

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
CÂMPUS CORNÉLIO PROCÓPIO
DIRETORIA DE GRADUAÇÃO E EDUCAÇÃO PROFISSIONAL
DEPARTAMENTO DE COMPUTAÇÃO
CURSO SUPERIOR DE ENGENHARIA DE COMPUTAÇÃO

WILLIAN CARDOSO HORIKOSHI

**MÉTODOS DE SEGMENTAÇÃO E CLASSIFICAÇÃO DE SEMENTES
UTILIZANDO DISPOSITIVOS MÓVEIS**

TRABALHO DE CONCLUSÃO DE CURSO

CORNÉLIO PROCÓPIO

2016

WILLIAN CARDOSO HORIKOSHI

**MÉTODOS DE SEGMENTAÇÃO E CLASSIFICAÇÃO DE SEMENTES
UTILIZANDO DISPOSITIVOS MÓVEIS**

Trabalho de conclusão de curso apresentado à disciplina de Orientação de Trabalho de Diplomação, do curso de Engenharia de Computação da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do grau de engenheiro

Orientador: Prof. Dr. Pedro Henrique Bugatti

CORNÉLIO PROCÓPIO

2016



TERMO DE APROVAÇÃO

MÉTODOS DE SEGMENTAÇÃO E CLASSIFICAÇÃO DE SEMENTES UTILIZANDO DISPOSITIVOS MÓVEIS

por

Willian Cardoso Horikoshi

Este Trabalho de conclusão de curso foi julgado adequado para obtenção do Título de “Engenheiro em Curso Superior de Engenharia de Computação” e aprovado em sua forma final pelo Programa de Graduação em Engenharia de Computação da Universidade Tecnológica Federal do Paraná.

Cornélio Procópio, 16/06/2016

Prof. Dr. Pedro Henrique Bugatti
Universidade Tecnológica Federal do Paraná

Profa. Dra. Priscila Tiemi Maeda Saito
Universidade Tecnológica Federal do Paraná

Prof. Dr. Claiton De Oliveira
Universidade Tecnológica Federal do Paraná

AGRADECIMENTOS

Primeiramente agradeço aos meus pais Sandra e Wilson que permitiram que tudo isso acontecesse ao longo da minha vida, sem o apoio deles seria impossível vencer este desafio.

À esta universidade, que me proporcionou tanto o crescimento intelectual quanto o profissional.

Ao professor Dr. Pedro Henrique Bugatti pela orientação e auxílio durante todas as etapas do trabalho.

À minha namorada Renata Carina Soares pelo incentivo, carinho e apoio ao longo de todos os anos dentro da universidade.

À todos os professores do curso que ensinaram com dedicação e respeito e repassar o todo conhecimento necessário.

À todos os colegas de sala por quem convivi durante estes 5 anos.

À todos que por algum motivo influenciaram diretamente ou indiretamente e contribuíram para o trajeto na Universidade e para este trabalho.

RESUMO

HORIKOSHI, Willian Cardoso. MÉTODOS DE SEGMENTAÇÃO E CLASSIFICAÇÃO DE SEMENTES UTILIZANDO DISPOSITIVOS MÓVEIS. 60 f. Trabalho de conclusão de curso – Curso Superior de Engenharia de Computação, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2016.

O procedimento para a verificação da qualidade da semente de soja é visual e devido a isto é altamente suscetível a erros. O especialista com uma lâmina realiza o corte ao meio da semente, após esta ser submetida à solução sal de tetrazólio, para analisar o vigor que possui. Contudo, o indivíduo pode ficar com dúvida em relação à qualidade de algumas sementes. Este trabalho tem como objetivo a implementação de um aplicativo em ambiente *mobile*, para classificação e avaliação de sementes de soja. Desta forma, a aplicação tem como função, realizar a aquisição da imagem por meio da câmera embutida no dispositivo, para posteriormente aplicar técnicas de realce, realizar a segmentação do objeto de interesse e finalizar com sua classificação.

Palavras-chave: Segmentação, Classificação, Sementes de soja

ABSTRACT

HORIKOSHI, Willian Cardoso. SEGMENTATION AND CLASSIFICATION METHODS OF SEEDS USING MOBILE DEVICES. 60 f. Trabalho de conclusão de curso – Curso Superior de Engenharia de Computação, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2016.

The procedure of verification of soybean seed quality is visual and highly susceptible to errors. The specialist performs cutting in half of the seed, after it, submit to the tetrazolium salt solution to analyze the strength. However, the specialist can have doubt about the quality of some seeds. This purpose of this work is the implementation of an application environment textit mobile for classification and soybeans evaluation. Thus, the application function performs image acquisition through the built-in camera on the device and later apply enhancement techniques, performs too segmentation of the object of interest and classify it.

Keywords: Segmentation, Classification, Soybeans Seeds

LISTA DE FIGURAS

FIGURA 1	– Soja (<i>Glycine Max (L.) Merrill</i>).	11
FIGURA 2	– Soja com o composto de tetrazólio.	15
FIGURA 3	– Tipos de sementes de soja.	16
FIGURA 4	– Representação das coordenadas de uma imagem.	17
FIGURA 5	– Vizinhança 4, considerando as horizontais e verticais à esquerda ou diagonais à direita.	18
FIGURA 6	– Vizinhança 8, considerando todos os pixels ao redor de p	18
FIGURA 7	– Etapas de um processamento de imagens.	19
FIGURA 8	– Cores em RGB aditivas à esquerda e subtrativa à direita.	20
FIGURA 9	– Representação do histograma da imagem.	21
FIGURA 10	– Aplicação do filtro da média à direita.	22
FIGURA 11	– Exemplo da aplicação de segmentação.	23
FIGURA 12	– Aplicação da limiarização com o limiar em 80.	24
FIGURA 13	– Árvore de decisão para um jogo de tênis.	29
FIGURA 14	– Dispositivo celular utilizado nos testes	32
FIGURA 15	– Tipo de classificação em sementes(Adaptado de (SANTANNA et al., 2009)).	34
FIGURA 16	– Interface simples da aplicação	36
FIGURA 17	– Opções de configurações.	38
FIGURA 18	– Opções de configurações de descritor de cor.	39
FIGURA 19	– Opções de escolha entre classificadores.	40
FIGURA 20	– Etapas de processamento	41
FIGURA 21	– Passo 2.1	42
FIGURA 22	– Passo 2.2	42
FIGURA 23	– Passo 2.3	43
FIGURA 24	– Passo 2.4	43
FIGURA 25	– Passo 2.5	44
FIGURA 26	– Passo 2.6	44
FIGURA 27	– Aplicação do algoritmo de rotação.	45
FIGURA 28	– Aplicação do algoritmo de fecho convexo	45
FIGURA 29	– Passo 2.8: Resultado das sementes segmentadas desde o passo 2.	46
FIGURA 30	– Imagem de sementes de soja normais com boa iluminação, sendo (a) imagem original e (b) imagem segmentada.	48
FIGURA 31	– Resultado da imagem capturada segmentada com sementes de soja.	48
FIGURA 32	– Imagem de sementes de soja normais com baixa iluminação, sendo (a) imagem original e (b) imagem segmentada.	49
FIGURA 33	– Resultado da imagem segmentada em ambiente pouco iluminado.	49
FIGURA 34	– Resultados das médias de acurácia e de tempo, classificando pelo método <i>cross-validation</i> considerando a base inteira.	52
FIGURA 35	– Resultados das médias de acurácia e de tempo, classificando uma lâmina.	55

LISTA DE TABELAS

TABELA 1	– Definição da base de imagem.	34
TABELA 2	– Classes de sementes da base.	35
TABELA 3	– Tabela comparativa de desempenho com classificador J48, onde T.D = tempo de descrição e T.C = tempo de classificação.	50
TABELA 4	– Tabela comparativa de desempenho com classificador IBk, onde T.D = tempo de descrição e T.C = tempo de classificação.	51
TABELA 5	– Tabela comparativa de desempenho com classificador Naive Bayes, onde T.D = tempo de descrição e T.C = tempo de classificação.	51
TABELA 6	– Tabela comparativa de desempenho entre os classificadores escolhidos em cada experimento, onde T.D = tempo de descrição e T.C = tempo de classificação.	52
TABELA 7	– Tabela comparativa de tamanho de vetor de características.	53
TABELA 8	– Tabela comparativa de desempenho entre os classificadores escolhidos em cada experimento, onde T.D = tempo de descrição e T.C = tempo de classificação (J48).	54
TABELA 9	– Tabela comparativa de desempenho entre os classificadores escolhidos em cada experimento, onde T.D = tempo de descrição e T.C = tempo de classificação (IBk).	54
TABELA 10	– Tabela comparativa de desempenho entre os classificadores escolhidos em cada experimento, onde T.D = tempo de descrição e T.C = tempo de classificação (Naive Bayes).	55
TABELA 11	– Tabela comparativa de desempenho entre os classificadores escolhidos nos experimentos 3 , onde T.D = tempo de descrição e T.C = tempo de classificação.	55

LISTA DE SIGLAS

RAS	Regras para Análise de Sementes
RGB	Espaço amostral de cores (Vermelho, Verde e Azul)
CMYK	Espaço amostral de cores (Ciano, Magenta e Amarelo)
BIC	Border Interior Classification
GCH	Global Color Histogram
CGCH	Cumulative Global Color Histogram
LBP	Local Binary Pattern
IBK	Instance-based learning algorithms
J48	Algoritmo de classificação baseado em árvores de decisões
Dataset	Conjunto de dados
GB	Gigabyte
RAM	Random Access Memory
OpenCV	Open Source Computer Vision Library
IDE	Integrated Development Environment
WEKA	Waikato Environment for Knowledge Analysis
.arff	Attribute-Relation File Format

SUMÁRIO

1	INTRODUÇÃO	11
1.1	MOTIVAÇÃO	11
1.2	PROBLEMA	12
1.3	OBJETIVOS GERAIS	12
1.4	OBJETIVOS ESPECÍFICOS	12
1.5	JUSTIFICATIVA	13
1.6	ORGANIZAÇÃO DO TEXTO	13
2	FUNDAMENTAÇÃO TEÓRICA	14
2.1	REALIZAÇÃO DO TESTE DE TETRAZÓLIO	14
2.2	COMPUTAÇÃO VISUAL	16
2.2.1	Imagem	17
2.2.2	Vizinhança de um pixel	18
2.2.3	Conectividade	18
2.3	PROCESSAMENTO DE IMAGENS	19
2.4	AQUISIÇÃO	20
2.4.1	Amostragem e quantização e resolução espacial	20
2.4.2	Espaço de cores	20
2.5	PRÉ-PROCESSAMENTO DE IMAGENS	21
2.5.1	Histograma	21
2.5.2	Filtros	22
2.5.2.1	Filtro da média	22
2.5.2.2	Filtro da mediana	22
2.6	SEGMENTAÇÃO	23
2.6.1	Detecção de bordas	23
2.6.2	Limiarização	24
2.7	REPRESENTAÇÃO E DESCRIÇÃO	24
2.7.1	Descritor de cor	25
2.7.1.1	BIC (Border/Interior Pixel Classification)	25
2.7.1.2	CGCH (Cumulative Global Color Histogram)	25
2.7.2	Descritor de textura	26
2.7.2.1	LBP (Local Binary Pattern)	26
2.7.3	Descritor de forma	26
2.8	RECONHECIMENTO E INTERPRETAÇÃO	27
2.8.1	Classificação	27
2.8.1.1	Algoritmo IBK	28
2.8.1.2	Algoritmo J48	28
2.8.1.3	Algoritmo Naive Bayes	29
2.8.2	Validação Cruzada	29
2.9	CONSIDERAÇÕES	30
2.10	TRABALHO RELACIONADO	30
3	MATERIAIS E MÉTODOS	32

3.1	DISPOSITIVO MÓVEL	32
3.2	SOFTWARES UTILIZADOS	33
3.3	DEFINIÇÃO DE CLASSIFICAÇÃO E CARACTERÍSTICAS	33
3.4	BASE DE IMAGENS	33
3.5	FUNIONAMENTO DA APLICAÇÃO	35
3.5.1	Interface	35
3.6	ETAPAS DE EXECUÇÃO	40
4	RESULTADOS E DISCUSSÕES	47
4.1	CENÁRIO 1	47
4.2	CENÁRIO 2	49
4.3	CENÁRIO 3	53
4.4	CONSIDERAÇÕES	56
5	CONSIDERAÇÕES FINAIS	57
5.1	TRABALHOS FUTUROS	58
	REFERÊNCIAS	59

1 INTRODUÇÃO

1.1 MOTIVAÇÃO

As sementes de soja (*Glycine max* (L.) Merrill), apresentadas na Figura 1, são uma cultura proveniente do continente asiático, sobretudo a região do rio Yangtse, localizado na China. Atualmente, a cultura é resultado da evolução de sucessivos processos de melhorias de genótipos ancestrais (NETO et al., 1998). Esse processo iniciou-se naturalmente entre espécies selvagens, com a posterior domesticação dessas e, a partir daí, o homem passou a direcionar melhoramento genético visando obter as características mais desejadas.



