PROCESSO DE SECAGEM DE GRÃOS E SEMENTES .....</b>	<b>74</b>
6.1 INTRODUÇÃO .....	74
6.2 MATERIAL E METODOS .....	75
6.3. RESULTADOS.....	77
6.4 DISCUSSÃO.....	84
6.5 CONCLUSÃO.....	87
<b>7 CONSIDERAÇÕES FINAIS .....</b>	<b>88</b>
<b>REFERÊNCIAS.....</b>	<b>89</b>

## 1 INTRODUÇÃO

Novas soluções de visão computacional combinadas com algoritmos de inteligência artificial podem ajudar a reconhecer padrões de qualidade das etapas de pós-colheita, reduzindo a subjetividade e otimizando o processo de análise no setor sementeiro. Nos últimos anos, as inovações tecnológicas permitiram avanços significativos no diagnóstico da qualidade das sementes (BATISTA et al., 2022). Cada setor agrícola está conquistando espaço para atuação em todo o processo de produção (PINHEIRO et al., 2021), pois, a tecnologia chega ao campo, de tal forma que todas as áreas agrícolas necessitam se atualizar e entender os processos digitais, que acompanham a agricultura inteligente. O setor de sementes também busca se inserir nesta modernização, pois os aspectos que envolve os setores sementeiros como, colheita, tratamento, secagem, armazenamento, semeadura e testes de controle de qualidade, gera uma demanda alta de dados que são incapazes para uma análise rápida e robusta de forma imediata.

A inovação tecnológica é frequentemente considerada como uma das principais forças motrizes para o aumento da produtividade, rentabilidade, segurança alimentar e sustentabilidade do setor agrícola (GONZALES et al., 2021). As soluções baseadas em inteligência artificial permitiram que os agricultores produzissem mais com menos insumos e até melhoraram a qualidade final, garantindo também um lançamento mais rápido das safras no mercado (TALAVIYA et al., 2020). Os dados coletados para a etapa de secagem geralmente são os tradicionais, limitados em informações de temperatura e umidade. Assim, na etapa seguinte, no armazenamento são realizadas as análises de qualidade e por consequência se poderá entender os danos, por isso a condição ideal de secagem das sementes é fundamental neste processo. As informações de conjunto de dados cada vez mais aumenta com a demanda de testes e análises, por isso os agricultores e tomadores de decisões nesta área precisam de ferramentas avançadas para ajudá-los a tomar decisões rápidas que afetarão a qualidade dos rendimentos agrícolas (CEDRIC et al., 2022).

As mudanças climáticas têm sido um fenômeno importante nas últimas décadas em todo o mundo. Esses eventos levam a maiores níveis de variabilidade nas condições em que ocorre a produção agrícola, gerando maior incerteza no planejamento, bem como variabilidade nos resultados (LIPPER et al., 2022). Um

impacto das mudanças climáticas tem sido observado na qualidade da produção agrícola (BHADOURIA et al., 2019), A alta produtividade pode ser maximizada quando a cultura é exposta a uma faixa de temperatura ótima do meio ambiente e diminui progressivamente à medida que a temperatura aumenta acima dessa faixa (HATFIELD et al., 2011). Mudanças na temperatura, dióxido de carbono atmosférico (CO<sub>2</sub>) e a frequência e intensidade de climas extremos podem ter impactos significativos no rendimento das culturas, afetando o desenvolvimento e crescimento das espécies agrícolas (MILONI et al., 2019), assim gerando sementes de baixa qualidade. Com isso a chegada da tecnologia de *big data* e internet das coisas (IoT) levou a novas ferramentas analíticas, como aprendizado de máquina, que se provaram eficientes em muitas áreas, como medicina, finanças, biologia e agricultura. De tal forma, que os investimentos e as adesões em inteligência artificial são crescentes, especialmente para tornar os processos mais rápidos, desde fábricas, transportes, setor imobiliário e no agronegócio (MORETI et al., 2021).

A partir desses fatos fica cada vez mais importante garantir a qualidade de sementes, que possa superar as mudanças ambientais, especialmente o aquecimento global e a variabilidade climática, pois causa impacto adverso no futuro agrícola. A produção de sementes de alta qualidade começa no campo, de modo que as demais etapas visam manter sua qualidade. Há grande preocupação em interpretar e tomar decisões sobre eficiência de secagem, beneficiamento, armazenamento e análises fisiológicas, pois esses produzem grande quantidade de dados gerados, garantindo informações robustas sobre o vigor dos lotes de sementes destinados a comercialização.

Os testes realizados para o controle de qualidade de sementes geram vários conjuntos de dados, por isso é importante realizar os padrões de análise da qualidade de sementes, uma vez que os rendimentos das culturas dependem de diferentes fatores, como clima, água, solo, uso de fertilizantes e manejo. Porém, existe uma infinidade de cultivares agrícolas no mercado, no qual são realizados os testes de viabilidade e vigor (Germinação e Tetrazólio), gerando uma quantidade elevada de informações, de modo a impossibilidade de uma interpretação rápida e eficaz. O auxílio de aplicação da estatística tradicional em muitas vezes, não se aplica. De acordo com Bali e Singla (2021), os modelos estatísticos são empregados para prever a eficiência da cultura, que é demorado e tedioso.



Os processos de inovação podem ser complexos e variar muito, o que os torna imprevisíveis (STRÆTE et al., 2022). Por isso, é crucial identificar as funções de suporte na mineração de dados que têm impacto para estimular diferentes métodos de aplicação no setor sementeiro. De modo que, se consiga aprimorar as funções de apoio podendo ter impacto no nível social para estimular a transição do sistema tecnológico. Uma questão importante é como isso pode ser feito de forma eficiente e responsável. Há também uma grande vontade e ambição, tanto na área sementeira como indústria do agronegócio, para que a inovação na agricultura aumente em âmbito, e atribui-se importância à resposta aos desafios mencionados, com resultados confiáveis e promissores fortalecendo os sistemas agrícolas no desenvolvimento rural.

Para o setor de sementes, a necessidade de saber mais sobre o envolvimento em processos torna-se particularmente um desafio a interpretação no uso do aprendizado de máquina, mineração de dados na incorporação das atividades de pesquisa e inovação. Um modelo de aprendizado de máquina pode ser descritivo ou preditivo, dependendo do problema e das questões de pesquisa (VAN KLOMPENBURG et al., 2020). Enquanto, os modelos descritivos são usados para obter conhecimento dos dados coletados e explicar o que aconteceu, os modelos preditivos são usados para fazer previsões no futuro (ALPAYDIN, 2010). Como o uso da inteligência artificial que chegou recentemente na agricultura para auxiliar a tomada de decisão (CEDRIC et al., 2022).

As mais recentes soluções de problemas de pós-colheita, tem se aplicado nos aspectos de previsão de germinação, qualidade fisiológica, estratificação de lotes e processamento de imagem de sementes com inteligência artificial, nas quais auxiliam na tomada de decisão da semeadura e colheita garantindo sua qualidade. Importante mencionar, que o uso de termografia infravermelha também se apresenta como inovação na avaliação das etapas mencionadas e se torna vantajosa, porque as medições são quantitativas e prontamente implementadas. Neste contexto, a termografia infravermelha pode ser usada para fornecer informações úteis sobre as características dos fluxos contendo meios participantes (temperatura, vapor, calor etc.), sendo empregada em vários ambientes (BLUNK, 2021).

Atualmente, a análise de defeitos mais comum é feita manualmente por um especialista na área. Os resultados das inspeções de equipamentos de secagem sem amostragem é algo promissor, no qual, o uso de algumas técnicas para a

automatização é geralmente representado por meio de imagens, assim evitando contato direto com o produto. A termografia infravermelha não necessita de meios de acoplamento facilitando a produção e velocidade das varreduras (PEDRAYES et al., 2022). A medição das propriedades ópticas das sementes tem sido usada com sucesso para a determinação simultânea de várias características de qualidade e para inspeção automática e avaliação de segurança (ELMASRY et al., 2019).

Diante do exposto, esse trabalho teve como objetivo avaliar inserção da inteligência artificial através do aprendizado de máquina não supervisionado no desempenho de equipamento agrícola e a termografia infravermelha no processo de secagem de sementes

## **2. REVISÃO DE LITERATURA**

### **2.1 AGRICULTURA DIGITAL**

Nos últimos anos, o conhecimento descoberto a partir dos processos de análise de dados é o mais diversificado e dinâmico na agricultura digital (NGO et al., 2022). A revolução na agricultura digital está se aproximando, baseando-se em dados agrícolas com fundamentação em tecnologia para aumentar a eficiência do fornecimento de alimentos (ROTZ et al., 2019). Existem diversas tecnologias digitais projetadas fundamentalmente para atender o setor agrícola (por exemplo, robótica agrícola), mas também existem soluções digitais que não são projetadas principalmente para o setor agrícola, mas amplamente utilizadas neste domínio econômico (por exemplo, drones). Devido às terminologias 'tecnologias agrícolas', 'agricultura digital', 'tecnologias digitais' ou 'soluções digitais' tem-se a empregabilidade de uso dos termos específico para cada setor (BENYAM et al., 2021).

Em outras palavras, a agricultura digital se beneficiou significativamente da mineração de dados, análise de dados ou, no termo mais geral, “ciência de dados”. Vários estudos baseados em dados foram realizados nos mais diversificados elementos agrícolas, incluindo solo, clima, rendimento das culturas, doenças, fertilizantes etc., com o objetivo de derivar modelos que governam o fenômeno por trás dos processos agrícolas, previsão ou otimização do uso de recursos (NGO et al., 2022). Relatórios recentes postulam que a agricultura digital é a chave para o

crescimento econômico e sistemas alimentares resilientes (CHANDRA; COLLIS, 2021).

Porém, a agricultura digital depende da capacidade dos sistemas de transmitir dados com outros sistemas habilitados. Lacunas de infraestrutura básica, como acesso a eletricidade ou redes de telefonia móvel, são uma das grandes barreiras (PORCIELLO et al., 2022). A agricultura enfrenta desafios que demandam a transição do setor. Por isso, apoiar a invenção para estimular a inovação é importante (STRÆTE et al., 2022). Com isso a condição de analisar e interpretar as informações geradas pelas ciências de dados deve acontecer através de estudos. Dentro da área de sementes a inovação tecnológica com a ciência de dados revelam desafios que precisam ser aprimorados. Considerando esses desafios, a revolução digital no campo está se aproximando cada vez mais, com o propósito de aumentar a eficiência de produção e gerar tomada de decisão rápida sobre as etapas pré-estabelecidas em cada setor agrícola.

Na modernização e automação da agricultura, existe a necessidade de uma tecnologia que seja mais facilmente compreendida, implementada e utilizada pelos agricultores (PINHEIRO et al., 2022). A demanda por equipamentos agrícolas que requerem menor esforço humano e tempo se torna necessário cada vez mais. Além disso, devido ao desenvolvimento da Internet das coisas e da robótica, os equipamentos agrícolas também se tornaram mais inteligentes (KUMAR, ASHOK, 2021). A facilidade de uso da tecnologia associada a inteligência artificial pode permitir respostas rápidas, fornecendo resultados confiáveis com boa acessibilidade, atraindo profissionais e leigos (PINHEIRO et al., 2022).

## 2.2 INOVAÇÕES TECNOLÓGICAS NO SETOR DE SEMENTES

Além dos equipamentos agrícolas que são inseridos no mercado com a mais moderna tecnologia, tanto para a semeadura, preparo de solo e colheita, a área de pós-colheita de sementes também acompanha sua tendência para melhorias do setor. Com os avanços na tecnologia computacional e coleta de dados, surgiu uma necessidade essencial de desenvolver novos modelos para previsão ou predição de rendimento agrícolas (SARIJALOO et al., 2021). Os modelos de predição e previsão são apresentados para garantir melhor desempenhos das atividades na área de sementes. Modelos de rendimento, incluindo algoritmos de aprendizado de máquina,

métodos de mineração de dados e modelos de rede neural profunda são alvos de estudos (LIAKOS et al., 2018; CHLINGARYAN et al., 2018; VLONTZOS e PARDALOS, 2017; MUCHERINO et al., 2009; PAPAJORGJI e PARDALOS, 2014, GADOTTI et al., 2022).

Métodos rápidos e não destrutivos de detecção da qualidade da semente devem, portanto, ser desenvolvidos para a agricultura e a indústria de produção de sementes (RAHMAN; CHO, 2016). Ferramentas inovadoras para análise de qualidade fisiológica de sementes tem sido investigada, tais como técnicas de raio-X e processamento de imagens (SHNEIDER et al., 2012; SHARMA et al., 2020; MEDEIROS et al., 2020a; MONTEIRO et al., 2021). Além destas, o efeito da tecnologia de ultrassom sobre o rendimento de fenólicos totais e a atividade antioxidante da semente de *Dimocarpus longan* Lour foram investigados (Wen et al., 2012). A qualidade da semente é uma caracterização de múltiplos componentes, incluindo pureza varietal e analítica, capacidade de germinação, vigor, desempenho e uniformidade (PINHEIRO et al., 2022). Alguns testes de qualidade dependem de inspeções físicas e químicas, bem como visuais, que são caras e demoradas. Além disso, as inspeções visuais são subjetivas e difíceis de reproduzir (BOELT et al., 2018). Por isso, a necessidade de recorrer ao auxílio da tecnologia que pode ser inovada ou adaptada as que já se encontram no mercado.

Outra tecnologia seria a de revestimento de sementes, com filme envolvendo a aplicação de uma camada fina (geralmente até 5% do peso da semente) de agente de revestimento benéfico diretamente na superfície do tegumento da semente (PEDRINI et al., 2017). O adesivo líquido (filme) é usado para dissolver/dispensar ingredientes ativos antes da aplicação nas sementes (JAVED et al., 2022). Diferentes estudos abordam a tecnologia de revestimento para garantir bom estabelecimento da cultura, além de aprimorar germinação das sementes sobre efeitos de estresses bióticos e abióticos (WILLENBORG et al., 2004; QIU et al., 2005; AVELAR et al., 2012; NAVEED et al., 2014; ACCINELLI et al., 2016; ROCHA et al., 2019a; ROCHA et al., 2019b; PIRI et al., 2019; QIU et al., 2020; JAVED e AFZAL, 2020). Além de impacto antifúngico da emulação da tecnologia de plasma contra fungos fitopatogênicos para garantir a qualidade de sementes (AHMAD et al., 2022).

A edição do genoma é outra inovação que permite a tecnologia de produção de sementes híbridas de última geração. Sendo que a tecnologia de reprodução

híbrida permite a produção bem-sucedida de sementes híbridas classificáveis a partir de linhagens e mantenedores genes estéreis masculino, no entanto, requer várias etapas laboriosas e complicadas (QI et al., 2020). Os mesmos autores projetaram uma estratégia simples de produção de sementes híbridas de próxima geração que aproveita a tecnologia CRISPR/Cas9. A edição de vários genes de glutelina pode gerar um novo germoplasma de arroz com teor de glutelina bastante reduzido, como também, o melhoramento eficiente de germoplasma de arroz com baixo teor de glutelina pela via edição CRISPR/Cas9 (CHEN et al., 2022).

Além das demais que já vem sendo abordado no decorrer desta revisão, no qual, fornecem alguns aprendizados importantes sobre as tendências do uso e aplicabilidade na ciência e tecnologia de sementes.

### 2.3 INOVAÇÃO NO PROCESSO DE SECAGEM DE SEMENTES

Diferentes técnicas de secagem são utilizadas para o armazenamento a longo prazo de produtos agroalimentares. Métodos para manter a germinabilidade e a tolerância à dessecação em sementes são estratégia para conservação de várias espécies que tem reprodução via sexuada. Secagem por ar quente, secagem por radiação infravermelha, secagem a vácuo e liofilização são aplicadas para obter os produtos secos desejados na fabricação de alimentos (CHAO et al., 2022), sendo que o primeiro método é o mais utilizado para secagem de grãos e sementes em grande escala, os demais por se tratar de tecnologia própria para secagem de gêneros alimentícios, podem ser testados no processo de secagem de sementes, principalmente para espécies olerícolas e ornamentais, no qual, o volume não é tão elevado.

A secagem por ar quente é identificada como um método de secagem de baixo custo e de fácil controle. No entanto, pode ocorrer degradação de compostos bioativos, perda de cor e alteração das estruturas (YAO et al., 2020). A secagem por radiação infravermelha é uma técnica inovadora que possui inúmeras vantagens, como maior eficiência energética, menor tempo de secagem e produto de melhor qualidade. Os raios infravermelhos são transferidos diretamente para o centro da matéria-prima por meio de vibrações moleculares, sem aquecer o ar circundante ou degradar moléculas na superfície do material (RATSEWO et al., 2020). Uma alternativa à secagem em alta temperatura é a vácuo, que pode prevenir danos

térmicos e oxidativos em compostos bioativos sob pressões subatmosféricas. No entanto, a secagem a vácuo geralmente resulta em maior tempo de secagem (PAPOUTSIS et al., 2017). Além destas, a técnica de liofilização remove a umidade dos produtos congelados sob sublimação a vácuo, tratamento a baixa temperatura e remoção de oxigênio. Assim, o produto geralmente mantém melhor qualidade, mas as desvantagens notáveis da liofilização são o alto custo de capital e energia (LENAERTS et al., 2018).

Embora essas técnicas se tenham visto para área de alimentos. Um estudo de Shammi et al. (2022), analisaram um secador desumidificador vertical a vácuo para secagem de sementes de arroz de modo que podem ser adequados para pequenos agricultores. O desempenho do secador foi avaliado em termos de taxa, capacidade, eficiência e custo de secagem. E concluíram que o equipamento atende aos requisitos dos pequenos agricultores, uma vez que eles podem utilizar o ano todo em qualquer condição do clima. E deixando de secar sementes de arroz ou outra cultura no sol.

Uma inovação abordada por Namjoo et al. (2022), sobre onda ultrassônica de alta potência, como tecnologia de campo não térmico e físico, teria bom potencial para fortalecer um sistema convencional de secagem de ar quente sem impacto ambiental e sem deterioração qualitativa. Pesquisas apontam a aplicação indireta de ultrassom (no ar) durante a secagem convectiva (ABDOLI et al., 2018; SZADZIŃSKA et al., 2019; MARTINS et al., 2019; GHANBARIAN et al., 2020; DIBAGAR et al., 2020; NUKULWAR e TUNGIKAR, 2021). A distribuição de vibração e o padrão de sonicação são controlados e alta intensidade de nível acústico é recebida pelas sementes durante o processo de desidratação (NAMJOO et al., 2022). O uso de ultrassom diminui o tempo de secagem, porém ainda recomenda-se estudar cada caso em diferentes espécies.

Portanto, a aplicação de alguns desse métodos para secagem de sementes requer cuidados e também estudos que possam aprimorar sua utilização em culturas de alto rendimento e volume. Principalmente, os efeitos de diferentes métodos de secagem sobre compostos bioativos, capacidade de atividades antioxidantes e enzimáticas, ainda não são claros, de modo que possa impactar na qualidade da semente.

## 2.4 INTELIGÊNCIA ARTIFICIAL NA AVALIAÇÃO DE PÓS-COLHEITA DE SEMENTES

A Inteligência artificial está encontrando cada vez mais aplicações na agricultura à medida que avança. Simultaneamente, a Internet das Coisas (IoT) e a Quarta Revolução Industrial (Indústria 4.0) permitem o desenvolvimento de novas tecnologias e ideias (SHAIKH et al., 2022). Na pós-colheita, a etapa de secagem é o componente principal para garantir o armazenamento visando preservar a qualidade das sementes, portanto todas as atividades estão interligadas no processo de produção de sementes. Com isso a demanda associada aos padrões de qualidade é criteriosa e, tem demandado respostas rápidas para gerenciamento do negócio de sementes.

Os desafios da robótica, dispositivos IoT e aprendizado de máquina, bem como os papéis da mineração de dados, inteligência artificial e sensores usados na agricultura, são componentes auxiliares nas etapas de produção e qualidade de sementes. Nesse contexto, o desenvolvimento de marcadores para avaliar os testes de viabilidade, sanidade e vigor das sementes é particularmente importante para as empresas sementeiras em seu controle interno de qualidade de sementes. Para isso, novas metodologias têm sido exploradas para monitorar a qualidade fisiológica de sementes utilizando imagens obtidas por meio de sensores ópticos robustos (GALLETTI et al., 2020) e mineração de dados.

Nos últimos anos, com o desenvolvimento de tecnologias emergentes de testes não destrutivos, vários métodos têm sido aplicados de forma não destrutivas de vigor de sementes, como espectroscopia de infravermelho próximo (SON et al., 2004), espectroscopia de ressonância magnética nuclear (KRISHNAN et al., 2003), espectroscopia de Fourier, espectroscopia Raman (SEO et al., 2016), Imagem de raios-X (AHMED et al., 2018), imagem hiperespectral com aprendizado de máquina (JIN et al., 2022), aprendizado de máquina não supervisionado (NOSRATI et al., 2018); análise de imagem multivariada e de aprendizado profundo de máquina (MUKASA et al., 2022) entre outros.

Esses métodos são utilizados para prever ou avaliar efeitos da qualidade de sementes, no qual se aplica na etapa de controle interno de qualidade fisiológica das sementes. Com isso, o aprimoramento e automação destas etapas está em futuro

próximo com aplicabilidade real das informações geradas nestas etapas de pós-colheita.

## 2.5 MODELOS DE APRENDIZADO DE MÁQUINA

A escolha correta de modelos ajuda a solucionar melhor o problema enfrentado, principalmente para a área de sementes. Essas técnicas fornecem um conjunto de ferramentas aplicada para diferentes campos de atuação (TAGARAKIS et al., 2013). Por isso, as técnicas de aprendizado de máquina têm sido amplamente aplicadas na determinação da qualidade de produtos agrícolas e alimentícios (SAHA; MANICKAVASAGAN, 2021). Rede neural artificial (Artificial Neural Network-ANN), lógica Fuzzy (Fuzzy logic-FI), árvores de decisão, Naïve Bayes, agrupamento de k-means, máquinas de vetor de suporte (support vector machines-SVM), floresta aleatória (Random forest-RF) (REHMAN et al., 2019), além de regressão linear múltipla (multiple linear regression-MLR) e multicamadas perceptron (multi-layer perceptron-MLP), são as técnicas investigadas na aplicação do setor de sementes (PINHEIRO et al., 2021).

O aprendizado profundo é outro subdomínio do aprendizado de máquina que pode demonstrar desempenho superior na classificação de dados em diferentes produtos (ZHOU et al., 2019). Essa técnica pode ser interessante devido ao contínuo aumento da produção de sementes, além de novas cultivares, necessitando de mais testes de controle de qualidade. Esses últimos geram uma infinidade de informações necessitando que seus dados passem por avaliações robustas. Essas ferramentas contribuem para aumento de receita e produtividade. No atual cenário pós-colheita é crescente o uso dessas tecnologias (LUTZ et al., 2022). As operações agrícolas em grande escala e velocidade exigirá uma transição significativa e rápida sobre as inovações tecnológicas inseridas em laboratórios e campos de produção.

A aprendizagem de máquina apresenta duas formas mais comum na base de treinamentos de algoritmos, sendo: supervisionada e não supervisionada. No aprendizado supervisionado, os dados de treinamento têm rótulos de saída, mas no aprendizado não supervisionado, os dados não têm rótulos de saída (CINAR, 2020). O método não supervisionado apresenta camadas gerando um subgrupo nos dados de trabalho. A maioria das aplicações de aprendizado de máquina em estudos com sementes depende de técnicas supervisionada. De acordo com Wang et al. (2022),



são usados para desenvolver modelos preditivos para estimar valores desconhecidos e explicar relações entre fenômenos. O aprendizado de máquina é uma tecnologia essencial para integrar estatísticas, ciência de dados e tecnologia. As técnicas de aprendizado de máquina usam seleção e classificação de recursos para selecionar importantes métodos e classificar conjuntos de dados com base neles (JAIN; CHOUDHARY, 2022).

## 2.6 MINERAÇÃO DE DADOS

As técnicas de mineração de dados são utilizadas para prever fenômenos e/ou analisar informações elevadas de vários conjuntos de dados através de uma filtragem, que também são apresentadas para fornecer o melhor entendimento sobre o futuro. Como por exemplo: a previsão do rendimento das culturas é a principal preocupação dos agricultores; por isso, alguns parâmetros ambientais são influenciados na produtividade que influencia a política de mercado que deve ser encontrada pelas técnicas de mineração de dados (PRABHAKARAN et al., 2021).

Os dados obtidos a partir de pesquisas experimentais auxiliam no processo de tomada de decisão por meio de aprendizado de máquina e inteligência artificial. As aplicações das etapas de mineração de dados tornam os dados agrícolas brutos mais significativos (JAIN; CHOUDHARY, 2022). A análise de mineração de dados usada em muitos campos traz uma variedade de benefícios ao seu uso na área sementeira. Os algoritmos de mineração de dados e aprendizado de máquina tornaram a previsão fácil e precisa nos setores de aplicação.

A técnica de mineração realiza o processo exploratório do conjunto de dados à procura de padrões consistentes, englobando todos os algoritmos existentes e a aprendizagem de máquina para classificar conjuntos de dados com base nos algoritmos pré-definidos, testando, predizendo ou prevendo o fenômeno.

Para determinar o aprimoramento da inteligência artificial sempre será necessário um volume de dados (RAHMAN et al. 2018). Avaliar esses conjuntos de dados é uma tarefa não tão fácil; consiste em várias etapas. Atualmente, os sistemas de apoio à decisão agrícola podem fornecer uma previsão razoável da produtividade, mas ainda é desejável um melhor desempenho na previsão do rendimento das culturas (ZHAO; JUSTINA, 2020). Assim como para o setor de

sementes, pois ainda existe muitos desafios que precisam ser solucionados e gerar informações de qualidade nos dados obtidos é fundamental.

## 2.7 IMAGEM TÉRMICA NA AVALIAÇÃO DA QUALIDADE DE SEMENTES

A qualidade das sementes utilizadas na agricultura e silvicultura está intimamente ligada à qualidade fisiológica (DUMONT et al., 2015), o desenvolvimento de métodos não destrutivos de alto rendimento para classificar as sementes é primordial. A possibilidade de avaliar a qualidade das sementes por meio de imagens multiespectrais tem sido demonstrada em diferentes culturas, como; soja (BAEK et al., 2019), feijão-caupi (ELMASRY et al., 2019) e outras seis espécies, sendo; *Acacia seyal*, *Galega orientalis*, *Glycyrrhiza glabra*, *Medicago sativa*, *Melilotus officinalis* e *Thermopsis lanceolata* (HU et al., 2020); tomate e cenoura (GALLETTI et al., 2020) e amendoim (OLIVEIRA et al., 2022).

Análise de imagens térmicas converte o padrão de radiação de uma amostra com base nas diferenças de temperatura na análise e diagnóstico do objeto (ALI et al., 2020). Eles, afirmam que o auxílio de técnicas avançadas de imagens, como a termografia proporciona a comparação entre diferentes regiões de imagens térmicas o que é útil e conveniente na interpretação dos dados. Existem dois tipos de sensores infravermelhos que são comumente usados para o sistema de imagem térmica, que são sensores térmicos e de fótons (DU et al., 2020). O fundamento básico da imagem térmica tem se baseado no objeto que libera radiação infravermelha na região do comprimento de onda do infravermelho de 0,75 até 100  $\mu\text{m}$  (DUARTE et al., 2014).

Diversos usos na indústria de sementes já são aplicados para avaliação de qualidade e caracterização de produtos (TIGABU et al., 2004; RUIZ-ALTISENT et al., 2010; SANKARAN et al., 2010). A termografia infravermelha média foi proposta como uma ferramenta para avaliação da viabilidade de sementes (KRANNER et al., 2010; KIM et al., 2013), enquanto imagens de infravermelho próximo podem ser usadas para determinar várias propriedades de sementes, como amido, proteína, água, teor de lignina (KIM et al., 2006; CEN; HE, 2007), para diferenciar cultivares e origens (ZHANG et al., 2012; GAO et al., 2013; KONG et al., 2013) ou para identificar sementes danificadas por insetos (SINGH et al., 2010).

Diversos estudos abordam os mais variados ramos como o uso não invasivo e destrutivo em sementes. Parâmetros morfológicos foram avaliados por processamento de imagens para caracterizar a emergência de raízes primárias na avaliação do vigor de sementes de tomate (OLIVEIRA et al., 2021). As técnicas de análise de imagens se tornaram mais confiáveis com o desenvolvimento de microscópios de fluorescência e alta resolução ganhando o interesse de todos os setores (LODDO et al., 2021).

