

UNIVERSIDADE ESTADUAL DE PONTA GROSSA
SETOR DE CIÊNCIAS AGRÁRIAS E DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO APLICADA

JAQUELINE RISSÁ FRANCO

**MÉTODO COMPUTACIONAL PARA IDENTIFICAÇÃO DO FUNGO
CERCOSPORA KIKUCHII EM SEMENTES DE SOJA**

**PONTA GROSSA
2017**

JAQUELINE RISSÁ FRANCO

**MÉTODO COMPUTACIONAL PARA IDENTIFICAÇÃO DO FUNGO
CERCOSPORA KIKUCHII EM SEMENTES DE SOJA**

Dissertação apresentada ao Programa de Pós-Graduação em Computação Aplicada, curso de Mestrado em Computação Aplicada da Universidade Estadual de Ponta Grossa, como requisito parcial para obtenção do título de Mestre.

Orientadora: Prof^a. Dr^a. Rosane Falate.

**PONTA GROSSA
2017**

Ficha Catalográfica
Elaborada pelo Setor de Tratamento da Informação BICEN/UEPG

F825 Franco, Jaqueline Rissá
Método computacional para identificação
do fungo Cercospora Kikuchii em sementes
de soja/ Jaqueline Rissá Franco. Ponta
Grossa, 2017.
109f.

Dissertação (Mestrado em Computação
Aplicada - Área de Concentração:
Computação para Tecnologias em
Agricultura), Universidade Estadual de
Ponta Grossa.

Orientadora: Prof^a Dr^a Rosane Falate.

1.OpenCV. 2.Glycine max (L.) Merrill.
3.Cercospora kikuchii. 4.Processamento de
imagens. 5.CIEL*a*b. I.Falate, Rosane.
II. Universidade Estadual de Ponta Grossa.
Mestrado em Computação Aplicada. III. T.

CDD: 006.3

TERMO DE APROVAÇÃO

Jaqueline Rissá Franco

“MÉTODO COMPUTACIONAL PARA IDENTIFICAÇÃO DO FUNGO CERCOSPORA KIKUCHII EM SEMENTES DE SOJA”.

Dissertação aprovada como requisito parcial para obtenção do grau de Mestre no Programa de Pós-Graduação em Computação Aplicada da Universidade Estadual de Ponta Grossa, pela seguinte banca examinadora:

Orientadora:


Dr.ª Rosane Falate
UEPG


Dr. David de Souza Jaccoud Filho
UEPG


Dr. Ionildo José Sanches
UTFPR/Ponta Grossa - PR

Ponta Grossa, 29 de maio de 2017.

AGRADECIMENTOS

Agradeço à DEUS, por estar presente em todos os momentos, presenteando-me com força e fé. Também pelas novas amizades construídas durante o curso e pelas antigas que foram estreitadas nos momentos de dificuldade.

Agradeço minha família por terem sempre me apoiado a seguir meus sonhos. Especialmente meus pais, Sebastião e Sibília, e minha tia Albertina, por terem sempre apoiado meus estudos, mesmo quando foi necessário morar longe de casa para continua-los.

Agradeço minha orientadora, Prof^a. Dr^a. Rosane Falate, pelas oportunidades, incentivos e ensinamentos, sempre presentes nesse e outros projetos.

Agradeço a todos os professores do programa que tanto contribuíram com o meu amadurecimento como aluna, pesquisadora e pessoa. Especialmente o Prof. Dr. Alceu de Souza Britto Junior e a Prof^a. Dr^a. Elaine Margarete Guimarães, que me orientaram em outros projetos, e o professor Prof. Dr. David de Souza Jaccoud Filho que vem apoiando projeto fornecendo informações essenciais. Agradeço também os professores Me. Luciano Döll, Dr. Willian Massami Watanabe e Dr^a. Maria Salete Marcon Gomes Vaz que me incentivaram a iniciar o curso.

Agradeço aos amigos e colegas acadêmicos que contribuíram com esse projeto de diversas maneiras, apoiando-me e ensinando-me. Especialmente os acadêmicos Luiz Pedro e Henrique, por termos construído o projeto EcoRastro em conjunto, o Teruo e o Malcon, que sempre me ajudaram nas diferentes facetas que envolvem o curso, o Antônio David pela ajuda com mineração de dados, a Evelaine pelo apoio e amizade. Agradeço também os amigos que entenderam minha ausência durante o curso e sempre me apoiaram, especialmente Juliana, Monica e Keila.

Agradeço a Universidade Estadual de Ponta Grossa e ao Programa de Pós-graduação em Computação Aplicada, por disponibilizarem toda a estrutura necessária para o desenvolvimento da pesquisa.

Agradeço a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (Projeto CNPq nº 480139/2013-0) pelo suporte financeiro e equipamentos.

*"Lately, I've been, I've been losing sleep
Dreaming about the things that we could be
But baby, I've been, I've been praying hard
Said, no more counting dollars
We'll be, we'll be counting stars"
(Ryan Tedder - Counting Stars)*

RESUMO

A presença da patologia conhecida como mancha púrpura da semente de soja é causada pelo fungo *Cercospora kikuchii* e pode implicar em prejuízos tanto de produtividade quanto de qualidade na produção de derivados. O controle de qualidade de sementes é essencial para evitar perdas como essas, sendo então convencionalmente realizadas inspeções visuais, para identificar as sementes contaminadas. Porém, tais processos convencionais são lentos e imprecisos, uma vez que depende diretamente do analista. O presente trabalho teve por objetivo desenvolver um sistema computacional para a identificação de sementes de soja contaminadas pelo fungo *Cercospora kikuchii*. O método proposto foi desenvolvido utilizando a biblioteca OpenCV, por meio da linguagem de programação Java, e utilizando a interface de integração da ferramenta WEKA. Foram consideradas amostras de 150 sementes sadias e de 150 sementes contaminadas. A obtenção individual da imagem de cada semente, para fins de classificação em sadia ou contaminada, foi realizada e foi considerada durante o processo a qualidade individual de cada etapa do processo. O resultado alcançado foi de 88% de assertividade, utilizando a validação cruzada sobre o modelo de rede neural artificial construído, e de 100% de assertividade sobre as imagens utilizadas. Os melhores resultados encontrados em trabalhos de outros autores, considerando especificamente o fungo *Cercospora kikuchii*, foram de 66% a 83% de assertividade.

Palavras chaves: OpenCV, *Glycine max* (L.) Merrill, *Cercospora kikuchii*, Processamento de imagens, CIEL*a*b, RGB, HSV.

ABSTRACT

The condition known as purple spot in soybean seed is caused by the fungus *Cercospora kikuchii* and can influence both yield and quality losses in the production of soybean derivatives. Seed quality control is essential to avoid such losses, so there are conventional methods, such as visual inspections to identify contaminated seeds. However, these conventional processes are slow and imprecise, since they depend directly on the analyst. The present work had as objective to develop a computational system for the identification of soybean seeds contaminated by the fungus *Cercospora kikuchii*. The proposed method was developed based on the OpenCV library, using the Java programming language and the integration interface of the WEKA tool. Samples of 150 healthy seeds and 150 contaminated seeds were considered. The individual image acquisition of each seed, for purposes of classification in healthy or contaminated, was performed and was considered in the process the individual quality of each stage. The obtained result was 88% of correct classifications, using cross-validation in the constructed neural network model and 100% correct classifications in the used images. The best results found in studies of other authors, specifically considering the fungus *Cercospora kikuchii*, were 66% to 83% of the correct classifications.

Keywords: OpenCV, *Glycine max* (L.) Merrill, *Cercospora kikuchii*, image processing, CIEL*a*b, RGB, HSV.

LISTA DE ILUSTRAÇÕES

Figura 1 – Sementes de soja contaminadas pelo fungo <i>Cercospora kikuchii</i> - Mancha Púrpura.	14
Figura 2 – Exemplos de imagens de sementes de soja capturadas em condições inadequadas: (a) região com deficiência de luz – subexposta, (b) reflexo provocado por iluminação direta, (c) sombra projetada, (d) semente com região contaminada oculta na imagem, e (e) região com muita luz – saturada.	15
Figura 3 – Níveis de processos envolvidos em PDI.	19
Figura 4 – Etapas envolvidas em sistemas de PDI.	19
Figura 5 – Uma imagem monocromática e a convenção utilizada para o par de eixos x, y	21
Figura 6 – Distribuição de níveis de cinza por: (a) imagem, e (b) histograma.	22
Figura 7 – Esquema cubo de cores RGB.	23
Figura 8 – Espaço de cor HSV - representação gráfica.	25
Figura 9 – Espaço de cor CIE $L^*a^*b^*$	26
Figura 10 – Imagens produzidas com diferentes ISO: (a) ISO 100; (b) ISO 400; (c) ISO 12800.	31
Figura 11 – Distância focal e ângulo de visão em lentes de diferentes distâncias focais.	32
Figura 12 – Limiarização de uma imagem monocromática utilizando limiar T: (a) histograma original e (b) histograma da imagem binarizada.	34
Figura 13 – Ilustração de uma visão superior de uma esteira de rolagem: (a) os objetos que podem ser classificados quanto a forma, e (b) objetos agrupados quanto a similaridade de forma.	38
Figura 14 – Fluxograma representando os principais passos no projeto de um classificador.	39
Figura 15 – Matriz de confusão - diferentes saídas em uma classificação de duas classes.	41
Figura 16 – Equipamento de aquisição e eliminação de sementes desenvolvido por Liu et al. (2015).	47
Figura 17 – Aquisição de imagens com Scanner HP LaserJet M1120 MPP.	50
Figura 18 – Aquisição de imagens com Scanner Epson V700 Photo e iluminação externa.	52
Figura 19 – Arranjo para aquisição de imagens do sistema de aquisição 6 – Luz indireta.	55
Figura 20 – Disposição dos equipamentos no sistema de aquisição utilizado no trabalho.	57
Figura 21 – Técnica de segmentação utilizada – Variação do método Otsu para imagens coloridas.	58
Figura 22 – Imagem em escala de cinza e seu histograma: (a) imagem e (b) histograma.	61
Figura 23 – Imagens produzidas pelo scanner HP LaserJet M1120 MPP com contorno desenhado nas sementes identificadas: (a) Fundo azul e sementes saudáveis; (b) Fundo preto e sementes saudáveis; (c) Fundo verde e sementes saudáveis; (d) Fundo azul e sementes contaminadas; (e) Fundo preto e sementes contaminadas; (f) Fundo verde e sementes contaminadas.	62

Figura 24 – Imagens produzidas pelo scanner Epson Perfection V700 Photo com contorno desenhado nas sementes identificadas: (a) Fundo azul e sementes saudas; (b) Fundo preto e sementes saudas; (c) Fundo verde e sementes saudas; (d) Fundo azul e sementes contaminadas; (e) Fundo preto e sementes contaminadas; (f) Fundo verde e sementes contaminadas.	65
Figura 25 – Imagens da amostra com sementes saudas – moldura 0,5 cm de altura. (a) Fundo preto; (b) Fundo azul; (c) Fundo verde; (d) Scanner aberto; (e) Scanner aberto com iluminação externa.	66
Figura 26 – Imagens da amostra com sementes contaminadas – moldura 0,5 cm de altura. (a) Fundo preto; (b) Fundo azul; (c) Fundo verde; (d) Scanner aberto; (e) Scanner aberto com iluminação externa.	67
Figura 27 – Imagens de sementes saudas produzidas no sistema de aquisição 5. (a) Fundo em EVA verde; (b) Fundo em EVA preto; (c) Fundo em EVA azul; (d) Fundo sem EVA, apenas a mesa Still; (e) Iluminação sob a mesa Still.	71
Figura 28 – Imagens de sementes contaminadas produzidas no sistema de aquisição 5. (a) Fundo em EVA verde; (b) Fundo em EVA preto; (c) Fundo em EVA azul; (d) Fundo sem EVA, apenas a mesa Still; (e) Iluminação sob a mesa Still.	72
Figura 29 – Imagem de semente de soja contaminada pelo fungo <i>Cercospora kikuchii</i> segmentada pelo método Otsu e sua variação para imagens coloridas (InRange/Otsu).	74
Figura 30 – Uma imagem de sementes de soja saudas produzida pelo sistema de aquisição 7 – Final.	75
Figura 31 – Uma imagem de sementes de soja contaminadas produzida pelo sistema de aquisição 7 – Final.	75
Figura 32 – Histograma de uma das imagens produzidas de sementes saudas com o sistema de aquisição 7 e convertida para o espaço de cor CIEL*a*b*...76	
Figura 33 – Histograma de uma das imagens produzidas de sementes saudas com o sistema de aquisição 7 no espaço de cor RGB.	77
Figura 34 - Histograma de uma das imagens produzidas de sementes saudas com o sistema de aquisição 7 e convertida para o espaço de cor HSV.	77
Figura 35 – Imagem contendo cinco sementes saudas e cinco contaminadas, disposta aleatoriamente.	78
Figura 36 – Imagem com 10 sementes, saudas e contaminadas, segmentada após conversão para o espaço de cor HSV.	79
Figura 37 – Imagem com 10 sementes, saudas e contaminadas, com ruído destacado.	80
Figura 38 – Imagem com 10 sementes, saudas e contaminadas, segmentada no espaço de cor RGB.	81
Figura 39 – Imagem com 10 sementes, saudas e contaminadas, segmentada após conversão para o espaço de cor CIEL*a*b*.	81
Figura 40 – Codificação do algoritmo de extração de características Percentil.	82
Figura 41 – Árvore construída pelo classificador quando considerado o espaço de cor CIEL*a*b* e imagens com fundo original.	87
Figura 42– Árvore construída pelo classificador quando considerado o espaço de cor RGB e imagens com fundo original.	88
Figura 43– Árvore construída pelo classificador quando considerado o espaço de cor HSV e imagens com fundo uniforme.	88

Figura 44 - Imagem 1310, incorretamente classificada pelas combinações avaliadas com o classificador J48.	88
Figura 45 - Exemplo de imagem corretamente classificada como semente contaminada.....	89
Figura 46 – Frame separado do primeiro experimento com captura de imagens por vídeo.	103
Figura 47 - Experimento de captura de vídeo com uma câmera GoPro configurada em: (a) 100 frames/segundo; (b) 120 frames/segundo; (c) 240 frames/segundo.....	104
Figura 48 – Primeiro protótipo de rampa para redução da velocidade das sementes.	104
Figura 49 – Rampa comercial utilizada para redução da velocidade da semente...	105
Figura 50 – Experimento com rampa comercial na combinação 14.....	107
Figura 51 – Experimento com rampa comercial na combinação 3.....	108

LISTA DE TABELAS

Tabela 1 – Análise dos contornos das imagens de 50 sementes produzidas pelo scanner LaserJet M1120 MPP	63
Tabela 2 – Análise dos contornos das imagens de 50 sementes produzidas pelo scanner Epson Perfection V700 Photo.....	65
Tabela 3 – Resultados dos valores calculados pelo sistema de processamento no sistema de aquisição 3 - Scanner Epson com iluminação externa.....	68
Tabela 4 – Sementes contabilizadas pelo método Otsu no sistema de aquisição 5 – Luz direta.....	70
Tabela 5 – Resultados da segmentação no sistema de aquisição 6 – Luz indireta. .	73
Tabela 6 – Resultados dos valores calculados pelo sistema utilizando uma imagem de 10 sementes, entre sadias e contaminadas.	79
Tabela 7 – Combinações avaliadas usando o classificador J48 e imagens com fundo original.....	86
Tabela 8 – Combinações avaliadas usando o classificador J48 e imagens com fundo uniforme.	86
Tabela 9 – Combinações avaliadas usando o classificador MultilayerPerceptron e imagens com fundo original.....	90
Tabela 10 – Combinações avaliadas usando o classificador MultilayerPerceptron e imagens com fundo preto.	90
Tabela 11 – Combinações avaliadas usando o classificador SMO e imagens com fundo original.....	91
Tabela 12 – Combinações avaliadas usando o classificador SMO e imagens com fundo preto.	91
Tabela 13 – Variáveis do experimento com a rampa comercial.	106

LISTA DE SIGLAS

A/D	Analógico/Digital
API	<i>Application Programming Interface</i> – Interface de Programação de Aplicativos
ARFF	<i>Attribute-Relation File Format</i> – Formato de Arquivo de Relação de Atributos
CIE	<i>Commission Internationale de l'Eclairage</i> – Comissão Internacional de Iluminação
CSV	<i>Comma-Separated Values</i> – Valores Separados por Vírgula
DSLR	<i>Digital Single-Lens Reflex</i> – Digitais com reflexão de uma única lente
EVA	Espuma Vinílica Acetinada
HP	Hewlett-Packard
HSV	<i>Hue, Saturation, Value</i> – Matiz, Saturação, Valor
IDE	<i>Integrated Development Environment</i> – Ambiente de Desenvolvimento Integrado
ISO	<i>International Standards Organization</i> – Organização Internacional de Padrões
JPEG	<i>Joint Photographic Experts Group</i> – Grupo de especialistas em fotografia
L*a*b*	Luminosidade, tons de verde e de vermelho, tons de azul e de amarelo
LED	<i>Light Emitter Diode</i> – Diodo Emissor de Luz
NTSC	<i>National Television Systems Committee</i> – Comitê Nacional dos Sistemas de Televisão
NTSC	<i>National Television System Committee</i> – Comitê Nacional de Sistema de Televisão
PDI	Processamento Digital de Imagens
PNG	<i>Portable Network Graphics</i> – Gráfico de Redes Portáteis
RGB	<i>Red, Green, Blue</i> – Vermelho, Verde, Azul
SMO	<i>Sequential Minimal Optimization</i> - Otimização Mínima Sequencial
UEPG	Universidade Estadual de Ponta Grossa

SUMÁRIO

1	INTRODUÇÃO	13
1.1	OBJETIVO GERAL	16
1.2	OBJETIVOS ESPECÍFICOS	16
1.3	ESTRUTURA	17
2	REVISÃO DE LITERATURA.....	18
2.1	PROCESSAMENTO DIGITAL DE IMAGENS	18
2.1.1	Imagens digitais	20
2.1.2	Espaços de cor	23
2.1.3	Aquisição de imagens	27
2.1.4	Segmentação	33
2.1.5	Representação e extração de características	35
2.1.6	Classificação	37
2.2	QUALIDADE DE SEMENTES.....	44
2.2.1	Processamento digital de imagens na qualidade de sementes.....	46
3	METODOLOGIA.....	49
3.1	AQUISIÇÃO DAS IMAGENS	49
3.1.1	Sistema de aquisição 1 – Scanner HP	49
3.1.2	Sistema de aquisição 2 – Scanners HP e Epson	51
3.1.3	Sistema de aquisição 3 – Scanner Epson com iluminação externa	52
3.1.4	Sistema de aquisição 4 – Captura por vídeo.....	53
3.1.5	Sistema de aquisição 5 – Luz direta.....	53
3.1.6	Sistema de aquisição 6 – Luz indireta.....	55
3.1.7	Sistema de aquisição 7 – Final	56
3.2	SISTEMA COMPUTACIONAL	57
3.2.1	Segmentação	57
3.2.2	Extração de características	59
3.2.3	Classificação	60
4	RESULTADOS E DISCUSSÃO	62
4.1	AVALIAÇÃO DOS SISTEMAS DE AQUISIÇÃO	62
4.1.1	Sistema de aquisição 1 – Scanner HP	62
4.1.2	Sistema de aquisição 2 – Scanners HP e Epson	64
4.1.3	Sistema de aquisição 3 – Scanner Epson com iluminação externa	66
4.1.4	Sistema de aquisição 4 – Captura por vídeo.....	70
4.1.5	Sistema de aquisição 5 – Luz direta.....	70
4.1.6	Sistema de aquisição 6 – Luz indireta.....	73
4.1.7	Sistema de aquisição 7 – Final	74
4.2	SISTEMA COMPUTACIONAL	78
4.2.1	Segmentação	78
4.2.2	Extração de características	82
4.2.3	Classificação	84
4.2.4	Considerações Finais.....	92
5	CONCLUSÕES E TRABALHOS FUTUROS	94
5.1	TRABALHOS FUTUROS	95
	REFERÊNCIAS.....	96
	APÊNDICE A – Sistema de aquisição 4 – Captura por vídeo	101

1 INTRODUÇÃO

As tecnologias de visão computacional, como processamento digital de imagens (PDI), têm sido utilizadas para análise de qualidade de diversas culturas e com diferentes abordagens, como monitoramento de fungos foliares na cultura da beterraba sacarina (ZHOU et al., 2015) e análise de maturação de sementes de uva (RODRÍGUEZ-PULIDO et al., 2012). No caso de análise de sementes de soja, muitos trabalhos procuram nos sistemas baseados em PDI soluções e otimizações para processos que convencionalmente são lentos, custosos e imprecisos (LIU et al., 2015; PAULSEN et al., 1989).

Liu et al. (2015) e Paulsen et al. (1989) buscaram analisar a qualidade sanitária de sementes de soja utilizando sistemas baseados em processamento digital de imagens para identificar danos nas sementes, como os causados por fungos e insetos. Automatizar esse processo pode contribuir para uma classificação rápida e confiável, aumentando a qualidade dos lotes e, conseqüentemente, sua produtividade.

Considerando a importância econômica que a produção de soja representa no Brasil, uma vez que é atualmente o grão de maior produção neste país, é essencial a busca por meios para aumentar a produtividade deste grão. Um dos maiores limitadores de produtividade é a utilização de sementes de baixa qualidade, pois grande parte dos patógenos é disseminada por meio das sementes, introduzindo-os em áreas indenidas, além de comprometer o vigor e a germinação, reduzindo a produtividade (EMBRAPA, 2004; KRZYZANOWSKI et al., 2008).

Dentre os patógenos de importância econômica na cultura da soja destaca-se o fungo *Cercospora kikuchii* (MATSUMOTO; TOMOYASU, 1925), que é um dos limitadores de produtividade de soja (GOULART, 2005). Esse fungo pode afetar diversas partes da planta e, nas sementes de soja, sua presença é detectada pela existência de manchas púrpura (Figura 1). A maioria das variedades de soja é suscetível a esse fungo, particularmente com a ocorrência de alta umidade, do início da frutificação à colheita, tornando-o significativo no controle de qualidade de sementes desta cultura (ALMEIDA et al., 1997; COSTA, 1996).

Figura 1 – Sementes de soja contaminadas pelo fungo *Cercospora kikuchii* - Mancha Púrpura.



Fonte: (MADALOSSO, 2012).

Aplicação de fungicidas foliares para o controle de doenças pode implicar em ganhos de qualidade e produtividade na produção de sementes de soja, mesmo naquelas de final de ciclo, como é o caso da *Cercospora kikuchii*. Também pode ser recomendado o tratamento químico com fungicidas para lotes de sementes de baixa qualidade devido à presença desse microrganismo. De qualquer forma, as sementes sempre devem ser submetidas ao beneficiamento, pois é necessário classificá-las, remover impurezas como torrões, insetos, sementes de outras culturas e ervas daninhas, além de outros processos de beneficiamento, como a secagem (COSTA, 1996; FRANÇA NETO et al., 2007).

