

O palmito é um alimento fornecido por diversas espécies de palmáceas produtoras através do extrativismo e cultivo, sendo a pupunha (*Bactris gasipaes*) uma alternativa sustentável. O objetivo deste trabalho é facilitar a classificação de mudas de pupunha com auxílio das técnicas de visão computacional. Para a classificação entre mudas de pupunha saudáveis/doentes o descritor *Color Structure Descriptor* (CSD) responsável pela captura da estrutura espacial das cores na imagem, combinado com o classificador *Support Vector Machine* (SVM) obteve 100% de acertos na classificação. Para os testes em mudas de pupunha com/sem espinhos no caule, o descritor de cor CSD combinado com SVM e com a alteração no brilho e contraste da imagem e aplicação do filtro Laplaciano atingiu 96,86% de acertos na classificação com desvio padrão de 5,73. Para os testes em mudas saudáveis/mortas a combinação do descritor CSD com SVM, obteve 100% de acertos na classificação. A classificação das mudas pequenas/grandes com a utilização do descritor SCD e SVM obteve 97,8% de acertos com desvio padrão de 5,04. Os resultados revelam a viabilidade da aplicação em um viveiro de mudas.

Orientador: André Tavares da Silva

Joinville, 2018

ANO  
2018



UNIVERSIDADE DO ESTADO DE SANTA CATARINA – UDESC  
CENTRO DE CIÊNCIAS TECNOLÓGICAS - CCT  
PROGRAMA DE PÓS GRADUAÇÃO EM COMPUTAÇÃO APLICADA

MARCO AURELIO PELLENS | ANÁLISE DE MUDAS DE PUPUNHA POR  
RECONHECIMENTO DE PADRÕES

DISSERTAÇÃO DE MESTRADO

**ANÁLISE DE MUDAS DE PUPUNHA  
POR RECONHECIMENTO DE  
PADRÕES**

MARCO AURELIO PELLENS

JOINVILLE, 2018

**MARCO AURELIO PELLENS**

**ANÁLISE DE MUDAS DE PUPUNHA POR RECONHECIMENTO DE PADRÕES**

Dissertação submetida ao Programa de Pós-Graduação em Computação Aplicada do Centro de Ciências Tecnológicas da Universidade do Estado de Santa Catarina, como requisito parcial para obtenção do grau de Mestre em Computação Aplicada.

Orientador: Prof. Dr. André Tavares da Silva

**JOINVILLE**

**2018**

Pellens, Marco Aurelio  
Análise de mudas de pupunha por reconhecimento  
de padrões / Marco Aurelio Pellens. - Joinville ,  
2018.

69 p.

Orientador: André Tavares da Silva  
Dissertação (Mestrado) – Universidade do Estado de  
Santa Catarina, Centro de Ciências Tecnológicas,  
Programa de Pós-Graduação em Computação Aplicada,  
Joinville, 2018.

1. Visão Computacional. 2. Agricultura. 3.  
Reconhecimento de Padrões. 4. Pupunha. 5.  
Descritores de Imagem. I. da Silva, André Tavares.  
II. Universidade do Estado de Santa Catarina.  
Programa de Pós-Graduação. III. Título.

**Análise Automática de Mudas de Pupunha por Reconhecimento de Padrões**

por

**Marco Aurelio Pellens**

Esta dissertação foi julgada adequada para obtenção do título de

**Mestre em Computação Aplicada**

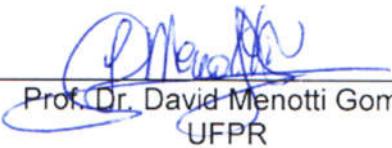
Área de concentração em "Ciência da Computação",  
e aprovada em sua forma final pelo

CURSO DE MESTRADO ACADÊMICO EM COMPUTAÇÃO APLICADA  
DO CENTRO DE CIÊNCIAS TECNOLÓGICAS DA  
UNIVERSIDADE DO ESTADO DE SANTA CATARINA.