Várias metodologias com processamento de imagem estão sendo implantadas no setor sementeiro. Como a mensuração de comprimento de parte aérea e também a área foliar de plântulas de arroz através de processamento de imagens com ótimas condições de técnicas convencionais na avaliação do vigor de sementes de arroz (BRUNES et al., 2019), apresentaram ótimo desempenho. Outro estudo com sementes de soja, visou avaliar e identificar danos nas sementes conseguindo segregar sementes esverdeadas com uso de RGB. E ainda para a separação de sementes enrugadas sob dano por umidade foi possível segregar com acerto de 74,3% as sementes com médio a alto grau de danos por umidade (MONTEIRO et al., 2021).

A imagem térmica é uma técnica não destrutiva de monitoramento para detectar temperaturas com base na radiação infravermelha emitida por um objeto alvo. A avaliação por imagem térmica fornece dados importantes sobre a dimensão, distribuição de calor e análise estrutural, permitindo avaliar objetos de grandes proporções, sem precisar ter o contato direto. O que a torna uma ferramenta ideal para avaliação do processo de secagem de sementes nos equipamentos agrícolas, uma vez que é necessário coletar amostras para averiguar temperatura e teor de água, de modo que estas informações precisam ser rápidas e precisas com finalidade de agilizar os processos de tomada de decisão.

A identificação de novas possibilidades e recursos para o desenvolvimento tecnológico de sistemas de secagem de sementes por meio de inteligência artificial e imagem termográfica são fatores importante na tomada de decisão em tempo real e até mesmo identificando falhas que podem ser corrigidas de imediato.

*Os capítulos um e dois apresentados a seguir é uma compilação na íntegra dos artigos de revisão de literatura publicado em revistas científicas sobre inteligência artificial no setor sementeiro e o outro aborda processamento de imagens com inteligência artificial. Os artigos foram publicados antes do término desta escrita. E atendendo a sugestão da banca foram inseridos para compor esta tese. As normas seguem de cada revista.*

### **3 CAPÍTULO I - INTELIGÊNCIA ARTIFICIAL NA AGRICULTURA COM APLICABILIDADE NO SETOR SEMENTEIRO**

**Artigo publicado na revista Diversitas Journal, ISSN 2525-5215. DOI: [https://doi.org/10.48017/Diversitas\\_Journal-v6i3-1857](https://doi.org/10.48017/Diversitas_Journal-v6i3-1857)**

#### **3.1 INTRODUÇÃO**

A inteligência artificial (IA) tem chamado atenção em todos os ramos de estudos e na agricultura não é diferente. Cada setor agrícola está conquistando espaço para atuação em todo o processo de produção. O aprendizado das máquinas tem impactado todos os setores da economia, especialmente pela capacidade de análise e de interpretação de dados em velocidade superior à do ser humano, de tal forma que os investimentos e as adesões em IA são crescentes, especialmente para tornar os processos mais rápidos, desde fábricas, transportes, setor imobiliário e no agronegócio (MORETI et al., 2021).

A tecnologia chega ao campo e com ela surge a necessidade de obter respostas rápidas e eficientes, onde a capacidade intelectual humana não é capaz de suprir a rapidez da demanda de um volume alto de dados que precisam ser destinados corretamente na execução das atividades. Este aspecto envolve os setores sementeiros (semeadura, colheita, processamento, tratamento, armazenamento e testes de controle de qualidade), principalmente quando se tem uma demanda alta de análise, exemplo vários lotes de sementes para realizar avaliação do controle de qualidade e ao mesmo tempo destinar sua finalidade, seja para sementes ou grãos (comercialização). Estes lotes precisam passar por alguns testes de controle de qualidade (germinação, emergência, envelhecimento acelerado, condutividade elétrica, teste frio, teor de água e etc) no qual vai garantir informações seguras sobre a qualidade das sementes.

E para interpretar todas as informações dos testes com uma demanda alta de análise dos lotes fica impossível a mente humana. As tecnologias baseadas em IA ajudam a melhorar

a eficiência em todos os ramos de estudos e também a gerenciar os desafios enfrentados nas indústrias, incluindo os campos do setor agrícola, como o rendimento da safra, irrigação, detecção de conteúdo do solo, monitoramento de safra, capina e estabelecimento da cultura (KIM et al., 2008). De acordo com Talaviya et al. (2020), as soluções tecnológicas baseadas em IA permitiram que os agricultores produzissem mais com menos insumos e até melhoraram a qualidade da produção, garantindo também um lançamento mais rápido das safras no mercado.

A inteligência artificial permite aos agricultores e produtores reunir quantidade elevada de dados, analisá-los todos e fornecer aos agricultores soluções para muitos problemas ambíguos, além de fornece uma maneira mais inteligente na tomada de decisão rápida e eficiente, resultando em melhor custo-benefício para os agricultores (PANPATTE, 2018). O setor agrícola depende de ideias inovadoras e avanços tecnológicos para ajudar a aumentar a produtividade e alocar melhor os recursos (SINGH et al., 2021).

Então, o objetivo com este artigo consiste em retratar os desafios e as soluções mais evidentes no uso da IA na agricultura e especificar as formas de utilização desta atividade intelectual no setor sementeiro.

### **3.2 METODOLOGIA**

Usou-se uma metodologia dedutiva, de caráter exploratório, fundamentada em pesquisa bibliográfica. Este trabalho revisa pesquisas anteriores e atuais sobre o uso e a aplicação de inteligência artificial na agricultura acompanhado de seus efeitos no setor sementeiro, mostrando em qual seguimento existe estudos dentro da ciência de sementes. Poucos estudos foram encontrados abordando sobre ensaios diretamente ligados aos tipos de aprendizados de máquinas e sua evolução na cadeia sementeira. Neste contexto, foi feita uma abordagem com maior enfoque na influência da inteligência artificial no uso da agricultura geral e seus efeitos sobre os algoritmos testados para classificar componentes agrícolas. E também foram destacados alguns trabalhos que retrata algoritmos utilizado na área sementeira.

As palavras-chave utilizadas na coleta de literatura para esta revisão foram “aprendizado de máquinas em sementes”, “inteligência artificial na agricultura”, “inteligência artificial em sementes”, “algoritmos estatísticos”, “máquinas do futuro na agricultura”, “agricultura do futuro” “modelos de algoritmos”, “árvore de decisão” e “redes neurais”. Bancos de dados computacional, agricultura de precisão e agricultura (todos os bancos de dados, CAB Abstracts e Global Health, Medline, Pubmed, Web of Science, BIOSIS Citation

Index, Science Direct, Current Content Connect, Google Scholar, Scielo, Frontiers, e Springer Link) foram pesquisados entre fevereiro e março de 2021.

Especificamente, aprendizado de máquinas em sementes e inteligência artificial na agricultura relataram trabalhos empregados nos últimos 20 anos (1999–2021), como suas técnicas de modelagem e seus domínios de pesquisa para solucionar os mais variados problemas encontrados, foram considerados prioritários. Os artigos com abrangência sobre métodos de uso e aprendizados de máquinas aplicado a inteligência artificial no setor sementeiro foram prioritários, o estado em que os experimentos foram realizados, o tipo de ensaio utilizado, a modelagem testada e a forma de como a técnica computacional de aplicação mostrava a eficiência do aprendizado das máquinas, foram considerados na filtração.

O Science Direct foi filtrado usando ‘pesquisa Science direct’ (inteligência artificial na agricultura com enfoque em sementes) e (aprendizado de máquinas em sementes) - em vista dos retornos de títulos >25 - e outros filtros foram aplicados a outras bases de dados conforme necessário. Todos os documentos considerados estavam em inglês e foram traduzidos para o português.

### **3.3 REFERENCIAL TEÓRICO**

Na literatura para inteligência artificial aplicado no setor de sementes, ainda existe uma abordagem superficial quanto ao aprendizado de máquinas em vários segmentos da área sementeira. No presente trabalho, apresentamos pesquisas atuais que estão sendo desenvolvidas neste setor, que possibilitam a aplicabilidade nos mais diversos tipos de dados de um campo de produção agrícola (sementeiro). A literatura tem abordado técnicas de visão computacional e imagem multiespectral para classificação de danos, viabilidade, fenotipagem, espécies de fungos, teste de pureza física, previsão de germinação, produção e predição de ranqueamento de lotes em sementes. Este último, ainda são necessários maiores aprimoramento para detectar a validação eficaz de um tanto de variáveis que surge na pós-colheita, uma vez, validado pode minimizar custos no controle de qualidade de sementes para os laboratórios.

E também são apresentados diversos modelos de técnicas para aprendizado de máquinas de acordo com a necessidade de modelagem dos dados. Essa abordagem com imagem em sementes envolve aspectos fenotípicos como seus parâmetros de refletância, cor, tamanho e textura correspondentes. Os algoritmos de aprendizagem mais utilizados na inteligência artificial nesse setor agrícola é o de rede neural e árvore de decisão. Sendo que o

primeiro, tem chamado mais atenção dos pesquisadores em obter respostas por meio de classificação por multicamadas, no qual, ele trabalha os dados brutos escondidos agrupando-os e classificando-os e simula conexões de um cérebro humano.

## **INTELIGÊNCIA ARTIFICIAL REVOLUÇÃO DO FUTURO NA AGRICULTURA**

Com aumento da população mundial, a demanda por alimento também cresce impulsionando a tecnologia no desenvolvimento agrícola. Dados demonstrado pela FAO (2009, 2017), apontam que as pessoas precisariam aumentar a produção geral de alimentos em cerca de 70% entre 2005/07 e 2050. No entanto, os produtores agrícolas em todo o mundo precisarão aumentar a quantidade de terras agrícolas ou aumentando a produtividade em terras agricultáveis existentes pelo uso de agricultura de precisão ou inteligente (ELFERINK; SCHIERHORN, 2016).

As tecnologias agrícolas atuais são geralmente desviadas para algoritmos de aprendizado de máquinas porque maximizam o rendimento da colheita com a minimização dos custos de insumos (REHMAN et al., 2019). O algoritmo de aprendizado de máquinas permite que o agricultor aprimore a seleção de plantio, previsão de safra, de rendimento, de doenças, do clima, preço mínimo de suporte e sistema de irrigação inteligente (KAUR, 2016). Como também colheita, seleção de lotes de sementes.

O uso de inteligência artificial envolve o processo de aprendizagem das máquinas. De acordo Jha et al. (2019), o único propósito do aprendizado de máquinas é alimentar um sistema de dados com experiências anteriores e dados estatísticos para que ela possa executar sua tarefa atribuída para resolver um problema específico. O aprendizado de máquinas é uma abordagem matemática para construir máquinas inteligentes.

IA é uma tecnologia emergente no campo da agricultura. Equipamentos e máquinas baseados em IA elevaram o sistema agrícola de hoje a um nível diferente (TALAVIYA et al., 2020). Dos padrões já visto na qualidade de produção agrícola. Esta tecnologia melhorou o desenvolvimento agrícola e melhorou o monitoramento, colheita, processamento e comercialização em tempo real (YANH et al., 2007).

As mais recentes tecnologias de sistemas automatizados que usam robôs, máquinas agrícolas e veículos aéreos não tripulados deram uma enorme contribuição no setor agroindustrial. Vários sistemas baseados em computador de alta tecnologia são projetados para determinar vários parâmetros importantes, como detecção de ervas daninhas, detecção de rendimento e qualidade da colheita e muitas outras técnicas (LIAKOS et al., 2018). E isso garante eficiência em todos os campos de atuação e/ou setores dentro da agricultura e ajuda

a gerenciar os desafios problemáticos enfrentados em um campo de produção e também nas indústrias.

As soluções tecnológicas baseadas em IA tem permitido que os agricultores aumentassem a produção com menos insumos e até melhoraram a qualidade da produção, garantindo lançamento mais rápido de produtos e/ou safras no mercado. Foi estimado que em 2020, os agricultores estariam usando 75 milhões de dispositivos conectados. Em 2050, espera-se que em média gere em média 4,1 milhões de pontos de dados todos os dias (TALAVIYA et al., 2020).

## **MODELOS DE TREINAMENTO PARA APRENDIZADOS DE MÁQUINAS**

O uso correto das técnicas de avaliação da seleção de modelo e de algoritmo é vital na pesquisa acadêmica de aprendizado de máquinas, bem como em muitos ambientes industriais (RASCHKA., 2018). A escolha correta de modelos ajuda a solucionar melhor o problema enfrentado. Portanto, a técnica de aprendizado de máquinas não são, e nunca serão, a solução para todos os problemas levantados pelos sistemas agrícolas. No entanto, essas técnicas fornecem um conjunto poderoso de ferramentas aplicadas para diferentes aplicações de campo (TAGARAKIS et al., 2013).

Técnicas de aprendizado de máquinas têm sido amplamente aplicadas na determinação da qualidade de produtos agrícolas e alimentícios (SAHA; MANICKAVASAGAN., 2021). Diferentes técnicas de aprendizado de máquinas como rede neural artificial (Artificial Neural Network-ANN), lógica Fuzzy (Fuzzy logic- FL), árvores de decisão, Naïve Bayes, agrupamento de k-means, máquinas de vetor de suporte (support vector machines- SVM), floresta aleatória (Random forest -RF), (REHMAN et al., 2019).

Também se destacam regressão linear múltipla (multiple linear regression - MLR) multicamadas perceptron (multi-layer perceptron - MLP), São a as mais utilizadas para aprendizado profundo de máquinas na área agrícola. Recentemente técnicas de modelagem não linear e dinâmica, têm sido empregadas para o desenvolvimento de modelos precisos em ciências ambientais (JAHANI., 2019a; 2019b; MOSAFFAEI et al., 2020).

Uma técnica destes modelos quando não treinados adequadamente, não apresenta consistência na validação dos dados apresentados, por isso, deve ser sempre coerente na aplicabilidade de cada treinamento para o aprendizado das máquinas. Em determinada situação Zhou et al. (2019), afirma que o aprendizado profundo é outro subdomínio do aprendizado de máquinas que pode demonstrar desempenho superior na classificação de



dados em diferentes produtos e estabelecer seu potencial para superar até mesmo humanos em alguns casos, quando treinados adequadamente.

A aprendizagem tem dois tipos principais: supervisionada e não supervisionada. No aprendizado supervisionado, os dados de treinamento têm rótulos de saída, mas no aprendizado não supervisionado, os dados não têm rótulos de saída (CINAR, 2020). A Rede neural artificial é uma das mais testadas nos mais diversos campos de aplicação, e na agricultura não é diferente.

## **INTELIGÊNCIA ARTIFICIAL NO SETOR DE SEMENTES E USO DE IMAGENS ESPECTRAIS**

A IA é aplicada por meio do gerenciamento informações e dados de uma cultura (visão computacional, aprendizado de máquinas, reconhecimento de padrões, robótica), a automação das operações agrícolas (PANT, 2016). E isso permite visualizar que a inteligência artificial é qualquer tecnologia que substituir o trabalho do homem, com maior eficácia.

Atualmente, a determinação da qualidade de sementes é feita manualmente por especialistas com testes de controle de qualidade ou em classificadores de grãos antes da fase de comercialização. Varela et al. (2020), verificaram através de ferramenta de software web que permite determinar o nível de qualidade de uma amostra de milho automaticamente a partir de uma imagem. Algoritmos de processamento de imagens foram implementados para corrigir distorções causadas principalmente pelo processo de captura. Foi utilizado o algoritmo de classificação K-Means.

Modelar as relações entre rendimento de sementes e seus componentes físicos (pureza, teor de umidade, tamanho, cor, densidade, danos mecânicos e causados por insetos), fisiológicos (vigor, germinação: está relacionado a capacidade de desempenhar funções vitais), sanitário (doenças, patógenos e fungos) e genético (pureza varietal, homogeneidade, potencial de rendimento, resistência a doenças e insetos, precocidade, estatura, estrutura de plantas), será útil para entender as características mais importantes com efeitos significativos na qualidade e produção de sementes.

Sobre esse aspecto citado acima, em estudo com sementes de Cártamo, Moslem et al. (2019), modelaram a produção de sementes através de redes neurais artificiais e regressão linear múltipla, onde avaliaram através de cinco modelos de redes neurais com diferentes algoritmos de aprendizagem funções de transferência, camadas ocultas e neurônios em cada camada, junto com modelo de regressão multilinear para prever a produção de sementes de

Cártamo. E também foi estudado por Saffariha et al. (2020), a previsão de germinação de sementes de *Salvia limbata* sob estresse. Onde, analisaram a germinação de sementes sob quatro estresses ecológicos: salinidade, seca, temperatura e pH, com aplicação de técnicas de modelagem de inteligência artificial, MLR e MLP.

A pureza das sementes é o fator mais importante na agricultura que determina o rendimento, a qualidade das sementes, o preço e a qualidade da safra. Arroz basmati na Índia apresentam diversas variedades e pesquisadores tem os desafios de selecionar a melhor variedade de alto rendimento e para isso, eles desenvolveram um servidor Web baseado na predição através de inteligência artificial que possa identificar as principais variedades de arroz basmati. Sendo baseado em imagens de sementes, para a identificação e diferenciação de dez variedades principais de arroz (SHARMA et al., 2020).

Os avanços nas técnicas de inteligência artificial vêm permitindo a combinação de métodos de análise de imagens e aprendizado de máquinas para diversos fins. Um estudo recente mostra a possibilidade de classificação das sementes de *Jatropha curcas* L. quanto à sua qualidade por meio do uso de dados fenotípicos obtidos por análise de imagens de raios-X com abordagens de aprendizado de máquinas (MEDEIROS et al., 2020a). Mahajan et al. (2018), avaliaram adequações de técnicas de imagem do tipo não-destrutiva e sem contato, como imagem visível e por raio-X, em testes de pureza física, viabilidade e vigor de sementes de soja. E Monteiro et al. (2021) investigaram danos e tons de cores em sementes (esverdeadas) de soja via processamento de imagens.

Um estudo com radiografia de sementes de espécies agrícolas foi investigada por Medeiros et al., 2020b, através de uma ferramenta chamada IJCropSeed. Foi desenvolvida na linguagem macro do software ImageJ® (SNHNEIDER et al., 2012). E nesta ferramenta foi inserido 24 culturas agrícolas que podem ser analisadas por radiografias, sendo: Repolho (*Brassica oleracea* var. capitata L.), Couve-flor (*Brassica oleracea* var. botrytis L.), Chicória (*Cichorium intybus* L.), Café (*Coffea* sp. L.), Feijão-caupi (*Vigna unguiculata* (L.) Walp.), Crambe (*Crambe abyssinica* Hochst. ex REFr.), Crotalaria (*Crotalaria juncea* L.), Lentilha (*Lens culinaris* Medik.), Milho (*Zea mays* L.), Melão (*Cucumis melo* L.), Feijão mungo (*Vigna radiate* (L.) R.Wilczek), Quiabo (*Abelmoschus esculentus* Moench), Cebola (*Allium cepa* L.), Grama Panicum (*Panicum maximum* Jacq), Mamão (*Carica papaya* L.), Ervilha (*Pisum sativum* L.), Pimenta (*Capsicum chinense* Jacq.), Sorgo (*sorghum bicolor* (L.) Moench), Soja (*Glycine max* (L.) Merr.), Girassol (*Helianthus annuus* L.), Milho doce (*Zea mays* L.), Tomate (*Solanum lycopersicum* L.), Grama urochloa (*Urochloa brizantha* (A.Rich.) RDWebster) e Trigo (*Triticum* L.). Sementes de Crambe foram utilizadas para desenvolver modelos de aprendizado de máquinas (MEDEIROS et al., 2020b).

A aplicação de ultrassom em sementes com modelagem de IA também é alvo de investigação. Wen et al. (2012), observaram o efeito do ultrassom sobre o rendimento de fenólicos totais e a atividade antioxidante da semente de *Dimocarpus longan* Lour. Onde uma rede neural multicamadas feed-forward treinada com um algoritmo de retropropagação de erro foi empregada para construir um modelo matemático.

Como na inspeção ocular, a classificação automática das sementes deve ser baseada no conhecimento do tamanho, forma, cor e textura da semente, esses podem ser critérios usados para identificar sementes de planta daninhas através de um classificador Naïve Bayes (GRANITTO et al., 2002). A aprendizagem por transferência é um método conveniente e eficiente para a adaptação do conhecimento (SALAKEN et al., 2018) A estratégia de aprendizagem por transferência foi aplicada para a detecção da autenticidade das sementes de milho, podendo até ser classificar suas características fenotípicas (tamanho, cor, forma e etc) e confirmar a autenticidade da variedade. Tu et al. (2021) estabeleceram que através de imagens RGB combinadas com aprendizado de máquinas ajuda a referenciar e identificar a autenticidade de sementes, por entrada de uma rede neural MLP. E isso pode ser aplicado a outras culturas.

Então, através de estudos de IA aliado com imagens multiespectrais podem ajudar na predição de determinados eventos que ocorre nas sementes em várias etapas de colheita e pós-colheita, por exemplo como danos (mecânico, por umidade, ataque de insetos) afeta o desempenho das sementes. E para identificar esses tipos de lesão, principalmente o mecânico que é mais comum ocorre durante a colheita e no beneficiamento é algo demorado e precisa de pessoal treinados. Então, Salami e Boelt (2019), investigaram através de imagem multiespectral diferentes tipos de danos em sementes de cenoura, no qual modelos de classificação foram utilizados. ElMasry et al. (2019), se basearam em análise multivariadas e imagem espectrais para classificar as sementes de feijão-caupi (*Vigna unguiculata*) em diferentes categorias de acordo com o envelhecimento, viabilidade, condição de plântulas a e velocidade de germinação.

Os métodos convencionais de detecção de fungos transmitidos por sementes são trabalhosos e demorados, exigindo analistas especializados para a caracterização de fungos patogênicos nas sementes. Imagem multiespectral combinada com visão de máquina foi usada como um método alternativo para detectar *Drechslera avenae* (Eidam) Sharif [*Helminthosporium avenae* (Eidam)] em sementes de aveia preta (*Avena strigosa* Schreb) (França-Filho et al., 2020). Neste caso, foi determinado um modelo de classificação com base na análise discriminante linear e através de comprimentos de onda dentro da faixa espectral de 365 a 970 nm. Olesen et al. (2015), também havia utilizado o mesmo comprimento de

ondas em sementes de mamona (*Ricinus cummunis* L.), em testes de qualidade com uso de imagens multiespectrais.

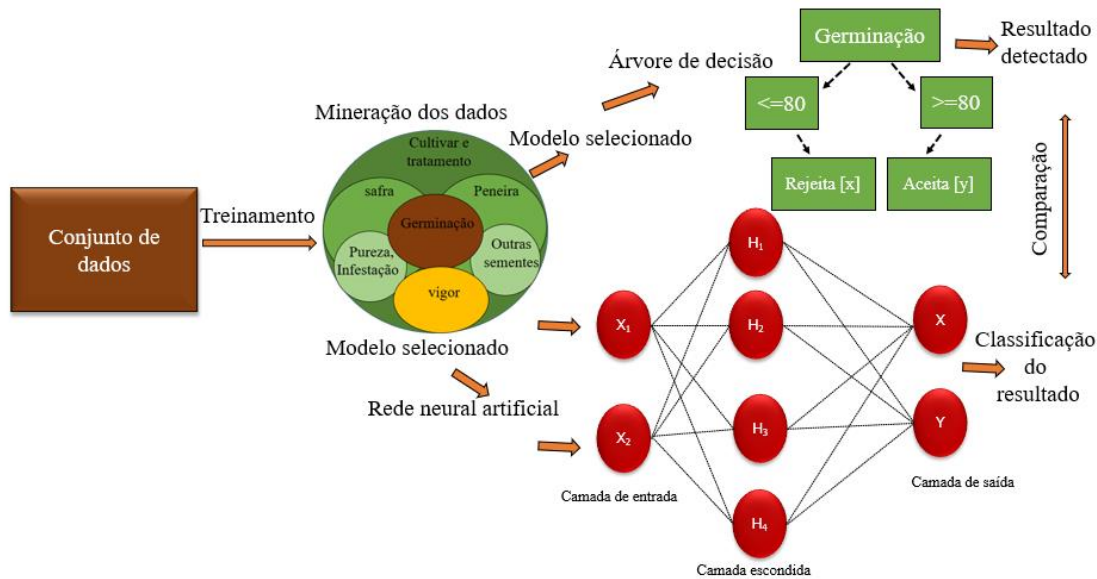
## **INTELIGÊNCIA ARTIFICIAL NO MODO DE APLICAÇÃO E NA SELEÇÃO DE LOTES DE SEMENTES**

Atualmente grande empresas e laboratórios apresentam uma demanda de dados sobre cultivares ou culturas agrícolas que precisam ser tomadas a decisão correta para comercialização, semeadura e colheita. No entanto, obter e repassar informações de uma infinidade de cultivares no mercado, requer cuidados e cautela. Pois uma demanda excessiva pode ocasionar erros de informações e levar sérios problemas a empresa.

Testes de controle de qualidade de sementes também são vários, alguns demorados e outro rápidos. Mas saber qual testes é mais adequado a ser realizado é um dos problemas enfrentados pelos laboratoristas, pois cada um complementa o outro. Portanto a regra é, quanto mais testes de qualidade melhor será para identificar um lote de qualidade fisiológica superior e assim, o aprendizado de máquinas ajuda com todos esses dados a ter uma rápida e eficiente decisão com tantas informações distintas. Com posse desses dados, através da inteligência artificial pode-se prever qual teste será necessário realizar primeiro ao determinar a qualidade da semente. Sem precisar incluir todos os testes, por exemplo o teste de vigor que complementa o de germinação, onde submete as sementes a diversos tipos de estresses (envelhecimento acelerado, teste de frio, deterioração controlada, teste tetrazólio) e avaliando as características das plântulas (crescimento de plântulas e fitomassa seca).

Com essa ferramenta facilitaria, nestes processos laborosos, na tomada de decisão. Na Figura 1 mostra um esboço de como o aprendizado de máquinas atuaria na decisão rápida e eficiente para escolhas de lotes de maior qualidade fisiológica. A escolha do modelo testado fica melhor explicado pelos valores de acurácia. No qual ela demonstra o quanto o valor estimado é semelhante ao real.

**Figura 1:** O processo de segmentação e seleção da técnica de aprendizado de máquinas gerando uma árvore de decisão e rede neural em lotes de sementes.



O conjunto de dados trabalhados em um treinamento de aprendizado de máquinas, geralmente são enormes, onde a análise humana pode ser prejudicada e delongada resposta. Quando são geradas informações de cultivar, tratamentos, safra, peneira, pureza, percentual de infestação, percentual de outras sementes, germinação e vigor, torna-se um trabalho lento e de pouca eficiência para a tomada de decisão. Então, testar os modelos classificadores são essenciais para corresponder o desempenho do algoritmo sobre o conjunto de dados fornecido.

Em uma árvore de decisão os atributos testados como classificadores e seletores de sementes expõe em qual situação pode aceitar ou rejeitar a qualidade das sementes sobre os atributos avaliados (mineração de dados), o algoritmo escolhe o atributo por meio do ganho de informação da quantidade de maiores valores encontrados no conjunto de dados, ou seja, o quanto informativo um atributo é (VIEIRA, 2018). Quanto a rede neural, apresenta camadas de entrada e de saída. As redes neurais simulam as conexões no cérebro humano (HAYKIN, 1999). Basicamente, a rede neural artificial pega as entradas, as calcula e produz as saídas. Este processo é conhecido como aprendizagem (CINAR et al., 2020). Em estudo com predição de ranqueamento de lotes de sementes de milho por inteligência artificial, Moraes (2020), definiu os algoritmos testados através de critérios de valores apresentados nas acurácias e matriz de confusão.

Importante ressaltar, que ao analisar os valores de acurácia em fase inicial de treinamento dos dados, quando se obtêm valores alto de percentagem, implica no grau de aprendizado das máquinas e prediz o quanto aquela informação ainda precisa ser trabalhada. Por exemplo, quando é observado um valor de 98% de acurácia, ela pode implicar que a máquina não aprendeu quase nada nos dados trabalhados. Ou seja, quando a acurácia apresenta alto valores, ainda necessita treinar mais a máquina isso é relacionado ao

comportamento de matriz de confusão onde ela ainda não consegue separar informações e assim, sendo necessário distinguir o que aceita e o que rejeita ou conforme queira a resposta.