De acordo com Liu et al. (2015), é possível classificar as sementes por inspeção visual ou procedimentos químicos, contudo ambos os processos são custosos em tempo, além do primeiro ser impreciso, por estar suscetível a subjetividade do responsável. Em relação aos seletores de sementes de soja, deve-se destacar que a maioria é projetada com mecanismos de vibração, centrifugação e fricção, ou seja, são projetados para a remoção apenas de detritos, não abrangendo sementes danificadas por patógenos ou insetos. Portanto, um método computacional para a detecção de patógenos, como a mancha púrpura, mostra-se interessante.


De fato, sistemas baseados em processamento de imagens podem automatizar procedimentos como inspeção visual, porém sua construção envolve diversos desafios. O processamento de imagens é composto por etapas estreitamente ligadas, sendo a saída de um processo a entrada do processo seguinte, tornando a

qualidade de cada etapa diretamente dependente da qualidade da etapa anterior. Assim, para a construção de um sistema de processamento de imagens de sucesso é necessário considerar os fatores de qualidade desde a primeira etapa: aquisição.

Muitas das dificuldades a serem superadas na etapa de aquisição se devem as características do objeto a ser identificado, já que itens como formato e tamanho podem influenciar na qualidade das imagens adquiridas. Um dos fatores destacados como de grande influência na qualidade de aquisição das imagens é a iluminação (GUNASEKARAN et al., 1988; LIU et al., 2015).

A iluminação adequada deve ser uniforme e com intensidade e coloração que não alterem as características do objeto. Imagens produzidas com iluminação inadequada podem apresentar ruídos indesejados, como reflexos, Figura 2 (b), ou sombras projetadas, Figura 2 (c). Ruídos ocasionados pela iluminação podem prejudicar procedimentos posteriores, como a incorreta identificação dos objetos, por exemplo, considerando os reflexos como objetos distintos ou sombras projetadas como parte do objeto.

Figura 2 – Exemplos de imagens de sementes de soja capturadas em condições inadequadas: (a) região com deficiência de luz – subexposta, (b) reflexo provocado por iluminação direta, (c) sombra projetada, (d) semente com região contaminada oculta na imagem, e (e) região com muita luz – saturada.



Fonte: a autora.

Enquanto, por um lado, a baixa intensidade de iluminação pode incorrer em imagens com regiões subexpostas, Figura 2 (a), por outro lado, uma iluminação de intensidade mais alta que a adequada pode produzir imagens com regiões saturadas, Figura 2 (e). Em ambos os casos, os procedimentos posteriores de identificação de cor podem ser prejudicados.

Em particular, nos sistemas cujo objetivo é a identificação de características em objetos, o sucesso do processo se relaciona ainda com o correto posicionamento

do objeto durante a aquisição. No caso de sementes de soja contaminadas pela mancha púrpura, por exemplo, a característica que se objetiva identificar, a cor púrpura, pode ser ocultada na imagem, Figura 2 (d), induzindo um resultado falso negativo. O correto posicionamento das sementes de soja durante a produção das imagens é dificultado devido ao seu formato particularmente esférico, mais acentuado em algumas variedades.

Outro fator considerado de alta complexidade no desenvolvimento de sistemas de processamento de imagens tange a segmentação, que consiste na separação dos objetos que se quer analisar, ou de interesse, do restante da imagem (GONZALEZ; WOODS, 2010). Muitas das técnicas de segmentação utilizam fronteiras de cores na imagem para determinar os limites do objeto identificado; assim, o contraste do fundo com o objeto se torna de grande importância. O fundo a ser utilizado na imagem também pode implicar em ruídos, pois, caso este não seja uniforme, o processo de segmentação pode considerar fragmentos deste como objetos de interesse.

Como pode ser notado, a combinação de iluminação e fundo adequados para os objetos de interesse pode resultar em imagens de qualidade para as etapas subsequentes. Isto posto, pretende-se construir um sistema computacional, com o auxílio do processamento digital de imagens, capaz de identificar características em sementes de soja para a classificação de sementes contaminadas pelo fungo *Cercospora kikuchii*.

1.1 OBJETIVO GERAL

Desenvolver um método computacional para identificação de sementes de soja contaminadas pelo fungo *Cercospora kikuchii*, a partir de um lote de sementes sadias e contaminadas somente com este fungo.

1.2 OBJETIVOS ESPECÍFICOS

Como objetivos específicos, têm-se:

- Definir uma metodologia para aquisição de imagens de amostras de sementes de soja, após a avaliação de ao menos três metodologias diferentes, englobando scanner e câmera digital;
- Definir uma técnica de segmentação por limiarização adequada às imagens coloridas adquiridas, após a análise de, ao menos, duas técnicas;

- Analisar a extração de características em três espaços de cor: RGB, CIEL*a*b* e HSV;
- Analisar o desempenho de, ao menos, dois classificadores, utilizando uma ferramenta de mineração de dados;
- Validar o sistema desenvolvido com 300 sementes previamente avaliadas por especialistas.

1.3 ESTRUTURA

Este trabalho está estruturado em 5 capítulos, sendo o primeiro este de introdução. No capítulo 2 são apresentados fundamentos e conceitos envolvidos e utilizados na técnica de processamento digital de imagens; conceitos a respeito da qualidade de sementes, destacando o que tange a cultura da soja; e revisão bibliográfica de trabalhos relacionados à pesquisa desenvolvida. No capítulo 3 é descrita a metodologia e os materiais utilizados no desenvolvimento deste trabalho. Os resultados são apresentados e discutidos no capítulo 4, enquanto as conclusões e perspectiva de trabalhos futuros são apresentadas no capítulo 5. Por fim, integra este trabalho o apêndice A, que apresenta uma das abordagens de aquisição de imagens avaliada durante a pesquisa.

2 REVISÃO DE LITERATURA


2.1 PROCESSAMENTO DIGITAL DE IMAGENS

Tecnologias de Processamento Digital de Imagens têm sido utilizadas amplamente e expansivamente em diversas áreas desde o fim da década de 1920, com o maior avanço na década de 1960, com o programa espacial norte-americano (MARQUES FILHO; VIEIRA NETO, 1999).

A área PDI se refere ao processamento de imagens digitais por um computador digital, por meio do desenvolvimento de ferramentas que objetivam simular computacionalmente as habilidades do sistema visual humano, proporcionando meios do computador interagir com o espaço de investigação para a construção de bases de conhecimento e de experiência. No entanto, a interdisciplinaridade entre as áreas que envolvem o processamento digital de imagens, e as demais áreas de conhecimento relacionadas, está mesclada de maneira que a maioria dos autores se isenta em delinear fronteiras entre estas áreas. Assim, um paradigma considerado para conceituar todos os processos envolvidos em PDI, em uma linha contínua, seria classificá-los como: processos de baixo nível, médio e alto (FACON, 2005; GONZALEZ; WOODS, 2010).

A Figura 3 apresenta os processos de baixo, médio e alto nível em PDI. Os processos de baixo nível envolvem atividades como aquisição de imagens e pré-processamentos, como tratamento de ruídos (pequenas imperfeições ou sombras, por exemplo), caracterizando-se principalmente por suas entradas e suas saídas serem imagens. Já os processos considerados como de nível médio são classificados assim por terem como entradas imagens e como saídas características extraídas destas imagens. Mais especificamente, a segmentação separa o objeto de estudo do restante da imagem, e a representação apresenta na saída é um conjunto de pontos, que podem ser informações de cor ou borda. Outra função da representação é elaborar uma estrutura adequada para agrupar os resultados obtidos nas etapas anteriores. Finalmente, os processos ditos como de alto nível objetivam a interpretação das imagens, o de reconhecimento de padrões, simulando as funções cognitivas comumente associadas ao sentido da visão humana (FACON, 2005; GONZALEZ; WOODS, 2010).


Figura 3 – Níveis de processos envolvidos em PDI.



Fonte: Adaptada de (FACON, 2005).

Outra abordagem utilizada para explicar como funciona o processamento digital de imagens se caracteriza por um conjunto de etapas (Figura 4), no qual a primeira etapa é a aquisição das imagens (MARQUES FILHO; VIEIRA NETO, 1999). Assim como nas demais etapas, a abordagem adotada para a obtenção das imagens (aquisição) está diretamente relacionada com as características do problema a ser solucionado, ou seja, a decisão de escolha do equipamento a ser utilizado ou protocolos adotados é feita de acordo com a problemática.

Figura 4 – Etapas envolvidas em sistemas de PDI.



Fonte: (MARQUES FILHO; VIEIRA NETO, 1999).

A segunda etapa do processo aborda atividades de pré-processamento, as quais podem abranger diferentes objetivos, desde redimensionamentos até reduções de ruídos, mas todos eles ambicionando a melhora da qualidade das imagens para as etapas seguintes. Assim como na abordagem de Facon (2005), a segmentação é a etapa na qual se procura identificar os objetos de interesse nas imagens. Embora seja considerada uma das tarefas mais difíceis, tem grande influência no resultado final, pois quanto mais precisa for a segmentação, maiores as chances de sucesso no reconhecimento dos objetos (GONZALEZ; WOODS, 2010).

A etapa de extração de características, na maior parte das vezes, tem como entrada o resultado da etapa de segmentação. Essa etapa procura selecionar informações da imagem que sejam pertinentes à análise do problema. Por fim, as características extraídas são utilizadas na etapa seguinte, na qual a interpretação e o reconhecimento buscados são processados, atribuindo rótulos e significados aos conjuntos de objetos identificados ao longo de todo o processo (MARQUES FILHO; VIEIRA NETO, 1999).


Todas as etapas descritas consideram a existência de uma base de conhecimento, ou dados, sobre o domínio do problema. Essa base de conhecimento é usada como fonte de informações sobre o domínio do problema e é realimentada ao longo do processo com novas informações geradas pelas etapas do processo (MARQUES FILHO; VIEIRA NETO, 1999).

Nem todas as etapas exibidas na Figura 4 estão presentes em todos os sistemas baseados em processamento digital de imagens, dependendo diretamente do problema que o sistema objetiva resolver e das imagens que este tem como entrada.

2.1.1 Imagens digitais

Segundo Gonzalez e Woods (2010), o termo *imagem* refere-se à função bidimensional da luz $f(x, y)$, sendo que x e y representam as coordenadas espaciais e seu valor é proporcional ao brilho, ou nível de cinza. Diferente do sistema cartesiano ortogonal, a convenção adotada por muitos dos autores, e também neste trabalho, posiciona a origem da imagem no canto superior esquerdo, como mostra a Figura 5.

Figura 5 – Uma imagem monocromática e a convenção utilizada para o par de eixos (x, y) .



Fonte: (MARQUES FILHO; VIEIRA NETO, 1999).


É chamada imagem digital uma imagem $f(x, y)$ discretizada em coordenadas espaciais e brilho, podendo ser representada como uma matriz bidimensional, cujos índices de linhas e colunas identificam um ponto da imagem e seu valor o nível de cinza naquele ponto. Os elementos dessa matriz digital são chamados pixels ou, menos comum, pels, ambos significando “elementos de figura” (GONZALEZ; WOODS, 2010; PEDRINI; SCHWARTZ, 2008).

Imagens coloridas são formadas por matrizes tridimensionais, compondo uma imagem multibanda ou multiespectral, sendo cada dimensão, ou matriz bidimensional, denominada banda ou canal e representa uma grandeza de cor. A maioria das cores visíveis pelo olho humano pode ser representada pelo espaço de cor RGB (*Red, Green, Blue* – Vermelho, Verde, Azul), porém existem outras representações, como HSV (*Hue, Saturation, Value* – Matiz, Saturação, Valor), também largamente utilizada (GONZALEZ; WOODS, 2010; PEDRINI; SCHWARTZ, 2008; SOLOMON; BRECKON, 2013).

Uma imagem, Figura 6 (a), pode ser descrita ainda de forma global, a partir de um histograma, Figura 6 (b), que desconsidera a localização dos pixels. O histograma, utilizado para análises como a distribuição de tons de cinza e nível de contraste, é um diagrama das frequências dos valores de $f(x, y)$ da imagem e é

normalmente representado por um gráfico de barras. Em imagens multibanda, como imagens coloridas, é possível gerar um histograma por banda, ou canal de cor (FACON, 2005; JÄHNE, 2004; MARQUES FILHO; VIEIRA NETO, 1999).

Figura 6 – Distribuição de níveis de cinza por: (a) imagem, e (b) histograma.



Fonte: (PEDRINI; SCHWARTZ, 2008).

O histograma também pode ser entendido como uma distribuição discreta de probabilidade, visto que a quantidade de pixels de um determinado nível de cinza pode ser utilizada no cálculo da probabilidade de se encontrar um pixel com o mesmo valor. Assim, normalizando a frequência de ocorrência dos níveis de cinza, um histograma $p_k(f)$ pode ser expresso como:

$$p_k(f) = \frac{n_k}{n} \quad (1)$$


onde n_k representa a quantidade de pixels de nível de cinza k e n representa o total de pixels na imagem (MARQUES FILHO; VIEIRA NETO, 1999; PEDRINI; SCHWARTZ, 2008;).

2.1.2 Espaços de cor

Existem diversos modelos, ou espaços, de cor, que são utilizados para representar uma cor, sendo o modelo RGB um dos mais utilizados e conhecidos, pois é comumente empregado em monitores coloridos. No entanto, existem outros também bastante utilizados como o HSV e o espaço de cores adotado pela CIE, o CIEL*a*b* (GONZALEZ; WOODS, 2010; PEDRINI; SCHWARTZ, 2008).

O espaço de cor RGB pode ser representado por um cubo (Figura 7) cujos pontos de cada eixo representam um canal e, ao longo da diagonal principal, eles representam os valores ou tons de cinza. Embora de uso bastante comum, esse modelo tem caráter não linear de percepção, ou seja, o deslocamento pelo espaço de cor (cubo) não necessariamente resulta em uma cor que seja percebida em consistência com a mudança ocorrida no canal, dificultando a relação natural do modo com que os humanos percebem as cores (SOLOMON; BRECKON, 2013).

Figura 7 – Esquema cubo de cores RGB.



Fonte: (MARQUES FILHO; VIEIRA NETO, 1999).

Uma imagem RGB, I_{cores} , pode ser convertida para escala cinza, I_{cinza} , conforme a transformação representada na Equação 2 (SOLOMON; BRECKON, 2013):


$$I_{cinza}(x,y) = \alpha I_{cores}(x,y,r) + \beta I_{cores}(x,y,g) + \gamma I_{cores}(x,y,b) \quad (2)$$

onde a coordenada (x, y) é a posição do pixel na imagem, e os coeficientes (α, β, γ) são fixados proporcionalmente à resposta do olho humano para cada canal, sendo no modelo YIQ, utilizado pelo padrão americano NTSC (*National Television System Committee* – Comitê Nacional de Sistema de Televisão) de televisão: $\alpha = 0,2989, \beta = 0,5870, \gamma = 0,1140$. Os canais vermelho e verde são considerados com coeficientes superiores ao azul devida a sensibilidade natural do olho humano a estas cores (PEDRINI; SCHWARTZ, 2008; SOLOMON; BRECKON, 2013; SZELISKI, 2010).

Ao contrário do RGB, o modelo HSV não tem a divisão de canais por cores, mas pelos componentes matiz, saturação e valor, aproximando-se da maneira como os seres humanos entendem as cores. Matiz representa a cor dominante percebida, a saturação se refere à pureza relativa, ou seja, a quantidade de luz branca presente; e o valor identifica a luminância, ou brilho, da cor (SOLOMON; BRECKON, 2013).

A separação das informações de cor da intensidade torna o espaço de cor HSV uma ferramenta ideal para o desenvolvimento de algoritmos de processamento digital de imagens. Geometricamente, o espaço de cor HSV pode ser visto como uma pirâmide hexagonal derivada do cubo RGB (Figuras 8 (a) e 8 (b)) (PEDRINI; SCHWARTZ, 2008).

Figura 8 – Espaço de cor HSV - representação gráfica.



Fonte: (PEDRINI; SCHWARTZ, 2008).

A conversão do modelo RGB para HSV pode ser realizada com as seguintes equações (Equação 3), sendo $m = \min(R, G, B)$, o valor mínimo entre os valores dos canais R, G e B, e $M = \max(R, G, B)$, o maior valor entre os valores dos canais R, G e B.

$$H = \begin{cases} 60 \frac{(G - B)}{(M - m)}, & \text{se } M = R \\ 60 \frac{(B - R)}{(M - m)} + 120, & \text{se } M = G \\ 60 \frac{(R - G)}{(M - m)} + 240, & \text{se } M = B \end{cases} \quad (3)$$


$$S = \begin{cases} \frac{(M - m)}{M}, & \text{se } M \neq 0 \\ 0, & \text{caso contrário} \end{cases}$$

$$V = M$$

Outro espaço de cor utilizado em diversos trabalhos de desenvolvimento de sistemas baseados em PDI é o CIE $L^*a^*b^*$. O modelo de cores CIE $L^*a^*b^*$ é fundamentado no espaço de cor CIE XYZ, proposto em 1931, e suas coordenadas foram inicialmente sugeridas por Richard S. Hunter em 1948. Em 1976, a proposta foi adotada pela CIE, que renomeou suas coordenadas de Lab para $L^*a^*b^*$, a fim de diferenciar as duas propostas (HUNTER, 1948; MARTÍN; MIRÓ; MORENO, 2015).

Como ilustra a Figura 9, o modelo $L^*a^*b^*$ é composto por três dimensões: L^* , que representa a luminosidade da cor, sendo zero o valor mínimo e 100 o valor máximo, e a^* e b^* as informações de cromaticidade. Os eixos a^* e b^* não têm limites numéricos específicos, contendo valores negativos e positivos. Os valores negativos de a^* representam os tons de verde e os positivos os tons de vermelho, enquanto os valores negativos do eixo b^* representam os tons de azul e os positivos os tons de amarelo (MOHEBBI et al., 2009).

Figura 9 – Espaço de cor CIE $L^*a^*b^*$.



Fonte: Adaptada de (MOHEBBI et al., 2009).

A conversão para o modelo $L^*a^*b^*$ deve partir do modelo CIE XYZ, no qual é baseado. Logo, para conversões entre os modelos RGB e $L^*a^*b^*$, é necessária a conversão para o espaço CIE XYZ, possível por meio da Equação 4, e então para o

modelo $L^*a^*b^*$ (Equação 5), considerando $f(t) = t^{1/3}$ se $t > 0,008856$, ou, caso contrário, $f(t) = 7,787t + 16/116$ (PEDRINI; SCHWARTZ, 2008):

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0,490 & 0,310 & 0,200 \\ 0,177 & 0,813 & 0,010 \\ 0,000 & 0,010 & 0,990 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (4)$$

$$L^* = \begin{cases} 116 \left(\frac{Y}{Y_n} \right)^{1/3} - 16, & \text{se } \frac{Y}{Y_n} > 0,008856 \\ 903,3 \left(\frac{Y}{Y_n} \right), & \text{se } \frac{Y}{Y_n} \leq 0,008856 \end{cases} \quad (5)$$

$$a^* = 500 \left[f \left(\frac{X}{X_n} \right) - f \left(\frac{Y}{Y_n} \right) \right]$$

$$b^* = 200 \left[f \left(\frac{Y}{Y_n} \right) - f \left(\frac{Z}{Z_n} \right) \right]$$

2.1.3 Aquisição de imagens

A etapa de aquisição de imagens compreende o processo de obtenção das imagens e representação de seus dados de forma numérica adequada para o processamento digital posterior. Existem diversos dispositivos de captura de imagens, os mais utilizados são câmeras, tomógrafos médicos, scanners e satélites. Na captura das imagens, são utilizados dispositivos sensíveis a uma determinada banda do espectro eletromagnético, como raios X ou infravermelhos, produzindo um sinal elétrico de saída de acordo com o nível de energia detectado. Para a interpretação das informações das imagens por computadores, o sinal elétrico é convertido em informação digital (MARQUES FILHO; VIEIRA NETO, 1999; PEDRINI; SCHWARTZ, 2008).

A captura de imagens por uma câmera pode ser entendida como a conversão, ou projeção, de uma cena tridimensional em uma representação bidimensional. Considerando uma cena iluminada por ao menos uma fonte de luz, parcelas da luz serão refletidas à câmera durante a captura. Utilizando câmeras convencionais, a luz é refletida na lente da câmera com base no modelo de projeção do dispositivo, transformando as coordenadas da cena tridimensional em bidimensional. Assim, a

maior parte das imagens capturadas é com o uso de uma projeção em perspectiva (MARQUES FILHO; VIEIRA NETO, 1999; SOLOMON; BRECKON, 2013).

Na projeção em perspectiva, uma posição (X, Y, Z) , sendo Z a profundidade, é reproduzida na posição (x, y) no plano da imagem determinado pela distância focal f . Em geral, a projeção em perspectiva pode ser expressa como (SOLOMON; BRECKON, 2013):

$$x = f \frac{X}{Z} \quad y = f \frac{Y}{Z} \quad (6)$$

A projeção em perspectiva tem duas principais propriedades (SOLOMON; BRECKON, 2013):

- Esforço: o tamanho do objeto na imagem é dependente da distância entre este e o dispositivo de captura;
- Convergência: retas paralelas na cena se tornam aparentemente convergentes na imagem; efeito conhecido como distorção de perspectiva.

Existem dispositivos, como scanners, que utilizam um modelo alternativo a projeção em perspectiva, o modelo de projeção ortográfica (ou paralela). Esse modelo pode ser enunciado como:

$$x = X \quad y = Y \quad (7)$$

Na projeção ortográfica as relações geométricas são mantidas, uma vez que os planos da cena e imagem são paralelos. Assim, toda informação de profundidade da cena é perdida. Em geral, é possível desprezar os efeitos da projeção em perspectiva quando as imagens são capturadas de objetos planos ou curtas distâncias (SOLOMON; BRECKON, 2013).

Após a formação da imagem, esta deve ser discretizada em uma imagem de resolução finita formada por pixels, processo denominado digitalização, para assim possibilitar o processamento digital subsequente. A digitalização da imagem capturada era tradicionalmente realizada por um conversor analógico-digital (A/D), uma vez que as imagens eram capturadas por câmeras de vídeo analógicas.

A digitalização fundamenta-se na quantização: o mapeamento do sinal contínuo da cena em um número discreto de pontos (pixels) organizados espacialmente. A quantização aproxima o sinal analógico de intensidade que entra na câmera em uma matriz de números discretos. Atualmente, sistemas com conversores A/D são raros, sendo substituídos por sistemas de captura de quadros diretamente integrados na câmera, nos quais a conversão A/D é realizada pelo sensor interno à câmera (SOLOMON; BRECKON, 2013).

