



UNIVERSIDADE DE BRASÍLIA-DF
FACULDADE DE AGRONOMIA E MEDICINA VETERINÁRIA
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA

ANÁLISE DE IMAGEM NO CONTROLE DE QUALIDADE DE
SEMENTES DE SOJA

VASCONCELOS ROMÃO DE OLIVEIRA

TESE DE DOUTORADO EM AGRONOMIA

BRASÍLIA-DF/DF

MAIO/2024



UNIVERSIDADE DE BRASÍLIA-DF
FACULDADE DE AGRONOMIA E MEDICINA VETERINÁRIA
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA

**ANÁLISE DE IMAGEM NO CONTROLE DE QUALIDADE DE
SEMENTES DE SOJA**

VASCONCELOS ROMÃO DE OLIVEIRA

ORIENTADORA: NARA OLIVEIRA SILVA SOUZA
CO-ORIENTADOR: MÁRCIO DA SILVA ARANTES

TESE DE DOUTORADO EM AGRONOMIA

BRASÍLIA-DF/DF
MAIO/ 2024



**UNIVERSIDADE DE BRASÍLIA-DF
FACULDADE DE AGRONOMIA E MEDICINA VETERINÁRIA
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA**

**ANÁLISE DE IMAGEM NO CONTROLE DE QUALIDADE DE
SEMENTES DE SOJA**

VASCONCELOS ROMÃO DE OLIVEIRA

**TESE DE DOUTORADO SUBMETIDA AO PROGRAMA DE PÓS-GRADUAÇÃO EM
AGRONOMIA, COMO PARTE DOS REQUISITOS NECESSÁRIOS À OBTENÇÃO
DO GRAU DE DOUTOR EM AGRONOMIA.**

APROVADO POR:

Prof. Dra. NARA OLIVEIRA SILVA SOUZA (FAV/UnB)

Prof. Dr. RICARDO CARMONA (FAV/UnB)

Dra. CAROLINE JÁCOME COSTA (EMBRAPA)

Prof. Dra. LILIAN VANUSSA MADRUGA DE TUNES (UFPeI)

BRASÍLIA-DF/DF, 24 DE MAIO DE 2024

FICHA CATALOGRÁFICA

Oliveira, Vasconcelos Romão

Análise de imagens no controle de qualidade de sementes de soja. /
Vasconcelos Romão de Oliveira: Orientadora Nara Oliveira Silva Souza; Co-
orientador Márcio da Silva Arantes – Brasília, 2024. 127p.

Tese de Doutorado – Universidade de Brasília/ Faculdade de Agronomia e
Medicina Veterinária, 2024.

1. Análise de imagem. 2. Semente esverdeada. 3. Mancha púrpura. 4. Tratamento de sementes. 5. GroundEye®. I.Souza, Nara Oliveira Silva, Orient. II. Arantes, Márcio da Silva, co-orient. III. Título.

REFERÊNCIA BIBLIOGRÁFICA

OLIVEIRA, V. R. **Análise de imagens no controle de qualidade de sementes de soja**. Brasília-DF: Faculdade de Agronomia e Medicina Veterinária, Universidade de Brasília-DF, 2024, 127p. Tese de Doutorado.

CESSÃO DE DIREITOS

NOME DO AUTOR: VASCONCELOS ROMÃO DE OLIVEIRA

TÍTULO DA TESE: Análise de imagens no controle de qualidade de sementes de soja.

GRAU: DOUTOR

ANO: 2024

É concedida à Universidade de Brasília-DF de Brasília-DF permissão para reproduzir cópias desta dissertação de mestrado para única e exclusivamente propósitos acadêmicos e científicos. O autor reserva para si os outros direitos autorais, de publicação. Nenhuma parte desta dissertação de mestrado pode ser reproduzida sem a autorização por escrito do autor. Citações são estimuladas, desde que citada à fonte.

Nome: Vasconcelos Romão de Oliveira

E-mail: vasco.r.oliv@gmail.com

Sebastiana Pereira de Oliveira (in memoriam)
Ana Batista de Jesus (in memoriam)
Lilian Aparecida de Souza
DEDICO

BIOGRAFIA DO AUTOR

Vasconcelos Romão de Oliveira, nascido em Ituiutaba – MG em 10 de setembro de 1988. Concluiu o segundo grau integrado ao curso Técnico em Agropecuária no Instituto Federal do Triângulo Mineiro. Bacharel em Engenharia Agrônômica pelo Centro Universitário do Triângulo Mineiro. Mestre em Ciência e Tecnologia de Sementes pela Universidade Federal de Pelotas. Atua há mais de 15 anos em empresas multinacionais com ênfase em controle de qualidade e laboratório de análise de sementes. Em 2019, ingressou no Programa de Pós-Graduação em Agronomia, *Stricto Sensu*, da Universidade de Brasília-DF (UnB), área de concentração: Produção sustentável.

RESUMO

A avaliação da qualidade é essencial para assegurar a comercialização de sementes capazes de expressar o máximo desempenho em campo, e por conseguinte, garantir a satisfação dos produtores. Os métodos empregados nos programas de controle de qualidade são majoritariamente testes tradicionais, suportados em inspeções visuais. Assim, os critérios de avaliação das análises incluem a subjetividade e erro dos avaliadores, comuns em operações humanas. Em contraponto, o uso da análise de imagem e inteligência artificial têm oferecido mais padronização, confiabilidade, agilidade e praticidade aos processos de avaliação de sementes. O GroundEye® é uma destas soluções, que se compõe de um sistema capaz de capturar imagens de alta resolução e transformá-las em informações como cor, textura e geometria. Neste sentido, esta pesquisa tem como objetivo utilizar análise de imagem como ferramenta complementar na avaliação de qualidade de sementes de soja, através do GroundEye®. Foram analisadas variáveis do espaço de cores HSV, CIE Lab* e LCh*, obtidas por imagem fotográfica para determinar semente esverdeada e com mancha púrpura, também foi comparada a intensidade destas injúrias com a qualidade fisiológica das sementes. Por fim, o estudo analisou como a variação de cor no recobrimento do tratamento de sementes se correlaciona com a quantidade de ingrediente ativo do produto aplicado em sementes tratadas com adição de pó secante. Os ensaios foram conduzidos no Laboratório de Análise de Sementes da Corteva Agriscience do Brasil Ltda, em Brasília-DF, Distrito Federal.

Palavras chaves: análise de imagem, GroundEye®, semente esverdeada, mancha púrpura, tratamento de sementes.

ABSTRACT

Evaluating seed quality is crucial to ensure the marketing of seeds capable of delivering maximum field performance, thereby guaranteeing farmer satisfaction. Quality control programs predominantly employ traditional testing methods supported by visual inspections. However, these evaluation criteria often involve the subjectivity and error typical of human operation. In contrast, the use of image analysis and artificial intelligence has brought more standardization, reliability, speed, and convenience to seed evaluation processes. GroundEye® represents one such solution, comprising a system capable of capturing high-resolution images and converting them into data concerning color, texture, and geometry. Accordingly, this research aims to utilize image analysis as a complementary tool in assessing the quality of soybean seeds via GroundEye®. Variables from the HSV, CIE Lab*, and LCh* color spaces were analyzed using photographic images to identify greenish seeds and those with purple stains, and to compare the intensity of these defects with the physiological quality of the seeds. Additionally, the study explored how variations in the color of the seed coating correlate with the amount of active ingredient in the product applied to seeds treated with drying powder. The experiments were conducted at the Seed Analysis Laboratory of Corteva Agriscience do Brasil Ltda, in Brasília-DF, Federal District.

Keywords: image analysis, GroundEye®, greenish seed, purple stain, seed treatment.

LISTA DE ILUSTRAÇÕES

Capítulo I

Figura 1 – GroundEye® S800D.....	50
Figura 2 – Imagens de sementes de soja capturadas pelo GroundEye® S800D. (A) e (B) ilustram sementes amarelas; (C) e (D) apresentam sementes esverdeadas.....	51
Figura 3 – Espaço de cor teórico CIE Lab* (Hunter, 1958)	53
Figura 4 – Imagem de plântula de soja capturada pelo GroundEye® S800D.....	57
Figura 5 – Árvore de decisão para classificação de semente esverdeada e amarela em soja.....	63
Figura 6 – Índice de germinação por média de ângulo de tonalidade.....	68

Capítulo II

Figura 1 – Representação de sementes de soja com mancha púrpura. (A) semente com intensidade leve; (B) semente com intensidade severa.....	79
Figura 2 – GroundEye® S800D.....	80
Figura 3 – Árvore de decisão para classificação de sementes de soja em amarela e com mancha púrpura.....	86
Figura 4 – Variabilidade cromática no espaço de cor HSV para sementes amarela (A) e com presença de mancha púrpura leve (B) e severa (C).....	89

Capítulo III

Figura 1 – Representação esquemática do tratador de sementes.....	104
Figura 2 – Friabilômetro em operação para o teste de abrasão Friabilômetro em operação para o teste de abrasão.....	106
Figura 3 – Analisador XRF, modelo Vanta™.....	107
Figura 4 – GroundEye® S800D.....	108
Figura 5 – Diferença total de cor entre sementes de soja após 12 e 24 minutos de abrasão em diferentes doses de pó secante.....	114
Figura 6 – Análise de componentes principais para diferentes cores do espaço de cor HSV.....	115
Figura 7 – Imagens de sementes de soja submetidas a diferentes doses de pó secante e diferentes tempos de abrasão.....	118
Figura 8 – Valores individuais da soma das cores vermelha e rosa para lotes de soja submetidos ou não a pó secante em diferentes tempos de abrasão.....	120

LISTA DE TABELAS

Capítulo I

Tabela 1 – Comparação de porcentagem de sementes esverdeadas em soja avaliadas por diferentes avaliadores.....	60
Tabela 2 – Diferença de médias entre diferentes avaliadores e o avaliador controle para análise de sementes esverdeadas em soja.....	61
Tabela 3 – Concordância de avaliação entre diferentes avaliadores na identificação de sementes amarelas e esverdeadas em soja.....	61
Tabela 4 – Matriz de confusão para classificação de sementes de soja: amarela versus esverdeada.....	64
Tabela 5 – Análise da árvore de decisão de acordo com as principais métricas de desempenho.....	64
Tabela 6 – Percentual de germinação e tamanho de raiz primária, hipocótilo e comprimento total em plântulas de sementes de soja amarela e esverdeada.....	66

Capítulo II

Tabela 1 – Expressão de cores no espaço HSV.....	81
Tabela 2 – Matriz de confusão para classificação de sementes de soja: amarela versus mancha púrpura.....	85
Tabela 3 – Análise da árvore de decisão de acordo com as principais métricas de desempenho.....	86
Tabela 4 – Valores médios e desvio padrão combinado para diferentes cores do modelo HSV, obtidos para as classes: semente amarela, mancha púrpura leve e mancha púrpura severa.....	88
Tabela 5 – Matriz de confusão para classificação de sementes de soja: mancha púrpura leve versus mancha púrpura severa.....	91
Tabela 6 – Germinação de sementes e tamanho de raiz primária, hipocótilo e comprimento total de plântulas de soja resultantes de sementes com e sem mancha púrpura leve ou severa.....	92
Tabela 7 – Taxas de plântulas normais, anormais e sementes mortas resultantes do teste germinação em sementes de soja com e sem mancha púrpura leve ou severa.....	93
Tabela 8 – Taxas de vigor, viabilidade, dano mecânico (DM) e dano por umidade (DU) classe 6-8 por meio do teste de tetrazólio em semente com e sem presença de mancha púrpura.....	94

Capítulo III

Tabela 1 – Produtos aplicados nas sementes de soja, com respectivos produtos comerciais (p.c.), ingredientes ativos e doses utilizadas.....	104
Tabela 2 – Expressão de cores no espaço HSV.....	109

Tabela 3 – Massa de mil sementes e quantidade de sementes por quilo de diferentes lotes de sementes de soja tratados industrialmente com e sem pó secante.....	111
Tabela 4 – Diferença total de cor (ΔE^*ab) para sementes de soja tratadas com e sem adição de pó secante, submetidas posteriormente a diferentes tempos de abrasão.....	113
Tabela 5 – Concentração das cores vermelha, rosa e laranja em resposta à abrasão e variação na concentração de pó secante em sementes de soja tratadas industrialmente.....	116
Tabela 6 – Média da Ineficiência do Recobrimento para diferentes concentrações de pó secante e tempos de abrasão no tratamento industrial de sementes de soja....	121
Tabela 7 – Concentração de Dermacor® em sementes de soja tratadas industrialmente em resposta à abrasão e concentração de pó secante.....	122

LISTA DE ABREVIATURAS E SIGLAS

%	Porcentagem
±	Mais ou menos
°	Graus
°C	Graus Celsius
a*	Eixo verde e vermelho
b*	Eixo azul e amarelo
C*	Croma
cm	Centímetros
h*	Ângulo de tonalidade
L*	Luminosidade
Ltda	Limitada
n	Número de dados
kg	Quilograma
=	Igual
≤	Menor ou igual
RPM	Rotação por minuto
p.c.	Produto comercial
mL	Mililitro
CIE	Commission Internationale de l'Eclairage
CONAB	Companhia Nacional de Abastecimento
IC	Intervalo de confiança
TIS	Tratamento industrial de sementes
XRF	Fluorescência de Raios X
IA	Inteligência artificial
FAO	Organização das Nações Unidas para a Alimentação e a Agricultura

SUMÁRIO

1. INTRODUÇÃO GERAL	15
2. OBJETIVOS	17
2.1 Objetivo geral.....	17
2.2 Objetivos específicos	17
3. REVISÃO DE LITERATURA	18
3.1 A cultura da soja	18
3.2 Controle de qualidade.....	19
3.3 Semente esverdeada.....	19
3.4 Mancha púrpura.....	21
3.5 Tratamento industrial de sementes.....	23
3.6 Análise de imagem	26
3.6.1 Imagem digital.....	26
3.6.2 Visão computacional.....	29
3.6.3 Análise de imagem na qualidade de sementes.....	30
3.6.4 GroundEye®.....	33
4. REFERÊNCIAS BIBLIOGRÁFICAS	35
CAPÍTULO I – INTELIGÊNCIA ARTIFICIAL APLICADA À CLASSIFICAÇÃO DE SEMENTES ESVERDEADAS E PREDIÇÃO DE QUALIDADE FISIOLÓGICA EM SOJA	43
RESUMO	44
ABSTRACT	45
1. INTRODUÇÃO	46
2. MATERIAL E MÉTODOS.....	48
2.1 Avaliação visual de sementes.....	49
2.2 Análise de imagem através do GroundEye®	49
2.3 Modelo de validação	53
2.4 Caracterização e avaliação da qualidade das sementes	55
2.4.1 Teor de água.....	55
2.4.2 Massa de mil sementes	55
2.4.3 Germinação	55
2.4.4 Vigor via GroundEye®	56
2.4.5 Análise estatística	58
3. RESULTADOS E DISCUSSÃO	59
3.1 Avaliação visual de sementes esverdeadas	59
3.2 Aprendizado de máquina: Árvore de decisão	62
3.3 Qualidade fisiológica.....	65
4.CONCLUSÕES	70
5. REFERÊNCIAS BIBLIOGRÁFICAS	71

CAPÍTULO II – INTELIGÊNCIA ARTIFICIAL APLICADA À CLASSIFICAÇÃO DE SEMENTES COM MANCHA PÚRPURA E PREDIÇÃO DE QUALIDADE FISIOLÓGICA EM SOJA 74

RESUMO 75

ABSTRACT 76

1. INTRODUÇÃO 77

2. MATERIAL E MÉTODOS 79

2.1 Análise de imagem através do GroundEye® 79

2.2 Modelo de validação 81

2.3 Avaliação da qualidade das sementes 83

2.3.1 Germinação 83

2.3.2 Vigor via GroundEye® 83

2.3.3 Teste de tetrazólio 84

2.3.4 Análise estatística 84

3. RESULTADOS E DISCUSSÃO 85

3.1 Aprendizado de máquina: Árvore de decisão 85

3.3 Qualidade fisiológica 92

4. CONCLUSÕES 95

5. REFERÊNCIAS BIBLIOGRÁFICAS 96

CAPÍTULO III – ANÁLISE DE IMAGEM NA AVALIAÇÃO DO RECOBRIMENTO DE SEMENTES DE SOJA TRATADAS INDUSTRIALMENTE COM ADIÇÃO DE PÓ SECANTE 99

RESUMO 100

ABSTRACT 101

1. INTRODUÇÃO 102

2. MATERIAL E MÉTODOS 104

2.1 Teste de abrasão – Friabilidade 105

2.2 Concentração de Dermacor® 106

2.3 Análise de imagem através do GroundEye® 107

2.4 Delineamento experimental 110

3. RESULTADOS E DISCUSSÃO 111

4. CONCLUSÕES 124

5. REFERÊNCIAS BIBLIOGRÁFICAS 125

1. INTRODUÇÃO GERAL

Ao longo das últimas décadas, houve significativos avanços na avaliação da qualidade de sementes, contemplando aspectos físicos, fisiológicos, sanitários e genéticos (MARCOS FILHO, 2015). Apesar destes avanços, grande parte da avaliação da qualidade ainda é conduzida com base na subjetividade, muitas vezes dependente de técnicos experientes que inspecionam visualmente as sementes (BEWLEY et al., 2012). Este método subjetivo pode resultar em possíveis inconsistências na classificação das sementes, levando a decisões equivocadas quanto ao seu uso e comercialização. Em resposta a essa subjetividade, técnicas avançadas, como a análise de imagem, têm sido desenvolvidas, proporcionando avaliação mais precisa e objetiva da qualidade das sementes (PATEL et al., 2012; RAJJOU et al., 2012). Com base nisso, esta abordagem demonstra potencial para elevar a eficiência e confiabilidade dos métodos de avaliação e seleção de sementes.

A análise de imagens tem emergido como uma técnica fundamental na avaliação da qualidade de sementes (BARBEDO, 2018). Com a capacidade de avaliar várias características das sementes, como tamanho, forma, cor e textura, essa tecnologia representa uma abordagem mais objetiva e precisa, detectando defeitos e irregularidades que muitas vezes passam despercebidos na avaliação visual convencional (BAURIEGEL et al., 2011). Pesquisas recentes comprovam a aplicabilidade da análise por imagem na avaliação de sementes de diversos cultivos, incluindo soja, milho, feijão, arroz e outros cereais (SILVA et al., 2014; PINTO et al., 2015; LEE et al., 2017; HUANG et al., 2020; THAUKER et al., 2022)

Conforme enfatizado por Al-Hammad e Al-Ammari (2017), a análise por imagem oferece a vantagem significativa de ser um método não destrutivo, preservando intacta a amostra em estudo. Primeiramente, ao manter a amostra sem alterações, ela pode ser reutilizada em testes subsequentes ou comparada em diferentes métodos de avaliação. Isso proporciona uma economia de recursos, especialmente quando lidamos com amostras raras ou limitadas. Além disso, o fato de o método ser não destrutivo permite melhor rastreabilidade e controle de qualidade. Em eventuais discrepâncias ou dúvidas sobre os resultados, os especialistas podem retornar à amostra original e realizar novas análises, assegurando a confiabilidade das informações obtidas.

A utilização de tecnologias de análise de imagens pode representar importante evolução no conceito de qualidade em sementes, permitindo avaliação mais objetiva, precisa e automatizada. Essas tecnologias são capazes de fornecer informações mais detalhadas e precisas sobre a qualidade das sementes, contribuindo para a seleção de materiais de melhor qualidade, redução de perdas e aumento da produtividade. Além disso, a utilização de análises de imagens pode trazer ganhos em termos de eficiência, rapidez e economia de recursos, uma vez que dispensa a necessidade de inspeções manuais.

Em empresas especializadas na produção de sementes de soja, três desafios centrais se destacam no controle de qualidade: a correta identificação de sementes esverdeadas, a detecção da mancha púrpura e a avaliação da eficácia do tratamento das sementes. Diante deste cenário, o objetivo desta tese é investigar o equipamento GroundEye® como ferramenta aplicável no controle de qualidade de sementes. Utilizando técnicas de análise de imagem e inteligência artificial, aspira-se aperfeiçoar as avaliações relacionadas às sementes esverdeadas, mancha púrpura e ao tratamento químico industrial, contribuindo assim para a elevação dos padrões de qualidade na produção de sementes de soja.

2. OBJETIVOS

2.1 Objetivo geral

Utilizar análise de imagem como ferramenta complementar para avaliação de qualidade de sementes de soja, através do GroundEye®.

2.2 Objetivos específicos

Empregar técnicas de inteligência artificial para analisar e identificar sementes esverdeadas de soja através de análise de imagem.

Empregar técnicas de inteligência artificial para analisar e identificar sementes com mancha púrpura através de análise de imagem.

Analisar o impacto de sementes esverdeadas e de mancha púrpura na qualidade fisiológica de sementes de soja.

Utilizar a análise de imagem para avaliação de sementes de soja tratadas industrialmente com e sem pó secante.

3. REVISÃO DE LITERATURA

3.1 A cultura da soja

A soja, nomeada cientificamente como (*Glycine max* (L.) Merrill), é uma planta da família Fabaceae e da classe magnoliopsida (dicotiledônea) que teve origem na região asiática, principalmente na China. Sua expansão ocorreu pela Europa no final do século XV e nos Estados Unidos no início do século XX, tornando-se uma das principais culturas agrícolas do país. No Brasil, a soja foi introduzida em 1882 e somente na década de 1960 começou a ser cultivada comercialmente (QIU LIJUAN, 2010; HARTMAN et al., 2011).

De acordo com dados divulgados pela Companhia Nacional de Abastecimento (CONAB), a produção de soja no Brasil tem aumentado significativamente nos últimos anos. Esse aumento pode ser atribuído ao crescimento tanto da área cultivada, que cresceu 3,7%, quanto da produtividade média, que atingiu a marca de 3,54 toneladas por hectare (CONAB, 2022)

O Brasil é hoje o maior produtor e exportador mundial de soja, sendo esse cultivo de grande importância para a economia do país (CONAB, 2022). O contínuo crescimento da produção de soja tem contribuído significativamente para o desenvolvimento econômico e social em várias regiões do país, impulsionando a geração de empregos e o aumento da renda dos produtores rurais.

O alto teor de óleo e proteína nos grãos de soja atraiu a atenção do mercado e impulsionou sua produção em larga escala. Essa riqueza nutricional estabeleceu a soja como ingrediente fundamental na indústria global, abrangendo diversas aplicações, como a fabricação de óleo e farelo, essenciais para a alimentação humana e animal. Além disso, a soja é utilizada na produção de biodiesel, leite de soja, tofu e uma ampla gama de outros produtos (SINGH e SHIVAKUMAR, 2010).

Segundo Marcos Filho et al. (2009), para superar os desafios enfrentados na produção de soja, é fundamental adotar sementes de qualidade, uma vez que estas apresentam maior vigor, resistência a doenças, melhor estabelecimento e maior produtividade. Assim, é essencial que as empresas produtoras implementem programas de controle rigorosos para avaliar o impacto de diferentes variáveis na qualidade das sementes e garantir a comercialização de produtos com alto potencial de desempenho agrônomo.

3.2 Controle de qualidade

A qualidade de uma semente determina seu valor para a semeadura. Sementes de alta qualidade resultam em maior uniformidade e taxa de emergência das plântulas, aumentando a produtividade das culturas; também são mais capazes de lidar com estresses ambientais, como temperaturas extremas, seca e doenças. (MCDONALD, 1998).

De acordo com França-Neto et al. (2016), a qualidade das sementes é determinada por diversos fatores, incluindo características genéticas, físicas, fisiológicas e sanitárias. A avaliação desses atributos é essencial para garantir que as sementes utilizadas na agricultura sejam de alta qualidade e contribuam para o sucesso da produção agrícola.

Com o objetivo de atender aos padrões de identidade e qualidade exigidos para produção e comercialização de sementes, são realizados diferentes tipos de análises. Essas análises seguem protocolos estabelecidos pelas Regras para Análise de Sementes, a fim de padronizar os métodos entre diferentes laboratórios (BRASIL, 2009).

Adicionalmente, a maioria das empresas implementam testes adicionais para uma avaliação mais detalhada da qualidade de seus produtos. Entre os testes extraoficiais destacam-se as avaliações visuais das sementes, que visam identificar através da coloração desuniformidades e anomalias visíveis, como as sementes esverdeadas, a mancha púrpura e o recobrimento do tratamento de sementes. Ambos têm potencial de influenciar a qualidade do produto, justificando a necessidade de criar níveis de controle para garantir que o produto atenda limites aceitáveis para comercialização.

3.3 Semente esverdeada

Sementes esverdeadas são aquelas que possuem altos teores de clorofila em seu interior, resultantes da imaturidade fisiológica ou de condições adversas de cultivo. A presença de tonalidade verde nos cotilédones indica que o processo de maturação foi interrompido prematuramente, resultando em redução na qualidade e produtividade das sementes (FRANÇA NETO et al., 2005).

Pádua et al. (2007) apontam que vários fatores ambientais, como altas temperaturas, seca, chuvas excessivas, doenças e pragas, podem contribuir para a ocorrência de sementes esverdeadas em soja durante a maturação. Esses fatores afetam a produção de enzimas responsáveis pela degradação da clorofila, levando à acumulação de clorofila nas sementes e, conseqüentemente, à sua coloração verde.

A degradação da clorofila ocorre em duas fases distintas: a primeira fase, conhecida como fase verde, ocorre durante a maturação das sementes e é caracterizada pela redução na atividade fotossintética, pela diminuição do teor de clorofila e pelo aumento da atividade de enzimas responsáveis pela sua degradação. Já a segunda fase, conhecida como fase amarela, ocorre durante a secagem das sementes e é caracterizada pela completa degradação da clorofila e pelo início da síntese de compostos que conferem cor amarela às sementes maduras (TAIZ et al., 2017).

De acordo com estudos realizados por Pádua et al. (2007), a ocorrência de sementes esverdeadas em soja está diretamente relacionada ao déficit hídrico, ao uso de herbicidas e às altas temperaturas. Esses fatores afetam principalmente a atividade enzimática, resultando na acumulação de clorofila na semente. A decomposição da clorofila pode levar à produção de compostos tóxicos que danificam as membranas celulares das sementes, reduzindo sua viabilidade e vigor (CÍCERO, et al., 2009).

Segundo Rangel et al. (2011), a incidência de sementes esverdeadas na região sul do Mato Grosso do Sul foi principalmente causada pelo uso de herbicidas e colheita antecipada, o que pode prejudicar a maturação adequada das sementes e comprometer a qualidade da produção.

De Arruda et al. (2016) constataram que a presença de sementes esverdeadas afeta negativamente a qualidade fisiológica dos lotes de sementes de soja, reduzindo a germinação e o vigor das sementes. Essa conclusão foi corroborada por Teixeira et al. (2020), que também observaram diminuição significativa na qualidade fisiológica das sementes esverdeadas em comparação às sementes maduras e amarelas. Além disso, as sementes esverdeadas apresentaram menor velocidade de germinação, comprimento de raiz e massa seca das plântulas.

De acordo com Pupim et al. (2005) e Zorato et al. (2007), a presença de sementes esverdeadas em lotes de soja pode comprometer a qualidade fisiológica das sementes, resultando em menor germinação e vigor em relação às sementes maduras e amareladas. Portanto, é fundamental garantir que as sementes

comercializadas estejam dentro dos limites aceitáveis em relação a essa característica, o que requer a realização de testes laboratoriais precisos.

A detecção de sementes esverdeadas é crucial, uma vez que sua presença indica a possibilidade de sementes imaturas, o que pode comprometer a qualidade e o potencial produtivo da semente. No entanto, a avaliação tradicionalmente realizada por meio de inspeções visuais é subjetiva e propensa a erros humanos, ressaltando a necessidade de técnicas mais precisas para o controle de qualidade das sementes. Nesse contexto, a análise de imagem surge como uma alternativa promissora, capaz de superar as limitações dos testes visuais e fornecer resultados mais precisos e confiáveis.

3.4 Mancha púrpura

A mancha púrpura da semente é consensualmente associada ao fungo necrotrófico *Cercospora kikuchii* (MATSUMOTO e TOMOYASU) M. W. Gardner (GARDNER, 1925; MATSUMOTO e TOMOYASU, 1925). Nos grãos de soja, os sintomas são facilmente reconhecidos pela cor arroxeadada nos tecidos superficiais e pequenas fissuras no tegumento que apresenta aspecto áspero e opaco (LEHMAN et al., 1950). Além de afetar folhas e sementes, *C. kikuchii* também provoca lesões em vagens, pecíolos e hastes da planta (LEHMAN et al., 1950; MURAKISHI et al., 1951).

As sementes são um importante veículo de dispersão do patógeno, uma vez que os sintomas típicos da mancha púrpura das sementes podem nem sempre estar presentes (HARTMAN et al., 1999). A dispersão dos conídios pelo vento também tem papel importante na epidemiologia, sendo que temperaturas entre 20 e 24 °C e umidade relativa acima de 80% aumentam a incidência das doenças (KUDO et al., 2011).

A tonalidade roxa observada no tegumento da semente é consequência da ação do fungo que produz cercosporina, uma toxina do tipo perilenoquinona. Quando exposta à luz, essa toxina capta energia luminosa e, em resposta, libera espécies reativas de oxigênio que comprometem a integridade das membranas celulares das sementes (DAUB et al., 2005). Além de prejudicar a membrana celular, a cercosporina induz a oxidação de lipídios, proteínas e ácidos nucleicos, comprometendo a viabilidade da semente (DAUB; CHUNG, 2007).

Sementes de soja afetadas com mancha púrpura frequentemente exibem diminuição na germinação e vigor, comprometendo o estabelecimento inicial da planta no campo (WRATHER e KOENNING, 2006). Esta perturbação na germinação e no vigor se traduz em prejuízos econômicos significativos para os produtores. Segundo Hartman et al. (1999), a mancha-púrpura afeta negativamente a qualidade dos grãos de soja, resultando na redução da germinação e consequente morte precoce das plântulas. Esta questão foi reforçada por Pathan et al. (1989), Schuh (1999) e Li et al. (2016), que destacaram sua influência adversa no vigor das sementes e, assim, no adequado estabelecimento da cultura.

A infecção por *Cercospora kikuchii* compromete a qualidade das sementes, resultando em plantas de menor vigor e, conseqüentemente, mais vulneráveis a outras patologias e estresses abióticos (SINCLAIR e BACKMAN, 1989). Adicionalmente, esta doença leva à diminuição do teor de óleo nos grãos (HARTMAN et al., 2015) e altera a composição química e as propriedades antioxidantes das sementes (LEE et al., 2015).