Outro segmento ligado a sementes que necessitam de modernização digital e tecnológica são os laboratórios, onde, equipamentos em laboratório são regulados conforme normativas de cada órgão fiscalizador, são necessários calibrações uniforme e padronização em todos os laboratórios, que emitam atestados da qualidade de sementes. Esses atestados são imprescindíveis para a comercialização, armazenamento, distribuição de sementes. O teste de sementes também é usado na pesquisa e na identificação de problemas de qualidade (TILLMANN; MENEZES, 2012). Souza et al. (2019), apresentaram um sistema integrado composto por hardware, middleware e aplicativo para monitorar e registrar o desempenho de equipamentos nos testes de sementes, desde o início até a conclusão de cada teste em laboratórios de sementes (com o chamado internet das coisas). Portando o aprendizado de máquinas podem ser úteis para diversos equipamentos de laboratório. Isto associado a inteligência artificial torna imprescindível.

### **3.4 CONSIDERAÇÕES FINAIS**

O avanço de Inteligência artificial com o aprendizado de máquinas tornará as tecnologias agrícolas precisas, eficientes, robustas e de baixo custo. O processamento de dados com uma visão de máquina se complementa através de imagem com um discriminador para classificar o alvo desejado com dados dimensionais elevados.

Estudos com processamento de imagem e aliado a aplicação de IA fornece resolução de problemas na ciência e tecnologia de sementes como métodos não destrutivos em suas análises. Técnicas de aprendizado de máquinas podem facilitar extração e seleção de recursos com algoritmos de previsão apropriado.

O campo das sementes ainda necessita ser explorado com maior robustez. Com a dinâmica de pesquisas atuais no ramo sementeiro, espera-se tendências que investigue em um futuro próximo, análise de dados característicos em sistemas de produção de sementes relacionado aos aspectos de beneficiamento, armazenamento, secagem e controle de qualidade.

### **REFERÊNCIAS**

1. CINAR, A. C. Training feed-forward multi-layer perceptron neural network with a tree-seed algorithm. *Arabian Journal for Science and Engineering*. v. 45, p. 10915 -10938, 2020. Doi: <https://doi.org/10.1007/S13369-020-04872-1>.
2. ELFERINK, M.; SCHIERHORN, F. *Global demand for food is rising. Can we meet it?* Harvard Business Review. 4p. April 07. 2016. <https://hbr.org/2016/04/global-demand-for-food-is-rising-can-we-meet-it>.
3. ELMASRY, G.; MANDOUR, N.; WAGNER, MH.; DEMILLY, D.; VERDIER, J.; BELIN, E., ROUSSEAU, D. Utilization of computer vision and multispectral imaging techniques for classification of cowpea (*Vigna unguiculata*) seeds. *Plant Methods*, v. 15, n. 24, 2019. Doi: <https://doi.org/10.1186/s13007-019-0411-2>.
4. FAO, Food and Agriculture Organization of the United Nations. *Global agriculture towards 2050: high-level expert forum on how to feed the world in 2050*, 12-13. Oct 2009 by Food and Agriculture Organization of the United Nations, 2009. <https://reliefweb.int/report/world/global-agriculture-towards-2050-high-level-expert-forum-how-feed-world-2050-12-13-oct>.
5. FAO. Food and Agriculture Organization of the United Nations, 2017. *The state of food and agriculture leveraging food systems for inclusive rural transformation*. 978-92-5-109873-8. 2017, p. 1-181.
6. FRANÇA-SILVA, F.; REGO, C. H. Q.; GOMES-JUNIOR, F. G.; MORAES, M. H. D.; MEDEIROS, A. D.; SILVA C. B. Detection of *Drechslera avenae* (Eidam) Sharif [*Helminthosporium avenae* (Eidam)] in Black Oat Seeds (*Avena strigosa* Schreb) using multispectral imaging. *Sensors*, v. 20, n. 12, p. 33-43, 2020. doi: <https://doi.org/10.3390/s20123343>.
7. GRANITTO, P. M.; NAVONE, H. D.; VERDES, P. F.; CECCATTO, H. A. Weed seeds identification by machine vision, *Computers and Electronics in Agriculture*, v. 33, n. 2, p. 91-103, 2002. Doi: [https://doi.org/10.1016/S0168-1699\(02\)00004-2](https://doi.org/10.1016/S0168-1699(02)00004-2).
8. HAYKIN, S. *Neural networks: a comprehensive foundation*. New Jersey: Prentice Hall; Upper Saddle River, 1999. 218 p.
9. JAHANI, A. Sycamore failure hazard classification model (SFHCM): an environmental decision support system (EDSS) in urban green spaces. *International Journal of Environmental Science and Technology*. v. 16, p. 955–964. 2019a Doi: <https://doi.org/10.1007/s13762-018-1665-3>.
10. JAHANI, A. Forest landscape aesthetic quality model (FLAQM): A comparative study on landscape modelling using regression analysis and artificial neural networks. *Journal of Forest Science*. v. 65, n. 2, 61–69, 2019b. Doi: <https://doi.org/10.17221/86/2018-JFS>.

11. JHA, K.; DOSHI, A.; PATEL, P.; SHAH, M. A comprehensive review on automation in agriculture using artificial intelligence, *Artificial Intelligence in Agriculture*, v. 2, p. 1-12, 2019. Doi: <https://doi.org/10.1016/j.aiia.2019.05.004>.
12. KAUR, K. Machine learning: applications in Indian agriculture. *International Journal of Advanced Research in Computer and Communication Engineering*, v. 5, n. 4. 2016.
13. KIM, R. G.; EVANS; W. M. IVERSEN. Remote sensing and control of an irrigation system using a distributed wireless sensor network. *IEEE Transactions on Instrumentation and Measurement*, v. 57, n. 7, p. 1379-1387, 2008. Doi: 10.1109/TIM.2008.917198.
14. LIAKOS, K.; BUSATO, P.; MOSHOU, D.; PEARSON, S.; BOCHTIS, D. Machine learning in agriculture: A review. *Sensors*, v. 18, n. 8, p. 2674, 2018. Doi: 10.3390/s18082674.
15. MAHAJAN, S.; MITTAL, S. K; DAS, A. Alternative test approach based on machine vision for testing physical purity, viability and vigor of soybean seeds (*Glycine max*). *Journal of Food Science and Technology*, v. 55, n. 10, p. 3949-3959. Doi: <https://doi.org/10.1007/s13197-018-3320-x>
16. MEDEIROS, A. D. de; PINHEIRO, D. T.; XAVIER, W. A.; SILVA, L. J. da; DIAS, D. C. F. dos S. Quality classification of *Jatropha curcas* seeds using radiographic images and machine learning. *Industrial Crops and Products*, v. 146, p. 112-162, 2020a. Doi: <https://doi.org/10.1016/j.indcrop.2020.112162>.
17. MEDEIROS, A. D. de; SILVA, L. J.; SILVA, J. M.; DIAS, D. C. F. S.; PEREIRA, M. D. IJCropSeed: An open-access tool for high-throughput analysis of crop seed radiographs. *Computers and Electronics in Agriculture*, v. 175, p. 105555, 2020b. Doi: <https://doi.org/10.1016/j.compag.2020.105555>.
18. MONTEIRO, R. C. M.; GADOTTI, G. I.; MALDANER, V.; CURI, A. B. J.; BARBARA NETO, M. Image processing to identify damage to soybean seeds. *Ciência Rural*, v. 51, p. 1-8, 2021. Doi: <https://doi.org/10.1590/0103-8478cr20200107>.
19. MORAES, N. A. B. *Predição de ranqueamento de lotes de sementes de milho por inteligência artificial*. 2020, 29 f. Dissertação de Mestrado em Ciências – Programa de Pós-Graduação em Ciência e Tecnologia de Sementes. Universidade Federal de Pelotas, Pelotas/RS. 2020. link: <http://guaiaca.ufpel.edu.br/handle/prefix/5713>.
20. MORETI, M. P.; OLIVEIRA, T.; SARTORI, R.; CAETANO, W. Inteligência artificial no agronegócio e os desafios para a proteção da propriedade intelectual. *Cadernos de Prospecção*, v. 14, p. 60, 2021. Doi: <http://dx.doi.org/10.9771/cp.v14i1.33098>.
21. MOSAFFAEI, Z.; JAHANI, A.; ZARE, C. M. A.; GOSHTASB, H.; ETEMAD, V. SAFFARIHA, M. Soil texture and plant degradation predictive model (STPDPM) in



- national parks using artificial neural network (ANN). *Journal Modeling Earth Systems and Environment*, v. 6, p. 715–29, 2020. Doi: <https://doi.org/10.1007/s40808-020-00723-y>.
22. MOSLEM, A.; YOUNESSI-HMAZEKHANLU, M.; RAMAZANI, S. H. R.; OMIDI, A. H. Artificial neural networks and multiple linear regression as potential methods for modeling seed yield of safflower (*Carthamus tinctorius* L.), *Industrial Crops and Products*, v. 127, p. 185–194, 2019. Doi: <https://doi.org/10.1016/j.indcrop.2018.10.050>.
  23. OLESEN, M. H.; NIKNESHAN, P.; SHRESTHA, S.; TADAYYON, A.; DELEURAN, L. C.; BOELT, B.; GISLUM, R. Viability prediction of *Ricinus cummunis* L. seeds using multispectral imaging. *Sensors*, v. 15 n. 2, p. 4592–4604, 2015. Doi: <https://doi.org/10.3390/s150204592>
  24. PANPATTE, D. G. *Artificial intelligence in agriculture: an emerging era of research*. Anand Agricultural University, Canada, p. 1–8, 2018.
  25. PANT, L. P. Digitally engaged rural community development. *Journal of Agriculture, Food Systems, and Community Development*, v. 6, n. 4, p. 169–171, 2016. Doi: [10.5304/jafscd.2016.064.005](https://doi.org/10.5304/jafscd.2016.064.005).
  26. RASCHKA, S. Model evaluation, model selection, and algorithm selection in machine learning. *arXiv*, v. 3, p. 1–48, 2018. Doi: [arXiv:1811.12808](https://arxiv.org/abs/1811.12808).
  27. REHMAN, T. U.; SULTAN MAHMUD, M. D.; CHANG, Y. K.; JIN, J.; SHIN, J. Current and future applications of statistical machine learning algorithms for agricultural machine vision systems, *Computers and Electronics in Agriculture*, v. 156, p. 585–605. 2019. Doi: <https://doi.org/10.1016/j.compag.2018.12.006>.
  28. SAFFARIHA, M.; JAHANI, A.; POTTER, D. Germination prediction of *Salvia limbata* seeds under ecological stress in protected areas: an artificial intelligence modeling approach. *BMC Ecology*, v. 20, 48, 2020. Doi: <https://doi.org/10.1186/s12898-020-00316-4>.
  29. SAHA, D.; MANICKAVASAGAN, A. Machine learning techniques for analysis of hyperspectral images to determine quality of food products: A review, *Current Research in Food Science*, v. 4, p. 28–44, 2021. Doi: <https://doi.org/10.1016/j.crfs.2021.01.002>.
  30. SALAKEN, M. S.; ABBAS, K.; THANH, N.; SAEID, N. Seeded transfer learning for regression problems with deep learning. *Expert Systems with Applications*, v. 115, p. 565–577. 2018. Doi: <https://doi.org/10.1016/j.eswa.2018.08.041>.
  31. SALIMI Z.; BOELT. B. Classification of processing damage in sugar beet (*Beta vulgaris*) seeds by multispectral image analysis. *Sensors*, v. 19, n. 10, p. 23–60, 2019. Doi: <https://doi.org/10.3390/s19102360>.

32. SCHNEIDER, C. A.; RASBAND, W. S.; ELICEIRI, K. W. NIH Image to ImageJ: 25 years of image analysis. *Nature Methods*, v. 9, p. 671-675, 2012. Doi: 10.1038/nmeth.2089.
33. SHARMA, A. SATISH, D.; SHARMA, S.; GUPTA, D. iRSVPred: A web server for artificial intelligence based prediction of major basmati paddy seed varieties. *Frontiers in Plant Science*, v. 10, p. 1791, 2020. Doi: 10.3389/fpls.2019.01791.
34. SINGH, G.; SINGH, A.; G. KAUR. *Role of artificial intelligence and the internet of things in agriculture*. 16. Ed(s): KAUR, G.; TOMAR, P.; TANQUE, M. Artificial intelligence to solve pervasive internet of things issues, Academic Press, c. 16, p. 317-330, 2021. Doi: <https://doi.org/10.1016/B978-0-12-818576-6.00016->.
35. SOUZA, S. de R.; LOPES, B.; LADISLAU, J.; RESIN GEYER, C. F.; DA ROSA, S. J. L.; AFONSO CARDOZO, A.; CORRÊA, Y. A.; GADOTTI, G. I.; BARBOSA, J. L. V. Continuous monitoring seed testing equipments using internet of things. *Computers and Electronics in Agriculture*, v. 158, p. 122-132, 2019. Doi: <https://doi.org/10.1016/j.compag.2019.01.024>.
36. TAGARAKIS, A.; LIAKOS, V.; FOUNTAS, S.; KOUNDOURAS, S.; GEMTOS, T. Management zones delineation using fuzzy clustering techniques in grapevines. *Precision Agriculture*, v. 14, n. 1, p. 18-39, 2013. Doi: <https://doi.org/10.1007/s11119-012-9275-4>.
37. TALAVIYA, T.; SHAH, D.; PATEL, N.; YAGNIK, H.; SHAH, M. Implementation of artificial intelligence in agriculture for optimisation of irrigation and application of pesticides and herbicides. *Artificial Intelligence in Agriculture*, v. 4, p. 58-73, 2020. Doi: <https://doi.org/10.1016/j.aiia.2020.04.002>.
38. TILLMANN, M. A. A.; MENEZES, N. L. *Análise de Sementes*. In: *Sementes: Fundamentos científicos e tecnológicos*. Ed. Universitária/UFPel, Pelotas, p. 138-198, c. 3, 2012.
39. TU, K.; WEN, S.; HENG, Y.; ZHANG, T.; PAN, T.; WANG, J.; WANG, J.; SUN, Q. A non-destructive and highly efficient model for detecting the genuineness of maize variety 'JINGKE 968' using machine vision combined with deep learning. *Computers and Electronics in Agriculture*, v. 182, p. 106002, 2021. Doi: <https://doi.org/10.1016/j.compag.2021.106002>.
40. VARELA, N.; SILVA, J.; PINEDA, O. B.; CABRERA, D. Prediction of the corn grains yield through artificial intelligence. *Procedia Computer Science*, v. 170, p. 1017-1022, 2020. Doi: <https://doi.org/10.1016/j.procs.2020.03.080>.
41. VIEIRA, E. M. de A.; NEVES, N. T. de A. T.; de OLIVEIRA, A. C. C.; de MORAES, R. M.; do NASCIMENTO, J. A. Avaliação da performance do algoritmo J48 para construção de modelos baseados em árvores de decisão. *Revista Brasileira de Computação Aplicada*, v. 10, p. 80-90, 2018. Doi: <https://doi.org/10.5335/rbca.v10i2.8078>.

42. ZHOU, L.; ZHANG, C.; LIU, F.; QIU, Z.; HE, Y. Application of deep learning in food: a review. *Comprehensive Reviews in Food Science and Food Safety*, v. 18, p. 1793-1811, 2019. Doi: <https://doi.org/10.1111/1541-4337.12492>.
43. YANG, H.; LIUSHENG, W.; HONGLI JUNMIN, X. *Wireless Sensor Networks for Intensive Irrigated Agriculture, Consumer Communications and Networking Conference, 2007. CCNC 2007. 4th IEEE*, p. 197-201. Las Vegas, Nevada. Jan. 2007.
44. WEN, L.; YANG, B.; CUI, C.; YOU, L.; ZHAO, M. Ultrasound-assisted extraction of phenolics from Longan fruit seeds (*Dimocarpus longan* Lour.) With artificial neural network and its antioxidant activity. *Food Analytical Methods*, v. 5, p. 1244-1251, 2012. Doi: <https://doi.org/10.1007/s12161-012-9370-1>.

## **4 CAPÍTULO II - PROCESSAMENTO DE IMAGENS COMO FERRAMENTA IMPORTANTE PARA INTELIGÊNCIA ARTIFICIAL NO SETOR DE SEMENTES**

**Artigo publicado na Revista Agrária Acadêmica, ISSN 2595-3125. DOI: 10.32406/v5n1/2022/89-101/agrariacad**

### **4.1 Introdução**

A imagem multiespectral é uma nova tecnologia implantada para avaliar os parâmetros de qualidade das sementes (BOELT et al., 2018). E ferramentas inovadoras têm sido projetadas para melhorar a caracterização de diferentes classes de sementes e, conseqüentemente, as tomadas de decisões tornando-se mais eficientes (MEDEIROS et al., 2021). As indústrias agrícolas estão buscando abordagens inovadoras para melhorar a produtividade das safras devido às mudanças climáticas imprevisíveis, ao rápido aumento do crescimento populacional e às preocupações com a segurança alimentar. Assim, a inteligência artificial na agricultura também chamada de “Inteligência Agrícola” está surgindo progressivamente como parte da revolução tecnológica da indústria (PATHAN et al., 2020).

Na agricultura, atualmente são gerados aplicativos de processamento de imagem e visão computacional que vêm crescendo devido aos custos de equipamento reduzidos, maior poder computacional e crescente interesse em métodos de avaliação não destrutivos (MAHAJAN et al., 2015). Esse interesse também cresce para o setor de sementes, pois é o

principal insumo em uma lavoura agrícola que pode gerar uma boa safra. Porém, ainda é um desafio a ser superado no setor sementeiro por se tratar de técnicas avançadas que apresenta vantagens aos métodos tradicionais de avaliação do controle de qualidade das sementes, quando se trabalha manualmente.

Métodos rápidos e não destrutivos de detecção da qualidade da semente devem, portanto, ser desenvolvidos para a agricultura e a indústria de produção de sementes (RAHMAN; CHO, 2016). Pois, a qualidade da semente é uma caracterização de múltiplos componentes, incluindo pureza varietal e analítica, capacidade de germinação, vigor, desempenho e uniformidade da semente. Atualmente, os testes de qualidade das sementes dependem de inspeções físicas e químicas, bem como visuais, que são caras e demoradas. Além disso, as inspeções visuais são subjetivas e difíceis de reproduzir (BOELT et al., 2018).

O uso não destrutivo de sementes minimiza as perdas em testes realizados na necessidade de retirar parte de uma semente ou de uma plântula. A avaliação da qualidade das sementes é tradicionalmente realizada manualmente por trabalhadores qualificados ou semiquilificados (MAHAJAN et al., 2015). No entanto, este não é um método eficiente, pois os custos crescentes da mão-de-obra e a escassez de mão-de-obra qualificada prejudicam a eficiência do processo de avaliação (KANNUR et al., 2011). Avaliações visuais da qualidade da semente usando cor, tamanho, forma e textura são fáceis de realizar, mas podem ser altamente subjetivas, tediosas, caras e inconsistentes, se feitas manualmente (BROSNAN; SUN, 2004, DU; SUN, 2004, DU; SUN, 2006, GUNASEKARAN, 1996). Por outro lado, a avaliação da qualidade da semente com base na visão de máquina pode ser alcançada em menos tempo de teste e com maior eficiência devido à sua velocidade e consistência. Benefícios adicionais incluem melhor precisão e disponibilidade 24 horas, o que leva a menores custos de avaliação (BROSNAN, SUN, 2002; JAYAS et al., 2000).

Nesse sentido, o uso da visão de máquina tem crescido nos últimos anos para atender à crescente demanda por métodos rápidos e precisos no monitoramento da produção agrícola (PATRÍCIO, RIEDER, 2018). O aprendizado de máquina é um subconjunto da inteligência artificial, onde os avanços são rápidos e significativos (KAKKAD et al., 2019). Problemas muito complexos para serem resolvidos por humanos são enfrentados por aprendizado de máquina, deslocando a carga da tomada de decisão para o algoritmo (SHAH et al., 2020a;, SHAH et al., 2020b; PATEL et al., 2020a, PATEL et al., 2020b; PANCHIWALA, SHAH, 2020; TALAVIYA et al., 2020). Com isso o objetivo deste trabalho foi relatar a inserção de processamento de imagem com inteligência artificial na área de sementes.

## 4.2 Metodologia

Usou-se uma metodologia dedutiva, de caráter exploratório, fundamentada em pesquisa bibliográfica. Este trabalho revisa pesquisas anteriores e atuais sobre o uso e a aplicação de inteligência artificial na agricultura acompanhado de seus efeitos no setor sementeiro com a utilização de processamento de imagens. Neste contexto, foi feita uma abordagem com maior enfoque na influência da inteligência artificial com o uso de processamento de imagens aplicado ao setor de sementes. E também foram destacados alguns trabalhos que retratam o início das pesquisas utilizando o processamento de imagens em culturas agrícolas, com ênfase em sementes.

As palavras-chave utilizadas na coleta de literatura para esta revisão foram “aprendizado de máquinas em sementes”, “processamento de imagens”, “inteligência artificial em sementes”, “técnica não destrutiva”, “técnicas de processamento de imagens por inteligência artificial”, “tipos de imagens”. Bancos de dados computacional, ferramentas de imagens na inteligência artificial (todos os bancos de dados, CAB Abstracts e Global Health, Medline, Pubmed, Web of Science, BIOSIS Citation Index, Science Direct, Current Content Connect, Google Scholar, Scielo, Frontiers e Springer Link) foram pesquisados entre agosto e novembro de 2021.

Especificamente, processamento de imagens em sementes no aprendizado de máquinas como ferramenta para inteligência artificial em processo de pós-colheita relataram trabalhos empregados nos últimos 25 anos (1996–2021), como suas técnicas e tipos de imagens e seus domínios de pesquisa para solucionar os mais variados problemas encontrados, foram considerados prioritários. Os artigos com abrangência sobre métodos de uso de imagens e aprendizado de máquinas aplicado a inteligência artificial no setor sementeiro foram prioritários, o estado em que os experimentos foram realizados, o tipo de ensaio utilizado, a modelagem testada e a forma de como a técnica computacional de aplicação mostrava a eficiência apresentada, foram considerados na filtração.

O Science Direct foi filtrado usando ‘pesquisa Science direct’ (inteligência artificial na agricultura com enfoque imagens) e (aprendizado de máquinas em sementes) - em vista dos retornos de títulos >30 - e outros filtros foram aplicados a outras bases de dados conforme necessário. Todos os documentos considerados estavam em inglês e foram traduzidos para o português.

## 4.3 Referencial teórico

A literatura apresenta uma abordagem do uso de inteligência artificial aplicado no setor de sementes via processamento de imagens com aprendizado de máquinas em vários segmentos da área sementeira. Embora se tenha mais de 20 anos de estudos sobre imagens na aplicação de qualidade de sementes, o fato é que o uso da inteligência artificial necessita ser estudada em várias etapas das pós-colheita de sementes, pois, é algo novo para os sementeiros. Neste trabalho, apresentamos pesquisas atuais que foram desenvolvidas na linha de investigação com imagens para avaliar qualidade de sementes.

A forma como se interpreta os dados para aprendizado profundo de máquinas no setor de sementes ainda necessita de alguns esclarecimentos e metodologias mais acessíveis, para que possa ser transferida a tecnologia para os produtores rurais de sementes como uma ferramenta promissora. Nesta revisão, apontamos alguns estudos realizado com a inteligência artificial e o processamento de imagens através de técnicas de aprendizado de máquinas.

### **Inteligência artificial na automação do setor de sementes**

Na modernização e automação da agricultura, existe a necessidade de uma tecnologia que seja mais facilmente compreendida, implementada e utilizada pelos agricultores. E que possa demonstrar eficiência nos resultados de pós-colheita no setor de sementes, pois uma demanda de dados nas avaliações de qualidade de sementes é algo que requer cuidado e se torna muito trabalhoso. Atualmente, a demanda por equipamentos agrícolas que requerem menos esforços humanos e tempo está aumentando a cada dia. Além disso, devido ao desenvolvimento da Internet das coisas e da robótica, os equipamentos agrícolas também se tornaram mais inteligentes (KUMAR, ASHOK, 2021). A facilidade de uso com a tecnologia associado a inteligência artificial, permite respostas rápidas e os resultados confiáveis fornecidos pela tecnologia de ponta e sua acessibilidade pode atrair profissionais e leigos.

A automação agrícola é a principal preocupação e assunto emergente para todos os países (JHA et al., 2019). O uso de inteligência artificial envolve o processo de aprendizagem das máquinas em todos os ramos das ciências de investigações experimentais (PINHEIRO et al., 2021a), na agricultura está sendo cada vez mais comum. Para o setor de Ciência e Tecnologia de sementes é algo promissor, porém a área sementeira, ainda pode demandar um período prolongado para as investigações e soluções tecnológicas através de inteligência artificial nas linhas de pesquisas de armazenamento, secagem, beneficiamento, controle de qualidade e fisiologia da qualidade de sementes, entre outros. De acordo com

Pinheiro et al. (2021b), interpretar os resultados gerados pela técnica de aprendizado de máquinas é um passo essencial de garantir uma informação robusta e precisa para a tomada de decisão. E assim, ajudar os produtores e as empresas de sementes com modelos precisos para prever a produtividade das culturas e a qualidade das sementes.

Nos países em desenvolvimento e/ou subdesenvolvidos a operação de análise da qualidade de sementes (pós-colheita) atualmente é realizada manualmente. Em algumas situações do processo ocorre por meio automatizado (semeadura, colheita, beneficiamento e secagem). Entretanto, a natureza de algumas tarefas é monótona e o envolvimento de uma quantidade considerável de mão-de-obra torna-se imprecisa, tediosa e cara. E então, algoritmos de aprendizagem de máquina são testados para estabelecer a melhor alternativa na predição dos resultados das análises de sementes sobre sua qualidade fisiológica. Treinar robôs pode ser uma alternativa para modernizar todo o processo no setor de sementes incluindo a combinação de análise de imagens e dados digitais e/ou manuais, no qual trabalhadores humanos podem ser substituídos por robôs na análise e, coleta de dados reduzindo os custos de mão-de-obra e tornando o processo mais rápido e eficaz.

Á medida que ferramentas inovadoras de tecnologia da informação e comunicação foram gradualmente introduzidas ao longo das últimas décadas no setor agrícola, o uso de sistemas de informação de gestão agrícola foi amplamente expandido e hoje são considerados ferramentas importantes para a gestão do negócio agrícola (PARAFOROS et al., 2017). Estes autores relatam que, a carga de trabalho necessária para coletar, agregar e importar dados relacionados às atividades agrícolas em um sistema de informação de gestão agrícola é uma tarefa que geralmente consome tempo e os agricultores relutam em realizar. Desde mesmo modo, acontece nos processos de pós-colheita das sementes, pois existe uma infinidade de dados que são gerados para garantir a qualidade da semente. A combinação de informações adequadas relacionadas ao tempo com tomada de decisão cuidadosa é o fator chave para o sucesso no negócio de sementes.

### **Análise de imagens na avaliação da qualidade fisiológica de sementes**

Toda a natureza do processo de pós-colheita de sementes envolve os aspectos da germinação. Se beneficiar, secar, armazenar as sementes ou qualquer outra etapa que envolve a propagação de uma espécie via sexuada, necessita realizar testes de vigor e germinação para garantir uma alta produtividade e resistência a condições adversas do ambiente. O uso de

técnica não destrutivas na avaliação da qualidade de sementes permite reutiliza-las, sendo muito importante para sementes de espécies florestais, no qual, algumas espécies produzem poucas sementes e/ou a coleta se torna difícil e, se trabalha com uma quantidade de amostras de sementes reduzida. Para as espécies agrícolas as informações obtidas por meio de imagem permitem mais rapidez na interpretação dos dados, visto que o volume de informações é alto.

A viabilidade de investigar a taxa de germinação em sementes individuais dentro de uma população, sugerem que as técnicas de análise de imagens têm alto potencial em estudos de biologia de sementes (DELL'AQUILA et al., 2000). Considerando que o uso da análise de imagens na tecnologia da Ciência de Sementes tem levado a avanços consideráveis na avaliação da qualidade das sementes (MEDEIROS et al., 2020a). Sugere que as técnicas de inteligência artificial e de imagem possam agilizar uma grande quantidade de dados gerados na avaliação da qualidade de sementes entre as etapas de pós-colheita. Neste contexto, usando técnicas de visão de máquina baseadas em imagens não destrutivas permite obter estimativa e classificação de características de sementes com alta precisão.

Dependendo das características do alvo, vários métodos de análise de imagem foram desenvolvidos, como imagem de raios-X (MOONEY et al., 2012), imagem por ressonância magnética (van DUSSCHOTEN et al., 2016), imagem bidimensional (2D) (PORNARO et al., 2017) e imagens tridimensionais (3D) (TOPP et al., 2013; van DUSSCHOTEN et al., 2016). E além das, imagens hiperespectrais e multiespectrais, imagens de raios X suaves, microtomografia computadorizada, termografia infravermelha (MEDEIROS et al., 2021). Entre as tecnologias ópticas disponíveis, a imagem de raio-X suave tem sido aplicada com sucesso para a inspeção de sementes com mais frequência (HUANG et al., 2015; KOTWALIWALE et al., 2014). A principal vantagem desta técnica é a capacidade de obter informações de forma não destrutiva sobre a morfologia interna da semente (MEDEIROS et al., 2021).