Figura 1: Soja (*Glycine Max* (L.) Merrill).

Fonte: <http://midias.folhavoria.com.br/files/2014/05/soja.jpg>

Segundo Neto et al. (1998) em 1882, ocorreu a introdução da soja no Brasil pelo professor Gustavo Dutra, da Escola de Agronomia da Bahia, o qual foi o responsável pelos primeiros estudos com a cultura no país. Após dez anos, o Instituto Agrônomo de Campinas (IAC), no Estado de São Paulo, iniciou estudos para obtenção de cultivares aptos à região, a partir disto o IAC iniciou a distribuição de sementes para produtores do Estado. Há indícios que neste período na região sul do país, principalmente no Estado do Rio Grande do Sul, começou o cultivo da soja. Esta região possui as condições ideais para o cultivo e clima semelhante a do sul dos Estados Unidos, o qual promoveu a origem dos primeiros genótipos da soja brasileira.

Segundo Neto et al. (1998), o vigor de uma semente está atrelado ao potencial fisiológico em gerar uma boa planta. Assim, tratando-se da qualidade fisiológica, este representa o vigor das sementes, no qual pode influenciar diretamente muitos aspectos de qualidade como, por exemplo, o desenvolvimento final da planta, bem como a quantidade de sementes produzidas.

O método de análise das sementes é visual e suscetível a erros, variando ainda a opinião entre um analista e outro por ser um método subjetivo, assim, requer do analista de sementes conhecimento anatômico destas, experiência e um nível de criteriosidade acurado (PINHO, 2011).

1.2 PROBLEMA

Atualmente, o procedimento para a verificação da qualidade e vigor da semente de soja, derivada de uma amostra do lote, é realizada de forma visual. Deste modo, o especialista com as ferramentas necessárias, realiza o corte ao meio da semente após esta ser submetida à solução corante (tetrazólio), permitindo assim, observar a vigor do lote. Contudo, a precisão de acerto é um dos problemas decorrentes das análise dos grãos, no qual leva o indivíduo a ficar com dúvida em relação à análise de algumas sementes, bem como trata-se de um trabalho extremamente cansativo e, portanto suscetível à erros.

1.3 OBJETIVOS GERAIS

O presente trabalho visa, a implementação de uma aplicação para dispositivos móveis baseado em processamento de imagens, o qual auxiliará a classificação no vigor da semente de soja.

1.4 OBJETIVOS ESPECÍFICOS

Os objetivos específicos do trabalho são:

- estudar os tipos de anomalias e vigor presentes em sementes de soja;
- adquirir conhecimento a respeito da visão computacional;
- desenvolver um aplicativo móvel, para o auxílio na tomada de decisão para classificação quanto ao vigor da semente de soja desde o processo de aquisição da amostra do lote, podendo ser utilizado para aplicações futuras e outros tipos de sementes.

1.5 JUSTIFICATIVA

Conforme citado na seção 1, o método aplicado no processo de análise das sementes de soja é visual e suscetível a erros devido à identificação inadequada, a qual promove prejuízos tanto para a empresa fornecedora quanto ao cliente. Desta forma a empresa terá sua reputação comprometida caso o lote vendido seja, realmente, de má qualidade, a qual o técnico havia avaliado como sendo de boa qualidade. A organização fornecedora, ainda, poderá ter prejuízos financeiros quando um lote de boa qualidade for avaliado como de baixa qualidade e, assim, ser vendido por preço inferior ou descartado.

Com o objetivo de reduzir esse prejuízo e melhorar a eficiência na classificação, o uso das técnicas de processamento de imagens implementadas em um aplicativo móvel, de uma certa forma, aprimoraria a análise realizada sobre as sementes de soja. O motivo de ser em ambiente móvel, está ligado à facilidade e mobilidade no manuseio da aplicação, desta forma, o técnico com o dispositivo em mãos (celular), realizaria a aquisição da foto por meio da câmera e, posteriormente, uma análise de classificação de uma amostra de sementes.

1.6 ORGANIZAÇÃO DO TEXTO

Este texto está organizado em 5 capítulos, sendo o presente capítulo referente a motivação e os objetivos para o desenvolvimento do trabalho, os demais capítulos possuem a seguinte distribuição:

- no segundo Capítulo, apresenta-se a fundamentação teórica, na qual incluem conceitos referentes a processamento de imagens;
- no terceiro Capítulo, apresenta-se os materiais e a metodologia;
- no quarto Capítulo, os resultados e discussões;
- no quinto Capítulo, as considerações finais.

2 FUNDAMENTAÇÃO TEÓRICA

Será apresentado nesse capítulo todo o embasamento teórico dos conceitos e técnicas, relativos ao processamento de imagens digitais, os quais foram estudados e aplicados para o desenvolvimento do aplicativo.

2.1 REALIZAÇÃO DO TESTE DE TETRAZÓLIO

Atualmente, a utilização do teste de tetrazólio gera uma grande repercussão quanto aos aspectos qualitativos pois, devido a este teste, elevado número lotes de sementes de alto padrão vem sendo comercializadas. O teste destaca-se devido a sua rapidez, precisão e pelo grande número de informações que são fornecidas (NETO et al., 1998), o qual permite-se verificar:

- danos mecânicos;
- deterioração relativa a umidade;
- danos por insetos (percevejos);
- danos por secas e altas temperaturas;
- danos por geada.

O teste consiste nas atividades das enzimas desidrogenases, as quais catalizam as vias respiratórias nas mitocôndrias, durante a glicose e o ciclo de Krebs, reduzindo o sal de tetrazólio nos tecidos vivos. Assim, quando a semente de soja é imersa na solução incolor destas enzimas, sendo difundida por meio dos tecidos vivos, resulta na formação de um composto vermelho, como mostra a Figura 2, indicando que há atividade respiratória nas mitocôndrias, ou seja, é uma indicação positiva da viabilidade celular do tecido.

Para a realização do teste é necessário:



Figura 2: Soja com o composto de tetrazólio.

Fonte: França Neto.

- reagente:

sal de tetrazólio: 2,3,5-trifenil cloreto de tetrazólio.

- vidraria:

placas de Petri;

frasco de vidro (becker), volume 50 ml;

frasco de vidro de cor âmbar, para armazenar o reagente no qual é fotossensível e se reduz com a luz.

- outros materiais:

lâminas de barbear;

estufa ou germinador, ajustado na temperatura de 35 a 40°C;

lupa;

refrigerador para armazenamento;

papel de germinação.

Utiliza-se a solução com concentração de 0,075% permitindo a coloração adequada das sementes e, conseqüentemente, a visualização com maior precisão dos danos mecânicos, aos quais não seriam detectados com contrações maiores.

No preparo das sementes, selecionam-se amostras representativas do lote e coletadas conforme a RAS (Regras para Análise de Sementes; Brasil, 1992). Recomenda-se a utilização de 400 sementes por amostra (8 sub-amostras, com 50 sementes cada) (MINISTÉRIO DA

AGRICULTURA, PECUÁRIA E ABASTECIMENTO, 2009). Todas as amostras são pré-condicionadas em embalagens de papel de germinação umedecida e mantida por 16 horas em temperatura ambiente de 25°C, permanecendo em câmaras úmidas.

Após o processo do pré-condicionamento, em ambiente escuro, as amostras são colocadas em frascos de béquer e sendo submersas na solução de tetrazólio a uma temperatura de 35°C a 40°C por um tempo de 150 a 180 minutos.

A lavagem da amostra ocorre quando a coloração for ideal e são mantidas na água até o momento da avaliação. Os possíveis níveis de vigor (Tz 1-3) segundo (NETO et al., 1998) são:

- vigor muito alto: igual ou superior a 85%;
- vigor alto: de 75% a 84%;
- vigor médio: de 60% a 74%;
- vigor baixo: de 50% e 59%;
- vigor muito baixo: igual ou inferior a 49% .

Como mostra na Figura 3 é possível distinguir pela coloração, os danos causados nas sementes (b), (c) e (d) em relação a semente (a).




Figura 3: Tipos de sementes de soja.

Fonte: <http://www.seednews.inf.br> (adaptado).

2.2 COMPUTAÇÃO VISUAL

Nesta seção e subseções todas as informações estão baseadas em (GONZALEZ; WO-ODS, 2001) em adição com as referências citadas no texto.

Com a constante evolução da tecnologia, na qual a computação visual está inserida uma importante área com uma vasta gama de aplicações em diversos segmentos, e que certamente está em conjunto com a tecnologia, em constante evolução. Nela estão envolvidos:

A tecnologia está constantemente em evolução, estando ligada a computação visual, a qual é uma importante área com uma vasta gama de aplicações em diversos segmentos. Esta área envolve:

- processamento de imagens;
- computação gráfica;
- visão computacional;
- aprendizado de máquina.

2.2.1 IMAGEM

Antes de prosseguir com a seção de processamento de imagens é necessário entender o conceito de imagem propriamente dito.

Imagem é uma função bidimensional da intensidade de luz, em função de x e y , desta forma, a amplitude de $f(x,y)$ define a intensidade. A definição do ponto inicial por padrão é a partir da esquerda para direita e de cima para baixo, conforme indica a Figura 4. Para formação de uma imagem é necessário que x , y e a amplitude de f tenham valores finitos, ou seja, discretizados. Desta forma, uma imagem possui um número finito de elementos, com seus respectivos referenciais de localização (x e y), tais elementos são conhecidos como pixels.




Figura 4: Representação das coordenadas de uma imagem.

Fonte: (GONZALEZ; WOODS, 2001) (adaptado).

2.2.2 VIZINHANÇA DE UM PIXEL

O termo vizinhança e conectividade está relacionado as propriedades utilizadas nas operações de pixel a pixel em algoritmos de processamento de imagens digitais. A forma de avaliação do posicionamento do pixel é definido por um ponto $p(x, y)$, desta forma traça-se um plano imaginário sobre o ponto central, no qual a coordenada é representada pelo x e a ordenada pelo y . As vizinhanças comumente utilizadas são:

- **Vizinhança 4.** Classificada como N4, considera-se os pontos nas horizontais e verticais, ou somente as diagonais ao redor do pixel p , a Figura 5 exemplifica este processo.




Figura 5: Vizinhança 4, considerando as horizontais e verticais à esquerda ou diagonais à direita.

Fonte: Autoria própria.

- **Vizinhança 8.** Classificada como N8, considera-se todos os pontos horizontais, verticais e diagonais ao redor do pixel p , como mostra a Figura 6.




Figura 6: Vizinhança 8, considerando todos os pixels ao redor de p .

Fonte: Autoria própria.

2.2.3 CONECTIVIDADE

A análise dos pontos adjacentes que tenham as mesmas propriedades que o pixel p , considerando a vizinhança 4 ou 8, define-se de conectividade. Assim, o valor da conectividade

em uma imagem binária é definida pela quantidade de transições do pixel branco para o preto, percorrendo os pixels vizinhos ao central.

2.3 PROCESSAMENTO DE IMAGENS

O processamento de imagens pertencente à Computação Visual, nos permite realizar o processo de visualização, análise e manipulação das informações contida na imagem. Desta forma como representado na Figura 7, as etapas do sistema de processamento de imagens serão abordadas mais detalhadamente nas seções posteriores.

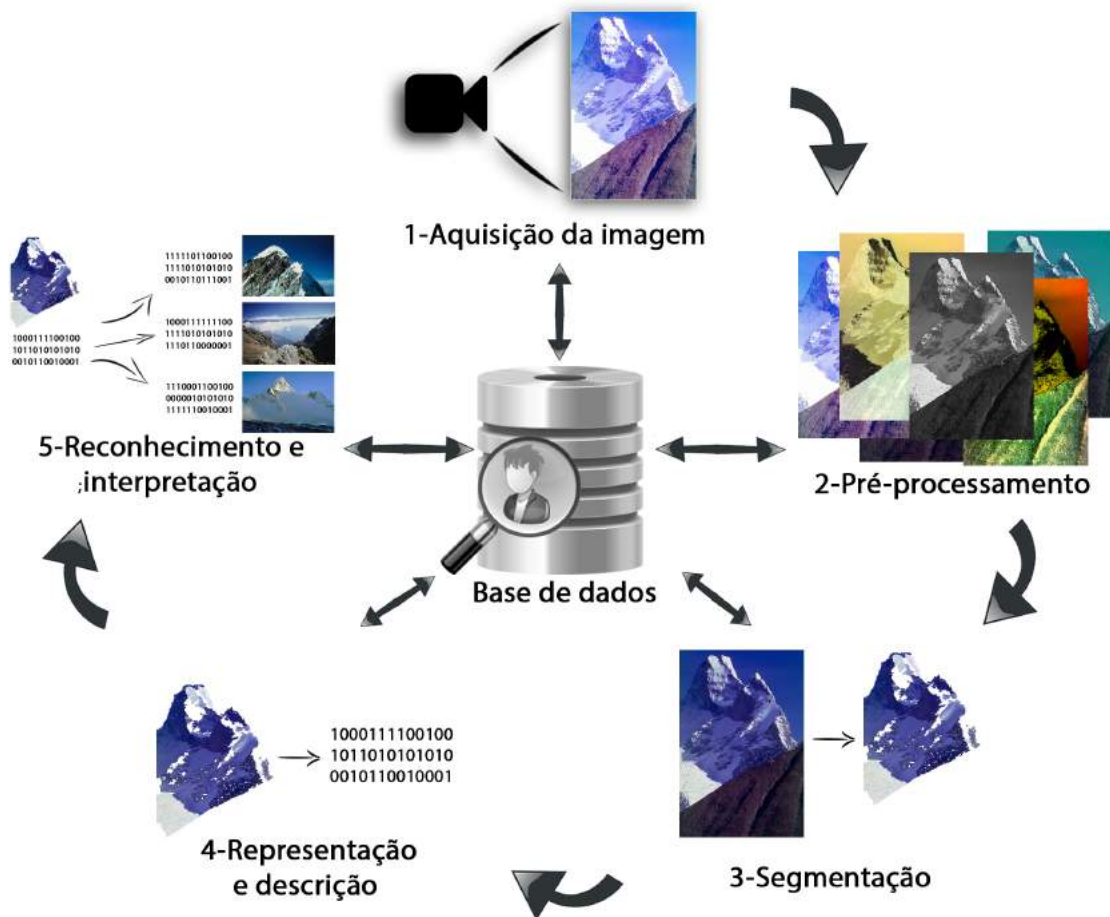


Figura 7: Etapas de um processamento de imagens.