Os sintomas da mancha-púrpura nas sementes, que incluem a coloração púrpura e a formação de estrias escuras no tegumento, não apenas indicam a presença do patógeno, mas também reduzem o valor comercial da semente, o que resulta em perdas econômicas diretas para os produtores (HARTMAN et al., 1999).

Embora diversos estudos tenham sugerido um impacto negativo da mancha-púrpura (MP) na qualidade fisiológica das sementes de soja, há uma controvérsia no campo científico a respeito dessa conclusão. Muitos desses estudos indicam que sementes infectadas pelo fungo *C. kikuchii*, podem ter reduzido vigor, germinação e produtividade. No entanto, outras investigações apontam para resultados distintos.

Oliveira et al. (1993), por exemplo, não identificaram quaisquer efeitos deletérios desta doença sobre a germinação da soja. Este resultado foi semelhante ao observado por Galli et al. (2005) e Câmara (2019), reforçando a ideia de que, ao menos sob certas condições ou em determinados contextos, a mancha púrpura pode não comprometer a qualidade das sementes.

De maneira mais enfática, Henning et al. (2019) afirmaram que a simples presença do fungo *C. kikuchii*, não afeta intrinsecamente a qualidade fisiológica das sementes de soja. Quando a semente de soja apresenta boa qualidade fisiológica, mesmo estando infectada por fungos cercosporoides, o controle desse fungo pode ser

efetuado com aplicações de fungicidas, tanto sistêmicos quanto de contato (HENNING et al., 2019).

Em um estudo conduzido por Velicheti et al. (1992), foi observado que sementes infectadas por este fungo germinaram de forma semelhante às que não foram infectadas. A pesquisa também indicou que, mesmo com a degradação das proteínas presentes no tegumento das sementes infectadas, as proteínas cotiledonares permaneceram intactas. Além disso, a infecção de sementes pelo patógeno por um período superior a trinta dias não resultou em efeitos significativos na germinação das sementes ou na mortalidade das plântulas, evidenciando a insignificância da influência do fungo ou de sua toxina, a cercosporina.

É possível que as divergências entre os diversos estudos sobre a mancha púrpura sejam, em parte, decorrentes do uso de diferentes cultivares de soja (hospedeiro), de isolados do fungo (patógeno) e de fatores ambientais (ambiente) – triângulo das relações patógeno hospedeiro.

Como defendido por Morais (2022), avaliação da severidade da infecção nas sementes de soja pelo fungo *C. kikuchii* é um elemento crucial para compreender o impacto real da doença. Dependendo da metodologia e dos critérios adotados, os resultados podem variar, o que pode explicar as discrepâncias observadas entre diferentes estudos.

3.5 Tratamento industrial de sementes

O tratamento de sementes (TS) é uma tecnologia importante para proteger as sementes durante o armazenamento e a fase inicial de desenvolvimento das plântulas contra patógenos e pragas presentes nas sementes e no ambiente. Além de controlar a transmissão de patógenos pelas sementes, o TS garante eficientemente populações adequadas de plantas quando as condições edafoclimáticas são menos favoráveis à rápida germinação e emergência de plântulas, deixando as sementes expostas por mais tempo a fungos e pragas (HENNING, 2005).

O tratamento químico de sementes tem se mostrado uma prática eficaz na melhoria da qualidade sanitária das sementes e na proteção contra patógenos que podem prejudicar o desenvolvimento das plântulas (BALARDIN et al., 2011; CONCEIÇÃO et al., 2014), reduzindo os efeitos negativos sobre seu estabelecimento inicial no campo (CASTRO et al., 2008; MERTZ et al., 2009; PEREIRA et al., 2011).

Existem diferentes procedimentos para a aplicação de produtos químicos nas sementes, os quais podem ser divididos em duas categorias principais. No primeiro método, chamado de "*on farm*", o processo é realizado sob a supervisão do agricultor e com equipamentos geralmente menos precisos (LUDWIG et al., 2011). No tratamento industrial de sementes (TIS), realizado pelas empresas produtoras, as sementes são tratadas na própria linha de processamento, ensacadas e armazenadas até o momento da semeadura (BRZEZINSKI et al., 2015). O tratamento industrial apresenta vantagens em relação à eficiência na aplicação da dose do produto, à uniformidade de cobertura e à aderência dos produtos às sementes (REIS et al., 2023).

Após o tratamento químico das sementes de soja, a aplicação de um recobrimento pode ajudar a melhorar a distribuição do produto e reduzir o risco de superdosagem ou subdosagem. Em um estudo realizado por Bays et al. (2007), o recobrimento com fungicida, micronutrientes e polímeros resultou em sementes com boa aparência, aderência, distribuição e coloração. Levien et al. (2008) também observaram que a adição de polímeros no tratamento de sementes de soja melhora aderência dos produtos e sua distribuição no tegumento.

Mais recentemente, o pó secante tem sido incorporado ao tratamento industrial de sementes com o objetivo de melhorar a aderência dos produtos químicos às sementes. O uso de pó secante oferece diversas vantagens, como a secagem rápida e uniforme das sementes e a melhor aparência visual do tratamento. O pó secante também pode funcionar como um lubrificante, aprimorando a fluidez das sementes durante a semeadura e, assim, facilitando o processo.

A composição do pó secante inclui mica revestida com dióxido de titânio e talco natural de cloreto. Conforme mencionado por Clifton (1985), esta última substância possui características hidrofílicas. Assim, ao aplicar o pó seco nas sementes, é possível obter uma rápida secagem dos líquidos, graças a um processo físico natural decorrente da natureza hidrofílica do talco.

A avaliação visual é uma das técnicas mais comuns na indústria de sementes para verificar a uniformidade do revestimento e identificar possíveis problemas, como a presença de sementes com excesso ou falta de recobrimento. Para realizar a avaliação visual do recobrimento, é necessário ter um padrão visual para comparar a aparência das sementes. Durante a avaliação, o avaliador observa uma amostra

representativa das sementes tratadas e a compara com o padrão estabelecido, geralmente atribuindo um conceito qualitativo, como aprovado ou reprovado.

A avaliação visual é uma análise qualitativa, que, embora útil e acessível, apresenta a subjetividade na interpretação como sua principal limitação. Portanto, recomenda-se complementar essa avaliação com outras técnicas, como análises químicas, para obter informações mais precisas sobre a eficácia do tratamento e a concentração do ingrediente ativo, garantindo, assim, a qualidade do tratamento aplicado às sementes.

Entre as técnicas utilizadas para identificar e quantificar elementos químicos destaca-se a Fluorescência de Raios X (XRF, do inglês *X-ray Fluorescence*). Essa técnica consiste na excitação dos átomos de um material através de raios X, provocando a ejeção de elétrons de suas camadas internas, que posteriormente emitem fluorescência ao retornarem ao estado fundamental (MOUAZEN et al., 2005). Adicionalmente, a técnica apresenta a vantagem de ser não destrutiva e não invasiva, possibilitando a análise de amostras sem modificá-las ou danificá-las (MARGUÍ et al., 2014).

A técnica de Fluorescência de Raios X (XRF) é amplamente reconhecida por sua rapidez, precisão e capacidade de analisar uma vasta gama de elementos químicos em diversas aplicações (HOU et al., 2004). Essa versatilidade permite que a técnica seja empregada em diversos campos, incluindo a agricultura, com aplicação na análise de solos, fertilizantes, plantas e alimentos.

Zaman et al. (2018) utilizaram a técnica de espectroscopia de fluorescência de raios X (XRF) para avaliar a concentração de zinco em diferentes partes da planta de arroz, incluindo sementes, casca e palha. Rohr (2021) aplicou esta mesma técnica para medir a concentração e distribuição do zinco nas sementes e plântulas de soja, além de avaliar o efeito do tratamento com zinco no crescimento e desenvolvimento das plantas.

No estudo de Cotrim et al. (2019) os autores investigaram a relação entre o desempenho fisiológico das sementes de crotalária e a distribuição de cálcio (Ca), fósforo (P), potássio (K) e enxofre (S), utilizando a técnica de fluorescência de raios X.

3.6 Análise de imagem

3.6.1 Imagem digital

A imagem digital é uma representação visual de uma cena ou objeto, composta por um conjunto finito de elementos discretos chamados pixels, cada um com uma cor e uma posição específica em uma grade bidimensional (GONZALEZ e WOODS, 2008).

A primeira envolve a captura da imagem por meio de um dispositivo de aquisição, como uma câmera digital, um scanner ou um microscópio eletrônico (SZELISKI, 2022). A imagem é então convertida em uma matriz bidimensional de pixels, onde cada pixel é representado por um valor numérico correspondente à sua intensidade ou cor.

A etapa de pré-processamento consiste em melhorar a qualidade da imagem, corrigindo problemas como ruído, distorções e variações de iluminação. As técnicas de pré-processamento incluem filtragem, equalização de histograma, correção de geometria e ajuste de contraste (GONZALEZ e WOODS, 2008).

A segmentação é o processo de dividir a imagem em regiões ou objetos de interesse. Isso é feito identificando bordas, áreas de cor ou textura semelhantes e agrupando os pixels em regiões conectadas. Algumas técnicas de segmentação incluem limiarização, crescimento de regiões, detecção de bordas e agrupamento (SZELISKI, 2022).

Após a segmentação, as características relevantes dos objetos de interesse são extraídas para análise posterior. Essas características podem incluir tamanho, forma, cor, textura e orientação. A extração de características é crucial para a interpretação e classificação das informações visuais contidas na imagem (SONKA et al., 2014).

A última etapa envolve a análise das características extraídas para obter informações úteis sobre a cena ou objeto representado na imagem. Isso pode incluir a identificação e classificação de objetos, a estimativa de parâmetros geométricos e a detecção de padrões ou tendências (SZELISKI, 2022).

As imagens digitais são compostas por pixels, e cada pixel possui informações de cor que podem ser descritas por diferentes sistemas ou modelos de cores. Os sistemas de cores mais comuns utilizados na imagem digital incluem o RGB (Red,

Green, Blue), o CMYK (Cyan, Magenta, Yellow, Key/Black), o HSL (Hue, Saturation, Lightness) e o HSV (Hue, Saturation, Value) (SHARMA, 2017).

O sistema RGB é baseado em uma combinação aditiva das cores primárias e é amplamente utilizado em dispositivos eletrônicos, como monitores, câmeras digitais e scanners (REINHARD et al., 2010). Por outro lado, o sistema CMYK é um sistema de cores subtrativo usado principalmente na indústria gráfica para impressão (RODRIGUEZ, 2013).

Os sistemas HSL e HSV são comumente empregados no processamento de imagem e análise de cores, pois separam as informações de cor e brilho, facilitando a manipulação de imagens e a identificação de características específicas das cores (SMITH, 1978). Segundo Meneses (2012), o sistema HSV não constitui uma teoria de cores propriamente dita, mas sim uma alternativa para modelar uma representação espacial de três atributos de cor, de forma equivalente ao espaço do cubo de cor RGB. Em outras palavras, o sistema HSV é uma transformação numérica do espaço de cor RGB para o espaço HSV.

Os espaços de cores baseados em matiz e saturação são utilizados principalmente devido à necessidade de especificar as propriedades da cor de forma numérica. Esses espaços representam cores utilizando valores intuitivos, que são baseados nos conceitos de matiz, saturação e intensidade. O matiz (H) identifica a cor dominante no espectro visível — como vermelho, verde, violeta e amarelo — e é geralmente escalado de 0 a 360 graus. A saturação (S) indica a pureza da cor, com valores mais baixos resultando em uma cor mais próxima do cinza e valores mais altos indicando uma cor mais pura, variando de 0% a 100%. A intensidade (V), por sua vez, mede o brilho da cor, também escalado de 0% a 100% (SMITH, 1978; MISS.SNEHAL e CHOUGULE, 2013).

Além desses sistemas, o CIE Lab* (Commission Internationale de l'Eclairage Lab) é outro modelo de cores importante no campo da imagem digital (FAIRCHILD, 2013). O CIE Lab* é projetado para ser perceptualmente uniforme, o que significa que as diferenças entre as cores no espaço CIE Lab* correspondem às diferenças percebidas pelo olho humano (LUO e RHODES, 2001).

O espaço de cor CIE Lab* possui três eixos: L^* , a^* e b^* , como ilustrado na Figura 1. O eixo L^* representa a luminosidade, variando de 0 (preto) a 100 (branco). Os eixos a^* e b^* representam as coordenadas cromáticas do verde ao vermelho (a^*) e do azul ao amarelo (b^*) (MCLAREN, 1976).

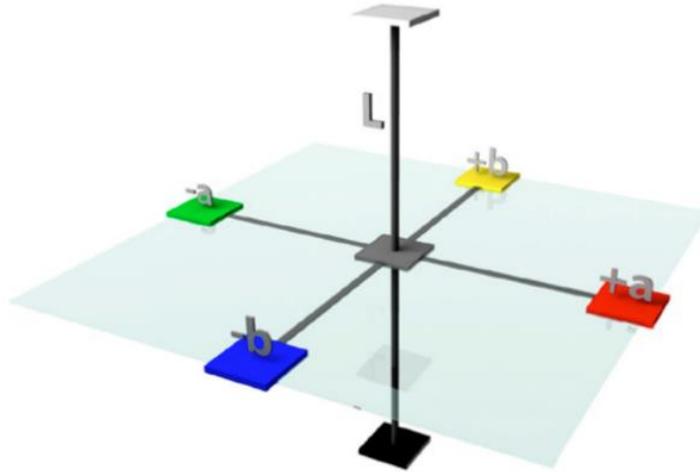


Figura 1 – Espaço tridimensional de cores CIE Lab*.
Fonte: Adaptado de X-Rite (2016).

O espaço de cor LCh refere-se a um sistema de cores que é uma transformação polar do espaço CIE Lab*. Para calcular o cromatismo (C^*) e o ângulo de tonalidade (h^*) no espaço de cor CIE Lab*, é necessário converter as coordenadas a^* e b^* em coordenadas polares C^* e h^* . A seguir, apresentam-se as etapas para o cálculo do cromatismo e do ângulo de tonalidade, conforme Robertson (1977):

a) O cromatismo (C^*) representa a intensidade ou pureza da cor e é calculado como a distância radial no plano ab , conforme Equação 1.

$$Croma = \sqrt{a^2 + b^2}$$

b) O ângulo de tonalidade (h^*) corresponde ao ângulo no plano ab que descreve a cor em termos de matiz. Para calcular o ângulo de tonalidade, emprega-se a Equação 2. Em que atan2 é a função arco tangente de dois argumentos, retornando o ângulo no plano ab entre a linha que passa pelas coordenadas (a^* , b^*) e o eixo a^* . O ângulo de tonalidade é expresso em graus, com valores variando entre 0° e 360° .

$$\hat{\text{Angulo de tonalidade}} = \tan^{-1} \frac{b^*}{a^*}$$

A Figura 2 demonstra a representação bidimensional do espaço de cor CIE Lab*, em que o croma é denotado por C^* e o ângulo de tonalidade é representado por h° .

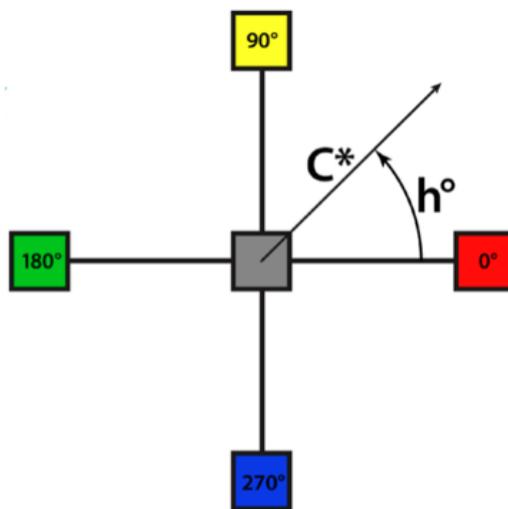


Figura 2 – Plano bidimensional CIE Lab*.
Fonte: Adaptado, X-Rite (2016).

3.6.2 Visão computacional

Segundo Santos (2020), a visão computacional é um ramo da inteligência artificial que se concentra na extração de informações a partir de imagens digitais. A visão computacional tem como objetivo desenvolver algoritmos e técnicas que permitem que os computadores entendam, interpretem e analisem imagens e vídeos de maneira semelhante ao sistema visual humano. (SZELISKI, 2022).

O campo da visão computacional tem sido impulsionado pelo avanço das redes neurais artificiais nos últimos anos (HINTON et al., 2015). Esses modelos computacionais, inspirados no funcionamento do cérebro humano, são capazes de aprender a partir de grandes quantidades de dados e de se adaptar a diferentes contextos e problemas (GOODFELLOW et al., 2016).

Dentre as redes neurais, as redes convolucionais (CNNs) têm se mostrado particularmente eficazes na análise de imagens e na resolução de problemas complexos de visão computacional (KRIZHEVSKY et. al, 2017). As CNNs são capazes de aprender automaticamente recursos hierárquicos a partir de imagens, o

que permite que elas alcancem um alto desempenho em tarefas como classificação de imagens, detecção de objetos e segmentação semântica (SIMONYAN e ZISSERMAN, 2014).

Além das redes neurais, as redes de decisão (ou árvores de decisão) também são uma abordagem popular para lidar com problemas de classificação e regressão em visão computacional e outras áreas da inteligência artificial (QUINLAN, 1986). Redes de decisão são estruturas em forma de árvore que representam conjuntos de regras de decisão, as quais podem ser aplicadas de forma sistemática para solucionar problemas complexos e tomar decisões com base em dados (BREIMAN et al., 1984).

A aplicação do processamento de imagem digital tem apresentado um potencial significativo na área da tecnologia de sementes, fornecendo métodos mais precisos e eficientes para a avaliação da qualidade das sementes, em comparação com as abordagens tradicionais. Através da análise de imagem, é possível obter resultados mais confiáveis, reduzindo a subjetividade e os erros humanos associados à análise visual das sementes (CHAUGULE et al., 2012).

3.6.3 Análise de imagem na qualidade de sementes

O modelo tradicional de análise para determinação de testes que avaliam a qualidade das sementes exige tempo e maior custo para as empresas sementeiras (MARCHI; CICERO, 2016). Atualmente, os sistemas de visão computacional mais recentes têm sido adotados com o objetivo de realizar análises automatizadas para avaliar a qualidade das sementes, proporcionando menor custo e maior praticidade, além de reduzir a subjetividade, aumentando assim, a rapidez e facilidade na classificação dos resultados (POURREZA et al., 2012). Um estudo realizado por Silva et al. (2014) mostrou que a análise de imagem foi eficiente na obtenção de informações precisas e confiáveis sobre a morfologia das sementes de abóbora, além de permitir a avaliação da qualidade fisiológica das sementes com alta precisão.

A análise por imagem vem sendo adotada como uma ferramenta de avaliação dos aspectos quanto a fisiologia das sementes que visa esclarecer e aprimorar as metodologias tradicionais para garantir a rapidez e a confiabilidade dos resultados. Tanto Škrubej et al. (2015) quanto Lee et al. (2017) apresentaram técnicas que combinam processamento de imagem e aprendizado de máquina para avaliar a qualidade das sementes. Enquanto Škrubej et al. (2015) conseguiram estimar a taxa

de germinação de sementes de tomate de forma eficiente, Lee et al. (2017) demonstraram alta precisão na classificação do vigor das sementes de soja. Esses resultados evidenciam a promissora aplicação da visão computacional na análise de sementes, oferecendo uma alternativa mais precisa e automatizada às abordagens tradicionais.

Guedes et al. (2011), utilizaram técnicas de processamento de imagem digital para caracterizar grãos de soja por meio de parâmetros físicos, como tamanho, forma e cor, visando aprimorar a compreensão da qualidade e das características dos grãos. Kaur et al. (2017), mostraram que através da análise de imagens é possível classificar e contar sementes de soja com alta precisão.

Esse tipo de análise consiste na obtenção de informações através da captura de imagens digitais das sementes, de plântulas ou de suas partes constituintes, por meio de câmera fotográfica, filmadora ou “scanner”, com base em algumas características como cor, textura etc. (SILVA et al., 2014). Liu et al. (1999), investigaram a aplicação de técnicas de imagem de cores para identificar e classificar sementes de diferentes espécies. Eles comparam duas abordagens distintas: análise discriminante e redes neurais artificiais. As redes neurais artificiais mostraram um desempenho superior o que sugeriu podem ser uma opção mais promissora para a identificação e classificação de sementes.

Ainda segundo Silva et al., (2014) em seu estudo sobre a análise de imagens no estudo morfológico e fisiológico de sementes de abóbora, afirmam que imagens coletadas a partir do uso do raio-X (um dos equipamentos mais utilizados na avaliação da qualidade de sementes), além de não causar danos às sementes, é possível utilizá-las para a condução de testes fisiológicos para confrontar as observações da morfologia interna com as plântulas (normais ou anormais) ou sementes mortas resultantes dos testes fisiológicos. Além disso, com as imagens de raios X é possível visualizar as estruturas da semente, identificando possíveis alterações, particularmente com referência ao eixo embrionário (BINO et al., 1993 e ISTA, 1995). Esse método além de não ser destrutivo, permite que as sementes submetidas à análise sejam colocadas para germinar proporcionando uma relação entre danos mecânicos ou alterações assistidas na semente e danos à germinação (CICERO et al., 1998).

Outro sistema citado na literatura utilizado é o software chamado de “Vigor-S” usado para avaliação automatizada do vigor de sementes de soja, permitindo a

determinação do índice de vigor e do comprimento de plântulas de soja com grande rapidez e precisão (SILVA; GOMES JÚNIOR, 2014). Marcos Filho et al. (2009) e Medeiros et al. (2019) mostraram a eficiência de sistemas de análise de imagem na avaliação da qualidade de sementes. O Vigor-S apresentou alta correlação com os testes tradicionais de avaliação de vigor para sementes de soja, enquanto o SAPL® demonstrou alta correlação em relação a testes tradicionais para sementes de milho. Esses resultados indicam que os sistemas de análise de imagem são alternativas viáveis para avaliação da qualidade de sementes, oferecendo vantagens como facilidade de execução, rapidez e baixo custo.

Sako et al. (2001) desenvolveram um programa destinado à determinação do vigor de sementes de alface, mediante a análise computadorizada de imagens de plântulas (Seed Vigor Imaging System - SVIS®). Em sintonia com o desafio de desenvolvimento de técnicas digitais para análise de sementes, diferentes softwares de imagem foram desenvolvidos, cita-se o Seed Vigor Imaging System (SVIS®) (SAKO et al., 2001), o Sistema Automatizado do Vigor de Sementes (Vigor-S®) (CASTAN et al., 2018) e o Sistema de Análise de Plântulas (SAPL®) (MEDEIROS et al., 2018). Estes três sistemas têm em comum a avaliação de plântulas para análise de germinação e vigor.

Pinto et al. (2015) demonstraram a eficácia da análise de imagem na avaliação da qualidade de sementes de milho, utilizando o sistema Seed Vigor Imaging System (SVIS®). A pesquisa concluiu que a análise de imagem é uma abordagem eficiente para identificação de diferenças significativas entre lotes de sementes em relação à germinação, vigor e uniformidade. Os resultados obtidos pelo SVIS podem se relacionar com os testes de vigor tradicionais para sementes como o envelhecimento acelerado, tetrazólio e condutividade elétrica (ALVARENGA; MARCOS FILHO; GOMES JUNIOR, 2012).

Thakuer et al. (2022), aplicaram a técnica de aprendizado profundo (deep learning) usando uma arquitetura de rede neural convolucional (CNN) pré-treinada, para criar avaliações não destrutivas da qualidade de sementes. Huang et al. (2020) também exploraram a aplicação de técnicas de aprendizado de máquina (machine learning) na detecção, previsão e avaliação da qualidade da germinação de trigo, milho e arroz. Utilizando algoritmos como redes neurais convolucionais e árvores de decisão, os autores desenvolveram modelos eficazes para prever a germinação das sementes e avaliar sua qualidade.

Outro sistema promissor na análise por imagem é o GroundEye® que possui uma câmera de captação de imagem e um software de análise. A câmera fotográfica utilizada na obtenção da imagem é de alta resolução, o que possibilita capturar imagens com alta qualidade, onde a análise da imagem é feita em tempo real (AVILA, 2017). As informações capturadas pelas imagens do GroundEye® são relacionadas quanto cor, textura e geometria de cada componente individualmente da imagem. (PINTO et al., 2015).

O uso do GroundEye® em comparação aos demais métodos tradicionais de avaliação, pode diminuir os erros das análises feitas pelo analista através da observação visual, contribuindo com maior reproducibilidade dos resultados. Assim, vários estudos evidenciam que o uso de análise de imagem com o GroundEye® traz benefícios para agilidade e confiabilidade dos dados.

3.6.4 GroundEye®

O GroundEye® é uma inovação tecnológica desenvolvida e patenteada pela empresa brasileira *Tbit Tecnologia e Sistemas*, lançado em 2012 com o nome Sistema de Análise de Sementes – SAS® e posteriormente renomeado para GroundEye. O GroundEye® S800D é um dos modelos oferecidos como solução para análise de imagens de sementes, plântulas e folhas. Trata-se de um sistema avançado que combina hardware e software, equipado com duas câmeras fotográficas de alta resolução que capturam imagens da parte superior e inferior de cada objeto analisado. O sistema é capaz de fornecer informações detalhadas sobre a cor, forma, geometria e textura dos objetos analisados.

Andrade et al. (2016) conduziram um estudo com o objetivo de avaliar a eficácia do GroundEye® na detecção de sementes esverdeadas em soja. Os resultados indicaram que o equipamento apresentou uma taxa de acerto de 97% na detecção dessas sementes, o que evidencia a alta precisão do sistema. Esse estudo ilustra a importância da análise de imagem, que permite identificar características invisíveis a olho nu, a fim de aumentar a eficiência do processo de seleção e classificação de lotes.

Ferreira et al. (2020) destacaram que a análise de imagens com o GroundEye® permite uma seleção mais eficiente de sementes crioulas de milho, uma vez que é possível avaliar características que não são detectadas pelos testes tradicionais,

como a cor e a textura da semente. Taniguchi et al. (2022) utilizaram o GroundEye® para a análise de imagens de sementes de *Strelitzia reginae*, permitindo a obtenção de características morfoanatômicas e bioquímicas relevantes para a taxonomia e fisiologia dessa espécie ornamental.

Um estudo conduzido por Da Luz et al. (2021) utilizou a análise de imagens com o sistema GroundEye® para avaliar a qualidade das sementes de maracujá-do-mato. As características das sementes, como tamanho, forma e cor, foram analisadas para avaliar a qualidade do lote. Os resultados indicaram que a análise de imagens foi eficaz na identificação de sementes com qualidade inferior, permitindo a seleção e separação dessas sementes para evitar a contaminação do lote.

Souza et al. (2018) destacaram a eficiência do sistema de análise de imagens computadorizado do GroundEye® na avaliação de características biométricas e morfofisiológicas de sementes de pêssogo, além de fornecer informações precisas sobre o crescimento inicial das plântulas. A correlação positiva encontrada entre o comprimento da radícula, o comprimento da raiz principal e o crescimento inicial das plântulas sugere que essas características podem ser utilizadas como indicadores do potencial fisiológico das sementes.

Sousa et al. (2017) utilizaram o software de análise de imagens GroundEye® para avaliar as dimensões das sementes de camu-camu, incluindo área, comprimento, largura, volume, peso e índice de esfericidade. Os resultados demonstraram diferenças significativas entre as sementes coletadas em diferentes locais, destacando a importância da caracterização morfoestrutural na identificação de genótipos e na qualidade das sementes.

A análise por imagem oferece várias vantagens em relação às análises manuais. Primeiramente, ela é capaz de fornecer resultados mais objetivos e precisos, pois elimina a subjetividade e as variações inerentes às inspeções visuais humanas (PATEL et al., 2012). Além disso, a análise por imagem permite uma maior velocidade de processamento, o que é especialmente útil para a avaliação da qualidade de grandes volumes de produtos. Isso também resulta em maior eficiência e redução dos custos de mão de obra.

Dessa forma, o uso do sistema GroundEye® vem sendo uma prática promissora para avaliação da qualidade de sementes. Entretanto, é recomendado a realização de mais pesquisas voltadas para cada espécie, a fim de comprovar a sua eficiência na avaliação da qualidade física e fisiológica de diferentes cultivos.

4. REFERÊNCIAS BIBLIOGRÁFICAS

- AL-HAMMAD, B. A.; AL-AMMARI, B. S. Seed viability of five wild Saudi Arabian species by germination and X-ray tests. **Saudi Journal of Biological Sciences**, v. 24, n. 6, p. 1424-1429, 2017.
- ANDRADE, D. B. et al. Detection of green seeds in soybean lots by the seed analysis system (SAS). **International Journal of Current Research**, v. 8, n. 2, p. 26462-26465, 2016.
- AVILA, M. A. B. Análise de imagem na avaliação do potencial fisiológico de sementes de soja. Dissertação apresentada à Universidade Federal de Lavras, 2017.
- BALARDIN, Ricardo Silveiro et al. Tratamento de sementes com fungicidas e inseticidas como redutores dos efeitos do estresse hídrico em plantas de soja. **Ciência Rural**, v. 41, p. 1120-1126, 2011.
- BARBEDO, Jayme Garcia Arnal. A review on the main challenges in automatic plant disease identification based on visible range images. **Biosystems engineering**, v. 144, p. 52-60, 2016.
- BAURIEGEL, E. et al. Early detection of Fusarium infection in wheat using hyperspectral imaging. **Computers and electronics in agriculture**, v. 75, n. 2, p. 304-312, 2011.
- BAYS, Rodrigo et al. Soybean seed coating with micronutrients, fungicide and polymer. **Revista Brasileira de Sementes**, v. 29, p. 60-67, 2007.
- BEWLEY, J. Derek et al. **Seeds: physiology of development, germination and dormancy**. Springer Science e Business Media, 2012.
- BINO, R.J.; AARTSE, J.W.; VAN DER BURG, W.J. Non destructive X-ray of *Arabidopsis* embryo mutants. **Seed Science Research**, Wallingford, v.3, p.167-170, 1993.
- BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. Regras para análise de sementes. Brasília-DF: **Departamento Nacional de Produção Vegetal**, 2009. 399 p.
- BREIMAN, L. et al. Classification and regression trees—crc press. **Boca Raton**, 1984.
- BRZEZINSKI, Cristian Rafael et al. Seeds treatment times in the establishment and yield performance of soybean crops. **Journal of Seed Science**, v. 37, p. 147-153, 2015.
- CASTAN, Danielle Otte Carrara; GOMES-JUNIOR, Francisco Guilhien; MARCOS-FILHO, Julio. Vigor-S, a new system for evaluating the physiological potential of maize seeds. **Scientia Agricola**, v. 75, p. 167-172, 2018.