Sendo uma técnica não destrutiva para avaliar aspectos de integridade morfológicas e fisiológicas das sementes, no qual se observa as suas características externas e internas, os métodos de avaliação através de imagens têm ganhado destaque na área da Ciência e Tecnologia de sementes. Os métodos tradicionais usados na determinação dos parâmetros essenciais de qualidade das sementes são habitualmente realizados usando técnicas destrutivas baseadas em métodos bioquímicos e moleculares realizados por analistas de sementes (ELMasry et al., 2020). Mesmo sendo preciso e eficiente, esses métodos em laboratório, eles apresentam limitações principalmente com a demora de obter resultados rápidos e eficiente sobre a qualidade física e fisiológica de sementes. E assim órgãos oficiais de sementes



percebem a importância de desenvolver novas tecnologias avançadas para superar as limitações dos métodos tradicionais de determinação da qualidade de sementes (BOELT et al., 2018).

A necessidade dos setores da indústria de sementes em desenvolverem novos métodos que permitam uma avaliação mais rápida da qualidade e composição das sementes tem sido alvo de pesquisa sobre os métodos rápidos e não destrutivos, especialmente técnicas ópticas, espectrais e de imagem (ELMasry et al., 2020). A imagem biológica de amostras inalteradas pode ser realizada em tempo real de atributos físicos, químicos, fisiológicos e patológicos de produtos, revelando a qualidade interna de vários produtos agrícolas e alimentícios, incluindo grãos, frutas, vegetais, carne e peixes (WU, SUN, 2013; RAHMAN, CHO, 2016; KUMAR, KARNE, 2017), como também das sementes. Métodos baseados em propriedades eletromagnéticas de tecidos de sementes, como fluorescência de clorofila e imagem multiespectral se encaixam bem nessas características desejáveis (GALLETTI et al., 2020).

As técnicas de análise de imagens tornaram-se mais confiáveis com o desenvolvimento de microscópios de fluorescência e alta resolução para ganhar o interesse dos pesquisadores. A possibilidade de estudar os detalhes estruturais de elementos biológicos, como organismos e suas partes internas e externas, pode ter um impacto profundo na pesquisa biológica (LODDO et al., 2021) e agrárias que assume papel importante nas subáreas agrônômicas (Fitotecnia). Em geral, é uma importante área de pesquisa no domínio agrícola para classificação de imagens, detecção de anomalias, cores, tamanhos e formas (KAMILARIS, PRENAFETA-BOLDÚ, 2018).

Os aspectos físicos das sementes através de suas características morfológicas estão entre as observações mais difundida pelo processamento de imagens. A forma e o tamanho das sementes estão entre as características agrônômicas mais vitais, uma vez que desempenham um papel crucial na qualidade da alimentação, na produção e no preço de mercado (LIU et al., 2020). A avaliação quantitativa de suas características morfológicas externas e internas pode promover o progresso das áreas de pesquisa de plantas, incluindo genética, fisiologia, análise funcional e melhoramento de plantas (TANABATA et al., 2021). No caso, de métodos para obtenção de imagens do interior das sementes tem a capacidade de obter informações de forma não destrutiva sobre a sua morfologia interna. Além disso, pesquisas recentes demonstraram que parâmetros físicos internos avaliados por imagens de raios-X de sementes têm forte relação com a germinação e o vigor das sementes (ABUD et al., 2018; DELL'AQUILA, 2007; GAGLIARDI, MARCOS-FILHO, 2011; MEDEIROS et al., 2020a, 2020b).

Para avaliações físicas das sementes quanto aos seus aspectos morfológicos não é necessário realizar nenhum procedimento de ruptura dos tegumentos das sementes. portanto, ao analisar uma amostra de uma espécie desconhecida é necessária analisar internamente as estruturas previas com corte horizontais ou transversais, para fins de conhecer a morfologia interna e identificar quais estruturas compõe a semente. E deste modo, obtendo-se os conhecimentos prévios pode-se realizar ou aplicar métodos de análise de imagem profunda (Figura 1).

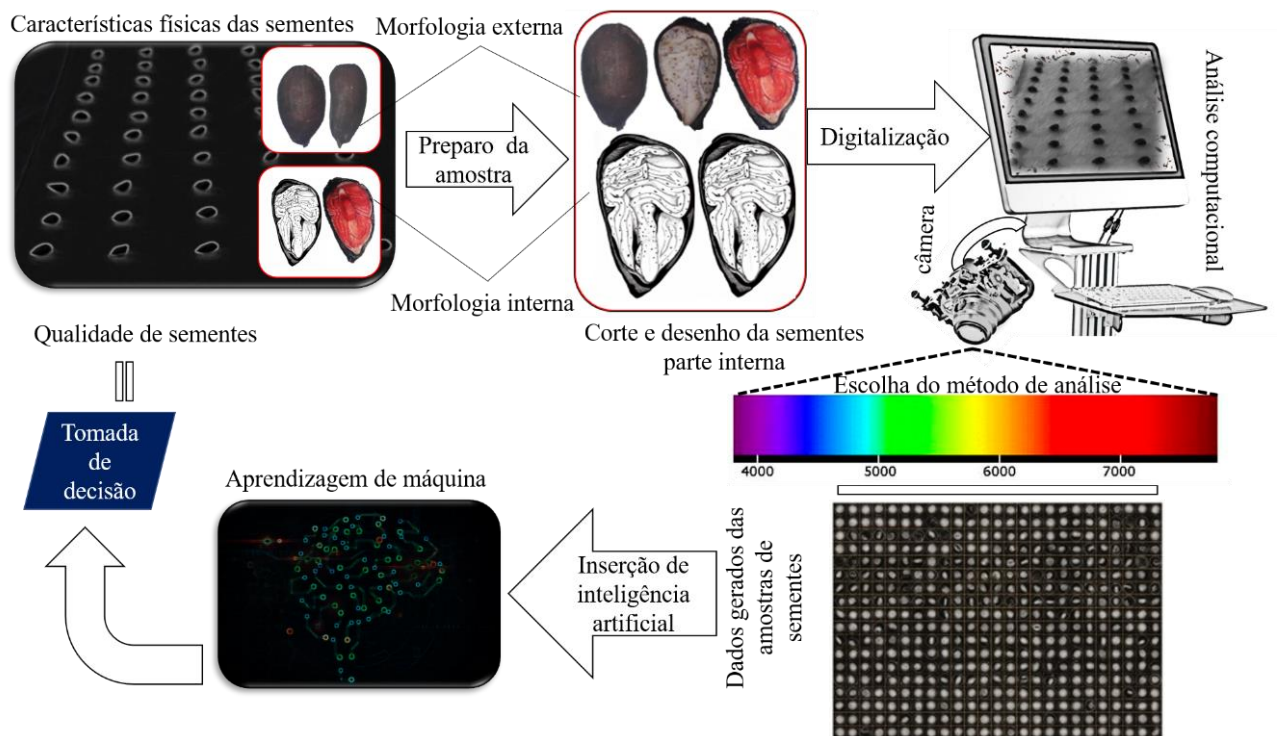


Figura 1. Esquema para preparação de amostra para sementes de espécies não conhecidas e utilização do processamento de imagens como ferramentas para inteligência artificial.

E os dados gerados através das imagens podem ser utilizados no treinamento de aprendizagem de máquina. Portanto, conhecimento das estruturas internas antes de qualquer análise é necessário para garantir que a avaliação estar sendo correta e de acordo com a resposta fisiológica da espécie e seus aspectos estruturais.

**Aspectos atuais de investigação sobre os estudos em sementes no processamento de imagem e inteligência artificial**

Visão de máquina ou análise de imagem é uma ferramenta importante no estudo da morfologia de quaisquer materiais (SUMATHI, BALAMURUGAN, 2013). As novas técnicas baseadas em inteligência artificial, pode tornar possível a automatização da análise quantitativas e qualitativa no setor de sementes agrícolas, forrageiras, florestais e hortícolas. Muitos testes e/ou análises padrão para garantir a qualidade e o bom desenvolvimento de uma cultura são exigidas pela lei brasileira, profissionais credenciados pelo MAPA (Ministério da Agricultura, Pecuária e Abastecimento) que realize os trabalhos manuais. A imagem óptica é uma tecnologia rápida, não destrutiva e precisa que pode produzir medições consistentes da qualidade do produto em comparação com as técnicas convencionais (GALLETTI et al., 2020).

Desde modo, vários pesquisadores tem investigados os métodos de aplicação dessas tecnologias mencionadas nos setores sementeiros. A partir do ano de 2000, os resultados analisados através de imagens já demonstravam seres promissores. Vários pesquisadores, então, buscaram esclarecer seus benefícios na avaliação de sementes em diferentes culturas. Com destaque para os trabalhos de Dell'Aquila et al. (2000), que investigou a aplicação da análise de imagens no monitoramento do processo de embebição de sementes de couve-branca (*Brassica oleracea* L.), Ducournau et al. (2004), sobre o sistema de aquisição de imagens para monitoramento automatizado da taxa de germinação de sementes de girassol, novamente Dell'Aquila, (2005), utilizou análise de imagens para monitorar a germinação de sementes de brócolis (*Brassica oleracea*) e rabanete (*Raphanus sativus*). Dell'Aquila, (2007), observou a germinação de sementes de pimenta avaliada por radiografia combinada e análise de imagem auxiliada por computador.

Teixeira et al. (2007), estudaram a montagem instrumental para processo germinativo de sementes com controle de temperatura e registro automático de imagens. Dell'Aquila (2009), apresentou uma revisão sobre tecnologia da informação de imagem digital aplicada ao teste de germinação de sementes. Geetha et al. (2011), avaliou a caracterização de genótipos de mostarda por meio de análise de imagens. Sivakumar et al. (2013), realizaram a discriminação de sementes de acácia em níveis de espécies e subespécies usando um analisador de imagem. Škrubej et al. (2015), investigaram a avaliação da taxa de germinação das sementes de tomate usando processamento de imagem e aprendizado de máquina. Oliveira et al. (2021), demonstraram parâmetros morfológicos de processamento de imagens para caracterizar a emergência de raízes primárias na avaliação do vigor de sementes de tomate.

As abordagens baseadas em imagens que usam tecnologias de processamento digital de imagens e visão computacional oferecem soluções para medir automaticamente uma variedade de recursos de tamanho e forma a partir de imagens de alta resolução em um modo de alto rendimento (LIU et al., 2020). Graças à sua ampla gama de aplicações, a análise de imagens desempenha um papel importante no campo das Ciências Agrárias, sendo primordial nos processos de pós-colheita de sementes, onde envolve secagem, beneficiamento, armazenamento e além do controle de qualidade. Estas etapas demandam uma série de informações que requer cuidados e rapidez na entrega de resultados, além de gerar um alto volume de dados. Sendo assim, exige de um analista a máxima atenção ao interpretar os dados, para garantir a entrega ao produtor sementes de alta qualidade.

Neste contexto, o aprendizado de máquinas e o processamento de imagens surgem para agregar segurança e agilidade de todo o processo sementeiro. Loddo et al. (2021), asseguram que as técnicas de análise de imagens se tornaram mais confiáveis com o desenvolvimento de microscópios de fluorescência e alta resolução para ganhar o interesse de todos os setores. O aprendizado profundo é uma técnica recente e moderna para processamento de imagens e análise de dados na área de semente. Porém requer algumas investigações em várias análises que são realizadas nas etapas de pós-colheita de sementes.

Os avanços da tecnologia vêm possibilitando o aprimoramento do uso aprendizados de máquinas e o processamento de imagens, recentemente a tecnologia de imagem hiperespectral tem sido uma questão de grande interesse em uma ampla gama de campos, como sensoriamento remoto e ciência médica e qualidade e segurança alimentar, detecção de doenças de plantas, qualidade de sementes e assim por diante (ELISABETH et al., 2019; FENG et al., 2020; XING et al., 2019; ZHANG et al., 2016).

Consideraremos, duas abordagens para a identificação de morfologia, dimensões e até variedades de sementes. O primeiro é a detecção de amostras a granel e o segundo é a identificação de semente única. Para avaliação de sementes com base a granel, os espectros médios de cada granel são frequentemente extraídos de acordo com a região predefinida de interesse. E no caso de uma única semente, a imagem hiperespectral pode adquirir simultaneamente imagens hiperespectrais de centenas ou milhares de sementes individuais. O espectro de cada semente pode ser extraído, o que o torna bastante adequado para classificação de variedades e para garantir a pureza das sementes (FENG et al., 2019).

### **Considerações finais**

Vários modelos de aprendizados de máquinas são alvos de investigação para melhorar as respostas de alvos trabalhosos e problemáticos. Estudos de aprendizados profundo na área de sementes oferece resultados promissores e tem grande potencial.

No setor de sementeiro novas metodologias podem ser apresentadas para prever vários parâmetros fisiológicos afim de garantir a qualidade de sementes, como também determinar lotes de alta qualidade através de inteligência artificial. Para tanto, ferramentas como lógicas fuzzy, redes neurais, árvores de decisão, naïve bayes, agrupamento de k-means, máquinas de vetor de suporte, floresta aleatória e etc, contribuem para as aplicações do aprendizado profundo na área de sementes.

O processamento de dados com uma visão de máquina através de imagens no campo da Ciência e Tecnologia de sementes permite selecionar e classificar dados dimensionais elevados, facilitando a extração e seleção de recursos com algoritmos de previsão apropriado. Para tanto, considera investigar todas as etapas de pós-colheita de sementes focando em inteligência artificial.

### **Conflitos de interesse**

Não houve conflito de interesses dos autores.

### **Contribuição dos autores**

Romário de Mesquita Pinheiro - ideia original, leitura e interpretação das obras e escrita; Gizele Ingrid Gadotti, orientação, correções e revisão do texto; Ruan Bernardy, revisão de texto; Rita de Cassia Mota Monteiro e Isabella Brandão Moreira, correções textuais.

### **Referências bibliográficas**

ABUD, H. F.; CICERO, S. M.; GOMES-JUNIOR, F. G. Radiographic images and relationship of the internal morphology and physiological potential of broccoli seeds. **Acta Scientiarum-Agronomy**, v. 40, p. 34950, 2018. Doi: <https://doi.org/10.4025/actasciagron.v40i1.34950>.

- BOELT, B.; SHRESTHA, S.; SALIMI, Z.; JØRGENSEN, J.; NICOLAISEN, M.; CARSTENSEN, J. Multispectral imaging - a new tool in seed quality assessment? **Seed Science Research**, v. 28, n. 3, p. 222-228. 2018. Doi: 10.1017/S0960258518000235.
- BROSNAN, T.; SUN, D.-W. Improving quality inspection of food products by computer vision-a review. **Journal of Food Engineering**, v. 61, n. 1, p. 3-16. 2004. Doi: [https://doi.org/10.1016/S0260-8774\(03\)00183-3](https://doi.org/10.1016/S0260-8774(03)00183-3).
- BROSNAN, T.; SUN, D.-W. 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. Doi: [https://doi.org/10.1016/S0168-1699\(02\)00101-1](https://doi.org/10.1016/S0168-1699(02)00101-1).
- DELL'AQUILA, A. The use of image analysis to monitor the germination of seeds of broccoli (*Brassica oleracea*) and radish (*Raphanus sativus*). **Annals of Applied Biology**, v. 146, n. 4, p. 545. 2005. Doi: <https://doi.org/10.1111/j.1744-7348.2005.040153.x>.
- DELL'AQUILA, A. Pepper seed germination assessed by combined X-radiography and computer-aided imaging analysis. **Biologia plantarum**, v. 51, n. 4, p. 777-781. 2007. Doi: 10.1007/s10535-007-0159-9.
- DELL'AQUILA, A. Digital imaging information technology applied to seed germination testing. A review. **Agronomy for Sustainable Development**, v. 29, n. 1, p. 213-221. 2009. Doi: <https://doi.org/10.1051/agro:2008039>.
- DELL'AQUILA, A., VAN ECK, J.; VAN DER HEIJDEN, G. The application of image analysis in monitoring the imbibition process of white cabbage (*Brassica oleracea* L.) seeds. **Seed Science Research**, v. 10, n. 2, p.163-169. 2000. Doi: 10.1017/S09602585 00000179.
- DU, C.-J.; SUN, D.-W. Recent developments in the applications of image processing techniques for food quality evaluation. **Trends in Food Science & Technology**, v. 15, n. 5, p. 230-249. 2004. Doi: <https://doi.org/10.1016/j.tifs.2003.10.006>.
- DU, C.-J.; SUN, D.-W. Learning techniques used in computer vision for food quality evaluation: a review. **Journal of Food Engineering**, v. 72, n. 1, p. 39-55. 2006. Doi: <https://doi.org/10.1016/j.jfoode ng.2004.11.017>.
- DUCOURNAU, S.; FEUTRY, A.; PLAINCHAULT, P.; REVOLLON, P.; VIGOUROUX, B.; WAGNER, M. H. An image acquisition system for automated monitoring of the germination rate of sunflower seeds. **Computers and Electronics in Agriculture**, v. 44, n. 3, p. 189-202, 2004. Doi: <https://doi.org/10.1016/j.compag.2004.04.005>.
- ELISABETH, J. M. B.; ESTHER, N. D. K.; SUSAN, G. B. D. K.; JOYCE, S.; AREND, G. J. A. NIELS, F. M. K.; THEO, J. M. R. Hyperspectral imaging for tissue classification, a way toward smart laparoscopic colorectal surgery. **Journal of Biomedical Optics**, v. 24, n. 1, p. 1-9, 2019. Doi: <https://doi.org/10.1117/1.JBO.24.1.016002>.

- ELMASRY, G.; ELGAMAL, R.; MANDOUR, N.; GOU, P.; AL-REJAIE, S.; BELIN, E.; ROUSSEAU, D. Emerging thermal imaging techniques for seed quality evaluation: Principles and application. **Food Research International**, v. 131, p. 109025, 2020. Doi: <https://doi.org/10.1016/j.foodres.2020.109025>.
- FENG, X.; ZHAN, Y.; WANG, Q.; YANG, X.; YU, C.; WANG, H.; HE, Y. Hyperspectral imaging combined with machine learning as a tool to obtain high-throughput plant salt-stress phenotyping. **The Plant Journal**, v. 101, n. 6, p. 1448-1461. 2020. Doi: [10.1111/tpj.14597](https://doi.org/10.1111/tpj.14597).
- FENG, L., ZHU, S., LIU, F.; HE, Y.; BAO, Y.; ZHANG, C. Hyperspectral imaging for seed quality and safety inspection: a review. **Plant Methods**, v. 15, n. 91, 2019. Doi: <https://doi.org/10.1186/s13007-019-0476-y>.
- GALLETTI, P. A.; CARVALHO, M E. A.; HIRAI, W. Y. BRANCAGLIONI, V. A.; ARTHUR, V.; BARBOZA DA S. C. Integrating optical imaging tools for rapid and non-invasive characterization of seed quality: Tomato (*Solanum lycopersicum* L.) and Carrot (*Daucus carota* L.) as study cases. **Frontiers in Plant Science**, v. 11, p. 2041, 2020. Doi: [10.3389/fpls.2020.577851](https://doi.org/10.3389/fpls.2020.577851).
- GEETHA, V.; BALAMURUGA, V.; P.; BHASKARAN, M. Characterization of mustard genotypes through image analysis. **Research Journal of Seed Science**, v. 4, n. 4, p. 192-198. 2011. Doi: [10.3923/rjss.2011.192.198](https://doi.org/10.3923/rjss.2011.192.198).
- GUNASEKARAN, S. Computer vision technology for food quality assurance. **Trends in Food Science & Technology**, v. 7, n. 8, p. 245-256, 1996. Doi: [https://doi.org/10.1016/0924-2244\(96\)10028-5](https://doi.org/10.1016/0924-2244(96)10028-5).
- HUANG, M.; WANG, Q. G. G.; ZHU, Q. B. B.; QIN, J. W. W.; HUANG, G. Review of seed quality and safety tests using optical sensing technologies. **Seed Science and Technology**, v. 43, n. 3, p. 337-366, 2015. Doi: <https://doi.org/10.15258/sst.2015.43.3.16>.
- JAYAS, D.; PALIWAL, J.; VISEN, N. S. Review paper (AE-Automation and emerging technologies): multi-layer neural networks for image analysis of agricultural products. **Journal of Agricultural Engineering Research**, v. 77, n. 2, p. 119-128. 2000. Doi: <https://doi.org/10.1006/jaer.2000.0559>.
- JHA, K.; DOSHI, A.; PATEL, P.; SHAH, M. A comprehensive review on automation in agriculture using artificial intelligence. **Artificial Intelligence in Agriculture**, v. 2, p. 1-12, 2019. Doi: <https://doi.org/10.1016/j.aiia.2019.05.004>.
- KAKKAD, V.; PATEL, M.; SHAH, M. Biometric authentication and image encryption for image security in cloud framework. **Multiscale and Multidisciplinary Modeling, Experiments and Design**, v. 2, p. 233-248, 2019. Doi: <https://doi.org/10.1007/s41939-019-00049-y>.
- KAMILARIS, A.; PRENAFETA-BOLDÚ, F. X. Deep learning in agriculture: A survey. **Computers and Electronics in Agriculture**, v. 147, p. 70-90, 2018. Doi: <https://doi.org/10.1016/j.compag.2018.02.016>.

- KANNUR, A.; KANNUR, A.; RAJPUROHIT V. S. Classification and grading of bulk seeds using artificial neural network. **International Journal of Machine Intelligence**, v. 3, n. 2, p. 62-73, 2011. Doi: 10.9735/0975-2927.3.2.62-73.
- KOTWALIWALE, N.; SINGH, K.; KALNE, A.; JHA, S. N.; SETH, N.; KAR, A. X-ray imaging methods for internal quality evaluation of agricultural produce. **Journal of Food Science and Technology**, v. 51, n. 1, p. 1–15, 2014. Doi: <https://doi.org/10.1007/s13197-011-0485-y>.
- KUMAR, P.; ASHOK, G. Design and fabrication of smart seed sowing robot. **Materials Today: Proceedings**, v. 39, p. 354-358, parte 1, 2021. Doi: <https://doi.org/10.1016/j.matpr.2020.07.432>.
- KUMAR, Y.; KARNE, S. C. Spectral analysis: a rapid tool for species detection in meat products. **Trends meato in Food Science & Technology**, v. 62, p. 59-67, 2017. Doi: 10.1016 /j.tifs.2017.02.008.
- LIU, W.; CHANG, J.; LI, J.; FU, D.; XIAOHUI, Y. High-throughput phenotyping of morphological seed and fruit characteristics using x-ray computed tomography. **Frontiers in Plant Science**, v. 11, p. 1783, 2020. Doi:10.3389/fpls.2020.601475.
- GAGLIARDI, B; MARCOS-FILHO, J. Relationship between germination and bell pepper seed structure assessed by the X-ray test. **Scientia Agricola**, v. 68, p. 411-416, 2011. Doi: <https://doi.org/10.1590/S0103-90162011000400004>.
- LODDO, A.; LODDO, M.; DI RUBERTO, C. A novel deep learning based approach for seed image classification and retrieval. **Computers and Electronics in Agriculture**, v. 187, p. 106269, 2021. Doi: <https://doi.org/10.1016/j.compag.2021.106269>.
- MAHAJAN, S.; DAS, A., SARDANA, H. K. Image acquisition techniques for assessment of legume quality, **Trends in Food Science & Technology**, v. 42, n. 2, p. 116-133. 2015. Doi: <https://doi.org/10.1016/j.tifs.2015.01.001>.
- MEDEIROS, A. D. de; BERNARDES, R. C.; da SILVA, L. J.; FREITAS, B. A. L. de; DIAS, D. C. F. dos S.; DA SILVA, C. B., Deep learning-based approach using X-ray images for classifying *Crambe abyssinica* seed quality, **Industrial Crops and Products**, v. 164, p. 113378, 2021. Doi: <https://doi.org/10.1016/j.indcrop.2021.113378>.
- MEDEIROS, A. D.; PINHEIRO, D. T.; XAVIER, W. A.; da SILVA, L. J.; DIAS, D. C. F. S. Quality classification of *Jatropha curcas* seeds using radiographic images and machine learning. **Industrial Crops and Products**, v. 146, p. 112162, 2020a. Doi: <https://doi.org/10.1016/j.indcrop.2020.112162>.
- MEDEIROS, A. D.; SILVA, L. J.; SILVA, J. M.; DIAS, D. C. F. S.; PEREIRA, M. D. IJCropSeed: An open-access tool for high-throughput analysis of crop seed radiographs. **Computers and Electronics in Agriculture**, v. 175, p. 105555, 2020b. Doi: <https://doi.org/10.1016/j.compag.2020.105555>.



- MOONEY, S. J.; PRIDMORE, T. P.; HELLIWELL, J.; BENNETT, M. J. Developing X-ray computed tomography to non-invasively image 3-D root systems architecture in soil. **Plant Soil**, v. 352, 1–22, 2012. Doi: <https://doi.org/10.1007/s11104-011-1039-9>.
- OLIVEIRA, G. R. F. de; SALLES, F. K. L. de; BATISTA, T. B.; SILVA, M. S. da; Cicero, S. M.; GOMES-JUNIOR, F. GUILHIEN. Morphological parameters of image processing to characterize primary root emergence in evaluation of tomato seed vigor. **Journal of Seed Science**, v. 43, p. e202143005, 2021. Doi: 10.1590/2317-1545v4324 5215.
- PANCHIWALA, S.; SHAH, M. A. Comprehensive study on critical security issues and challenges of the IoT world. **Journal of Data, Information and Management**, v. 2, n. 7, 257-278. 2020. Doi: 10.1007/s42488-020-00030-2.
- PARAFOROS, D. S.; VASSILIADIS, V.; KORTENBRUCK, D.; STAMKOPOULOS, K.; ZIOGAS, V.; SAPOUNAS, A. A.; GRIEPENTROG, H. W. Multi-level automation of farmmanagement information systems. **Computers and Electronics in Agriculture**, 142,504–514. <https://doi.org/10.1016/j.compag.2017.11.022>.
- PATEL, D.; SHAH, Y.; THAKKAR, N.; SHAH, K.; SHAH, M. Implementation of artificial intelligence techniques for cancer detection. **Augmented Human Research**, v. 5, n. 1, 2020<sup>a</sup>. Doi: 10.1007/s41133-019-0024-3.
- PATEL, H.; PRAJAPATI, D.; MAHIDA, D.; SHAH, M. Transforming petroleum downstream sector through big data: a holistic review. **Journal of Petroleum Exploration and Production Technology**, v. 10, p. 2601-2611, 2020<sup>b</sup>. Doi: 10.1007/ s13202-020-00889-2.
- PATHAN, M., PATEL, N., YAGNIK, H.; SHAH, M. Artificial cognition for applications in smart agriculture: A comprehensive review, **Artificial Intelligence in Agriculture**, v. 4, p. 81-95, 2020. Doi: <https://doi.org/10.1016/j.aiaa.2020.06.001>.
- PATRÍCIO, D. I.; RIEDER, R. Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review, **Computers and Electronics in Agriculture**, v. 153, p. 69-81, 2018. doi: <https://doi.org/10.1016/j.compag.2018.08.001>.
- PINHEIRO, R. de M.; GADOTTI, G. I.; MONTEIRO, R. de C. M.; BERNARDY, R. Inteligência artificial na agricultura com aplicabilidade no setor sementeiro. **Diversitas Journal**, v. 6, n. 3, p. 2996-3012, 2021a. Doi: <https://doi.org/10.48017/DiversitasJournal-v6i3-1857>.
- PINHEIRO, R. M.; GADOTTI, G. I.; BERNARDY, R.; ASCOLI, C. A. Análise do desempenho de técnicas de aprendizado de máquina para classificação de lotes de sementes de soja. In: 7 SIEPE- Semana Integrada UFPEL 2021- XXII Encontro de Pós-Graduação, **Anais... ENPÓS**, 2021<sup>b</sup>, Pelotas. XXIII ENPÓS, 2021.