Fonte: autoria própria.

2.4 AQUISIÇÃO

Possuir um dispositivo de captura é essencial, podendo ser uma câmera fotográfica, de vídeo, *scanners* dentre outros, o qual realizará a aquisição da imagem.

2.4.1 AMOSTRAGEM E QUANTIZAÇÃO E RESOLUÇÃO ESPACIAL

Após a etapa de aquisição, a imagem precisa ser convertida em dados numéricos para análise computacional. A amostragem ocorre na definição da escalas das coordenadas, enquanto, o processo de quantização representa os níveis de intensidades da luz na imagem. Ao realizar o processo de digitalização, inicialmente, a imagem assume um tamanho adimensional, portanto, definindo a razão entre o número de pixels e o tamanho da imagem real tem-se a resolução espacial (CASTLEMAN, 1995).

2.4.2 ESPAÇO DE CORES

O espaço de cores é um sistema tridimensional de coordenadas, onde cada eixo se refere a uma cor primária (HUGHES et al., 1990). Desta forma, a quantidade de cores primárias para reproduzir uma cor secundária consiste no valor de intensidade de cada eixo da coordenada.

Conforme Souto (2000), o espaço de cores RGB se baseia em três cores primárias, vermelho, verde e azul. A luz branca é reproduzida se as três cores forem somadas, conforme ilustra a Figura 8. As cores ciano, magenta e amarelo (CMYK) são definidas como cores subtrativas que quando somadas reproduzem a cor preta. Este tipo de espaço de cor é comumente empregado em impressoras coloridas.




Figura 8: Cores em RGB aditivas à esquerda e subtrativa à direita.

Fonte: autoria própria.

2.5 PRÉ-PROCESSAMENTO DE IMAGENS

Este passo é importante para realizar um tratamento da imagem capturada. Aplica-se técnicas de realce, suavização de elementos, minimização de ruídos de uma imagem e funções de transformação com o objetivo de melhorar a qualidade.

2.5.1 HISTOGRAMA

Os histogramas são determinados a partir da contagem da quantidade dos pixels pelos valores de sua intensidade, também, conhecidos como Função de Densidade de Probabilidade (PDF) (SWAIN; BALLARD, 1991), como representa a Figura 9. Assim, como exemplo de aplicações de histogramas estão a melhoria da definição, compressão, segmentação ou, ainda, a descrição de uma imagem.




Figura 9: Representação do histograma da imagem.

Fonte: (GONZALEZ; WOODS, 2001) (adaptado).

O histograma fornece a descrição global de uma imagem. Caso ele seja estreito, é indício de baixa visibilidade em uma imagem, pois o intervalo em níveis de cinza é baixo. Uma distribuição uniforme dos níveis de cinza de um histograma representa um maior contraste e uma melhor visibilidade (ACHARYA; RAY, 2005).

Para sua implementação, o histograma possui baixo nível de complexidade, portanto, é uma técnica muito utilizada em aplicações em que o *hardware* não pode oferecer muito processamento.

2.5.2 FILTROS

Consiste na aplicação de técnicas de transformação utilizando máscaras, onde o procedimento é realizado pixel a pixel. O objetivo é corrigir, suavizar ou realçar determinada característica de uma imagem em um contexto específico. Existem dois tipos de filtros, os lineares e não-lineares.

2.5.2.1 FILTRO DA MÉDIA

Dentre as técnicas de realce mais simples destaca-se o filtro da média. Segundo (FILHO; NETO, 1999) é conhecido como filtro do domínio espacial, no qual sua máscara possui o valor 1 para todos os valores e, posteriormente, dividindo o resultado da convolução da máscara com a imagem por um fator de normalização que é igual à soma da máscara utilizada. Desta forma, verifica-se que ao utilizar máscaras maiores o grau de borramento da imagem resultante será elevado (FILHO; NETO, 1999), um exemplo, pode ser verificado na Figura 10.



Figura 10: Aplicação do filtro da média à direita.

Fonte: (GONZALEZ; WOODS, 2001) (adaptado).

2.5.2.2 FILTRO DA MEDIANA

Este filtro consiste em substituir a intensidade do pixel central pela mediana dos pixel em dada máscara aplicada na imagem. Segundo Gonzalez e Woods (2001), este filtro é mais útil no processamento de imagens em relação à certos tipos de ruídos como o conhecido ruído de sal e pimenta, proporcionando ótimos resultados na redução de ruídos e preservação da intensidade das bordas e linhas de uma imagem.

Sua implementação é muito simples, basta ordenar de ordem crescente ou decrescente os valores dos pixels vizinhos contidos na máscara aplicada, incluindo o pixel central. Desta

forma, calcula-se a mediana desta sequência de pixels e atribui o valor calculado ao pixel central. Assim, o objetivo do filtro é forçar que as intensidades muito distintas se assemelhem com sua vizinhança.

2.6 SEGMENTAÇÃO

Segundo Jain (1989) a segmentação refere-se ao processo de decomposição de uma imagem digital em vários segmentos (regiões) que a formam. Assim, consiste em separar o objeto de interesse do restante da imagem, baseando-se em técnicas de detecção de descontinuidades caracterizadas como borda ou de similaridades em determinadas regiões. A segmentação de imagens tem como função decompor a imagem em partes, analisar e, posteriormente, realizar uma mudança de representação (SHAPIRO; STOCKMAN, 2001), como mostra a Figura 11.



Figura 11: Exemplo da aplicação de segmentação.

Fonte: <http://www.vision.ime.usp.br/noma/segm1p/pics/segm1-10.jpg>

2.6.1 DETECÇÃO DE BORDAS

O método de detecção de bordas é, frequentemente, utilizado para segmentar imagens. Baseia-se em variações abruptas (locais) de intensidades entre os pixels (GONZALEZ; WOODS, 2001) para detecção de bordas. Portanto, para identificação das descontinuidades, essas técnicas utilizam o cálculo da primeira e segunda derivada entre as intensidades dos pixels.

A primeira derivada possui comportamento de atribuir valores nulos as intensidades de cinza constantes e atribuir uma constante igual ao grau da inclinação da borda aos trechos de descontinuidade. Enquanto, que a segunda derivada atribui valores positivos a transições relacionadas ao lado escuro da borda e negativo ao lado claro desta.

Desta forma, utiliza-se a primeira derivada para detecção da presença de uma borda e a segunda derivada para fornecer uma localização da borda mais próxima do real. Para calcular a primeira derivada em qualquer ponto da imagem, utiliza-se a magnitude do gradiente naquele ponto e aplica-se o *laplaciano* para obter a segunda derivada.

2.6.2 LIMIAZIZAÇÃO

O processo de limiarização consiste basicamente em separar os grupos de cinza de uma imagem (LEITE et al., 2011), ou seja, determina-se uma intensidade de cinza (limiar), a qual separa as partes da imagem em que grupos de pixels semelhantes, em intensidades, sejam separados de outros. Assim, o desafio de realizar este processo é determinar qual o melhor valor de limiar. Com isto, analisando um histograma de uma imagem, observa-se a formação de vales na intensidade, a partir deste fato o valor de limiar é escolhido, baseando-se neste vale, a Figura 12 ilustra um exemplo.



Figura 12: Aplicação da limiarização com o limiar em 80.

Fonte: (GONZALEZ; WOODS, 2001) (adaptado).

2.7 REPRESENTAÇÃO E DESCRIÇÃO

Este processo realiza a conversão dos dados primários (pixels) à uma forma adequada ao processamento computacional. O processo de descrição extrai características intrínsecas à imagem, ou seja, atributos que resultam em alguma informação quantitativa de interesse.

As regiões de uma imagem possuem forma, cor e textura, as quais podem ser mensuradas. Portanto, este tipo de medida é denominada de característica de uma imagem, que normalmente é agrupada em vetor de valores escalares, denominado descritor de imagem. Assim, cada objeto (ou imagem) é representado por um ponto no espaço R^n , para n características. Os algoritmos extratores de características trabalham por meio dos conteúdos intrínsecos das imagens. Como resultados de saída, geram-se os vetores de características que armazenam os atributos visuais, aos quais permitem, posteriormente, a medição da similaridade entre duas ou mais imagens.

2.7.1 DESCRITOR DE COR

A cor de um objeto pode ser representada em diferente espaço de cores, que em uma imagem, pode possuir características diferenciadas. Este tipo descritor pode representar a distribuição de cor do objeto da imagem, podendo levar em conta ou não a informação espacial. Segundo Swain e Ballard (1991) imagens que possuem distribuição de cor similares, podem conter algum grau de similaridade.

2.7.1.1 BIC (BORDER/INTERIOR PIXEL CLASSIFICATION)

O descritor BIC é um algoritmo que realiza a análise baseando-se no espaço de cor da imagem (STEHLING et al., 2002). Este espaço de cor é o canal RGB uniformemente quantizado em 64 cores, sendo 4 para cada canal (vermelho, verde e azul).

Após esta quantização de cada pixel da imagem, define-se se é ele de borda ou interior com base em sua vizinhança. São criados dois vetores com 64 posições cada, definidos de vetor de interior ou vetor de borda.

O *pixel* é classificado como interior se todos os seus vizinhos possuírem a mesma cor quantizada, da mesma forma, para ser classificado como borda, pelo menos um de seus vizinhos deve possuir uma cor diferente do pixel central. Cada pixel analisado retornará um valor de 0 a 63 sendo este incrementado no vetor de acordo com sua característica (borda/interior) supondo que, inicialmente, cada vetor esteja com os valores zerados. A vizinhança pode definida como 4 ou 8.

2.7.1.2 CGCH (CUMULATIVE GLOBAL COLOR HISTOGRAM)

Segundo Santos et al. (2009) o GCH (Global Color Histogram) é o mais popular descritor de cor da literatura onde é utilizado como base para teste de outros descritores. Este algoritmo de descrição realiza a quantização de cores do espaço RGB e a contagem de cada intensidade de pixel de cada canal, formando três histogramas, um para cada canal de cor (SWAIN; BALLARD, 1991). Ao final da contagem os três são concatenados formando um único histograma. O tamanho deste varia do valor quantizado da imagem. Como derivado a partir da função GCH o algoritmo CGCH (Cumulative Global Color Histogram) realiza a mesma função. A diferença está no histograma, onde cada *bin* (barra vertical do histograma) se refere ao valor acumulado pela soma dos valores anteriores (SANTANNA et al., 2009).

2.7.2 DESCRITOR DE TEXTURA

Os descritores de textura podem ser separados por taxonomias em diferentes métodos:

- **Estatísticos.** Sendo a maneira mais tradicional de analisar a distribuição espacial, onde é possível extrair informações estatística sobre os níveis de cinza de uma imagem.
- **Geométricos.** Analisa a imagem por meio de elementos de textura ou primitivas, onde é considerado o tamanho, forma, a área e comprimento.
- **Baseado em modelos.** Realiza-se a construção de modelos, que podem descrever a textura, utilizando as qualidades perceptivas essenciais.
- **De processamento de sinais.** Utilizado para filtragem no domínio espacial e de frequência, sendo densidades de bordas ou desvio padrão respectivamente.

2.7.2.1 LBP (LOCAL BINARY PATTERN)

Sendo do tipo estatístico o LBP ou Padrão Binário Local extrai informações de variação dos brilhos entre pixels vizinhos (OJALA et al., 1996). É definida uma janela com raio r e uma quantidade de vizinhos p .