CASTRO, Gustavo Spadotti Amaral et al. Tratamento de sementes de soja com inseticidas e um bioestimulante. **Pesquisa Agropecuária Brasileira**, v. 43, p. 1311-1318, 2008.

CHAUGULE, Archana. Application of image processing in seed technology: A survey. **International Journal of Emerging Technology and Advanced Engineering**, v. 2, n. 4, p. 153-159, 2012.

CICERO, Silvio Moure; SCHOOR, Rob Van Der; JALINK, Henk. Use of chlorophyll fluorescence sorting to improve soybean seed quality. **Revista Brasileira de Sementes**, v. 31, p. 145-151, 2009.

CÍCERO, S.M.; VAN DER HEIJDEN, G.W.A.M.; VAN DER BURG, W.J.; BINO, R.J. Evaluation of mechanical damage in seeds of maize (*Zea mays* L.) by X-ray and digital imaging. **Seed Science and Technology**, Zürich, v.26, n.3, p.603-612, 1998.

CLIFTON, R.A. Talc and pyrophyllite. Washington: **Bureau of Mines**, 5 p, 1985. (Bulletin 675).

CONAB, Companhia Nacional de Abastecimento. **Acompanhamento da safra brasileira de grãos 2021/2022**. v.9, nº7 - Sétimo levantamento, abril/2022.

CONCEIÇÃO, Gersa Massuquini et al. **Desempenho de plântulas e produtividade de soja submetida a diferentes tratamentos químicos nas sementes**. 2014.

COTRIM, Mayara Fávero et al. Studying the link between physiological performance of *Crotalaria ochroleuca* and the distribution of Ca, P, K and S in seeds with X-ray fluorescence. **Plos one**, v. 14, n. 9, p. e0222987, 2019.

DA LUZ, Petterson Baptista et al. Utilização de análise de imagem para avaliação da qualidade de sementes de *Passiflora cincinnata* (maracujá-do-mato). **Multitemas**, p. 123-139, 2021.

DAUB, M. E. et al. Photoactivated perylenequinone toxins in fungal pathogenesis of plants. **FEMS Microbiology Letters**, v. 252, n. 2, p. 197-206, 2005.

DAUB, Margaret E.; CHUNG, Kuang-Ren. Cercosporin: a photoactivated toxin in plant disease. **APSnet Feature**, p. 1-12, 2007.

DE ARRUDA, M. H. M. et al. Physiological quality of soybean seed lots with different percentages of green seeds. **Magistra**, v. 28, n. 2, p. 194-200, 2016.

DE MEDEIROS CÂMARA, Francisco Mickael et al. Emergência de sementes de soja com diferentes porcentagens de infestação de mancha púrpura. **Agropecuária Científica no Semiárido**, v. 15, n. 1, p. 18-22, 2019.

FAIRCHILD, Mark D. **Color appearance models**. John Wiley e Sons, 2013.

FRANÇA NETO, José de Barros et al. Semente esverdeada de soja e sua qualidade fisiológica. 2005.

FRANÇA-NETO, J. de B. et al. Tecnologia da produção de semente de soja de alta qualidade. 2016.

GALLI, Juliana Altafin et al. Efeito de *Colletotrichum dematium* var. *truncata* e *Cercospora kikuchii* na germinação de sementes de soja. **Revista Brasileira de Sementes**, v. 27, p. 182-187, 2005.

GARDNER, Max W. Indiana plant diseases, 1924. In: **Proceedings of the Indiana Academy of Science**. 1925. p. 237-258.

GONZALEZ, Rafael C.; WOODS, Richard E. Digital image processing, prentice hall. **Upper Saddle River, NJ**, 2008.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. Regularization for deep learning. **Deep learning**, p. 216-261, 2016.

GUEDES, Manoel Adalberto et al. Caracterização física de grãos de soja utilizando-se processamento digital de imagens. **Revista Brasileira de Produtos Agroindustriais**, v. 13, n. 3, p. 279-294, 2011.

HARTMAN, G. L. et al. Compendium of soybean diseases and pests 5th ed. **St. Paul, MN. The American Phytopathological Society. pp3**, 2015.

HARTMAN, G. L.; SINCLAIR, J. B.; RUPE, J. C. Compendium of soybean diseases. **Soybean Disease Compendium; Agricultural Research Service: Washington, DC, USA**, p. 37-39, 1999.

HARTMAN, Glen L.; WEST, Ellen D.; HERMAN, Theresa K. Crops that feed the World 2. Soybean—worldwide production, use, and constraints caused by pathogens and pests. **Food Security**, v. 3, p. 5-17, 2011.

HENNING, A. et al. Ocorrência de mancha púrpura (*Cercospora kikuchii*) em sementes de soja no Brasil e seu efeito na qualidade fisiológica: mito ou verdade? In: REUNIÃO DE PESQUISA DA SOJA, 37., 2019, Londrina. Resumos expandidos... Londrina: **Embrapa**, 2019. p. 227-229.

HENNING, Ademir Assis. **Patologia e tratamento de sementes: noções gerais**. 2005.

HINTON, Geoffrey; LECUN, Yann; BENGIO, Yoshua. Deep learning. **Nature**, v. 521, n. 7553, p. 436-444, 2015.

HOU, Xiandeng; HE, Yihua; JONES, Bradley T. Recent advances in portable X-ray fluorescence spectrometry. **Applied Spectroscopy Reviews**, v. 39, n. 1, p. 1-25, 2004.

HUANG, Sheng et al. Research on classification method of maize seed defect based on machine vision. **Journal of Sensors**, v. 2019, p. 1-9, 2019.

KAUR, Jasdeep; CHOPRA, Anshu. 'Digital image analysis based on automated counting clustered soybean seeds. **International Journal of Computers e Technology**, v. 12, n. 3, p. 3, 2014.

KRIZHEVSKY, Alex; SUTSKEVER, Ilya; HINTON, Geoffrey E. Imagenet classification with deep convolutional neural networks. **Communications of the ACM**, v. 60, n. 6, p. 84-90, 2017

KUDO, Ângela Sathiko; BLUM, Luiz Eduardo Bassay; LIMA, Marcello Arrais. Aerobiologia de Cercospora kikuchii. **Ciência Rural**, v. 41, p. 1682-1688, 2011.

LEE, Hoonsoo et al. Machine vision technique for rapid measurement of soybean seed vigor. **Journal of Biosystems Engineering**, v. 42, n. 3, p. 227-233, 2017.

LEE, Jin Hwan et al. Changes occurring in compositions and antioxidant properties of healthy soybean seeds [*Glycine max* (L.) Merr.] and soybean seeds diseased by *Phomopsis longicolla* and *Cercospora kikuchii* fungal pathogens. **Food chemistry**, v. 185, p. 205-211, 2015.

LEHMAN, Samuel George et al. Purple stain of soybean seeds. **Purple stain of soybean seeds.**, n. 369, 1950.

LEVIEN, A.; PESKE, S. T.; BAUDET, L. Film coating no recobrimento das sementes. **Seed News**, v. 12, p. 1-5, 2008.

LI, Shuxian et al. Research on purple seed stain of soybean: germplasm screening and genetic resistance. Germplasm Characteristics, Diversity and Preservation. **Nova Science Publisher**, p. 65-77, 2016.

LUDWIG, Marcos Paulo et al. Qualidade de sementes de soja armazenadas após recobrimento com aminoácido, polímero, fungicida e inseticida. **Revista Brasileira de Sementes**, v. 33, p. 395-406, 2011.

LUO, M. Ronnier; CUI, Guihua; RIGG, Bryan. The development of the CIE 2000 colour-difference formula: CIEDE2000. **Color Research e Application: Endorsed by Inter-Society Color Council, The Colour Group (Great Britain), Canadian Society for Color, Color Science Association of Japan, Dutch Society for the Study of Color, The Swedish Colour Centre Foundation, Colour Society of Australia, Centre Français de la Couleur**, v. 26, n. 5, p. 340-350, 2001.

MARCOS FILHO, Julio. Seed vigor testing: an overview of the past, present and future perspective. **Scientia agricola**, v. 72, p. 363-374, 2015.

MARCOS FILHO, Julio; KIKUTI, Ana Lúcia Pereira; LIMA, Liana Baptista de. Procedures for evaluation of soybean seed vigor, including an automated computer imaging system. **Revista Brasileira de Sementes**, v. 31, p. 102-112, 2009.

MARGUÍ, E.; ZAWISZA, B.; SITKO, R. Trace and ultratrace analysis of liquid samples by X-ray fluorescence spectrometry. **TrAC Trends in Analytical Chemistry**, v. 53, p. 73-83, 2014.

MARQUES FERREIRA, Olavo José et al. TECNOLOGIA DE ANÁLISE DE IMAGENS PARA A SELEÇÃO DE SEMENTES CRIOULAS DE MILHO. **Global Science e Technology**, v. 13, n. 2, 2020.

MATSUMOTO, Takashi; TOMOYASU, Ryoichi. Studies on purple speck of soybean seed. **Japanese Journal of Phytopathology**, v. 1, n. 6, p. 1-14_1, 1925.

MCDONALD, Miller B. Seed quality assessment. **Seed Science Research**, v. 8, n. 2, p. 265-276, 1998.

MCLAREN, K. XIII—The development of the CIE 1976 (L* a* b*) uniform colour space and colour-difference formula. **Journal of the Society of Dyers and Colourists**, v. 92, n. 9, p. 338-341, 1976.

MEDEIROS, André Dantas de; PEREIRA, Márcio Dias. SAPL®: a free software for determining the physiological potential in soybean seeds. **Pesquisa Agropecuária Tropical**, v. 48, p. 222-228, 2018.

MENESES, P. R.; ALMEIDA, T. D. **Introdução ao Processamento de Imagens de Sensoriamento Remoto**. Universidade de Brasília-DF, Brasília-DF, 2012, 266 p.

MERTZ, Liliane Marcia; HENNING, Fernando Augusto; ZIMMER, Paulo Dejalma. Bioprotectors and chemical fungicides in the treatment of soybean seeds. **Ciência Rural**, v. 39, p. 13-18, 2009.

MISS.SNEHAL, M.; CHOUGULE, D. M. S. R. Skin detection for face recognition based on HSV color space. **International Journal of Engineering Sciences e Research Technology**, 2(7):1883, 2013.

MORAIS, Thaís Rezende et al. **Vigor e germinação de sementes de soja com mancha-púrpura**. 2022.

MOUAZEN, Abdul Mounem; DE BAERDEMAEKER, Josse; RAMON, Herman. Towards development of on-line soil moisture content sensor using a fibre-type NIR spectrophotometer. **Soil and Tillage Research**, v. 80, n. 1-2, p. 171-183, 2005.

MURAKISHI, Harry H. et al. Purple seed stain of Soybean. **Phytopathology**, v. 41, n. 4, 1951.

OLIVEIRA, JOÃO ALMIR et al. Transmissibilidade e danos causados por *Cercospora kikuchii* em sementes de soja. **Revista Brasileira de Sementes**, v. 15, n. 1, p. 97-100, 1993.

PÁDUA, Gilda Pizzolante de et al. Tolerance level of green seed in soybean seed lots after storage. **Revista Brasileira de Sementes**, v. 29, p. 128-138, 2007.

PATEL, Krishna Kumar et al. Machine vision system: a tool for quality inspection of food and agricultural products. **Journal of food science and technology**, v. 49, p. 123-141, 2012.

PATHAN, M. A. et al. Effects of *Cercospora kikuchii* on soybean seed germination and quality. **Plant disease**, v. 73, n. 9, p. 720-723, 1989.

PEREIRA, Carlos Eduardo et al. Fungicide treatment and film coating of soybean seeds submitted to storage. **Ciência e Agrotecnologia**, v. 35, p. 158-164, 2011.
Phomopsis longicolla in soybean seed coats and cotyledons. **Plant Disease**, v. 76, n. 8, p. 779-782, 1992.

PINTO, Crislaine Aparecida Gomes et al. Image analysis in the evaluation of the physiological potential of maize seeds. **Revista Ciência Agronômica**, v. 46, p. 319-328, 2015.

POURREZA, Alireza et al. Identification of nine Iranian wheat seed varieties by textural analysis with image processing. **Computers and electronics in agriculture**, v. 83, p. 102-108, 2012.

PUPIM, T. L. et al. Ocorrência de sementes verdes e qualidade fisiológica de sementes de soja. 2005.

QIU LIJUAN, Qiu LiJuan; CHANG RUZHEN, Chang RuZhen. The origin and history of soybean. In: **The soybean: botany, production and uses**. Wallingford UK: CABI, 2010. p. 1-23.

QUINLAN, J.. Ross . Induction of decision trees. **Machine learning**, v. 1, p. 81-106, 1986.

RAJJOU, Loïc et al. Seed germination and vigor. **Annual review of plant biology**, v. 63, p. 507-533, 2012.

RANGEL, Marco Antônio Sedrez et al. Presença e qualidade de sementes esverdeadas de soja na região sul do estado do Mato Grosso do Sul. **Acta Scientiarum. Agronomy**, v. 33, p. 127-132, 2011.

REINHARD, Erik et al. **High dynamic range imaging: acquisition, display, and image-based lighting**. Morgan Kaufmann, 2010.

REIS, Leandro Vilela et al. Treatment technologies for soybean seeds: Dose effectiveness, mechanical damage and seed coating. **Ciência e Agrotecnologia**, v. 47, p. e013622, 2023.

ROBERTSON, Alan R. The CIE 1976 color-difference formulae. **Color Research e Application**, v. 2, n. 1, p. 7-11, 1977.

ROHR, Livia Araújo. **Tratamento de sementes de soja com zinco: absorção e distribuição do zinco na germinação e desenvolvimento de plântulas, e sua relação com o desempenho das plantas.** 2021. Tese de Doutorado. Universidade de São Paulo.

SAKO, Y.; MCDONALD, M. B.; FUJIMURA, K. A System for Automated Seed Vigor Assessment. **Seed Science and Technology**, v. 29, n. 3, p. 625–636, 2001.

SANTOS, Thiago Teixeira et al. **Visão computacional aplicada na agricultura.** 2020.

SCHUH, W. Cercospora blight, leaf spot, and purple seed stain. **Compendium of soybean diseases**, 1999.

SHARMA, Gaurav; BALA, Raja (Ed.). **Digital color imaging handbook.** CRC press, 2017.

SILVA, Patricia P. et al. Análise de imagens no estudo morfológico e fisiológico de sementes de abóbora. **Horticultura Brasileira**, v. 32, p. 210-214, 2014.

SILVA, P. P.; FREITAS RA; CÍCERO S. M.; MARCOS FILHO J; NASCIMENTO W. M. Análise de imagens no estudo morfológico e fisiológico de sementes de abóbora. **Horticultura Brasileira** 32: 210-21, 2014.

SIMONYAN, Karen; ZISSERMAN, Andrew. Very deep convolutional networks for large-scale image recognition. **arXiv preprint arXiv:1409.1556**, 2014.

SINCLAIR, J. B.; BACKMAN, P. A. **Compendium of Soybean Diseases.**: 1–106. 1989.

SINGH, Guriqbal; SHIVAKUMAR, B. G. The role of soybean in agriculture. The soybean: Botany, production and uses. **CAB International**, Oxfordshire, UK, p. 24-47, 2010.

ŠKRUBEJ, U. et al. Assessment of germination rate of the tomato seeds using image processing and machine learning. **European Journal of Horticultural Science**, v. 80, n. 2, p. 68-75, 2015.

SMITH, Alvy Ray. Color gamut transform pairs. **ACM Siggraph Computer Graphics**, v. 12, n. 3, p. 12-19, 1978.

SONKA, Milan; HLAVAC, Vaclav; BOYLE, Roger. **Image processing, analysis, and machine vision.** Cengage Learning, 2014.

SOUSA, R. et al. Description and automated seed morphostructural characterization of *Myrciaria dubia* (Kunth) **McVaugh: Diagnostic Imaging.** 2017.

SZELISKI, Richard. **Computer vision: algorithms and applications.** Springer Nature, 2022.

- TAIZ, Lincoln et al. **Fisiologia e desenvolvimento vegetal**. Artmed Editora, 2017.
- TANIGUCHI, Marisa et al. Caracterização de sementes e embriões de *Strelitzia reginae*. **Ornamental Horticulture**, v. 28, n. 3, p. 314-322, 2022.
- TEIXEIRA, Sheila Bigolin et al. Green soybean seeds: effect on physiological quality. **Ciência Rural**, v. 50, 2020.
- THAKUR, Puneet Singh et al. Deep transfer learning based photonics sensor for assessment of seed-quality. **Computers and Electronics in Agriculture**, v. 196, p. 106891, 2022.
- VELICHETI, R. K. et al. Selective degradation of proteins by *Cercospora kikuchii* and
- WRATHER, J. Allen; KOENNING, Steve R. Estimates of disease effects on soybean yields in the United States 2003 to 2005. **Journal of nematology**, v. 38, n. 2, p. 173, 2006.
- X-RITE. Lab color space. Disponível em: <https://www.xrite.com/pt-pt/blog/lab-color-space>. Acesso em: 20 maio 2023.
- ZAMAN, Q.U.Z. et al. Zinc biofortification in rice: leveraging agriculture to moderate hidden hunger in developing countries. Arch. Agron. **Soil Sci**, v.64, p.147-161, 2018.
- ZORATO, Maria de Fátima et al. Presença de sementes esverdeadas em soja e seus efeitos sobre seu potencial fisiológico. **Revista Brasileira de Sementes**, v. 29, p. 11-19, 2007.

CAPÍTULO I

INTELIGÊNCIA ARTIFICIAL APLICADA À CLASSIFICAÇÃO DE SEMENTES ESVERDEADAS E PREDIÇÃO DE QUALIDADE FISIOLÓGICA EM SOJA

Artigo aceito para publicação na Revista ***Ciência e Agrotecnologia*** em 03/05/2024.

RESUMO

A presença de sementes esverdeadas representa um obstáculo ao potencial produtivo da cultura da soja, gerando impactos significativos no aspecto visual e na qualidade fisiológica. Tradicionalmente, as sementes são avaliadas visualmente, um método sujeito à subjetividade e erros humanos. Frente a isto, esta pesquisa propõe uma abordagem inovadora que integra análise de imagens e inteligência artificial para desenvolver um modelo de aprendizado de máquina capaz de distinguir sementes esverdeadas de amarelas com base em parâmetros de cor. Este estudo visa aprimorar a precisão na avaliação das sementes e expandir o entendimento sobre a relação entre a tonalidade da cor das sementes e sua qualidade fisiológica. A inteligência artificial foi treinada com 12.000 imagens capturadas e processadas pelo GroundEye® S800D. A metodologia empregada para treinar o sistema envolveu a utilização de uma árvore de decisão, utilizando a biblioteca *sklearn.tree* do Python. Cada semente, após a captura de imagem, foi submetida a um teste de germinação padrão. As plântulas normais foram então reanalisadas no GroundEye® S800D para determinar seu vigor através da mensuração do tamanho de raiz primária e hipocótilo. Na avaliação visual de sementes esverdeadas a concordância entre todos os avaliadores e o padrão foi de apenas 77,5%. Sementes de soja amarelas demonstram qualidade fisiológica superior às esverdeadas, destacando-se em germinação e crescimento da plântula. O ângulo de tonalidade (h) e a luminosidade (L) mostraram-se os critérios mais responsivos ao modelo de aprendizado de máquina, alcançando uma acurácia de 89,7%. O ângulo de tonalidade demonstrou ser um preditor robusto, correlacionando-se com altas taxas de germinação em sementes com ângulo inferior a 97,5°. A relação entre a viabilidade das sementes e o ângulo de tonalidade foi apoiada por um coeficiente de determinação (R^2) de 73%.

Palavras-chaves: semente esverdeada; inteligência artificial; aprendizado de máquina; GroundEye®.

ABSTRACT

The presence of greenish seeds represents a hurdle to the productive potential of the soybean crop, generating significant impacts on the visual appearance and physiological quality. Traditionally, seeds are visually evaluated, a method prone to subjectivity and human errors. Against this backdrop, this research proposes an innovative approach that integrates image analysis and artificial intelligence to develop a machine learning model capable of distinguishing greenish seeds from yellow ones based on color parameters. This study aims to enhance the accuracy in seed evaluation and expand understanding of the relationship between the seed color tone and its physiological quality. The artificial intelligence was trained with 12,000 images captured and processed by GroundEye® S800D. The methodology employed to train the system involved the use of a decision tree, utilizing the Python *sklearn.tree* library. Each seed, after image capture, underwent a standard germination test. Normal seedlings were then reanalyzed in the GroundEye® S800D to determine their vigor by measuring the size of the primary root and hypocotyl. In the visual evaluation of greenish seeds, the agreement between all evaluators and the standard was only 77.5%. Yellow soybean seeds demonstrate superior physiological quality compared to greenish ones, excelling in germination and seedling growth. The hue angle (h) and luminosity (L) proved to be the most responsive criteria in the machine learning model, achieving an accuracy of 89.7%. The hue angle proved to be a robust predictor, correlating with high germination rates in seeds with an angle below 97.5°. The relationship between seed viability and hue angle was supported by a determination coefficient (R^2) of 73%.

Keywords: greenish seed; artificial intelligence; machine learning; GroundEye®.

1. INTRODUÇÃO

A soja (*Glycine max* (L.) Merrill) desempenha um papel crucial na economia global, sendo um dos principais produtos do agronegócio mundial. Ela é uma das maiores fontes de proteína vegetal e óleo comestível, vital para as cadeias alimentares em todo o mundo (SINGH e SHIVAKUMAR, 2010). Além disso, a Organização das Nações Unidas para a Alimentação e a Agricultura – FAO (2021) destaca a soja como um componente essencial na transição para biocombustíveis, tornando-a um elemento chave tanto nas discussões sobre segurança alimentar quanto na sustentabilidade energética.

É um consenso técnico que sementes de alta qualidade apresentam maior vigor, maior resistência a doenças, melhor estabelecimento em campo e maior produtividade. Por outro lado, sementes esverdeadas representam um desafio à máxima performance almejada na produção de soja. Essas sementes são caracterizadas por altos teores de clorofila em seu interior, resultado da imaturidade fisiológica ou de condições adversas de cultivo. A presença de tonalidade verde nos cotilédones indica que o processo de maturação foi interrompido prematuramente, resultando em decréscimo na qualidade e produtividade das sementes (ZORATO et al., 2007; ARRUDA et al., 2016; TEIXEIRA et al., 2020) e, com consequente impacto na lucratividade das lavouras. Portanto, é essencial implementar técnicas de controle de qualidade capazes de identificar e avaliar o impacto de sementes esverdeadas na cultura da soja, garantindo assim a comercialização de produtos com alto potencial de desempenho agrônômico.

Embora avanços significativos tenham sido alcançados na avaliação da qualidade de sementes, com a padronização de metodologias para a análise de parâmetros físicos, fisiológicos, sanitários e genéticos, a maioria das avaliações laboratoriais ainda é realizada de forma subjetiva. Esse caráter subjetivo deve-se, em grande parte, à dependência da experiência de técnicos responsáveis pelas inspeções visuais das sementes. Em resposta a este desafio, técnicas avançadas têm sido desenvolvidas, proporcionando uma avaliação mais precisa e objetiva da qualidade das sementes (PATEL et al., 2012; XIA et al., 2019), impulsionadas pela revolução da inteligência artificial (IA) aplicada à agricultura.

Sem dúvidas, a IA está redefinindo fronteiras em diversos campos de atuação, destacando-se por sua capacidade de processar e analisar dados com eficiência, especialmente por meio de técnicas de visão computacional e aprendizado de máquina (RUSSELL e NORVIG, 2010). Segundo Bishop (2006), enquanto a visão computacional facilita a captura e o processamento de imagens, o aprendizado de máquina se dedica ao desenvolvimento de algoritmos e modelos que aprendem padrões e realizam previsões baseadas em dados. A aplicação conjunta dessas duas técnicas é capaz de identificar, categorizar e até prever a qualidade das sementes de diferentes cultivos, como vários estudos demonstraram, especialmente na última década (ŠKRUBEJ et al., 2015; MOMIN et al., 2017; MAHAJAN et al., 2018; MEDEIROS et al., 2020; BARROS et al., 2021; THAKUER et al., 2022).

A análise de imagem, ao avaliar diversas características das sementes, como tamanho, forma, cor e textura, é capaz de detectar defeitos e irregularidades frequentemente ignorados pelos métodos de avaliação visual convencionais (BAURIEGEL et al., 2011). Além disso, essa abordagem pode oferecer uma vantagem significativa em termos de eficiência operacional e custo, devido ao seu processamento mais rápido em comparação com métodos manuais.

Neste estudo, o principal objetivo foi criar um modelo de classificação para distinguir sementes de soja esverdeadas das amarelas por meio de análise de imagem, utilizando técnica de aprendizado de máquina e parâmetros colorimétricos. Através deste trabalho, buscou-se não apenas melhorar a precisão na avaliação das sementes, mas também expandir o conhecimento sobre como a tonalidade da cor das sementes pode afetar a sua qualidade fisiológica.

2. MATERIAL E MÉTODOS

Os experimentos foram conduzidos no Laboratório de Análise de Sementes da Corteva Agriscience do Brasil Ltda, empresa multinacional agrícola localizada em Brasília-DF, Distrito Federal.

As sementes foram produzidas e beneficiadas no município de Lagoa da Confusão no estado do Tocantins, durante a safra 2021/2021. A colheita dos campos de produção foi realizada durante o mês de outubro do ano de 2021, de maneira mecanizada e com acompanhamento técnico-agronômico. Embora o cultivo tenha acontecido durante o vazio sanitário, a região possuía autorização legal para produção de sementes neste período. O vazio sanitário é uma pausa estratégica durante a entressafra, no qual não são permitidas plantas vivas de soja nos campos agrícolas do Brasil, como medida preventiva contra a ferrugem-asiática, uma doença causada pelo fungo *Phakopsora pachyrhizi* (GODOY et al., 2017).

Um dos principais desafios enfrentados pelos produtores de sementes de soja na região do Tocantins é a alta prevalência de sementes esverdeadas, fenômeno amplamente documentado na literatura (PADUA et al., 2007; ARRUDA et al., 2016; FERRARI et al., 2023). Este problema é frequentemente atribuído a condições de estresse ambiental, como déficit hídrico ou elevadas temperaturas (FRANÇA-NETO et al., 2016), características típicas desta região. Assim, a expectativa de alta incidência de sementes esverdeadas foi o fator determinante para a escolha de lotes produzidos desta procedência. Adicionalmente, o fato de as sementes terem sofrido um estresse ambiental natural, tornou-as objeto ideal para a finalidade do estudo.

Foram selecionados dez lotes de sementes, cada um pesando 1 quilo, pertencentes a duas cultivares distintas, codificadas como A e B. Para cada cultivar, os dez lotes foram combinados em uma única amostra composta, resultando em um total de 10 quilos por cultivar. Essa quantidade foi adequada para garantir uma fonte suficiente para a seleção manual e individual das sementes analisadas neste estudo, permitindo a comparação entre sementes esverdeadas e sementes amarelas.

As amostras foram armazenadas em condições ambientais controladas durante o período de teste, onde a temperatura foi mantida abaixo de 13°C e a umidade relativa do ar não excedeu 60%. A segregação, identificação e armazenamento ocorreu de maneira a garantir a correta rastreabilidade das amostras.

2.1 Avaliação visual das sementes

A classificação visual das sementes foi testada em dois estudos com o objetivo de analisar o sistema de medição e a concordância entre os avaliadores e um padrão definido. A categorização das sementes esverdeadas baseou-se na premissa de que qualquer traço de coloração verde nos cotilédones caracteriza um grão esverdeado. Os experimentos foram randomizados entre as rodadas, de modo que os avaliadores não pudessem identificar seus resultados anteriores. Foi utilizada lupa circular de seis aumentos para favorecer o ambiente de análise.

No primeiro experimento, um analista experiente, denominado avaliador controle, selecionou 30 amostras de 200 sementes com índices de grãos esverdeados variando entre zero e trinta por cento. Cada amostra foi inspecionada por oito avaliadores distintos, incluindo o avaliador controle em duas rodadas de avaliação (duas repetições).

No segundo experimento, o mesmo especialista experiente, selecionou aleatoriamente 40 sementes, dividindo-as em dois grupos: 20 sementes esverdeadas e 20 amarelas ou "maduras". Cada semente foi avaliada por nove avaliadores em duas rodadas de avaliação (duas repetições). Cada avaliador classificou individualmente a semente registrando se considera ou não aquele objeto uma semente esverdeada.

As análises estatísticas dos dois experimentos foram realizadas por meio do *Minitab® 21 Statistical Software* (MINITAB, 2021). Para o tratamento estatístico do primeiro ensaio optou-se pela adoção do teste de médias de *Dunnett*. Os resultados do segundo ensaio foram submetidos à análise de concordância por atributo para verificar o grau de concordância e consistência entre os avaliadores.

2.2 Análise de imagem através do GroundEye®

O GroundEye® é uma inovação tecnológica desenvolvida e patenteada pela empresa brasileira *Tbit Tecnologia e Sistemas*, lançado em 2012 com o nome Sistema de Análise de Sementes – SAS® e posteriormente renomeado para GroundEye. O GroundEye® S800D (Figura 1) é um dos modelos oferecidos como solução para análise de imagens de sementes, plântulas e folhas. Trata-se de um sistema avançado

que combina hardware e software, equipado com duas câmeras fotográficas de alta resolução que capturam imagens da parte superior e inferior de cada objeto analisado. O sistema é capaz de fornecer informações detalhadas sobre a cor, forma, geometria e textura dos objetos analisados.



Figura 1 – GroundEye® S800D.
Fonte: Tbit, 2023.

Um analista experiente selecionou 3.000 sementes de cada cultivar (A e B) por meio de inspeção visual, totalizando 6.000 unidades. Em cada cultivar, um grupo distinto de 1.500 "sementes amarelas" e outras 1.500 "sementes esverdeadas" foi separado. Assim, cada grupo experimental contou com um conjunto de 3.000 sementes. Considerou-se como semente amarela aquela que não apresentava vestígios de pigmentação de clorofila, enquanto as sementes esverdeadas foram identificadas quando essa evidência foi percebida, mesmo que parcialmente. A cada semente foi atribuído um identificador numérico único.