- RAHMAN, A.; CHO, B. Assessment of seed quality using non-destructive measurement techniques: A review. **Seed Science Research**, v. 26, n. 4, p. 285-305. 2016. Doi: 10.1017/S096 0258516000234.
- SHAH, M.; SIRCAR, A.; SHAIKH, N.; PATEL, K.; THAKAR, V.; SHARMA, D.; SARKAR, P.; VAIDYA, D. Groundwater analysis of dholera geothermal field, Gujarat, India for suitable application. **Groundwater for Sustainable Development**, v. 7, p. 143-156, 2018b. Doi: <https://doi.org/10.1016/j.gsd.2018.05.002>.
- SHAH, M.; VAIDYA, D.; SIRCAR, A. Using Monte Carlo simulation to estimate geo-thermal resource in Dholera geothermal field, Gujarat, India. **Multiscale and Multidisciplinary Modeling, Experiments and Design**, v. 1, p. 83-95, 2018a. Doi: <https://doi.org/10.1007/s41939-018-0008-x>.
- SIVAKUMAR, V.; ANANDALAKSHMI, R.; WARRIER, REKHA, R.; SINGH, B. G.; TIGABU, M.; NAGARAJAN, B. Discrimination of *Acacia* seeds at species and subspecies levels using an image analyzer. **Forest Science and Practice**, v. 15, n. 4, p. 253. 2013. Doi: 10.1007/s11632-013-0414-4.
- ŠKRUBEJ, U. ROZMAN, Č.; STAJNKO, D. Assessment of germination rate of the tomato seeds using image processing and machine learning. **European Journal of Horticultural Science**, v. 80, n. 2, p. 68. 2015. Doi: <http://dx.doi.org/10.17660/eJ HS.2015/80.2.4>.
- SUMATHI, S.; BALAMURUGA, P. Characterization of oats (*Avena sativa L.*) cultivars using machine vision. Paquistão. **Journal of Biological Sciences**, v. 16, n. 20, p. 1179. 2013. Doi: 10.3923/pjbs.2013.1179.1183.
- TALAVIYA, T.; SHAH, D.; PATEL, N.; YAGNIK, H.; SHAH, M. Implementation of artificial intelligence in agriculture for optimisation of irrigation and application of pesticides and herbicides. **Artificial Intelligence in Agriculture**, v. 4, p. 58-73, 2020. Doi: 10.10 16/j.aiia.2020.04.002.
- TANABATA, T.; SHIBAYA, T.; HORI, K.; EBANA, K.; YANO, M. Smartgrain: high-throughput phenotyping software for measuring seed shape through image analysis. **Plant physiology**, v. 160, n. 4, p. 1871–1880, 2021. Doi: 10.1104/pp.112 .205120.
- TEIXEIRA, P. C. N.; COELHO NETO, J. A.; ROCHA, H.; OLIVEIRA, J. M. An instrumental set up for seed germination studies with temperature control and automatic image recording. **Brazilian Journal of Plant Physiology**, v. 19, n. 2, p. 99-108. 2007. Doi: 10.1590/S1677-04202007000200002.
- TOPP, C. N., IYER-PASCUZZI, A. S., ANDERSON, J. T., LEE, C. R., ZUREK, P. R., SYMONOVA, O.; ZHENG, Y.; BUCKSCH, A.; MILEYKO, Y.; GALKOVSKYI, T.; MOORE, B. T. HARER, J.; EDELSBRUNNER, H.; MITCHELL-OLDS, T.; WEITZ, J. S.; BENFEY, P. N. 3D phenotyping and quantitative trait locus mapping identify core regions of the rice genome controlling root architecture. **Proceedings of the National Academy of Sciences**, v. 110, n. 18, p. E1695–E1704, 2013. Doi: 10.1073/pnas.1304 354110.

van DUSSCHOTEN, D.; METZNER, R.; KOCHS, J.; POSTMA, J. A.; PFLUGFELDER, D.; BÜHLER, J.; SHURR, U.; JAHNKE. Quantitative 3D analysis of plant roots growing in soil using magnetic resonance imaging. **Plant Physiology**, v. 170, n. 3, p. 1176–1188, 2016. Doi: <https://doi.org/10.1104/pp.15.01388>.

WU, D.; SUN, D-W. Advanced applications of hyperspectral imaging technology for food quality and safety analysis and assessment: A review - Part II: Applications. **Innovative Food Science & Emerging Technologies**, v. 19, p. 15–28. 2013. Doi: <https://doi.org/10.1016/j.ifset.2013.04.016>.

XING, F.; YAO, H.; LIU, Y.; DAI, X.; BROWN, R. L.; Bhatnagar, D. Recent developments and applications of hyperspectral imaging for rapid detection of mycotoxins and mycotoxigenic fungi in food products. **Critical Reviews in Food Science and Nutrition**, v. 59, n. 1, p. 173-180. 2019. Doi: [10.1080/10408398.2017.1363709](https://doi.org/10.1080/10408398.2017.1363709).

ZHANG, C.; GUO, C.; LIU, F.; KONG, W.; HE, Y.; LOU, B. Hyperspectral imaging analysis for ripeness evaluation of strawberry with support vector machine. **Journal of Food Engineering**, v. 179, p. 11-18, 2016. Doi: <https://doi.org/10.1016/j.jfoodeng.2016.01.010>

## **5 CAPÍTULO III - TÉCNICA DE MINERAÇÃO DE DADOS NÃO SUPERVISIONADO NO PROCESSO DE SECAGEM DE SEMENTES**

### **5.1 INTRODUÇÃO**

A inteligência artificial por meio do aprendizado profundo de máquina e mineração de dados são poderosas ferramentas inter-relacionadas para design eficaz e otimização de desempenho, análise de dados e monitoramento e controle de sistema (WANG et al., 2020). É uma ferramenta muito importante que pode ser usada para resolver vários desafios no setor sementeiro, como capacidade de tomada de decisão sobre germinação, vigor, detecção de patogenicidade, qualidade de armazenamento e condições de secagem.

A crescente demanda da agricultura inteligente levou ao crescimento e desenvolvimento significativos no campo da estimativa e previsão de safras, melhorando sua produtividade (SHARMA et al., 2022). As etapas de pós-colheita ou pré-semeadura são situações que requerem atenção e cuidado, devido a quantidade elevada de informações geradas para se obter respostas rápidas sobre a qualidade de sementes e assim, garantir o rendimento máximo da cultura.

Quando são geradas informações das respectivas etapas de pós-colheita relacionado as cultivares, tratamentos, safra, peneira, pureza, percentual de infestação por micro-organismos, percentual de outras sementes, germinação e vigor, torna-se um trabalho lento e de pouca eficiência para a tomada de decisão rápida (PINHEIRO et al., 2021). Estes são um dos fatores mais avaliados em processo de qualidade. Porém, não podemos deixar de atender os processos de beneficiamento, secagem e armazenamento no qual são primordiais para completar o ciclo de sucesso em um estabelecimento de lavoura.

Obviamente, a inteligência artificial foi identificada como uma ferramenta indispensável para deter o desafio da instabilidade e obter respostas rápidas sobre a geração de dados elevados e vem se aprimorando no setor de sementes. Hoje, há uma necessidade urgente de decifrar questões de eficiência de equipamentos agrícolas (secadores artificiais) sobre os resultados durante a secagem de sementes, a fim de garantir segurança e qualidade do produto. Na escolha do método de secagem, o fator quantidade de sementes é limitante e, como

necessitamos secar grandes quantidades, é imprescindível a utilização de secagem artificial, cujos custos de operação estão relacionados com volume, velocidade de secagem e temperatura do ar (GARCIA et al., 2004).

A secagem de sementes, além de contribuir para sua preservação da qualidade fisiológica durante o armazenamento, possibilita a antecipação da colheita evitando perdas durante o processo produtivo (DHURVE et al., 2022). Os dados sobre teor de água nas sementes e grãos ajudam na tomada de decisão, sobre a eficiência do equipamento. O aprendizado de máquina não supervisionado tenta obter resposta não direcionadas, permitindo que a decisão seja determinada pelo próprio modelo preditivo. De acordo com Onukwuli et al. (2021), a mineração de dados é uma técnica para extrair padrões essenciais e conhecimento de um grande conjunto de dados. O aprendizado de máquina inclui uma ampla variedade de algoritmos para aprender regras preditivas a partir de dados históricos e construir um modelo que possa prever dados futuros invisíveis (ARUMUGAM et al., 2022).

O secador de sementes e grãos contribuem significativamente para manutenção da qualidade fisiológica de sementes e nesta operação de secagem é fundamental compreender as informações geradas através dos equipamentos agrícolas, pois, é uma operação de risco, podendo proporcionar danos irreversíveis se realizada sem os conhecimentos e cuidados necessários à preservação, comprometendo a qualidade inicial das sementes.


Diante do exposto, o objetivo com este trabalho foi avaliar o desempenho de secagem em secadores fixo e móveis utilizando a ferramenta de aprendizado de máquina.

## **5.2 MATERIAL E MÉTODOS**

O estudo foi realizado em equipamento agrícola, conforme sua condição de instalação, sendo secadores fixo (instalado debaixo de um galpão) e móvel (instalado em carretas e transportado para as fazendas), no qual seu funcionamento é através de sistema de aquecimento a gás em grande escala e contém painel de controle.

A configuração consiste em uma unidade de ventilador movido por um motor elétrico, válvulas de controle de fluxo, aquecedor a gás, câmara de secagem e sensores da temperatura de ar e da massa das sementes. O secador móvel era

conduzido até a propriedade, no qual estava montado em um caminhão de transporte de carga. E o secador fixo era instalado em propriedades com galpões fechados (Figura 1).



**Figura 1** - Esquemática dos sistemas de secagem, onde o equipamento agrícola fica instalado, o fixo fica embaixo de um galpão e o móvel poderia ficar no meio da lavoura ou em um veículo móvel. (fonte: adaptação de Daurana Oliveira).

O tipo de secador estudado apresenta dimensões 6,65 m de comprimento x largura 2,50 m x altura 3,25 m, além de um formato semelhante a um octógono. Suas divisões são compostas por 12 células no qual, comporta uma camada de sementes de aproximadamente 45 cm de espessura. Tem uma capacidade total de 17 t ou aproximadamente 300 sacos por carga. Seu funcionamento é através de um sistema de gás GLP passando entre os queimadores no interior do secador para seu aquecimento, além de apresentar motor de 12,5 cv modelo premium W22 (rotação 1765 rpm, tensão 220-380 V) com hélices de 795 mm (pás de 37,5°). Também é composto por um painel de controle digital que controla a temperatura do ar, além da pressão de gás.

Foram levantados dados obtidos no processo de secagem de sementes de algumas culturas agrícolas como soja, milho, cevada, gergelim, feijão referente aos anos de 2020 a 2021. Foram coletados os dados referentes a secagem obtidos com base em: i) total de secadores em funcionamento em cada cliente; ii) tempo de duração de secagem nos equipamentos (horas); iii) percentual de umidade das

sementes na entrada e saída do produto (%); e iv) diferenças de umidade entres ambas (%).

A quantidade total dos elementos apresentou um conjunto de dados com 2028 informações sobre os atributos de secagens, no qual é primordial compreender o tempo de duração da secagem, para isso foi coletado informações de horário de entrada e saída, umidade de entrada e saída em ambos os sistemas de secadores, além de temperatura. Esses dados foram analisados e confrontados com os sistemas de avaliação tanto para sistema fixo ou móvel de secagem, onde se pudesse observar a tomadas de decisão em equipamentos individuais, como também em conjunto dos sistemas.

Para compreender esta etapa inicial foram utilizadas técnicas de inteligência artificial e mineração de dados. Sendo necessário preparar os dados de inserção de acordo com a leitura do software. Então, realizou-se a organização dos dados brutos. Inicialmente foi necessário a realização de pré-processamento destes, de modo a preparar o conjunto para que a ferramenta possa efetuar a correta leitura e análise. Nessa etapa, os dados recebidos em formato .xls (Excel) são tratados para que possa ser compatível com o software, passando a colocar todos os atributos em uma única linha e, cada valor, em colunas, abaixo do seu respectivo atributo.

Posteriormente foi convertido o arquivo para formato .csv, com isso o conjunto de dados foi executado com auxílio do software Bloco de Notas do Microsoft Windows®, necessitando a substituição das “vírgulas”, quando o valor atribuído era decimal (número com vírgulas), para “pontos” e dos “ponto e vírgula”, que realizam a divisão das colunas dos atributos, para “vírgulas”. Além disso, linhas com valores faltantes ou dados considerados equivocados durante a análise das planilhas foram excluídos neste processamento prévio.

Para utilizar como atributo o tipo de sistema (fixo ou móvel), foi necessário substituir o termo “fixo” por 1 e o “móvel” por 2, pois a análise dos algoritmos é realizada através do software Weka, versão 3.8.5, aceitando somente dados numéricos nos atributos considerados “features”. Foi realizado o processo de clusterização para encontrar padrões no conjunto de dados proposto. O algoritmo empregado foi o "Filtered Clusterer" para a mineração de dados. O treinamento dos dados foi realizado com 66% dos mesmos (1338 secagens aleatórias). E também foi utilizado filtros, como o “Resample”, e parâmetros de avaliação diferentes nos algoritmos citados, sendo o número de repetições e “clusters” realizados, bem como

o método matemático para encontrar as semelhanças dos dados, para efetuar testes de modo a otimizar os resultados, reduzindo erros na avaliação.

Também foi utilizado o modelo algoritmo "*K-Means*", por ser método de agrupamento baseado em partições amplamente utilizado. Este algoritmo encontra qual é o centroide mais próximo e define-o como representante do dado treino. Algoritmo k-means encontra k (agrupamento) clusters,  $C = \{c_1, \dots, c_k\}$  de um determinado conjunto de pontos de dados  $n$ ,  $d$ -dimensionais  $D = \{x_1, \dots, x_n\}$  de modo a minimizar a distância quadrada de cada ponto de dados para o centro do cluster mais próximo (KUMAR e REDDY 2017), no qual eles propõem uma equação denominada *Squared Error Distortion* -SED (Equação 1).

$$SED = \sum_{i=1}^n \sum_{j=1 \dots k}^K \|x_i - \bar{c}_j\|^2 \quad \text{Equação 1}$$

$\bar{c}_j$  é a média do cluster  $c_j$

De acordo com Yao et al. (2013), este algoritmo divide os dados em uma classe predeterminada com base na minimização da função de erro. O *K*-significa que o algoritmo de agrupamento faz particionamento dos algoritmos de agrupamento de espaço de recursos, que é amplamente utilizado.

As etapas do cálculo realizado pelo algoritmo de agrupamento são as seguintes: Primeira: Seleciona aleatoriamente a partir do conjunto de dados de pontos como centros iniciais do cluster. Segunda: Respectivamente calcula a distância de cada amostra para os centros de cluster, a amostra é colocada sob a classe mais próxima. Terceira: De acordo com os resultados do agrupamento, recalcula o centro do agrupamento. O método de cálculo é tomar a média aritmética de todos os elementos como o novo centro de agrupamento. Quarta: De acordo com o novo centro, reagrupa todos os elementos do conjunto de dados. Quinta: Repete a quarta etapa até que o agrupamento não seja alterado. Sexta: Emite o resultado.

### 5.3 RESULTADOS

Os resultados obtidos a partir desta pesquisa podem auxiliar o processo de tomada de decisão por meio de inteligência artificial através do aprendizado de máquina não-supervisionado, no qual envolve a identificação dos dados fornecidos

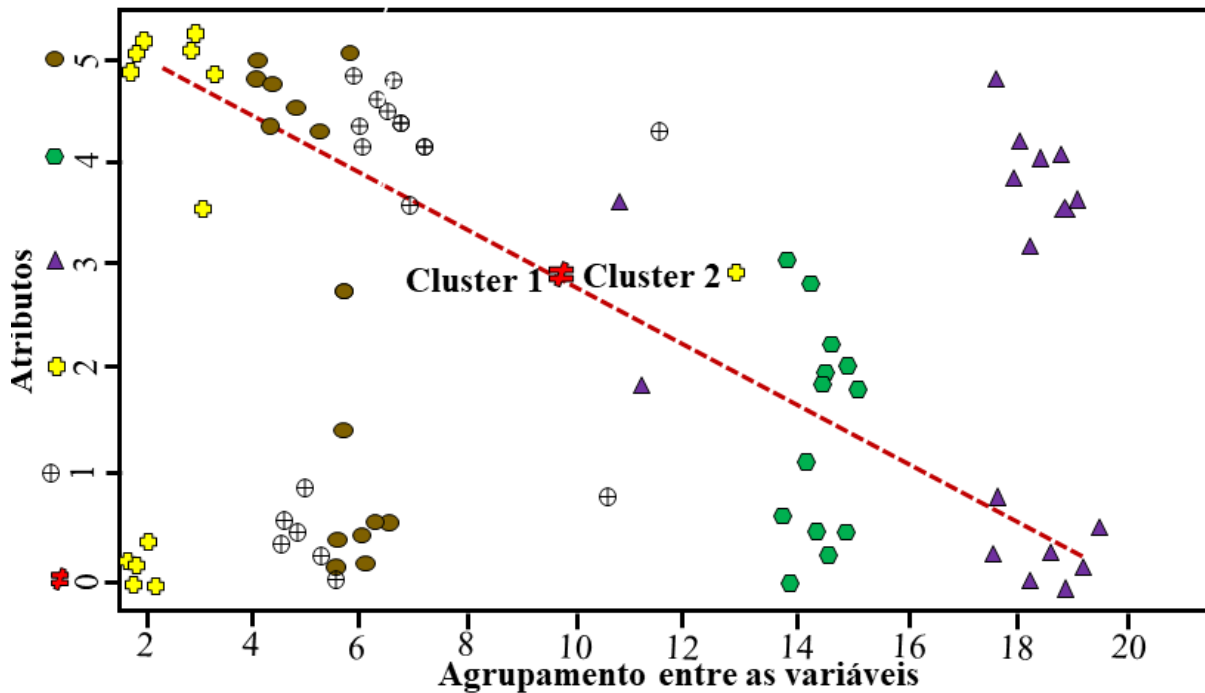


durante a secagem de sementes, agrupando-os em classes, de modo que, o algoritmo *Filtered Clusterer* executasse no conjunto de dados sistema de secagem fixo e móvel em conjuntos para uma análise padrão, já que, estrutura do filtro é baseada exclusivamente nos dados de treinamento e as instâncias de teste serão processadas pelo filtro sem alterar sua estrutura (Tabela 1).

**Tabela 1** - Resultados do agrupamento de dados para os sistemas de secagem de acordo com as variáveis estabelecidas em modelo padrão de avaliação. T. secadores é o total de secadores necessário para execução do trabalho, conforme predição do algoritmo.

<b>Atributo</b>	<b>Cluster 1</b>	<b>Cluster 2</b>
Sistemas	1 (fixo)	2 (móvel)
T. secadores	5,15	6,06
Duração (h)	01:43	01:55
Umidade Entrada (%)	19,60	19,68
Umidade Saída (%)	13,28	14,72
Diferença de umidade (%)	6,31	4,95

Na Tabela 1 e Figura 2 observam-se os valores de separação realizados pelo filtro em dois clusters, conforme o sistema de secagem utilizado. Demonstrando que os resultados de secagem são distintos entre os equipamentos fixo e móvel, com diferenças bem definidas dentro dos sistemas de secagem estabelecidos.



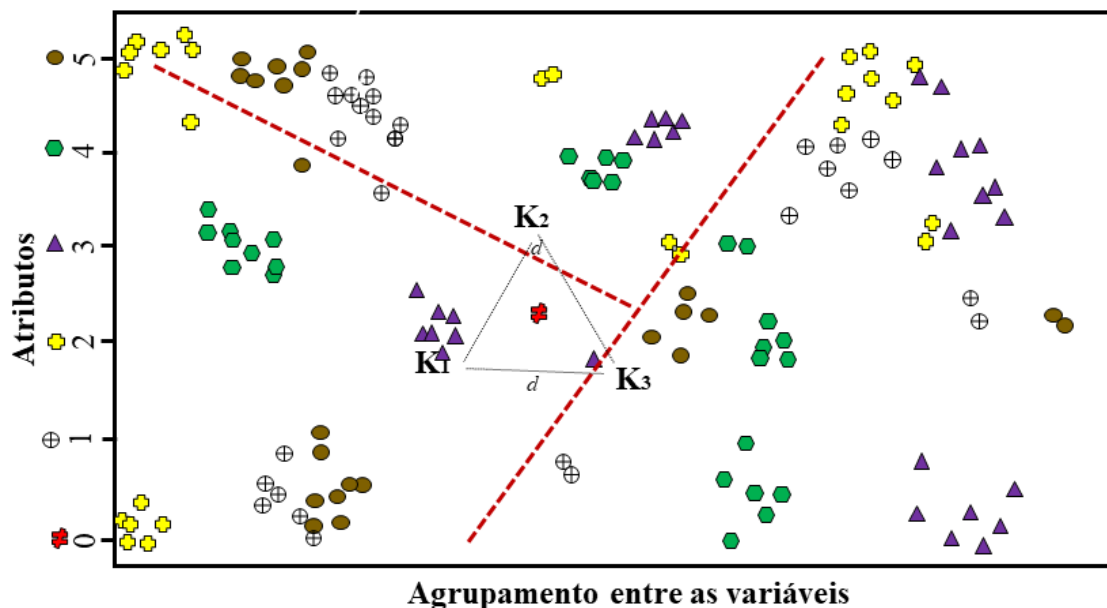
**Figura 2** - Representa a proximidade entre os pares de dados calculados com diferentes noções de distância entre as variáveis. [0] diferença entre secador fixo e móvel ou cluster 1 e cluster 2; [1] total de secadores (unidade); [2] duração de secagem (h); [3] umidade de entrada (%); [4] umidade saída (%) e [5] diferença de secagem entre o sistema fixo e móvel (%).

Constata-se na Tabela 1 que a diferença mais expressiva é em relação à umidade de entrada e saída com o tempo de secagem, onde o secador fixo apresentou menor tempo para a retirada de água (4,41 p.p./h), mesmo apresentando um percentual elevado de umidade. Já o secador móvel, necessitou de mais tempo para reduzir o percentual de umidade das sementes e não atingiu os padrões estabelecido de secagem adequada para sementes, pois o principal objetivo é reduzir a umidade em um percentual de 12% ou 13% para milho, soja, feijão, gergelim e cevada (14,72%).

Após a análise do resultado gerado pelo *Filtered Clusterer* observou-se (Figura 2) que ainda se encontravam dados dispersos. Então, o conjunto de dados foi novamente submetido a avaliação, porém, com a adição do algoritmo "*K-Means*", onde o número de clusters e interações é definido exclusivamente pelo software de execução do algoritmo. Além disso, foi utilizado o filtro "*Resample*", que informa ao software o número ideal de repetições para o treinamento de modo que no final o

classificador demonstre seu máximo desempenho para classificação do conjunto de dados. Nesta avaliação dos dados com o modelo *K-means*, verificou-se que o agrupamento em duas classes não contemplava todas as informações, deixando alguns dados dispersos (Figura 2). A quantidade média total de secadores trabalhando em cada sistema demonstrou que o tempo de secagem são semelhantes, pois o processo de retirada do conteúdo de água, pode ser influenciado pelo ambiente de trabalho onde o secador está instalado.

O modelo *K-means* define os pontos aleatórios chamado de centroides, a partir de cada agrupamento o algoritmo calcula a média aritmética e define o resultado com os valores para representar aquele agrupamento onde estabelece os valores próximos dos clusters de separação, a partir de dois ou mais agrupamentos (Figura 2). As variáveis apresentadas no processo de secagem de sementes são informações primordiais para que se obtenha o sucesso no armazenamento. Os dados para a quantidade de secadores em etapas de secagem também influenciam na tomada de decisão, podendo tornar o processo mais rápido, necessitando de agilidade nestas etapas de secagem. Portanto, verifica-se na Figura 3 e Tabela 2 as diferenças entre os sistemas pré-estabelecidos para eficiência da secagem em locais bem distintos, sendo esses, um local que se mantém o secador fixo e ou outro em local móvel sobre uma carreta.



**Figura 3** - Comportamento dos dados com divisão inter-cluster em relação ao agrupamento no sistema fixo ( $K_1$  e  $K_2$ ) e móvel ( $K_3$ ). [0] diferença entre secador fixo e móvel ou cluster 1 e cluster 2; [1] total de secadores (unidade); [2] duração de secagem (h); [3] umidade de entrada (%); [4] umidade saída (%) e [5] diferença de

secagem entre o sistema fixo e móvel (%).  $d$ - Distância dimensional entre os pontos; K- Agrupamento.

Na tabela 2 constata-se uma divisão de dois Cluster no sistema de secagem fixa, pois o conjunto de dados apresentava mais dados dispersos. A quantidade total de secadores necessária para diminuir o teor de água não influencia muito nesta etapa, pois o tempo de duração da secagem em ambos são muito semelhantes. O que pode ser favorável ao secador é o fato de sua eficiência se tornar elevada, pois conta com dois fatores para secar a semente, velocidade de secagem ao ar (atingindo 26 m/s) e a temperatura (combustão a gás adequado para sementes, 35-37 °C).

**Tabela 2** - Mineração de dados realizada com dois sistemas (fixo e móvel) juntos utilizando filtro Resample e os algoritmos "*Filtered Clusterer*" + "*K-Means*". T. secadores é o total de secadores necessário para execução do trabalho, conforme predição do algoritmo.

Atributo	Cluster 1	Cluster 2	Cluster 3
Sistema	1 (fixo)	1 (fixo)	2 (móvel)
T. secadores	6,43	3,16	6,11
Duração (h)	01:31	01:47	1:56
Umidade Entrada (%)	20,32	16,56	19,75
Umidade Saída (%)	13,23	13,57	14,65
Diferença de umidade (%)	7,09	2,99	5,10

Nessa segunda avaliação, o algoritmo definiu três clusters, diferenciando o sistema fixo pela quantidade de secadores utilizados. O primeiro foi definido com o número maior de secadores, resultando conseqüentemente em menor tempo de secagem para reduzir maior conteúdo de água ao final do processo (5,41 p.p./h). O segundo cluster se restringiu a um menor número de secadores e menor umidade inicial de processo com 2,03 p.p./h e finalmente o terceiro com um pouco menos de secadores que o primeiro, mas com menor eficiência (3,27 p.p./h) corroborando que os secadores móveis são menos eficientes. De maneira geral, o algoritmo

demonstrou que para o tempo de secagem (01:44 h), baixar em média 5,06 p.p./h é necessário aumentar a quantidade de secadores, porém se o teor de umidade estiver alto toda essas etapas também aumentam. De maneira que a secagem é trabalhada em cima de dois fatores umidade e temperatura.

Mesmo utilizando parâmetros semelhantes de treinamento, a mineração de dados apresentou valores diferentes para o sistema móvel de secagem. Para o sistema móvel conseguir ser mais eficiente que o fixo é necessário elevar o número de secadores no processo. Com isso, buscou-se a análise dos sistemas separadamente, de modo a entender quais padrões e diferenças poderiam ser encontradas internamente no sistema, pois as diferenças prévias entre os sistemas já são conhecidas a partir das Tabelas 1 e 2.

Na avaliação dos modelos de aprendizagem de máquina somente para os conjuntos de dados nos secadores fixos (Tabela 3), o algoritmo criou dois clusters diferenciando o atributo total de secadores, onde a coluna do cluster 1 foi determinado com o dobro de secadores e 4,27 p.p./h. Já em relação ao cluster 2 com 4,53 p.p./h. Infere-se com esses dados, que dobrar o número de secadores não aumenta eficiência de processo. Essa análise se torna importante para conhecer a eficiência do processo produtivo e como os secadores se comportam, bem como na tomada de decisão de indicação de conjuntos modulares ou secadores em paralelo.

**Tabela 3** - Mineração de dados realizada com o sistema 1 (fixo) utilizando filtro "Resample". T. secadores é o total de secadores necessário para execução do trabalho, conforme predição do algoritmo.

<b>Atributo</b>	<b>Cluster 1</b>	<b>Cluster 2</b>
Sistema	1 (fixo)	1 (fixo)
T. secadores	6,20	3,00
Duração (h)	01:03	02:13
Umidade Entrada (%)	17,80	22,55
Umidade Saída (%)	13,40	12,88
Diferença de umidade (%)	4,40	9,66

Também foi analisado o efeito individual nas etapas do processo de secagem apenas no sistema fixo, para isso, utilizando novamente o filtro "*Resample*" e o algoritmo "*Filtered Clusterer*", os resultados demonstraram que a segregação entre o sistema fixo permite observar, que quanto maior percentual de água tiver a espécie, mais tempo de secagem será necessário, porém atingido as condições ideais de umidade em sementes (Tabela 3).

**Tabela 4** - Mineração de dados realizada com o sistema 2 (móvel) utilizando filtro "*Resample*". T. secadores é o total de secadores necessário para execução do trabalho, conforme predição do algoritmo.