A imagem é percorrida considerando as variações entre os brilhos dos pixels vizinhos em relação ao pixel central da janela, sendo 0 para avaliação negativa e 1 para a positiva. Para garantir invariância a rotação, realiza-se a contagem das transições entre 1/0 e 0/1. Se a quantidade for menor ou igual a 2, o valor do LBP é a quantidade de sinais 1, senão, o valor é $p+1$. O vetor de característica é um histograma contendo $p+2$ valores (TAKALA et al., 2005).

2.7.3 DESCRITOR DE FORMA

Basicamente os descritores de forma se resumiam em definir informações simples como, comprimento, perímetro e área. Ao longo do tempo, diversas implementações de descritores de forma vêm sendo propostas, como os baseados em transformada discreta de Fourier, BAS (Beam Angle Statistics), dimensão Fractal Multiescala, saliências do Segmento e saliências do Contorno e Editing Shock Graphs (TORRES; MORENO, 2008).

2.8 RECONHECIMENTO E INTERPRETAÇÃO

Sendo a última etapa do processo atribuí-se um rótulo ao objeto com base nos dados fornecido pelo descritor. A interpretação é realizada com base nos rótulos existentes e conhecidos, uma das formas de realizar este processo é com base em classificação.

2.8.1 CLASSIFICAÇÃO

O Aprendizado de Máquina (do inglês, Machine Learning) é a área de Inteligência Artificial cujo objetivo é o desenvolvimento de técnicas computacionais sobre processo de aprendizado (BISHOP, 2006), desta forma, a classificação pertence ao processo de aprendizado de máquina, no qual um modelo é desenvolvido com capacidade de realizar identificação sobre um conjunto de população.

Segundo Souto (2000) os métodos de classificação de imagens podem ser divididos entre aqueles que se utilizam de informações das classes que devem encontrar na imagem (supervisionados), e aqueles que procuram as classes sem nenhuma informação prévia (não-supervisionados). Desta forma os métodos supervisionados se baseiam em informações de amostragem de cada classe.

No presente trabalho, serão abordados os conceitos de aprendizado supervisionado. Como citado anteriormente, é fornecida uma referência do objetivo a ser alcançado, assim, o algoritmo de aprendizado recebe o valor de saída desejado para cada conjunto de dados de entrada apresentado. Como exemplo de alguns algoritmos, temos:

- Árvores de Decisões;
- Redes Neurais;
- Máquinas de Vetores de Suporte (Support Vector Machine - SVM);
- Transformação Baseada em Aprendizado (Transformation Based Learning - TBL);
- Algoritmo J48;
- Random Trees;
- Perceptron de Multicamadas (Multilayer Perceptron - MLP);
- Vizinhos Próximos (K Nearest Neighbor - KNN);
- Floresta de Caminhos Ótimos (Optimum Path Forest - OPF).

2.8.1.1 ALGORITMO IBK

Proposto por (AHA; KIBLER, 1991) o algoritmo IBK (Instance-based learning algorithms) é um algoritmo do tipo K-Nearest Neighbors (K-NN), onde o aprendizado é baseado em analogia. Seu conjunto de treinamento é constituído de vetores de n-dimensões, onde cada elemento no conjunto representa um ponto no espaço n-dimensional.

A classificação de uma instância desconhecida é feita baseada nas classes dos K elementos vizinhos mais próximos, assim, serão escolhidos os elementos que tiverem o maior grau de similaridade com a instância desconhecida e a rotulação é indicada pela maior frequência de classe entre os k-vizinhos.

É um método de classificação exaustivo em processamento de grandes conjunto de dados, mas para determinadas aplicações menores, o método é bastante aceitável.

2.8.1.2 ALGORITMO J48

O algoritmo J48 forma uma árvore de decisão a partir de um conjunto de treinamento. A estrutura da árvore é formada por nós (raiz e internos), os quais são rotulados com o nome do atributo do vetor de características. Define-se rótulos com os valores dos atributos as quais são pertinentes para suas ramificações, e nas pontas ficam as folhas, nos quais são rotuladas com o nome da classe que define todas as condições daquela ramificação.

Esses classificadores possuem esse nome, pois sua estrutura é similar a uma árvore. Os algoritmos de árvore de decisão possuem metodologias que a partir de um conjunto de dados de treinamento, onde as classes são previamente conhecidas conseguem induzir a formação da árvore de decisão. Um exemplo clássico ilustrado para a possibilidade de ocorrer uma partida de tênis com base no tempo, umidade e vento é apresentada na Figura 13.

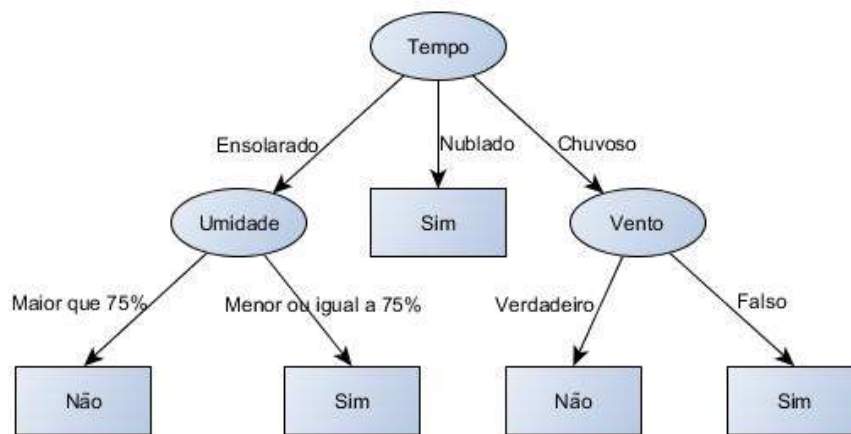


Figura 13: Árvore de decisão para um jogo de tênis.

Desta forma, este processo de classificação de uma instância acontece percorrendo a árvore, começando pelo nó raiz, procurando percorrer os arcos que unem os nós, onde cada um destes possui uma condição específica para determinar a qual ramificação seguir, ao contemplar todas as condições até atingir um nó folha, rotula-se aquela folha com o nome da classe referente à condição encontrada.

2.8.1.3 ALGORITMO NAIVE BAYES

O algoritmo classificador Naive Bayes é baseado em funções bayesianas sendo um tipo de classificador estatístico (JOHN; LANGLEY, 1995), sendo o mais simples dos classificadores Bayesianos (YANG; WEBB, 2003; KEOGH; PAZZANI, 1999), que tem como base, a probabilidade de uma instância pertencer à uma classe. Dessa forma, considera-se que as instâncias sejam independentes uma das outras em relação as classes, descrito na literatura como um classificador ingênuo.

Proveniente do teorema de Bayes, a classificação bayesiana calcula a probabilidade condicional de cada instância a uma determinada classe, portanto, o rótulo da instância é definido pela classe que obteve o maior resultado probabilístico.

2.8.2 VALIDAÇÃO CRUZADA

A técnica de validação cruzada (Cross-validation) permite utilizar todos os elementos disponíveis e, assim, avaliar a capacidade de generalização de um modelo a partir de um conjunto de dados (KOHAVI, 1995). Assim, não é necessário separar amostras para fase de treinamento e teste. A validação cruzada consiste em dividir as amostras (P) em K subcon-

juntos mutuamente exclusivos (P_1, P_2, \dots, P_k) e de dimensões aproximadamente iguais (K -folds) (SANTOS et al., 2009).

Os modelos são executados K vezes pelo o algoritmo de classificação, então, os K subconjuntos restantes destinam-se à parte P para ser realizada a classificação. Ao final das K iterações calcula-se a acurácia ou erro final, a qual é dada pela média dos resultados das execuções. Pode-se utilizar valores de 2 a N para dividir os subconjuntos, mas o valor 10 é o mais utilizado (*Ten-Fold Cross-Validation*).

2.9 CONSIDERAÇÕES

Apresentou-se neste capítulo, conceitos de processamento de imagens, bem como as técnicas de manipulação dos *pixels* e extração de características de uma imagem. Também, verificou-se que o teste de tetrazólio vem se destacando por sua rapidez, precisão e a obtenção de grande número de informações fornecidas.

2.10 TRABALHO RELACIONADO

Pereira (2015) propõe a automatização do processo de definição de sementes de soja, diminuindo os problemas intrínsecos as mesmas. O qual serão aplicadas primeiramente técnicas de processamento de imagens com o intuito de pre-processar, segmentar e descrever as imagens de sementes para prover a posterior classificação automática das mesmas, segundo diferentes danos que estas podem sofrer, influenciando diretamente no vigor.

Desta forma o objetivo principal era o de prover um método em pipeline que reconhecesse uma imagem com semente de soja e identificá-las individualmente afim de poder em seguida classificá-las de maneira correta quanto ao tipo de dano que a semente contém. Um método em pipeline foi desenvolvido para a identificação e segmentação de sementes em uma imagem podendo ser avaliado não só com sementes de soja oriundas do teste de tetrazólio como também sementes de milho e imagens montadas manualmente.

Nesse trabalho também foram estudados classificadores supervisionados que puderam a partir de conjuntos de treinamentos, predizer as classes de conjuntos de testes de sementes para um estudo de quais extratores/classificadores melhores se ajustam ao processo de classificação automática das sementes de soja. Finalmente realizou-se uma análise sobre a representatividade das porções da imagem da semente em relação à imagem como um todo para avaliar se alguma determinada porção consegue ser mais descritiva que a imagem original da semente.

Para o presente trabalho, foram realizadas algumas alterações no *pipeline* proposta por (PEREIRA, 2015), com o objetivo de reduzir o custo computacional do dispositivo móvel adicionando mais uma etapa no processo de segmentação. Utilizou-se também, um conjunto de imagens (Dataset) maior para a realização da classificação.

3 MATERIAIS E MÉTODOS

No presente capítulo, serão descritos todos os materiais utilizados (software e hardware) e as etapas de pré-processamento e processamento com técnicas envolvidas para o desenvolvimento do trabalho.

3.1 DISPOSITIVO MÓVEL

Todos os testes foram realizados com o dispositivo celular Motorola modelo G2 (Figura 14), este dispositivo possui processador quadcore Qualcomm MSM8226 Snapdragon 400 de 1.2GHz de clock, 1GB de memória RAM, 8Gb de armazenamento interno e câmera de 8 megapixels. Como parâmetros de configuração para aquisição de imagens, utilizou-se a opção de captura com o flash desabilitado.



Figura 14: Dispositivo celular utilizado nos testes

Fonte: <http://gadgets.ndtv.com>

3.2 SOFTWARES UTILIZADOS

Após os estudos dos métodos de processamento de imagens, iniciou-se o desenvolvimento da aplicação móvel. Para a realização dos testes utilizou-se as seguintes ferramentas:

- biblioteca de visão computacional OpenCV (Open Source Computer Vision Library). Trata-se de uma biblioteca multi-plataforma que implementa diversos métodos de processamento de imagens e visão computacional, bem como apresenta o código fonte aberto. Foi desenvolvida com o intuito de proporcionar uma infraestrutura comum para aplicações de visão computacional. Contém mais de 2500 algoritmos otimizados;
- ambiente de desenvolvimento Android Studio. Fornece um ambiente de desenvolvimento integrado (IDE) para desenvolvedores de aplicativos móveis, possibilitando a criação de aplicações Java. Está disponível para Linux, MacOS X e sistemas operacionais Windows. Como requisito mínimo do dispositivo, é necessário possuir a versão JellyBean ou superior para a execução da aplicação;
- biblioteca de classificação WEKA (Wakaito Environment for Knowledge Analysis). Desenvolvido pela Universidade de Wakaito, na Nova Zelândia. Possui uma coleção de algoritmos para classificação e mineração de dados e foi desenvolvido em Java. É uma biblioteca Open-Source e tem como entrada o arquivo com a extensão *.arff* para realização da classificação.

3.3 DEFINIÇÃO DE CLASSIFICAÇÃO E CARACTERÍSTICAS

Como citado no capítulo 1 (Introdução) o objetivo do presente trabalho é a realização da identificação e descrição de sementes de soja, por meio de uma aplicação, baseando-se em técnicas de descrição e sua, posterior, classificação. Para isto, utilizou-se os conhecimentos teóricos para a implementação dos descritores de cor e textura.

Para a classificação utilizou-se um algoritmo denominado J48 baseado em decisão por árvores, um classificador que considera os K-vizinhos chamado IBk e o classificador bayesiano Naive Bayes.

3.4 BASE DE IMAGENS

Para a realização das etapas de pré-processamento, descrição e classificação, o conjunto de imagens de sementes de soja e, suas respectivas doenças, já foram previamente captura-

das (SANTANNA et al., 2009), utilizando um scanner de 600dpi de resolução e as representando-as por 8 bits por cor de profundidade no espaço de cor RGB com sementes de soja em solução de tetrazólio, metodologia descrita por Neto et al. (1998).

A base possui sementes separadas nas seguinte categorias, conforme exemplifica a Tabela 1 e suas quantidades na Tabela 2:

Tabela 1: Definição da base de imagem.