Além do modelo de projeção e características do sensor, a qualidade das imagens adquiridas é influenciada ainda por variáveis como iluminação da cena e condições do ambiente, pois são possíveis origens de ruídos. Ruídos são pequenas variações aleatórias do sinal em torno do seu verdadeiro valor, e representam grande parte dos motivos de insucesso de processamento de imagens. Assim, muitas das técnicas de processamento de imagens se dedicam a remoção ou a redução de ruídos. No processamento de imagens digitais, os ruídos podem ser originários de diferentes fontes, tais como (SOLOMON; BRECKON, 2013):

- Captura: variações de iluminação, saturação do sensor por iluminação em excesso, subexposição por deficiência de luz, poeira no ambiente, vibração, distorção de lente, entre outros;
- Armazenagem, codificação e processamento: limitações no processo de digitalização, perda de informações na compressão da imagem e limitações na precisão numérica durante o processamento;
- Oclusão de cena: quando o objeto de interesse do processo é oculto com outro elemento da cena (SOLOMON; BRECKON, 2013).


Segundo Solomon e Breckon (2013), um dos objetivos principais no processamento de imagens é tornar as imagens o mais próximo possível da cena original. Com o uso de câmeras digitais atuais é possível manipular uma gama de variáveis, como velocidade de captura e sensibilidade do sensor, que permitem a aproximação da projeção da cena na imagem com grande fidelidade.

As câmeras digitais podem ser de diferentes tamanhos, sendo classificadas em três grupos: compactas, compactas avançadas e DSLR (*Digital Single-Lens Reflex* – Digitais com reflexão de uma única lente). No primeiro grupo as opções de manipulação de configurações podem ser limitadas com o intuito de facilitar seu manuseio, pois são destinadas para uso pessoal. As câmeras digitais compactas

avançadas costumam disponibilizar mais recursos que as do grupo anterior, como aproximação ótica (zoom ótico), porém não permitem a mudança de lentes, sendo esta única e fixa no equipamento. As câmeras do terceiro grupo são empregadas por profissionais da área, permitindo a alteração de lentes e um controle de configurações mais amplo. Entre as configurações passíveis de ajuste podem-se citar como principais: velocidade do obturador, abertura e sensibilidade ISO, conhecidos como Triângulo de Exposição (GIMENES, 2016; MORAZ, 2009).

A velocidade do obturador é o tempo que o sensor fica exposto à luz durante a captura da imagem. Em fotografia de cenas estáticas esta velocidade costuma ser uma fração de segundo, no entanto, em captura de cenas em movimento deve ser ajustada para um tempo menor, podendo chegar a minutos em muitas câmeras, a fim de produzir uma imagem nítida. A abertura é uma característica da lente, pois se refere a abertura do diafragma desta, permitindo mais ou menos passagem de luz para o sensor. Essa configuração também altera a profundidade de campo, pois valores reduzidos prejudicam a nitidez em determinadas regiões da imagem. A configuração ISO é referente a sensibilidade do sensor a luz. Aumentar a sensibilidade ISO torna o sensor mais sensível a fraca luminosidade, porém valores elevados podem produzir imagens de baixa qualidade, com presença de ruídos (Figura 10) (GIMENES, 2016; HARMAN, 2013).

Figura 10 – Imagens produzidas com diferentes ISO: (a) ISO 100; (b) ISO 400; (c) ISO 12800.




Fonte: Adaptada de (GIMENES, 2016).

Em câmeras profissionais existe ainda o ajuste de balanço de branco, que é o ajuste de interpretação das cores da cena pelo sensor, removendo cores não reais. As cores projetadas pela cena são influenciadas principalmente pela temperatura da luz utilizada na iluminação da cena, uma vez que esta altera a percepção de cor pelos olhos humanos. O balanço de branco altera como o sensor registra a luz. O modo automático, no qual o sistema da câmera digital calibra as temperaturas de cor, pode gerar resultados satisfatórios, porém recomenda-se a configuração manual ou personalizada, normalmente disponíveis em câmeras DSLR (GIMENES, 2016; HARMAN, 2013).

Outro fator importante é a escolha da lente. A seleção da lente a ser utilizada deve considerar o ângulo de abrangência que se ambiciona capturar a cena, pois, diferentemente da visão humana, o ângulo de captura da cena por uma câmera é limitado. Existem lentes com diversas distâncias focais (Figura 11) e propriedades, podendo-se citar como mais comum as normais ou padrão, com distância focal em torno de 50 mm, indicada para fotografias de curta distância, como retratos, por exemplo.

Figura 11 – Distância focal e ângulo de visão em lentes de diferentes distâncias focais.



Fonte: (GIMENES, 2016).

Lentes com maior distância focal são conhecidas como teleobjetiva, indicadas para fotografia em longa distância. As lentes com distância focal inferior a 50 mm são conhecidas como grande angular e são indicadas para fotografia de paisagens. As lentes com opção de regulagem entre distâncias focais são chamadas zoom. Outra lente amplamente utilizada, especialmente para fotografia de pequenos objetos e cenas de natureza, como insetos, é a chamada macro. Lentes macro têm como principal característica a capacidade de focalizar objetos a pequenas distâncias. Assim, o uso dessas lentes possibilita a captura de imagens com maiores detalhes (GIMENES, 2016).

O formato das imagens produzidas por câmeras digitais pode variar, sendo o mais comum o JPEG (*Joint Photographic Experts Group* – Grupo de especialistas em fotografia). No entanto, câmeras profissionais costumam disponibilizar a opção de armazenamento de imagens no formato RAW. Esse formato corresponde às imagens geradas pelo sensor sem qualquer compactação e, diferentemente das imagens em

JPEG, que sofrem perda de informações no processo de compactação, imagens no formato RAW possuem todas as informações fornecidas pelo sensor. Por meio de plug-ins, editores de imagem são capazes de alterar imagens nesse formato, porém o formato não é editável. Assim, para utilizar imagens sem perda de informações devida a compressão e quantização é recomendado que seja convertida a imagem do formato RAW para um formato adequado para processamento, como PNG (*Portable Network Graphics* – Gráfico de Redes Portáteis) (GIMENES, 2016).

2.1.4 Segmentação

O objetivo do processo de segmentação é subdividir a imagem em regiões, identificando os objetos de interesse da imagem, o que depende diretamente do problema a ser resolvido pelo sistema. Esse processo é complexo e de grande importância no processamento de imagens, podendo determinar seu sucesso ou fracasso. Existem diversas técnicas de segmentação, mas a maioria se divide entre abordagens de descontinuidade, como detecção de bordas, e de similaridade, como limiarização (GONZALEZ; WOODS, 2010).


Segundo Marques Filho e Vieira Neto (1999), é considerada borda a fronteira entre duas regiões cujos níveis de cinza predominantes são razoavelmente diferentes. Logo, o contraste de cor entre o objeto e o fundo é de grande relevância para tal, tornando a decisão de escolha do fundo, quando possível, de igual relevância. Para o desenvolvimento de algoritmos de detecção de bordas, Gonzalez e Woods (2010) definem três passos fundamentais: redução de ruído, detecção de pontos como potenciais pontos de borda e a definição de quais destes pontos devem realmente ser considerados bordas. Muitos dos trabalhos utilizam algoritmos já consagrados para detecção de bordas, sendo muitas vezes recomendado testes de validação para a tomada de decisão de qual o algoritmo que melhor atende o problema, como feito por Zhou et al. (2015).

Zhou et al. (2015) utilizaram detecção de bordas para destacar as regiões das imagens correspondentes a folha de beterraba sacarina em relação ao fundo da imagem, correspondente ao solo. Para isso, eles verificaram o desempenho dos algoritmos Canny, Sobel, Prewitt e Log, concluindo que, naquelas condições de aquisição, o algoritmo Canny obteve melhor resultado na detecção de bordas, com alterações em duas amostras, justificadas pela diferença de luminosidade na aquisição das imagens.

Outros autores optam pela abordagem de similaridade, também sendo comum a realização de testes para verificar o algoritmo mais apropriado para cada caso. A limiarização global, uma abordagem por similaridade, é uma das técnicas mais simples de segmentação e consiste na classificação dos pixels de uma imagem a partir de um valor, ou limiar, T . Muitas vezes a limiarização é denominada binarização, pois produz uma imagem binária como saída (GONZALEZ; WOODS, 2010; MARQUES FILHO; VIEIRA NETO, 1999).

Em uma imagem cujos objetos são formados por pixels com níveis de cinza aproximadamente iguais, diferindo do nível de cinza do fundo, o histograma será composto por dois picos distintos, um formado pelos pixels dos objetos e o outro pelos pixels do fundo, apresentando um formato bimodal. Embora a abordagem mais direta para definição do limiar global seja a seleção do valor que separa os picos (pontos de máximo), ou seja, o ponto de mínimo (Figura 12), uma imagem pode apresentar um histograma com diversos pontos de mínimo ou máximo, devido a ocorrência de ruídos, por exemplo. Assim, o problema de seleção do ponto mínimo é de solução não trivial (PEDRINI; SCHWARTZ, 2008).

Figura 12 – Limiarização de uma imagem monocromática utilizando limiar T : (a) histograma original e (b) histograma da imagem binarizada.



Fonte: (MARQUES FILHO; VIEIRA NETO, 1999).

O melhor limiar de uma imagem também é chamado de limiar ótimo, e existem diversas estratégias para a determinação deste, buscando a identificação dos pontos de máximo e mínimo no histograma. Um dos métodos mais conhecido e amplamente

empregado é o método de Otsu (1979), que determina o limiar ótimo para a imagem a partir da avaliação estatística da eficácia de cada possível valor de limiar. O método baseia-se na busca pelo limiar que maximize a variância entre classes ($\sigma_B^2(t)$), como segue:

$$\sigma_B^2(t) = \frac{[v_G P(t) - v(t)]^2}{P(t)[1 - P(t)]} \quad (8)$$

onde v_G é a intensidade média de toda a imagem, $v(t)$ é a média acumulada de nível de cinza t , $P(t)$ é a soma cumulativa da probabilidade atribuída ao objeto ou ao fundo. O limiar ótimo é o valor t^* que maximiza $\sigma_B^2(t)$ (GONZALEZ; WOODS, 2010; XIN; WENZHU; ZHENBO, 2015):

$$\sigma_B^2(t^*) = \max_{0 \leq t \leq h-1} \sigma_B^2(t) \quad (9)$$

onde h representa os diferentes níveis de intensidade na imagem.

2.1.5 Representação e extração de características

A representação e extração de características de imagens busca um conjunto de características do objeto de interesse que seja consonante com o propósito da classificação. Existem diversas técnicas, podendo ser agrupadas em dois tipos: características externas (bordas) e características internas (pixels que compõem o objeto). Os descritores devem permitir a caracterização da imagem sem ambiguidades e com número reduzido de características ou medidas (PEDRINI; SCHWARTZ, 2008; SOLOMON; BRECKON, 2013).

Em sistema cujo objeto a ser classificado mostra alterações de cores, como em imagens de sementes contaminadas por fungos, é possível basear a classificação na característica de cor, como nos trabalhos desenvolvidos por Paulsen et al. (1989) e Ahmad et al. (1998).

Algumas abordagens de extração de características de cor são baseadas em histogramas, como o algoritmo Percentil, utilizado por Cavalin et al. (2006). O algoritmo baseia-se na seleção de alguns percentis para a extração do valor do histograma no percentil selecionado usando-o como primitivo. Os percentis são considerados sobre o histograma de cada canal de cor, então se obtém as características invariantes contra o deslocamento e a largura do histograma. Por meio

da diferença de dois percentis e normalizando o valor obtido, dividindo-o pela diferença entre os valores máximo, $F_c(100\%)$, e mínimo, $F_c(0\%)$, conforme definidos na Equação 10.

$$f_c = \frac{F_c(y_{j-1}) - F_c(y_j)}{F_c(100\%) - F_c(0\%)} \quad (10)$$

onde $F_c(y_c)$ representa o valor do j -percentil, y_j , no canal de cor c , sendo j o número de percentis utilizado. Os valores de percentil podem ser definidos a partir da divisão do total de pixels da imagem em partes iguais, considerando valores de mínimo e máximo pré-definidos. Cavalin et al. (2006) consideraram uma margem de erro de 10% (5% nos valores iniciais e 5% nos valores finais), visando desconsiderar ruídos comuns nas imagens por eles utilizadas. Com isso, no caso deles, os percentis foram definidos a partir da divisão em 10 partes iguais de 90% do total de pixels.

No espaço de cor HSV o canal H (*Hue*) representa o matiz, porém, em outros espaços de cor, como o CIEL*a*b* e RGB, o matiz não pode ser obtido diretamente, podendo ser calculado. A Equação 11 representa o cálculo do matiz para o espaço de cor CIEL*a*b* (CIE, 2004), enquanto a Equação 12 representa o cálculo do matiz para o espaço de cor RGB (PREUCIL, 1953 apud GESLIN; JÉGOU; BEAUDOIN, 2016).

$$h_{ab} = \text{atan2}(b, a) \quad (11)$$

$$h_{rgb} = \text{atan2}(\sqrt{3} \cdot (G - B), 2 \cdot R - G - B) \quad (12)$$

onde a e b representam os valores dos canais a^* e b^* , respectivamente, no espaço de cor CIEL*a*b* e R , G e B representam, respectivamente, os valores dos canais R , G e B no espaço de cor RGB.

Semelhante ao cálculo do matiz, em alguns espaços de cor, como o CIEL*a*b*, é possível extrair outros atributos de cor, como o croma (Equação 13).

$$C_{ab} = \sqrt{a^2 + b^2} \quad (13)$$

onde a e b representam os valores dos canais a^* e b^* , respectivamente, no espaço de cor CIEL*a*b*.

Outra métrica passível de extração de característica de cor das imagens é diferença de cor ΔE , onde E representa a palavra alemã *Empfindung* (sensação).

Diferentes equações já foram propostas para o cálculo deste parâmetro, como, por exemplo, a indicada pela CIE em 1976, conhecida como $\Delta E76$, Equação 14, (CIE, 2004; MARTÍN; MIRÓ; MORENO, 2015):

$$\Delta E76 = \sqrt{\Delta L^2 + \Delta a^2 + \Delta b^2} \quad (14)$$


onde L, a, b representam, respectivamente, os valores do primeiro, segundo e terceiro canais no espaço de cor. O $\Delta E76$ baseia-se na distância euclidiana entre os pontos da matriz tridimensional da imagem colorida, sendo também utilizada em espaços de cor diferentes do CIEL*a*b*, substituindo L, a, b , na Equação 14, pelos valores dos canais de cor do espaço de cor utilizado (CIE, 2004; MARTÍN; MIRÓ; MORENO, 2015).

2.1.6 Classificação

Segundo Tan; Steinbach e Kumar (2009), classificação é a tarefa de organizar objetos em uma categoria, dentre diversas categorias pré-definidas, e é um problema presente em inúmeras aplicações. Em processamento de imagens, o objetivo da classificação pode ser definido como relacionar as propriedades extraídas de amostras e atribuir o mesmo rótulo às imagens com características semelhantes, tornando-as parte da mesma classe (PEDRINI; SCHWARTZ, 2008; SOLOMON; BRECKON, 2013).

Cada classe recebe um dentre os rótulos $\omega_1, \omega_2, \dots, \omega_l$, sendo l o número de classes de interesse no experimento. Um exemplo de classificação é o apresentado na Figura 13, relativo a classificação automática de objetos, por meio de uma cena de vista superior sobre uma esteira de rolagem. Analisando a forma apresentada pelos objetos, podem-se considerar três classes distintas, fazendo com que o objetivo do algoritmo classificador, no exemplo, seja encontrar um mapeamento a partir das propriedades de cada objeto para o conjunto $\lambda = \{\omega_1, \omega_2, \omega_3\}$ (PEDRINI; SCHWARTZ, 2008).

Figura 13 – Ilustração de uma visão superior de uma esteira de rolagem: (a) os objetos que podem ser classificados quanto a forma, e (b) objetos agrupados quanto a similaridade de forma.



Fonte: Adaptada de (PEDRINI; SCHWARTZ, 2008).

As técnicas de classificação podem ser divididas em duas principais categorias: supervisionada e não supervisionada. As técnicas do primeiro grupo se baseiam na existência de classes previamente definidas, sendo necessária uma etapa de treinamento para que os parâmetros que caracterizam cada classe sejam obtidos. Nesses casos, são utilizados conjuntos de amostras específicos para treinamento. O segundo conjunto de técnicas de classificação, não supervisionadas, fundamentam-se em exemplos não rotulados, buscando agrupar os objetos a partir de todo o corpo de características (PEDRINI; SCHWARTZ, 2008; SOLOMON; BRECKON, 2013).

Segundo Solomon e Breckon (2013), o desenvolvimento de um classificador pode ser representado pelo fluxograma da Figura 14.

Figura 14 – Fluxograma representando os principais passos no projeto de um classificador.



Fonte: (SOLOMON; BRECKON, 2013).

A definição das classes necessárias está diretamente relacionada com o objetivo do problema a ser solucionado. Quando abrange apenas duas classes, o sistema classificador é denominado binário, ou dicotomizador (SOLOMON; BRECKON, 2013). Por exemplo, em um sistema de análise de grãos o objetivo pode ser a classificação de imagens apenas em duas classes: contaminado e sadio.

Examinar os dados visa compreender os tipos de propriedades que podem distinguir as classes de acordo com o objetivo do classificador, tais como cor, forma ou textura. A partir dessa compreensão é definido o espaço, ou conjunto, de características a ser utilizado, buscando atender a duas fundamentais propriedades: ser compacto e discriminativo. Um conjunto compacto é importante pois seu tamanho tem influência direta no tamanho da amostra de treinamento. Ademais, é importante que as características sejam distribuídas pelas classes de maneira ampla e estatisticamente independentes umas das outras (SOLOMON; BRECKON, 2013).

A construção do classificador é realizada a partir de uma amostra de exemplos que pode ser rotulada com confiança para cada classe. Existem diversas abordagens que podem ser utilizadas na construção de um classificador a partir de um conjunto de dados de entrada, entre os mais utilizados estão árvores de decisão, redes neurais e máquinas de vetores de suporte. O objetivo de cada abordagem é empregar um algoritmo de aprendizagem na construção de um modelo que se adapte aos dados de

entrada, prevendo corretamente os rótulos de classes de registros novos, resultando em um modelo com capacidade de generalização satisfatória (TAN; STEINBACH; KUMAR, 2009; RUIZ; CATEN; DALMOLIN, 2014).

O teste do classificador desenvolvido, por outro lado, deve ser realizado com uma amostra de dados diferente, determinando se as etapas do processo de construção do classificador devem ser reconsideradas. Existem diversas técnicas para avaliar o desempenho do modelo gerado, permitindo a seleção do classificador com menor erro de generalização, ou que cumpra o critério de satisfação definido. Entre as técnicas mais abordadas podem-se citar a contagem simples, matriz de confusão e a validação cruzada (PEDRINI; SCHWARTZ, 2008).

A contagem simples consiste na determinação do número de amostras classificadas correta e incorretamente em relação ao conjunto de treinamento. A taxa para a ocorrência de uma classificação errada e pode ser calculada:

$$e = \frac{k_e}{a_t} \quad (15)$$

onde k_e representa o número de amostras classificadas incorretamente e a_t o número total de amostras (TAN; STEINBACH; KUMAR, 2009; PEDRINI; SCHWARTZ, 2008; SOLOMON; BRECKON, 2013).

O grau de confiança obtido na Equação 15 pode ser maior quando aplicado ao conjunto de teste, uma vez que a aplicação desta equação no mesmo conjunto de treinamento pode tornar as taxas tendenciosas. Uma abordagem considerada para a seleção do conjunto de treinamento é a divisão do total de amostras, de modo a utilizar cerca de 70% para treinamento e as demais para teste. Por outro lado, a separação do total de amostras em dois conjuntos independentes pode aumentar a instabilidade do modelo, pois reduz a quantidade de amostras de treinamento (PEDRINI; SCHWARTZ, 2008; TAN; STEINBACH; KUMAR, 2009).

Diferentemente da contagem simples, a matriz de confusão pode propiciar informações mais específicas sobre as classificações realizadas correta e incorretamente por classe. Definida como uma matriz quadrada, com número de linhas igual ao número de classes, uma matriz de confusão tabula as amostras classificadas correta e incorretamente. Os elementos da diagonal principal da matriz caracterizam as corretas classificações por classe e os demais elementos

representam as classificações incorretas. Em um conjunto de dados categorizados em duas classes, sim e não, a matriz de confusão segue o modelo apresentado na Figura 15 (PEDRINI; SCHWARTZ, 2008; TAN; STEINBACH; KUMAR, 2009; WITTEN; FRANK; HALL, 2011).

Figura 15 – Matriz de confusão - diferentes saídas em uma classificação de duas classes.

		Classe predita pelo classificador	
		sim	não
Classe observada no conjunto de dados	sim	Corretamente classificado (verdadeiro positivo)	Incorretamente classificado (falso negativo)
	não	Incorretamente classificado (falso positivo)	Corretamente classificado (verdadeiro negativo)

Fonte: Adaptada de (WITTEN; FRANK; HALL, 2011).

A validação cruzada é uma técnica para separação de amostras, na qual cada registro é usado o mesmo número de vezes para treinamento e uma vez para teste. O objetivo é o maior aproveitamento do total de amostra para incrementar o grau de confiança na estimativa da taxa de erro. Na comparação do desempenho relativo entre dois ou mais classificadores é comum a utilização de teste estatísticos para hipóteses, como, por exemplo, o teste t (PEDRINI; SCHWARTZ, 2008; TAN; STEINBACH; KUMAR, 2009).

2.1.6.1 Ferramenta WEKA

WEKA (*Waikato Environment for Knowledge Analysis* - Ambiente Waikato para Análise de Conhecimento) é uma ferramenta desenvolvida pela Universidade Waikato, Nova Zelândia, em 1993 (CUNNINGHAM; DENIZE, 1993). Desenvolvida na linguagem de programação Java, a WEKA oferece uma coleção de algoritmos de aprendizado de máquina, além de ferramentas de pré-processamento de dados. Com o WEKA é possível realizar experimentos rápidos e comparações com diferentes métodos de mineração de dados, como classificação e regressão com diversos conjuntos de dados. Os algoritmos disponíveis englobam árvores de decisão, redes neurais e máquinas de vetores de suportes (AGRAWAL et al., 2013; WITTEN; FRANK; HALL, 2011).

Uma árvore de decisão pode ser interpretada como uma estrutura de nodos conectados por ramos, sendo os nodos entendidos como atributos classificatórios e

os ramos correspondentes descendentes entendidos como possíveis valores. Cada nodo folha recebe um rótulo de classe, por conseguinte, os caminhos completos da árvore determinam as regras de classificação (TAN; STEINBACH; KUMAR, 2009, RUIZ; CATEN; DALMOLIN, 2014). Um exemplo de algoritmo de árvore de decisão utilizado em classificadores é o C4.5, inicialmente desenvolvido por Ross Quinlan, e implementado na opção de classificador J48 na ferramenta WEKA (WITTEN; FRANK; HALL, 2011).