<b>Atributo</b>	<b>Cluster 1</b>	<b>Cluster 2</b>
Sistema	2 (móvel)	2 (móvel)
T. secadores	9,01	4,03
Duração (h)	01:25	02:16
Umidade Entrada (%)	19,74	19,64
Umidade Saída (%)	15,30	14,32
Diferença de umidade (%)	4,44	5,32

Na Tabela 4, os dados de secadores móveis demonstram a condição de secagem, não sendo tão eficiente em um curto período de tempo comparado ao fixo, 3,55 p.p./h e 3,02 p.p./h, cluster 1 e 2 respectivamente. Nessa última avaliação, o atributo com maior peso foi o total de secadores, mostrando que no sistema de secagem móvel, o algoritmo encontra semelhanças na relação entre a quantidade de secadores. Portanto, para o sistema de secagem móvel, constata-se que a sua eficiência de secagem aumenta conforme o maior número de secadores a ser utilizados, com maior tempo de secagem comparado ao fixo e ainda não atinge uma secagem ideal para sementes (12% final), sendo necessário mais tempo de operação para se obter o resultado para este fim.

A diferença entre os clusteres referente as umidades iniciais e final para cada cluster são bem expressivas, indicando que ao realizar a colheita de sementes com alto grau de umidade, o tempo de secagem vai aumentar conseqüentemente, neste caso, a eficiência de análise do secador estudado atende com maior rapidez as

culturas que obtiver umidade em torno de 18%. O trabalho do secador fixo permite melhores ajustes em seu funcionamento garantido melhor desempenho de secagem. Porém, é necessário analisar demais quesitos como gasto energético, consumo de gás, qualidade fisiológica de sementes, pós-secagem e além de outros pontos para melhor relação custo-benefício.

#### **5.4 DISCUSSÃO**

A secagem é um requisito para o manuseio e armazenamento de grãos e sementes, a fim de manter sua qualidade por longos períodos de tempo e/ou preservar os estoques de material reprodutivo de uma estação para outra (MORENO et al., 2022). Analisar e avaliar equipamentos agrícolas sobre a eficiência de secagem de sementes é essencial para armazenamento seguro por longos períodos de tempo. Importante destacar que o equipamento de secagem deve estar regulado para temperaturas ideais das cultivares. Durante a secagem e posterior armazenamento das sementes, a viabilidade é o fator mais importante a ser mantido (MAQUEDA e BALLESTORES, 2017).

Os dados analisados demonstram que o secador avaliado consegue baixar o teor de água em poucas horas de trabalho. E a quantidade de secadores utilizados no processo apenas permite agilizar uma demanda alta de produtos a serem secos. Com isso o fator importante é observar o teor de água durante a colheita. Os secadores analisados em sistema fixo apresentam uma eficiência elevada, considerando os teores de águas das cultivares analisadas, destacando o tempo/horas na redução de umidade entre os sistemas apresentados (fixo e móvel). Entretanto autores como Peske, Villela, Gadotti (2019) enfatizam que 1,2 p.p/h podem causar danos às sementes. E então a tomada de decisão deve ser no campo durante a colheita ao determinar a umidade, sabendo que colher sementes com umidade acima de 16% eleva o tempo, necessita de mais equipamento trabalhando, além de comprometer a qualidade inicial das sementes.

O sistema móvel apresentou menos eficiência no processo de secagem das sementes, demonstrando que o secador a campo está sujeito a variações ambientais impactando diretamente no processo de secagem e assim, demorando mais tempo para reduzir o teor de água das sementes. O sistema fixo de secagem demonstrou que independente dos procedimentos de análise sobre os dados

usando os algoritmos não supervisionado foram mais eficientes para separar cluster no conjunto de dados através do algoritmo K-means, permitindo observar dados mais dispersos em um mesmo sistema de secagem de sementes.

Atualmente, os efeitos de diferentes métodos de secagem sobre sementes e grãos são alvo dos equipamentos lançados no mercado, no qual, se considera o menor tempo para secar determinada cultura. Porém, deve-se atentar ao custo-benefício ao produtor, pois eles requerem algo barato, eficiente, simples de manuseio, auto rendimento, menor tempo do produto exposto a temperatura e alta qualidade final. Vários métodos de secagem têm sido usados para secagem de sementes, como ar natural, infravermelho, ar aquecido, vácuo, congelamento, leiteo fluidizado e secagem por micro-ondas para preservação, principalmente para espécies olerícolas. Entre todas as técnicas de secagem, a com ar aquecido é a preferida devido à sua simplicidade e baixo custo (DHURVE et al., 2022).

A secagem é uma tecnologia de conservação eficaz para conter o crescimento de microrganismos, reduzir as reações de degradação mediadas pela umidade (RASHMI e NEGI, 2020) e garantir a manutenção da qualidade fisiológica das sementes. As condições estabelecidas no processo de análise dos dados permitem entender a dinâmica de uma aprendizagem não-supervisionada nas etapas de pós-colheita, as abordagens definidas por algoritmos podem interagir tanto com agentes computacionais quanto com agentes humanos (HOLZINGER, 2016), tornando uma ferramenta promissora para auxiliar as etapas de pós-colheita de sementes.

O algoritmo juntamente com os filtros demonstrara serem eficientes na classificação não supervisionada, identificando e minimizando similaridade inter-cluster do sistema fixo definindo em classes distintas dentro do conjunto de dados. De acordo com Gersho e Gray (1992), a análise de cluster desempenha um papel importante em diferentes aplicações, como quantização vetorial e compactação de dados. O desempenho do K-means pode ser melhorado reduzindo os cálculos de distância envolvidos em encontrar o centro do cluster mais próximo de um ponto (KUMAR e REDDY, 2017) e assim agrupar os dados mais próximo do centroide, considerando que os dados de secagem apresentam pontos aleatórios no espaço dimensional.

Os métodos de aprendizado de máquina aplicados neste estudo foram promissores para classificar a qualidade do método de secagem de sementes. A



técnica de secagem com fluxo de ar quente é um método conveniente do ponto de vista de custo que traz diversos benefícios no processo, como higiene, distribuição uniforme, agilidade e produtos secos apresentando alta qualidade (ONWUDE et al., 2016). Porém vale ressaltar, sementes com teor de água extremamente baixos são mais suscetíveis à danos (quebra e fissuras) durante as operações mecânicas na colheita e no processamento (MEDEIROS et al., 2020).

Outros estudos com classificação fisiológica e com lotes (GADOTTI et al., 2022a, 2022b; MEDEIROS et al., 2020b, PINHEIRO., et al., 2022 e 2021), tem apresentado o uso da inteligência artificial no setor de sementes uma vez que a tomada de decisão sobre a destinação de sementes com maior qualidade é exigência dos produtores, além de estar vigente na legislação brasileira de sementes. Por isso, compreender tais fatores que ajudem na destinação correta, rapidez e menor custo-benefício é algo desafiador no setor sementeiro. Deste modo o uso do aprendizado de máquina para auxiliar na tomada de decisão é fundamental para este setor.

De acordo com André et al. (2022) e Gadotti et al. (2022b), para preencher lacunas onde as estatísticas convencionais não podem gerar resultados de previsão satisfatórios, a modelagem de dados usando técnicas de inteligência artificial pode se tornar uma alternativa viável para avaliar a qualidade de sementes. Como também, analisar métodos de secagem de sementes em equipamento que demonstre resultados rápidos e conseqüentemente consiga armazenar o produto por período prologando de tempo e com segurança.

## **5.5 CONCLUSÃO**

O método não supervisionado de aprendizado de máquina para classificação do sistema de secagem é ferramenta promissora para auxiliar esta etapa de pós-colheita de sementes. Essa abordagem identifica efetivamente o conjunto de dados dispersos de modo que o algoritmo classifica e minimiza similaridade inter-cluster do sistema de secagem fixo.

## 6 CAPÍTULO II- IMAGEM TÉRMICA PARA DETECTAR O PROCESSO DE SECAGEM DE GRÃOS E SEMENTES

### 6.1 INTRODUÇÃO

O processo de secagem artificial envolve equipamentos agrícolas que podem gerar calor através da combustão de um elemento químico e a passagem do ar quente gerado através de um ventilador ligado a um motor elétrico, que passa ar entre os queimadores de gás gerando uma massa de ar quente dentro do compartimento do secador. A pressão gerada no interior do secador empurra a massa de ar quente entre as camadas de grãos ou sementes. Sabendo-se que a secagem de produtos agrícolas é uma tarefa laboriosa no período pós-colheita (CAMAS-NAFATE et al., 2019; VEERAKUMAR et al., 2014), porém necessária para o prolongamento do armazenamento de sementes e grãos. A secagem por meio de convecção envolve um processo térmico complexo com transferência contínua de calor e massa instáveis durante todo o processo.

A secagem desempenha um papel muito importante na preservação dos produtos. Aumentando a estabilidade, diminuindo o teor de água, o crescimento microbiano e reduzindo a degradação química. As técnicas de secagem com ar quente é a preferida devido à sua simplicidade e baixo custo (DHURVE et al., 2022). Equipamentos agrícolas com alta capacidade, se torna complexo a uniformidade em todo o compartimento do secador. Assim, mantendo uma secagem desuniforme, pois um lado pode secar mais do que o outro. No caso de sementes, a não homogeneização da secagem afeta a qualidade fisiológica e aumenta danos mecânicos.

Geralmente a medição do teor de água nos grãos e sementes durante a secagem é através da retirada de amostras nos secadores, sendo essas levadas até o determinador de umidade. Além disso, há necessidade de se ter controle e conhecimento da temperatura do ar do secador e da massa de sementes. Alternativa que podem identificar locais menos ou mais quentes dentro de um secador é a câmera térmica, no qual sua emissividade através do calor demonstra pontos de temperatura diferentes. Xu et al., (2016), comentam que as câmeras termográficas estão se tornando uma alternativa sólida como ferramenta de imagem

não invasiva, não destrutiva, versátil e portátil para monitorar variações de temperatura.


As diferentes características termodinâmicas em um secador de sementes ou grãos resultam em imagens termográficas infravermelhas características. Em produtos alimentícios, a termografia tem sido empregada recentemente e com sucesso para detectar adulterações de qualidade para o consumo, pois os perfis de evolução de temperatura desses produtos são representativos de suas composições únicas, possibilitando a implementação e treinamento adequado de padrões de reconhecimento (IZQUIERDO et al., 2020a, 2020b).

Quando se trabalha com sementes é essencial o monitoramento de temperatura pois, se houver aumento haverá desuniformidade e com isso poderá apresentar uma diminuição de germinação. Moreno et al. (2022) mostram que quando determinados parâmetros operacionais do processo de secagem, como densidade de potência e temperatura, são aumentados, alcançam-se maiores taxas de secagem e, conseqüentemente, menores tempos de secagem e consumo de energia, mas a viabilidade e qualidade das sementes diminuiu.

Conforme exposto, o objetivo com este trabalho foi analisar os efeitos da eficiência de secagem em um secador estático tipo batelada convectivo, para detectar pontos desuniforme durante seu funcionamento através de uma câmera térmica.

## **6.2 MATERIAL E MÉTODOS**

Para condução deste trabalho foi determinado a aplicação de imagem térmica. Foi realizado uma análise com imagem infravermelha em um equipamento produzido por uma empresa privada brasileira (por questões de confidencialidade não será mencionado o nome da empresa). A Figura 1 demonstra dois secadores um sobreposto sobre o outro, secadores em série.



**Figura 1** - Desenho esquemático do secador avaliado neste estudo, (A) secador com corte lateral em azul são os complementos de entrada de ar nas turbinas; (B) corte do secador mostrando saída de dentro do secador para as turbinas; (C) corte com vista para a descarga e janelas para manutenção no interior do secador; (E) vista superior.

O secador apresenta dimensões 6,65 m de comprimento x largura 2,50 m x altura 3,25 m, além de um formato semelhante a um octógono. Suas divisões são compostas por 12 células no qual comporta uma camada de sementes de aproximadamente 45 cm de espessura. Tem uma capacidade total de 17 t ou aproximadamente 300 sacos por carga. Seu funcionamento é através de um sistema de gás GLP passando entre os queimadores no interior do secador para seu aquecimento, além de apresentar motor de 12,5 cv modelo premium W22 (rotação 1765 rpm, tensão 220-380 V) com hélices de 795 mm (pás de 37,5°). Também é composto por um painel de controle digital que controla a chama, temperatura do ar e da massa de sementes, além da pressão de gás.

Para obtenção das imagens térmicas foi utilizado uma câmera termográfica Flir E4 de resolução no infravermelho de 4.800 (80 x 60) pixels. Faixa de temperatura de armazenamento: -40 °F a +158 °F (-40 °C a +70 °C) e faixa de temperatura operacional: +5 °F a +122 °F (-15°C a +50°C), com um desempenho de precisão  $\pm 2$  °C ( $\pm 3,6$  °F) ou  $\pm 2\%$  da leitura para temperatura ambiente 10 °C a 35 °C (+50 °F a 95 °F) e temperatura de objetos acima de +0 °C (+32 °F). Essa câmera é

usada para medição de temperatura contínua e não invasiva. Os dados da câmera são gravados no software FLIR ResearchIR (interface micro USB com possibilidade transferência de dados para computadores) que permite a visualização em tempo real e a análise de dados pós-processamento.

A câmera IR é sensível na faixa espectral de 7,5-13  $\mu\text{m}$ . Para encontrar o padrão de calor problemático no secador foi mantido uma distância de 2,5 a 3 metros do objeto alvo para poder analisar o tamanho total do equipamento agrícola, com objetivo de detectar as falhas de foco de calor durante o processo de secagem. A câmera auto se calibrava e ajustava ao ambiente detectando as temperaturas (câmera portátil era apontada para o equipamento pelo operador com as mãos na altura do peito até ela calibrar e após registrar a imagem térmica).

Um corpo aquecido (ou um objeto a uma temperatura acima do zero absoluto), como uma partícula quente, emite radiação infravermelha em todas as direções. Quando essa energia entra em contato com outros objetos (por exemplo, outras partículas, a parede do secador ou a massa de sementes), a energia é absorvida, refletida ou transmitida através do objeto. Portanto, o destino da radiação incidente em um objeto é determinado por três frações dependentes do comprimento de onda, a saber, absorvância ( $a$ ), refletividade ( $r$ ) e transmitância ( $t$ ). Como a radiação é absorvida, refletida ou transmitida, temos  $a + r + t = 1$  (ADEPU et al., 2021).


Para um objeto que deve ser transparente à radiação IR, como a parede do secador de aço galvanizado e massa da semente, a transmitância deve ser próxima de 1. Portanto, utiliza-se uma chapa de aço galvanizado, que não tem uma transmitância muito boa, cerca de 0,35  $\mu\text{m}$ , pois tem dificuldade de perder calor para o meio externo devido à baixa emissividade e absorve muito calor (PERALTA, 2006; (DEWITT e NUTTER, 1988; PATIL et al., 2015). Desta forma, a massa de ar quente das sementes favorece identificar pontos falhos no secador.

### **6.3 RESULTADOS**

Atualmente, o uso de secadores agrícolas passa por processo de modernização e com isso, se faz necessário investigar métodos de avaliação do processo da secagem visando identificar temperaturas desiguais em seus compartimentos. Pois, pode haver maior aumento de temperatura em lados

diferentes devido a desuniformidade de carregamento, entre outros motivos. Para abordar a preocupação relacionada à qualidade das sementes durante o processo de secagem, a técnica de imagem térmica infravermelha tem sido considerada devido à sua capacidade de não contato e ser menos laboriosa para determinar e observar o comportamento da temperatura dentro de um secador. A fim de garantir menos coleta de amostras para determinação do teor de água durante toda etapa de secagem daquela carga.

A técnica termográfica combinada com a emissividade de temperatura da massa de ar quente tem se mostrado uma ferramenta sensível para a identificação qualitativa de detecção de uma amostra, se está sendo seca uniformemente. Na Figura 2, são exemplificadas dois secadores no qual o comportamento do gradiente de temperatura oscila em função de suas dimensões (pressão e vazão podem ser ineficientes), cores em vermelho apresentam altas temperaturas e em azul as menores temperaturas de secagem.



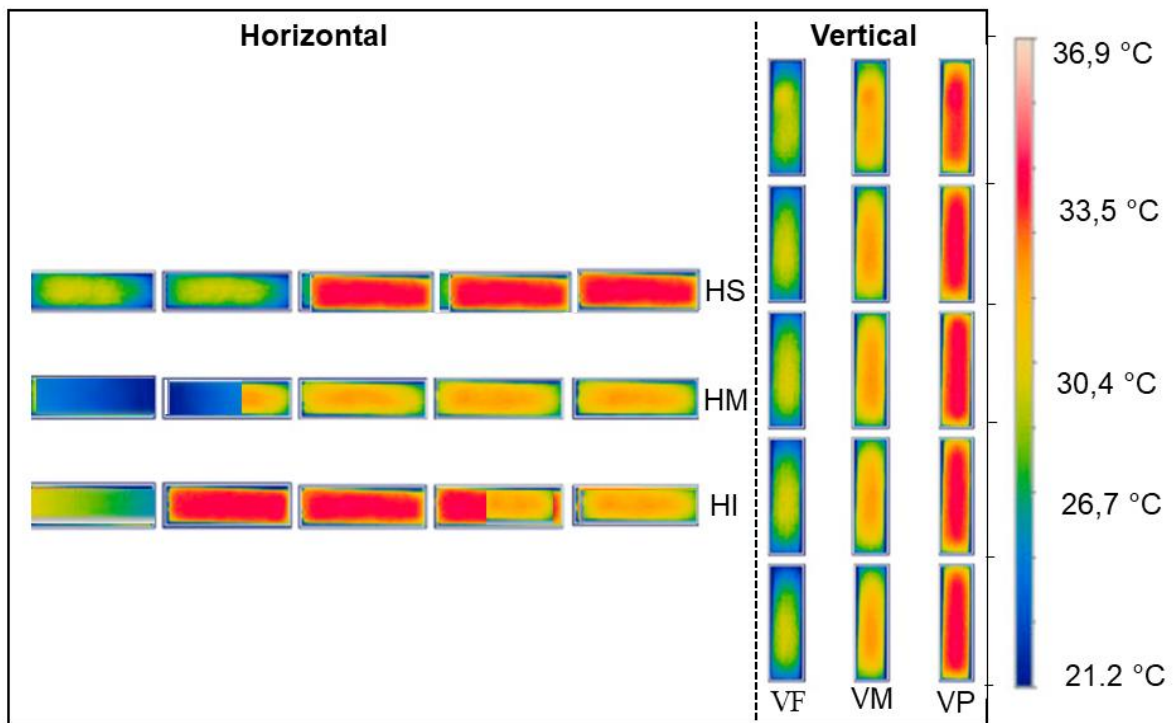
**Figura 2** - Comportamento do gradiente de temperatura (°C) em secadores fixo durante o seu funcionamento.

A velocidade de entrada do ar com aproximadamente 25,6 m/s, o tipo de ventilador, além de detalhes de projeto não gera uma pressão e vazão suficiente para manter a homogeneização de secagem, muito provavelmente, pois o mesmo não possui pressão estática e total para tal fim neste secador. Além desde fator

ainda existe outras situações, como a não utilização de pré-limpeza, o que ocasiona desuniformidade de massa e com isso diferenças de temperatura. O secador se encontra dentro de um galpão próximo as paredes, principalmente na entrada do ar do ventilador e das demais máquinas ao seu redor e isso também contribui para desuniformidade de secagem, já que o mesmo possui câmara de secagem aberta sendo constatado pela imagem termográfica.

A Figura 3 demonstra imagens termográficas do secador em funcionamento apontando diferentes gradientes de aquecimento no processo de secagem. O ar quente é distribuído dentro da câmara de secagem por um soprador (ventilador) com motor trifásico. Ao conduzir a massa de ar quente entre as células sob as camadas de sementes ocorre diferente pontos desiguais da temperatura no equipamento. Neste contexto, o processo de secagem na horizontal do secador demonstra que a parte de baixo (Figura 3HI) tem maior aumento de temperatura, como também na parte superior (Figura 3HS), porém a região mediana do secador a temperatura varia entre 26,7 a 32,3 °C, na imagem essa temperatura se mantém mais estática, devido a massa de ar quente ter dificuldade de romper a camada de sementes, por outro lado tanto a região superior, quanto inferior as barreiras para a massa de ar quente romper a camada de semente é menor, devido as abertura existentes.

Ao analisar o lado na vertical encontra-se um elevado fluxo de ar quente colidindo ao fundo do secador (Figura 3). O ar quente provoca maior aquecimento na parte de trás (Figura 3VP), devido a velocidade gerada pelo ventilador. A região mediana demonstra um aquecimento menos intenso (Figura 3 VM), na região frontal do secador se observa o aquecimento mais leve (Figura 3 VF). Nessa região mais frontal denota essa diferença devido está próxima ao ventilador. Ao levar o ar para a parte posterior do secador o mesmo não retorna com intensidade para igualar ambas regiões dentro da câmara de secagem. Esses perfis de cores formam os gradientes de comportamento de temperatura dentro do secador, constatando uma heterogeneização no processo de secagem. Os pontos falhos no secador são apontados nessas oscilações observadas nas imagens da câmara termográfica, no qual, a perda de umidade das sementes não pode ser alcançada uniformemente, assim sendo necessário ajustes no equipamento agrícola, além de estudar a qualidade fisiológica das sementes, com coletas de amostras em diferentes locais no secador.



**Figura 3** - Representação da imagem térmica conforme as dimensões do equipamento agrícola, no qual apresenta temperaturas médias (média de pixels) em diferentes pontos do secador durante o processo de secagem. A parte horizontal compreende o comprimento (HS= parte horizontal superior, HM = Horizontal mediana e HI= Horizontal inferior) e vertical se relaciona com a altura do secador (parte vertical frontal= VF entrada de ar pelas turbinas, vertical mediana = VM e vertical posterior = VP, compreende a região de descarga dos produtos).




Os resultados obtidos indicaram que as amostras analisadas durante o processo de secagem são significativamente diferentes em temperatura ao longo do tempo de exposição e posição. Na Tabela 1 demonstra os valores médios das temperaturas no equipamento em funcionamento (gradientes) e da massa da semente acompanhado da duração de secagem e das velocidades, do ar na entrada da câmara de secagem, de saída entres as células na camada de sementes (espessura de 45 cm), com tempo de exposição e a perda de ar saindo por locais aberto no secador (descarga, orifício de parafusos e chapas mal encaixadas).

A espessura da camada de sementes entre as células (compartimento) do secador podem ser um fator determinante para melhorar a eficiência de secagem no equipamento, no qual, passe primeiramente as sementes em uma máquina de pré-limpeza. Portanto, deve-se analisar dois fatores: a porosidade das sementes facilita



a passagem de ar entre ambas, onde as sementes com restos culturais e corpos estranhos permite uma passagem da massa de ar quente com uma menor restrição de barreiras entre elas, por outro lado, o teor de umidade com restos culturais juntamente com as sementes é maior, assim levando mais tempo para realizar a secagem e maior exposição de temperatura, podendo afetar a qualidade final.

**Tabela 1** - Oscilações de temperaturas em três diferentes gradientes de imagem termográficas capturadas durante o processo de secagem. T. = temperatura; V. S. = velocidade de saída do ar entre a camada de sementes; T. S. = tempo de secagem; V. E.= velocidade de entrada do ar na câmara de secagem. Pd= pressão dinâmica, F= Fluxo e V. C. velocidade dentro da câmara de secagem.

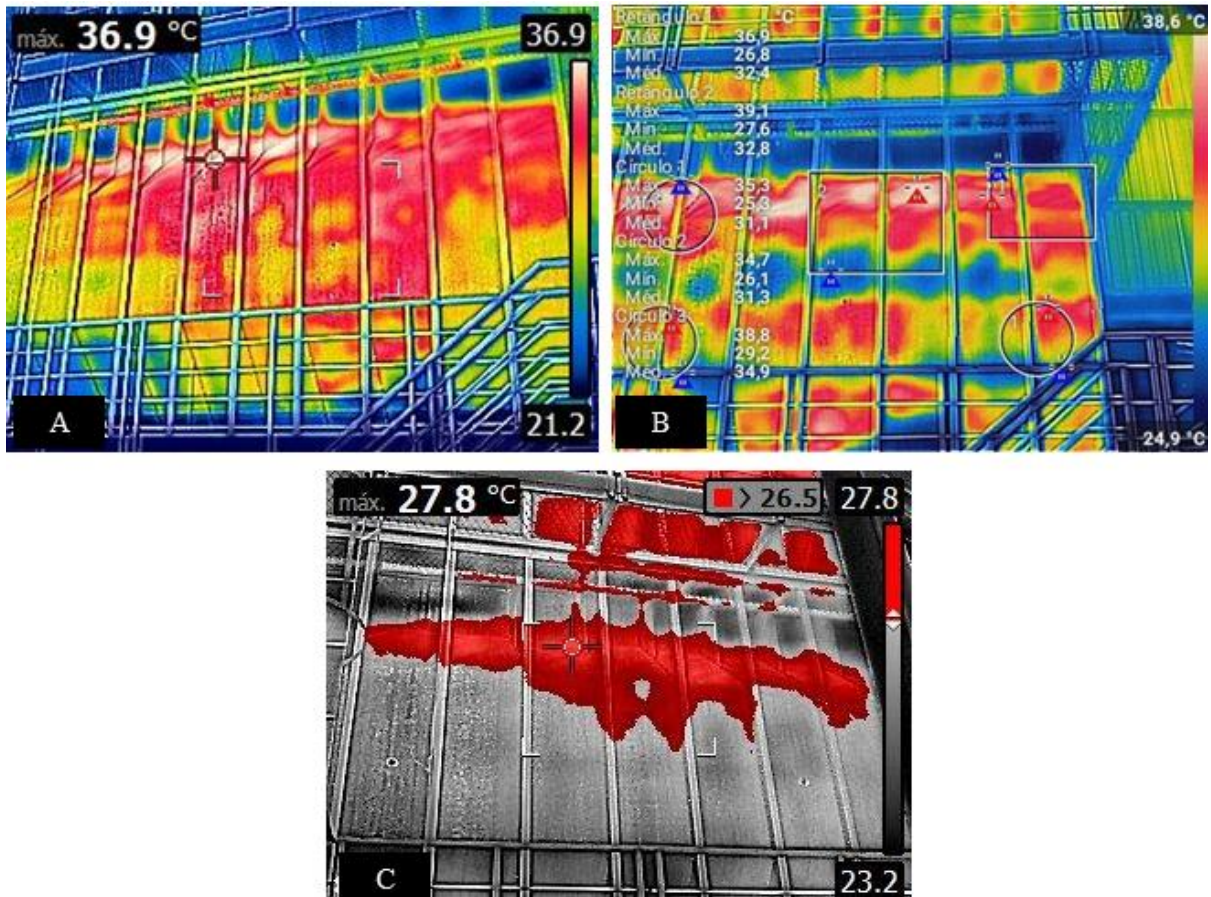
<b>Gradientes de temperaturas</b> (°C)	<b>T. massa de sementes</b> (°C)	<b>V. S. (m.s<sup>-1</sup>)</b>	<b>T. S. (h)</b>	<b>V. E. (m.s<sup>-1</sup>)</b>	<b>Ar perdido (m.s<sup>-1</sup>)</b>
 36,97	30,5	0,60 - 0,80			
 30,68	29,55	0,40 - 0,60	01:00 - 02:20	26,3	6,4
 22,75	27,5	0,00 - 0,20			
Média 30,13	29,18	0,33 - 0,53	01:20	-	-
Valores médio	<b>V. C. (m.s<sup>-1</sup>)</b>	<b>P. d. (mmca)</b>	<b>F= cfm</b>	-	-
	10,59	6,8	634,5	-	-

A temperatura do secador e da massa de sementes variaram de 22,75 °C a 35,7 °C e 27,5 °C a 30 °C, respectivamente, com uma velocidade média de saída entre as células variando entre 0,33 a 0,53 m/s (Tabela 1). Além de atingir uma alta velocidade de entrada do ar na câmara de secagem, porém apresenta uma perda de 24,33% de ar saindo por locais abertos como abertura da descarga, chapas mal encaixadas, perfuração da chapa de aço, abertura de encaixe de parafusos. E assim gerando menor pressão para o ar sair entre as camadas de sementes. A câmara possui um volume de 21 m<sup>3</sup> e, portanto, cabem 17 t de sementes com ventiladores produzidos uma vazão 75.000 m<sup>3</sup>/h. Analisando o valor médio de fluxo de ar (Tabela

1), nos módulos de secagem inferior foi verificado 0,48 m<sup>3</sup> de ar/min/t de sementes. No módulo superior havia 0,42 m<sup>3</sup> de ar/min/t de sementes. Devemos lembrar que a literatura diz entre 6 a 24 m<sup>3</sup> de ar/min/t conforme Peske et al. (2019) e 4 a 18 m<sup>3</sup> de ar/min/t por Guimarães et al. (2015), para garantia uma melhor eficiência e desempenho do secador durante o processo de secagem.