	Descrição	Valores
Nível	Valor numérico do dano	1 a 4
Tipo	Dano visível na semente	Umidade (u), Percevejo (p) ou Mecânico (m)
Localidade	Localização verificada do dano	Dentro (d) ou Fora (f)

A classificação do nível de vigor possui uma escala que varia de 1 (maior vigor) até 8 (sementes mortas), alguns exemplos destas rotulações podem ser observadas na Figura 15. Então, por exemplo, uma semente que possuir dano de nível dois causado por percevejo no lado externo, receberá a rotulação 2pf. As classes xd e xf são referentes às sementes que não possuem nenhum tipo de dano. A distribuição das classes das sementes pode ser vista na Tabela 2.

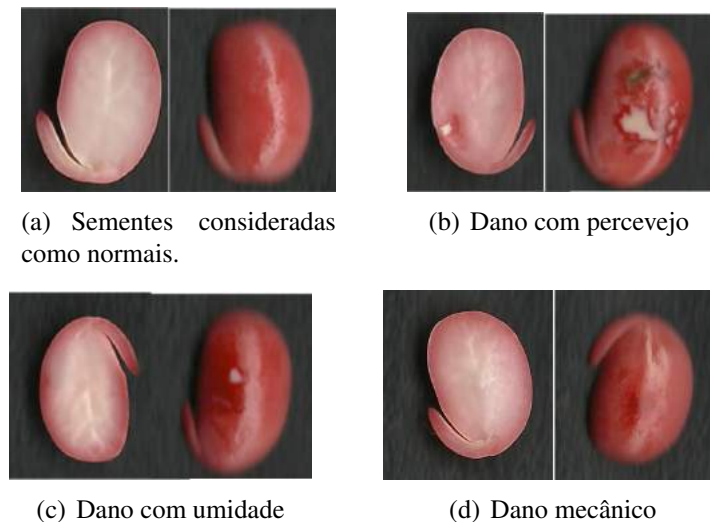


Figura 15: Tipo de classificação em sementes(Adaptado de (SANTANNA et al., 2009)).

Tabela 2: Classes de sementes da base.

Classe	Quantidade de sementes
2md	2
2mf	2
2pd	32
2pf	32
2uf	275
2ud	275
3md	23
3mf	23
3pd	326
3pf	252
3ud	241
3uf	241
4pd	175
4pf	175
4ud	21
4uf	21
xd	118
xf	118
Total	2352

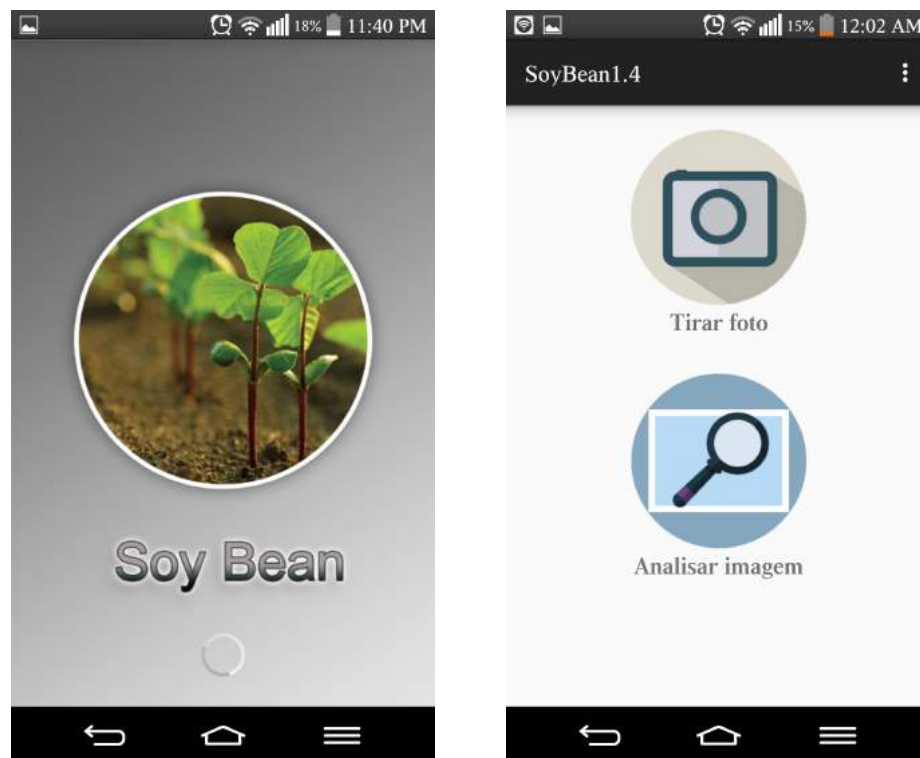
3.5 FUNCIONAMENTO DA APLICAÇÃO

3.5.1 INTERFACE

A ferramenta implementada nomeada de “SoyBean” possui uma interface simples para uma interação mais prática com o usuário (Figura 16). Ao inicializar a aplicação, automaticamente, sempre criará uma pasta padrão dentro do diretório de imagens do dispositivo denominada de “SoyBeanImages”, também, é necessário antes de realizar a classificação configurar todas as opções desejadas no botão menu e em “Configurações”.

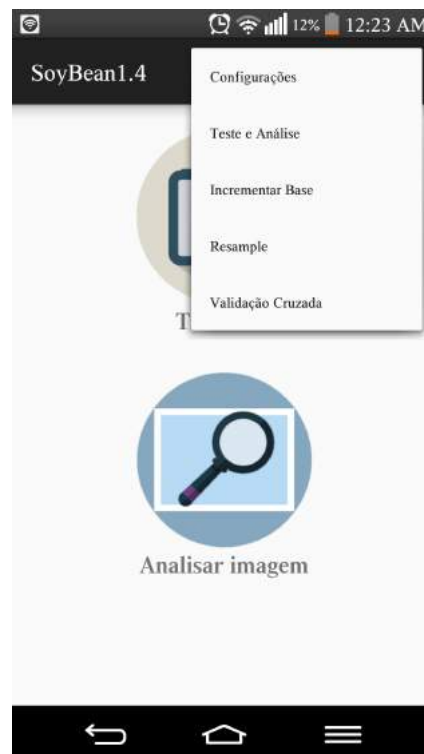
Conforme ilustra a Figura 16 (b), a aplicação possui dois botões na região central e um botão de opções no canto superior direito, denominado por três pontos em posição vertical. As funcionalidades dos botões são:

- **Tirar Foto:** realiza a aquisição da foto por meio da câmera do dispositivo. É importante observar que não há restrições quanto à capacidade de resolução da câmera, porém, ao utilizar uma câmera com resolução muito baixa o processo de segmentação poderá ficar comprometido. Realizada a captura, o aplicativo irá executar todo o processo de segmentação e descrição da imagem. Para finalizar, cria-se um arquivo *.arff* dentro do diretório do programa contendo os vetores de características;



(a) Tela de início

(b) Botões de análises



(c) Botões de Opções

Figura 16: Interface simples da aplicação**Fonte: Autoria própria.**

- **Analisar Imagem:** realiza o carregamento de uma imagem disponibilizada na memória do dispositivo para a aplicação, a imagem carregada poderá possuir a extensão *.jpg*, *.png*, *.tif* e *.tiff*. Após a seleção, realizará-se os processos de segmentação, descrição e finalizando com a criação de um arquivo *.arff* dentro do diretório do programa, contendo os vetores de características;

- **Opções** (Figura 17) possui os seguintes itens:

Configurações: abre uma nova tela onde é possível configurar a aplicação de acordo com as preferências do usuário, as quais serão exemplificadas posteriormente;

Teste e Análise: promove a classificação com base em uma entrada de teste (arquivo *.arff*) e de treinamento (arquivo base selecionado em Configurações). Cria-se este arquivo de treinamento quando o usuário conhece a doença das sementes e realiza somente a descrição da imagem desabilitando a opção de classificação, assim o aplicativo gerará somente o arquivo *.arff* como resultado. Por fim, cria-se um arquivo de texto dentro do diretório do programa contendo os resultados da classificação;

Incrementar Base: adiciona os vetores de características de um arquivo *.arff* de entrada com o arquivo base do sistema (arquivo selecionado em Configurações);

Resample: realiza o redimensionamento de uma imagem de entrada, o parâmetro pode ser configurado em Configurações, a imagem resultante será gerada no diretório da aplicação;

Validação Cruzada: realiza a classificação utilizando o método de validação cruzada, ao final do processo cria-se um arquivo de texto contendo os resultados da classificação na pasta do sistema.

Nas opções de configuração, como explicado anteriormente, configuram-se as definições utilizadas para as etapas de processamento da aplicação como apresentadas na Figura 17.

Nesta tela pode-se encontrar as seguintes opções:

- **Filtro Vermelho:** esta opção habilita ou desabilita um filtro utilizado em pré-processamento da imagem, onde realiza um incremento em tons de vermelho desta, devido ao fato de que a semente de soja aplicada ao corante de tetrazólio apresenta tons avermelhados, esta opção aprimora o reconhecimento da mesma;
- **Gerar imagem:** esta opção, se habilitada, gera as imagens da etapa de pré-processamento da semente, desta forma, incluem todas as máscaras geradas bem como cada semente identificada;

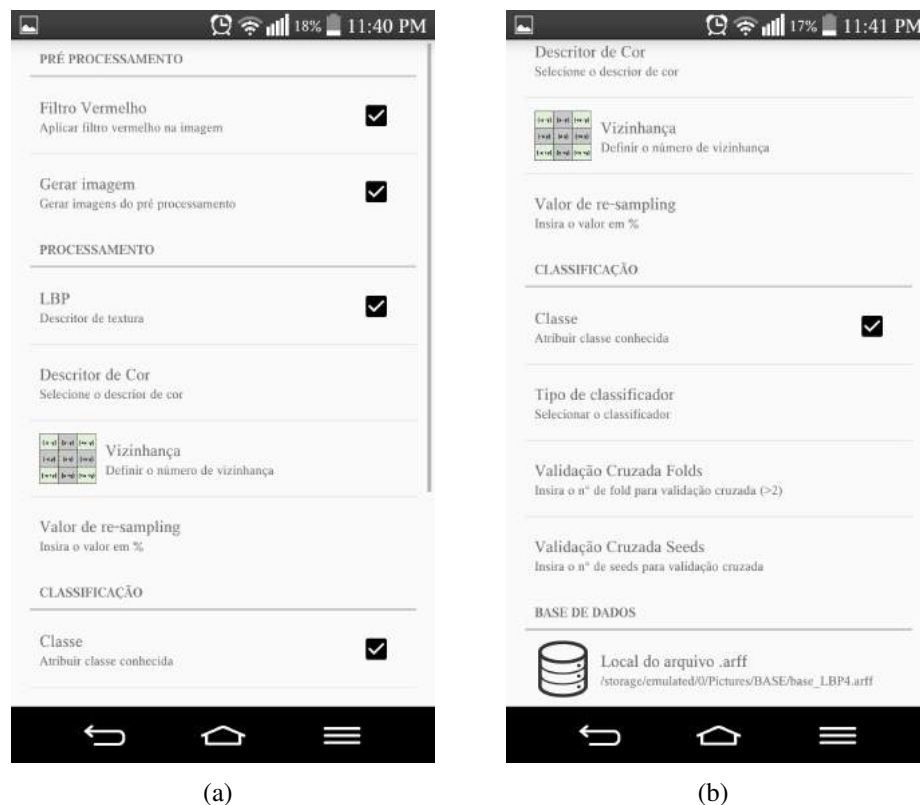


Figura 17: Opções de configurações.

Fonte: Autoria própria.

- **LBP:** habilita ou desabilita a descrição da imagem com o algoritmo LBP;
- **Descritor de Cor:** habilita ou desabilita a descrição da imagem com os algoritmos de cores BIC ou CGCH como ilustra a Figura 18;
- **Vizinhança:** nesta opção define-se a vizinhança utilizada pelo descritor LBP, podendo ser de valor 4 ou 8;
- **Valor de resampling:** define-se o valor de amostragem da uma imagem utilizando valores em porcentagem com base em uma imagem de entrada. Assim, a resolução também será afetada bem como o tamanho final;
- **Classe:** é possível definir a classe da semente após a etapa de pré-processamento, portanto, se o usuário conhecer a doença da semente, esta pode ser definida por ele. Esta opção, se habilitada, atribui estas novas características geradas pelo algoritmo de descrição à base de dados. É importante observar que se o usuário definir o rótulo errado, este irá ser escrito nos vetores de característica no arquivo *.arff*, prejudicando o processo de classificação posteriormente;



Figura 18: Opções de configurações de descritor de cor.

Fonte: Autoria própria.