Diferente das árvores de decisão, os métodos que utilizam redes neurais e máquinas de vetores de suporte exigem maior tempo de processamento e apresentam maior dificuldade de interpretação (RUIZ; CATEN; DALMOLIN, 2014). Uma rede neural artificial é composta por um conjunto interconectado de nodos e ligações direcionadas. Os nodos representam os neurônios artificiais e as arestas orientadas, ou ligações direcionadas, as conexões entre as entradas e saídas dos neurônios. O modelo de rede neural mais simples, de uma unidade perceptron, mapeia múltiplas entradas de valores reais para uma saída binária. Para cenários de maior complexidade são utilizados modelos de redes neurais de múltiplas camadas intermediárias entre as camadas de entrada e saída, denominadas camadas ocultas (PEDRINI; SCHWARTZ, 2008; TAN; STEINBACH; KUMAR, 2009). Um dos modelos de rede neural mais utilizados em classificadores é o de retro propagação, disponível na coleção WEKA sob o nome MultilayerPerceptron (WITTEN; FRANK; HALL, 2011).

Máquina de vetores de suporte é outra técnica de classificação bastante utilizada, mostrando bons resultados com dados de alta dimensionalidade. Baseada na teoria de aprendizagem estatística, essa abordagem utiliza um subconjunto dos exemplos de treinamento, vetor de suporte, na representação do limite de decisão (TAN; STEINBACH; KUMAR, 2009). O algoritmo seleciona um conjunto de instâncias de limite crítico, chamadas vetores de suporte, de cada classe para construir uma função linear discriminante que separe as instâncias por classes o mais amplamente possível. O algoritmo de otimização mínima sequencial é um algoritmo desenvolvido sob os conceitos de máquina de vetores de suporte disponível na ferramenta WEKA, sob o nome SMO (WITTEN; FRANK; HALL, 2011).

A ferramenta WEKA disponibiliza ainda opções de validação, como a validação cruzada, com definição do percentual da base destinada para teste e a opção de especificar um conjunto específico para teste. Após a validação, a

ferramenta exibe informações específicas do classificador, como a árvore criada, no caso de classificadores baseados em árvores de decisão; e índices de estimativa da performance do classificador, sobre todo o conjunto de dados de teste e separados por classe; e a matriz de confusão. Dentre as informações de performance estão as quantidades de dados corretamente e incorretamente classificados (*Correctly Classified Instances* e *Incorrectly Classified Instances*), o índice Kappa (*Kappa statistic*), o erro absoluto médio (*Mean absolute error*) e a raiz do erro quadrático relativo (*Root relative-squared error*) (WITTEN; FRANK; HALL, 2011).

O índice Kappa, cujo valor máximo é 100%, é usado para mensurar a consonância entre a categorização predita e observada no conjunto de dados de teste, considerando ajuste de classificações ao acaso, e é expresso como uma proporção das corretas classificações sobre o total de dados. O erro absoluto médio é a média dos erros individuais, sem considerar perdas (Equação 16). A raiz do erro quadrático relativo considera o valor médio da base de treinamento, ou seja, é a raiz do erro quadrático total dividido pelo erro quadrático sobre a base de treinamento (Equação 17) (WITTEN; FRANK; HALL, 2011):

$$\text{Erro absoluto médio} = \frac{\sum_{w=1}^{\mu} (|p'_w - a'_w|)}{\mu} \quad (16)$$

$$\text{Raiz do erro quadrático relativo} = \sqrt{\frac{\sum_{w=1}^{\mu} (p'_w - a'_w)^2}{\sum_{w=1}^{\mu} (a'_w - \bar{a}')^2}} \quad (17)$$

sendo μ o total de instâncias na base de treinamento, p'_w o valor predito para a instância w , a'_w o valor real da instância w e $\bar{a}'$ o valor real médio sobre a base de treinamento.

A partir dos índices de desempenho e a matriz de confusão exibidos na tela de saída da ferramenta WEKA é possível analisar o desempenho do classificador sobre os dados, apoiando assim decisões como a adoção do classificador ou a necessidade de operações a parte sobre os dados, como a consideração de um conjunto maior de dados ou agrupamento destes.

Com a ferramenta WEKA existe ainda a possibilidade de integração com sistemas desenvolvidos na linguagem Java, por meio de sua API (*Application*

Programming Interface – Interface de Programação de Aplicativos). A integração torna disponíveis os algoritmos e funções da coleção sem a necessidade de uso da interface padrão (WITTEN; FRANK; HALL, 2011).

2.2 QUALIDADE DE SEMENTES

As primeiras regulamentações sobre o cultivo de sementes foram criadas pelo governo suíço em 1816, iniciando a preocupação com a qualidade de sementes. Somente cerca de 50 anos depois, foi inaugurado o primeiro espaço para análise de sementes. Porém, apenas em 1976 foi criado, por um laboratório alemão, o primeiro manual de análise de sementes. Também em 1976, foi criado no Brasil o primeiro Manual de Regras para Análise de Sementes. Atualmente o país produz sementes para abastecer o mercado interno e para exportação e existem centenas de laboratórios para análise de sementes no país, sendo que em julho de 2015 existiam 293 laboratórios registrados em 18 municípios (CARVALHO et al., 2015).

Segundo Costa et al. (2003), a adoção de regras claras de controle de qualidade de sementes de soja é de fundamental importância na cadeia produtiva da cultura. A utilização de sementes de alta qualidade garante a população adequada de plantas, além um controle eficiente de ervas daninhas e de introdução de patógenos em áreas indenizadas. Sementes de soja de alta qualidade apresentam características de alta qualidade fisiológica, física e sanitária, refletindo no desempenho destas em campo.

A qualidade fisiológica da semente de soja se refere, principalmente, as taxas de vigor e germinação, que podem ser deterioradas por oscilações de umidade em campo. Outra causa de prejuízo à qualidade fisiológica, no caso da semente de soja, é o percevejo, pois, ao picá-la, este inocula o fungo *Nematospora coryli*, que pode provocar a necrose dos tecidos. Também é necessário considerar a quantidade de sementes esverdeadas, sendo que se passar de 9% da quantidade de sementes do lote, este não deve ser comercializado por ter a qualidade fisiológica comprometida (KRZYZANOWSKI et al., 2008).

Quanto à qualidade física de um lote de sementes de soja, é necessário considerar pureza física, uniformidade de tamanho e dano mecânico, pois estes fatores são importantes para o estabelecimento da lavoura, já que influenciam a germinação e emergência das plântulas (KRZYZANOWSKI et al., 2008).

De acordo com o MAPA (2009), a qualidade sanitária da semente de soja refere-se, primeiramente, à presença de agentes patogênicos, como fungos, bactérias e vírus. A baixa qualidade sanitária pode afetar negativamente a qualidade fisiológica assim como a sanidade da lavoura, já que diversos fungos, como *Fusarium* spp., *Colletotrichum truncatum* e *Cercospora kikuchii*, contribuem para redução do vigor e germinação (KRZYZANOWSKI et al., 2008).

O fungo *Cercospora kikuchii* (MATSUMOTO; TOMOYASU, 1925) é o agente causal da mancha púrpura em sementes de soja, além da mancha foliar. A presença da coloração de róseo a púrpura, variando de pontuações até toda a superfície das sementes de soja, facilita a identificação do fungo, bastando assim a observação desta presença para a identificação (COSTA, 1996; GOULART, 2005). Os primeiros relatos de sementes de soja com sintomas característicos de contaminação pelo *Cercospora kikuchii* se iniciaram na Coreia em 1921 e relatado em 1922 no Japão. Sementes contaminadas podem aumentar a incidência de plantas infectadas, o que pode reduzir a qualidade dos grãos produzidos (IMAZAKI et al., 2006).

A presença deste fungo nas sementes pode influir no início do desenvolvimento, penetrando na semente e passando às folhas primárias, produzindo posteriormente áreas com necrose, mais comum nas folhas, evidenciando a redução de vigor, qualidade e produção. Também há grande produção de esporos que podem infectar plantas sadias (IMAZAKI; SASAHARA; KOIZUMI, 2007; COSTA, 1996; LURÁ et al., 2011). Contradizendo outros autores (IMAZAKI; SASAHARA; KOIZUMI, 2007), Galli et al. (2015) concluíram que a presença do *Cercospora kikuchii* não prejudica a germinação das sementes de soja.

A contaminação por esse fungo reduz o valor comercial da soja, pois por diversos padrões, os grãos com sua presença são classificados como de menor qualidade. No Brasil, um lote de sementes de soja não deve conter mais de 10% de presença de sementes com sintomas do fungo *Cercospora kikuchii* para ser considerado de qualidade, de acordo com o manual para análise de sementes de trigo e soja (BRASIL, 1998; IMAZAKI et al., 2006). Esse fungo é considerado como um dos fungos prejudiciais a cultura da soja de maior importância econômica, pois além de prejudicar os grãos produzidos sob aspectos físicos e químicos, reduz a qualidade do óleo extraído. A produção de óleo de soja com grãos contaminados pelo fungo pode resultar em maior concentração livre de ácidos graxos e menor produção no

refinamento. O óleo produzido também tem aspectos prejudicados, como coloração mais escura, sabor não característico, maior quantidade de proteínas e menor quantidade de carboidratos (WANG et al., 2004).

De fato, um dos procedimentos que pode garantir a qualidade de um lote de sementes de soja é a inspeção visual. Porém, esse procedimento pode ser impreciso, devido à subjetividade inerente ao analista, além de demandar tempo. Existem também procedimentos químicos para identificação de patógenos, como fungos, porém estes destroem as amostras, são custosos e lentos (LIU et al., 2015). Assim, a automatização do processo de inspeção visual se torna vantajosa, e pode ser alcançado por meio de sistemas de processamento digital de imagens.

2.2.1 Processamento digital de imagens na qualidade de sementes


O processamento digital de imagens tem auxiliado muitos autores na busca de novos métodos para seleção e análise de qualidade de sementes em diversas culturas (AHMAD et al., 1998), (GUNASEKARAN et al., 1988), (KHATCHATOURIAN; PADILHA; 2008), (LIU et al., 2015), (PAULSEN et al., 1989), (RODRÍGUEZ-PULIDO et al., 2012) e (ZAPOTOCZNY, 2011).

Rodríguez-Pulido et al. (2012) analisaram sementes de uva utilizando técnicas de PDI, com extração de características de cor com o espaço de cor CIEL*a*b* e atributos físicos. No trabalho, os autores utilizaram o sistema de processamento de imagens digitais DigiEye, comparando análises químicas convencionais com as informações extraídas das imagens visando verificar a correlação com a maturação das sementes de uva. Com um coeficiente de correlação $R^2 = 0,97$, os autores concluíram que o processamento de imagens se apresenta como uma alternativa versátil e de baixo custo para mensuração de cores e aparência de sementes de uva.

Na análise de sementes de soja, Liu et al. (2015) desenvolveram um equipamento próprio (Figura 16) para identificação e eliminação de sementes. No trabalho foram consideradas sementes com cinco tipos de danos diferentes, incluindo sementes mofadas. Foi utilizada uma rede neural de retro propagação, considerando como neurônios características de forma, cor e textura de imagens. O sistema lê uma semente por vez para avaliação. Assim como no trabalho desenvolvido por Rodríguez-Pulido et al. (2012), o espaço de cor utilizado foi o CIEL*a*b*. Os autores destacam que o desenvolvimento do equipamento de aquisição promoveu um ambiente de luminosidade controlada por duas fontes de iluminação posicionadas a 45° e 40

centímetros de distância da câmera, aumentando a qualidade da aquisição das imagens. Como resultados, os autores obtiveram classificações com precisão que variaram entre 94% e 100%, sendo que o resultado de 100% foi alcançado na identificação de sementes não danificadas.

Figura 16 – Equipamento de aquisição e eliminação de sementes desenvolvido por Liu et al. (2015).



Fonte: (LIU et al., 2015).

Paulsen et al. (1989) buscaram classificar sementes de soja danificadas por quatro fungos: *Cercospora kikuchii*, *Fusarium* spp., *Phomopsis* spp. e *Alternaria* spp. Para tanto, foram utilizados critérios de cores, no modelo de cores RGB, obtendo até 98% de precisão na identificação de sementes contaminadas por um dos fungos. O classificador utilizado foi baseado em regras de características de cores. A determinação do fungo variou entre 66% com *Cercospora kikuchii* e *Phomopsis* spp. e 96% com o fungo *Alternaria* spp.

Ahmad et al. (1998), utilizando também RGB como espaço de cor, buscaram a classificação de sementes de soja com os quatro fungos analisados por Paulsen et al. (1989), mais sementes esverdeadas (imaturas) e contaminadas pelo vírus do mosaico. Nesse estudo a classificação de sementes afetadas pelo *Cercospora kikuchii* foi precisa em 83% dos testes realizados. A metodologia adotada nos dois trabalhos

(AHMAD et al., 1998; PAULSEN et al., 1989) foi diferente no que tange a extração de características, embora ambos tenham utilizado apenas critérios de cores, indicando que, mesmo em contextos semelhantes, a análise de método de extração de informação de cor tem grande influência no resultado final.

Também analisando sementes de soja, porém para identificação dentre oito variedades, Khatchatourian e Padilha (2008) utilizaram redes neurais como algoritmo classificador. A acurácia do método desenvolvido variou entre 42,9% e 77,1%. Os autores optaram por utilizar um fundo preto para as imagens e, assim como Ahamad et al. (1999) e Paulsen et al. (1989), Khatchatourian e Padilha (2008) utilizaram câmeras fotográficas posicionada a 90° para a captura das imagens. Porém os autores não ressaltam detalhes a respeito dos métodos de aquisição utilizados, como posicionamento da fonte de iluminação.

Zapotoczny (2011) também utilizou fundo preto para as imagens, no entanto, diferentemente dos demais autores, optou por um scanner Epson Perfection, modelo 4490 Photo, como equipamento de captura para a aquisição, que já promove a captura em ângulo de 90° do objeto e fonte de iluminação. O estudo objetivou a identificação de variedades de trigo utilizando métodos de medição e rede neural artificial. Para as 11 variedades avaliadas, o método desenvolvido atingiu 100% de acurácia.

Gunasekaran et al. (1988) buscaram desenvolver um método baseado na análise de níveis de cinza das imagens, para identificação de sementes de soja com dois tipos de danos mecânicos, atingindo 96% de acurácia em sementes com rachaduras no tegumento e 100% em semente com rachaduras de cotilédone. O trabalho de Gunasekaran et al. (1988), diferentes de muitos dos autores encontrados na literatura, detalha experimentos a respeito da etapa de aquisição das imagens. Durante o desenvolvimento do trabalho, foram realizados experimentos variando fundos para as imagens, como placas pretas, vidro fosco e vidro branco. Também variou o posicionamento das fontes de iluminação: diretamente sobre as sementes, diretamente abaixo das sementes e uma fonte a 45° na direita e outra igual na esquerda. Das avaliadas, a combinação que mostrou melhor resultado foi com fundo preto e com a fonte de luz sob as sementes.

3 METODOLOGIA

Para avaliar a metodologia mais adequada para a construção do sistema de identificação de sementes de soja contaminadas pelo fungo *Cercospora kikuchii*, foram inicialmente estudados artigos e demais materiais bibliográficos. Posteriormente, foram realizados experimentos com os métodos elaborados a partir do material estudado. Foram avaliados sistemas de aquisição de imagens, métodos de segmentação e extração de características e, com o apoio da ferramenta WEKA, classificadores.

O Laboratório de Patologia de Sementes do Departamento de Fitotecnia e Fitossanidade da Universidade Estadual de Ponta Grossa (UEPG) forneceu amostras de sementes de soja com presença de mancha púrpura e sementes de soja sadias, dentre as quais foram selecionados aleatoriamente conjuntos de sementes sadias e contaminadas para a realização dos experimentos.

3.1 AQUISIÇÃO DAS IMAGENS

Na seção 2.1 foram descritos os fatores de maior complexidade e os obstáculos presentes na construção de sistemas de processamento digital de imagens, entre eles os de maior relevância na aquisição de imagens. Para compreensão da influência desses fatores, e o desenvolvimento de um sistema de aquisição adequado para sementes de soja, foram elaborados sete sistemas de aquisição, para avaliação de suas características, por meio de experimentos. Foram exploradas principalmente variáveis como sistema de iluminação, sensor de captura e plano de fundo.


3.1.1 Sistema de aquisição 1 – Scanner HP

Inicialmente buscou-se avaliar a influência do fundo no contraste das imagens de semente de soja (FRANCO et al., 2015a). Foi utilizado como sensor de captura um scanner de uma impressora multifuncional da marca HP (Hewlett-Packard), modelo LaserJet M1120 MPP, com resolução de 150 dpi, semelhante a Khatchatourian e Padilha (2008). A seleção desse dispositivo de captura levou em consideração o modelo de projeção ortográfico utilizado pelo equipamento, uma vez que neste modelo os efeitos de perspectiva podem ser desprezados, fator com influência na qualidade das imagens, segundo Liu et al. (2015). Também foi considerado o sistema de iluminação do scanner, pois este apresenta iluminação controlada e com baixas

variações, característica também com atuação na qualidade final, como concluído por Gunasekaran et al. (1988) e Zhou et al. (2015).

Para avaliação do fundo, foram produzidas imagens com três diferentes fundos: preto, verde e azul, uma vez que estas são as comumente utilizadas em estúdios fotográficos e de vídeo, bem como citadas pelos autores de trabalhos similares (GUNASEKARAN et al.; 1988), (KHATCHATOURIAN; PADILHA; 2008) e (LIU et al., 2015). Todos os fundos foram feitos do mesmo material, Espuma Vinílica Acetinada (EVA), e foram instalados envolvendo a tampa do scanner (Figura 17).

Figura 17 – Aquisição de imagens com Scanner HP LaserJet M1120 MPP.



Fonte: (FRANCO et al., 2015a).

Neste experimento, foram utilizados dois conjuntos de 50 sementes, um deles com sementes saudáveis e o outro com sementes contaminadas. Como Liu et al. (2015), as imagens foram delimitadas nas dimensões 10 cm de lado. Para auxiliar na limitação do tamanho e na distribuição das sementes pela superfície do scanner, foi utilizada uma moldura de EVA com 1 cm de espessura. Considerando os dois conjuntos de sementes e os três fundos a serem avaliados, foram produzidas no total de seis imagens para processamento e análise.

O processamento das imagens foi realizado utilizando um sistema desenvolvido especificamente para tal. Diferente de autores como Liu et al. (2015) e Khatchatourian e Padilha (2008), que utilizaram a MatLab, o sistema foi escrito na linguagem Java. Também foi utilizada a biblioteca OpenCV na versão 2.4.0. OpenCV é uma biblioteca de código aberto para visão computacional, uma das bibliotecas mais amplamente utilizada no processamento de imagens com código aberto. Mantida pela

Intel Corporation, foi escrita nas linguagens C e C++, e tem suporte para diferentes sistemas operacionais e linguagens (BRADSKY; KAEHLER; 2008; SUGANO; MIYAMOTO, 2010). Para a utilização das rotinas dessa biblioteca por meio da linguagem Java, foi utilizada a interface JavaCV 1.0. O computador utilizado na captura das imagens, no desenvolvimento do software e na realização dos experimentos foi um notebook da marca HP, com processador AMD Phenom II Quad-Core 1,6 Ghz, 6,00 GB de memória RAM e sistema operacional Microsoft Windows 7 64-bits.

Após a captura das imagens, foi utilizado o editor de imagens Gimp 2.8 para recortar as imagens em tamanhos iguais, de maneira a permanecer apenas as sementes nas imagens para processamento. O algoritmo de processamento das imagens teve como funções principais a segmentação das sementes nas imagens, a contagem destas e a soma da área, em pixels, das regiões de semente. Primeiramente, o sistema realizou a segmentação das imagens utilizando limiares fixos por canal de cor, selecionados empiricamente. Em seguida, foram identificadas as sementes considerando as regiões segmentadas com área superior a 100 pixels, para assim desconsiderar pequenos ruídos. Então, foi calculado o total de pixels das regiões consideradas como sementes. O sistema também criou novas imagens com desenho de contornos nas sementes identificadas, para auxiliar na análise visual posterior.

3.1.2 Sistema de aquisição 2 – Scanners HP e Epson


O segundo experimento visou avaliar as diferenças de qualidade de aquisição entre os scanners de uma impressora multifuncional da marca HP, modelo LaserJet M1120 MPP, utilizado no experimento anterior, e um scanner profissional Epson, modelo Perfection V700 Photo (FRANCO et al., 2015b). Como no primeiro experimento, foram avaliados os fundos preto, verde e azul, utilizando folhas de EVA, totalizando 12 imagens para avaliação. As demais condições (como posicionamento das sementes no scanner e resolução das imagens), número de sementes, e o sistema de processamento das imagens, foram as mesmas do sistema de aquisição 1.

3.1.3 Sistema de aquisição 3 – Scanner Epson com iluminação externa

O sistema de aquisição 3 buscou o aprimoramento do sistema anterior, com base em seus resultados. Foram considerados cinco arranjos e três resoluções diferentes, utilizando o scanner profissional Epson, modelo Perfection V700 Photo, produzindo 30 imagens para análise (FRANCO; FALATE; MARUYAMA, 2016). Com o objetivo de reduzir as sombras projetadas pelas sementes, foi mensurada a altura média das sementes do conjunto de sementes com um paquímetro digital, e alterada a altura da moldura de EVA, que limita a área da imagem em 10 cm de lado, para 0,5 cm de espessura.

Além da avaliação dos fundos em EVA (preto, verde e azul), neste experimento foram avaliadas condições de iluminação. Todas as imagens foram adquiridas em ambiente escuro, também foram produzidas imagens utilizando o scanner aberto e com a combinação de iluminação externa (Figura 18). A iluminação externa foi promovida por três refletores comerciais compostos por quatro lâmpadas fluorescentes de 45 W cada. As imagens foram produzidas nas resoluções 150 dpi, 300 dpi e 600 dpi.

Figura 18 – Aquisição de imagens com Scanner Epson V700 Photo e iluminação externa.



Fonte: Adaptada de (FRANCO; FALATE; MARUYAMA, 2016).

Como nos experimentos anteriores, foi desenvolvido um sistema de processamento na linguagem Java, utilizando a biblioteca OpenCV, porém na versão 2.4.13 e JavaCV na versão 1.1. O computador utilizado na captura das imagens, desenvolvimento do software e realização dos experimentos foi um notebook da marca Dell, com processador Intel i7, 8,00 GB de memória RAM e sistema operacional Microsoft Windows 10 64-bits. Como nos anteriores, neste experimento foram utilizados dois conjuntos de sementes: um de 50 sementes sadias e outro de 50 sementes contaminadas.

O algoritmo desenvolvido utilizou como técnica de segmentação o método Otsu (1979), por ser uma técnica de limiarização automatizada a partir do cálculo do limiar ótimo, utilizando de cálculos estatísticos (GONZALEZ; WOODS, 2010). Para considerar uma região segmentada como semente, foi delimitada a área mínima em 150 pixels nas imagens de 150 dpi, 800 pixels nas imagens de 300 dpi, e 3000 pixels nas imagens de 600 dpi, valores selecionados empiricamente.