Após a seleção manual, cada semente foi posicionada individualmente em uma bandeja de acrílico transparente dentro do equipamento GroundEye® S800D para a obtenção de sua imagem. Essas imagens foram adquiridas utilizando a configuração de câmera padronizada pelo fabricante para garantir a consistência na iluminação e no posicionamento. A Figura 2 mostra uma representação das sementes amarelas e

esverdeadas capturadas e processadas pelo dispositivo. O fundo da imagem é azul para contrastar as cores das sementes. Os arquivos das imagens estão originalmente no formato PNG, com um tamanho médio de 17KB.

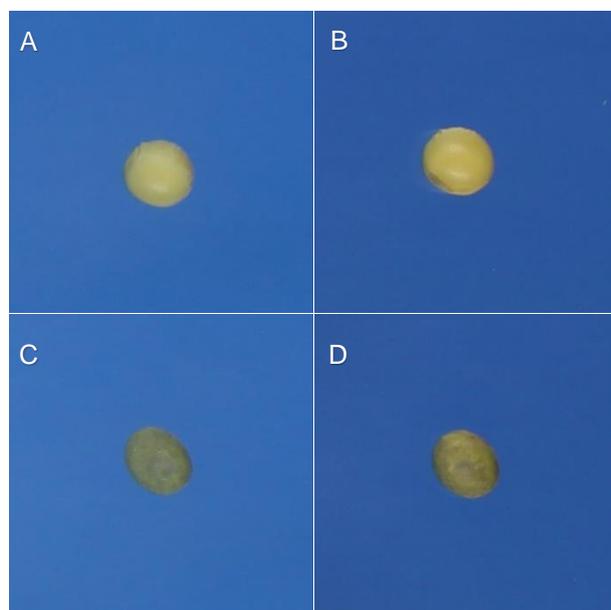


Figura 2 – Imagens de sementes de soja capturadas pelo GroundEye® S800D. (A) e (B) ilustram sementes amarelas; (C) e (D) apresentam sementes esverdeadas. Brasília-DF, 2023.

A decisão de analisar cada semente individualmente foi tomada com o objetivo de construir um conjunto de dados robusto para o modelo de aprendizado de máquina, além de possibilitar uma correlação direta com a qualidade fisiológica. Logo, foram processadas um total de 3.000 análises para o conjunto "sementes esverdeadas", seguindo um procedimento idêntico para o conjunto "sementes amarelas". Como cada semente capturada gerou duas imagens, uma superior e outra inferior, obteve-se um total de 12.000 dados para o treinamento e validação do algoritmo de classificação. A consideração de cada lado da semente como um dado individual de avaliação foi fundamentada na prática analítica comum para esse tipo de dano, na qual, independentemente da sua posição na semente, a presença de tons esverdeados é computada na avaliação.

Embora o GroundEye® seja capaz de avaliar uma ampla gama de parâmetros colorimétricos, a presente investigação concentrou-se especificamente nos espaços de cor CIE Lab* e LCh*. O espaço de cor CIE Lab* é projetado para oferecer uma representação objetiva das cores baseada na percepção humana, dividido em três

dimensões: L^* (luminosidade), a^* (variação entre verde e vermelho) e b^* (variação entre azul e amarelo). Por outro lado, o espaço de cor LCh^* é derivado do CIE Lab^* através de uma transformação polar, mantendo L^* para luminosidade, enquanto C^* denota o croma e h^* indica o ângulo de tonalidade. Os valores de L^* , a^* e b^* foram diretamente obtidos pelo software do GroundEye[®], enquanto os valores de C^* e h^* foram calculados a partir dos dados disponíveis. As fórmulas para o cálculo do croma (C^*) e do ângulo de tonalidade (h^*) seguem as definições estabelecidas por Robertson (1977), descritas a seguir.

O croma (C^*) representa a intensidade ou pureza da cor e é calculado como a distância radial no plano ab (1).

$$Croma = \sqrt{a^2 + b^2} \quad (1)$$

O ângulo de tonalidade (h^*) corresponde ao ângulo no plano ab que descreve a cor em termos de matiz. Para calcular o ângulo de tonalidade, emprega-se a Equação 2. Em que atan2 é a função arco tangente de dois argumentos, retornando o ângulo no plano ab entre a linha que passa pelas coordenadas (a^* , b^*) e o eixo a^* . O ângulo de tonalidade é expresso em graus, com valores variando entre 0° e 360° (2).

$$\hat{\text{Ângulo de tonalidade}} = \tan^{-1} \frac{b^*}{a^*} \quad (2)$$

A Figura 2 ilustra essas representações e facilita a compreensão da relação entre os componentes de cada espaço, oferecendo uma visão da distribuição de cores no espectro humano perceptível.

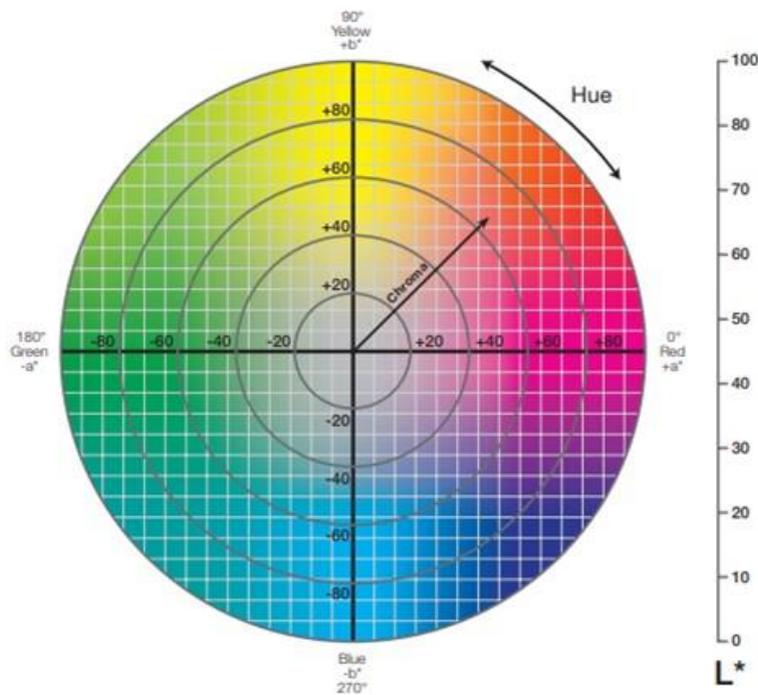


Figura 3 – Espaço de cor teórico CIE Lab* (Hunter, 1958).

2.3 Modelo de validação

Um conjunto de dados contendo 12.000 imagens de sementes de soja foi compilado, com as imagens igualmente divididas em duas categorias: “semente esverdeada” e “semente amarela”. Utilizando o software GroundEye®, extraiu-se de cada imagem as informações cromáticas referentes à luminosidade (L^*), à variação entre verde e vermelho (a^*) e à variação entre azul e amarelo (b^*). Adicionalmente, os valores de croma (C^*) e ângulo de tonalidade (h^*), calculados matematicamente, foram incorporados como variáveis analíticas.

Adotou-se a árvore de decisão para classificação das sementes. Este tipo de modelo preditivo segmenta o conjunto de dados em subconjuntos cada vez menores, enquanto constrói um modelo decisório em cada nó. Este método foi escolhido por sua capacidade de formular perguntas binárias claras—cruciais para distinguir entre as categorias "semente esverdeada" e "semente amarela" baseadas em características visuais capturadas nas imagens.

A implementação foi realizada utilizando a biblioteca *sklearn.tree* do Python, fornecida pela Python Software Foundation (2021). O modelo *DecisionTreeClassifier* foi empregado para desenvolver uma árvore de decisão que aprende com as características cromáticas extraídas das imagens (L^* , a^* , b^* , C^* e h^*). Essa árvore foi treinada para diferenciar sementes esverdeadas e amarelas, utilizando esses atributos para realizar classificações precisas baseadas nas distinções visuais entre as duas categorias de sementes. Este processo envolveu treinar o modelo no conjunto de dados, dividido em 66% (7.919 imagens) para treinamento e 34% (3.041 imagens) para testes, permitindo que o modelo aprendesse e depois validasse sua capacidade de generalização em dados não vistos.

Para avaliar a eficácia do modelo, utilizou-se uma matriz de confusão, que ajudou a visualizar e quantificar os verdadeiros positivos (VP), verdadeiros negativos (VN), falsos positivos (FP) e falsos negativos (FN). Estas taxas foram utilizadas para calcular os indicadores de desempenho do modelo obtido pela árvore de decisão, sendo eles: acurácia, precisão, sensibilidade e especificidade. A acurácia (3) refere-se à proporção de predições feitas pelo modelo que se mostraram corretas. Precisão (4) indica a proporção de identificações positivas feitas pelo modelo que foram, de fato, corretas. Sensibilidade (5) representa a proporção de positivos reais que o modelo identificou corretamente. Especificidade (6) corresponde à proporção de negativos reais que o modelo identificou corretamente.

$$Acurácia = \frac{VP+VN}{VP+VN+FP+FN} \times 100 \quad (3)$$

$$Precisão = \frac{VP}{(VP+FP)} \times 100 \quad (4)$$

$$Sensibilidade = \frac{VP}{VP+FN} \times 100 \quad (5)$$

$$Especificidade = \frac{VN}{VN+FP} \times 100 \quad (6)$$

Adicionalmente, o índice de Gini foi utilizado como critério de seleção de características na construção da árvore de decisão, fornecendo uma medida de impureza que otimizou o particionamento das categorias entre os nós. Esse índice ajuda a determinar como cada característica contribui para a homogeneidade dos nós e das folhas da árvore, com o objetivo de minimizar a probabilidade de erros de classificação. A utilização do índice de Gini neste contexto aumenta a capacidade da árvore para distinguir claramente entre as diferentes categorias com base nas características mais relevantes extraídas das imagens das sementes.

2.4 Caracterização e avaliação da qualidade das sementes

2.4.1 Teor de água

O teor de água dos lotes foi determinado segundo o método de estufa a $105 \pm 3^\circ\text{C}$ por 24h, conforme as Regras para Análise de Sementes (BRASIL, 2009). Foram utilizadas duas amostras de 10 gramas, e os resultados foram expressos em porcentagem.

2.4.2 Massa de mil sementes

A massa de mil sementes foi calculada com base em 8 subamostras de 100 sementes de cada lote, conforme o método preconizado nas Regras para Análise de Sementes (BRASIL, 2009). Após os cálculos específicos, os valores obtidos foram expressos em gramas.

2.4.3 Germinação

As 6.000 sementes previamente selecionadas pelo analista, sendo 3.000 esverdeadas e 3.000 amarelas, foram submetidas individualmente ao teste de germinação, ou seja, semente a semente. Cada semente foi disposta em uma folha de papel *germitest* umedecida, com quantidade de água equivalente a 2,5 vezes a massa do substrato seco. Em cada rolo de papel, foram distribuídas 25 sementes de maneira uniforme, e cada uma recebeu uma identificação única para assegurar correta rastreabilidade. Após a sementeira os rolos de papel foram acondicionados em um germinador com temperatura controlada de $25 \pm 2^\circ\text{C}$. No quinto dia após a

semeadura, as plântulas foram avaliadas e classificadas como normais, anormais e mortas, de acordo com os critérios estabelecidos pelas Regras para Análise de Sementes (BRASIL, 2009). Realizou-se uma avaliação única, tendo em vista que a mesma plântula também foi submetida ao teste de vigor através do GroundEye® na sequência. Além disso, nos laboratórios de sementes, é prática comum realizar a leitura de germinação em uma única análise ao quinto dia.

De acordo com as Regras para Análise de Sementes, plântulas normais são aquelas que apresentam todas as estruturas essenciais — tanto do sistema radicular quanto parte aérea — completamente desenvolvidas, evidenciando potencial para continuar seu desenvolvimento e gerar plantas normais sob condições favoráveis. Em contraste, plântulas anormais são aquelas que, mesmo em condições ideais, não demonstram potencial para prosseguir no desenvolvimento e originar plantas normais. Sementes mortas, por outro lado, são aquelas que ao término do teste não mostram nenhum sinal de início de germinação; estas frequentemente se apresentam amolecidas e atacadas por microorganismos (BRASIL, 2009).

Os dados relativos à germinação foram correlacionados com o ângulo de tonalidade para avaliar a relação entre esses dois parâmetros. Para isto, os resultados foram considerados independentemente de sua categoria de classificação (amarela ou esverdeada). Essa análise visou identificar possíveis padrões ou tendências que indicassem como variações no ângulo de tonalidade podem influenciar a taxa de germinação das sementes.

2.4.4 Vigor via GroundEye®

O vigor das sementes refere-se à sua capacidade de germinar e estabelecer-se rapidamente em condições adversas de cultivo. Somente as sementes normais, que demonstram um desenvolvimento estrutural adequado, possuem o potencial necessário para expressar vigor e estabelecer-se eficazmente no campo. Assim, nesta pesquisa optou-se por mensurar o vigor apenas de plântulas normais, logo plântulas anormais e sementes mortas foram desconsideradas, reduzindo o número amostral quando comparado às 6.000 análises performadas para o teste de germinação.

Imediatamente após a avaliação individual das plântulas no teste de germinação, todas as classificadas como normais foram fotografadas com o auxílio do sistema GroundEye® para análise de vigor. Foram analisadas 2.880 plântulas normais para o grupo “semente amarela” e outras 2.070 plântulas normais do grupo “semente esverdeada”. A Figura 4, mostra uma representação de imagem de uma plântula processada via software do GroundEye®.

Para o registro fotográfico, cada plântula foi posicionada na bandeja do equipamento, permitindo a aquisição da imagem e a medição do comprimento da raiz primária e do hipocótilo. O comprimento total da plântula foi determinado pela soma do tamanho da raiz primária ao do hipocótilo, e os resultados foram apresentados em centímetros. Barros et al. (2021) validaram a eficácia da medição automatizada do comprimento de plântulas e raízes através do sistema GroundEye®, equivalendo-o com a medição manual.



Figura 4– Imagem de plântula de soja capturada pelo GroundEye® S800D.

2.4.5 Análise estatística

No estudo realizado para avaliar a germinação, cada uma das 6.000 sementes, divididas entre esverdeadas e amarelas, foi considerada uma unidade amostral. Posteriormente, na análise de vigor, cada plântula normal também foi tratada como uma unidade amostral única, totalizando 4.950 plântulas normais, divididas nos mesmos dois tratamentos da germinação.

A análise estatística foi conduzida por meio de uma análise de variância (ANOVA) para identificar diferenças significativas entre os tratamentos. Após isso, o teste de Tukey foi aplicado para comparações múltiplas entre as médias dos grupos, utilizando um nível de significância de 5%. O software estatístico adotado foi o Assistat, versão 7.7 (SILVA e AZEVEDO, 2016).

3. RESULTADOS E DISCUSSÃO

As novas soluções de visão computacional, aliadas a algoritmos de inteligência artificial, mostram grande potencial para revolucionar a análise de imagens biológicas. Elas têm a capacidade de minimizar a subjetividade e otimizar o processo de análise, resultando em um controle de qualidade mais eficiente e preciso na agricultura. Com essas tecnologias, é possível discernir padrões em imagens biológicas que podem ser difíceis de distinguir a olho nu, permitindo uma avaliação mais objetiva e precisa da qualidade das sementes (MEDEIROS, et. al 2020).

Neste contexto, este estudo demonstrou que os dados cromáticos obtidos por análise de imagem e aplicados na modelagem de aprendizado de máquina possibilitaram uma classificação efetiva entre as classes de sementes. Além disso, os achados desta pesquisa destacam que a qualidade fisiológica das sementes esverdeadas é inferior à das sementes amarelas. Ineditamente, explorou-se a relação entre o ângulo de tonalidade e viabilidade das sementes de soja, destacando-o como um preditor significativo para este fim.

Nas cultivares A e B, a média de umidade observada foi de 9,9%. Este é um valor que se enquadra na faixa ideal de umidade para o armazenamento e conservação a longo prazo das sementes de soja, que geralmente está entre 8 e 10%. Nesse nível de umidade, a atividade metabólica das sementes é minimizada, o que ajuda a preservar a viabilidade e a qualidade das sementes durante o armazenamento (ELLIS e HONG, 2007).

Em relação à massa de mil sementes, a cultivar A apresentou 167,5 g e a cultivar B 145,5 g. Esses valores, embora diferentes, estão ambos dentro do intervalo normalmente observado para a cultura da soja, que costumeiramente varia entre 100 a 200 gramas.

3.1 Avaliação visual de sementes esverdeadas

Na Tabela 1, evidencia-se diferenças significativas entre os avaliadores B, D e H em relação ao avaliador controle (F). Essa variação observada na classificação de cor das sementes é uma descoberta relevante, reforçando a compreensão comum de

que a subjetividade desempenha um papel crítico nos programas de controle de qualidade de sementes.

Tabela 6 – Comparação de porcentagem de sementes esverdeadas em soja avaliadas por diferentes avaliadores. Brasília-DF, 2023.

Avaliador	% Semente esverdeada
F (controle)	16,62 ^{ns}
B	22,20 ⁺
D	21,97 ⁺
E	18,77 ^{ns}
C	16,28 ^{ns}
A	15,47 ^{ns}
G	11,78 ^{ns}
H	11,17 ⁻

ns Não significativo, pelo teste de Dunnett, em nível de 5% de probabilidade;

- Significativo e inferior ao controle, pelo teste de Dunnett, em nível de 5% de probabilidade;

+ Significativo e superior ao controle, pelo teste de Dunnett, em nível de 5% de probabilidade.

As diferenças de médias entre o avaliador controle (F) e os avaliadores B, D e H são estatisticamente significativas, como indicado pelos valores-P inferiores ao nível de significância de 0,05. Isso implica que as médias desses avaliadores foram significativamente diferentes da média de controle, como ilustrado na Tabela 2.

Os resultados revelaram que os avaliadores B e D apresentaram diferenças médias maiores em comparação ao avaliador controle, com médias de 5,58 e 5,35, respectivamente. Por outro lado, o avaliador H apresentou médias inferiores, com uma média de -5,45 em relação ao controle. Essas diferenças indicam que os avaliadores B e D foram mais críticos em sua avaliação, enquanto o avaliador H foi menos rigoroso. Esses achados corroboram a necessidade de aprimorar os métodos de controle, incluindo o desenvolvimento de protocolos de treinamento mais robustos para os avaliadores.

O nível de confiança individual foi de 99,10%, o que indica que existe apenas uma probabilidade de 0,9% de que a diferença observada seja devida ao acaso.

Tabela 7 – Diferença de médias entre diferentes avaliadores e o avaliador controle para análise de sementes esverdeadas em soja. Brasília-DF, 2023.

Diferença de níveis	Diferença de médias	Valor-P
A - F	-1,15	0,992
B - F	5,58	0,036
C - F	-0,33	1,000
D - F	5,35	0,049
E - F	2,15	0,822
G - F	-4,83	0,093
H - F	-5,45	0,043

Análise de média por Dunnett a nível de confiança individual = 99,10%.

No segundo experimento, foi registrada uma taxa de concordância de avaliação de 77,5% entre os avaliadores, como destacado na Tabela 3. Isso indica que, das 40 sementes analisadas, houve um consenso (correspondências) entre todos os avaliadores em 31 casos. Esta taxa de concordância ressalta a consistência na avaliação e interpretação das características das sementes pelos diferentes avaliadores. O intervalo de confiança de 95% para a taxa de concordância sugere que, se o experimento fosse repetido diversas vezes, esperaríamos que a taxa de concordância ficasse entre 61,55% e 89,16% na maioria (95%) das repetições.

Tabela 8 – Concordância de avaliação entre diferentes avaliadores na identificação de sementes amarelas e esverdeadas em soja. Brasília-DF, 2023.

Nº sementes inspecionadas	Nº correspondências ¹	Concordância (%)	IC de 95%
40	31	77,5	(61,55; 89,16)

¹ Nº correspondências: as avaliações de todos os avaliadores concordam entre si.

A percepção de cor é intrinsecamente subjetiva devido à variabilidade na forma como os indivíduos percebem e interpretam as cores. Fatores como a idade, a saúde ocular, as condições de iluminação e até a cultura podem influenciar a maneira como as cores são percebidas e descritas (FAIRCHILD, 2013). Em análises de controle de qualidade, testes que envolvem avaliação de elementos por cor, como a semente esverdeada, esbarram na subjetividade como um limitador no alcance de maior precisão e reprodutibilidade dos resultados.

3.2 Aprendizado de máquina: Árvore de decisão

Em contextos de visão computacional, o espaço de cores Lab* é muitas vezes preferido porque sua composição é projetada para se aproximar da maneira como os humanos percebem as cores. Isso significa que as diferenças no espaço de cores Lab* se correlacionam de maneira mais direta e intuitiva com as diferenças que os humanos realmente percebem, em comparação a outros espaços de cores, como o usual RGB (KANAN e COTTRELL, 2012). Lin et al. (2019), concordando com Kanan e Cottrell (2012), argumentaram que a percepção visual dos componentes (vermelho, verde e azul) da imagem RGB da soja é extremamente próxima. No entanto, quando a conversão do espaço de cores de RGB para Lab* é realizada, os componentes do espaço de cores Lab* exibem uma diferença visual expressiva entre os três canais de cores distintos, permitindo a formação de características bem definidas.

Estes achados foram confirmados neste estudo, onde variáveis do espaço de cor CIE Lab* foram superiores na tarefa de segregar sementes esverdeadas das amarelas. O ângulo de tonalidade (h) e a luminosidade (L) foram os critérios discriminantes mais responsivos ao modelo de aprendizado (Figura 5). Os resultados do modelo indicaram que um ângulo de tonalidade menor ou igual a $97,885^\circ$ teve uma forte associação com a avaliação das sementes como "amarelas". Por outro lado, valores do ângulo de tonalidade acima desse limite foram predominantemente associados à classificação das sementes como "esverdeadas".

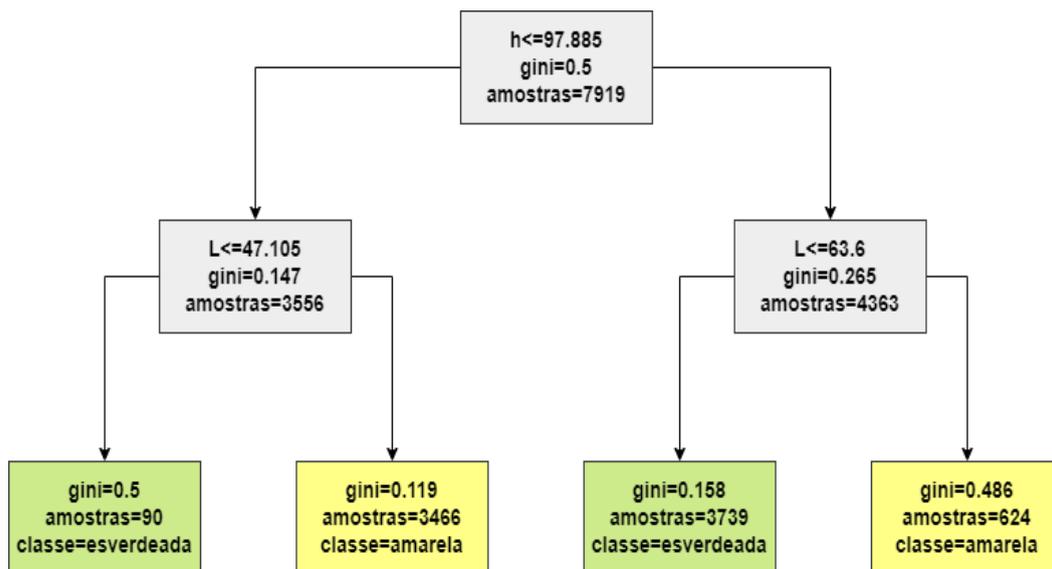


Figura 5 – Árvore de decisão para classificação de semente esverdeada e amarela em soja. Brasília-DF, 2023.

Ainda, na Figura 5, verifica-se que o emprego exclusivo do ângulo de tonalidade (h) não foi suficiente para diferenciar efetivamente as duas classes de sementes. Contudo, ao incorporar a luminosidade (L) como um segundo atributo, observou-se uma melhora significativa na classificação, evidenciada pela redução no índice de Gini. “Nós” com índices de Gini reduzidos em árvores de decisão geralmente apresentam melhor desempenho na classificação de novos dados, uma vez que agrupam os subconjuntos de dados de maneira mais homogênea (HASTIE et al., 2009; JAMES et al., 2023).

Na Tabela 4 apresenta-se uma matriz de confusão, onde as amostras foram divididas em duas categorias: amarela e esverdeada. Nesse estudo, foram classificadas corretamente 1870 amostras como amarelas, 1791 amostras como esverdeadas, 170 amostras amarelas foram classificadas erroneamente como esverdeadas, e 250 amostras esverdeadas foram classificadas erroneamente como amarelas.

Tabela 9 – Matriz de confusão para classificação de sementes de soja: amarela versus esverdeada. Brasília-DF, 2023.

n = 4081		Classe real	
		Amarela	Esverdeada
Classe predita	Amarela	1870	170
	Esverdeada	250	1791

Apoiado nas métricas apresentadas na Tabela 5, pode-se inferir que os resultados obtidos a partir do modelo de árvore de decisão são indicativos de um bom desempenho na distinção entre as sementes de soja classificadas como "amarelas" e "esverdeadas". O modelo analisado demonstrou uma sensibilidade de 88,2%, indicando que foi capaz de identificar corretamente 88,2% dos verdadeiros casos de sementes amarelas. A especificidade alcançada foi de 91,3%, refletindo a habilidade do modelo em classificar acertadamente as amostras que não são sementes amarelas. Além disso, a precisão para previsões da classe de sementes amarelas foi destacada em 91,7%. A acurácia geral do modelo foi de 89,8%, evidenciando a exatidão nas predições na maioria dos casos.

Tabela 10 – Análise da árvore de decisão de acordo com as principais métricas de desempenho. Brasília-DF, 2023.

Sensibilidade	Especificidade	Precisão	Acurácia
..... %			
88,2	91,3	91,7	89,8

A eficácia na distinção das classes de sementes amarelas e esverdeadas, evidenciada pelas altas taxas de sensibilidade, especificidade, precisão e acurácia, destaca a eficiência do modelo de classificação desenvolvido neste estudo. A aplicabilidade desse modelo é corroborada por outros autores, que também empregaram o aprendizado de máquina na classificação de sementes e plântulas de soja com diferentes níveis de assertividade (MOMIN et al., 2017; LIN et al., 2019; ANDRADRE et al. 2024). Os variados graus de sucesso nas pesquisas com IA indica que os modelos de validação necessitam de constante aperfeiçoamento para alcançar uma maior acuracidade. Isso implica que devem ser alimentados com uma quantidade

crescente de dados para aprimoramento, assim conseguem aumentar sua capacidade de generalização e acerto nas previsões.

Thilakarathne et al. (2018) analisaram sementes de cominho preto (*Nigella sativa*) de diferentes origens e observaram uma mudança significativa nos valores de luminosidade após a descorticação. Embora as cultivares fossem visualmente indistinguíveis, a análise de cor contribuiu para uma separação clara entre elas. Park et al. (2023) concluíram que a integração da espectroscopia de infravermelho próximo (SWIR) com técnicas de classificação baseadas em aprendizado de máquina demonstra eficácia na detecção de adulterações artificiais específicas em pimenta vermelha (*Capsicum annum*).

A relevância desses estudos anteriores é enfatizada pela investigação atual, que destaca como a combinação do ângulo de tonalidade e da luminosidade na classificação de sementes esverdeadas introduz uma valiosa objetividade ao processo. Esses parâmetros permitem uma avaliação quantitativa e imparcial da cor, essencial para atenuar a subjetividade inerente à percepção humana. Portanto, o uso simultâneo dessas duas medidas viabiliza uma metodologia objetiva para a classificação das sementes, aumentando a precisão e a reprodutibilidade do processo classificatório, e demonstrando sua potencial aplicabilidade em contextos mais amplos além da soja.

3.3 Qualidade fisiológica

Sementes classificadas como amarelas apresentaram uma taxa média de germinação mais alta, de 96%, e geraram plântulas com maior desenvolvimento inicial (Tabela 6) em comparação com as esverdeadas. Isso sugere que as sementes amarelas não apenas germinam melhor, mas também produzem plântulas mais vigorosas, o que pode melhorar o desempenho da cultura durante os estágios iniciais. A cor esverdeada está de alguma forma relacionada a uma diminuição na qualidade fisiológica das sementes de soja.

Tabela 6 – Percentual de germinação e tamanho de raiz primária, hipocótilo e comprimento total em plântulas de sementes de soja amarela e esverdeada. Brasília-DF, 2023.

Categoria	Germinação (%)	Raiz primária (cm)	Hipocótilo (cm)	Comprimento total (cm)
Amarela	96 a	13,91 a	7,88 a	21,72 a
Esverdeada	69 b	10,95 b	6,87 b	17,82 b

Médias seguidas pela mesma letra não diferem pelo teste de Tukey a 5% de probabilidade.

Os resultados obtidos neste estudo se alinham com a literatura existente, onde foi observado que a coloração esverdeada em sementes pode impactar negativamente a qualidade fisiológica, reduzindo tanto a germinação quanto o vigor das sementes. Por exemplo, Arruda et al. (2016) e Teixeira et al. (2020), já haviam identificado que a presença de sementes esverdeadas pode prejudicar a qualidade fisiológica de sementes de soja dependendo do seu índice de presença nos lotes.

Este trabalho complementa e expande as conclusões anteriores ao incorporar o teste tradicional de germinação e ao introduzir a análise de imagem como uma ferramenta adicional para a avaliação do vigor das sementes. Além disso, a investigação acerca da influência do ângulo de tonalidade na avaliação da viabilidade das sementes introduziu uma nova e relevante abordagem ao tema de predição de qualidade de sementes, e, portanto, merece ser aprofundado rigorosamente através de outras pesquisas científicas.

Genze et al. (2020), ao estudarem as culturas de milho, centeio e milheto, propuseram uma abordagem baseada em aprendizado de máquina para acelerar a avaliação da germinação de sementes. Esta tecnologia demonstrou menor taxa de erro e desempenho superior em comparação com métodos convencionais e manuais, resultando em índices de germinação e avaliações de qualidade de sementes mais precisos. Os autores Gulzar et al. (2020) evidenciam que a utilização de redes neurais convolucionais proporciona uma estratégia eficaz para a identificação e classificação de sementes.