Analisando a pressão estática, a mesma foi medida no módulo de secagem inferior sendo de 24 mmca e no módulo de 26 mmca. Calculado pelo gráfico de Shedd (1953) encontramos 20 mmca (Peske et al., 2019) e pela fórmula 25,47 mmca (Guimarães et al., 2015). Sobre a pressão dinâmica (Tabela 1) foi encontrando valores médios de 6,8 mmca. A pressão dinâmica calculada com o valor médio da velocidade do ar dentro da câmara de secagem e determinada conforme Guimarães et al. (2015). Portanto, as pressões estática e dinâmica estão dentro do esperado.


Como a técnica de aplicação termográfica é capaz de detectar temperaturas de superfície dos objetos sob investigação, os dados térmicos resultantes podem ser usados direta ou indiretamente para muitas aplicações, inclusive no processo de secagem de sementes. O gradiente de calor ajustado para essa análise diretamente no secador foi de tons azuis próximo a 20 °C e os vermelhos de 40 °C (Figura 4a). Assim, podemos verificar que a técnica da imagem termográfica é bem semelhante a coleta de dados manual sendo um método rápido e eficiente devendo ser sugerida como técnica de análise rápida e não laboriosa na avaliação de um secador durante o processo de secagem.



**Figura 4** - Imagens termográficas capturas em secador convectivo. A- Maior pico de temperatura com 36,9 °C; B- Identificação de vários pontos de temperatura média, mínima e máxima; C- Identificação do ponto mais homogêneo.

A câmera infravermelha é sensível o suficiente para registrar as principais diferenças termodinâmicas no secador através de sua emissividade. A maior concentração de ar em local específico do secador devido a estagnação do mesmo pelos motivos apresentados anteriormente e, conseqüentemente aumento da temperatura do ar devido a característica do secador de camada delgada há um aumento da temperatura da massa de sementes. Assim, se detecta pontos de secagem diferentes, o que não se pode chamar de frente de secagem pois não houve homogeneidade dentro da câmara de secagem.

Os resultados revelaram que existe uma diferença significativa entre os dados de temperatura entres as paredes do secador e das sementes no seu interior, porque a respiração e a energia térmica liberada das sementes são maiores do que a emissividade das paredes do equipamento agrícola (Figura 5).



**Figura 5** – Diferença na temperatura quando direcionado a câmera térmica para o objeto alvo específico, estando no mesmo ponto: (A) a câmera direcionada para capturar a parede e na (B) foi especificamente as sementes demarcada no retângulo.

Essa descoberta demonstra que a massa de ar quente na semente aquece a nível mais elevado, quando existe menor corrente de ar quente passando entre as camadas de sementes, ficando o ar estagnado e com isso equilibrando a temperatura do ar com a da massa de sementes, confirmando a capacidade do método de imagem térmica em identificar diferentes pontos de secagem dentro do equipamento agrícola. As principais diferenças nas imagens termográficas coletadas durante o processo de secagem de sementes são baseadas nas disparidades estruturais combinada com a pouca velocidade de entrada do ar gerado pelo ventilador e a baixa pressão estática do mesmo fazendo com que a massa de ar quente se mantenha tempo suficiente em contato com a massa de sementes e com isso se equilibrando.

#### 6.4 DISCUSSÃO

As informações utilizadas para classificar e detectar diferentes pontos de secagem foram contidas em imagens termográficas de um secador convectivo durante seu funcionamento, com objetivo de diminuir o teor de água. Pois a secagem desempenha um papel importante para escalonamento de colheita e armazenamento, além de aumentar a estabilidade dos produtos. O alto grau de

umidade pode afetar a qualidade de sementes o que está associado a reações químicas, microbianas e enzimáticas, o que leva a efeitos adversos sobre sua qualidade. De acordo com Dhurve et al. (2022), a qualidade fisiológica das sementes afeta diretamente o sucesso das culturas e contribui significativamente para aumentar os níveis de produtividade.

A imagem térmica infravermelha é uma ferramenta poderosa usada para monitorar a qualidade e a segurança de vários produtos agrícolas (ALI et al., 2022). No entanto, as aplicações disponíveis envolvendo imagens térmicas infravermelhas em processo de equipamentos agrícolas para escala industrial ainda são limitadas. Ao contrário dos métodos clássicos de medição de temperatura usando termômetros, termopares ou termistores que só podem medir a temperatura em um ponto específico, o sistema de imagem térmica fornece registros de temperatura para todos os pontos em todos os objetos examinados sem um contato direto com os objetos que estão sendo testados (ELMASRY et al., 2020).

Neste estudo, a heterogeneidade de calor observada no interior do secador está associada a baixa vazão de ar entre as camadas de sementes, pois a pressão não consegue vencer locais onde as sementes e impurezas se concentraram mais. Outros fatores que podem influenciar é a não utilização de máquinas de ar e peneiras, neste caso diminuindo a porosidade. Isso pode influenciar muito na etapa de uma secagem mais uniforme. Nesse sentido, as câmeras termográficas estão se tornando uma alternativa sólida como ferramenta de imagem não invasiva, não destrutiva, versátil e portátil para monitorar variações de temperatura (Xu et al., 2016) e, conseqüentemente a etapa de secagem de sementes.

O efeito do processo de secagem é alterado de acordo com as propriedades físico-química das sementes, interferindo assim na cinética de secagem (MARTIM et al., 2019). No entanto, se espera que a técnica de secagem com fluxo de ar quente seja um método conveniente do ponto de vista de custo que traz diversos benefícios no processo, como higiene sanitária, distribuição uniforme e produtos secos apresentando alta qualidade (ADILETTA et al., 2015; ONWUDE et al., 2016; ZIELINSKA e MARKOWSKI, 2016; FRANCO et al., 2021). Portanto determinar que os pontos de temperatura dentro de um secador sejam iguais é impossível observar através de termômetros convencionais, e/ou caracterizar medidas feitas no equipamento agrícola. Assim surge, a necessidade de entender como a termografia pode auxiliar o processo de secagem sem a necessidade do contato direto.



Deste modo, o tipo de inspeção utilizada por sistemas de infravermelho, que ao detectar a radiação não ionizante emitida naturalmente pelos corpos, geram imagens térmicas que proporcionam informações relativas à condição operacional do equipamento, como medição de temperatura ou padrões diferenciais de distribuição de calor no interior do secador. De acordo com Blunck (2022), a termografia infravermelha é uma técnica promissora para estudar qualitativa e quantitativamente as características dos fluxos quando os meios participantes estão presentes.

No processo de secagem das sementes, através dos termogramas, foi possível identificar e diferenciar pontos de calor e associar a possíveis causas de sua não uniformização de secagem. Primeira situação: pode ocorrer devido fluxo de ar com baixa pressão, segunda situação é perda de ar em locais de descarga ou qualquer abertura de parafusos e janelas de manutenção. Esses fatores podem influenciar no processo de secagem além de perda de eficiência de ar (pressão).

Foi constatado, *in loco*, neste trabalho que a perda de ar pelos locais de escape quando aquecido em temperatura de secagem podem ultrapassar 85 °C entre a massa do ar quente e as paredes do secador (aço galvanizado). Se essa temperatura junto com o ar quente passar entre a massa de sementes, pode-se obter uma secagem rápida, se houver fluxo. Porém, em caso específico de sementes, vai aumentar danos mecânicos. Estrada-Pérez et al. (2021) observaram imagens térmicas em grãos de arroz e obtiveram, as principais diferenças nas imagens termográficas baseadas nas disparidades e de solubilidade em água de diferentes composições de amilose e amilopectina presente. Por isso é um fator importante analisar todos os componentes estruturais das sementes, sendo que cada espécie apresenta diferentes composições e conteúdo de água.

A análise de imagens térmicas em um secador de sementes ou grãos se torna importante para avaliar a eficiência de secagem. Assim, esses resultados promissores oportunizam uma análise ampla dos tipos de secadores no mercado para detectar uma secagem uniforme e o quanto os diferentes focos de calor encontrados podem afetar a qualidade de sementes.

## **6.5 CONCLUSÃO**

Com base nos resultados obtidos, pode-se concluir que as imagens térmicas do processo de secagem de sementes, com equipamentos de medição não destrutivos e portáteis, como uma câmera termográfica, facilitam a obtenção de termogramas com diferentes pontos de calor no interior do secador, a partir do qual se podem deduzir características diferenciadoras entre as células divisórias do secador observadas neste trabalho.

## 7 CONSIDERAÇÕES FINAIS

As tecnologias de aprimoramento de sementes, após a colheita estão sendo cada vez mais usadas para aliviar as barreiras de uma demanda alta de informações geradas sob um conjunto de dados. Técnicas inteligentes estão sendo testadas nos mais variados campos de pesquisa dentro da área sementeira. Uma agricultura inteligente requer cuidados para compreensão das informações obtidas. Com foco de transmitir a informação coerente e que seja de fácil assimilação.

Reduzir perdas e aumentar produtividade são dois fatores que precisam ser superados. A área de sementes é o principal agente que tem a responsabilidade de garantir a qualidade de safras alinhado ao auto rendimento das culturas agrícolas. Com isso, se buscar, através de inteligência artificial, a eficiência de processos haverá soluções promissoras neste segmento. Um rápido aumento da população representa a responsabilidade alimentar, uma vez, que a produção de alimentos exige mais recursos tecnológicos.

O conjunto de tecnologias proposto neste trabalho permite a integração do aprendizado de máquina e imagens termográficas, como também permitem captar mais ideias inovadoras, as tecnologias devem ser integradas à indústria agrícola em maior escala. No qual, poderá ajudar os sementeiros e agricultores a capitalizar as inovações. Com avanços atuais que podem melhorar a produção agrícola e reduzir o uso de água e energia, como também em tomada de decisões que são morosas e laboriosas permitindo a eficácia no agronegócio.

As respostas obtidas neste trabalho com secagem de sementes demonstram os efeitos da tecnologia de inteligência artificial e a termografia nas condições de trabalho de um equipamento agrícola, atuando na percepção de seu desempenho com os impactos de tempo de exposição das sementes no processo de secagem. Onde se obteve resultados condizentes com a realidade através da mineração de dados. Demonstrando a eficiência do uso destas tecnologias na minimização dos fatores prejudiciais a secagem (temperatura, umidade, tempo de exposição).



## REFERÊNCIAS

- ADEPU, M.; BOEPPLE, B.; FOX, B.; EMADY, H. Experimental investigation of conduction heat transfer in a rotary drum using infrared thermography. **Chemical Engineering Science**, v. 230, p. 116145, 2021. Doi: <https://doi.org/10.1016/j.ces.2020.116145>.
- ABDOLI, B.; ZARE, D.; JAFARI, A.; CHEN, G. Evaluation of the air-borne ultrasound on fluidized bed drying of shelled corn: Effectiveness, grain quality, and energy consumption. **Drying Technology**, v. 36, n. 14, p. 1749-1766, 2018. Doi: <https://doi.org/10.1080/07373937.2018.1423568>.
- ACCINELLI, C.; ABBAS, H. K.; SHIER, W. T.; VICARI, A.; LITTLE, N. S.; ALOISE, M. R.; GIACOMINI, S. Degradation of microplastic seed film-coating fragments in soil. **Chemosphere**, v. 226, p. 645-650, 2019. Doi:10.1016/j.chemosphere.2019.03.161.
- ADILETTA, G.; RUSSO, P.; PROIETTI, N.; CAPITANI, D. MANNINA, L. CRESCITELLI, A. Characterization of pears during drying by conventional technique and portable non invasive. **NMR**, v. 44, p. 151-156. 2015. Doi: 10.3303/CET1544026.
- AHMAD, A.; SRIPONG, K.; UTHAIRATANAKIJ, A.; PHOTCHANACHAI, S.; PANKASEMSUK, T.; JITAREERAT, P. Decontamination of seed borne disease in pepper (*Capsicum annuum* L.) seed and the enhancement of seed quality by the emulated plasma technology. **Scientia Horticulturae**, v. 291, p. 110568, 2022. <https://doi.org/10.1016/j.scienta.2021.110568>.
- AHMED, M. R.; YASMIN, J.; COLLINS, W.; CHO, B.-K. X-ray CT image analysis for morphology of muskmelon seed in relation to germination. **Biosystems Engineering**, v. 175, p. 183-193, 2018. Doi: <https://doi.org/10.1016/j.biosystemeng.2018.09.015>.
- ALI, M.; HASHIM, M.; N., AZIZ, S. A.; LASEKAN, O. Emerging non-destructive thermal imaging technique coupled with chemometrics on quality and safety inspection in food and agriculture. **Trends in Food Science & Technology**, v. 105, p. 176-185, 2020. Doi: <https://doi.org/10.1016/j.tifs.2020.09.003>.
- ALPAYDIN, E. **Introduction to Machine Learning**. 3 ed. MIT Press, 2014, 613 p.
- ANDRÉ, G. da S.; CORADI, P. C.; TEODORO, L. P. R.; TEODORO, P. E. Predicting the quality of soybean seeds stored in different environments and packaging using machine learning. **Scientific Reports**, v. 12, p. 8793, 2022. Doi: <https://doi.org/10.1038/s41598-022-12863-5>.
- ARUMUGAM, K.; DOMENIC, S. Y.; SANCHEZ, T.; MUSTAFA, M.; PHOEMCHALARD, C.; PHASINAM, K.; OKORONKWO, E. Towards applicability of machine learning techniques in agriculture and energy sector. **Materials Today: Proceedings**, v. 51, n. 8, p. 2260-2263, 2022. Doi: <https://doi.org/10.1016/j.matpr.2021.11.394>.

AVELAR, S. A. G.; SOUSA, F. V. D.; FISS, G.; BAUDET, L.; PESKE, S. T. The use of film coating on the performance of treated corn seed. **Revista Brasileira de Sementes**, v. 34, n. 2, p. 186-192, 2012. Doi: 10.1590/S0101-3122201200020 0001.

BAEK, I.; KUSUMANINGRUM, D.; KANDPAL, L. M.; LOHUMI, S.; MO, C.; KIM, M. S. Rapid measurement of soybean seed viability using Kernel-based multispectral image analysis. **Sensors**, v. 19 n. 271, 2019. Doi: 10.3390/s19 020271

BALI, N.; SINGLA, A. Deep learning based wheat crop yield prediction model in Punjab region of North India. **Applied Artificial Intelligence**, v. 35, n.15, p. 1304-1328, 2021. Doi: 10.1080/08839514.2021.1976091.

BATISTA, T. B.; MASTRANGELO, C. B.; MEDEIROS, A. D.; PETRONILIO, A. C. P. FONSECA. DE O.; GUSTAVO R.; DOS SANTOS, I. L.; CRUSCIOL, C. A. C.; AMARAL, S. E. A. A reliable method to recognize soybean seed maturation stages based on autofluorescence-spectral imaging combined with machine learning algorithms. **Frontiers in Plant Science**, v. 13, 2022. Doi: 10.3389/fpls.2 022.914287.

BENYAM, A.; SOMA, T.; FRASER, E. Digital agricultural technologies for food loss and waste prevention and reduction: Global trends, adoption opportunities and barriers. **Journal of Cleaner Production**, v. 323, p. 129099, 2021. Doi: <https://doi.org/10.1016/j.jclepro.2021.129099>.

BHADOURIA, R. R.; SINGH, V.K.; SINGH, A.; BORTHAKUR, A.; AHAMAD, G.; KUMAR, P. SINGH. **Chapter 1 - agriculture in the era of climate change: consequences and effects** Choudhary, K. K. A.; Kumar, A. Singh, K. (Eds.), *Climate Change and Agricultural Ecosystems*, Woodhead Publishing, 2019, p. 1-23. Doi: 10.1016/B978-0-12-816483-9.00001-3.

BLUNCK, D. L. Review: Applications of infrared thermography for studying flows with participating media. **Experimental Thermal and Fluid Science**, v. 130, p.110502, 2022. Doi: <https://doi.org/10.1016/j.expthermflusci.2021.110502>.

BOATENG, I. D.; YANG, X. M.; Li, Y. Y. Optimization of Infrared-drying parameters for *Ginkgo biloba* L. seed and evaluation of product quality and bioactivity. **Industrial crops and products**, v. 160, p 113108, 2021. Doi: 10.1016/j.indcrop.2020.113108.

BOELT, B.; SHRESTHA, S.; SALIMI, Z.; JØRGENSEN, J.; NICOLAISEN, M.; CARSTENSEN, J. Multispectral imaging - a new tool in seed quality assessment? **Seed Science Research**, v. 28, n. 3, p. 222228, 2018. Doi: <https://doi.org/10.1017/S0960258518000235>.

BRUNES, A. P.; ARAÚJO, Á. S.; DIAS, L. W.; ANTONIOLLI, J.; GADOTTI, G. I.; VILLELA, F. A. Rice seeds vigor through image processing of seedlings. **Ciência Rural**, v. 49, n. 8, p. 1-6, 2019. Doi: <https://doi.org/10.1590/0103-8478cr2018 0107>.

CAMAS-NAFATE, M. P.; ALVAREZ-GUTIERREZ, P.; VALENZUELA-MONDACA, E. CASTILLO-PALOMERA, R. PEREZ-LUNA, Y. C. Improved agricultural products drying through a novel double collector solar device. **Sustainability**, v. 11, n. 10, p. 2920, 2019. Doi: 10.3390/su11102920.

CEDRIC, L. S.; WILFRIED, Y. H. A., AWORKA, R.; ZOUEU, J. T.; MUTOMBO, F. K.; KRICHEN, M.; KIMPOLO, C. L. M. Crops yield prediction based on machine learning models: Case of West African countries. **Smart Agricultural Technology**, v. 2, p. 100049, 2022. Doi: <https://doi.org/10.1016/j.atech.2022.100049>.

CEN, H.; HE Y. Theory and application of near infrared reflectance spectroscopy in determination of food quality. **Trends in Food Science & Technology**, v. 18, p. 72-83, 2007. Doi: <https://doi.org/10.1016/j.tifs.2006.09.003>.

CHANDRA, R.; COLLIS, S. Digital agriculture for small-scale producers: challenges and opportunities. **Communications of the ACM**, v. 64, n. 12, p. 75-84, 2021. Doi: <https://doi.org/10.1145/3454008>.

CHAO, E.; TIAN, J.; FAN, L.; ZHANG, T. Drying methods influence the physicochemical and functional properties of seed-used pumpkin. **Food Chemistry**, 369, p. 130937, 2022. Doi: <https://doi.org/10.1016/j.foodchem.2021.130937>.

CHLINGARYAN, A.; SUKKARIEH, S.; WHELAN, B. Machine learning approaches for crop yield prediction and nitrogen status estimation in precision agriculture: a review. **Computers and Electronics in Agriculture**, v. 151, p. 61-69, 2018. Doi: <https://doi.org/10.1016/j.compag.2018.05.012>.

CHEN, Z.; DU, H.; TAO, Y.; XU, Y.; WANG, F.; LI, B.; ZHU, Q.; NIU, H.; YANG, J. Efficient breeding of low glutelin content rice germplasm by simultaneous editing multiple glutelin genes via CRISPR/Cas9. **Plant Science**, v. 324, p. 111449, 2022. Doi: <https://doi.org/10.1016/j.plantsci.2022.111449>.

DEWITT, D. P.; NUTTER, G. D. **Theory and practice of radiation thermometry**, theory and practice of radiation thermometry, ed. JOHN WILEY & SONS, Inc, Hoboken, NJ, USA, p. 19-229, 1988, 1138 p. Doi: 10.1002/9780470172575.

DOYMAZ, İ. Effect of citric acid and blanching pre-treatments on drying and rehydration of Amasya red apples. **Food and Bioproducts Processing**, v. 88, n. 2-3, p. 124-132, 2010. Doi: <https://doi.org/10.1016/j.fbp.2009.09.003>.

DHURVE, P.; KUMAR, A. V.; YADAV, K. D.; MALAKAR, S. Drying kinetics, mass transfer parameters, and specific energy consumption analysis of watermelon seeds dried using the convective dryer. **Materials Today: Proceedings**, v. 59, p. 926-932, 2022. Doi: <https://doi.org/10.1016/j.matpr.2022.02.008>.

DIBAGAR, N.; KOWALSKI, S. J.; CHAYJAN, R. A.; FIGIEL, A. Accelerated convective drying of sunflower seeds by high-power ultrasound: Experimental assessment and optimization approach. **Food and Bioproducts Processing**, v. 123, p. 42-59, 2020. Doi: <https://doi.org/10.1016/j.fbp.2020.05.014>

DU, Z.; ZENG, X.; LI, X.; DING, X.; CAO, J.; JIANG, W. Recent advances in imaging techniques for bruise detection in fruits and vegetables. **Trends in Food Science & Technology**, v. 99, p. 133-141, 2020. Doi: 10.1016/j.tifs.2020.02.024.

DUARTE, D.; CARRÃO, L.; ESPANHA, M.; VIANA, T.; FREITAS, D.; BÁRTOLO, P. Segmentation algorithms for thermal images. **Procedia Technology**, v. 16, p. 1560-1569, 2014. Doi: 10.1016/j.protcy.2014.10.178.

DUMONT, J.; HIRVONEN, T.; HEIKKINEN, V.; MISTRETTA, M.; GRANLUND, L.; HIMANEN, K.; FAUCH, L.; PORALI, I.; HILTUNEN, J.; KESKI-SAARI, S.; NYGREN, M.; OKSANEN, E.; HAUTA-KASARI, M.; KEINÄNEN, M. Thermal and hyperspectral imaging for Norway spruce (*Picea abies*) seeds screening. **Computers and Electronics in Agriculture**, 116, 118-124, 2015. Doi: <https://doi.org/10.1016/j.compag.2015.06.010>.

ELMASRY, G.; MANDOUR, N.; WAGNER, M. H.; DEMILLY, D.; VERDIER, J.; BELIN, E. Utilization of computer vision and multispectral imaging techniques for classification of cowpea (*Vigna unguiculata*) seeds. **Plant Methods**, v. 15, n. 24, 2019. Doi: 10.1186/s13007-019-0411-2.

ELMASRY, G.; ELGAMAL, R.; MANDOUR, N.; GOU, P.; AL-REJAIE, S.; BELIN, E.; ROUSSEAU, D. Emerging thermal imaging techniques for seed quality evaluation: principles and application. **Food Research International**, v. 131, 109025, 2020. Doi: <https://doi.org/10.1016/j.foodres.2020.109025>.

ESTRADA-PÉREZ, L. V.; PRADANA-LÓPEZ, S.; PÉREZ-CALABUIG, A. M.; MENA M. L.; CANCELLA, J. C.; TORRECILLA, J. S. Thermal imaging of rice grains and flours to design convolutional systems to ensure quality and safety. **Food Control**, v. 121, p. 107572, 2021. Doi: <https://doi.org/10.1016/j.foodcont.2020.107572>.

FRANCO, C. M. R.; SILVA JÚNIOR, A. F.; ARAÚJO, I. D. Equação de difusão em coordenadas cilíndricas aplicada na secagem de sementes da Araucária (*Araucaria angustifolia*). **Proceeding Series of the Brazilian Society of Computational and Applied Mathematics**, v. 8, n. 1, 2021 Doi: <https://doi.org/10.5540/03.2021.008.01.0403>.

GADOTTI, G. I.; ASCOLI, C. A.; BERNARDY, R.; MONTEIRO, R. C. M.; PINHEIRO, R. M. Machine learning for soybean seeds lots classification. **Engenharia Agrícola**, v. 42, p. e20210101, 2022a. Doi: <https://doi.org/10.1590/1809-4430-Eng.Agric.v42nepe20210101/2022>

GADOTTI, G. I.; MORAES, N. A. B.; SILVA, J. G. DA; PINHEIRO, R. DE M.; MONTEIRO, R. DE C. M. Prediction of ranking of lots of corn seeds by artificial intelligence. **Engenharia Agrícola**, v. 42, p. e20210005, 2022b. Doi: <https://doi.org/10.1590/1809-4430-Eng.Agric.v42n4e20210005/2022>.

GALLETTI, P. A.; CARVALHO, M. E. A.; HIRAI, W. Y.; BRANCAGLIONI, V. A.; ARTHUR, V. BARBOZA, S. C. Integrating optical imaging tools for rapid and non-invasive characterization of seed quality: tomato (*Solanum lycopersicum* L.) and Carrot (*Daucus carota* L.) as study cases. **Frontiers Plant Science**, v. 11, p. 577851, 2020. Doi: 10.3389/fpls.2020.577851.

GARCIA, D. C.; ALBUQUERQUE, A. C. S.; PESKE, S. T.; MENEZES, N. L. de. A secagem de sementes. **Ciência Rural**, Santa Maria, v. 34, n.2, p. 603-608, 2004. Doi: <https://doi.org/10.1590/S0103-84782004000200045>.

GAO, J.; LI, X.; ZHU, F.; HE, Y. Application of hyperspectral imaging technology to discriminate different geographical origins of *Jatropha curcas* L. seeds. **Computers and Electronics in Agriculture**, v. 99, p. 186-193, 2013. <https://doi.org/10.1016/j.compag.2013.09.011>.

GERSHO, A.; GRAY, R. M. **Vector quantization and signal compression**. Kluwer Academic, Boston. The Springer International Series in Engineering and Computer Science. 1992, p. XXIII, 732. Doi: <https://doi.org/10.1007/978-1-4615-3626-0>.

GHANBARIAN, D.; TORKI-HARCHEGANI, M.; SADEGHI, M.; PIRBALOUTI, A. G. Ultrasonically improved convective drying of peppermint leaves: Influence on the process time and energetic indices. **Renewable Energy**, v. 153, p. 67-73, 2020. Doi: <https://doi.org/10.1016/j.renene.2019.10.024>.

GONZALEZ, E. B.; EASDALE, M. H.; SACCHERO, D. M. Socio-technical networks modulate on-farm technological innovations in wool production of North Patagonia, Argentina. **Journal of Rural Studies**, v. 83, p. 30-36, 2021. Doi: <https://doi.org/10.1016/j.jrurstud.2021.02.015>.

GUIMARÃES, D. S.; LUZ, C. A. S.; PERES, W. B.; LUZ, M. L. G. S.; GADOTTI, G. **Secagem de grãos e sementes**. 1. ed. Pelotas: Santa Cruz, 2015. 314p.

HATFIELD, J. L.; BOOTE, K. J.; KIMBALL, B. A.; ZISKA, L. H.; IZAURRALDE, R. C.; ORT, D.; WOLFE, D. Impactos climáticos na agricultura: implicações para a produção agrícola. **Agronomy Journal**, v. 103, p. 351 – 370, 2011. Doi: <https://doi.org/10.2134/agronj2010.0303>

HOLZINGER, A. Interactive machine learning for health informatics: When do we need the human-in-the-loop? **Brain Informatics**, v. 3, p. 119–131, 2016. Doi: <https://doi.org/10.1007/s40708-016-0042-6>.

HU, X.; YANG, L.; ZHANG, Z. Non-destructive identification of single hard seed via multispectral imaging analysis in six legume species. **Plant Methods** v. 16, n. 116, 2020. Doi: [10.1186/s13007-020-00659-5](https://doi.org/10.1186/s13007-020-00659-5).

IZQUIERDO, M.; LASTRA-MEJÍAS, M.; GONZÁLEZ-FLORES, E.; CANCELLA, J. C.; AROCA-SANTOS, R.; TORRECILLA, J. S. Deep thermal imaging to compute the adulteration state of extra virgin olive oil. **Computers and Electronics in Agriculture**, v. 171, p. 105290, 2020a. Doi: <https://doi.org/10.1016/j.compag.2020.105290>.

IZQUIERDO, M.; LASTRA-MEJÍAS, M.; GONZÁLEZ-FLORES, E.; CANCELLA, J. C.; AROCA-SANTOS, R.; TORRECILLA, J. S. Convolutional decoding of thermographic images to locate and quantify honey adulterations. **Talanta**, v. 209, p. 120500, 2020b <https://doi.org/10.1016/j.talanta.2019.120500>.

JAIN, K., CHOUDHARY, N. Comparative analysis of machine learning techniques for predicting production capability of crop yield. **International Journal of System Assurance Engineering and Management**, v. 13, Suppl 1, p. 583–593, 2022. Doi: <https://doi.org/10.1007/s13198-021-01543-8>.

JAVED, T.; AFZAL, I. Impact of seed pelleting on germination potential, seedling growth and storage of tomato seed. **Acta Horticulturaev.** 1273, p. 417-424, 2020. Doi: [10.17660/ActaHortic.2020.1273.54](https://doi.org/10.17660/ActaHortic.2020.1273.54).