Banca Examinadora:

  
Prof. Dr. André Tavares da Silva  
CCT/UDESC (Orientador/Presidente)

  
Prof. Dr. Marcelo da Silva Hounsell  
CCT/UDESC

  
Prof. Dr. David Menotti Gomes  
UFPR

Joinville, SC, 28 de setembro de 2018.

## RESUMO

O palmito é um alimento fornecido por diversas espécies de palmáceas através do extrativismo e cultivo, sendo a pupunha (*Bactris gasipaes*) uma alternativa sustentável. Um processo de fabricação de mudas de pupunha envolve a seleção das mudas em condições de tamanho e fitossanidade para o plantio no campo. O processo de inspeção pode ser melhorado com a utilização de visão computacional. O objetivo deste trabalho é facilitar a classificação de mudas de pupunha com auxílio das técnicas de visão computacional. Uma base de imagens de mudas de pupunha foi criada com as classes: mudas saudáveis, doentes, com espinho no caule, sem espinho no caule, mortas, pequenas e grandes. O Mapeamento Sistemático da Literatura fornece uma síntese do estado da arte da área com as técnicas utilizadas, combinadas com os melhores resultados alcançados em trabalhos similares. Após o estudo dos trabalhos relacionados foram executados testes para determinar a melhor combinação entre descritores de imagem para extrair as características das imagens; e classificadores. Para a classificação entre mudas de pupunha saudáveis/doentes o descritor *Color Structure Descriptor* (CSD), responsável pela captura da estrutura espacial das cores na imagem, combinado com o classificador *Support Vector Machine* (SVM) obteve 100% de acertos na classificação. Para os testes em mudas de pupunha com/sem espinhos no caule, o descritor de cor CSD combinado com SVM e com a alteração no brilho e contraste da imagem e aplicação do filtro Laplaciano atingiu 96,86% de acertos na classificação com desvio padrão de 5,73. Para os testes em mudas saudáveis/mortas a combinação do descritor CSD com SVM, obteve 100% de acertos na classificação. A classificação das mudas pequenas/grandes com a utilização do descritor SCD e SVM obteve 97,8% de acertos com desvio padrão de 5,04. Os resultados revelam a viabilidade da aplicação em um viveiro de mudas.

**Palavras-chave:** Visão Computacional 1. Agricultura 2. Reconhecimento de Padrões 3. Pupunha 4. Descritores de Imagem 5.

## ***ABSTRACT***

*The palm heart is a food supplied by several species of palm tree through the extractivism and cultivation, being the pupunha (*Bactris gasipaes*) a sustainable alternative. A process of production of pupunha seedlings involves the selection of seedlings under conditions of size and phytosanitary for planting in the field. The inspection process can be improved with the use of computer vision. The objective of this work is to facilitate the classification of pupunha seedlings with the help of computer vision techniques. A base of images of pupunha seedlings was created with the classes: healthy, diseased seedlings, with thorn in the stem, without spine in the stem, dead, small and large. Systematic Literature Mapping provides a synthesis of the state of the art of the area with the techniques used, combined with the best results achieved in similar works. After the study of the related works, tests were carried out to determine the best combination of image descriptors to extract the characteristics of the images; and classifiers. For the classification between healthy / diseased pupunha seedlings, the descriptor Color Structure Descriptor (CSD) responsible for capturing the spatial structure of colors in the image, combined with the Support Vector Machine classifier (SVM) obtained 100% correctness in the classification. For the tests on pupunha seedlings with / without spines in the stem, the CSD color descriptor combined with SVM and with the change in the brightness and contrast of the image and application of the Laplacian filter reached 96.86% of correct answers in the classification with standard deviation of 5.73. For the tests in healthy / dead seedlings the combination of the CSD descriptor with SVM obtained 100% correct answers in the classification. The classification of the small / large seedlings using the SCD and SVM descriptor obtained 97.8% of hits with a standard deviation of 5.04. The results reveal the viability of the application in a seedling nursery.*