Andrade et al. (2016) empregaram o sistema GroundEye® na análise de grãos verdes de soja, atingindo uma precisão superior a 99% na identificação deste tipo de defeito. Diferentemente do presente estudo, que focou na análise individualizada de sementes, Andrade et al. (2016) examinaram amostras contaminadas com grãos verdes, isto é, misturadas com grãos amarelos, e confirmaram a precisão e rapidez

do equipamento ao lidar com amostras heterogêneas. Adicionalmente, também constataram que o percentual de plântulas normais é inversamente proporcional à presença de grãos verdes nas amostras, evidenciando uma redução conforme o percentual de grãos verdes aumenta.

O ângulo de tonalidade, apontado neste estudo como um critério discriminante eficaz na tarefa de classificação de sementes esverdeadas, revelou-se também um importante preditor da qualidade fisiológica. Independentemente de as sementes serem amarelas ou esverdeadas, elas alcançam suas maiores taxas de germinação quando o ângulo médio de tonalidade é de até $97,5^\circ$ (Figura 6). Neste intervalo, observou-se, em média, 95% de germinação, em comparação com uma germinação de 71% quando o ângulo de tonalidade ultrapassava $97,5^\circ$.

Observa-se também, através da equação de regressão linear, que à medida que o ângulo de tonalidade aumenta, a viabilidade das sementes de soja tende a diminuir (Figura 6). O coeficiente de determinação sugere que cerca de 73% da variação da viabilidade das sementes de soja pode ser explicada pela variação do ângulo de tonalidade. Isto indica uma relação considerável entre estas duas variáveis, sugerindo que o ângulo de tonalidade pode ser um bom indicador da viabilidade das sementes de soja. As limitações desta pesquisa incluem a necessidade de explorar outras variáveis que podem influenciar a viabilidade das sementes, o que ressalta a importância de mais estudos e a adoção de análises multivariadas.

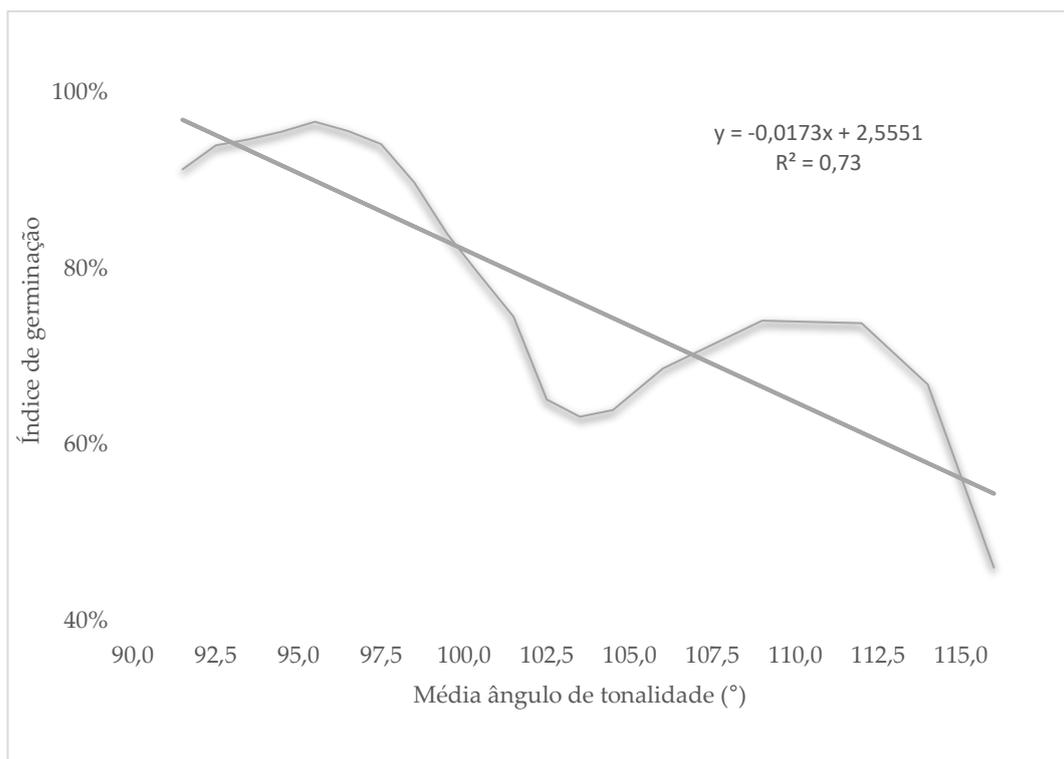


Figura 6 – Índice de germinação por média de ângulo de tonalidade. Brasília-DF, 2023.

O ângulo de tonalidade, tanto sementes amarelas quanto esverdeadas, situa-se no mesmo espectro de variação cromática, indicando que ambas as cores são variantes próximas dentro de um espectro contínuo de cores. No círculo de cromaticidade, a cor amarela é posicionada em um ângulo de 90°, como ilustrado na Figura 2. Esse posicionamento sugere que a distinção entre as sementes amarelas e esverdeadas pode ser sutil, baseando-se em pequenas variações de tonalidade. Esta proximidade no espectro de cores, por sua vez, pode colaborar para a subjetividade na análise, tornando a tarefa de distinguir as sementes uma atividade passível de erro, especialmente quando conduzida manualmente ou por avaliadores não treinados. Assim, a escolha de ferramentas e técnicas adequadas para discernir essas nuances é essencial para garantir uma classificação precisa e minimizar a ambiguidade.

Nos últimos anos, tem-se observado um avanço significativo nos recursos disponíveis para explorar e validar modelos matemáticos em diversas áreas de pesquisa. Apesar dessa evolução tecnológica, a aplicação dessas técnicas na análise de sementes, especialmente na utilização das cores como preditores de qualidade, ainda é notoriamente subrepresentada na literatura científica. A proposta de

incorporar características cromáticas na avaliação da qualidade das sementes representa uma metodologia inovadora, que se destaca não apenas pela sua aplicabilidade prática, mas também pela capacidade de amplificar resultados quando combinada com tecnologias emergentes, como IA e aprendizado de máquina.

Este novo paradigma promete não só melhorar a precisão da análise de sementes, mas também tornar o processo mais eficiente. No entanto, é importante notar que essas novas tecnologias não eliminam completamente a necessidade de intervenção humana. Na verdade, elas podem servir como uma ferramenta valiosa para auxiliar os especialistas na tomada de decisões, complementando, mas não substituindo, o conhecimento e a experiência humana.

4. CONCLUSÕES

Na avaliação visual de sementes amarelas e esverdeadas a concordância entre todos os avaliadores e o padrão foi de 77,5%. Sementes de soja amarelas demonstram qualidade fisiológica superior às esverdeadas, destacando-se em germinação e crescimento da plântula. O ângulo de tonalidade (h) e a luminosidade (L) mostraram-se os critérios mais responsivos ao modelo de aprendizado de máquina, alcançando uma acurácia de 89,7%. O ângulo de tonalidade demonstrou ser um preditor robusto, correlacionando-se com altas taxas de germinação em sementes com ângulo inferior a 97,5°. A relação entre a viabilidade das sementes e o ângulo de tonalidade foi apoiada por um coeficiente de determinação (R^2) de 73%.

5. REFERÊNCIAS BIBLIOGRÁFICAS

- ANDRADE, D. B. et al. Artificial intelligence tools and a diagrammatic scale for evaluating the quality of coating in treated soybean seeds. **Neural Computing and Applications**, v. 36, n. 6, p. 3101-3106, 2024.
- ANDRADE, D. B. et al. Detection of green seeds in soybean lots by the seed analysis system (SAS). **International Journal of Current Research**, v. 8, n. 2, p. 26462-26465, 2016.
- ARRUDA, M. H. M. et al. Qualidade fisiológica de lotes de sementes de soja com diferentes percentuais de sementes esverdeadas. **Magistra**, 28(2):194-200, 2016.
- BARROS, B. E. et al. Image analysis for the evaluation of soybean seeds vigor. **Acta Agronômica**, 70(3):311-316, 2021.
- BAURIEGEL, E. et al. Early detection of Fusarium infection in wheat using hyperspectral imaging. *Computers and electronics in agriculture*, v. 75, n. 2, p. 304-312, 2011.
- BISHOP, C. M. **Pattern recognition and machine learning (Information science and statistics)**. New York, United States: Springer-Verlag, 2006. 738p.
- BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. Regras para Análise de Sementes; **Departamento Nacional de Produção Vegetal**: Brasília-DF, DF, Brasil, 2009. 399p.
- ELLIS, R. H.; HONG, T. D. Seed longevity–moisture content relationships in hermetic and open storage. **Seed Science and Technology**, v. 35, n. 2, p. 423-431, 2007.
- FAIRCHILD, Mark D. **Color appearance models**. John Wiley e Sons, 2013.
- FAO – Food and Agriculture Organization. *World Food and Agriculture - Statistical Yearbook 2021*. Roma, 2021.
- FERRARI, Juliana Marques; SILVA, Dayara Vieira; FIDELIS, Rodrigo Ribeiro. Comportamento da qualidade fisiológica de sementes de soja esverdeadas durante o armazenamento. *Revista Caribeña de Ciencias Sociales*, v. 12, n. 7, p. 3055-3060, 2023.
- FRANÇA-NETO, J. B. et al. **Tecnologia da produção de semente de soja de alta qualidade**. 2016.
- GENZE, Nikita et al. Accurate machine learning-based germination detection, prediction and quality assessment of three grain crops. **Plant methods**, v. 16, n. 1, p. 1-11, 2020.

GODOY, C. V. et al. **Boas práticas para o enfrentamento da ferrugem-asiática da soja**. 2017.

GULZAR, Yonis et al. A convolution neural network-based seed classification system. **Symmetry**, v. 12, n. 12, p. 2018, 2020.

HASTIE, Trevor et al. **The elements of statistical learning: data mining, inference, and prediction**. New York: springer, 2009.

Hunter, R. S. (1958). **Photoelectric color difference meter**. *Josa*, 48(12), 985-995.

JAMES, G. et al. **An introduction to statistical learning: With applications in python**. New York, NY: Springer Nature, 2023.

KANAN, C.; COTTRELL, G. W. Color-to-grayscale: does the method matter in image recognition?. *PloS one*, 7(1):e29740, 2012.

LIMA, Juliana Maria Espíndola et al. Técnicas de análise de imagem para caracterização da qualidade de sementes de paricarana (*Bowdichia virgilioides* Kunth). **Ciência Florestal**, v. 28, p. 1202-1216, 2018.

LIN, P. et al. Rapidly and exactly determining postharvest dry soybean seed quality based on machine vision technology. **Scientific Reports**, 9(1):17143, 2019.

MAHAJAN, S.; MITTAL, S. K.; DAS, A. Machine vision based alternative testing approach for physical purity, viability and vigour testing of soybean seeds (*Glycine max*). *Journal of food science and technology*, 55(10):3949-3959, 2018.

MEDEIROS, A. D. et al. Interactive machine learning for soybean seed and seedling quality classification. **Scientific Reports**, 10(1):11267, 2020.

MINITAB. (2021). Minitab® 21 Statistical Software. Disponível em:
<https://www.minitab.com/pt-br/products/minitab/?locale=pt-BR>

MOMIN, M. A. et al. Machine vision based soybean quality evaluation. **Computers and Electronics in Agriculture**, 140:452-460, 2017.

PÁDUA, Gilda Pizzolante de et al. Tolerance level of green seed in soybean seed lots after storage. **Revista Brasileira de Sementes**, v. 29, p. 128-138, 2007.

PARK, Jong-Jin et al. Detection of Red Pepper Powder Adulteration with Allura Red and Red Pepper Seeds Using Hyperspectral Imaging. **Foods**, v. 12, n. 18, p. 3471, 2023.

PATEL, Krishna Kumar et al. Machine vision system: a tool for quality inspection of food and agricultural products. **Journal of food science and technology**, v. 49, p. 123-141, 2012.

PYTHON SOFTWARE FOUNDATION. **Python**. Versão 3.10 [s.l.], 2021. Disponível em: <<https://www.python.org/>>. Acesso em: 10 mai. 2023.

ROBERTSON, Alan R. **The CIE 1976 color-difference formulae**. Color Research e Application, v. 2, n. 1, p. 7-11, 1977.

RUSSELL, S. J.; NORVIG, P. **Artificial intelligence: a modern approach**. Pearson, 2016.

SILVA, F. A. S.; AZEVEDO, C. A. V. The Assistat Software Version 7.7 and its use in the analysis of experimental data. **African Journal of Agricultural Research**, 11(39):3733-3740, 2016.

SINGH, Guriqbal; SHIVAKUMAR, B. G. The role of soybean in agriculture. The soybean: Botany, production and uses. **CAB International**, Oxfordshire, UK, p. 24-47, 2010.

ŠKRUBEJ, U. et al. Assessment of germination rate of the tomato seeds using image processing and machine learning. **European Journal of Horticultural Science**, v. 80, n. 2, p. 68-75, 2015.

TBIT TECNOLOGIAS S.A. **Manual do Usuário SAS – Sistema de Análise de Sementos**. 1. Ed. Lavras, MG: [s.n.], 2014, 152 p.

TEIXEIRA, S. B. et al. Green soybean seeds: effect on physiological quality. **Ciência Rural**, 50, 2020.

THAKUR, Puneet Singh et al. Deep transfer learning based photonics sensor for assessment of seed-quality. **Computers and Electronics in Agriculture**, v. 196, p. 106891, 2022.

THILAKARATHNE, R. C. N.; MADUSHANKA, G. D. M. P.; NAVARATNE, S. B. **Morphological characteristics of black cumin (*Nigella sativa*) seeds**. 2018.

XAVIER, J. B. et al. Caracterização morfológica, química e fisiológica de sementes de *Amaranthus* spp. **Journal of Seed Science**, v. 41, p. 478-487, 2019.

XIA, Y. et al. Recent advances in emerging techniques for non-destructive detection of seed viability: A review. **Artificial Intelligence in Agriculture**, 1:35-47, 2019.

ZORATO, M. F. et al. Presença de sementes esverdeadas em soja e seus efeitos sobre seu potencial fisiológico. **Revista Brasileira de Sementes**, 29:11-19, 2007.

CAPÍTULO II

INTELIGÊNCIA ARTIFICIAL APLICADA À CLASSIFICAÇÃO DE SEMENTES COM MANCHA PÚRPURA E PREDIÇÃO DE QUALIDADE FISIOLÓGICA EM SOJA

RESUMO

A mancha púrpura representa um fator potencialmente prejudicial para a qualidade física, fisiológica e sanitária das sementes de soja. Tradicionalmente, as sementes são avaliadas por inspeção visual, um método sujeito à subjetividade e erros humanos. Frente a isto, esta pesquisa propõe uma abordagem inovadora que integra análise de imagens e inteligência artificial para desenvolver um modelo de aprendizado de máquina capaz de distinguir sementes amarela de sementes com mancha púrpura com base em parâmetros de cor. Com essa pesquisa, aspirou-se aprimorar a acurácia na categorização das sementes e, simultaneamente, aprofundar o entendimento sobre como presença e intensidade de mancha púrpura nas sementes podem impactar a qualidade fisiológica da cultura da soja. A inteligência artificial foi treinada com 6.000 imagens capturadas e processadas pelo GroundEye® S800D. A metodologia empregada para treinar o sistema envolveu a utilização de uma árvore de decisão, utilizando a biblioteca *sklearn.tree* do Python. Cada semente, após a captura de imagem, foi submetida a um teste de germinação padrão. As plântulas normais foram então reanalisadas no GroundEye® S800D para determinar seu tamanho. Foi realizado teste de tetrazólio para determinar vigor, viabilidade e diagnóstico dos danos. No modelo de aprendizado de máquina adotado, a cor laranja destacou-se como o critério discriminante mais responsivo, alcançando uma acurácia de 96,4% na árvore de decisão destinada a diferenciar sementes amarela de sementes com mancha púrpura. Uma acurácia menor, contudo, eficiente, de 89,4%, foi alcançada para separação de mancha púrpura em tonalidade leve e severa. As sementes categorizadas como amarelas demonstraram uma taxa de germinação significativamente mais elevada em comparação às sementes com mancha púrpura leve e severa. Além disso, a severidade influenciou negativamente o vigor, resultando plântulas menores para o grupo com mancha púrpura severa. O decréscimo de qualidade em sementes com mancha púrpura também foi evidenciado por índices reduzidos de viabilidade e vigor, no teste de tetrazólio.

Palavras-chaves: qualidade soja; mancha púrpura; inteligência artificial; aprendizado de máquina; GroundEye®.

ABSTRACT

The purple stain represents a potentially detrimental factor for the physical, physiological, and sanitary quality of soybean seeds. Traditionally, seeds are evaluated through visual inspection, a method subject to subjectivity and human error. In front of this, this research proposes an innovative approach that integrates image analysis and artificial intelligence to develop a machine learning model capable of distinguishing yellow seeds from purple-stained seeds based on color parameters. This study aims to enhance the accuracy of seed categorization and simultaneously deepen the understanding of how the presence and intensity of purple staining in seeds can impact the physiological quality of soybean crops. Artificial intelligence was trained with 6,000 images captured and processed by the GroundEye® S800D. The methodology employed to train the system involved the use of a decision tree, utilizing the *sklearn.tree* library in Python. Each seed, after image capture, underwent a standard germination test. The normal seedlings were then reanalyzed with the GroundEye® S800D to determine their size. A tetrazolium test was conducted to determine vigor, viability, and diagnose damages. In the adopted machine learning model, the orange color stood out as the most responsive discriminative criterion, achieving an accuracy of 96.4% in the decision tree designed to differentiate yellow seeds from purple-stained seeds. A lower, yet efficient accuracy of 89.4% was achieved for the separation of light and severe purple staining. Seeds categorized as yellow exhibited a significantly higher germination rate compared to seeds with light and severe purple staining. Furthermore, severity negatively influenced vigor, resulting in smaller seedlings for the group with severe purple staining. The decline in quality of purple-stained seeds was also evidenced by reduced viability and vigor indices in the tetrazolium test.

Keywords: soybean quality; purple stain; artificial intelligence; machine learning; GroundEye®.

1. INTRODUÇÃO

A mancha púrpura da semente é consensualmente associada ao fungo necrotrófico *Cercospora kikuchii* (GARDNER, 1925; MATSUMOTO e TOMOYASU, 1925). Além de afetar folhas e sementes, *C. kikuchii* também provoca lesões em vagens, pecíolos e hastes da planta (LEHMAN et al., 1950; MURAKISHI et al., 1951).

Os sintomas da mancha púrpura nas sementes, que incluem a coloração púrpura e a formação de estrias escuras no tegumento, não apenas indicam a presença do patógeno, mas também reduzem o valor comercial da semente, o que resulta em perdas econômicas diretas para os produtores (HARTMAN et al., 1999).

A infecção por *C. kikuchii* compromete a qualidade das sementes, resultando em plantas de menor vigor (TURNER et al., 2020) e, conseqüentemente, mais vulneráveis a outras patologias e estresses abióticos. Adicionalmente, esta doença leva à diminuição do teor de óleo nas sementes (PRASHANT e PATIL, 2012; HARTMAN et al., 2015) e, segundo Lee et al., (2015), também altera a composição química e as propriedades antioxidantes das sementes.

Sementes de soja afetadas por mancha púrpura frequentemente exibem diminuição na germinação e vigor, comprometendo o estabelecimento inicial da planta no campo (WRATHER e KOENNING, 2006). De acordo com Hartman et al. (1999), a mancha púrpura afeta negativamente a qualidade das sementes de soja, resultando na redução da germinação e conseqüente morte precoce das plântulas. Esta conclusão foi reforçada por Pathan et al. (1989), Schuh (1999) e Li et al. (2016), que destacaram sua influência adversa no vigor das sementes e, assim, no adequado estabelecimento da cultura.

Henning (2004) concluiu que sementes de soja com incidência de mancha púrpura superior a 10% em seus tegumentos apresentaram significativa redução na porcentagem de emergência em campo em comparação com as sementes sem sintomas. Ainda, de acordo com Grigolli (2015), a infestação causada pela *C. kikuchii* resulta em reduções substanciais na produtividade da cultura da soja, variando entre 7% e 30%, dependendo da intensidade da incidência da doença e das condições ambientais locais.

Embora diversos estudos tenham sugerido um impacto negativo da mancha-púrpura na qualidade fisiológica de sementes de soja, há uma controvérsia no campo

científico a respeito dessa conclusão. Muitos desses estudos indicam que sementes infectadas pelo fungo *C. kikuchii* podem ter reduzido vigor, germinação e produtividade. No entanto, alguns estudos apontam que mesmo quando as sementes estando infectadas com o fungo, não há prejuízos à qualidade fisiológica e rendimento da cultura (VELICHETI et al., 1992; OLIVEIRA et al., 1993; GALLI et al., 2005).

Como defendido por Moraes (2022), avaliação da severidade da infecção nas sementes de soja pelo fungo *C. kikuchii* é um elemento crucial para compreender o impacto real da doença. Dependendo da metodologia e dos critérios adotados, os resultados podem variar, o que pode explicar as discrepâncias observadas entre diferentes estudos. A avaliação visual da mancha-púrpura é comumente utilizada, mas sua precisão é questionável. Isso porque a presença dessa mancha nem sempre indica a ativação ou a intensidade da infecção fúngica. Além disso, sua classificação pode ser subjetiva, variando conforme a interpretação humana.

Neste contexto, o propósito deste estudo foi desenvolver um modelo de classificação para identificar sementes com mancha púrpura utilizando análise de imagem. Assim, técnicas de inteligência artificial foram aplicadas para criar um modelo de aprendizado de máquina que diferencie sementes de soja com mancha púrpura de sementes amarelas, com base em características cromáticas. Com essa pesquisa, aspirou-se aprimorar a acurácia na categorização das sementes e, simultaneamente, aprofundar o entendimento sobre como a presença e intensidade de mancha púrpura nas sementes podem impactar a qualidade fisiológica na cultura da soja.

2. MATERIAL E MÉTODOS

Os experimentos foram conduzidos no Laboratório de Análise de Sementes da Corteva Agriscience do Brasil Ltda, empresa multinacional agrícola localizada em Brasília-DF, Distrito Federal.

Três lotes de uma única cultivar foram escolhidos para a coleta das sementes deste estudo. As sementes foram provenientes da safra 2022/2023. A colheita foi realizada em fevereiro de 2023, de forma mecanizada e com acompanhamento técnico-agronômico. Todas as etapas, desde a segregação até o armazenamento, foram conduzidas de forma a assegurar a adequada rastreabilidade das amostras.

2.1 Análise de imagem através do GroundEye®

Um analista experiente, selecionou manualmente 3000 sementes, categorizadas posteriormente em três grupos: “semente amarela”, que não apresentavam sinais de pigmentação púrpura; “mancha púrpura leve”, nas quais a pigmentação cobria menos de 50% da superfície do tegumento; e “mancha púrpura severa”, com coloração púrpura em mais de 50% da sua superfície total. Dessa forma, cada categoria continha um lote de 1.000 sementes. Para cada semente uma identificação unívoca foi atribuída. A Figura 1 ilustra a severidade de manifestação da coloração púrpura no tegumento de sementes de soja.

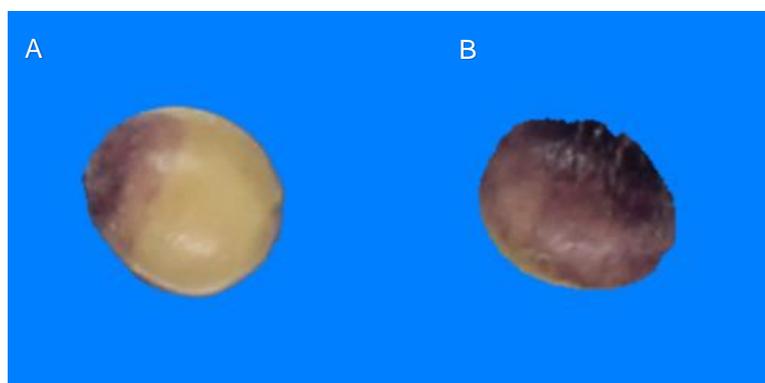


Figura 1 – Representação de sementes de soja com mancha púrpura. (A) semente com intensidade leve; (B) semente com intensidade severa. Brasília-DF, 2023.

Cada semente foi posicionada individualmente em uma bandeja de acrílico transparente dentro do equipamento GroundEye® S800D (Figura 2) para a obtenção de sua imagem. Após captura e processamento digital, diversas características relacionadas à cor foram avaliadas através de relatórios produzidos pelo software associado ao equipamento.



Figura 2 – GroundEye® S800D.
Fonte: Tbit, 2023.

O GroundEye® S800D, equipado com um sistema de duas câmeras, viabiliza a captura de imagens da face superior e inferior de cada item em análise. Assim, cada semente contribui com duas imagens para a avaliação digital, resultando em um total de 6.000 imagens no conjunto dos dados. Embora o GroundEye® possua a capacidade de avaliar diversos parâmetros de cor e outras características, o foco da presente investigação recaiu sobre a análise do sistema de cor HSV. Os resultados analisados concentraram-se principalmente no entendimento da dominância de cores, que representa a prevalência de uma cor específica dentro de uma faixa determinada.

A utilização dos parâmetros de matiz, saturação e valor (ou intensidade) permitiu estabelecer valores mínimos e máximos para cada faixa de cor, possibilitando

um entendimento mais aprofundado da distribuição cromática das sementes, tanto na presença como na ausência de mancha púrpura no tegumento (Tabela 1).

Tabela 1 – Expressão de cores no espaço HSV. Brasília-DF, 2023.

Cor	Parâmetros de cálculo ¹
Preta	$(V \leq 0.25)$
Cinza escuro	$(V \leq 0.25) \text{ E } (V \leq 0.60) \text{ E } (S \leq 0.20)$
Cinza clara	$(V > 0.60) \text{ E } (V \leq 0.90) \text{ E } (S \leq 0.20)$
Vermelha	$(H > 345) \text{ OU } (H \geq 0) \text{ E } (H \leq 15) \text{ E } (S > 0.10) \text{ E } (V > 0.25)$
Laranja	$(H \leq 45) \text{ E } (H > 15) \text{ E } (S > 0.10) \text{ E } (V > 0.25)$
Amarela	$(H \leq 75) \text{ E } (H > 45) \text{ E } (S > 0.10) \text{ E } (V > 0.25)$
Oliva	$(H \leq 105) \text{ E } (H > 75) \text{ E } (S > 0.10) \text{ E } (V > 0.25)$
Verde	$(H \leq 135) \text{ E } (H > 105) \text{ E } (S > 0.10) \text{ E } (V > 0.25)$
Turquesa	$(H \leq 165) \text{ E } (H > 135) \text{ E } (S > 0.10) \text{ E } (V > 0.25)$
Ciano	$(H \leq 195) \text{ E } (H > 165) \text{ E } (S > 0.10) \text{ E } (V > 0.25)$
Celestial	$(H \leq 225) \text{ E } (H > 195) \text{ E } (S > 0.10) \text{ E } (V > 0.25)$
Azul	$(H \leq 225) \text{ E } (H > 225) \text{ E } (S > 0.10) \text{ E } (V > 0.25)$
Púrpura	$(H \leq 285) \text{ E } (H > 255) \text{ E } (S > 0.10) \text{ E } (V > 0.25)$
Magenta	$(H \leq 315) \text{ E } (H > 285) \text{ E } (S > 0.10) \text{ E } (V > 0.25)$
Rosa	$(H \leq 345) \text{ E } (H > 315) \text{ E } (S > 0.10) \text{ E } (V > 0.25)$
Branca	$(V > 0.90) \text{ E } (S \leq 0.10)$

¹ Em que, H é o canal matiz, S é o canal saturação e V é o canal valor do espaço de cores HSV.

2.2 Modelo de validação

Para desenvolver o sistema de avaliação de sementes com base em inteligência artificial, foi montado um conjunto de dados (*data set*) composto por 6.000 imagens de sementes, 2.000 das quais foram classificadas como “semente amarela” e 4.000 como “semente púrpura”. A metodologia empregada para treinar o sistema envolveu a utilização de uma árvore de decisão, utilizando a biblioteca *sklearn.tree* do Python. O conjunto de dados foi segmentado em duas frações: 66% do total, correspondendo a 3.959 imagens, foram empregados no treinamento do modelo e o restante, representado por 2.041 imagens (34%), foi empregado nos testes propriamente ditos.

Para avaliar a eficácia do modelo, utilizou-se uma matriz de confusão, que ajudou a visualizar e quantificar os verdadeiros positivos (VP), os verdadeiros negativos (VN), os falsos positivos (FP) e os falsos negativos (FN). Estas taxas foram utilizadas para calcular os indicadores de desempenho do modelo obtido pela árvore de decisão, sendo eles: acurácia, precisão, sensibilidade e especificidade. A acurácia (1) refere-se à proporção de predições feitas pelo modelo que se mostraram corretas. Precisão (2) indica a proporção de identificações positivas feitas pelo modelo que foram, de fato, corretas. Sensibilidade (3) representa a proporção de positivos reais que o modelo identificou corretamente. Especificidade (4) corresponde à proporção de negativos reais que o modelo identificou corretamente.

$$\text{Acurácia} = \frac{VP+VN}{VP+VN+FP+FN} \times 100 \quad (1)$$

$$\text{Precisão} = \frac{VP}{(VP+FP)} \times 100 \quad (2)$$

$$\text{Sensibilidade} = \frac{VP}{VP+FN} \times 100 \quad (3)$$

$$\text{Especificidade} = \frac{VN}{VN+FP} \times 100 \quad (4)$$

Adicionalmente, o índice de Gini foi utilizado como critério de seleção de características na construção da árvore de decisão, fornecendo uma medida de impureza que otimizou o particionamento das categorias entre os nós. Esse índice ajuda a determinar como cada característica contribui para a homogeneidade dos nós e das folhas da árvore, com o objetivo de minimizar a probabilidade de erros de classificação. A utilização do índice de Gini neste contexto aumenta a capacidade da árvore para distinguir claramente entre as diferentes categorias com base nas características mais relevantes extraídas das imagens das sementes.