- **Tipo de classificador:** abre-se uma caixa de seleção para a escolha do classificador (Figura 19). É possível escolher entre os classificadores IBk, J48 e Naive Bayes ou não classificar, caso o usuário queira apenas segmentar e extrair as características da imagem, gerando somente o arquivo .arff contendo os vetores de características das imagens;

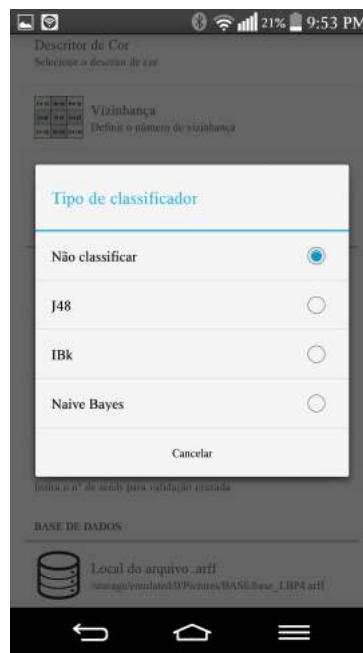


Figura 19: Opções de escolha entre classificadores.

Fonte: Autoria própria.

- **Validação Cruzada Folds:** seleciona a quantidade de Folds a ser utilizada durante a classificação por validação cruzada. Este parâmetro será utilizado pela função da biblioteca Weka, no qual, deverá ser maior que um e menor que a quantidade máxima de sementes da base de dados;
- **Validação Cruzada Seeds:** seleciona a quantidade de Seeds (para o processo de geração de números aleatórios) a serem utilizados durante a classificação por validação cruzada, utilizada pela função da biblioteca Weka. Este valor deverá ser maior que um;
- **Local de arquivo .arff.** Indica o local onde está a base de dados das sementes. Deverá ser um arquivo com a extensão *.arff*.

3.6 ETAPAS DE EXECUÇÃO

O diagrama, apresentado na Figura 20, ilustra a etapas de execução do aplicativo:

Passo 1: este passo consiste em carregar uma imagem para a memória do dispositivo. É importante observar que a imagem deverá conter formas elípticas, caso contrário, resultará em um erro e o aplicativo disparará uma exceção. Assim, pode-se fazer de duas maneiras como ilustradas na Figura 16:

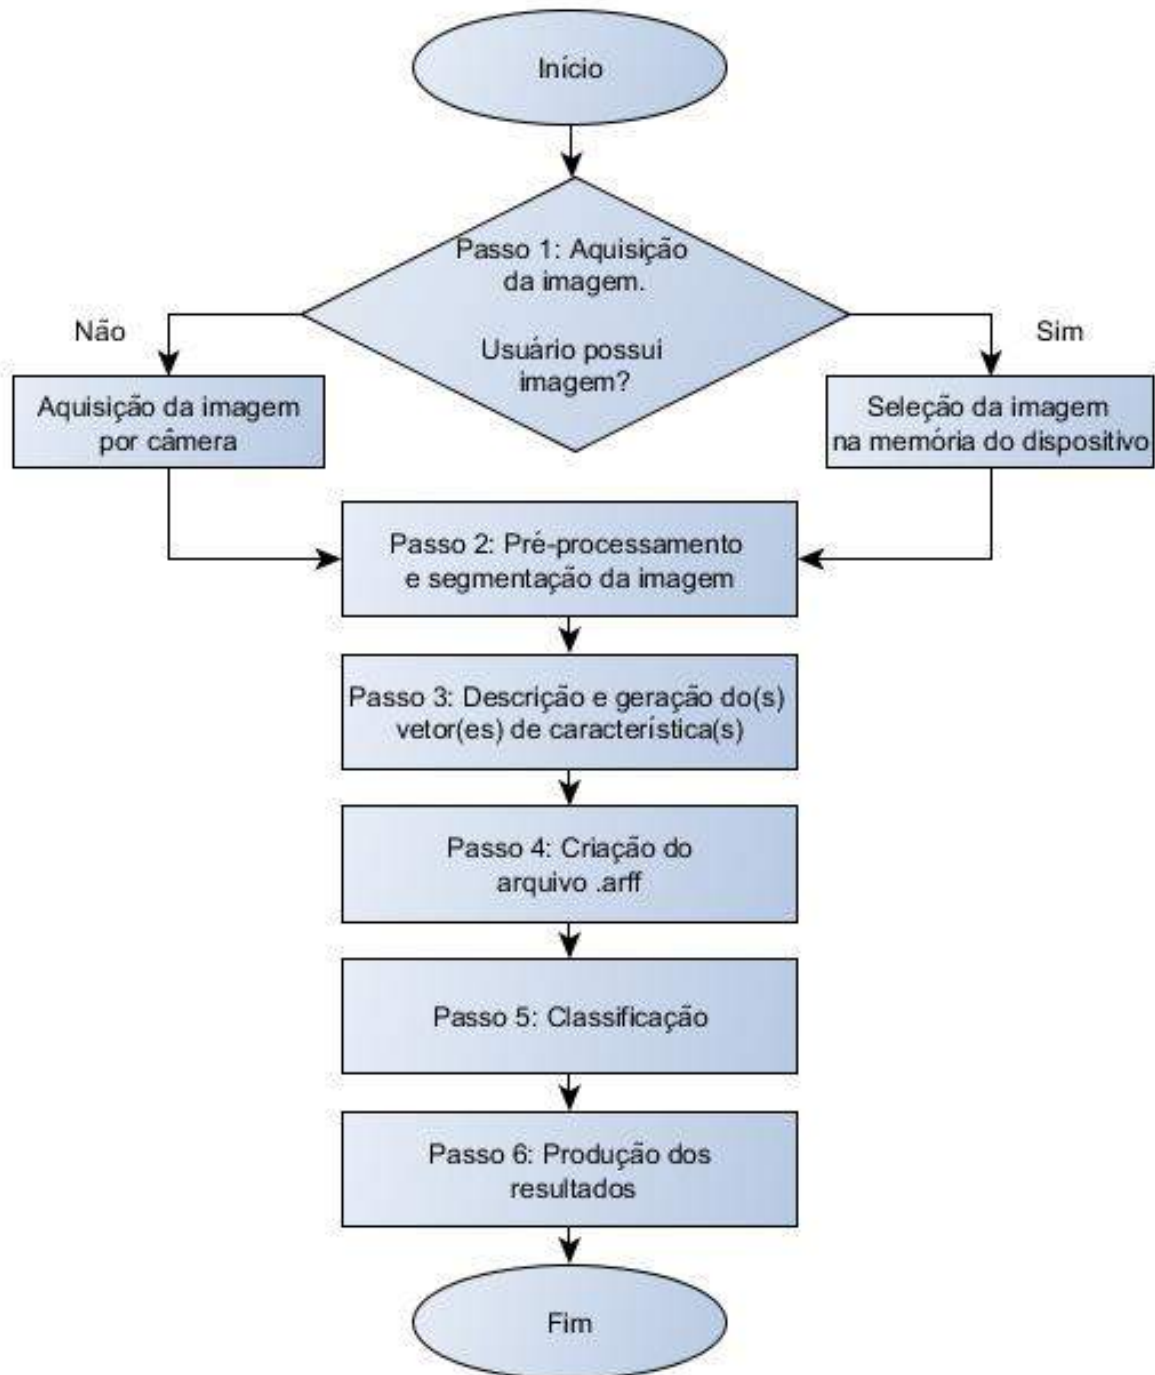


Figura 20: Etapas de processamento

Fonte: Autoria própria.

1. Por meio da câmera do dispositivo;
2. carregando uma imagem que se encontra no dispositivo, podendo ter a extensão *.jpg*, *.bmp*, *.png* ou *.tif*.

Passo 2: este passo de segmentação da imagem ocorre em subetapas conforme é apresentado a seguir:

1. Conversão do espaço de cores do canal RGB para o HSV, onde gera-se uma máscara (*mI*) a partir desta conversão utilizando somente o canal H, como mostra a Figura 21;




Figura 21: Passo 2.1

Fonte: Autoria própria.

2. Aplica-se a máscara (*mI*) na imagem original (*src*) e obtém-se uma resultante com poucos ruídos de fundo (Figura 22);



(a) Máscara *mI* aplicada à *src*

Figura 22: Passo 2.2

Fonte: Autoria própria.

3. A partir da imagem resultante utiliza-se o canal vermelho e acentua-se suas intensidades (se opção de Filtro Vermelho estiver habilitado em Configurações) separando os canais

da imagem, e, multiplicando cada intensidade dos pixels do canal vermelho por um valor numérico. Novamente gera-se uma máscara (m_2) resultante (Figura 23);



(a) Máscara do vermelho excessivo. (m_2)

Figura 23: Passo 2.3

Fonte: Autoria própria.

4. A partir da máscara m_2 aplica-se o processo de limiarização de OTSU, gerando uma máscara m_3 (Figura 24);




(a) Máscara otsu (m_3)

Figura 24: Passo 2.4

Fonte: Autoria própria.

5. Então, aplica-se o filtro da mediana com o tamanho de 25×25 sobre o resultado do processo anterior (m_3), o qual será m_4 (Figura 25);



(a) Aplicando mediana sobre a máscara $m4$

Figura 25: Passo 2.5

Fonte: Autoria própria.

6. Neste passo, aplica-se a máscara resultante do último passo ($m4$) na imagem original (src), como mostrado na Figura 26;



(a) Aplicando $m4$ sobre a imagem original src

Figura 26: Passo 2.6

Fonte: Autoria própria.

7. Com o fundo totalmente removido, restando apenas as sementes com suas formas elípticas, aplica-se o algoritmo *fitEllipse*, da biblioteca OpenCV, onde detecta-se os contornos por equações algébricas, criando uma elipse sobreposta à imagem da semente incluindo uma caixa circunscrevendo a elipse (*Bouding Box*);
8. Após a detecção de todos os contornos, segue-se as seguintes sub-etapas:
- (a) realiza rotações na imagem, onde é verificado o ângulo de inclinação do *boudingBox* da semente com o ângulo de orientação vertical, conforme descreve a Figura 27;




Figura 27: Aplicação do algoritmo de rotação.
Fonte: Adaptado de (PEREIRA, 2015)

(b) inverte a imagem nos eixos horizontal e vertical, pois é importante padronizar a orientação da semente. Para este processo aplica-se a função da biblioteca OpenCV, chamada de fecho convexo (*ConvexHull*), o qual cria traços lineares sobrepostos ao contorno da semente, com o intuito de detectar o maior defeito do fecho convexo (e.g. maior distância entre o contorno da semente e o contorno gerado pelo fecho convexo).

Assim, realiza-se o espelhamento orientado para o terceiro quadrante, onde houver maior distância entre um ponto do fecho convexo em relação a um ponto do contorno da semente. Isto possibilita encontrar o caulículo ou pedúnculo da semente, como exemplifica a Figura 28;




Figura 28: Aplicação do algoritmo de fecho convexo
Fonte: Adaptado de (PEREIRA, 2015)

Fonte: Autoria própria.

(c) recorta a imagem até a borda da semente.

O resultado de todas as etapas do pré-processamento pode ser visto na Figura 29.

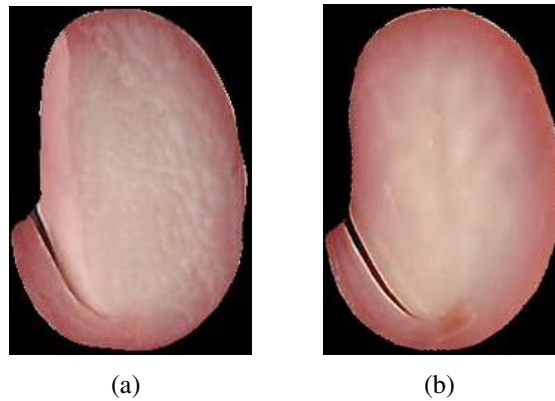


Figura 29: Passo 2.8: Resultado das sementes segmentadas desde o passo 2.

Fonte: Autoria própria.

Passo 3: esta aplicação permite a escolha do algoritmo de descrição da imagem, sendo eles um de textura (LBP) e dois de cores (BIC e CGCH). É possível escolher um ou dois ao mesmo tempo, porém a escolha deverá ser de tipos diferentes, o resultado deste processo é um vetor de características. Se escolher dois ocorrerá a concatenação dos vetores que cada um produz, onde adotou-se como o primeiro vetor, o descritor LBP. Observa-se que não é possível escolher dois descritores do mesmo tipo.

Passo 4: a partir de cada análise realizada, produz-se os vetores resultantes das sementes processadas e, então, gera-se um novo arquivo com a extensão .arff (arquivo de entrada para as funções do classificador Weka) onde o vetor de cada semente é escrito de forma sequencial neste arquivo.

Passo 5: como explicado anteriormente a aplicação, também, permite a escolha do classificador, sendo eles IBk, J48 e Naive Bayes. A classificação e predição são realizadas com base em um arquivo .arff onde deverá conter todas as classes distintas e descritas, conforme os algoritmos descritores desejados.

Passo 6: por fim, neste passo gera-se um arquivo de texto onde serão salvo todos os dados da classificação, bem como o valor de acurácia, a predição de cada semente e desvio padrão entre outros.

Os passos de pré-processamento são importantes pois a imagem capturada ou selecionada a partir do dispositivo conterá ruídos que dificultarão o processo de análise e extração de suas características. Estes ruídos se persistirem na imagem, poderão ser detectados como elipses pelo algoritmo de segmentação, gerando vetores de características muito discrepantes em relação às outras sementes identificadas. Assim o processo de classificação poderá ficar prejudicado.