Após a identificação das sementes, estas foram contabilizadas e foram calculados os valores de área e o perímetro dos contornos. Para facilitar a análise visual, também foram produzidas imagens com os contornos desenhados nas sementes identificadas.

3.1.4 Sistema de aquisição 4 – Captura por vídeo

Foi observado que os autores estudados não abordam a aquisição de imagens de múltiplas faces das sementes, apenas sendo destacado em poucos dos trabalhos, como Gunasekaran et al. (1988), que o correto posicionamento das sementes influencia no sucesso da classificação destas. Visando abordar tal questão, foram realizados experimentos com captura de vídeo de sementes em movimento, utilizando uma câmera digital Canon, modelo EOS REBEL T5i e uma câmera GoPro, modelo Hero 4. Porém, com os equipamentos disponíveis não foi possível capturar imagens nítidas da semente. Maiores detalhes são relatados no Apêndice A.

3.1.5 Sistema de aquisição 5 – Luz direta

O sistema de aquisição 5 fez parte do projeto de Weiber, Franco e Falate (2016) e teve como objetivo avaliar imagens capturadas com luz de fundo, como Gunasekaran et al. (1988). Foi utilizada como dispositivo de captura uma câmera digital DSLR da marca Canon, modelo EOS REBEL T5i, acoplada a um tripé, visando

o emprego do plano ortográfico. Autores como Lin et al. (2014) e Khatchatourian e Padilha (2008) também selecionaram câmeras digitais como equipamento para captura das imagens.

Utilizou-se também uma mesa de Still, equipamento que permite a passagem de luz de maneira uniforme e indireta. Esse equipamento é comumente empregado em estúdios fotográficos especializados em fotografar objetos. Como fonte de iluminação, foram utilizadas duas luminárias com lâmpadas de LED de 16 W cada, posicionadas em 45°, e um refletor comercial de quatro lâmpadas fluorescentes posicionado sub a mesa, arranjo semelhante ao utilizado por Gunasekaran et al. (1988). A fim de comparação, também foram produzidas imagens com fundos em EVA (preto, verde e azul) e sem iluminação, produzindo no total 10 imagens.


Ainda, foi utilizada uma lente do tipo zoom, configurada para distância focal de 55 mm e abertura de f5,6. A sensibilidade ISO utilizada foi de 400 e a velocidade do obturador foi de 1/125 segundos. A configuração de balanço de branco foi selecionada como automática, sendo assim controlada pelo sistema da câmera. Essas configurações foram selecionadas empiricamente a partir de experimentos pontuais. A resolução utilizada foi a máxima disponível no equipamento, 18 megapixels, resultando em imagens com dimensões de 5184 pixels por 3456 pixels.

Foram utilizados dois conjuntos de sementes, um de sementes contaminadas e outro de sementes sadias, ambos com seis sementes cada. O pré-processamento das imagens neste experimento envolveu, além do recorte das imagens, a conversão destas do formato RAW para PNG, utilizando o software Digital Photo Professional, fornecido pelo fabricante da câmera e o software Adobe Photoshop Elements 11, fornecido pelo fabricante do scanner Epson, utilizado nos sistemas de aquisição 2 e 3. O sistema de processamento utilizado foi semelhante aos anteriores, empregando a segmentação pelo método Otsu e a contagem das sementes identificadas. Porém, devida a dimensão das imagens produzidas, foi necessário um ajuste na área mínima utilizada para redução de ruído, sendo considerados como sementes apenas os contornos identificados com mais de 5000 pixels.

3.1.6 Sistema de aquisição 6 – Luz indireta

Visando aprimorar o experimento anterior, foram produzidas imagens substituindo a luz direta por luz indireta. O sistema de iluminação foi composto de duas fontes de luz laterais posicionadas em 45°, provenientes de dois refletores comerciais com quatro lâmpadas fluorescentes de 45 W cada (Figura 19).

Figura 19 – Arranjo para aquisição de imagens do sistema de aquisição 6 – Luz indireta.



Fonte: (FRANCO; SANDRINO; FALATE, 2016).

Como anteriormente, foi utilizada a câmera digital DSLR da marca Canon, modelo EOS REBEL T5i, porém empregando a lente macro de 60 mm, com abertura f14. A quantidade de sementes foi reduzida de 50 para 30, devido ao limite de ângulo de visão da lente. Assim, foram produzidas imagens com conjuntos de uma e 30 sementes, para avaliar o desempenho das técnicas de segmentação com diferentes quantidades de objetos a serem identificados na imagem.

A velocidade de captura foi igual àquela configurada para a produção das imagens do sistema de aquisição 5, 1/125 segundos. Já a configuração ISO foi alterada para adaptar a exposição das imagens a menor incidência de luz do novo sistema. Foram produzidas imagens com ISO 800 e 1600, para avaliar a influência da configuração no processo de segmentação. Considerando a quantidade de amostras

e a variação de ISO, foram produzidas o total de oito imagens para análise, todas utilizando a iluminação sob a mesa. Para evitar flutuações na temperatura da luz sobre as sementes, foi respeitado um tempo de cinco minutos com os refletores ligados antes da captura das imagens.

Antes do processamento das imagens estas foram submetidas ao mesmo processo de pré-processamento que as do sistema de aquisição 5: recorte e conversão do formato RAW para PNG.


O processo de segmentação utilizado na avaliação deste sistema consistiu na comparação do desempenho na identificação das sementes na imagem por contagem e soma das áreas em pixels, utilizando duas técnicas de segmentação: método Otsu e uma variação deste para imagens coloridas (FRANCO; SANDRINO; FALATE, 2016). O método Otsu é aplicado sobre imagens em escala cinza, já a variação desenvolvida para imagens coloridas consistiu no uso do cálculo do limiar ótimo de Otsu para cada canal de cor, realizando a limiarização de forma individual, e, posteriormente, usando os resultados de cada canal na construção de uma nova imagem binária.

3.1.7 Sistema de aquisição 7 – Final

A partir dos resultados dos sistemas de aquisição avaliados foram definidas as especificações para aquisição das imagens a serem utilizadas para sementes de soja saudáveis e com fungo *Cercospora kikuchii*. A definição do sistema de aquisição é importante e influencia nas demais etapas do processamento digital de imagens deste trabalho.

Desse modo, o sistema de aquisição de imagens elaborado para a classificação de sementes é baseado especialmente no sistema de aquisição 6 – Luz indireta, adotando o mesmo sistema de iluminação. Foi utilizada a lente de 55 mm com abertura f 14, configuração ISO 800 e velocidade 1/125 segundos. Com a utilização da lente de 55 mm foi possível utilizar subconjuntos de 50 sementes cada, sendo selecionadas três conjuntos de sementes saudáveis e três de sementes contaminadas, totalizando seis imagens e 300 sementes (Figura 20).

Figura 20 – Disposição dos equipamentos no sistema de aquisição utilizado no trabalho.



Fonte: a autora.

3.2 SISTEMA COMPUTACIONAL

Após definido o sistema de aquisição das imagens, foi desenvolvido o sistema de processamento cujo objetivo final é a classificação das sementes de soja entre sadias e contaminadas pelo fungo *Cercospora kikuchii*. Diferentemente de autores como Liu et al. (2015), que utilizaram a linguagem de programação Matlab para o desenvolvimento do sistema de processamento digital de imagens, neste trabalho foi utilizada a linguagem de programação Java, juntamente com a biblioteca OpenCV na versão 2.4.13. Como plataforma de desenvolvimento, foi adotada a IDE (*Integrated Development Environment* – Ambiente de Desenvolvimento Integrado) NetBeans 7.0.1 e o computador utilizado foi um notebook da marca Dell, com processador Intel® Core™ i7 – 5500U 2.40 GHz e 8GB de memória RAM, com sistema operacional Windows 10 64-bits.


3.2.1 Segmentação

Durante os experimentos iniciais de aquisição de imagens o espaço de cor RGB para identificação das sementes de soja atendeu satisfatoriamente, porém, nas demais etapas do processamento das imagens, outros espaços de cor foram considerados: RGB, CIEL*a*b* e HSV. Também foram realizadas validações quanto a performance da técnica de segmentação utilizando imagens com 10 sementes, incluindo sadias e contaminadas, na mesma imagem. Como nos experimentos iniciais,

foram calculadas a área, em pixels, das regiões consideradas como sementes pela segmentação e a quantidade de sementes identificadas. A área mínima considerada como semente, diferentemente dos experimentos iniciais, foi de 300 pixels, apenas eliminando pequenos ruídos como possíveis grãos de poeira presentes durante a aquisição.

Assim, inicialmente o sistema desenvolvido converte as imagens, originalmente em RGB, para os espaços de cor HSV e CIEL*a*b*. Utilizando imagens nos três espaços de cor, o sistema então realiza a segmentação das imagens utilizando uma variação do método Otsu para imagens coloridas (FRANCO; SANDRINO; FALATE, 2016). Para a aplicação dessa técnica de segmentação, como utilizada no sistema de aquisição 6, primeiramente as imagens coloridas foram separadas em três imagens, cada uma referente a um dos canais de cor, produzindo três imagens monocromáticas. Após, foi realizada a limiarização das três imagens utilizando o limiar ótimo calculado pelo método de Otsu. Então, as três imagens binárias resultantes foram usadas na construção de uma nova imagem binária, de modo que os pixels considerados como fundo, ou objeto, na imagem final assim o são em um ou mais dos canais. A Figura 21 ilustra as etapas do processo utilizado na técnica de segmentação.

Figura 21 – Técnica de segmentação utilizada – Variação do método Otsu para imagens coloridas.



Fonte: a autora.

A partir das imagens binárias em cada espaço de cor, o sistema encontra o contorno das sementes identificadas nas imagens coloridas. Cada semente foi cortada, criando uma nova imagem com a área equivalente ao menor retângulo capaz de englobar todos os pixels da semente. Também foram criadas imagens aplicando as imagens binárias resultantes sobre as imagens originais (coloridas), de modo a resultar em imagens coloridas com fundo uniforme, ou seja, os pixels correspondentes às sementes permaneceram coloridos como na imagem original, enquanto os pixels correspondentes ao fundo foram formados com as mesmas características da imagem binária, separando assim os objetos de interesse (sementes) do fundo da imagem.

3.2.2 Extração de características

Com as novas imagens de sementes individuais o sistema faz a extração das características para classificação. Segundo Costa (1996) e Goulart (2005), a principal característica de sementes contaminadas pelo fungo *Cercospora kikuchii* é a alteração da cor, assim, foram extraídas as características de cores sobre as imagens segmentadas. Para o processo de extração de características, as imagens criadas pelo processo de segmentação são primeiramente convertidas para os espaços de cor avaliados (HSV e CIEL*a*b*), uma vez que o processo anterior cria as imagens no espaço RGB.

Nos três espaços de cor avaliados foram extraídos os valores de percentil por canal de cor, como o método descrito por Cavalin et al. (2006), conforme descrito na seção 2.1.5. Os valores de percentis foram definidos a partir da divisão em 10 partes iguais como em Cavalin et al. (2006), porém os valores de mínimo e máximo utilizados foram 0% e 100%, respectivamente. Logo, foram extraídas 10 características por imagem e canal do espaço de cor.

No espaço de cor HSV, o H representa diretamente o matiz de cor, já nos espaços de cor RGB e CIEL*a*b* o valor de matiz foi calculado. Também foram calculados os percentis sobre o valor que representa o matiz de cor das imagens nos espaços RGB e CIEL*a*b*. Com o espaço de cor CIEL*a*b*, foi implementada ainda uma extração de característica semelhante, com o cálculo da propriedade de croma. Outra característica extraída em todas as imagens foi a ΔE_{76} , encontrada em trabalhos cujo espaço de cor usado foi CIEL*a*b*. A ΔE_{76} é baseada na distância euclidiana entre os pontos da matriz tridimensional da imagem colorida (MARTÍN; MIRÓ; MORENO, 2015).

As características extraídas foram organizadas em três arquivos, um para cada espaço de cor. Para identificação das características extraídas, cada característica foi nominada como AE_cP_e , onde A representa o algoritmo de extração (p ou $de76$), E_c corresponde ao espaço de cor utilizado e P_e ao percentil considerado, de forma crescente, de 1 à 30, para todos os canais, ou seja, os percentis do primeiro canal foram numerados de 1 à 10, os do segundo canal de 11 à 20 e os do terceiro canal de 21 à 30. Por exemplo, $prgb11$ corresponde a característica extraída pelo algoritmo Percentil, das imagens no espaço de cor RGB e considerando o primeiro percentil do segundo canal, G.

As características extraídas pelo algoritmo Percentil sobre as propriedades calculadas, croma e matiz no espaço de cor CIEL*a*b* e o matiz no espaço de cor RGB, foram nomeados como $pclab_e$, $phla_e$ e $phrgbP_e$, respectivamente, sendo P_e o percentil considerado, assim como nas características extraídas pelo algoritmo Percentil sobre os canais de cor.

3.2.3 Classificação

Para análise da performance dos classificadores, as características extraídas foram separadas por espaço de cor e tipo de fundo (original e uniforme), e então organizadas em arquivos ARFF (*Attribute-Relation File Format* – Formato de Arquivo de Relação de Atributos), formato utilizado pela API WEKA. Com a integração do sistema desenvolvido em linguagem Java, a API permite a utilização das rotinas disponíveis na coleção da ferramenta. Embora não seja necessária a utilização de arquivos ARFF, estes foram utilizados para que fosse possível comparar os resultados do sistema desenvolvido com os da ferramenta.

Após a criação dos arquivos no formato apropriado, foram realizadas classificações com três diferentes algoritmos: J48, MultilayerPerceptron e SMO. Com a ferramenta WEKA é possível alterar diversos parâmetros, dependentes do algoritmo de classificação. As configurações utilizadas no sistema foram aquelas sugeridas inicialmente pela ferramenta (configuração padrão), e a validação aplicada foi a validação cruzada. Embora o número padrão de folds seja 10, Witten; Frank e Hall (2011) afirma que não existe definição clara do valor ideal para estimação de erro, assim foi escolhido o valor de 50 folds. Os resultados do processo foram tabulados em um arquivo no formato CSV (*Comma-Separated Values* – Valores Separados por


Vírgula) para posterior análise, considerando a raiz erro quadrático relativo, calculado pela API WEKA.

Visando analisar a configuração dos histogramas das imagens produzidas, foi implementado o cálculo dos histogramas, para posterior análise visual em planilha eletrônica (Figura 22).

Figura 22 – Imagem em escala de cinza e seu histograma: (a) imagem e (b) histograma.



(a)



(b)

Fonte: a autora.


4 RESULTADOS E DISCUSSÃO

4.1 AVALIAÇÃO DOS SISTEMAS DE AQUISIÇÃO

4.1.1 Sistema de aquisição 1 – Scanner HP

A Figura 23 apresenta as seis imagens produzidas, após processamento, utilizando os mesmos parâmetros, no sistema de processamento desenvolvido a partir da biblioteca OpenCV. Conforme colocado na seção 3.1.1, as imagens foram processadas no espaço de cor original da aquisição (RGB) e recortadas de forma a permanecer apenas as sementes na imagem, eliminando elementos externos como a borda em EVA utilizada para facilitar a distribuição das sementes.

Figura 23 – Imagens produzidas pelo scanner HP LaserJet M1120 MPP com contorno desenhado nas sementes identificadas: (a) Fundo azul e sementes saudáveis; (b) Fundo preto e sementes saudáveis; (c) Fundo verde e sementes saudáveis; (d) Fundo azul e sementes contaminadas; (e) Fundo preto e sementes contaminadas; (f) Fundo verde e sementes contaminadas.



Fonte: (FRANCO et al., 2015a).

As imagens recortadas foram segmentadas utilizando a técnica de limiarização por canais de cor, empregando a função `cvInRangeS()`. Após, utilizando a função `cvFindContours()`, foram identificados os contornos das sementes na imagem. Visando eliminar ruídos como partes do fundo ou sombras, foi adicionada uma condição na rotina que encontra os contornos cujo objetivo foi ignorar contornos

com área inferior a 100 pixels. Assim, apenas objetos identificados com área maior que 100 pixels foram considerados sementes. O sistema de processamento também criou novas imagens com o desenho do contorno nas sementes identificadas, utilizando a função `cvDrawContours()`.

Para verificar a diferença entre as imagens, ao encontrar os contornos correspondentes às sementes, estes foram contabilizados e foi calculada a área total, em pixels, utilizando a função `cvContourArea()`. A quantidade de sementes identificadas e a área total para cada fundo são relatadas na Tabela 1.

Tabela 1 – Análise dos contornos das imagens de 50 sementes produzidas pelo scanner LaserJet M1120 MPP

Fundo	Sadias		Mancha Púrpura	
	Quantidade	Área*	Quantidade	Área*
Azul	33	122080	39	109289
Preto	49	64477	50	67696
Verde	50	70097	50	72741

* Em pixels

Fonte: (FRANCO et al., 2015a).

Observam-se sombras projetadas pelas sementes em todas as imagens produzidas, possivelmente devido às limitações do scanner utilizado. Nas imagens com fundo azul a presença das sombras gerou maior quantidade de ruídos para o processo de segmentação, tornado os valores de quantidade e área irreais.

Nas imagens com fundo verde e preto as sombras interferiram menos no processo de segmentação, aparentando contornos mais precisos que as imagens de fundo azul. Ainda existiu erro na contagem das sementes sadias com fundo preto, uma vez que existiam 50 sementes e o sistema contabilizou apenas 49. Esse erro deve-se a proximidade de duas sementes (Figura 23 (b)), fazendo com que o contorno identificado englobasse duas sementes sendo contabilizado apenas uma vez. Nas imagens de fundo verde a contagem foi precisa, embora também existam sementes com proximidade semelhante a da imagem com fundo preto com sementes sadias (Figura 23 (c)).

Comparando visualmente as imagens da Figura 23 é possível verificar que os contornos detectados nas imagens de amostra de sementes com mancha púrpura não foram tão bem definidos quanto nas imagens de amostra de sementes sadias, indicando que a coloração das sementes contaminadas pode ser interpretada como fundo ou sombra em configurações que as sementes sadias são delineadas por

completo. Também é possível visualizar que as sementes contaminadas na imagem com fundo preto, Figura 23 (e), tem o contorno menor que o real quando a semente tem maior grau de contaminação, pois a coloração desta se aproxima da coloração do fundo, incorrendo em falha na identificação pelo processo de segmentação. Embora esse efeito também seja perceptível na imagem com fundo verde, Figura 23 (f), a coloração do fundo verde promove maior contraste com a coloração das sementes de alto grau de contaminação, reduzindo assim o erro na identificação do contorno correto. Logo, a diferença entre as somas das áreas nos fundos preto e verde indicam que o fundo verde provê uma melhor abrangência das sementes, aparentando, portanto, ser o fundo mais adequado, como mencionado por Paulsen et al. (1989), para o conjunto de materiais, configurações e equipamentos utilizados.


O experimento mostrou que o scanner utilizado não promove um ambiente de iluminação uniforme como suposto e, segundo Gunasekaran et al. (1988) e Liu et al. (2015), necessário para a obtenção de imagens de qualidade.

4.1.2 Sistema de aquisição 2 – Scanners HP e Epson

Com o objetivo de verificar a influência das limitações do scanner utilizado no experimento anterior, o experimento com sistema de aquisição 1 foi reproduzido utilizando um scanner profissional da marca Epson, modelo Perfection V700 Photo, seção 3.1.2.

A Figura 24 apresenta os resultados do sistema de aquisição 2. Novamente, as imagens produzidas não tiveram fundo uniforme, apresentando também sombras projetadas pelas sementes. Porém, a influência das sombras foi menor que nas imagens produzida com o scanner HP, possivelmente devido a maior nitidez que o equipamento proporciona para as imagens na mesma resolução.

Figura 24 – Imagens produzidas pelo scanner Epson Perfection V700 Photo com contorno desenhado nas sementes identificadas: (a) Fundo azul e sementes saudáveis; (b) Fundo preto e sementes saudáveis; (c) Fundo verde e sementes saudáveis; (d) Fundo azul e sementes contaminadas; (e) Fundo preto e sementes contaminadas; (f) Fundo verde e sementes contaminadas.



Fonte: (FRANCO et al., 2015b).

A contagem das sementes identificadas foi precisa em todas as imagens produzidas pelo scanner Epson (Figura 24).

Tabela 2 – Análise dos contornos das imagens de 50 sementes produzidas pelo scanner Epson Perfection V700 Photo.

Fundo	Sadias		Mancha Púrpura	
	Quantidade	Área*	Quantidade	Área*
Azul	50	59773	50	66577
Preto	50	58381	50	64495
Verde	50	60087	50	67188

* Em pixels

Fonte: a autora.


O total de pixels identificados como sementes foi superior nas imagens de fundo verde, indicando este como o mais adequado, dentre os avaliados, também para o novo equipamento. Assim como nos resultados do sistema de aquisição 1, as sementes contaminadas apresentaram contorno menos preciso que nas sementes

sadias, em todos os fundos, evidenciando a influência da coloração das sementes contaminadas no processo de segmentação.

4.1.3 Sistema de aquisição 3 – Scanner Epson com iluminação externa


As Figuras 25 e 26 apresentam, respectivamente, os resultados da aquisição obtidos para sementes sadias e contaminadas. O sistema de processamento foi aplicado nas 30 imagens produzidas, seção 3.1.3. Os contornos desenhados nas imagens das sementes identificadas foram feitos por meio da função `cvDrawContours()`.

Figura 25 – Imagens da amostra com sementes sadias – moldura 0,5 cm de altura. (a) Fundo preto; (b) Fundo azul; (c) Fundo verde; (d) Scanner aberto; (e) Scanner aberto com iluminação externa.



Fonte: (FRANCO; FALATE; MARUYAMA, 2016).

Figura 26 – Imagens da amostra com sementes contaminadas – moldura 0,5 cm de altura. (a) Fundo preto; (b) Fundo azul; (c) Fundo verde; (d) Scanner aberto; (e) Scanner aberto com iluminação externa.



Fonte: (FRANCO; FALATE; MARUYAMA, 2016).

Embora a moldura utilizada para limitar a distribuição das sementes tenha altura inferior a utilizada nos sistemas de aquisição 1 e 2, seção 3.1.3, as imagens ainda apresentaram sombras projetadas pelas sementes, porém com dimensões menores. Sendo de dimensões menores, as sombras projetadas pelas sementes exerceram menor influência sobre o processo de segmentação, em especial nas imagens com fundo em EVA preto, Figura 25 (a) e 26 (a). O processo de segmentação das imagens de sementes contaminadas com fundos verde e azul, Figuras 26 (b) e 26 (c), respectivamente, sofreu maior influência das sombras projetadas pelas sementes. A altura entre o vidro do scanner e o fundo em EVA, com o sistema de iluminação do scanner, provavelmente leva a reflexão da luz em um ângulo diferente de 90°, provocando assim a sombra projetada pelas sementes no momento da aquisição das imagens.