2.3 Avaliação da qualidade das sementes

2.3.1 Germinação

As 3.000 sementes previamente selecionadas pelo analista experiente (1.000 amarelas e 2.000 púrpuras), foram submetidas individualmente ao teste de germinação. Cada semente foi disposta em uma folha de papel *germitest* umedecida, com quantidade de água equivalente a 2,5 vezes a massa do substrato seco. Em cada rolo de papel, foram distribuídas 25 sementes de maneira uniforme e cada uma recebeu uma identificação para assegurar correta rastreabilidade. Após a semeadura os rolos de papel foram acondicionados em germinador a 25 ± 2 °C. Após cinco dias, as plântulas foram avaliadas e classificadas como normais, anormais e mortas (BRASIL, 2009). Realizou-se uma avaliação única, tendo em vista que as plântulas também foram submetidas ao teste de vigor através do GroundEye®. Além disso, nos laboratórios de sementes, é prática comum realizar a leitura de germinação em uma única avaliação ao quinto dia.

2.3.2 Vigor via GroundEye®

Imediatamente após a avaliação individual das plântulas no teste de germinação, todas as classificadas como normais foram fotografadas com o auxílio do sistema GroundEye® para análise de vigor. Foram analisadas 870 plântulas normais para o grupo “semente amarela”, 710 plântulas normais do grupo “mancha púrpura leve” e 450 plântulas normais para o grupo “mancha púrpura severa”.

Para o registro fotográfico, cada plântula foi posicionada na bandeja do equipamento, permitindo a aquisição da imagem e a medição do comprimento da raiz primária e do hipocótilo. O comprimento total da plântula foi determinado pela soma do tamanho da raiz primária ao do hipocótilo, e os resultados foram apresentados em centímetros. Barros et al. (2021) validaram a eficácia da medição automatizada do comprimento de plântulas e raízes através do sistema GroundEye®, equivalendo-o com a medição manual.

2.3.3 Teste de tetrazólio

Para a realização do teste de tetrazólio, foram selecionadas aleatoriamente 500 sementes de cada subgrupo. Depois de capturadas e processadas pelo GroundEye® S800D, essas sementes foram analisadas conforme a metodologia proposta por França-Neto e Krzyzanowski (2022). Um analista experiente examinou cada semente, classificando-a como viável ou não-viável com base nas categorias de vigor e viabilidade do método.

2.3.4 Análise estatística

Os experimentos para caracterização e avaliação da qualidade das sementes foram analisados utilizando a análise de variância. As médias foram submetidas ao teste de Tukey com um nível de significância de 5%. As análises foram feitas usando o software Assistat 7.7 (SILVA e AZEVEDO, 2016).

3. RESULTADOS E DISCUSSÃO

3.1 Aprendizado de máquina: Árvore de decisão

O modelo para segregação de sementes amarelas das sementes apresentando mancha púrpura foi treinado com 66% do conjunto dos dados, totalizando 3.959 registros. Para o modelo de teste, foram analisadas 2041 sementes ou 34% do *dataset*, das quais 1968 foram classificadas corretamente, enquanto 73 apresentaram classificação equivocada (Tabela 2).

Tabela 2 – Matriz de confusão para classificação de sementes de soja: amarela versus mancha púrpura. Brasília-DF, 2023.

N = 2041		Classe real	
		Amarela	Mancha púrpura
Classe predita	Amarela	670	10
	Mancha púrpura	63	1298

Das sementes amarelas analisadas, 670 foram acertadamente identificadas como tal, ao passo que 10 foram erroneamente classificadas como sendo mancha púrpura. Por outro lado, 63 sementes com mancha púrpura foram incorretamente categorizadas como amarela, enquanto 1298 foram corretamente agrupadas nesta categoria.

A acurácia geral alcançada foi de 96,4% (Tabela 3) o que atesta a competência do modelo em diferenciar adequadamente as categorias de sementes amarela e com mancha púrpura, com alta confiabilidade. Os valores de sensibilidade, especificidade e precisão apresentados corroboram a alta eficácia do modelo preditivo. Estas métricas de desempenho têm resultados superiores a 90%, evidenciando a robustez e a confiabilidade do modelo em classificar corretamente as sementes com base nos parâmetros estabelecidos.

Tabela 3 – Análise da árvore de decisão de acordo com as principais métricas de desempenho. Brasília-DF, 2023.

Sensibilidade	Especificidade	Precisão	Acurácia
..... %			
99,2	91,4	95,3	96,4

A regra que sintetiza a árvore de decisão relatada neste estudo está descrita e representada graficamente na Figura 3. Ela traduz que quando o valor do atributo "Laranja" é menor ou igual a 88,735, a classe resultante é "mancha púrpura" e valores superiores a este, em sementes classificadas como "amarela".

***SE** Laranja ≤ 88,735 **ENTÃO** classe = mancha púrpura*
***SE** Laranja > 88,735 **ENTÃO** classe = amarela*

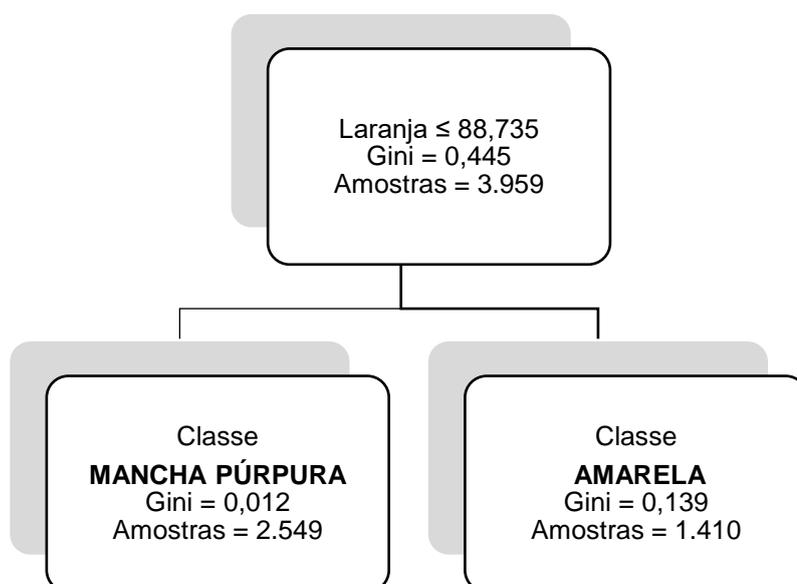


Figura 3 – Árvore de decisão para classificação de sementes de soja em amarela e com mancha púrpura. Brasília-DF, 2023.

No modelo de cores HSV (Matiz, Saturação e Valor), o componente Hue, ou matiz, é responsável por determinar a tonalidade específica da cor. O Hue representa a posição angular na roda de cores e varia de 0 a 360 graus, enquanto os componentes de Saturação e Valor representam, respectivamente, a intensidade da cor e o brilho (FOLEY, 1996).

Para esta pesquisa, o intervalo de 15 a 45 graus foi identificado como representativo da cor laranja, e selecionado para capturar toda a variedade de tonalidades para este parâmetro. A cor laranja começa imediatamente após o término do espectro do vermelho, cerca de 15 graus, e termina antes do início do espectro do amarelo, que começa a partir de 45 graus. Faz sentido intuitivo que o atributo de cor "laranja" seja eficiente na distinção entre sementes amarelas e sementes com mancha púrpura, tal como percebido visualmente pelo olho humano.

Ao limitar-se a um único atributo de classificação, o modelo torna-se mais fácil de interpretar, o que é uma vantagem significativa em termos de simplicidade e compreensão. No entanto, essa abordagem pode limitar a capacidade do modelo de capturar toda a complexidade dos dados. Em muitos casos, os dados são intrinsecamente multidimensionais e requerem consideração de múltiplos atributos para uma classificação mais precisa (RIBEIRO, 2016), particularmente em aplicação para análise de sementes em que a variação cromática pode ser substancial entre elementos de um mesmo grupo de inspeção.

A análise detalhada dos valores médios e do desvio padrão combinado para diferentes cores no espaço de cor HSV, revela variações significativas na predominância de cores entre os tipos de sementes (Tabela 4), o que favorece sua segmentação em análise por imagem e também pode ser um indicativo de diferenças na qualidade física, fisiológica e sanitária entre elas. Por exemplo, a cor laranja é majoritariamente predominante nas sementes amarelas (91,6469), mas é consideravelmente reduzida em sementes com mancha púrpura leve e severa. Em contraste, a cor vermelha aumenta de 0,7524 nas sementes amarelas para 30,5360 nas sementes com mancha púrpura severa, destacando uma variação significativa que pode estar relacionada à severidade da mancha púrpura.

O desvio padrão combinado serve como indicativo da variabilidade entre as medições, e os valores elevados observados em cores como laranja e vermelha sugerem uma dispersão considerável que pode ser atribuída às diferenças intrínsecas entre as sementes dentro de cada grupo classificado. A cor cinza escuro também mostra uma dispersão relevante (desvio padrão de 5,2429), possivelmente refletindo a heterogeneidade na intensidade da coloração entre as sementes avaliadas.

Tabela 4 – Valores médios e desvio padrão combinado para diferentes cores do modelo HSV, obtidos para as classes: semente amarela, mancha púrpura leve e mancha púrpura severa. Brasília-DF, 2023.

Cor	Semente amarela	Mancha púrpura leve	Mancha púrpura severa	Desvio padrão combinado
Preta	0,0027 c	1,0400 b	10,0800 a	9,9169
Cinza escuro	5,0482 c	6,1305 b	10,1650 a	5,2429
Cinza clara	0,2154 b	0,4331 a	0,2355 b	0,5641
Vermelha	0,7524 c	13,9670 b	30,5360 a	9,7750
Laranja	91,6469 a	72,3450 b	27,4970 c	14,4584
Amarela	0,7515 a	0,6251 b	0,3158 c	0,9603
Oliva	0,0000 a	0,0056 b	0,0023 c	0,0405
Verde	0,0004 a	0,0000 b	0,0000 c	0,0091
Turquesa	0,0000 b	0,0031 ab	0,0019 b	0,0308
Ciano	0,1509 a	0,0810 b	0,0549 c	0,2499
Celestial	0,0240 b	0,0316 b	0,0823 a	0,2021
Azul	1,3240 a	1,8420 a	3,8166 c	1,9646
Púrpura	0,0498 c	0,3858 b	1,7465 a	1,3247
Magenta	0,0000 c	0,1308 b	1,0555 a	0,8052
Rosa	0,0342 c	2,9801 b	14,4100 a	5,7690

Médias seguidas pela mesma letra não diferem pelo teste de Tukey a 5% de probabilidade.

As sementes classificadas como amarelas exibem uma dominância da cor laranja, enquanto as sementes com mancha púrpura, tanto leve quanto severa, apresentam diversidade de cores: diminuição da cor laranja e aumento nas cores preta, cinza escuro, vermelha, rosa e azul (Figura 4).

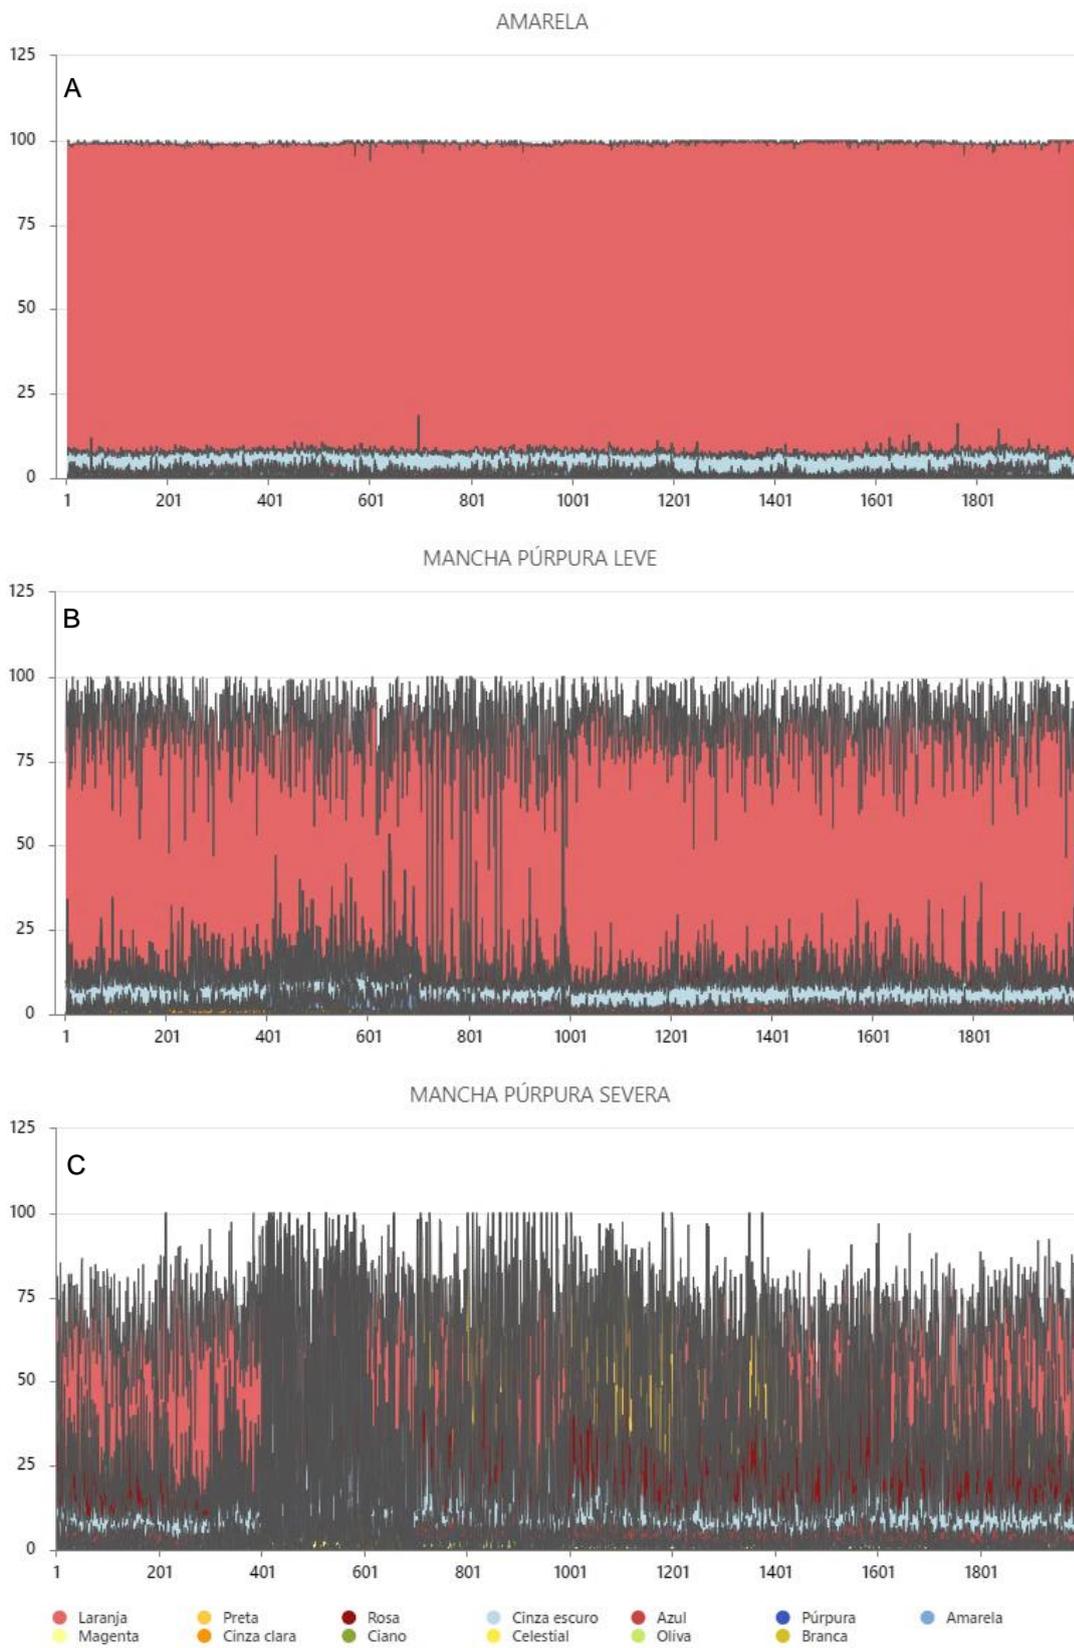


Figura 4 – Variabilidade cromática no espaço de cor HSV para sementes amarela (A) e com presença de mancha púrpura leve (B) e severa (C). Brasília-DF, 2023.

Métodos computacionais para identificação de mancha púrpura em sementes de soja foram explorados por outros autores com diferentes níveis de assertividade. Paulsen et al. (1989) tiveram precisão superior a 66% enquanto Ahmad et al. (1998) atingiram 83%. Mais recentemente, Jitanan e Chimlek (2019) alcançaram 100% de acurácia ao identificar mancha púrpura no tegumento de soja, usando técnicas de processamento de imagem e aprendizado de máquina.

Ningsih e Cholidhazia (2022) empregaram o algoritmo K-Nearest Neighbor (KNN) para classificar os estágios de maturidade de tomates (*Lycopersicon esculentum* Mill), utilizando características de cor nos espectros RGB e HSV. O método alcançou uma precisão máxima de 91,25% na classificação dos diversos níveis de maturação dos frutos. De maneira similar, o uso do modelo de cor HSV foi também explorado por Ganesh et al. (2019) visando a avaliação individual de frutas. A eficácia do algoritmo foi avaliada por meio da comparação entre o uso exclusivo de imagens RGB e o uso combinado de imagens RGB e HSV. Os resultados mostraram uma melhora significativa na precisão ao utilizar a combinação dos dados.

O modelo de validação também foi testado para analisar a precisão na classificação da intensidade da deposição de mancha púrpura no tegumento, visando distinguir sementes com mancha púrpura de intensidade leve ou severa. Foi utilizado um conjunto de dados composto por 4000 observações, das quais 2640 (66%) foram empregadas no treinamento do modelo, enquanto as 1360 (34%) restantes foram destinadas ao teste propriamente dito. Durante o processo de validação, identificou-se que o atributo relacionado à cor laranja foi o mais responsivo na diferenciação da intensidade de coloração das sementes com mancha púrpura, reforçando sua relevância como classificador cromático preciso, robusto e de alto potencial de aplicabilidade em análise de sementes.

Nesta pesquisa, valores menores ou iguais a 53,71 na intensidade da cor laranja foram associados consistentemente a sementes com mancha púrpura severa, enquanto valores superiores a este se relacionaram predominantemente a mancha púrpura de intensidade leve.

Tabela 5 – Matriz de confusão para classificação de sementes de soja: mancha púrpura leve versus mancha púrpura severa. Brasília-DF, 2023.

N = 1360		Classe real	
		Mancha púrpura leve	Mancha púrpura severa
Classe predita	Mancha púrpura leve	622	58
	Mancha púrpura severa	80	600

Dos 1360 casos analisados, a classe real de mancha púrpura leve foi prevista corretamente 622 vezes, mas também foi erroneamente classificada como mancha púrpura severa em 58 casos. Da mesma forma, a classe real de mancha púrpura severa foi corretamente prevista em 600 casos, porém foi erroneamente classificada como mancha púrpura leve 80 vezes (Tabela 5).

Embora, isoladamente, a acurácia geral na segregação tenha sido maior para identificar apenas presença ou ausência de mancha púrpura na semente (96,4%), um alto grau de confiabilidade também foi observado na separação dos níveis de intensidade (89,8%) leve e severo. A diferenciação entre esses níveis de intensidade foi feita visualmente por um especialista, o que pode introduzir os erros típicos associados a avaliações manuais. Esses erros decorrem principalmente da subjetividade inerente ao julgamento humano, que pode variar significativamente entre diferentes observadores ou mesmo para o mesmo observador em diferentes ocasiões.

Nos últimos anos, tem-se observado avanço significativo nos recursos disponíveis para explorar e validar modelos matemáticos em diversas áreas de pesquisa. Apesar dessa evolução tecnológica, a aplicação dessas técnicas na análise de sementes, especialmente na utilização das cores como preditores de qualidade, ainda é notoriamente sub-representada na literatura científica. A proposta de incorporar características cromáticas na avaliação da qualidade das sementes representa uma metodologia inovadora, que se destaca não apenas pela sua aplicabilidade prática, mas também pela capacidade de amplificar resultados quando combinada com tecnologias emergentes, como inteligência artificial (IA) e aprendizado de máquina.

3.2 Qualidade fisiológica

Observou-se a superioridade germinativa das sementes categorizadas como amarelas (87%) em relação às com mancha púrpura leve (71%) e mancha púrpura severa (45%). Bernardo et al. (2021) também observaram redução nas taxas de germinação e vigor nas sementes de soja quando a mancha púrpura recobre mais de 51% do tegumento da semente.

Sementes com mancha púrpura severa resultaram em plântulas com menor comprimento total (Tabela 6), em relação às com mancha púrpura leve e amarelas. Além disso, essas sementes também apresentaram raízes primárias mais curtas. Morais (2022) também constatou efeito negativo dos sintomas de infecção por *C. kikuchii* sobre o tamanho das plântulas de soja, o qual está relacionado ao vigor das sementes e seu desenvolvimento inicial.

Tabela 6 – Germinação de sementes e tamanho de raiz primária, hipocótilo e comprimento total de plântulas de soja resultantes de sementes com e sem mancha púrpura leve ou severa. Brasília-DF, 2023.

Categoria	Germinação (%)	Raiz primária (cm)	Hipocótilo (cm)	Comprimento (cm)
Amarela	87 a	13,83 a	7,27 a	21,10 a
Mancha púrpura leve	71 b	13,58 a	7,48 a	21,06 a
Mancha púrpura severa	45 c	12,49 b	7,11 a	19,58 b

Médias seguidas pela mesma letra não diferem pelo teste de Tukey a 5% de probabilidade.

Prashant e Patil (2012) evidenciaram redução significativa na germinação das sementes de soja com mancha púrpura em relação às saudáveis. Estes autores também observaram diminuição no teor de óleo e proteína com aumento dos sintomas de mancha púrpura. Venturoso et al. (2008) relataram relação inversa entre a área ocupada pela mancha púrpura no tegumento da semente e sua qualidade fisiológica, concluindo, que, quanto maior a área, menor o índice de velocidade de emergência.

Observou-se diferença significativa no percentual de plântulas anormais entre sementes com e sem mancha púrpura (Tabela 7). Sementes com intensidade severa de mancha púrpura apresentaram o maior índice de plântulas anormais (55%), o que comprova uma qualidade fisiológica inferior em relação àquelas com mancha púrpura

leve (28%) e às amarelas (12%). Pereira et al. (2017) também evidenciaram maior prevalência de plântulas anormais em sementes com sintomas de mancha púrpura.

Tabela 7 – Taxas de plântulas normais, anormais e sementes mortas resultantes do teste germinação em sementes de soja com e sem mancha púrpura leve ou severa. Brasília-DF, 2023.

Categoria	Plântulas normais (%)	Plântulas anormais (%)	Sementes mortas (%)
Amarela	87 a	12 a	1 a
Mancha púrpura leve	71 b	28 b	1 a
Mancha púrpura severa	45 c	55 c	0 a

Médias seguidas pela mesma letra não diferem pelo teste de Tukey a 5% de probabilidade.

Bernardo et al. (2021) observaram que as sementes com maior intensidade visual de manchas púrpuras também apresentaram, predominantemente, fissuras no tegumento, cuja gravidade aumentava proporcionalmente à intensificação das manchas. Castro et al. (2004) corroboraram essa observação, confirmando que fissuras no tegumento causam danos no embrião, podendo resultar na perda de solutos por lixiviação e, conseqüentemente, na redução da massa e viabilidade da semente. Além disso, as lesões no tegumento podem desencadear processos de mobilização de energia na semente, buscando reparar o tecido danificado, o que pode acarretar disponibilidade energética insuficiente para concluir o processo germinativo (CARVALHO e NAKAGAWA, 2000).

Sementes afetadas por mancha púrpura severa também apresentaram menor vigor (50%) e viabilidade (51%) em tetrazólio (Tabela 8), em relação às amarelas ou com mancha púrpura leve.

Em sementes com mancha púrpura severa, os menores índices de vigor e viabilidade podem ser explicados pelos maiores percentuais de dano mecânico (classe 6-8). Esta categoria alcançou uma média de 40% deste tipo de dano, em comparação com 25% para a classe de mancha púrpura leve e 7% para semente amarela (Tabela 8). Pode-se sugerir que a presença de mancha púrpura, devido à maior incidência de fissuras no tegumento, colabora para uma rápida absorção de água, favorecendo que o dano mecânico se manifeste. No entanto, esta inferência

carece de mais estudos para ser confirmada, especialmente, isolando o efeito positivo do pré-acondicionamento para mensuração da qualidade da semente.

Tabela 8 – Taxas de vigor, viabilidade, dano mecânico (DM) e dano por umidade (DU) classe 6-8 por meio do teste de tetrazólio em semente com e sem presença de mancha púrpura. Brasília-DF, 2023.

Categoria	Vigor (%)	Viabilidade (%)	DM 6-8 (%)	DU 6-8 (%)
Amarela	87 a	87 a	7 a	5 a
Mancha púrpura leve	66 b	67 b	25 b	8 a
Mancha púrpura severa	50 c	51 c	40 c	9 a

Médias seguidas pela mesma letra não diferem pelo teste de Tukey a 5% de probabilidade.

Neste trabalho, as sementes foram analisadas sem a adição de tratamento químico, a fim de facilitar a análise de imagem e a caracterização do dano. Em contraste, alguns estudos sugerem que o uso de fungicidas é eficaz para reduzir os índices de infestação por *C. kikuchii* e, conseqüentemente, melhorar o desempenho fisiológico das sementes (CONCEIÇÃO et.al, 2014; PEREIRA et al., 2017) tanto em campo como em análises laboratoriais.

Os resultados desta pesquisa destacam o impacto negativo da mancha púrpura na qualidade fisiológica das sementes de soja e ressaltam a importância de considerar a gravidade da lesão dessa doença na avaliação da qualidade das sementes. Portanto, enfatiza-se a necessidade de métodos que não apenas identifiquem esse tipo de dano, mas também possam avaliar a severidade e a extensão das lesões no tegumento da semente.

A tecnologia de análise de imagem se destaca como uma alternativa promissora para superar as barreiras associadas à classificação manual, proporcionando um método mais exato e objetivo para a avaliação das sementes. Portanto, é imperativo que a implementação e o aprimoramento contínuo dessa tecnologia sejam prioritários nos programas de controle de qualidade.

4. CONCLUSÕES

No modelo de aprendizado de máquina adotado, a cor laranja destacou-se como o critério discriminante mais responsivo, alcançando uma acurácia de 96,4% na árvore de decisão destinada a diferenciar sementes amarela de sementes com mancha púrpura. Uma acurácia menor, contudo, eficiente, de 89,4%, foi alcançada para separação de mancha púrpura em tonalidade leve e severa.

As sementes categorizadas como amarelas demonstraram uma taxa de germinação significativamente mais elevada em comparação às sementes com mancha púrpura leve e severa. Além disso, a severidade influenciou negativamente o vigor, resultando plântulas menores para o grupo com mancha púrpura severa. O decréscimo de qualidade em sementes com mancha púrpura também foi evidenciado por índices reduzidos de viabilidade e vigor, no teste de tetrazólio.

5. REFERÊNCIAS BIBLIOGRÁFICAS

- BERNARDO, A. P. G.; KROHN, N. G.; GOMES, S. de M. S. Germinação e vigor de sementes de soja com níveis de mancha púrpura. **Revista Agronomia Brasileira**. Jaboticabal – SP, v. 5, 2021.
- BRANDANI, Erich Barros et al. Image analysis for the evaluation of soybean seeds vigor. **Acta Agronômica**, v. 70, n. 3, 2021.
- BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. Regras para análise de sementes. Brasília-DF: **Departamento Nacional de Produção Vegetal**, 2009. 399 p.
- CARVALHO, N.M.; NAKAGAWA, J. **Sementes: ciência, tecnologia e produção**. 4. ed. Jaboticabal: FUNEP, 2000. 588p.
- CASTRO, Renato Delmondez; BRADFORD, Kent J.; HILHORST, Henk WM. **Desenvolvimento de sementes e conteúdo de água. Germinação: Do básico ao aplicado** (AG Ferreira e F. Borghetti, eds.). Artmed, Porto Alegre, p. 51-68, 2004.
- CONCEIÇÃO, Gerusa Massuquini et. al. Tratamento químico de sementes de soja: qualidade fisiológica, sanitária e potencial de armazenamento. **Bioscience Journal**, Uberlândia, v. 30, n. 6, p. 1711-1720, 2014.
- E SILVA, Francisco de Assis Santos; DE AZEVEDO, Carlos Alberto Vieira. The Assistat Software Version 7.7 and its use in the analysis of experimental data. **African Journal of Agricultural Research**, v. 11, n. 39, p. 3733-3740, 2016.
- FOLEY, James D. **Computer graphics: principles and practice**. Addison-Wesley Professional, 1996.
- FRANÇA-NETO, José de Barros; KRZYZANOWSKI, Francisco Carlos. **Metodologia do teste de tetrazólio em sementes de soja**. Londrina: Embrapa Soja, 2022. 111 p. (Documentos / Embrapa Soja, ISSN 2176-2937; n. 449).
- GALLI, J. A., PANIZZI, R. C., FESSEL, S. A., SIMONI, F., ITO, M. F. Effect of Colletotrichum dematium var. truncata and Cercospora Kikuchii on soybean seed germination. **Revista Brasileira de Sementes**, Pelotas, v.27, n. 2, p. 182-187, 2005.
- GANESH, P. et al. Deep orange: Mask R-CNN based orange detection and segmentation. **Ifac-papersonline**, v. 52, n. 30, p. 70-75, 2019.
- GARDNER, Max W. Indiana plant diseases, 1924. In: **Proceedings of the Indiana Academy of Science**. 1925. p. 237-258.
- GRIGOLLI, J.F.J. Manejo de doenças na cultura da soja. In: **Doenças da soja, tecnologia e produção**. Fundação MS, p.134-156, 2015.

HARTMAN, G. L. et al. Compendium of soybean diseases and pests 5th ed. **St. Paul, MN. The American Phytopathological Society. pp3**, 2015.

HARTMAN, G. L.; SINCLAIR, J. B.; RUPE, J. C. Rhizoctonia foliar blight (prepared by JS Russin, SR Stetina). **Compendium of Soybean Diseases, 4th ed., St. Paul, MN, USA, The American Phytopathological Society, APS Press**, p. 24-25, 1999.