4 RESULTADOS E DISCUSSÕES

O objetivo do presente trabalho foi o desenvolvimento de um software em um dado dispositivo móvel. Como visto na seção 1.1, o método de análise das sementes é visual, com base na percepção humana e suscetível a erros, variando ainda a opinião entre um analista e outro por ser um método subjetivo, assim, requer do analista de sementes conhecimento anatômico dessas, experiência e um nível de criteriosidade acurado.

Este capítulo está dividido em três cenários, o primeiro visou utilizar a câmera do dispositivo para a realização de teste do algoritmo de segmentação, verificando o desempenho sob baixa e alta iluminação do ambiente.

O segundo consistiu em analisar dados de acurácia considerando a base inteira, tempo de descrição e tempo de classificação considerando cada descritor. Para todos os teste, foram realização alterações no botão “Configurações” do programa. Ao final de cada experimento gerou-se um modelo de classificação que será considerado no teste seguinte e utilizado pelo aplicativo quando o usuário realizar uma análise de algum conjunto de sementes.

O terceiro teste utilizou uma amostra de um determinado dano da semente e o modelo (proveniente do teste dois) considerando cada classificador, para então realizar uma análise de classificação utilizando todos os descritores considerados no trabalho e obter a acurácia e o tempo.

4.1 CENÁRIO 1

Como descrito anteriormente utilizou-se a câmera do dispositivo, os testes referem-se a dois tipos de objetos fotografados. O primeiro com sementes de soja sem a adição de corante, colocadas em um fundo preto com boa iluminação e o segundo com os mesmos tipos de sementes sobre baixa luminosidade. A captura dos objetos foi realizada com a câmera do dispositivo à aproximadamente 20 centímetros de distância, com as sementes fixadas em uma cartolina de cor preta.

No primeiro teste, utilizando uma boa iluminação para captura da imagem e após a segmentação das sementes contidas na Figura 30(b) tem-se como resultado todas as sementes recortadas pelo algoritmo, nota-se que sob boa iluminação as bordas das sementes recortadas ficaram bem definidas, destacando alguns relevos e pontos da superfície e, também, preservando a tonalidade verdadeira de cor, como mostra a Figura 31. A boa iluminação foi obtida por meio de um pequeno estúdio de fotografia, desenvolvido por (SOARES, 2016).




Figura 30: Imagem de sementes de soja normais com boa iluminação, sendo (a) imagem original e (b) imagem segmentada.




Figura 31: Resultado da imagem capturada segmentada com sementes de soja.

A Figura 32 apresenta os resultados do segundo teste com sementes de soja em um ambiente pouco iluminado, considerando a luz ambiente.




Figura 32: Imagem de sementes de soja normais com baixa iluminação, sendo (a) imagem original e (b) imagem segmentada.

O algoritmo de segmentação obteve êxito ao identificar todas as 12 sementes diferentes da Figura 32, mesmo sob pouca iluminação do ambiente. O resultado é apresentado na Figura 33. Devido à baixa iluminação algumas sementes não tiveram as bordas bem definidas, apresentando pequenos ruídos e perdendo parte de suas características de textura. Devido à variação de iluminação, apresentaram uma tonalidade de coloração alterada em relação à imagem bem iluminada.



Figura 33: Resultado da imagem segmentada em ambiente pouco iluminado.

4.2 CENÁRIO 2

Três experimentos foram realizados, os quais são apresentados nas três subseções a seguir. Em cada um é estudado o comportamento de cada classificador, dos três considerados no trabalho (IBk, J48 e NaiveBayes), para cada descritor que foi utilizado.

Busca-se por meio dos experimentos escolher qual o descritor que promoveu a um dado classificador maior acurácia, levando em consideração o tempo total. Este tempo foi definido para verificar a viabilidade da aplicação. Como parâmetros da validação cruzada utilizou-se 10 fold (*Ten-Folds Cross Validation*) para a classificação da base contendo todas as sementes descritas na tabela 2 da seção 3.4.

Para o classificador J48, buscou-se analisar os valores considerando cada descritor e suas combinações, assim, tem-se o comportamento como ilustra a Tabela 3.

Observa-se que o descritor combinado LBP4 + CGCH promoveu o melhor valor de acurácia (36,35%), enquanto que, o BIC possui 1,32% de acurácia menor, porém, seu tempo corresponde a aproximadamente 64,35% menor em relação ao LBP4 + CGCH.

Os demais descritores LBP8 + BIC, CGCH, LBP8 possuem valores de acurácia menores quando comparados com o BIC, enquanto que, seus valores de tempo são maiores, tornando-os inviáveis. Os descritores LBP8 + CGCH também torna-se inviável por possuir um tempo bem elevado de classificação (3 horas e 33 minutos).

O descritor LBP4 possui o menor tempo, o que seria ideal, contudo, perde-se 6,25% de acurácia em relação ao BIC. Tanto o tempo quanto a acurácia são extremamente relevantes para uma aplicação móvel, visto que obviamente, não adianta fornecer um resultado rápido e incorreto. Busca-se a eficiência e eficácia dos métodos aplicados.

Portanto, com base na Tabela 3 define-se como o melhor descritor o BIC.

Tabela 3: Tabela comparativa de desempenho com classificador J48, onde T.D = tempo de descrição e T.C = tempo de classificação.

Descritor	Acurácia (%)	T.D	T.C	Tempo total
BIC	35,03	52m 52s	13m 21s	1h 6m 13s
CGCH	32,02	14m 5s	45m	59m 5s
LBP4	28,78	52m 20s	4m 25s	56m 45s
LBP8	28,06	1h 31m 34s	1h 41m 54s	3h 13m 28s
LBP4 + BIC	35,76	1h 41m 33s	13m 51s	1h 55m 24s
LBP4 + CGCH	36,35	58m 35s	44m 1s	1h 42m 36s
LBP8 + BIC	33,38	2h 21m 37s	1h 27m 30s	3h 49m 7s
LBP8 + CGCH	36,05	1h 27m 50s	2h 5m 45s	3h 33m 35s

O teste seguinte, analisou-se as acurácia do classificador IBk, a Tabela 4 mostra os resultados.

Observa-se que o descritor LBP8 promoveu o melhor valor de acurácia (38,22%). A diferença de acurácia entre o BIC e o LBP4 é de 1,22% para uma diferença de tempo total de aproximadamente 11 minutos. O LBP4 perde 5,86% de acurácia em relação ao LBP8, mas seu

tempo é menor em aproximadamente 3 horas.

Somente o descritor LBP4 promoveu um valor de tempo menor que uma hora, além do que alguns como o LBP4 + CGCH e o CGCH possuem valores de acurácia menores em relação ao LBP4.

Portanto, com base na Tabela 4 define-se como o melhor descritor o LBP4.

Tabela 4: Tabela comparativa de desempenho com classificador IBk, onde T.D = tempo de descrição e T.C = tempo de classificação.

Descritor	Acurácia (%)	T.D	T.C	Tempo total
BIC	33,58	52m 52s	18m 40s	1h 9m 38s
CGCH	31,76	14m 5s	1h 2m 56s	1h 17m 1s
LBP4	32,36	52m 19s	5m 57s	58m 16s
LBP8	38,22	1h 31m 34s	2h 22m 33s	3h 54m 7s
LBP4 + BIC	36,48	1h 41m 33s	19m 23s	2h 56s
LBP4 + CGCH	31,80	58m 35s	1h 1m 35s	2h 10s
LBP8 + BIC	36,18	2h 21m 37s	2h 2m 24s	4h 24m 1s
LBP8 + CGCH	35,16	1h 27m 50s	3h 6m 17s	4h 35m 67s

A Tabela 5 mostra os resultados obtidos pelo teste utilizando o classificador Naive Bayes.

Observa-se que o descritor combinado LBP8 + BIC promoveu o melhor valor de acurácia (37,67%). A diferença de acurácia entre o LBP4 é de 5,57% para um diferença de tempo de aproximadamente 2 horas.

Com exceção do LBP8 + BIC, LBP8 + CGCH e CGCH, os demais possuem valores de acurácia menores com valor de tempo maior em relação ao LBP4.

Portanto, com base na Tabela 5 define-se como o melhor descritor o LBP4.

Tabela 5: Tabela comparativa de desempenho com classificador Naive Bayes, onde T.D = tempo de descrição e T.C = tempo de classificação.

Descritor	Acurácia (%)	T.D	T.C	Tempo total
BIC	25,85	52m 52s	10m 8s	1h 3m
CGCH	24,11	14m 5s	14m 42s	28m 49s
LBP4	32,10	52m 19s	1m 7s	53m 26s
LBP8	30,32	1h 31m 34s	19m 38s	1h 51m 12s
LBP4 + BIC	25,47	1h 41m 33s	10m 59s	1h 52m 32s
LBP8 + BIC	37,67	2h 21m 37s	29m 32s	2h 51m 9s
LBP4 + CGCH	30,28	58m 35s	15m 57s	1h 14m 32s
LBP8 + CGCH	32,44	1h 27m 50s	34m 9s	2h 4m 59s

Com base nos resultados obtidos por meio das tabelas 3-5 anteriores tem-se a Tabela

6. Observa-se que o classificador Naive Bayes promove o menor valor de tempo total com uma acurácia mediana em relação ao demais. Possui uma redução de 2,93% de acurácia em relação ao J48, o qual torna-se um valor considerável, portanto, como visto na tabela, os tempos totais são próximos e o descritor BIC combinando com o classificador J48 resultou nos melhores parâmetros a serem utilizados pelo usuário real.

Tabela 6: Tabela comparativa de desempenho entre os classificadores escolhidos em cada experimento, onde T.D = tempo de descrição e T.C = tempo de classificação.

Classificador	Descritor	Acurácia (%)	T.D	T.C	Tempo total
J48	BIC	35,03	52m 52s	13m 21s	1h 6m 13s
NaiveBayes	LBP4	32,10	52m 19s	1m 7s	53m 26s
IBk	LBP4	32,36	52m 19s	5m 57s	58m 16s

Analisando o desempenho de tempo e acurácia dos três classificadores e com base nos resultados obtidos das tabelas anteriores, apresenta-se uma visão geral entre as médias de acurácia e as médias de tempo por classificador considerando todos os descritores e suas combinações, ilustrado na Figura 34:




Figura 34: Resultados das médias de acurácia e de tempo, classificando pelo método *cross-validation* considerando a base inteira.

Pode-se verificar que, o classificador IBk obteve melhores resultados em média para a acurácia, porém, levou mais tempo em relação aos demais. Assim, neste caso, o classificador Naive Bayes realizou a classificação mais rápida, mas isto afetou negativamente em relação à acurácia, tendo uma significativa queda em relação ao classificador IBk.

A respeito dos tempos de análises de cada algoritmo descritor, o CGCH possui os melhores resultados no quesito tempo, em contrapartida, os descritores BIC e LBP levaram um tempo maior em relação a ele, isto explica-se pela forma de implementação e a complexidade de processamento de cada algoritmo.

Analisando os dados de cada tempo de classificação, o motivo deste tempo variar significativamente entre cada descritor está relacionado ao tamanho do vetor. Assim, o algoritmo

que possuir um tamanho reduzido do vetor de características, realizará a classificação em menor tempo. A tabela 7 informa o tamanho de todos os descritores.

Tabela 7: Tabela comparativa de tamanho de vetor de características.

Descritor	Tamanho
LBP4	16
BIC	128
CGCH	192
LBP4 + BIC	144
LBP4 + CGCH	208
LBP8	256
LBP8 + BIC	384
LBP8 + CGCH	448

4.3 CENÁRIO 3

Mais três experimentos foram realizados. Para cada um, estuda-se o comportamento de acurácia e tempo de cada classificador com todas as combinações de descritores.

Retirou-se uma amostra de sementes da base (duas lâminas de imagens), contendo juntas 127 sementes do tipo de dano 3pd, essa amostra foi escolhida pelo fato de ser o tipo de semente que está disponível em maior quantidade na base. Sendo assim, para este teste realizou-se a classificação da base sem esta amostra de sementes e, posteriormente gerou-se um modelo de dados resultantes da classificação de cada classificador. Finalmente, analisou-se as acurácias e tempos de uma nova classificação entre a amostra e o modelo de dados.

O seguinte experimento visa analisar o comportamento do classificador J48, o resultado apresenta-se a seguir na Tabela 8.

Observa-se que o descritor BIC promoveu o melhor resultado (30,71%) e como não houve a necessidade de gerar um modelo de classificação, o tempo total para análise das sementes da amostra foi aceitável (4 minutos e 26 segundos).

Contudo, o descritor mais rápido foi o LBP4 com apenas 3 minutos e 12 segundos, porém, promoveu um resultado de 2,36% menor em relação ao descritor BIC. Assim, define-se como o melhor descritor para este experimento o BIC.