JAVED, T.; AFZAL, I.; SHABBIR, R.; IKRAM, K.; SAQLAIN ZAHEER, M.; FAHEEM, M.; HAIDER ALI H.; IQBAL, J. Seed coating technology: An innovative and sustainable approach for improving seed quality and crop performance. **Journal of the Saudi Society of Agricultural Sciences**. 2022. Doi: <https://doi.org/10.1016/j.jssas.2022.03.003>.

JIN, B.; QI, H.; JIA, L.; TANG, Q.; GAO, L.; LI, Z.; ZHAO, G. Determination of viability and vigor of naturally-aged rice seeds using hyperspectral imaging with machine learning. **Infrared Physics & Technology**, v. 122, p. 104097, 2022. Doi: <https://doi.org/10.1016/j.infrared.2022.104097>.

KIM, K. S.; PARK, S. H.; CHOUNG, M. G. Nondestructive determination of lignans and lignan glycosides in sesame seeds by near infrared reflectance spectroscopy. **Journal of agricultural and food chemistry**, v. 54, n. 13, p. 4544–4550, 2006. Doi: <https://doi.org/10.1021/jf0605603>.

KIM, G.; KIM, G. H.; AHN, C. K.; YOO, Y.; CHO, B. K. Mid-infrared lifetime imaging for viability evaluation of lettuce seeds based on time-dependent thermal decay characterization. **Sensors (Basel, Switzerland)**, v. 13, n. 3, p. 2986–2996, 2013. Doi: <https://doi.org/10.3390/s130302986>.

KONG, W.; ZHANG, C.; LIU, F.; NIE, P.; HE, Y. Rice seed cultivar identification using near-infrared hyperspectral imaging and multivariate data analysis. **Sensors (Basel, Switzerland)**, v. 13, n. 7, p. 8916–8927, 2013. Doi: <https://doi.org/10.3390/s130708916>.

KRANNER, I.; KEASTBERGER, G.; HARTBAUER, M.; PRITCHARD, H. W. Noninvasive diagnosis of seed viability using infrared thermography. **Proceedings of the National Academy of Sciences**, v. 107, n. 8, p. 3912–1917, 2010. Doi: <https://doi.org/10.1073/pnas.0914197107>.

KRISHNAN, P.; NAGARAJAN, S.; DADLANI, M.; MOHARIR, A. Characterization of wheat (*Triticum aestivum*) and soybean (*Glycine max*) seeds under accelerated ageing conditions by proton nuclear magnetic spectroscopy. **Seed Science and Technology**, v. 31, n. 3, p. 541-550, 2003. Doi: <https://doi.org/10.15258/sst.2003.31.3.03>.

KUMAR, K. M.; REDDY, A. R. M. An efficient k-means clustering filtering algorithm using density based initial cluster centers. **Information Sciences**, v. 418-419, p. 286-301, 2017. Doi: <https://doi.org/10.1016/j.ins.2017.07.036>.

KUMAR, P.; ASHOK, G. Design and fabrication of smart seed sowing robot. **Materials Today: Proceedings**, v. 39, part 1, p. 354-358, 2021. Doi: <https://doi.org/10.1016/j.matpr.2020.07.432>.

LENAERTS, S.; VAN DER BORGHT, M.; CALLENS, A.; VAN CAMPENHOUT, L. Suitability of microwave drying for mealworms (*Tenebrio molitor*) as alternative to freeze drying: Impact on nutritional quality and colour. **Food chemistry**, v. 254, p. 129–136, 2018. Doi: <https://doi.org/10.1016/j.foodchem.2018.02.006>.

LIAKOS, K. G.; BUSATO, P.; MOSHOU, D.; PEARSON, S.; BOCHTIS, D. Machine learning in agriculture: a review, **Sensors**, v. 18, p. 2674, 2018.

LIPPER, L.; PURI, J.; CAVATASSI, R.; MCCARTHY, N. How does climate change affect the evidence we need for agricultural development? **Agricultural Economics**, 1-13, 2022. Doi: <https://doi.org/10.1111/agec.12732>.

LODDO, A.; LODDO, M.; DI RUBERTO, C. A novel deep learning based approach for seed image classification and retrieval. **Computers and Electronics in Agriculture**, v. 187, 106269, 2021. Doi: <https://doi.org/10.1016/j.compag.2021.106269>.

LUTZ, É.; CORADI, P. C. Applications of new technologies for monitoring and predicting grains quality stored: Sensors, internet of things, and artificial intelligence. **Measurement**, v. 188, p. 110609, 2022. Doi: <https://doi.org/10.1016/j.measurement.2021.110609>.

MAQUEDA, R. H.; REDONDO, I. B.; JÁCOME, S. J.; MORENO, A. H. Microwave drying of amaranth and quinoa seeds: Effects of the power density on the drying time, germination rate and seedling vigor. **Journal of Microwave Power & Electromagnetic Energy**, v. 52, n. 4, p. 299-311, 2018. Doi: 10.1080/08327823.2018.1534052.

MARTINS, M. P.; CORTÉS, E. J.; EIM, V.; MULET, A.; CÁRCEL, J. A. Stabilization of apple peel by drying. Influence of temperature and ultrasound application on drying kinetics and product quality. **Drying Technology**, v. 37, n.5, p. 559-568, 2019. Doi: 10.1080/07373937.2018.1474476.

MARTIM, C.; SILVA, S.; FERNEDA, B.; LUZ, E.; JUSTI, J. Curva de secagem e contração volumétrica para o pinhão da Araucária (*Araucária angustifolia*). **Enciclopédia Biosfera**, v. 16, n. 30, 2019. Doi: 10.18677/EnciBio2019B18.

MEDEIROS, A. D. de; CAPOBIANGO, N. P.; DA SILVA, J. M.; SILVA, L. J.; SILVA., C. B.; DIAS, D. C. F. dos S. Interactive machine learning for soybean seed and seedling quality classification. **Scientific Reports**, v. 10, p. 11267, 2020b. Doi: <https://doi.org/10.1038/s41598-020-68273-y>.

MEDEIROS, A. D.; PINHEIRO, D. T.; XAVIER, W. A.; SILVA, L. J.; DIAS, D. C. F. S. Quality classification of *Jatropha curcas* seeds using radiographic images and machine learning. **Industrial Crops and Products**, v. 146, 112162, 2020a. doi: <https://doi.org/10.1016/j.indcrop.2020.112162>.

MINOLI, S.; EGLI, D. B.; ROLINSKI, S.; MÜLLER, C. Modelling cropping periods of grain crops at the global scale, **Global and Planetary Change**, v. 174, p. 35-46. 2019 Doi: <https://doi.org/10.1016/j.gloplacha.2018.12.013>.

MONTEIRO, R. C. M.; GADOTTI, G. I.; MALDANER, V.; CURI, A. B. J.; BARBARA NETO, M. Image processing to identify damage to soybean seeds. **Ciência Rural**, v. 51, n. 2, p. 1-8, 2021. Doi: <https://doi.org/10.1590/0103-8478cr20200107>.

MORENO, Á. H.; AGUIRRE, Á. J.; MAQUEDA, H. R.; JIMÉNEZ, J. G.; MIÑO, T. C. Effect of temperature on the microwave drying process and the viability of amaranth seeds. **Biosystems Engineering**, v. 215, p. 49-66. 2022. Doi <https://doi.org/10.1016/j.biosystemseng.2021.12.019>.

MORETI, M. P.; OLIVEIRA, T.; SARTORI, R.; CAETANO, W. Inteligência artificial no agronegócio e os desafios para a proteção da propriedade intelectual. **Cadernos de Prospecção**, v. 14, p. 60, 2021. Doi:<http://dx.doi.org/10.9771/cp.v14i1.33098>.

MUCHERINO, A.; PAPAJOJGI, P.; PARDALOS, P. M. A survey of data mining techniques applied to agriculture. **Operational Research**, v. 9, p. 121–140, 2009. Doi: <https://doi.org/10.1007/s12351-009-0054-6>.

MUKASA, P.; WAKHOLI, C.; AKBAR FAQEERZADA, M.; AMANAH, H. Z.; KIM, H.; JOSHI, R.; SUH, H.; KIM, G.; LEE, H.; KIM, M. S.; BAEK, I.; CHO, B. Nondestructive discrimination of seedless from seeded watermelon seeds by using multivariate and deep learning image analysis. **Computers and Electronics in Agriculture**, v. 194, p. 106799, 2022. Doi: <https://doi.org/10.1016/j.compag.2022.106799>.

NAMJOO, M.; MORADI, M.; NIAKOUSARI, M. Evaluation of the effect of high-power ultrasound waves on conventional air drying of cumin seeds. **Sustainable Energy Technologies and Assessments**, v. 52, p. 102262, 2022. Doi: <https://doi.org/10.1016/j.seta.2022.102262>.

NAVEED, M.; HUSSAIN, M. B.; ZAHIR, Z. A.; MITTER, B.; SESSITSCH, A. Drought stress amelioration in wheat through inoculation with *Burkholderia phytofirmans* strain PsJN. **Plant Growth Regulation**, v. 73, p. 121–131, 2014. Doi: <https://doi.org/10.1007/s10725-013-9874-8>.

NGO, Q. H.; KECHADI, T.; LE-KHAC, N. Knowledge representation in digital agriculture: A step towards standardised model. **Computers and Electronics in Agriculture**, v. 199, p. 107127, 2022. Doi: <https://doi.org/10.1016/j.compag.2022.107127>.

NOSRATI, R.; SOLIMAN, A.; SAFIGHOLI, H.; HASHEMI, M.; WRONSKI, M.; MORTON, G.; PEJOVIĆ-MILIĆ, A.; STANISZ, G.; SONG, W. Y. MRI-based automated detection of implanted low dose rate (LDR) brachytherapy seeds using quantitative susceptibility mapping (QSM) and unsupervised machine learning (ML). **Radiotherapy and Oncology**, v. 129, n. 3, p. 540-547, 2018. Doi: <https://doi.org/10.1016/j.radonc.2018.09.003>.



NUKULWAR, M. R.; TUNGKAR, V. B. Drying kinetics and thermal analysis of turmeric blanching and drying using solar thermal system. **Sustainable Energy Technologies and Assessments**, v. 45, p. 101120, 2021. Doi: <https://doi.org/10.1016/j.seta.2021.101120>.

OLIVEIRA, G. R. F DE; MASTRANGELO, C. B.; HIRAI, W. Y.; BATISTA, T. B.; SUDKI, J. M.; PETRONILIO, A. C.; CRUSCIOL, C. A.; APARECIDO, E. An approach using emerging optical technologies and artificial intelligence brings new markers to evaluate peanut seed quality. **Frontiers in Plant Science**. 2021. Doi: <https://doi.org/10.3389/fpls.2022.849986>.

OLIVEIRA, G. R. F. de; SALLES, F. K. L. de; BATISTA, T. B.; SILVA, M. S. da; CÍCERO, S. M.; GOMES JUNIOR, F. G. Morphological parameters of image processing to characterize primary root emergence in evaluation of tomato seed vigor. **Journal of Seed Science**, v. 43, p. e202143005, 2021. Doi: <https://doi.org/10.1590/2317-1545v43245215>.

ONU KWULI, D. O.; ESONYE, C.; OFOEFULE, A. U.; EYISI, R. Comparative analysis of the application of artificial neural network-genetic algorithm and response surface methods-desirability function for predicting the optimal conditions for biodiesel synthesis from chrysophyllum albidum seed oil. **Journal of the Taiwan Institute of Chemical Engineers**, v. 125, p. 153-167, 2021. Doi: <https://doi.org/10.1016/j.jtice.2021.06.012>.

ONWUDE, D. I.; HASHIM, N.; CHEN, G. Recent advances of novel thermal combined hot air drying of agricultural crops. **Trends Food Science Technology**, v. 57, p. 132-145, 2016. Doi: [10.1016/j.tifs.2016.09.012](https://doi.org/10.1016/j.tifs.2016.09.012).

PAPOUTSIS, K.; P. PRISTIJONO, J. B.; GOLDING, C. E.; STATHOPOULOS, M. C.; BOWYER, C. J.; SCARLETT, Q. V.; VUONG. Effect of vacuum-drying, hot air-drying and freeze-drying on polyphenols and antioxidant capacity of lemon (*Citrus limon*) pomace aqueous extracts. **International Journal of Food Science & Technology**, v. 52, n. 4, p. 880-887, 2017. Doi: <https://doi.org/10.1111/ijfs.13351>.

PATIL, A. V.; PETERS, E.; SUTKAR, V. S.; DEEN, N.; KUIPERS, J. A study of heat transfer in fluidized beds using an integrated DIA/PIV/IR technique. **Chemical Engineering Journal**, v. 259, p. 90-106, 2015. Doi: <https://doi.org/10.1016/j.cej.2014.07.107>.

PEDRAYES, O. D.; LEMA, D. G.; USAMENTIAGA, R.; VENEGAS, P.; GARCÍA, D. F. Semantic segmentation for non-destructive testing with step-heating thermography for composite laminates. **Measurement**, v. 200, p. 111653, 2022. Doi: <https://doi.org/10.1016/j.measurement.2022.111653>.

PEDRINI, S.; MERRITT, D. J.; STEVENS, J.; DIXON, K. Seed Coating: Science or Marketing Spin? *Trends in Plant Science*, v. 22, n. 2, p. 106-116. 2017. Doi: <https://doi.org/10.1016/j.tplants.2016.11.002>.

PERALTA, G. **Desempenho térmico de telhas: Análise de monitoramento e normalização específica**. 2006. 131 f. São Carlos, Dissertação (Mestrado) – Escola

de Engenharia da São Carlos, Universidade de São Paulo, 2006. Doi: 10.11606/D.18.2006.tde-16042007-154420.

PESKE, S. T.; VILLELA, F. A.; GADOTTI, G. I. **Secagem de sementes**. In: PESKE, S. T.; VILLELA, F. A.; MENEGHELLO, G. E. (Org.). Sementes: Fundamentos Científicos e Tecnológicos. 4 ed. Pelotas: Becker e Peske, p. 355-405. 2019.

PINHEIRO, R. M.; GADOTTI, G. I.; BERNARDY, R.; MONTEIRO, R. C. M.; MOREIRA, I. B. Processamento de imagens como ferramenta importante para inteligência artificial no setor de sementes. **Revista Agrária Acadêmica**, v. 5, p. 89-102, 2022. Doi: 10.32406/v5n1/2022/89-101/agrariacad.

PINHEIRO, R. M.; GADOTTI, G. I.; MONTEIRO, R. C. M.; BERNARDY, R. Inteligência artificial na agricultura com aplicabilidade no setor sementeiro. **Diversitas Journal**, v. 6, p. 2996-3012, 2021. Doi. [https://doi.org/10.48017/Diversitas\\_Journal-v6i3-1857](https://doi.org/10.48017/Diversitas_Journal-v6i3-1857).

PIRI, R.; MORADI, A.; BALOUCHI, H.; SALEHI, A. Improvement of cumin (*Cuminum cyminum*) seed performance under drought stress by seed coating and biopriming. **Scientia Horticulturae**, v. 257, p. 108667. 2019. Doi: <https://doi.org/10.1016/j.scienta.2019.108667>.

PORCIELLO, J.; COGGINS, S.; MABAYA, E.; OTUNBA-PAYNE, G. Digital agriculture services in low- and middle-income countries: A systematic scoping review. **Global Food Security**, v. 34, p. 100640, 2022. Doi: <https://doi.org/10.1016/j.gfs.2022.100640>.

PRABHAKARAN, A.; CHITHRA, L. K.; JANARTHANAN, G. Advancement of data mining methods for improvement of agricultural methods and productivity. **Artificial Intelligence in Data Mining**, p. 199-221, 2021. Doi: <https://doi.org/10.1016/B978-0-12-820601-0.00010-0>.

QIU, Y.; AMIRKHANI, M.; MAYTON, H.; CHEN, Z.; TAYLOR, A.G. Biostimulant seed coating treatments to improve cover crop germination and seedling growth. **Agronomy**, v. 10, n. 2 p. 154, 2020. Doi: <https://doi.org/10.3390/agronomy10020154>.

RAHMAN, A.; CHO, B-W. Assessment of seed quality using non-destructive measurement techniques: a review. **Seed Science Research**, v. 26, n. 4, p. 285-305, 2016. Doi: <https://doi.org/10.1017/S0960258516000234>.

RAHMAN, S. A. Z.; CHANDRA, M.I. K.; MOHIDUL I. S. Soil classification using machine learning methods and crop suggestion based on soil series. "2018 21st **International Conference of Computer and Information Technology (ICCIIT)**, 2018, p. 1–4. Doi: 10.1109/ICCITECHN.2018.8631943.

RATSEEW, J.; MEESO, N.; SIRIAMORNUN, S. Changes in amino acids and bioactive compounds of pigmented rice as affected by far-infrared radiation and hot air drying. **Food Chemistry**, v. 306, p. 125644, 2020. Doi: <https://doi.org/10.1016/j.foodchem.2019.125644>.

REHMAN, T. U.; SULTAN MAHMUD, M. D.; CHANG, Y. K.; JIN, J.; SHIN, J. Current and future applications of statistical machine learning algorithms for agricultural machine vision systems. **Computers and Electronics in Agriculture**, v. 156, p. 585-605. 2019. Doi: <https://doi.org/10.1016/j.compag.2018.12.006>.

ROCHA, I.; MA, Y.; SOUZA-ALONSO, P.; VOSÁTKA, M.; FREITAS, H.; OLIVEIRA, R. S. Seed coating: a tool for delivering beneficial microbes to agricultural crops. **Frontiers Plant Science**, v. 10, p. 1357, 2019a. Doi: <https://doi.org/10.3389/fpls.2019.01357>.

ROCHA, I.; MA, Y.; VOSÁTKA, M.; FREITAS, H.; OLIVEIRA, R. S. Growth and nutrition of cowpea (*Vigna unguiculata*) under water deficit as influenced by microbial inoculation via seed coating. **Journal Agronomy and Crop Science**, v. 205, n. 5, p. 447-459, 2019b. Doi: <https://doi.org/10.1111/jac.12335>.

ROTZ, S.; DUNCAN, E.; SMALL, M.; BOTSCHNER, J.; DARA, R.; MOSBY, I.; FRASER, E. The politics of digital agricultural technologies: A preliminary review. **Sociologia Ruralis**, v. 59, n. 2, p. 203–229, 2019. Doi: <https://doi.org/10.1111/soru.12233>.

RUIZ-ALTISENT, M.; RUIZ-GARCIA, L.; MOREDA, G.; LU, R.; HERNANDEZ-SANCHEZ, N.; CORREA, E.; DIEZMA, B.; NICOLAÏ, B.; GARCÍA-RAMOS, J. Sensors for product characterization and quality of specialty crops—A review. **Computers and Electronics in Agriculture**, v. 74, n. 2, p. 176-194. 2010. Doi: <https://doi.org/10.1016/j.compag.2010.07.002>.

SANKARAN, S.; MISHRA, A.; EHSANI, R.; DAVIS, C. A review of advanced techniques for detecting plant diseases. **Computers and Electronics in Agriculture**, v. 72, n. 1, p. 1-13. 2010. Doi: <https://doi.org/10.1016/j.compag.2010.02.007>.

SARIJALOO, F. B.; PORTA, M.; TASLIMI, B.; PANOS, F.; PARDALOS, M. Yield performance estimation of corn hybrids using machine learning algorithms. **Artificial Intelligence in Agriculture**, v. 5, p. 82-89, 2021. Doi: <https://doi.org/10.1016/j.aiia.2021.05.001>.

SCHNEIDER, C. A.; RASBAND, W. S.; ELICEIRI, K. W. NIH Image to ImageJ: 25 years of image analysis. **Nature Methods**, v. 9, p. 671-675, 2012. Doi: [10.1038/nmeth.2089](https://doi.org/10.1038/nmeth.2089).

SHAIKH, A. T.; RASOOL, T.; RASHEED LONE, F. Towards leveraging the role of machine learning and artificial intelligence in precision agriculture and smart farming. **Computers and Electronics in Agriculture**, v. 198, p. 107119, 2022. Doi: <https://doi.org/10.1016/j.compag.2022.107119>.

SAHA, D.; MANICKAVASAGAN, A. Machine learning techniques for analysis of hyperspectral images to determine quality of food products: A review, *Current*

**Research in Food Science**, v. 4, p 28-44, 2021. Doi: <https://doi.org/10.1016/j.crf.2021.01.002>.

SHARMA, A.; GEORGI, M.; TREGUBENKO, M.; TSELYKH, A.; TSELYKH, A. Enabling smart agriculture by implementing artificial intelligence and embedded sensing, **Computers & Industrial Engineering**, v. 165, p. 107936, 2022. Doi <https://doi.org/10.1016/j.cie.2022.107936>.

SINGH, C. B.; JAYAS, D. S.; PALIWAL, J.; WHITE, N. D. Identification of insect-damaged wheat kernels using short-wave near-infrared hyperspectral and digital colour imaging. **Computers and Electronics in Agriculture**, v. 73, n. 2, p. 118-125, 2010. Doi: <https://doi.org/10.1016/j.compag.2010.06.001>.

SINGH, G.; SINGH, A.; G. KAUR. **Role of artificial intelligence and the internet of things in agriculture**.16. Ed(s): KAUR, G.; TOMAR, P.; TANQUE, M. Artificial intelligence to solve pervasive internet of things issues, Academic Press, c. 16, p. 317-330, 2021. Doi: <https://doi.org/10.1016/B978-0-12-818576-6.00016-1>.

SHAMMI, S.; HOSSEN, M.; AL MAMUN, A. M. R.; SOEB, M. J. A. Temporal and spatial representation of temperature and moisture in drying chamber and its impact on vertical vacuum dehumidifying rice seed dryer performance. **Journal of Agriculture and Food Research**, v. 10, p. 100424, 2022. Doi: <https://doi.org/10.1016/j.jafr.2022.100424>.

SHARMA, A. SATISH, D.; SHARMA, S.; GUPTA, D. iRSVPred: A web server for artificial intelligence based prediction of major basmati paddy seed varieties. **Frontiers in Plant Science**, v. 10, p. 1791, 2020. Doi: [10.3389/fpls.2019.01791](https://doi.org/10.3389/fpls.2019.01791).

SON, J. R.; LEE, K. J.; CHOI, K. H.; KIM, G.; KANG, S.; CHOI, D. S.; JANG, I. J. Characteristics of transmittancespectrum of Korean red ginseng using VIS/NIR. **Journal of Biosystems Engineering**, v. 29, p. 329–334, 2004.

STRÆTE, E. P.; VIK, J.; FUGLESTAD, E. M.; GJEFSSEN, M. D.; MELÅS, A. M.; SØRAA, R. A. Critical support for different stages of innovation in agriculture: What, when, how? **Agricultural Systems**, v. 203, p. 103526, 2022. Doi: <https://doi.org/10.1016/j.agsy.2022.103526>.

SZADZIŃSKA, J.; ŁECHTAŃSKA, J.; PASHMINEHAZAR, R.; KHARAGHANI, A. TSOTSAS, E. Microwave- and ultrasound-assisted convective drying of raspberries: Drying kinetics and microstructural changes. **Drying Technology**, v. 37, n. 1, p. 1-12, 2019. Doi: [10.1080/07373937.2018.1433199](https://doi.org/10.1080/07373937.2018.1433199).

VAN KLOMPENBURG, T.; KASSAHUN, A.; CATAL, C. Crop yield prediction using machine learning: A systematic literature review. **Computers and Electronics in Agriculture**, v. 177, p. 105709, 2020. Doi: <https://doi.org/10.1016/j.compag.2020.105709>.

VEERAKUMAR, M.; VIJAYAKUMAR, K. C. K.; NAVANEETHAKRISHNAN, P. Different drying methods for agriculture products and eatables – a review.,

**International Journal of Mathematical Sciences and Engineering**, v. 3, n. 2, p. 53-60, 2014.

VLONTZOS, G. PARDALOS, P. M. Data mining and optimisation issues in the food industry, **International Journal of Sustainable Agricultural Management and Informatics**, v. 3, n. 1, p. 44-64, 2017. Doi: 10.1504/IJSAMI.2017.10003796.

TAGARAKIS, A.; LIAKOS, V.; FOUNTAS, S.; KOUNDOURAS, S.; GEMTOS, T. Management zones delineation using fuzzy clustering techniques in grapevines. **Precision Agriculture**, v. 14, n. 1, p. 18-39, 2013. Doi: <https://doi.org/10.1007/s11119-012-9275-4>.

TALAVIYA, T.; SHAH, D.; PATEL, N.; YAGNIK, H.; SHAH, M. Implementation of artificial intelligence in agriculture for optimisation of irrigation and application of pesticides and herbicides. **Artificial Intelligence in Agriculture**, v. 4, p. 58-73, 2020. Doi: <https://doi.org/10.1016/j.aiia.2020.04.002>.

TIGABU, M.; ODÉN, P. C. SHEN, T. Y. Application of near-infrared spectroscopy for the detection of internal insect infestation in *Picea abies* seed lots. **Canadian Journal of Forest Research**, 34, p. 76-84, 2004. Doi: <https://doi.org/10.1139/x03-189>.

XU, J.; LV, Y.; LIU, X.; DALSON, T.; YANG, S.; WU, J. Diagnosing crop water stress of rice using infra-red thermal imager under water deficit conditions. **International Journal of Agriculture & Biology**, v. 18, n. 3, p. 565–572. 2016. Doi: 10.17957/IJAB/15.0125.

ZHANG, X.; LIU, F.; HE, Y.; LI, X. Application of hyperspectral imaging and chemometric calibrations for variety discrimination of maize seeds. **Sensors**, v. 12, p. 17234-17246, 2012. Doi: <https://doi.org/10.3390/s121217234>.

ZHAO, Y.; JUSTINA, D. D. Machine learning approaches for crop growth monitoring using multi-temporal and multi-variety remotely sensed data, IGARSS 2020 - 2020 IEEE **International Geoscience and Remote Sensing Symposium**, p. 4890-4893, 2020. Doi: 10.1109/IGARSS39084.2020.9324066.

ZHOU, L.; ZHANG, C.; LIU, F.; QIU, Z.; HE, Y. Application of deep learning in food: a review. **Comprehensive Reviews in Food Science and Food Safety**, v. 18, p. 1793-1811, 2019. Doi: <https://doi.org/10.1111/1541-4337.12492>.

ZIELINSKA, M.; MARKOWSKI, M. The influence of microwave-assisted drying techniques on the rehydration behavior of blueberries (*Vaccinium corymbosum* L.). **Food Chemistry**, v. 196, p. 1188-1196, 2016. Doi: <https://doi.org/10.1016/j.foodchem.2015.10.054>.

WANG, J.; BILJECKI, F. Unsupervised machine learning in urban studies: A systematic review of applications. **Cities**, v. 129, p. 103925, 2022. Doi: <https://doi.org/10.1016/j.cities.2022.103925>.

WANG, Y.; SEO, B.; WANG, B.; ZAMEL, N.; JIAO, K.; ADROHER, X. C. Fundamentals, materials and machine learning of polymer electrolyte membrane fuel cell technology. **Energy AI**, v. 1, p. 100014, 2020. Doi: 10.1016/j.jegyai.

WEN, L.; YANG, B.; CUI, C.; YOU, L.; ZHAO, M. Ultrasound-assisted extraction of phenolics from Longan fruit seeds (*Dimocarpus longan* Lour.) With artificial neural network and its antioxidant activity. **Food Analytical Methods**, v. 5, p. 1244–1251, 2012. Doi: <https://doi.org/10.1007/s12161-012-9370-1>.

WILLENBORG, C. J.; GULDEN, R. H.; JOHNSON, E. N.; SHIRTLIFFE, S. J. Germination characteristics of polymer-coated canola (*Brassica napus* L.) seeds subjected to moisture stress at different temperatures. **Agronomy Journal**, v. 96, n. 3, p. 786-791, 2004. Doi: <https://doi.org/10.2134/agronj2004.0786>.

YAO, H.; DUAN, Q.; LI, D.; WANG, J. An improved K-means clustering algorithm for fish image segmentation. **Mathematical and Computer Modelling**, v. 58, n. 3-4, p. 790-798. Doi: <https://doi.org/10.1016/j.mcm.2012.12.025>.

YAO, L.; FAN, L.; DUAN, Z. Effect of different pretreatments followed by hot-air and far-infrared drying on the bioactive compounds, physicochemical property and microstructure of mango slices. **Food Chemistry**, v. 305, p. 125477, 2020. Doi: 10.1016/j.foodchem.2019.125477.