HENNING, A.A. Patologia e tratamento de sementes: noções gerais. Londrina: Embrapa Soja, 2004. 51p.

JITANAN, Sutasinee; CHIMLEK, Pawat. Quality grading of soybean seeds using image analysis. **International Journal of Electrical and Computer Engineering**, v. 9, n. 5, p. 3495-3503, 2019.

LEE, Jin Hwan et al. Changes occurring in compositions and antioxidant properties of healthy soybean seeds [*Glycine max* (L.) Merr.] and soybean seeds diseased by *Phomopsis longicolla* and *Cercospora kikuchii* fungal pathogens. **Food chemistry**, v. 185, p. 205-211, 2015.

LEHMAN, Samuel George et al. Purple stain of soybean seeds. **Purple stain of soybean seeds.**, n. 369, 1950.

LI, Shuxian et al. Research on purple seed stain of soybean: germplasm screening and genetic resistance. **Germplasm Characteristics, Diversity and Preservation. Nova Science Publisher**, p. 65-77, 2016.

MATSUMOTO, Takashi; TOMOYASU, Ryoichi. Studies on purple speck of soybean seed. **Japanese Journal of Phytopathology**, v. 1, n. 6, p. 1-14_1, 1925.

MORAIS, Thaís Rezende. **Vigor e germinação de sementes de soja com mancha-púrpura**. 2022. 36 p. Dissertação (Mestrado em Proteção de Plantas) – Instituto Federal Goiano, Urutaí, 2022.

MURAKISHI, Harry H. et al. Purple seed stain of Soybean. **Phytopathology**, v. 41, n. 4, 1951.

NINGSIH, Lidya; CHOLIDHAZIA, Putri. Classification Of Tomato Maturity Levels Based on RGB And HSV Colors Using KNN Algorithm. **RIGGS: Journal of Artificial Intelligence and Digital Business**, v. 1, n. 1, p. 25-30, 2022.

OLIVEIRA, J. A. et al. Transmissibilidade e danos causados por *Cercospora kikuchii* em sementes de soja. **Revista Brasileira de Sementes**, v. 15, n. 1, p. 97-100, 1993.

PAULSEN, M. R. et al. Computer image analyses for detection of maize and soybean kernel quality factors. **Journal of Agricultural Engineering Research**, v. 43, p. 93-101, 1989.

PATHAN, M. A. et al. Effects of *Cercospora kikuchii* on soybean seed germination and quality. **Plant disease**, v. 73, n. 9, p. 720-723, 1989.

PEREIRA, Carlos Eduardo et al. Sementes de soja infectadas por *Cercospora kikuchii*, sob déficit hídrico. **Científica**, v. 45, n. 3, p. 295-299, 2017.

PRASANTH, P. Satya; PATIL, P. V. Purple seed stain of soybean-its incidence, effect on seed quality and integrated management. **Indian Phytopathology**, v. 60, n. 4, p. 482-488, 2012.

RIBEIRO, Marco Tulio; SINGH, Sameer; GUESTRIN, Carlos. " Why should i trust you?" Explaining the predictions of any classifier. In: **Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining**. 2016. p. 1135-1144.

SCHUH, W. *Cercospora* blight, leaf spot, and purple seed stain. **Compendium of soybean diseases**, 1999.

TURNER, Richard E. et al. Effects of purple seed stain on seed quality and composition in soybean. **Plants**, v. 9, n. 8, p. 993, 2020.

VELICHETI, R. K. et al. Selective degradation of proteins by *Cercospora kikuchii* and *Phomopsis longicolla* in soybean seed coats and cotyledons. **Plant Disease**, v. 76, n. 8, p. 779-782, 1992.

VENTUROSOSO, L.R.; RANGEL, M.A.S.; SOUZA, F.R.; BERGAMIN, A.C.; CONUS, L.P.; COLETA, Q.P. Influência de diferentes classes de infestação por mancha púrpura sobre o vigor de sementes de soja. **Rev. Bras. Ol. Fibros.**, Campina Grande, v. 12, n. 1, p.41-48, 2008.

WRATHER, J. Allen; KOENNING, Steve R. Estimates of disease effects on soybean yields in the United States 2003 to 2005. **Journal of nematology**, v. 38, n. 2, p. 173, 2006.

CAPÍTULO III

ANÁLISE DE IMAGEM NA AVALIAÇÃO DO RECOBRIMENTO DE SEMENTES DE SOJA TRATADAS INDUSTRIALMENTE COM ADIÇÃO DE PÓ SECANTE

RESUMO

O Tratamento Industrial de Sementes é considerado uma técnica que evoluiu significativamente nos últimos anos, contudo, a resistência do recobrimento da semente aos atritos físicos e mecânicos, inerentes aos processos de beneficiamento, armazenagem, transporte e semeadura, após o tratamento, continua sendo um desafio para a garantia de qualidade do recobrimento. Uma alternativa para avaliar a eficiência do tratamento, é a análise de imagens. Assim, o objetivo desta pesquisa foi analisar os efeitos da aplicação de pó secante em sementes de soja tratadas industrialmente, focado em três aspectos principais: a resistência do recobrimento à abrasão, a eficácia na aplicação do inseticida Dermacor®, e o desempenho das cores conforme avaliado por análise de imagem. Além disso, este estudo buscou desenvolver uma metodologia objetiva para a classificação da qualidade do recobrimento das sementes, baseada em critérios cromáticos. Conduziu-se um delineamento experimental fatorial 3x3 para investigar o efeito de três diferentes concentrações de pó secante (0, 200 e 400 gramas) e três tempos distintos de exposição ao teste de abrasão (0, 12 e 24 minutos) sobre sementes de soja após o tratamento industrial. Foram realizadas 2 repetições de 25 sementes para cada combinação de tratamento na análise de imagem. Para análise de concentração de Dermacor® adotou-se 4 repetições por lote. A aplicação de pó secante no tratamento industrial de soja, na dose de 400 g/100 kg de sementes, melhora a integridade do recobrimento, evidenciada por menor variação de cor e redução na perda do produto Dermacor®, mesmo após abrasividade. Há um comportamento distinto das cores vermelho, rosa e laranja entre sementes tratadas com e sem pó secante; a cor vermelha predominou nas sementes não tratadas, enquanto a rosa, com uma tonalidade perolada, destacou-se nas tratadas. Em lotes tratados com pó secante, a presença da cor laranja é minimizada, permanecendo insignificante mesmo após o processo de abrasão. O índice de Ineficiência do Recobrimento desenvolvido oferece uma métrica objetiva e valiosa como ferramenta complementar no controle de qualidade, permitindo avaliações precisas e imparciais da eficácia dos tratamentos em sementes de soja.

Palavras-chave: qualidade soja; tratamento industrial de sementes; análise de imagem; GroundEye®.

ABSTRACT

The Industrial Treatment of Seeds is considered a technique that has significantly evolved in recent years. However, the resistance of seed coating to the physical and mechanical frictions inherent in processing, storage, transportation, and sowing remains a challenge for ensuring coating quality. One alternative to evaluate the efficiency of the treatment is image analysis. Thus, the objective of this research was to analyze the effects of applying drying powder on industrially treated soybean seeds, focusing on three main aspects: the abrasion resistance of the coating, the efficacy of Dermacor[®] insecticide application, and the performance of colors as evaluated by image analysis. Additionally, this study aimed to develop an objective methodology for classifying the quality of seed coating based on chromatic criteria. A 3x3 factorial experimental design was conducted to investigate the effect of three different concentrations of drying powder (0, 200, and 400 grams) and three distinct exposure times to the abrasion test (0, 12, and 24 minutes) on soybean seeds after industrial treatment. Two repetitions of 25 seeds were performed for each treatment combination in the image analysis. For the Dermacor[®] concentration analysis, four repetitions per lot were adopted. The application of drying powder in the industrial treatment of soybeans, at a dose of 400 g/100 kg of seeds, improves the integrity of the coating, evidenced by less color variation and reduced loss of the Dermacor[®] product, even after abrasiveness. Distinct color behaviors were observed among the red, pink, and orange hues between seeds treated with and without drying powder; red predominated in untreated seeds, while pink, with a pearlescent shade, stood out in treated seeds. In batches treated with drying powder, the presence of the color orange was minimized, remaining insignificant even after the abrasion process. The developed Coating Inefficiency Index offers an objective and valuable metric as a complementary tool in quality control, allowing precise and unbiased evaluations of the effectiveness of treatments on soybean seeds.

Keywords: soybean quality; industrial seeds treatment; image analysis; GroundEye[®].

1. INTRODUÇÃO

O Tratamento Industrial de Sementes (TIS) vem sendo adotado cada vez mais por produtores de sementes, especialmente na cultura da soja, devido aos significativos benefícios que oferece. Destacam-se a precisão na dosagem, a eficácia na cobertura e aderência dos produtos às sementes, e a maior segurança durante a operação. Além disso, o TIS proporciona a conveniência de aquisição de sementes já com a proteção fitossanitária necessária, eliminando a necessidade de tratamentos adicionais pelo agricultor (FRANÇA-NETO et al., 2015; ABATI et al., 2020).

O TIS é considerado uma técnica que evoluiu significativamente nos últimos anos, contudo, a resistência do recobrimento da semente aos atritos físicos e mecânicos, inerentes aos processos de beneficiamento, armazenagem, transporte e semeadura, após o tratamento, continua sendo um desafio para a garantia de qualidade do recobrimento. O desgaste ocasionado pela fricção ou raspagem pode comprometer o aspecto visual do tratamento, e até ocasionar perda de ingrediente ativo dos produtos aplicados, com consequente impacto na eficiência de controle de pragas e/ou doenças que se pretendem controlar.

Mais recentemente, frente aos desafios de aderência dos produtos químicos no tratamento de sementes, o pó secante tem sido adicionado ao processo com o objetivo de melhorar a fixação destes produtos às sementes. O uso de pó secante promove uma secagem rápida e uniforme das sementes, além de proporcionar melhor aparência visual do tratamento. Este aditivo também atua como um agente lubrificante, melhorando significativamente a fluidez das sementes durante a semeadura, o que facilita o processo e apresenta-se como alternativa eficaz ao uso tradicional do grafite (RIBEIRO, 2014).

O controle de qualidade do revestimento de sementes é frequentemente realizado por meio de avaliação visual, na qual o inspetor analisa uma amostra representativa do lote e determina sua adequação para comercialização, baseando-se principalmente na uniformidade da cobertura do tratamento na semente. Apesar de útil e prática, a avaliação visual tem como principal limitação a subjetividade na interpretação dos resultados. Portanto, recomenda-se complementar essa avaliação com técnicas adicionais, tais como análises químicas, que fornecem informações mais

precisas da quantidade de ingrediente ativo e análises de imagem, que podem oferecer uma avaliação mais objetiva e imparcial da qualidade do revestimento.

Entre as técnicas utilizadas para identificar e quantificar elementos químicos destaca-se a Fluorescência de Raios X (XRF, do inglês *X-ray Fluorescence*). Essa técnica consiste na excitação dos átomos de um material através de raios X, provocando a ejeção de elétrons de suas camadas internas, que posteriormente emitem fluorescência ao retornarem ao estado fundamental (MOUAZEN et al., 2005). Adicionalmente, a técnica apresenta a vantagem de ser não destrutiva e não invasiva, possibilitando a análise de amostras sem modificá-las ou danificá-las (MARGUÍ et al., 2014).

Em nível laboratorial, o teste de friabilidade, ou abrasão, tem sido adaptado e aplicado para testar a resistência dos revestimentos aplicados às sementes. Na indústria farmacêutica, a friabilidade é uma medida que indica o grau de suscetibilidade de um comprimido a sofrer danos por fratura ou abrasão (FELL e NEWTON, 1970). A friabilidade pode ser indicativa da resistência e da integridade do revestimento de comprimidos, sendo importante para garantir a robustez do produto durante o manuseio e o transporte (LERK et al., 1979).

Assim, o objetivo desta pesquisa foi analisar os efeitos da aplicação de pó secante em sementes de soja tratadas industrialmente, focado em três aspectos principais: a resistência do recobrimento à abrasão, a eficácia na aplicação do inseticida Dermacor®, e o desempenho das cores conforme avaliado por análise de imagem. Além disso, este estudo buscou desenvolver uma metodologia objetiva para a classificação da qualidade do recobrimento das sementes, baseada em critérios cromáticos.

2. MATERIAL E MÉTODOS

Os experimentos foram realizados em dois departamentos da empresa Corteva Agriscience do Brasil Ltda: o Laboratório de Análise de Sementes, localizado em Brasília-DF, Distrito Federal, e o CSAT (*Center Seeds Applied Treatment*), situado em Formosa, Goiás.

Foram utilizados lotes de sementes de soja de diferentes tamanhos de peneira tratados industrialmente. O tratamento industrial foi executado em tratadora tipo batelada (Figura 1) e operado por profissional devidamente treinado e habilitado para a função.

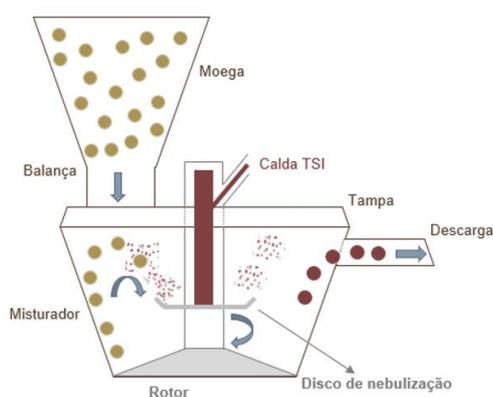


Figura 1 – Representação esquemática do tratador de sementes.

Fonte: Adaptado (MARÇAL, 2021).

Os produtos químicos utilizados no tratamento incluíram fungicida, inseticida, polímero e pó secante (Tabela 1).

Tabela 3 – Produtos aplicados nas sementes de soja, com respectivos produtos comerciais (p.c.), ingredientes ativos e doses utilizadas. Brasília-DF, 2023.

Tipo de produto	Nome comercial	Ingrediente ativo	Dose (p.c. 100 kg ⁻¹ de semente)
Fungicida	Rancona® T	Iprodione	20 mL
Inseticida	Dermacor®	Clorantraniliprole	100 mL
Polímero	Disco AG Red L-322	-	238 mL
Pó secante	Fluidus F-028	-	200 – 400 g

Os lotes de sementes de soja empregados nos experimentos foram previamente caracterizados quanto ao teor de água e massa de mil sementes.

O teor de água dos lotes foi determinado pelo método de estufa a $105 \pm 3^\circ\text{C}$ por 24h (BRASIL, 2009). Foram utilizadas duas amostras de 10 gramas, e os resultados expressos em porcentagem.

A massa de mil sementes, expressa em gramas, foi obtida a partir de oito subamostras de 100 sementes para cada lote (BRASIL, 2009). A partir da massa de mil sementes, procedeu-se ao cálculo da quantidade de sementes por quilograma, utilizando a fórmula apropriada (Equação 1). Para este cálculo a massa de mil sementes foi convertida em quilogramas. Os resultados foram arredondados para o número inteiro mais próximo.

$$\text{Quantidade de sementes. kg} - 1 = \frac{1000 \times 1000}{\text{massa mil sementes}} \quad (1)$$

A segregação, identificação e armazenamento ocorreram de maneira a garantir a correta rastreabilidade das amostras.

2.1 Teste de abrasão – Friabilidade

O equipamento usado para o teste de abrasão foi o friabilômetro modelo 300/2 fabricado pela empresa Ethik® (Figura 2), dotado de dois cilindros rotativos de acrílico transparente, com aproximadamente 280 mm de diâmetro e 38,0 mm de profundidade, que giram em torno de seu eixo a uma velocidade de 25 RPM (± 1 RPM).

Para o teste, uma amostra de 200 gramas de sementes foi colocada no tambor de acrílico do friabilômetro, o qual foi rotacionado a uma velocidade de 25 RPM, por 12 e 24 minutos. A velocidade de rotação e o tempo do teste foram selecionados para simular as condições de estresse que as sementes podem enfrentar durante as etapas do seu ciclo de vida.



Figura 2 – Friabilômetro em operação para o teste de abrasão. Brasília-DF, 2023.

Após a conclusão do teste de abrasividade (12 ou 24 minutos), foram obtidas duas amostras de 25 sementes de cada tratamento, coletada aleatoriamente e segregada para posterior análise de imagem. As amostras do tempo 0, também foram separadas para análise, e definidas como referência, pois representam o estado original das sementes antes de serem submetidas ao teste de abrasão. Logo, as amostras que não sofreram abrasão, serviram como controle para comparações de desempenho antes e após o teste.

2.2 Concentração de Dermacor®

Para a determinação da concentração do produto comercial Dermacor®, foi utilizado o analisador portátil de fluorescência de raios-X (XRF) da marca Olympus, modelo Vanta™ (Figura 3). Esse analisador possui dimensões de 8,3 cm de largura, 28,9 cm de altura e 24,2 cm de comprimento, pesando 1,70 kg. Dotado de tecnologia de detector de deriva de silício (SDD), o Vanta™ proporciona resoluções de pico elevadas, capazes de detectar e quantificar com precisão elementos químicos leves (OLYMPUS, 2023).

O Dermacor[®] pertencente ao grupo químico das diamidas antranílicas, atua por ingestão e proporciona proteção contra pragas de solo e foliares (CORTEVA, 2023). A possibilidade de quantificar o ingrediente ativo do Dermacor[®] através da técnica de XRF decorre da presença de moléculas de bromo em sua composição, permitindo assim uma medição indireta. A estrutura química do ingrediente ativo é representada por: 3-bromo-4'-cloro-1-(3-cloro-2-piridil)-2'-metil-6'-(metilcarbamoil)pirazol-5-carboxanilida.

O teste de XRF foi realizado em aproximadamente 200 gramas de sementes e as amostras foram provenientes do teste de abrasão, conduzido por 12 e 24 minutos. As amostras que não foram submetidas à abrasão, serviram como referência para comparações de desempenho e também foram avaliadas.



Figura 3 – Analisador XRF, modelo Vanta™. Brasília-DF, 2023.

2.3 Análise de imagem através do GroundEye[®]

O GroundEye[®] é uma inovação tecnológica desenvolvida e patenteada pela empresa brasileira *Tbit Tecnologia e Sistemas*, lançado em 2012 com o nome Sistema de Análise de Sementes – SAS[®] e posteriormente renomeado para GroundEye. O GroundEye S800D[®] (Figura 4) é um dos modelos oferecidos como solução para análise de imagens de sementes, plântulas e folhas. Trata-se de um sistema avançado que combina hardware e software, equipado com duas câmeras

fotográficas de alta resolução que capturam imagens da parte superior e inferior de cada objeto analisado. O sistema é capaz de fornecer informações detalhadas sobre a cor, forma, geometria e textura dos objetos analisados.



Figura 4 – GroundEye® S800D.
Fonte: Tbit, 2023.

As imagens de duas repetições de 25 sementes de cada tratamento, foram analisadas individualmente, totalizando 100 imagens por lote. As amostras que sofreram abrasividade por 12 e 24 minutos, foram amostradas após a conclusão do teste.

Cada semente foi posicionada individualmente em uma bandeja de acrílico transparente dentro do equipamento GroundEye® S800D para a obtenção de sua imagem. Essas imagens foram adquiridas utilizando a configuração de câmera padronizada pelo fabricante para garantir a consistência na iluminação e no posicionamento. Os arquivos das imagens estão originalmente no formato PNG, com um tamanho médio de 17KB.

Embora o GroundEye® seja capaz de avaliar uma ampla gama de parâmetros colorimétricos, a presente investigação concentrou-se especificamente nos espaços de cor CIE Lab* e HSV. O espaço de cor CIE Lab* é dividido em três dimensões: L* (luminosidade), a* (variação entre verde e vermelho) e b* (variação entre azul e amarelo). A diferença de cor, no espaço de cores Lab*, pode ser expressa com um

valor único, o ΔE^*_{ab} , o qual é uma medida tridimensional que combina diferenças em luminosidade (L^*), vermelho/verde (a^*), e azul/amarelo (b^*) em um valor escalar que indica o grau de diferença de cor percebida (MACDONALD et al, 2002; MALACARA, 2003). Usando os dados de Lab^* extraídos do relatório do software GroundEye® realizou-se o cálculo da diferença total de cor (Equação 2) para os tempos de 12 e 24 minutos pós abrasão, sendo as sementes sem abrasão consideradas as referências para efeito dos cálculos das diferenças de Lab^* .

$$\Delta E^*_{ab} = \sqrt{(\Delta L^*)^2 + (\Delta a^*)^2 + (\Delta b^*)^2} \quad (2)$$

O HSV (*Hue, Saturation, Value*) é um modelo de cores que representa as tonalidades de forma circular, em que o ângulo representa a cor (matiz), a saturação é a intensidade da cor, e o valor indica a luminosidade. Através dos parâmetros de matiz, saturação e valor, é possível estabelecer valores mínimos e máximos para cada faixa de cor, classificando-a numericamente. A expressão de cores representa o percentual de uma determinada cor em uma faixa específica (Tabela 2).

Tabela 4 – Expressão de cores no espaço HSV. Brasília-DF, 2023.

Cor	Parâmetros de cálculo ¹
Preta	(V ≤ 0.25)
Cinza escuro	(V ≤ 0.25) E (V ≤ 0.60) E (S ≤ 0.20)
Cinza clara	(V > 0.60) E (V ≤ 0.90) E (S ≤ 0.20)
Vermelha	(H > 345) OU (H ≥ 0) E (H ≤ 15) E (S > 0.10) E (V > 0.25)
Laranja	(H ≤ 45) E (H > 15) E (S > 0.10) E (V > 0.25)
Amarela	(H ≤ 75) E (H > 45) E (S > 0.10) E (V > 0.25)
Oliva	(H ≤ 105) E (H > 75) E (S > 0.10) E (V > 0.25)
Verde	(H ≤ 135) E (H > 105) E (S > 0.10) E (V > 0.25)
Turquesa	(H ≤ 165) E (H > 135) E (S > 0.10) E (V > 0.25)
Ciano	(H ≤ 195) E (H > 165) E (S > 0.10) E (V > 0.25)
Celestial	(H ≤ 225) E (H > 195) E (S > 0.10) E (V > 0.25)
Azul	(H ≤ 225) E (H > 225) E (S > 0.10) E (V > 0.25)
Púrpura	(H ≤ 285) E (H > 255) E (S > 0.10) E (V > 0.25)
Magenta	(H ≤ 315) E (H > 285) E (S > 0.10) E (V > 0.25)
Rosa	(H ≤ 345) E (H > 315) E (S > 0.10) E (V > 0.25)
Branca	(V > 0.90) E (S ≤ 0.10)

¹ Em que, H é o canal matiz, S é o canal saturação e V é o canal valor do espaço de cores HSV.

2.4 Delineamento experimental

Conduziu-se um delineamento experimental fatorial 3x3 para investigar o efeito de três diferentes concentrações de pó secante (0, 200 e 400 gramas) e três tempos distintos de exposição ao teste de abrasão (0, 12 e 24 minutos) sobre sementes de soja após o tratamento industrial. Foram realizadas 2 repetições de 25 sementes para cada combinação de tratamento na análise de imagem. Para análise de concentração de Dermacor® adotaram-se 4 repetições por lote.

No estudo, utilizaram-se dez lotes de sementes, dos quais foram extraídas duas repetições, cada uma composta por 25 sementes, para a análise de imagem. Como o GroundEye® S800D permite a captura de imagens tanto da parte superior como da inferior, cada repetição do teste resultou em 50 imagens. Assim, cada tratamento originou um conjunto de 2000 imagens, ou seja, 100 imagens por lote, multiplicado por duas repetições e dez lotes. No total, isto resultou em um conjunto de dados de 18.000 imagens, considerando os 9 tratamentos.

Para a análise de concentração de Dermacor® cada lote foi testado em XRF 3 vezes: 0 minutos (sem abrasão), 12 e 24 minutos, acarretando 360 resultados.

Realizou-se uma análise de componentes principais para definir quais cores influenciam mais significativamente na avaliação dos dados obtidos através das imagens. Essa análise possibilitou a identificação dos componentes principais que melhor descrevem a variabilidade dos dados em função dos tratamentos aplicados.

3. RESULTADOS E DISCUSSÃO

A umidade das amostras variou entre 9,1 a 9,7%, na faixa ideal para a conservação de sementes de soja, entre 8 e 10%. Neste nível, a atividade metabólica é minimizada, preservando a qualidade fisiológica das sementes durante o armazenamento (ELLIS e HONG, 2007).

Na Tabela 3, são apresentados os resultados referentes à massa de mil sementes e à quantidade de sementes por quilograma dos diferentes lotes do estudo, considerando as diferentes doses de pó secante (0, 200 e 400 g/100 kg de sementes).

Tabela 3 – Massa de mil sementes e quantidade de sementes por quilograma de diferentes lotes de sementes de soja tratados industrialmente com e sem pó secante. Brasília-DF, 2023.

Lote	Dose pó secante (g.100 kg ⁻¹)		
	0g	200g	400g
Massa de mil sementes (g)			
1	141,0 a	142,6 bc	183,0 b
2	142,7 a	140,5 bc	181,2 b
3	143,1 a	175,9 a	184,8 ab
4	138,9 a	174,5 a	187,4 a
5	142,9 a	172,7 a	141,1 cd
6	176,6 b	174,9 a	133,4 e
7	175,8 b	175,3 a	187,3 a
8	178,8 b	143,5 b	137,8 d
9	177,6 b	142,9 bc	139,1 d
10	180,5 b	138,6 c	144,2 c
F	83,78	351,44	913,84
CV (%)	11,82	10,64	14,39
Quantidade de sementes.kg-1			
1	7102 a	7014 a	5466 a
2	7014 a	7118 ab	5519 d
3	7020 a	5688 c	5411 de
4	7208 a	5732 c	5337 e
5	6999 a	5719 c	7095 bc
6	5664 b	5705 c	7501 a
7	5689 b	5705 c	5339 e
8	5593 b	6969 b	7260 b
9	5632 b	6996 b	7189 b
10	5542 b	7215 a	6936 c
F	68,61	301,82	706,01
CV (%)	11,98	10,68	14,48

Médias seguidas pela mesma letra não diferem pelo teste de Tukey a 5% de probabilidade.

A recomendação de dose para o tratamento industrial de soja é estabelecida pela relação entre a massa e o tipo de produto a ser aplicado, inseticida, fungicida, polímero e pó secante (Tabela 1). Esta orientação segue as doses recomendadas pelos fabricantes e as instruções nas bulas dos produtos. Em contraste, variações significativas na massa de mil sementes e no número de sementes por quilograma foram identificadas nesta pesquisa (Tabela 3). Oliveira (2016), ao trabalhar com milho doce, destacou a importância do ajuste das doses do tratamento industrial de sementes ao número de sementes, o que é justificado pelas diferenças observadas no número de sementes por quilograma entre lotes com peneiras de tamanhos distintos.

A relação entre a massa de mil sementes e o número de sementes por quilograma é inversamente proporcional (Tabela 3), assim lotes com menor massa de mil sementes apresentam maior número de sementes por quilograma. Além disso, a massa da semente está diretamente relacionada ao seu tamanho. Portanto, aplicar a mesma quantidade de calda a diferentes tamanhos de sementes pode resultar em cobertura desuniforme da superfície das mesmas.

De acordo com Anderson et. al (2014), a dose de pó secante aplicada às sementes é restringida pela capacidade de aderência do pó às sementes, variando de 0,06% a 1,0% da massa da semente. A taxa de aplicação é inversamente proporcional ao tamanho da semente; ou seja, a quantidade de pó retida aumenta à medida que o tamanho da semente diminui, em razão do aumento proporcional da área superficial nas sementes menores.

Para superar essa limitação, é essencial desenvolver métodos de aplicação de tratamento que considerem o número real de sementes por quilograma e ajustem o volume de calda de tratamento baseado neste critério. Isso garante que cada semente receba uma quantidade de produto proporcionalmente adequada para sua superfície, maximizando a eficácia do tratamento e melhorando a uniformidade da proteção oferecida.

No processo de recobrimento de sementes, a uniformidade da aplicação é um parâmetro crítico de qualidade. Uma das maneiras de se medir a uniformidade é através da diferença de cor entre a área coberta e um padrão de cor ideal (referência). Quando o recobrimento é aplicado de maneira uniforme, espera-se que a diferença de cor ΔE , seja minimizada. Por outro lado, valores elevados de ΔE podem sinalizar

inconsistências na aplicação, como áreas de sub-recobrimento ou de recobrimento excessivo.

A variação total de cor (ΔE^*ab) foi mais acentuada para os lotes tratados com 200g de pó secante submetidas a 12 minutos de abrasão e ainda mais elevada após 24 minutos de abrasão, representando 4,60 e 5,14, respectivamente; logo, eles são visualmente mais distantes do lote original, que não sofreu abrasão (Tabela 4 e Figura 5). Esses resultados indicam que a aplicação de 200 gramas de pó secante pode resultar em uma percepção mais desuniforme da coloração do produto. Isso sugere que, embora essa dose seja recomendada na bula, ela parece não apropriada para alcançar melhor homogeneidade de cobertura.

A menor variação de cor foi registrada nos lotes que receberam 400 g de pó secante e foram expostos a 12 minutos de abrasão, com 3,19 de diferença total de cor. Esse resultado evidencia a eficácia desse tratamento em preservar a integridade do recobrimento mesmo após um processo físico de abrasividade. Entre os períodos de 12 e 24 minutos, nota-se que o menor aumento médio na diferença de cor ocorreu com a dose de 400 g de pó secante, registrando um incremento de 0,48. Em contraste, observou-se aumento significativo nos lotes que não receberam pó secante, com um incremento de 1,09, indicando que sua resistência à abrasão é inferior em comparação aos lotes tratados com pó secante.

Tabela 4 –Diferença total de cor (ΔE^*ab) para sementes de soja tratadas com e sem adição de pó secante, submetidas posteriormente a diferentes tempos de abrasão. Brasília-DF, 2023.

Dose pó secante (g.100kg-1)	Abrasão (min)	ΔE^*ab	Incremento ¹
0	12	3,07 e	1,09
	24	4,16 c	
200	12	4,60 b	0,54
	24	5,14 a	
400	12	3,19 e	0,48
	24	3,67 d	
F		17,67	
CV (%)		66,21	

Médias seguidas pela mesma letra não diferem pelo teste de Tukey a 5% de probabilidade.

¹ Incremento = diferença entre o tempo 24 e 12 minutos de abrasão para média de ΔE^*ab .