Tabela 8: Tabela comparativa de desempenho entre os classificadores escolhidos em cada experimento, onde T.D = tempo de descrição e T.C = tempo de classificação (J48).

Descritor	Acurácia(%)	T.D	T.C	Tempo total
BIC	30,71	2m 51s	1m 35s	4m 26s
CGCH	23,62	46s	4m 7s	4m 53s
LBP4	28,35	2m 49s	23s	3m 12s
LBP8	19,69	4m 56s	7m 36s	12m 32s
LBP4 + BIC	29,92	5m 29s	1m 48s	7m 17s
LBP8 + CGCH	29,13	4m 44s	11m 15s	15m 59s
LBP8 + BIC	19,69	7m 39s	8m 9s	15m 48s
LBP4 + CGCH	26,77	3m 9s	4m 7s	7m 16s

Analisando o comportamento do classificador IBk (Tabela 9), observa-se que o descritor que realizou a análise em menor tempo foi novamente o CGCH com apenas 1 minuto e 24 segundos de análise, porém promoveu um resultado de 9,45% menor em relação ao descritor LBP8 + BIC, diferença considerada alta.

O LBP4 + BIC realiza a análise em 5 minutos e 58 segundos com uma acurácia de 35,20%. Comparando-o com o LBP8 + BIC, observa-se uma diferença de 1,02% com uma diferença de tempo considerável. Assim, define-se como o melhor descritor para este experimento o LBP4 + BIC.

Tabela 9: Tabela comparativa de desempenho entre os classificadores escolhidos em cada experimento, onde T.D = tempo de descrição e T.C = tempo de classificação (IBk).

Descritor	Acurácia (%)	T.D	T.C	Tempo total
BIC	24,91	2m 51s	26s	3m 17s
CGCH	26,77	46s	38s	1m 24s
LBP4	28,35	2m 49s	5s	2m 54s
LBP8	33,07	4m 56s	1m 48s	6m 44s
LBP4 + BIC	35,20	5m 29s	29s	5m 58s
LBP4 + CGCH	28,35	3m 9s	42s	3m 51s
LBP8 + BIC	36,22	7m 39s	2m 22s	10m 1s
LBP8 + CGCH	27,56	4m 44s	2m 38s	7m 32s

Este último experimento analisa o comportamento do classificador Naive Bayes, apresentado na Tabela 10. Verifica-se que o descritor LBP8 + BIC promoveu o melhor resultado (23,62%), e o tempo total de análise de 8 minutos e 38 segundos. O descritor que realizou a análise em menor tempo foi o CGCH com apenas 1 minuto e 13 segundos de análise, que em contrapartida, promoveu um resultado de 8,03% menor em relação ao descritor LBP8 + BIC.

O LBP8 + CGCH possui 0,79% de acurácia menor em relação ao LBP8 + BIC para uma diferença de tempo de aproximadamente 3 minutos, portanto, define-se como o melhor o

LBP8 + CGCH para este experimento.

Tabela 10: Tabela comparativa de desempenho entre os classificadores escolhidos em cada experimento, onde T.D = tempo de descrição e T.C = tempo de classificação (Naive Bayes).

Descriptor	Acurácia (%)	T.D	T.C	Tempo total
BIC	9,44	2m 51s	19s	3m 10s
CGCH	15,59	46s	27s	1m 13s
LBP4	15,75	2m 49s	2s	2m 51s
LBP8	17,32	4m 56s	38s	5m 34s
LBP4 + BIC	11,81	5m 29s	21s	5m 50s
LBP4 + CGCH	15,75	3m 9s	29s	3m 38s
LBP8 + BIC	23,62	7m39s	59s	8m 38s
LBP8 + CGCH	22,83	4m 44s	1m 5s	5m 49s

Com base nos resultados obtidos por meio das três tabelas anteriores tem-se a Tabela 11. Observa-se que o IBk promove o maior valor de acurácia em relação ao demais. Portanto, define-se este classificador com o descriptor LBP4 + BIC o melhor para este experimento.

Tabela 11: Tabela comparativa de desempenho entre os classificadores escolhidos nos experimentos 3, onde T.D = tempo de descrição e T.C = tempo de classificação.

Classificador	Descriptor	Acurácia (%)	T.D	T.C	Tempo total
J48	BIC	30,71	2m 51s	1m 35s	4m 26s
IBk	LBP4 + BIC	35,20	5m 29s	29s	5m 58s
Naive Bayes	LBP8 + CGCH	22,83	4m 44s	1m 5s	5m 49s

Avaliando para este experimento, apresenta-se a seguir (Figura 35) uma visão geral do desempenho entre classificadores, realizando uma comparação entre as médias de acurácias, bem como os tempos médios de classificação.




Figura 35: Resultados das médias de acurácia e de tempo, classificando uma lâmina.

Verifica-se que o classificador IBk proporciona a melhor média de classificação em relação aos demais, resultados que foram comprovados pelas análises do experimentos realizados. Assim, novamente o classificador Naive Bayes apresentou baixos resultados.

Analisando o tempo, o classificador Naive Bayes leva vantagens realizando a classificação significativamente mais rápido em relação aos demais. Em contrapartida o classificador J48 realiza a análise levando um tempo muito maior, podendo tornar inviável se utilizar uma quantidade de amostra maior para teste ou uma base dados maior.

4.4 CONSIDERAÇÕES

Apresentou-se neste capítulo, os testes realizados em três cenários. Em relação aos testes do cenário um, obteve-se êxito tanto em boa iluminação quanto em ambiente. Em relação aos resultados dos demais cenários, é interessante ressaltar que o cenário 2 proporciona resultados de classificações em relação à base como um todo, e, os resultados do cenário 3 para classificação de apenas uma amostra extraída da base de 127 sementes.

5 CONSIDERAÇÕES FINAIS

Apresentou-se neste trabalho a implementação de um aplicativo móvel, baseado em processamento de imagens, o qual auxilia a classificação no vigor de sementes de soja. Todas as técnicas citadas em fundamentação foram implementadas com sucesso, permitindo assim a melhor escolha entre os classificadores e descritores.

Verificou-se que os métodos de pré-processamento obtiveram êxito ao utilizar a câmera do dispositivo, assim, tanto em boa quanto em baixa iluminação, as sementes de soja puderam ser segmentadas com precisão. Por outro lado, realizar a aquisição da imagem com baixa iluminação, provoca uma queda significativa em relação à qualidade final de cada imagem gerada, como vistos nos experimentos, produzindo ruídos e coloração alterada. Assim, ao processar e descrever a imagem com baixa qualidade, afetaria de forma significativa o resultado da classificação.

É importante ressaltar, que para os experimentos realizados, visou-se a melhor performance no quesito acurácia e tempo dos descritores e para os classificadores. Porém, para a realização de testes e, se de fato for utilizado por um usuário real, é necessário que tanto para classificação da base quanto para uma amostra padronize-se somente um tipo de descritor e classificador para não gerar incompatibilidades dos vetores de características.

Assim, observou-se neste trabalho, que para os experimentos do cenário dois, o descritor BIC combinado com o classificador J48 foram definidos como os melhores parâmetros. E para o cenário três o descritor LBP4 + BIC atrelado ao classificador IBk promoveram os melhores desempenhos, definido como o melhor parâmetro para o experimento.

Analisando o comportamento do classificador IBk, este forneceu as melhores acurácias, tanto para o método de validação cruzada quanto para a classificação de uma amostra da base. Verificando o tempo, este classificador demorou mais em relação aos demais para realizar o método de validação cruzada. Quanto à classificação de uma amostra, este tempo foi significativamente menor em relação ao tempo do classificador J48.

Em relação às baixas acurácias atingidas pelos classificadores, pode-se elencar como

possível causador o alto desbalanceamento da base de imagens, como pôde ser observado na tabela 2. Para sanar tal problema seria interessante a aplicação de processos de balanceamento antes do processo de classificação, incluindo mais amostras de algumas classes.

Tratando-se do tempo de processamento os mesmos foram elevados, porém uma possibilidade de diminuição dos mesmos seria a análise do custo benefício entre realizar processos de reamostragem e requantização nas imagens de entrada, diminuindo assim o custo de processamento, obviamente, visando ainda uma correta segmentação, bem como alta acurácia. Além disso, os tempos de processamento obtidos referem-se à base como um todo, processo esse que pode ser executado de maneira offline.

5.1 TRABALHOS FUTUROS

Levando-se em consideração por esta aplicação estar voltada à dispositivos móveis, como sugestão para trabalhos futuros, poderá-se implementar:

- Outros descritores de cores e texturas com complexidade de $O(n)$ e outros classificadores;
- Realização de teste em uma base totalmente balanceada, assim, a distribuição das características da base tornaria-se uniforme e a classificação poderia promover maior precisão. Tal processo pode ser realizado, por exemplo, por meio de algoritmos de oversampling;
- Implementação de novos métodos de pré-processamento para segmentar outros tipos de culturas;
- Desenvolvimento de um *web-service*, onde o usuário poderá somente adquirir a imagem capturada pelo dispositivo, e posteriormente o aplicativo enviá-la para um servidor remoto para o processamento, retornando assim, os resultados da classificação.
- Estudo de métodos de fusão de informação na utilização de diferentes dispositivos móveis para a captura de diferentes imagens.

REFERÊNCIAS

- ACHARYA, T.; RAY, A. K. **Image Enhancement and Restoration**. [S.l.]: John Wiley & Sons, Inc., 2005.
- AHA, D.; KIBLER, D. **Instance-based learning algorithms**. **Machine Learning**. 1991. Machine Learning.
- BISHOP, C. M. **Pattern Recognition and Machine Learning**. [S.l.]: Springer-Verlag New York, 2006.
- CASTLEMAN, K. R. **Digital Image Processing**. 1^o. ed. [S.l.]: Prentice Hall, 1995.
- FILHO, O. M.; NETO, H. V. **Processamento Digital de Imagens**. [S.l.]: Rio de Janeiro, 1999.
- GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**. [S.l.]: Tom Robbins, 2001.
- HUGHES, J. F. et al. **Computer Graphics - Principles and Practice**. [S.l.]: Addison-Wesley, 1990.
- JAIN, A. K. **Fundamentals of Digital Image Processing**. [S.l.]: Prentice Hall, 1989.
- KOHAVI, R. A study of cross validation and bootstrap for accuracy estimation and model selection. **International Joint Conference on Artificial Intelligence**, 1995.
- LEITE, G. C. et al. A utilização de técnicas de limiarização para auxílio no diagnóstico de câncer de mama. **ENEBI**, 2011.
- MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO. **Regras para Análise de Sementes**. 2009. Disponível em: <http://www.agricultura.gov.br/arq_editor/file/2946_regras_analise_sementes.pdf>.
- NETO, J. F.; KRZYANOWSKI, F. C.; COSTA, N. P. da. **O teste de tetrazólio em sementes de soja**. [S.l.]: Embrapa, 1998.
- OJALA, T.; PIETIKAINEN, M.; HARWOOD, D. **Métodos de processamento de imagens aplicados a classificação automática de sementes de soja**. 1996. A comparative study of texture measures with classification based on featured distributions. **Pattern recognition**.
- PEREIRA, D. F. **Métodos de processamento de imagens aplicados a classificação automática de sementes de soja**. 2015. Trabalho de conclusão de curso.
- PINHO, D. S. Adequação da metodologia do teste de tetrazólio para a avaliação da viabilidade de sementes de angico. **Pesquisa Florestal Brasileira**, 2011.
- SANTANNA, M. G. F.; SAITO, P. T. M.; BUGATTI, P. H. Content-based image retrieval towards the automatic characterization of soybean seed vigor. In: . [S.l.: s.n.], 2009. p. 964–969.

SANTOS, J. A. dos; PENATTI, O. A. B.; TORRES, R. da S. Evaluating the potential of texture and color descriptors for remote sensing image retrieval and classification. **Instituto de Computação, Universidade Estadual de Campinas**, 2009.

SHAPIRO, L. G.; STOCKMAN, G. **Computer Vision**. [S.l.]: Prentice Hall, 2001.

SOARES, R. C. **Estudo da Visão Computacional aplicado à Urinálise**. 2016. Trabalho de conclusão de curso.

SOUTO, R. P. **Segmentação de imagem multiespectral utilizando-se o atributo matiz**. Dissertação (Mestrado) — INPE - São José dos Campos, 2000.

STEHLING, R. de O.; NASCIMENTO, M. A.; FALCÃO, A. X. A compact and efficient image retrieval approach based on border/interior pixel classification. **Proceedings of the International Conference on Information and Knowledge Engineering**, 2002.

SWAIN, M. J.; BALLARD, D. H. Indexing via color histogram. **International Journal of Computer Vision**, 1991.

TAKALA, V.; AHONEN, T.; PIETIKAINEN. Block-based methods for image retrieval using local binary patterns. **In Scandinavian Conference on Image Analysis (SCIA)**, 2005.

TORRES, R. da S.; MORENO, M. A. M. Recuperação de imagem utilizando descritores baseados em esqueletos. **Instituto de Computação, Universidade Estadual de Campinas**, 2008.