As diferentes resoluções (150, 300 e 600 dpi) produziram imagens de dimensões diferentes, assim foi necessário adequar os valores de área mínima, utilizados para filtrar contornos com tamanhos não correspondentes a sementes. Para a segmentação, inicialmente as imagens foram convertidas para a escala cinza utilizando a função `cvCvtColor()`, então foi utilizada a função `cvThreshold()`. Após,

foram utilizadas as funções `cvFindContours()`, `cvContourArea()` e `cvContourPerimeter()` para identificar as sementes nas imagens segmentadas e calcular a área e o perímetro das mesmas, respectivamente. Mesmo utilizando técnica de segmentação com limiar ótimo por imagem a segmentação não foi bem-sucedida em todas as imagens, resultando em valores de quantidade (Tabela 3) inferiores a 50, número de sementes presentes na imagem. Consequentemente, os cálculos de área e perímetro se tornaram igualmente irreais.

Tabela 3 – Resultados dos valores calculados pelo sistema de processamento no sistema de aquisição 3 - Scanner Epson com iluminação externa

Tipo da Amostra	Resolução da Imagem ¹	Fundo da Imagem	Quant. de Contornos Encontrados	Área Total dos Contornos ²	Perímetro Total dos Contornos ²
Contaminada	150	Aberto**	50	41850	6237
Contaminada	150	Azul	34	80308	14270
Contaminada	150	Luz*	51	43758	7222
Contaminada	150	Preto	50	35250	6065
Contaminada	150	Verde	25	89525	17337
Contaminada	300	Aberto**	50	170550	14188
Contaminada	300	Azul	33	296703	34348
Contaminada	300	Luz*	51	180999	16282
Contaminada	300	Preto	50	146100	13838
Contaminada	300	Verde	26	354718	43882
Contaminada	600	Aberto**	51	685644	33219
Contaminada	600	Azul	33	1156584	80221
Contaminada	600	Luz*	51	726954	37777
Contaminada	600	Preto	50	587150	32072
Contaminada	600	Verde	29	1371033	105564
Sadia	150	Aberto**	50	46700	5872
Sadia	150	Azul	50	27800	4847
Sadia	150	Luz*	50	53300	6376
Sadia	150	Preto	50	43800	5717
Sadia	150	Verde	50	30900	4988
Sadia	300	Aberto**	50	191600	12146
Sadia	300	Azul	50	115600	10789
Sadia	300	Luz *	50	219700	13171
Sadia	300	Preto	50	181200	11921
Sadia	300	Verde	50	128100	10985
Sadia	600	Aberto**	50	780300	26035
Sadia	600	Azul	50	466550	25854
Sadia	600	Luz*	50	893000	27202
Sadia	600	Preto	50	738700	26137
Sadia	600	Verde	50	525850	26613

* Scanner aberto com luz externa. ** Scanner aberto. ¹em dpi. ²em pixels

Fonte: a autora.

O erro na contagem de sementes contaminadas nas imagens com fundo preto (EVA, scanner aberto e scanner aberto com luz externa) ocorreu devido a uma semente com elevado índice de contaminação. A coloração das sementes com elevado grau de contaminação influenciou no contraste da imagem, fazendo com que o algoritmo de segmentação a identificasse como duas sementes. A contagem foi bem-sucedida em todas as imagens realizadas com a amostra de sementes sadias.

Com os valores de área e perímetro das imagens com contagem bem-sucedida, é possível quantificar a performance do algoritmo de segmentação nos diferentes arranjos de aquisição. Os arranjos que proporcionaram ao algoritmo melhores condições, resultando na identificação de maior área da semente foram, em ordem decrescente: scanner aberto com luz externa, scanner aberto, fundo de EVA preto, fundo de EVA verde e fundo de EVA Azul. O resultado se repetiu em todas as resoluções analisadas, indicando que a resolução das imagens produzidas tem pouca ou nenhuma influência sobre o processo de segmentação.

Em imagens com fundo em EVA, de ambas as amostras e em todas as resoluções, o algoritmo identificou maior área total como semente nas imagens de fundo verde do que as imagens com fundo azul, indicando que o fundo verde proporciona melhor contraste em níveis de cinza, como ressaltado por Paulsen et al. (1989). Contudo, os fundos escuros, obtidos por meio dos demais métodos, promoveram melhores resultados na técnica de segmentação empregada.

Dentre as imagens com fundo preto, o arranjo com iluminação externa apresentou maior abrangência de área identificada como semente em ambas as amostras de sementes, evidenciando a importância da iluminação para obtenção de contraste adequado, como destacado por Ahmad et al. (1999), Gunasekaran et al. (1988) e Liu et al. (2015), indicando que este arranjo seria o mais indicado.

No entanto, assim como pôde ser observado nas imagens produzidas pelos sistemas de aquisição 1 e 2, mesmo nas imagens de melhores resultados na segmentação existiu áreas de subexposição, ou seja, a cor das sementes não se mostrou real em toda sua área. Outro ponto comum em todos os experimentos com aquisição de imagens utilizando scanners foi a influência da coloração das sementes contaminadas sobre o processo de identificação destas. Portanto, os experimentos mostram que seria indicado o uso de outro equipamento de aquisição, como por exemplo câmeras digitais. Considerando também a influência da coloração das

sementes contaminadas, seria indicado um sistema de aquisição que resulte em imagens de fundo claro, para acentuar o contraste do fundo em relação as sementes.

4.1.4 Sistema de aquisição 4 – Captura por vídeo

Conforme apresentado no Apêndice A, os experimentos de aquisição de imagens multifaceis por captura de vídeo não resultaram em imagens com nitidez suficiente para as demais etapas de processamento das imagens, como segmentação e classificação. Assim, os experimentos seguintes passaram a buscar um melhor contraste entre o fundo das imagens e as sementes, considerando apenas a face da semente voltada para a câmera, como nos trabalhos desenvolvidos por Liu et al. (2015) e Paulsen et al. (1989).

4.1.5 Sistema de aquisição 5 – Luz direta

Tabela 4 apresenta como foi dada a identificação das sementes de soja nas imagens obtidas com o sistema de aquisição 5.

Tabela 4 – Sementes contabilizadas pelo método Otsu no sistema de aquisição 5 – Luz direta.

Tipo de amostra	Fundo	Quantidade de sementes
Contaminada	Azul	6
Contaminada	Luz**	6
Contaminada	Mesa*	5
Contaminada	Preto	6
Contaminada	Verde	19
Sadia	Azul	4
Sadia	Luz**	7
Sadia	Mesa*	3
Sadia	Preto	6
Sadia	Verde	14

*Fundo sem EVA, apenas a mesa Still. **Iluminação sob a mesa Still.


Fonte: a autora.

Em quatro das 10 imagens a contagem de sementes foi precisa (6 sementes), porém, foi possível visualizar nas imagens com contorno que, mesmo com contagem correta, a maioria das sementes não foi corretamente identificada.

O posicionamento das luminárias laterais produziram sombras projetadas pelas sementes, com maior destaque nas imagens com fundo verde e azul, Figuras 27 (a), 27 (c), 28 (a) e 28 (c)). O tipo de iluminação não promoveu exposição uniforme sobre todo o quadro na maioria das imagens, ocorrendo regiões de menor exposição

nas quais o processo de segmentação não discriminou corretamente as sementes do fundo, como na Figura 27 (d). No entanto, a imagem de sementes contaminadas com fundo iluminado e nas imagens com fundo em EVA preto, Figuras 27 (b), 28 (e) e 28 (b), a exposição ficou uniforme o bastante para que o processo de segmentação fosse capaz de identificar todas as sementes.


Figura 27 – Imagens de sementes saudáveis produzidas no sistema de aquisição 5. (a) Fundo em EVA verde; (b) Fundo em EVA preto; (c) Fundo em EVA azul; (d) Fundo sem EVA, apenas a mesa Still; (e) Iluminação sob a mesa Still.



Fonte: a autora.

Entretanto, nas imagens com fundo em EVA preto, Figuras 27 (b) e 28 (b), o efeito foi similar as imagens produzidas pelos scanners, ou seja, a coloração provocada pelo fungo interferiu no processo por ser próxima a coloração do fundo. Nas imagens com fundo iluminado, Figuras 27 (e) 28 (e), a segmentação teve melhor desempenho, porém existiram reflexos, como na imagem em destaque na Figura 28 (e).

Figura 28 – Imagens de sementes contaminadas produzidas no sistema de aquisição 5. (a) Fundo em EVA verde; (b) Fundo em EVA preto; (c) Fundo em EVA azul; (d) Fundo sem EVA, apenas a mesa Still; (e) Iluminação sob a mesa Still.



Fonte: a autora.

Nas imagens produzidas com luz de fundo é possível observar que a técnica minimiza ou elimina as sombras projetadas. Comparando as imagens e o desempenho da segmentação quanto ao formato e localização dos ruídos, é possível perceber que a falta de uniformidade de iluminação pode ser provocada pela baixa abrangência de iluminação promovida pelas luminárias. Logo, seria indicando que o uso de luminárias maiores, como refletores comerciais, poderia promover maior uniformidade na iluminação.

4.1.6 Sistema de aquisição 6 – Luz indireta

A Tabela 5 apresenta os resultados de identificação das sementes de soja nas imagens obtidas com o sistema de aquisição 6. Xin et al. (2015) relataram que o método Otsu costuma apresentar melhores resultados em imagens de maior quantidade de pixels de fundo. Para verificar isso, foram produzidas imagens com uma e 30 sementes, portanto, a tabela apresenta duas quantidades de sementes.

Tabela 5 – Resultados da segmentação no sistema de aquisição 6 – Luz indireta.

Semente	ISO	Limiar	Otsu		InRange/Otsu ¹		
			Área ²	Qnt	Limiares ³	Área ²	Qnt
Contaminada	800	108	39689	1	112, 110, 102	39815	1
Contaminada	1600	151	39412	1	158, 153, 143	39660	1
Contaminada	800	109	1133520	30	114, 111, 101	1137577	30
Contaminada	1600	151	1124337	30	159, 154, 140	1132069	30
Sadia	800	127	38720	1	136, 133, 113	38935	1
Sadia	1600	173	38555	1	186, 180, 154	38802	1
Sadia	800	123	1210446	30	133, 128, 108	1214719	30
Sadia	1600	172	1206604	30	186, 179, 152	1213079	30

¹Limiarização utilizando a função cvInRangeS() com limiares de entrada calculados pelo método Otsu.

²Número de pixels. ³ Respectivamente para os canais R, G e B.

Fonte: (FRANCO; SANDRINO; FALATE, 2016).


A alteração nas fontes de luz, em relação ao sistema de aquisição 5, proporcionou maior uniformidade de exposição e ausência de ruídos com influência no processo de segmentação, resultando na contagem correta de sementes em todas as imagens. Os resultados foram semelhantes para todas as imagens, independentemente da quantidade de sementes presentes e da configuração ISO utilizada.

A variação do método Otsu, conforme colocado na seção 3.1.6, foi implementada utilizando a função cvInRangeS(). Essa função utiliza três valores de limiares para a segmentação nos canais de cor de maneira individual, posteriormente

combinando-as na imagem binária final. Na variação do método Otsu esses limiares foram calculados como no método Otsu, porém a partir dos canais de cor da imagem, ao invés da imagem em escala de cinza.

A área identificada como semente foi superior nas imagens produzidas com ISO 800 em ambos os métodos e amostras, o que pode ser justificado pelo fato de que menores configurações de ISO produzem imagens de maior qualidade, como mencionado na seção 2.1.3. Considerando as condições de aquisição, com a iluminação constante e o uso de luz de fundo nas imagens, foi possível obter imagens de qualidade suficiente para uma segmentação de qualidade (GUNASEKARAN et al., 1988), o que pode ter produzido a elevada semelhança entre os métodos analisados. Porém, visualmente é possível verificar que a segmentação a partir da variação do método Otsu obteve maior abrangência de área na identificação das sementes, especialmente nas bordas da semente (Figura 29).

Figura 29 – Imagem de semente de soja contaminada pelo fungo *Cercospora kikuchii* segmentada pelo método Otsu e sua variação para imagens coloridas (InRange/Otsu).




Fonte: (FRANCO; SANDRINO; FALATE, 2016).

4.1.7 Sistema de aquisição 7 – Final

O sistema de aquisição 7 foi usado para a produção das imagens consideradas nas demais etapas do processamento. Esse sistema teve por princípio os melhores resultados dos sistemas anteriores, buscando imagens de maior qualidade. As imagens foram produzidas utilizando amostras com 50 sementes e empregando a lente objetiva de 55 mm.

As configurações empregadas na câmera, em conjunto com as condições de iluminação, proporcionaram a correta exposição para a formação das imagens, tanto para sementes sadias (Figuras 30) quanto para sementes contaminadas (Figuras 31).

Figura 30 – Uma imagem de sementes de soja sadias produzida pelo sistema de aquisição 7 – Final.



Fonte: a autora.

Figura 31 – Uma imagem de sementes de soja contaminadas produzida pelo sistema de aquisição 7 – Final.




Fonte: a autora.

Esse sistema também produziu imagens sem a presença de sombras projetadas pelas sementes, diferentemente das imagens produzidas por outros sistemas de aquisição avaliados, como os que empregaram fundos em EVA. Uma vez que a exposição e iluminação incorretas podem provocar ruídos, como áreas da

imagem com sombra, prejudicando processamentos posteriores (PEDRINI; SCHWARTZ, 2008), é esperado que as imagens produzidas por esse sistema sejam com maior qualidade que as produzidas por outros sistemas de aquisição avaliados.


Outro fator que pode evidenciar a qualidade das imagens produzidas é o alto contraste entre as sementes e o fundo da imagem, relevante em etapas posteriores do processamento, como a segmentação (GUNASEKARAN et al., 1988), e caracterizado pelo formato bimodal dos histogramas das imagens, indicando a distinção de cor entre os pixels referentes ao fundo em relação aos objetos de interesse (MARQUES FILHO; VIEIRA NETO, 1999). As Figuras 32 a 34 apresentam os histogramas de todos os canais de cor, dos três espaços de cor, de uma imagem obtida com o sistema de aquisição 7.

Figura 32 – Histograma de uma das imagens produzidas de sementes sadias com o sistema de aquisição 7 e convertida para o espaço de cor CIEL*a*b*.




Fonte: a autora.

Figura 33 – Histograma de uma das imagens produzidas de sementes sadias com o sistema de aquisição 7 no espaço de cor RGB.



Fonte: a autora.

Figura 34 - Histograma de uma das imagens produzidas de sementes sadias com o sistema de aquisição 7 e convertida para o espaço de cor HSV.



Fonte: a autora.

Está evidente o formato bimodal em todos os histogramas das imagens produzida com o sistema de aquisição 7.

4.2 SISTEMA COMPUTACIONAL

4.2.1 Segmentação

Havendo o formato bimodal dos histogramas das imagens produzidas, a técnica de segmentação utilizada foi baseada em limiarização global. A fim de avaliar a técnica de segmentação, foi processada uma imagem contendo 10 sementes de soja disposta aleatoriamente, sendo cinco contaminadas pelo fungo *Cercospora kikuchii* e outras cinco sementes saudáveis, produzida utilizando a lente de 55 mm e a configuração ISO 800 (Figura 35).

Figura 35 – Imagem contendo cinco sementes saudáveis e cinco contaminadas, disposta aleatoriamente.



Fonte: a autora.

A técnica de segmentação foi aplicada nas imagens originais, em RGB, e em imagens convertidas para os espaços de cor HSV e CIEL*a*b*, utilizando a função `cvCvtColor()` para essa conversão. Após a conversão para o espaço de cor, as imagens foram divididas em seus canais de cores utilizando a função `cvSplit()`, criando três novas imagens por espaço de cor.


A seguir, foram calculados os limiares ótimos de cada imagem de canal de cor, por meio do método Otsu, e então as imagens foram limiarizadas utilizando a função `cvThreshold()`.

Com as imagens limiarizadas de cada canal de cor, foi construída uma imagem binária resultante, com o auxílio da função `cvOr()`. Por fim, foram identificados os contornos das sementes nas imagens coloridas e foram criadas novas imagens de acordo com o menor retângulo que engloba a semente identificada, retângulo este detectado com a função `cvGetSubRect()`.

Para a criação de imagens de sementes com fundo uniforme, como nas imagens binárias, estas foram combinadas com as imagens originais, de acordo com o espaço de cor, empregando a função `cvAnd()`. Então, foram contabilizadas a quantidade de sementes e a área total em pixels identificada como semente na imagem.

O processo de segmentação não identificou corretamente as 10 sementes utilizando os espaços de cor avaliados. Utilizando as imagens convertidas para o espaço de cor HSV (Figura 36), foram identificados 186 contornos não correspondentes a sementes, com área variando de 4 a 216 pixels, como visível no destaque da Figura 36, contabilizado assim uma quantidade incorreta de sementes (Tabela 6).

Figura 36 – Imagem com 10 sementes, sadias e contaminadas, segmentada após conversão para o espaço de cor HSV.



Fonte: a autora.

Tabela 6 – Resultados dos valores calculados pelo sistema utilizando uma imagem de 10 sementes, entre sadias e contaminadas.

Espaço de cor	Quantidade de sementes identificadas	Área total considerada como sementes (pixels)
RGB	17	265775
CIEL*a*b*	11	271092
HSV	196	280302

Fonte: a autora.

A área considerada como sementes na imagem convertida para HSV foi superior às demais. No entanto, essa área foi irreal, uma vez que a quantidade de

sementes não foi precisa. A imprecisão na contagem das sementes utilizando o espaço de cor HSV também ocorreu quando foram usadas imagens com apenas sementes saudáveis e imagens com apenas sementes contaminadas. Desse modo, apesar de o espaço de cor HSV ser mais indicado para o processamento digital de imagens (GONZALEZ; WOODS, 2010), este foi desconsiderado nas etapas seguintes do processamento.


A maior precisão nas contagens de sementes foi obtida com a conversão para o espaço de cor CIEL*a*b*, contabilizando apenas um contorno incorreto, devida a uma imperfeição ou grão de poeira presente na superfície utilizada na aquisição das imagens (Figura 37). Avaliando visualmente as imagens resultantes da segmentação utilizando RGB (Figura 38) e CIEL*a*b* (Figura 39), é possível verificar que a área considerada como semente em ambas as sementes foi corretamente determinada.

Figura 37 – Imagem com 10 sementes, saudáveis e contaminadas, com ruído destacado




Fonte: a autora

Figura 38 – Imagem com 10 sementes, sadias e contaminadas, segmentada no espaço de cor RGB.



Fonte: a autora.

Figura 39 – Imagem com 10 sementes, sadias e contaminadas, segmentada após conversão para o espaço de cor CIEL*a*b*.



Fonte: a autora.

Uma vez que utilizando o espaço de cor CIEL*a*b* a área considerada como semente foi superior, assim como a precisão nas contagens das sementes, quando comparada com a área calculada na imagem em RGB, o espaço de cor CIEL*a*b* foi o considerado para segmentação das imagens utilizadas para as etapas seguintes do processamento. Visando eliminar possíveis ruído como o encontrado na imagem, foi adicionada uma área mínima de 300 pixels para a consideração do contorno segmentado como semente.

4.2.2 Extração de características

Nos três espaços de cor avaliados, foram extraídas características pelo algoritmo Percentil e $\Delta E76$. O algoritmo Percentil considerou 10 percentis por canal de cor, extraíndo como característica a diferença dos valores nos percentis normalizada, como descrito na seção 3.2.2. A Figura 40 apresenta a codificação utilizada nessa extração.

Figura 40 – Codificação do algoritmo de extração de características Percentil.

```

1 public double[][] calculaPercentil3C(int[][] histograma) {
2     // [canal][percentil]
3     int[][] somasPercentis = new int[3][11];
4     int[][] percentis = new int[3][11];
5     double[][] featuresCor = new double[3][10];
6     // [canal]
7     int[] somas = new int[3];
8     int j, k, aux;
9     double p;
10
11     // inicializa a matriz
12     for (j = 0; j < 3; j++) {
13         somas[j] = 0;
14     }
15     // soma os pixels por canal e cor para calcular os percentil
16     for (j = 0; j < 3; j++) {
17         for (k = 0; k < 256; k++) {
18             somas[j] += histograma[j][k];
19         }
20     }
21     // calcula os percentos de 0 a 10
22     for (j = 0; j < 3; j++) {
23         for (k = 0; k < 11; k++) {
24             p = k / 10.0;
25             somasPercentis[j][k] = (int) ((int) somas[j] * p);
26         }
27     }
28     // inicializa matriz com -1 para identificar caso já
29     // tenha sido selecionado o valor
30     for (j = 0; j < 3; j++) {
31         for (k = 0; k < 11; k++) {
32             percentis[j][k] = -1;
33         }
34     }
35     // busca a cor mais próxima do percentil
36     for (j = 0; j < 3; j++) {
37         aux = 0;
38         for (k = 0; k < 256; k++) {
39             aux += histograma[j][k];
40             for (int c = 0; c < 11; c++) {
41                 if (aux == somasPercentis[j][c] && percentis[j][c] == -1) {
42                     percentis[j][c] = k;
43                 } //quando a próxima cor passa do percentil
44                 else if (aux > somasPercentis[j][c] && percentis[j][c] == -1) {
45                     percentis[j][c] = k - 1;
46                 }
47             }
48         }
49     }
50     for (j = 0; j < 3; j++) {
51         for (k = 0; k < 10; k++) {
52             featuresCor[j][k] = (percentis[j][k+1] - percentis[j][k]) / (double) (percentis[j][10]);
53         }
54     }
55     return featuresCor;
56 }

```

Fonte: a autora.

A função `calculaPercentil3C()` considera em sua inicialização três histogramas da imagem, um por canal de cor, em uma estrutura bidimensional composta de valores inteiros. Enquanto nas linhas 2 a 9, são declaradas as variáveis necessárias na função, nas linhas 12 a 14 e nas linhas 30 a 34 estão inicializadas as estruturas utilizadas (vetores e matrizes). Inicialmente a função calcula o total de pixels de cada canal (linhas 16 a 20), então são definidos os percentis a serem utilizados por canal de cor, dividindo o valor total de pixels do canal de cor em 10 partes iguais (linhas 22 a 27). Nas linhas 36 a 49 é selecionado o valor no percentil, sendo que caso a soma dos pixels ultrapasse o percentil definido o valor selecionado é o imediatamente anterior (linha 45). Por fim, nas linhas 50 a 54 é realizada a normalização dos valores, terminando a extração da característica de cor. Como é possível observar na linha 52 da Figura 45, a normalização foi realizada utilizando o valor do último percentil, ou seja, o valor máximo considerado, pois o valor mínimo definido foi em 0%, diferente de Cavalin et al. (2006), que consideraram uma margem de 10% de pixels como sendo ruído, 5% no início e 5% no final do histograma.

Nos espaços de cor RGB e CIEL*a*b*, também foi calculado o matiz, como descrito na seção 2.1.5, formando uma matriz para cada um dos dois espaços de cor com os valores de matiz. Após, foi utilizado o mesmo algoritmo de Percentil para extrair característica sobre a matriz contendo a propriedade, extraíndo assim 10 novas características nos espaços de cor RGB e CIEL*a*b*. No espaço de cor CIEL*a*b* foi calculado ainda a propriedade croma, também formando uma matriz com os valores de croma na qual foi aplicado o algoritmo Percentil e assim extraídas outras 10 características de cor no espaço de cor CIEL*a*b*.