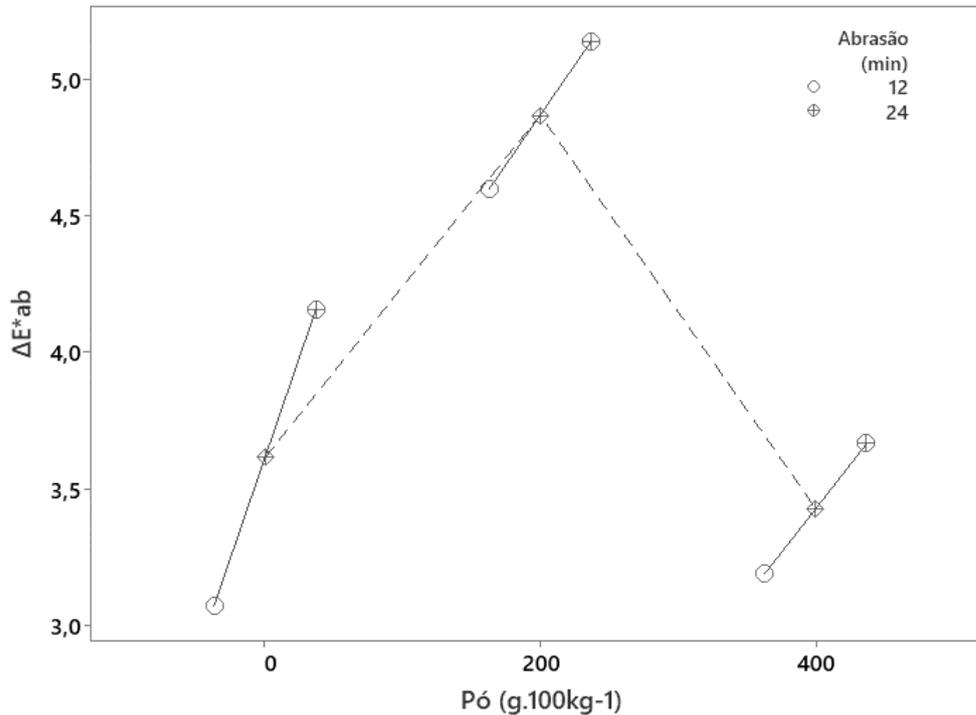


Figura 5 – Diferença total de cor entre sementes de soja após 12 e 24 minutos de abrasão em diferentes doses de pó secante. Brasília-DF, 2023.

O uso das variáveis do espaço de cor CIE Lab* em aplicações de análise de qualidade tem sido destacado na literatura como ferramenta objetiva que confere maior confiabilidade na tomada de decisão. Por exemplo, Mazzuz (1996) utilizou as coordenadas Lab* para avaliar a coloração em beterrabas cortadas em diferentes espessuras. Moura et al. (2007) aplicaram leituras objetivas de L*, a* e b* para prever a vida de prateleira de maçãs desidratadas. Vilhalva et al. (2012) empregaram essas coordenadas para medir a diferença total de cor (ΔE) em cascas de mandioca sob diferentes métodos de secagem. Kim et al. (2023) destacaram a utilidade do espaço de cor CIE Lab* na melhoria da segmentação de imagens de dossel de cebola e alho capturadas por drones.

Embora o ΔE^*_{ab} ofereça uma medida quantitativa da diferença entre duas cores, ele não especifica a natureza dessa diferença cromática. Neste sentido, as diferenças entre os tratamentos podem ser melhor compreendidas através das distinções de cores propostas pelo espaço de cor HSV (Tabela 2). Por exemplo, a cor vermelha captura matizes que incluem os extremos do círculo cromático, de 345 a 360 graus e de 0 a 15 graus. Essa ampla gama permite cobrir desde os tons mais intensos até os mais pálidos de vermelho. Em contraste, o rosa é definido por um intervalo mais

restrito, de 315 a 345 graus, situando-se entre o vermelho intenso e as cores mais frias, conferindo-lhe uma característica visualmente mais suave. Por outro lado, o laranja, situado entre 15 e 45 graus, serve como uma transição cromática entre o vermelho vibrante e o amarelo luminoso, enriquecendo a paleta de cores com uma tonalidade que equilibra a intensidade do vermelho com a vivacidade do amarelo (WYSZECKI e STILES, 2000; FAIRCHILD, 2013).

As cores vermelha, rosa e laranja foram as variáveis de maior resposta, conforme observado na análise de componentes principais (Figura 6). Isso indica que estas cores são as principais influenciadoras na variação dos dados de coloração das sementes, sugerindo que mudanças ou variações nessas tonalidades são mais impactantes para a caracterização das amostras. Esta seleção foi estrategicamente utilizada para a caracterização colorimétrica no presente estudo. Tal escolha está em consonância com as observações visuais das sementes tratadas, que destacam a predominância dos tons de vermelho e rosa, além da cor laranja, especialmente em casos de ausência ou menor intensidade de revestimento nas sementes.

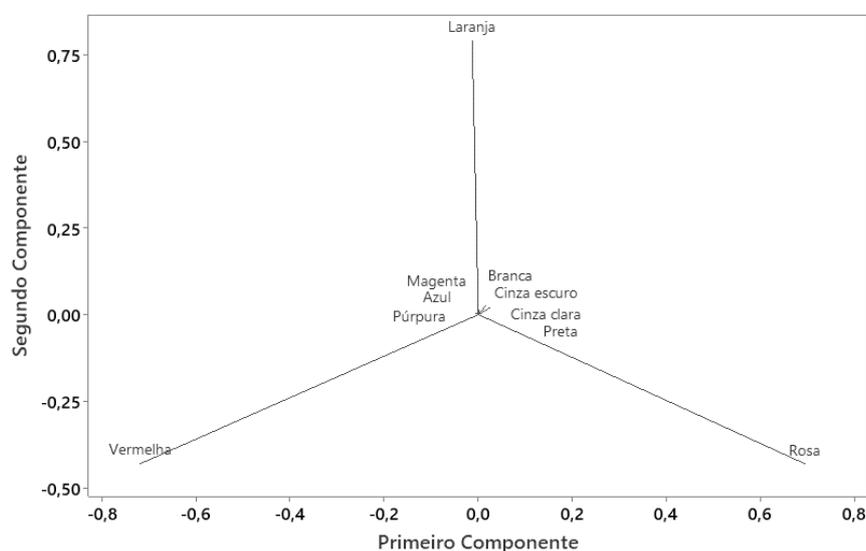


Figura 6 – Análise de componentes principais para diferentes cores do espaço de cor HSV. Brasília-DF, 2023.

A análise dos dados revela diferenças estatísticas significativas nas colorações vermelha, rosa e laranja entre os diferentes tratamentos (Tabela 5). Nos lotes sem pó secante na calda de tratamento, a cor vermelha mostra-se mais expressivamente, com uma média de 79,74% após 24 minutos de abrasão. Por outro lado, nos lotes tratados com pó secante, nota-se uma diminuição acentuada nesta coloração: os

valores médios do componente vermelho reduziram para 54,29% e 24,09% nas doses de 200 e 400 g/100 kg, respectivamente, também após 24 minutos de abrasão.

Tabela 5 – Concentração das cores vermelha, rosa e laranja em resposta à abrasão e variação na concentração de pó secante em sementes de soja tratadas industrialmente. Brasília-DF, 2023.

Dose pó secante (g.100 kg ⁻¹)	Abrasão (min)	Vermelha	Rosa	Laranja
		----- % -----		
0	0	85,55 a	7,05 g	0,05 c
	12	83,28 b	7,54 g	1,48 b
	24	79,74 c	7,49 g	5,04 a
200	0	79,74 d	25,55 f	0,03 c
	12	65,77 e	36,25 e	0,02 c
	24	54,29 f	39,81 d	0,03 c
400	0	37,01 g	53,18 c	0,01 c
	12	26,37 h	63,89 b	0,01 c
	24	24,09 i	65,52 a	0,01 c
F		77,4	171,4	329,4
CV (%)		48,0	76,8	535,9

Médias que não compartilham uma letra são significativamente diferentes, de acordo com o teste de Tukey a 5% de probabilidade.

A variação na tonalidade rosa demonstra resposta distinta às diferentes doses de pó secante e aos tempos de abrasão analisados. Sementes não tratadas com pó secante apresentaram os menores índices de cor rosa, e a abrasão não modificou significativamente essa proporção, com média de 7,49% após 24 minutos de abrasão. Por outro lado, a adição de pó secante resultou em aumento dessa tonalidade: para a dose de 200 g/100 kg, a proporção de rosa era de 25,55% antes da abrasão, aumentando para 39,81% após 24 minutos de abrasão, o que representa um incremento de 14,26%. Similarmente, na dose de 400 g/100 kg, a média inicial de cor rosa foi de 53,18%, subindo para 65,52% após o mesmo período de abrasão, um aumento de 12,34%.

A cor laranja mostra um comportamento distinto nos dados analisados. Nos lotes que não receberam pó secante, observa-se uma variação significativa dessa tonalidade com aumento do tempo de abrasão. Inicialmente quase imperceptível, com uma média de 0,05% sem abrasão, a intensidade da cor laranja cresce para 1,48% após 12 minutos e atinge 5,04% após 24 minutos de abrasão. Esse resultado é

visualmente perceptível e corrobora a hipótese de que a incorporação de pó secante ao tratamento de sementes pode mitigar a perda de cobertura, mantendo a uniformidade colorimétrica da superfície tratada. A presença de cor laranja em sementes tratadas é considerada indesejável, visto que é frequentemente associada a um tratamento inadequado, podendo afetar a percepção de qualidade do produto.

As sementes não expostas a pó secante exibiram predominantemente uma tonalidade vermelha, enquanto aquelas submetidas ao tratamento com pó secante adquiriram coloração rosada, frequentemente descrita de maneira empírica como “perolada” (Tabela 5). Tal nomenclatura é utilizada para caracterizar o aspecto visual peculiar conferido pelo recobrimento com pó secante.

Conforme discutido, a diferença total de cor foi mais acentuada nos lotes sem pó secante e submetidos à abrasão. Essa maior variação pode ser atribuída ao aumento significativo da cor laranja, que também está associada a este tratamento. Assim, observa-se que o tratamento de sementes com pó secante resultou em menor diferença total de cor entre as amostras padrão (sem abrasão) e as submetidas à abrasividade (12 e 24 minutos), o que pode ser parcialmente explicado pelo menor índice da cor laranja desses grupos.

A distribuição cromática das cores vermelho, rosa e laranja ilustra um aumento na dominância da cor laranja em lotes não tratados com pó secante após 12 e 24 minutos de abrasão. Em contraste, nos lotes tratados com pó secante, a presença da cor laranja permanece insignificante e imperceptível mesmo após abrasão, o que destaca o efeito positivo deste aditivo associado ao tratamento industrial das sementes (Figura 7).



Figura 7—Imagens de sementes de soja submetidas a diferentes doses de pó secante e diferentes tempos de abrasão. Brasília-DF, 2023.

Além disso, o pó secante pode atuar como lubrificante para melhorar a fluidez das sementes, reduzindo a fricção entre elas na semeadora, proporcionando um plantio mais uniforme (TAYLOR, 2003) e diminuindo a necessidade de aplicação de

grafite durante operação de semeadura (BORGES et al., 2023). Ainda, de acordo com Borges et al. (2023), o pó secante acelera o processo do tratamento, previne a formação de aglomerados durante o ensaque e promove melhora significativa na aparência visual das sementes tratadas. Buffington et al. (2018) acrescentam, ainda, que o pó secante ao atuar como lubrificante reduz o atrito das sementes na passagem pelo tratador.

Andrade et al. (2024), usando o sistema GroundEye®, investigaram a eficiência de ferramentas de inteligência artificial na análise da qualidade do revestimento de sementes de soja submetidas a tratamento químico. A quantificação do revestimento das sementes foi realizada somando as porcentagens das características de dominância de cor vermelha e rosa detectadas nas sementes, o que possibilitou criar uma escala diagramática para a avaliação visual da quantidade e qualidade do revestimento. A pesquisa confirmou que o uso de ferramentas de inteligência artificial é eficiente para avaliar a qualidade do revestimento das sementes tratadas, proporcionando melhoria significativa na precisão e padronização das avaliações visuais, o que facilita uma tomada de decisão mais rápida e segura.

No tocante à distribuição individual da soma das cores vermelha e rosa para os diferentes tratamentos e suas respectivas diferenças de médias, observa-se que a queda da soma dessas duas cores é maior para os lotes sem adição de pó secante ao tratamento, em contraste aos lotes que receberam pó secante nas doses de 200 e 400 g/100 kg de sementes (Figura 8).

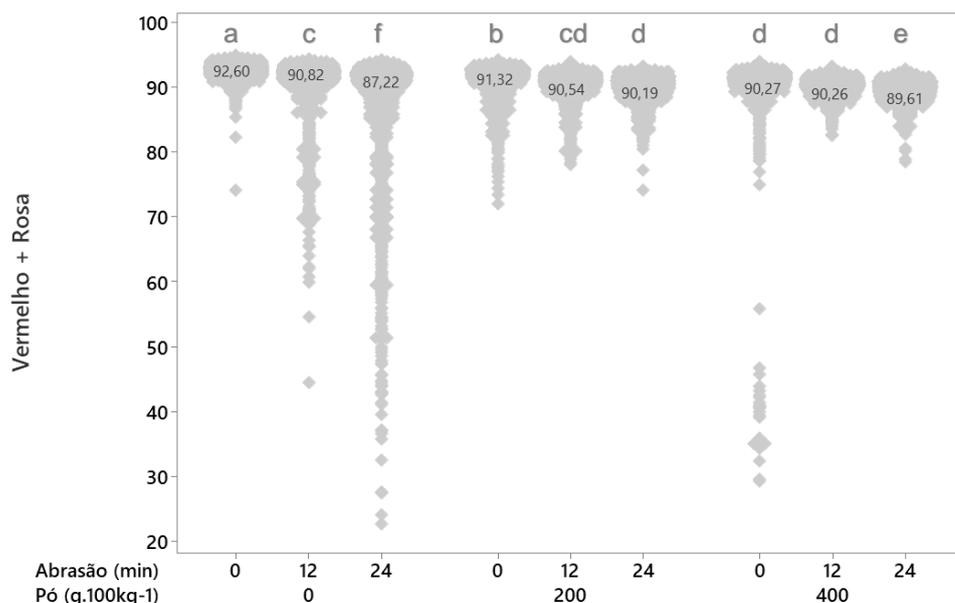


Figura 8 – Valores individuais da soma das cores vermelha e rosa para lotes de soja submetidos ou não a pó secante em diferentes tempos de abrasão. Brasília-DF, 2023. Médias seguidas pela mesma letra não diferem pelo teste de Tukey a 5% de probabilidade.

O pó secante, composto por mica revestida com dióxido de titânio e talco natural de cloreto, contribuiu significativamente para a melhoria da qualidade visual das sementes devido às propriedades físico-químicas de seus componentes. O talco, com sua capacidade hidrofílica, promove absorção e secagem rápidas, reduzindo manchas e aglomerações (CLIFTON, 1985). A mica revestida com dióxido de titânio, por sua vez, é um material compósito que reúne a robustez mecânica e isolamento da mica com a alta refração e resistência à degradação ultravioleta do dióxido de titânio. Esse revestimento é utilizado para melhorar a durabilidade e funcionalidade de produtos em diversas indústrias, como cosméticos, pinturas, revestimentos e materiais plásticos (SHI et al., 2013), apresenta mais recentemente novas aplicações no tratamento químico de sementes.

Nesta pesquisa, através da técnica de análise de imagem, comprovou-se que as cores vermelha e rosa foram associadas a um recobrimento mais uniforme da superfície da semente, enquanto a cor laranja indicou uma cobertura parcial ou ausente. Assim, para expressar quantitativamente a ineficiência do recobrimento, desenvolveu-se uma métrica baseada na prevalência dessas cores (Equação 6).

$$\text{Ineficiência do recobrimento} = [100 - (\text{Vermelho} + \text{Rosa}) - (0,5 \times \text{Laranja})] \quad (6)$$

A aplicação dessa fórmula nos resultados experimentais demonstrou ser um indicador eficiente para avaliar a qualidade do recobrimento (Tabela 6), sugerindo que essa técnica pode ser adotada como ferramenta no controle de processos na indústria sementeira. A diferença média entre a ausência de abrasão e 24 minutos de abrasão foi significativamente maior para sementes sem pó secante, com aumento de 2,88 no índice de ineficiência do recobrimento. Nos lotes tratados com pó secante nas doses de 200 e 400 g/100kg de sementes as diferenças médias foram 1,13 e 0,66, respectivamente, o que corrobora os efeitos positivos do pó secante na qualidade e uniformidade de recobrimento de sementes de soja.

Tabela 6 – Média da Ineficiência do Recobrimento para diferentes concentrações de pó secante e tempos de abrasão no tratamento industrial de sementes de soja. Brasília-DF, 2023.

Abrasão (min)	Dose pó secante (g.100kg ⁻¹)		
	0	200	400
12	8,44 +	9,45 +	9,74 ^{ns}
24	10,26 +	9,79 +	10,39 +
0 (testemunha)	7,38	8,67	9,72
Diferença de médias (24 – 0)	2,88 *	1,13 *	0,66 *

^{ns} Não significativo, pelo teste de Dunnett, em nível de 5% de probabilidade;

+ Significativo e superior a testemunha, pelo teste de Dunnett, em nível de 5% de probabilidade.

* p≤0,05

A partir do índice proposto é possível criar critérios de tolerância de um processo, a fim de aceitar ou não variações que não comprometam a percepção visual da semente e a qualidade do tratamento. Esse procedimento pode ser realizado considerando o percentual de sementes com ineficiência de recobrimento em um mesmo lote. Pode-se, por exemplo, adotar uma amostra representativa de 200 sementes por lote e definir que todas aquelas que apresentarem um índice de ineficiência de recobrimento superior a 10% representam uma unidade defeituosa. Entretanto, este estudo não aprofundou no desenho de um processo analítico, se reservando ao trabalho de construir uma variável matemática objetiva para avaliação da qualidade do recobrimento.

O índice de Ineficiência do Recobrimento pode suportar melhores tomada de decisão, como reprovação e retratamento. Além disso, com base em métrica objetiva é possível monitorar o processo comparativamente entre lotes, tipo de tratamento e outras variáveis, acompanhando a qualidade do tratamento com maior rigor e baseada em dados.

Nos períodos de abrasão de 12 e 24 minutos, as concentrações de 200 e 400 g/100 kg de pó secante não diferiram significativamente da testemunha (sem abrasão) em relação à concentração de Dermacor® nas sementes (Tabela 7). No entanto, para o tempo de 24 minutos, os lotes que não foram tratados com pó secante apresentaram redução significativa na média, inferior à da testemunha. Este resultado implica uma perda média de 4,25% na concentração do produto químico Dermacor® nas sementes, sem adição de pó secante e submetidas a 24 minutos de abrasão.

Tabela 7 – Concentração de Dermacor® em sementes de soja tratadas industrialmente em resposta à abrasão e concentração de pó secante. Brasília-DF, 2023.

Abrasão (min)	Dose pó secante (g.100 kg ⁻¹)		
	0	200	400
12	88,58 ^{ns}	83,64 ^{ns}	89,14 ^{ns}
24	86,69 ⁻	83,49 ^{ns}	87,27 ^{ns}
0 (testemunha)	90,94	87,30	90,59
Diferença de médias (24 – 0)	4,25 [*]	3,81	3,32

ns Não significativo, pelo teste de Dunnett, em nível de 5% de probabilidade;

- Significativo e inferior a testemunha, pelo teste de Dunnett, em nível de 5% de probabilidade.

* p≤0,05

A eficiência do pó secante na melhor adesão do produto químico, pós processos abrasivos também foi discutida por Del Bem Júnior (2017) em sementes de soja, concluindo que as tratadas com polímero e pó secante apresentaram menor desprendimento de thiametoxam após o teste de abrasão, além de melhor fluidez.

O tratamento de semente também é beneficiado pelo uso de polímeros. O recobrimento com fungicidas, micronutrientes e polímeros resulta em sementes com boa aparência, aderência, distribuição e coloração (PEREIRA et al., 2007; BAYS et al., 2007; LEVIEN et al., 2008). Avelar et al. (2012) constataram que o revestimento de sementes com polímeros em tratamento de sementes de milho melhora a capacidade de semeadura, reduz a formação de poeira e minimiza a lixiviação de inseticidas.

O presente trabalho corrobora os resultados quanto à melhora da aparência visual das sementes e à aderência dos produtos com o uso de polímeros. Além disso, acrescenta o pó secante como um potencializador desses efeitos já experimentados com o uso de polímeros, ressaltando a eficácia dessa combinação no tratamento de sementes.

Reis et al. (2023) observaram que o tratamento industrial de sementes de soja garante melhor revestimento de sementes, maior eficácia da dose, menos desprendimento de partículas e menor ocorrência de danos mecânicos em comparação com a tecnologia de aplicação na fazenda (*on-farm*). Eles também ressaltaram que processamento digital de imagens de alta resolução é eficiente para quantificar o revestimento de sementes de soja por produtos fitossanitários. A qualidade do revestimento está diretamente relacionada à eficácia da dose.

Diversos estudos têm demonstrado que a análise de imagem é uma ferramenta eficaz para avaliar características físicas de sementes de várias culturas, proporcionando uma caracterização detalhada que inclui aspectos como cor, geometria, textura e tamanho. Por exemplo, Lima et al. (2018) trabalharam com sementes de paricarana (*Bowdichia virgilioides* Kunth), caracterizando-as de acordo com as variações de coloração do tegumento. Por sua vez, Xavier et al. (2019) diferenciaram espécies de *Amaranthus* spp., baseando-se nas características geométricas e na predominância de cores. Estes achados corroboram as descobertas deste estudo, destacando o amplo campo de aplicação da análise de imagem oferece para avaliações de controle de qualidade, como técnica não destrutiva, objetiva, precisa e rápida.

Esta pesquisa concentrou-se na avaliação da qualidade de recobrimento das sementes, utilizando métodos como resistência à abrasão, análise de imagem e análise química. No entanto, é fundamental destacar que aspectos importantes como plantabilidade e geração de pó não foram abordados neste estudo, indicando a necessidade de investigações futuras para avaliar a influência do uso de pó secante nessas variáveis. Além disso, há evidências de que a aplicação de pó secante pode reduzir a germinação e o vigor das sementes (ABATI et al., 2018), o que reforça a necessidade de futuros estudos acerca do efeito de pó secante nas qualidades física e fisiológica de sementes.

4. CONCLUSÕES

A aplicação de pó secante no tratamento industrial de soja, na dose de 400 g/100 kg de sementes, melhora a integridade do recobrimento, evidenciada por menor variação de cor e redução na perda do produto Dermacor®, mesmo após abrasividade.

Há um comportamento distinto das cores vermelho, rosa e laranja entre sementes tratadas com e sem pó secante; a cor vermelha predominou nas sementes não tratadas, enquanto a rosa, com uma tonalidade perolada, destacou-se nas tratadas. Em lotes tratados com pó secante, a presença da cor laranja é minimizada, permanecendo insignificante mesmo após o processo de abrasão.

O índice de Ineficiência do Recobrimento desenvolvido oferece uma métrica objetiva e valiosa como ferramenta complementar no controle de qualidade, permitindo avaliações precisas e imparciais da eficácia dos tratamentos em sementes de soja.

5. REFERÊNCIAS BIBLIOGRÁFICAS

ABATI, J. et al. Physiological potential of soybean industrially treated with different spray volumes and dry powder. **Australian Journal of Crop Science**, v. 14, n. 5, p. 836-841, 2020.

ANDERSON, D. **Talc and graphite: what you need to know before you plant machinery**. AgWeb J. 2014.

AVELAR, Suemar Alexandre Gonçalves et al. The use of film coating on the performance of treated corn seed. **Revista Brasileira de Sementes**, v. 34, p. 186-192, 2012.

BAYS, Rodrigo et al. Soybean seed coating with micronutrients, fungicide and polymer. **Revista Brasileira de Sementes**, v. 29, p. 60-67, 2007.

BORGES, C. T.; FRANCO, J. J.; MENEGHELLO, G. E. Tratamento de sementes de soja e sua influência na qualidade fisiológica. **Gestão dos processos para produção de sementes: Do campo a pós-colheita**, p. 108, 2023.

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. Regras para análise de sementes. Brasília-DF: **Departamento Nacional de Produção Vegetal**, 2009. 399 p.

BUFFINGTON, B.; BEEGLE, D.; LINDHOLM, C. Seed Treatment a National Pesticide Applicator Manual. **Pesticide Educational Resources Collaborative (PERC), University of California Davis: Davis, CA, USA**, 2018.

CLIFTON, R.A. Talc and pyrophyllite. Washington: **Bureau of Mines**, 5 p, 1985. (Bulletin 675).

CORTEVA. **Dermacor**. Disponível em: <https://www.corteva.com.br/produtos-e-servicos/protacao-de-cultivos/dermacor.html>. Acesso em 10 mar. 2023.

ANDRADE, Dayliane Bernardes et al. Artificial intelligence tools and a diagrammatic scale for evaluating the quality of coating in treated soybean seeds. **Neural Computing and Applications**, v. 36, n. 6, p. 3101-3106, 2024.

DEL BEM JUNIOR, Luciano. **Avaliação qualitativa de métodos de tratamento de sementes de soja**. Botucatu: Universidade Estadual Paulista, 2017, 68p. Dissertação de Mestrado.

LIMA, J. M. et al. TÉCNICAS DE ANÁLISE DE IMAGEM PARA CARACTERIZAÇÃO DA QUALIDADE DE SEMENTES DE PARICARANA (*Bowdichia virgilioides* Kunth). **Ciência Florestal (01039954)**, v. 28, n. 3, 2018.

FAIRCHILD, Mark D. **Color appearance models**. John Wiley e Sons, 2013.

FELL, J. T.; NEWTON, J. M. Determination of tablet strength by the diametral-compression test. **Journal of pharmaceutical sciences**, v. 59, n. 5, p. 688-691, 1970.

FRANÇA-NETO, J. B. et al. Adoção do tratamento industrial de sementes de soja no Brasil, safra 2014/15. Trabalhos técnicos – **Informativo ABRATES**, Londrina, v. 25, n.1, p. 26-29, 2015.

ELLIS, R. H.; HONG, T. D. Seed longevity–moisture content relationships in hermetic and open storage. **Seed Science and Technology**, v. 35, n. 2, p. 423-431, 2007.

KIM, DW. et al. Growth monitoring of field-grown onion and garlic by CIE L* a* b* color space and region-based crop segmentation of UAV RGB images. **Precision Agriculture**, v. 24, n. 5, p. 1982-2001, 2023.

LERK, C. F.; BOLHUIS, G. K.; DE BOER, A. H. Effect of microcrystalline cellulose on liquid penetration in and disintegration of directly compressed tablets. **Journal of Pharmaceutical Sciences**, v. 68, n. 2, p. 205-211, 1979.

LEVIEN, A.; PESKE, S. T.; BAUDET, L. Film coating no recobrimento das sementes. **Seed News**, v. 12, p. 1-5, 2008.

MACDONALD, L. et al. **Colour image science: exploiting digital media**. John Wiley and Sons Ltd, 2002.

MALACARA, D. **Color vision and colorimetry: theory and applications**. 2003.

MARÇAL, J. V. M. **Estudo de caso: seleção de revestimento antiaderente para redução de setup do tratamento de sementes de milho**. São Carlos: Universidade Federal de São Carlos, 2021, 72 p. Trabalho de conclusão de curso.

MARGUÍ, E.; ZAWISZA, B.; SITKO, R. Trace and ultratrace analysis of liquid samples by X-ray fluorescence spectrometry. **TrAC Trends in Analytical Chemistry**, v. 53, p. 73-83, 2014.

MAZZUZ, C. F. **Calidad de Frutos Citricos. Manual para su Gestión desde la Recolección hasta la Expedición**. Reus. Ed. Horticultura, 1996.

MOUAZEN, Abdul Mounem; DE BAERDEMAEKER, Josse; RAMON, Herman. Towards development of on-line soil moisture content sensor using a fibre-type NIR spectrophotometer. **Soil and Tillage Research**, v. 80, n. 1-2, p. 171-183, 2005.

MOURA, S. C. S. R.; Berbari, S.A.; Germer, S. P. M.; Almeida, M. E. M.; Fefim, D. A. Determinação da vida-de-prateleira de maçã-passa por testes acelerados. **Food Science and Technology**, Campinas, v. 27, n. 1, p. 141-148, 2007.

OLIVEIRA, Vasconcelos Romão de. **Tratamento industrial de sementes: quantificação do ingrediente ativo em lotes de milho doce**. Pelotas: Universidade Federal de Pelotas, 2017, 60p. Dissertação de Mestrado.

OLYMPUS. **Analísadores por XRF e XRD**. Disponível em: <<https://www.olympus-ims.com/pt/xrf-analyzers/handheld/vanta/>>. Acesso em 10 jul. 2023.

PEREIRA, Carlos Eduardo et al. Desempenho de sementes de soja tratadas com fungicidas e peliculizadas durante o armazenamento. **Ciência e Agrotecnologia**, v. 31, p. 656-665, 2007.

REIS, Leandro Vilela et al. Treatment technologies for soybean seeds: Dose effectiveness, mechanical damage and seed coating. **Ciência e Agrotecnologia**, v. 47, p. e013622, 2023.

RIBEIRO, L. **Pó secante é aliado no tratamento de sementes**. **Revista Campo e Negócio**, dez. 2014.

TAYLOR, A. G. **Seed treatments**. In *Encyclopedia of Applied Plant Sciences*; Thomas, B.D.J., Murphy, B.G., Eds.; Elsevier Academic Press: Cambridge, UK, 2003; pp. 1291–1298

VILHALVA, D. A. et al. Secagem convencional de casca de mandioca proveniente de resíduos de indústria de amido. **Agricultural Research in the Tropics/Pesquisa Agropecuária Tropical**, v. 42, n. 3, 2012.

WYSZECKI, G.; STILES, W. S. **Color science: concepts and methods, quantitative data and formulae**. John Wiley e sons, 2000.

XAVIER, João Barcellos et al. Morphological, chemical and physiological characterization of *Amaranthus* spp. Seeds. **Journal of Seed Science**, v. 41, p. 478-487, 2019.

SHI, H. et al. Titanium dioxide nanoparticles: a review of current toxicological data. **Particle and fibre toxicology**, v. 10, p. 1-33, 2013.