As características extraídas foram organizadas em arquivos ARFF, formato utilizado pela ferramenta WEKA. Foram formados três arquivos, um para cada espaço de cor avaliado. Logo, foi criado um arquivo correspondente ao espaço de cor RGB com 41 características, considerando o valor extraído pelo ΔE_{76} e o algoritmo Percentil sobre os canais de cores e matiz. O arquivo correspondente ao espaço de cor CIEL*a*b* foi criado com 51 características, considerando os mesmos extratores utilizado no espaço de cor RGB mais o algoritmo Percentil aplicado à propriedade de croma. Por fim, o arquivo correspondente ao espaço de cor HSV foi construído com 31 características, considerando o valor extraído pelo ΔE_{76} e o algoritmo Percentil sobre os canais de cores.

As imagens foram previamente rotuladas, identificado cada imagem como sadia ou contaminada por meio dos nomes dos arquivos de imagens. A partir desses, o sistema identificou o rótulo correto para cada imagem de semente, adicionando o rótulo e o nome do arquivo no arquivo de características.

4.2.3 Classificação

A classificação foi realizada com o auxílio da ferramenta WEKA, por intermédio de sua API. O sistema computacional desenvolvido foi integrado com a API WEKA por meio da importação do arquivo apropriado, o mesmo utilizado para a execução da ferramenta, uma vez que esta foi construída na mesma linguagem do sistema computacional desenvolvido, a linguagem Java.

Foram avaliados três classificadores dos disponíveis na ferramenta (seção 3.2.3): J48, MultilayerPerceptron e SMO. Inicialmente, o sistema computacional desenvolvido busca o arquivo ARFF previamente criado e interpreta as informações contidas nele por meio da classe *Instances*. Em seguida, é criado um objeto da classe *FilteredClassifier*, no qual deve ser definido o classificador. A definição do classificador a ser utilizado é feita por meio da classe de mesmo nome, ou seja, para utilizar o classificador J48 foi instanciado um objeto da classe *J48*. Diferentemente do uso da ferramenta via interface, para a utilização da ferramenta por meio de integração foi necessário definir as configurações a serem consideradas pelo classificador. Por meio da função *setOptions()*, foram definidas as opções de configuração do classificador como as mesmas sugeridas por padrão pela interface, igualando assim os resultados da classificação no sistema computacional desenvolvido com os da ferramenta WEKA, para futuras análises.

Após a definição do classificador, o primeiro atributo do arquivo de características foi desconsiderado, utilizando a classe *Remove* e a função *setFilter()*, pois em todos os arquivos de características construídos foi incluído como primeira característica o nome do arquivo, e a consideração deste na classificação implicaria em resultados equivocados. Então, utilizando a função *setClassifier()*, o classificador é atribuído ao objeto da classe *FilteredClassifier*, previamente instanciado, e construído, de acordo com as características do arquivo ARFF, pela função *buildClassifier()*.

Para validação da classificação, nos três classificadores, foi usada a validação cruzada, conforme seção 3.2.3. Por meio da função *crossValidateModel()* do objeto

da classe *Evaluation*, pertinente as validações, foi definida a base de teste para a validação como sendo todo o conjunto de dados e o valor de 50 *folds*, as subdivisões usada pela validação cruzada.

Como resultado do processo executado pelo sistema computacional desenvolvido, é criado um arquivo, no formato CSV, com as informações sobre as características e sobre o classificador. Esse arquivo contém as seguintes informações:

- Fundo: Original ou Preto, pois foram avaliadas as possibilidades de imagens de sementes a partir da imagem original e a partir da imagem segmentada, como descrito na seção 3.2.1;
- Espaço de cor utilizado na classificação, identificado nas tabelas de resultado como “Espaço de cor”;
- Classificador utilizado: J48, MultilayerPerceptron ou SMO;
- Nome do arquivo ARFF: para análises posteriores;
- Raiz do erro quadrático relativo, identificado nas tabelas de resultado como “Raiz do Erro Quadrático Relativo”;
- Quantidade de imagens incorretamente classificadas na validação cruzada, identificado nas tabelas de resultado como “Quant. Incorretas – Validação Cruzada”;
- Nome dos arquivos de imagem incorretamente classificadas na base de imagens utilizada, identificado nas tabelas de resultado como “Nomes dos Arquivos de Imagens Classificadas Incorretamente”.

As informações a respeito da validação cruzada, como a raiz do erro quadrático relativo e quantidade correta e incorretamente classificada, foram obtidas por meio do objeto da classe *Evaluation*. Os nomes dos arquivos de imagem que foram incorretamente classificados foram obtidos a partir da comparação entre a classe, ou rótulo, definida no arquivo e a prevista pelo classificador, disponível por meio da função `classifyInstance()`.

Buscando identificar a combinação de espaço de cor para classificação, tipo de fundo para as imagens, e classificador, foram avaliadas 18 combinações, considerando três espaços de cor, dois tipos de fundo para as imagens e três classificadores.

4.2.3.1 Classificações utilizando o algoritmo J48

Uma vez que o algoritmo J48 é baseado em árvore de decisão, as avaliações iniciais quanto a extração de características e a classificação das imagens foram realizadas empregando este algoritmo. Inicialmente foram empregadas três imagens contendo 50 sementes sadias e três imagens contendo 50 sementes contaminadas. Essas imagens foram produzidas utilizando a lente de 55 mm, configuração ISO 800 e abertura f14.

As Tabelas 7 e 8 apresentam, respectivamente, o resultado da classificação com o uso do classificador J48, para as imagens de sementes com fundo original e com fundo uniforme.

Tabela 7 – Combinações avaliadas usando o classificador J48 e imagens com fundo original.

Espaço de Cor	Raiz do Erro Quadrático Relativo	Quant. Incorretas – Validação Cruzada	Nomes dos Arquivos de Imagens Classificadas Incorretamente
CIEL*a*b*	16,302%	2	1310
HSV	25,732%	5	1310
RGB	16,302%	2	1310

Fonte: a autora.

Tabela 8 – Combinações avaliadas usando o classificador J48 e imagens com fundo uniforme.

Espaço de Cor	Raiz do Erro Quadrático Relativo	Quant. Incorretas – Validação Cruzada	Nomes dos Arquivos de Imagens Classificadas Incorretamente
CIEL*a*b*	23,093%	4	113 ,1310
HSV	16,302%	2	1310
RGB	19,977%	3	1310

Fonte: a autora.

Utilizando o classificador J48 e as imagens iniciais, todas as combinações apresentaram ao menos uma imagem incorretamente classificada, tanto nas imagens com fundo original (Tabela 7), quanto nas imagens com fundo uniforme (Tabela 8). Os valores de raiz do erro quadrático relativo variaram entre 16,302% e 25,732%, e a validação cruzada apresentou entre duas e nove imagens incorretamente classificada.


Durante a validação da técnica de segmentação, o espaço de cor CIEL*a*b* se mostrou como mais indicado para a segmentação das imagens. Porém, utilizando

as imagens com fundo original, os resultados entre a classificação das imagens utilizando o método de extração de característica no espaço de cor CIEL*a*b* se assemelharam aos resultados quando o método de extração de característica utilizou o espaço de cor RGB, Tabela 7.

Contrário ao apresentado nas imagens com fundo original, a classificação das imagens com fundo uniforme apresentou os menores índices de erro utilizando o espaço de cor HSV na extração de características, indicando um valor de raiz do erro quadrático relativo de 16,302% (Tabela 8) semelhante aos resultados da classificação utilizando os outros espaços de cor, RGB e CIEL*a*b*, na extração de característica com as imagens com fundo original, Tabela 7.


Uma vez que o classificador J48 é baseado em árvore de decisão foram extraídas as árvores construídas pelo algoritmo de aprendizagem, com o auxílio da interface padrão da ferramenta WEKA e considerando os menores índices de erros quadrático relativo apresentados. As Figuras 41 e 42 apresentam as árvores construídas quando utilizadas imagens com fundo original e espaço de cor CIEL*a*b* e RGB, respectivamente, enquanto a Figura 43 apresenta a árvore considerada quando usadas as imagens de fundo uniforme e espaço de cor HSV.

Figura 41 – Árvore construída pelo classificador quando considerado o espaço de cor CIEL*a*b* e imagens com fundo original.




Fonte: a autora.

Figura 42– Árvore construída pelo classificador quando considerado o espaço de cor RGB e imagens com fundo original.



Fonte: a autora.

Figura 43– Árvore construída pelo classificador quando considerado o espaço de cor HSV e imagens com fundo uniforme.



Fonte: a autora.

Como é possível observar nas árvores construídas, apenas uma das características extraídas pelo algoritmo Percentil foi considerada. Logo, as características extraídas a partir da distância euclidiana, ΔE_{76} , o matiz calculado nos espaços de cor CIEL*a*b* e RGB e o croma calculado no espaço de cor CIEL*a*b*, não apresentaram influência na classificação com o algoritmo de aprendizagem J48.

Em todas as variações de extração de características utilizando o classificador J48, a imagem do arquivo 1310.png foi classificada incorretamente, Figura 44.

Figura 44 - Imagem 1310, incorretamente classificada pelas combinações avaliadas com o classificador J48.



Fonte: a autora.

Como é possível observar no destaque da Figura 44, a semente presente nesta imagem apresenta a mancha púrpura, indicando ser contaminada pelo fungo *Cercospora kikuchii* e, portanto, a classificação incorreta não foi devida a problemas no posicionamento da semente perante a câmera, no momento da aquisição da imagem.

A característica extraída da imagem considerada pelo algoritmo de aprendizagem foi $plab18 = 0,045$, quando em CIEL*a*b* e fundo original; $prgb11 = 0,484$ quando em RGB e fundo original; e $phsv21 = 0,539$ quando em HSV com fundo uniforme, se enquadrando na classe sadia nos três casos, conforme as Figuras 41, 42 e 43. Uma vez que em imagens de sementes com maior grau de contaminação a característica no mesmo percentil de cor é de valor menor como, por exemplo, na semente da Figura 45, cujos valores foram: $prgb11 = 0,225$ e $plab18 = 0,007$ usando a imagem com fundo original, e $phsv21 = 0,277$ usando a imagem com fundo uniforme. Desse modo, é possível que a área de contaminação na semente em incorretamente classificada não tenha sido ampla o suficiente para que a característica extraída obtivesse representatividade suficiente.

Figura 45 - Exemplo de imagem corretamente classificada como semente contaminada.



Fonte: a autora.

Os melhores resultados dentre todas as combinações avaliadas indicam que o espaço de cor com maior assertividade na classificação foi o HSV, quando utilizadas imagens com fundo uniforme. Porém, quando consideradas imagens com fundo original, os resultados foram similares nos espaços de cor RGB e CIEL*a*b*, apontando assim a necessidade de maiores análises para determinar o método mais indicado. Por outro lado, considerando os menores valores de raiz do erro quadrático relativo, 16,302%, tem-se que a assertividade do método desenvolvido, utilizando o classificador J48, é de 83,698%. Logo, o método desenvolvido alcançou maior assertividade que autores como Ahmad et al. (1998), que atingiram 83% de

assertividade, e Paulsen et al. (1989), que atingiram 66% de assertividade. Porém, buscando maior precisão na classificação e a determinação mais precisa do método indicado, foram avaliados outros classificadores, MultilayerPerceptron e SMO, utilizando as imagens produzidas inicialmente.

4.2.3.2 Classificações utilizando o algoritmo MultilayerPerceptron

A Tabela 9 apresenta os resultados obtidos com o classificador MultilayerPerceptron para imagens com fundo original.

Tabela 9 – Combinações avaliadas usando o classificador MultilayerPerceptron e imagens com fundo original.

Espaço de cor	Raiz do Erro Quadrático Relativo	Quant. Incorretas – Validação Cruzada	Nomes dos Arquivos de Imagens Classificadas Incorretamente
CIEL*a*b*	16,125%	2	-
HSV	20,383%	3	-
RGB	14,441%	2	-

Fonte: a autora.

Como ocorrido na avaliação do classificador J48, os resultados da validação cruzada utilizando o classificador baseado em redes neurais artificiais, MultilayerPerceptron, apresentaram maior valor de raiz do erro quadrático relativo quando as características foram extraídas usando o espaço de cor HSV, no caso das imagens com fundo original, chegando a 20,383% (Tabela 9). Embora esse valor tenha sido o maior dentre os três espaços de cor avaliados, para o classificador MultilayerPerceptron, foi menor que o apresentado pelo classificador J48 (25,731%), nas mesmas condições de imagem e extração de características.

A Tabela 10 apresenta os resultados obtidos com o classificador MultilayerPerceptron para imagens com fundo uniforme.

Tabela 10 – Combinações avaliadas usando o classificador MultilayerPerceptron e imagens com fundo preto.

Espaço de cor	Raiz do Erro Quadrático Relativo	Quant. Incorretas – Validação Cruzada	Nomes dos Arquivos de Imagens Classificadas Incorretamente
CIEL*a*b*	14,679%	2	-
HSV	27,440%	8	-
RGB	11,642%	1	-

Fonte: a autora.

Diferentemente dos resultados apresentados pelo classificador J48, o método de extração de características com espaço de cor HSV não apresentou os melhores resultados dentre os avaliados sobre as imagens de fundo uniforme (Tabela 10). A classificação das imagens utilizadas não apresentou classificações incorretas com o algoritmo MultilayerPerceptron, com as imagens utilizadas. O classificador apresentou menor valor de raiz do erro quadrático relativo quando a extração das características considerou o espaço de cor RGB e fundo uniforme, sendo o menor valor de raiz do erro quadrático relativo, 11,642%, dentre os avaliados com esse classificador. Esse valor de raiz do erro quadrático relativo foi inferior ao menor apresentado pelo classificador J48 (16,302%). Assim, entre os algoritmos do J48 e do MultilayerPerceptron, o algoritmo baseado em redes neurais artificiais é mais indicado para a classificação das imagens utilizadas que o algoritmo baseado em árvore de decisão avaliado.

4.2.3.3 Classificações utilizando o algoritmo SMO

As Tabelas 11 e 12 apresentam, respectivamente, o resultado da classificação com o uso do algoritmo SMO, para as imagens de sementes com fundo original e com fundo uniforme.

Tabela 11 – Combinações avaliadas usando o classificador SMO e imagens com fundo original.

Espaço de cor	Raiz do Erro Quadrático Relativo	Quant. Incorretas – Validação Cruzada	Nomes dos Arquivos de Imagens Classificadas Incorretamente
CIEL*a*b*	16,330%	2	-
HSV	20,000%	3	1310
RGB	23,094%	4	1310

Fonte: a autora.

Tabela 12 — Combinações avaliadas usando o classificador SMO e imagens com fundo preto.

Espaço de cor	Raiz do Erro Quadrático Relativo	Quant. Incorretas – Validação Cruzada	Nomes dos Arquivos de Imagens Classificadas Incorretamente
CIEL*a*b*	23,094%	4	-
HSV	23,094%	4	113, 1310
RGB	16,330%	2	1310

Fonte: a autora.

Diferentemente dos resultados apresentados pelos algoritmos MultilayerPerceptron e J48, o menor valor de raiz do erro quadrático relativo (16,330%) foi obtido na validação do classificador SMO utilizando o espaço de cor CIEL*a*b*, na extração de características das imagens com fundo original (Tabela 11). O mesmo valor de raiz do erro quadrático relativo foi apresentado quando usado o espaço de cor RGB nas imagens com fundo uniforme (Tabela 12), sendo este o menor dentre os obtidos com o classificador SMO e imagens de fundo uniforme.

Em quatro das seis combinações avaliadas com o classificador SMO, este classificou incorretamente a imagem 1310, semelhante ao ocorrido na avaliação com o classificador J48. A maior quantidade de imagens classificadas incorretamente na validação do classificador SMO foi quatro, diferente do apresentado pelo classificador MultilayerPerceptron que chegou a apresentar uma combinação com oito imagens incorretamente classificadas na validação cruzada. Porém, mesmo os menores índices apresentados pelo classificador SMO foram superiores aos melhores resultados apresentados pelos classificadores MultilayerPerceptron e J48.

4.2.4 Considerações Finais

O classificador MultilayerPerceptron seria o mais indicado para a classificação das imagens de sementes de soja contaminadas pelo fungo *Cercospora kikuchii*, nas condições de aquisição de imagens e processamento utilizadas. E, o espaço de cor mais indicado para a extração de características seria o RGB, nas imagens segmentadas com fundo uniforme.

A diferença entre os resultados da classificação das imagens com fundo uniforme e fundo original pode ser devido ao fundo utilizado nas imagens binárias, ou seja, preto. Como evidenciado nos experimentos de aquisição de imagens, utilizando scanners, o uso de fundo de tom escuro pode ter influência negativa no processamento de imagens de sementes de soja contaminadas pelo fungo *Cercospora kikuchii*, uma vez que as cores características na contaminação também costumam ser de tons escuros.

O melhor desempenho do classificador MultilayerPerceptron, sobre os demais avaliados, pode indicar que os algoritmos de aprendizagem baseados em redes neurais artificiais são os mais adequados para a classificação de dados com as

características dos dados da base construída com as características extraídas das imagens, como ocorre em outros trabalhos de classificação de imagens por processamento de dados (LIU et al., 2015) e (ZAPOTOCZNY, 2011). Como mencionado por Ruiz; Caten e Dalmolin (2014), árvores de decisão, como o classificador J48 é baseado, apresentam maior simplicidade na interpretação. Porém as árvores de decisão construídas pelo algoritmo empregando as bases de dados construídas nesse trabalho consideraram apenas uma característica, possivelmente tornando-as mais suscetíveis a classificações incorretas.

Considerando o classificador MultilayerPerceptron aplicado sobre as características extraídas de imagens em RGB com fundo uniforme, segmentadas empregando o espaço de cores CIEL*a*b*, os resultados na identificação das sementes contaminadas chegou à 88,358% de assertividade, de acordo com a validação cruzada com 50 *folds*, e 100% de assertividade com as imagens utilizadas. Essa assertividade foi superior aos 66% atingidos no trabalho de Paulsen et al. (1989) e aos 83% atingidos por Ahmad et al. (1998). Embora Liu et al. (2015) tenha atingido 98,2% de assertividade para sementes de soja mofadas, este não especificou para o fungo *Cercospora kikuchii*, além de utilizar imagens de única semente.

5 CONCLUSÕES E TRABALHOS FUTUROS

Esse trabalho teve como objetivo o desenvolvimento de um sistema computacional, baseado em processamento digital de imagens, para a identificação de sementes de soja contaminadas pelo fungo *Cercospora kikuchii*. Com a pesquisa inicial realizada para esse trabalho, foi possível compreender a influência da presença do fungo *Cercospora kikuchii* em sementes e grãos de soja (IMAZAKI et al., 2006), bem como as desvantagens da utilização dos métodos tradicionais, como a inspeção visual (LIU et al., 2015).

Com o sistema de aquisição proposto é possível a produção de imagens com qualidade suficiente para as demais etapas do processamento, sem a utilização de muitos recursos de pré-processamento, uma vez que produz imagens com poucos ruídos e ausência de sombras projetadas ou áreas com reflexos significativos. Esse sistema limita a quantidade de sementes na imagem apenas ao ângulo de visão da lente utilizada, de modo que as sementes fiquem separadas, produzindo assim imagens com múltiplas sementes. Logo, a quantidade de imagens necessárias para análise de um conjunto de sementes é reduzida, diferente de trabalhos como Liu et al. (2015), que consideraram apenas imagens com uma semente.

A técnica de segmentação utilizada, por considerar de maneira automatizada o limiar ótimo individual em imagens coloridas, pode ser também utilizada para imagens de sementes com outros danos, proporcionando a expansão do método proposto. Também a generalidade do sistema de extração de características, permite a inclusão de sementes de soja com outros danos que alterem sua coloração.

Por fim, é possível concluir que o método proposto obteve resultados satisfatórios para a identificação de sementes de soja contaminadas pelo fungo *Cercospora kikuchii*. Considerando que poucos autores especificam a identificação de contaminação em sementes de soja, especialmente para a identificação do fungo *Cercospora kikuchii* (AHMAD et al., 1998), (PAULSEN et al., 1989), este trabalho pode contribuir com análise de qualidade de sementes de soja.

5.1 TRABALHOS FUTUROS

A pesquisa mostrou que um dos desafios na aquisição de imagens de sementes de soja para o processamento e identificação de características é o formato arredondado das sementes. Esse formato dificulta a aquisição de imagens de todas as faces da semente, podendo provocar falhas na classificação. Sob esse contexto, neste trabalho foi explorada a possibilidade de aquisição de imagens de sementes de soja em movimento no ar, porém sem resultados satisfatórios. Assim, sugere-se como trabalho futuro a exploração de alternativas para a aquisição de imagens de múltiplas faces das sementes, utilizando, por exemplo, uma superfície de vidro suspensa ou uma estrutura com espelhos.

Durante a pesquisa também foi verificado que classificações incorretas em sementes de baixo grau de contaminação podem ser consequentes da baixa quantidade de pixels com a característica que indica a contaminação da semente. Assim, sugere-se a análise de sistemas de aquisição de imagens que empreguem lentes com maior distância focal, potencialmente aumentando o número de pixels na região de contaminação. Ainda se sugere para a etapa de aquisição de imagens a avaliação de alternativas para produção de imagens de qualidade similar utilizando recursos não específicos de estúdios fotográficos profissionais, potencialmente reduzindo o custo de implementação do sistema desenvolvido.

Outra sugestão de trabalho futuro é a alteração da técnica de segmentação para considerar a possibilidade de as sementes estarem muito próximas nas imagens, facilitando ainda mais a etapa de aquisição de imagens.

Também com o objetivo de expansão do sistema computacional desenvolvido neste trabalho, propõem-se a inclusão de sementes com outros danos que influenciem na cor, como o vírus mosaico comum da soja, de sementes imaturas, e de sementes com danos no tegumento, visto que estes têm influência nas taxas de vigor e germinação.

REFERÊNCIAS

- AGRAWAL, M. N.; MAHAJAN, A. M.; BADGUJAR, C. D.; MANDE, H. P.; DIXIT, G. Horizontal Aggregation in SQL to Prepare Dataset for Generation of Decision Tree using C4.5 Algorithm in WEKA. **International Journal of Advanced Computer Research**, v. 3, n. 3, p. 164-169, 2013.
- AHMAD, I. S., REID, J. F., PAULSEN, M. R., AND SINCLAIR, J. B. Color Classifier for Symptomatic Soybean Seeds Using Image Processing. **Plant Disease**, v. 83, nº 4, p. 320-327, 1998.
- ALMEIDA, A.M.R. et al. Doenças da soja. In: KIMATI, H.; AMORIM, L.; BERGAMIN FILHO, A.; CAMARGO, L.E.A.; REZENDE, J.A.M. **Manual de Fitopatologia v. 2: Doenças das plantas cultivadas. 3 ed.** São Paulo: Agronômica Ceres, 1997. p. 642 – 664.
- BRADSKI, G.; KAEHLE, A. **Learning OpenCV**. Sebastopol: O'Reilly. 2008.
- BRASIL, MINISTERIO DA AGRICULTURA - **AGIPLAN. Manual para análise de sementes de trigo e soja.** [S.l.] labor. Analise sementes s.d.,1998.
- CARVALHO, C. de; KIST, B. B.; SANTOS, C. E. dos; BELING R. R.; MENDES L.; REETZ, E. R. **Anuário brasileiro de sementes 2015**. Santa Cruz do Sul: Editora Gazeta Santa Cruz, 2015.
- CAVALIN, P., OLIVEIRA, L. S., KOERICH A. L., BRITTO JR., A. S., Wood Defect Detection using Grayscale Images and an Optimized Feature Set. **32º Conferência anual IEEE Industrial Electronics Society (IECON 2006)**, p. 3408-3412, Paris, France, IEEE Press, 2006.
- CIE - INTERNATIONAL COMMISSION ON ILLUMINATION.CIE 15: Technical Report: Colorimetry**, 3º edição, Washington, Estados Unidos da America, 2004.
- COSTA, J. A. **Cultura da soja**. Porto Alegre: Ivo Manica e José Antonio Costa. 1996.
- COSTA, N. P.; MESQUITA, C. M.; MAURINA, A. C.; FRANÇA NETO, J. B.; KRZYZANOWSKI, F. C.; HENNING, A. A. Qualidade fisiológicas, física e sanitária de sementes de soja produzidas no Brasil. **Revista Brasileira de Sementes**, v. 25, nº 1, p. 128-132, 2003.
- CUNNINGHAM, S. J.; DENIZE, P. A tool for model generation and knowledge acquisition. In **Proc International Workshop on Artificial Intelligence and Statistics**, p. 213-222, Fort Lauderdale, Florida, USA, 1993.
- EMBRAPA – EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA.** Tecnologias de Produção de Soja Região Central do Brasil 2004. Disponível em: <<http://www.cnpso.embrapa.br/producaosoja>>. Acesso em: 12 jun 2015.
- FACON, J; **Processamento e Análise de Imagens**. Pontifícia Universidade Católica do Paraná. 2005.

FRANÇA NETO, J. B.; KRZYZANOWSKI, F. C.; PÁUDA, G. P.; COSTA, N. P.; HENNING, A. A. Tecnologia da produção de semente de soja de alta qualidade Série Sementes. **Londrina: Embrapa Soja**. 2007. (Embrapa Soja. Circular Técnica, 40).

FRANCO, J. R.; FALATE, R.; MARUYAMA, T. Avaliação do scanner Epson Perfection V700 Photo para auxiliar na detecção de danos em sementes de soja. In: **8º Congresso Sul Brasileiro de Computação** (SulComp 2016), 2016, Criciúma (SC).

FRANCO, J. R.; FALATE, R.; VALLE, H. P.; HENNEBERG, L.; JACCOUD FILHO, D. S. Avaliação de cores de fundo em imagens de sementes de soja com mancha púrpura. In: **Congresso Brasileiro de Agroinformática**, 10, 2015a, UEPG. Anais... Ponta Grossa: UEPG, 2015. 1 pen-drive.

FRANCO, J. R.; SANDRINO, K.; FALATE, R. Análise de imagens de sementes de soja utilizando algoritmo Otsu para cálculo de limiar ótimo. In: **IV Congresso Agropecuário, Industrial e Tecnológico do Paraná**, 2016, Ponta Grossa. Anais... Ponta Grossa: UEPG, 2016.

FRANCO, J. R.; VALLE, H. P.; HENNEBERG, L.; JACCOUD FILHO, D. S.; FALATE, R. Avaliação da influência da cor de fundo e da qualidade do scanner na aquisição de imagens de semente de soja com mancha púrpura. In: **Congresso Brasileiro de Sementes**, 19, 2015b, Foz do Iguaçu. Anais... Foz do Iguaçu: ABRATES, 2015. 1 CR-ROM.

GALLI, J. A.; PANIZZI, R. de C.; FESSEL, S. A.; SIMONI, F. de; ITO, M. F. Efeito de colletotrichum dematium var. *truncata* e *Cercospora kikuchii* na germinação de sementes de soja. **Revista Brasileira de Sementes**, v. 27, p. 182-187, 2015.

GESLIN, E.; JÉGOU, L.; BEAUDOIN, D. How Color Properties Can Be Used to Elicit Emotions in Video Games. **International Journal of Computer Games Technology**, v. 2016, p. 1-9, 2016.

GIMENES, A. **Aprenda Fotografia de A a Z**. São Paulo: Diafragma 8. 2016.

GONZALEZ, R. C.; WOODS, R. E. **Processamento digital de imagens**. São Paulo: Pearson Prentice Hall. 2010.

GOULART, A. C. P. Fungos em sementes de soja. **Dourados: Embrapa Agropecuária Oeste**. 2005.

GUNASEKARAN S., COOPER T. M., BERLAGE A. G. Soybean Seed Coat and Cotyledon Crack Detection by Image Processing. **Journal of Agricultural Engineering Research**, v. 43, p. 139-148, 1988.

HARMAN, D. **O Manual da Fotografia Digital**. São Paulo: Editora Escala. 2013.

HUNTER, R. S. Accuracy, Precision, and Stability of New Photoelectric Color-Difference Meter. **Journal of The Optical Society Of America**, v. 38, n. 12, p. 1094, 1948.

IMAZAKI, I.; ISHIKAWA, K.; YASUDA, N.; ATSUSHI MIYASAKA, A.; KAWASAKI, S.; KOIZUMI, S. Incidence of thiophanate-methyl resistance in *Cercospora kikuchii* within a single lineage based on amplified fragment length polymorphisms in Japan. **Journal of General Plant Pathology**, v. 72, p. 77-84, 2006.

IMAZAKI, I.; SASAHARA, M.; KOIZUMI, S. Spatial distribution of purple seed stain of soybean caused by *Cercospora kikuchii* in fields. **Journal of General Plant Pathology**, v. 73, p. 41-45, 2007.

JÄHNE, B. **Practical Handbook on Image Processing Scientific and Technical Applications**. 2 ed. CRC Press, 2004.

KHATCHATOURIAN, O.; PADILHA, F. R. R. Reconhecimento de Variedades de Soja por Meio do Processamento de Imagens Digitais Usando Redes Neurais Artificiais, **Engenharia Agrícola**, v. 28, p. 759-769, 2008.

KRZYZANOWSKI, F. C.; FRANÇA NETO, J. B.; HENNING, A. A.; COSTA, N. P. A Semente de soja como tecnologia e base para altas produtividades Série Sementes. **Londrina: Embrapa Soja**. 2008. (Embrapa Soja. Circular Técnica, 55).

LIU, D.; NING, X.; LI, Z.; YANG, D.; LI, D.; LI, H.; GAO, L. Discriminating and elimination of damaged soybean seeds based on image characteristics. **Journal of Stored Products Research**, v. 60, p. 67-74, 2015.

LURÁ, M. C.; RAPELA, M. G. L.; VACCARI, M. C.; MAUMARY, R.; SOLDANO, A.; MATTIO, M.; GONZÁLEZ, A. M. Genetic Diversity of *Cercospora kikuchii* Isolates from Soybean Cultured in Argentina as Revealed by Molecular Markers and Cercosporin Production. **Mycopathologia**, v. 171, p. 361-371, 2011.

MADALOSSO, M. **Sintomas de mancha purpura (*Cercospora kikuchii*) em sementes de soja**, 2012. Disponível em : http://phytus.s3.amazonaws.com/clubephytus/media/2012/10/xlarge_Soja_Cercospora_Marcelo_03.jpg. Acesso em: 24/06/2015.

MARQUES FILHO, O.; VIEIRA NETO, H. **Processamento Digital de Imagens**. Rio de Janeiro: Brasport. 1999.

MARTÍN, F.; MIRÓ, J. V.; MORENO, L. RGB-D DE-based Scan Matching: Exploiting Colour Properties in Registration. **J Intell Robot Syst**, v. 80, p. 71-85, 2015.

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

MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO - MAPA. Regras para análise de sementes. Secretaria de Defesa Agropecuária. – Brasília: Mapa/ACS, 2009.

MOHEBBI, M.; MOHEBBI, M.; SHAHIDI, F.; MOUSSAVI, M.; GHODDUSI, H. Computer vision systems (CVS) for moisture content estimation in dehydrated shrimp. **Computers and Electronics in Agriculture**, v. 69, p. 128-134, 2009.

MORAZ, e. **Fotografia Digital – para quem não sabe nada de Fotografia**. São Paulo: Digerat Books. 2009.

OTSU, N. A threshold selection method from gray-level histograms. **IEEE Transactions On Systems, Man, and Cybernetics**, v. 9, no. 1, p. 62-99, 1979.

PAULSEN, M. R.; WIGGER, W. D.; LITCHFIELD, J. B.; SINCLAIR, J. B. Computer Image Analyses for Detection of Maize and Soybean Kernel Quality Factors. **Journal of Agricultural Engineering Research**, v. 43, p. 93-101, 1989.

PEDRINI, H.; SCHWARTZ, W. R. **Análise de Imagens Digitais: Princípios, Algoritmos e Aplicações**. São Paulo: Thomson Learning, 2008.

RODRÍGUEZ-PULIDO, F. J.; FERRER-GALLEGO, R.; GONZÁLEZ-MIRET, M. L.; RIVAS-GONZALO, J. C.; ESCRIBANO-BAILÓN, M. T.; HEREDIA, F. J. Preliminary study to determine the phenolic maturity stage of grape seeds by computer vision. **Analytica Chimica Acta**, v. 732, p. 78-82, 2012.

RUIZ, L. F. C.; CATEN, A. ten; DALMOLIN, R. S. D. Árvore de decisão e a densidade mínima de amostras no mapeamento da cobertura da terra. **Ciência Rural**, v. 44, n. 6, p. 1001-1007, 2014.

SOLOMON, C.; BRECKON, T. **Fundamentos de processamento digital de imagens: Uma abordagem prática com exemplos em MATLAB**. Rio de Janeiro: LTC, 2013.

SUGANO, H; MIYAMOTO, R. Highly optimized implementation of OpenCV for the Cell Broadband Engine. **Computer Vision and Image Understanding**. v. 114, p. 1273-1281, 2010.

SZELISKI, R. **Computer Vision: Algorithms and Applications**. New York: Springer, 2010.

TAN, P.; STEINBACH, M.; KUMAR V. **Introdução ao data mining: Mineração de dados**. Rio de Janeiro: Editora Ciência Moderna Ltda., 2009.

WANG, D.; DOWELL, F. E.; RAM, N. S.; SCHAPAUGH, W. T. Classification of fungal-damaged soybean seeds using near-infrared spectroscopy. **International Journal of Food Properties**, v. 7, n. 1, p. 75-82, 2004.

WEIBER, W. L.; FRANCO, J. R; FALATE, R. Aquisição de imagens: uso e avaliação de um estúdio fotográfico comercial. In: **25º Encontro Anual de Iniciação Científica (XXV EAIC)**, 2016, Ponta Grossa. Anais... Ponta Grossa: UEPG, 2016.

WITTEN, I. H.; FRANK, E.; HALL, M. A. **Data Mining – Practical Machine Learning Tools and Techniques – Third Edition**. Burlington: Morgan Kaufmann. 2011.

XIN, W.; WENZHU, Y.; ZHENBO, L. A fast image segmentation algorithm for detection of pseudo-foreign fibers in lint cotton. **Computers and Electrical Engineering**, v.46, p.500-510, 2015.

ZAPOTOCZNY, P. Discrimination of wheat grain varieties using image analysis and neural networks. Part I. Single kernel texture. **Journal of Cereal Science**. v. 54, p. 60-68, 2011.

ZHOU, R.; KANEKO, S.; TANAKA, F.; KAYAMORI, M.; SHIMIZU, M. Image-based field monitoring of *Cercospora* leaf spot in sugar beet by robust template matching and pattern recognition. **Computers and Electronics in Agriculture**, v. 116, p. 65-79, 2015.

APÊNDICE A – Sistema de aquisição 4 – Captura por vídeo

Foi observado que um problema pouco abordado na maior parte dos trabalhos de classificação de sementes por processamento de imagens, e ainda significativo, é a visibilidade do dano da semente na imagem, pois, por vezes, as imagens produzidas não revelam que a semente está danificada, devido ao posicionamento desta diante da câmera.

O problema é ocasionado na aquisição da imagem, já que o ângulo de visão da câmera é limitado em relação ao formato da semente de soja, não abrangendo todas as suas regiões. Como concluíram Gunasekaran et al. (1988), é imprescindível que as sementes estejam corretamente posicionadas durante a aquisição das imagens para que não existam falsos negativos durante a classificação, reduzindo assim a eficiência do sistema.

Um dos meios de aquisição mais utilizados nos trabalhos que empregam técnicas de processamento digital de imagens envolve o uso de câmeras fotográficas. Porém, é igualmente possível cumprir a etapa de aquisição de imagens utilizando vídeos, separando os quadros (*frames*).

Por muito tempo as aquisições de vídeos foram limitadas em configurações reduzidas, consequentemente limitando o processamento digital das imagens extraídas destes. No entanto, com a evolução da aquisição diretamente em vídeos digitais, os novos sensores de vídeo utilizados permitem a utilização de configurações de maiores resoluções e velocidades de captura, otimizando o processamento posterior (JÄHNE, 2004).

Sob este contexto, foram desenvolvidos sistemas de aquisição de imagens por captura de vídeo experimentais, com o objetivo de tratar o problema da visualização da região danificada da semente de soja na imagem.

O propósito da utilização de vídeo foi adquirir imagens de todas as regiões da semente sem apoio, ou seja, em movimento no ar. Para cumprir esse objetivo foram realizados experimentos com diferentes protocolos de aquisição, envolvendo diferentes equipamentos e configurações.

Inicialmente, os experimentos foram conduzidos com uma câmera fotográfica profissional da marca Canon, modelo EOS REBEL T5i, e foram utilizadas amostras de semente de soja artificialmente coloridas, para simular diferentes danos e doenças.

Os experimentos foram conduzidos visando um cenário onde as sementes seriam conduzidas por uma esteira, com múltiplas câmeras posicionadas no final, de

modo a filmar a queda da semente de diversos ângulos. Porém, inicialmente, a pesquisa iniciou-se utilizando apenas uma câmera, para posteriormente serem verificadas as melhores posições para as demais.

O primeiro experimento consistiu em soltar manualmente uma semente diante da câmera, o mais próximo da lente possível, com a câmera configurada para utilizar 60 frames por segundo. Após, o vídeo foi processado de maneira a separar os frames para identificar aqueles com a presença da semente. A Figura 46 mostra um dos frames com o rastro da semente em movimento.

Figura 46 – Frame separado do primeiro experimento com captura de imagens por vídeo.



Fonte: a autora.

Como é possível visualizar na Figura 46, devido a influência da aceleração gravitacional, a velocidade da semente foi muito alta para uma captura nítida, impossibilitando as demais análises necessárias.

Dado que a câmera utilizada permite o máximo de 60 frames por segundo, foram realizados testes comparativos com uma câmera da marca GoPro, modelo Hero4. Foram utilizadas as configurações que permitem 100, 120 e 240 frames por segundo (Figura 47).

Figura 47 - Experimento de captura de vídeo com uma câmera GoPro configurada em: (a) 100 frames/segundo; (b) 120 frames/segundo; (c) 240 frames/segundo.




Fonte: a autora.

Mesmo com a configuração mais alta, 240 frames por segundos, a aceleração da gravidade sobre a semente a fez atingir uma velocidade que impediu a captura nítida, semelhante ao ocorrido com o equipamento anterior, no primeiro experimento.

Para reduzir a velocidade da semente, foi então projetada uma rampa, para que a semente descesse em uma parábola de aceleração e depois subisse uma rampa de desaceleração e continuasse a mesma trajetória no ar, onde os vídeos seriam realizados. Primeiramente, foi construído um protótipo utilizando uma mangueira transparente e uma estrutura em EVA (Figura 48).

Figura 48 – Primeiro protótipo de rampa para redução da velocidade das sementes.



Fonte: a autora.

Na Figura 48 é possível observar que com a redução da velocidade obteve-se maior nitidez na imagem resultante, porém ainda existiu inconsistência. Embora a captura de vídeos da Canon T5i seja em progressive scannig em todas as configurações de resolução, diferentes configurações na velocidade do sensor da câmera ou com câmeras diferentes poderiam aperfeiçoar o resultado. Entretanto,

testes com diferentes configurações de velocidade ou câmeras não foram conduzidos com este protótipo, pois a estrutura se mostrou instável, alterando a altura de descida constantemente, fazendo com que muitas das sementes não alcançassem velocidade suficiente, ficando presas antes da rampa de desaceleração.

Foi então adquirida uma rampa comercial, de material plástico, para promover maior estabilidade para os experimentos seguintes (Figura 49). Como mostra a figura, a nova rampa teve 71 cm de altura por 109 cm de comprimento na rampa de aceleração e 58,2 cm de comprimento na rampa de desaceleração.

Figura 49 – Rampa comercial utilizada para redução da velocidade da semente.



Fonte: a autora.

Para potencializar a iluminação e promover maior uniformidade do plano de fundo para as imagens, o ambiente em torno da rampa foi revestido com tecido branco. Foi adicionada ao final da rampa uma armação para facilitar o posicionamento da câmera e ajuste do foco. Para a iluminação foram utilizados 2 refletores de estúdio comercial com 4 lâmpadas de 45W cada, uma luminária com uma lâmpada de LED de 12W e uma luminária recarregável composta por 42 lâmpadas de LED, totalizando 2,94W.

Foram realizados testes variando a velocidade do obturador, a quantidade de frames por segundo, a lente objetiva, a abertura e a sensibilidade do sensor (ISO), de acordo com a Tabela 13, totalizando 24 filmagens. Após, os vídeos foram processados de maneira a separar os frames contendo imagem das sementes para análise visual da combinação mais adequada. Foram produzidas 104 imagens para análise.

Tabela 13 – Variáveis do experimento com a rampa comercial.

Combinação	Velocidade do Obturador (em segundos)	Quantidade de Frames por Segundo	Lente Objetiva	Abertura	ISO
1	1/2000	30	55mm	f5.6	6400
2	1/2000	30	55mm	f5.6	3200
3	1/2000	60	55mm	f5.6	6400
4	1/2000	60	55mm	f5.6	3200
5	1/4000	30	55mm	f5.6	6400
6	1/4000	30	55mm	f5.6	6400
7	1/4000	60	55mm	f5.6	3200
8	1/4000	60	55mm	f5.6	3200
9	1/2000	30	60mm	f4.0	3200
10	1/2000	30	60mm	f4.0	6400
11	1/2000	30	60mm	f2.8	3200
12	1/2000	30	60mm	f2.8	6400
13	1/2000	60	60mm	f4.0	3200
14	1/2000	60	60mm	f4.0	6400
15	1/2000	60	60mm	f2.8	3200
16	1/2000	60	60mm	f2.8	6400
17	1/4000	30	60mm	f4.0	3200
18	1/4000	30	60mm	f4.0	6400
19	1/4000	30	60mm	f2.8	3200
20	1/4000	30	60mm	f2.8	6400
21	1/4000	60	60mm	f4.0	3200
22	1/4000	60	60mm	f4.0	6400
23	1/4000	60	60mm	f2.8	3200
24	1/4000	60	60mm	f2.8	6400


Fonte: a autora.

As configurações de velocidade selecionadas foram 1/4000 segundos e 1/2000 segundos por serem duas das maiores disponíveis na câmera, enquanto as

demais configurações foram escolhidas de modo a promover maior luminosidade ao resultado final.

Ao analisar visualmente as imagens produzidas é possível concluir que a principal variação foi a exposição das imagens. Embora 19 das 104 imagens produzidas não tenham apresentado a mesma inconsistência de duplicidade de objeto que os primeiros experimentos, ou seja, duas sementes na mesma imagem quando deveria aparecer apenas uma, pela trajetória no vídeo e pela opacidade aparente é possível concluir que foi devido ao enquadramento da imagem. Em 85 das 104 imagens produzidas o resultado foi semelhante ao mostrado na Figura 50, exibindo duas imagens de uma mesma semente no quadro, sendo uma (da direita) com menor opacidade aparente, destacada na imagem como sombra da semente e a outra (da esquerda) de maior opacidade aparente, destacada na imagem como semente.

Figura 50 – Experimento com rampa comercial na combinação 14.



Fonte: a autora.

As demais imagens produzidas se assemelham a Figura 51, mostrando apenas uma imagem de semente no quadro, porém com opacidade aparente bastante reduzida, indicando que existiu a mesma duplicidade dos outros casos, porém não visível no frame.

Figura 51 – Experimento com rampa comercial na combinação 3.



Fonte: a autora.

Logo, a velocidade das sementes ainda foi superior a capacidade de filmagem nítida do equipamento para utilização por frames individuais para as demais análises. Procurando reduzir ainda mais a velocidade alterando a altura da rampa, primeiramente foi medida a velocidade da semente, a partir da tomada de 10 medidas de tempo que 10 sementes diferentes demoraram em percorrer a rampa, calculando então a média das velocidades em 7,5 km/h.

Variando a altura da rampa de aceleração e o ângulo da rampa de desaceleração, conforme o permitido pelo modelo, e recalculando a velocidade da semente pelo mesmo critério, foi possível reduzir apenas cerca de 1 km/h, o que não produziu efeito significativo quanto a nitidez nas imagens finais.

Com o intuito de verificar diferentes equipamentos, foram realizados então experimentos com câmeras CCTV Basler 70gm e 74gc. Para captura das imagens dessas câmeras foi utilizada um equipamento DVR da marca Alive. No entanto a velocidade das sementes também foi superior ao possível para uma captura nítida.

Mesmo que as câmeras tenham uma velocidade significativa de captura, esta é reduzida devido a utilização do DVR. Foram ainda realizados testes com uma câmera IP GC 750, GigE Vison, do fabricante Prosilica. Porém também não foram produzidas imagens com resultados satisfatórios.

Portanto, no cenário adotado, com os equipamentos de captura de vídeo disponíveis, as configurações de velocidade de seus sensores não foram suficientes para que fosse possível estabelecer um protocolo de aquisição, ou seja, uma combinação de equipamento, configuração do equipamento, iluminação e cenário, que produzisse imagens com a nitidez necessária para as análises posteriores pertinentes a pesquisa de qualidade de semente de soja.

A pesquisa mostrou que o equipamento para captura de vídeo, no cenário proposto, deve ser voltado para maiores velocidades, para contrapor a influência da aceleração gravitacional sobre a semente com maior eficiência. Outra abordagem possível para tratar o problema de limitação do ângulo de visão, seria adotar um cenário em que a semente estaria suspensa, porém não em movimento, logo não demandando equipamento voltado para grandes velocidades.