***Keywords:*** Computer Vision 1. Agriculture 2. Pattern Recognition 3. Pupunha 4. Image Descriptors 5

## LISTA DE ILUSTRAÇÕES

FIGURA 1 – PALMITO PROCESSADO PARA COMERCIALIZAÇÃO EM CONSERVAS .....	12
FIGURA 2 – CULTIVO DE PUPUNHA PARA PRODUÇÃO DE PALMITO .....	12
FIGURA 3 – EXEMPLO DE ESTADO SANITÁRIO DE MUDAS DE PUPUNHA: A) SAUDÁVEL/ B) DOENTE .....	14
FIGURA 4 – EXEMPLO DE TAMANHO DE MUDA: A) GRANDE/ B) PEQUENA.....	14
FIGURA 5 – EXEMPLO DE VARIEDADE DE MUDA: A) COM/ B) SEM ESPINHOS NO CAULE.....	15
FIGURA 6 – EXEMPLO DE UMA MUDA DE PUPUNHA MORTA .....	15
FIGURA 7 – DIAGRAMA DO SISTEMA DE CLASSIFICAÇÃO: FUNÇÕES DISCRIMINANTES $F(X,K)$ REALIZAM ALGUMA COMPUTAÇÃO NO VETOR DE CARACTERÍSTICAS DE ENTRADA X USANDO ALGUM CONHECIMENTO K PARA TREINAR E PASSAR RESULTADOS PARA UM ESTÁGIO FINAL QUE DETERMINA A CLASSE. ....	20
FIGURA 8 – ELEMENTOS ESTRUTURANTES PARA IMAGENS COM DIFERENTES RESOLUÇÕES: A) $320 \times 240$ E B) $640 \times 480$ PIXELS .....	24
FIGURA 9 – EXEMPLO DE FUNCIONAMENTO DO CSD: A) IMAGEM DE FOLHA COM DOENÇA; B) ELEMENTO ESTRUTURANTE; C) RESULTADO DE QUANTIFICAÇÃO DE COR.....	24
FIGURA 10 – HIPERPLANOS DE SEPARAÇÃO LINEAR. VETORES DE SUPORTE CIRCULADOS .....	30
FIGURA 11 – HIPERPLANOS DE SEPARAÇÃO LINEAR PARA CASOS NÃO SEPARÁVEIS.....	31
FIGURA 12 – A) CONJUNTO DE DADOS NÃO LINEAR NO ESPAÇO 2-D; B) FRONTEIRA NÃO LINEAR NO ESPAÇO DE ENTRADA; C) DADOS PROJETADOS DO ESPAÇO 2-D PARA UM ESPAÇO 3-D, PRODUZINDO UMA FRONTEIRA COM SEPARAÇÃO LINEAR.....	31
FIGURA 13 – MODELO NÃO-LINEAR DE UM NEURÔNIO .....	32
FIGURA 14 – REDE ACÍCLICA COM UMA ÚNICA CAMADA DE NEURÔNIOS .....	33
FIGURA 15 – REDE ACÍCLICA TOTALMENTE CONECTADA COM UMA CAMADA OCULTA E UMA CAMADA DE SAÍDA .....	34
FIGURA 16 – REDE RECORRENTE COM NEURÔNIOS OCULTOS .....	35
FIGURA 17 – RESULTADO DO MSL COM RELAÇÃO ENTRE O DESCRIPTOR E O OBJETIVO DO TRABALHO .....	39
FIGURA 18 – RESULTADO DO MSL COM RELAÇÃO ENTRE O CLASSIFICADOR UTILIZADO E O OBJETIVO DO TRABALHO .....	39
FIGURA 19 – TRABALHO DE BASHISH, BRAIK, E BANI-AHMAD (2010): EXEMPLO DE DETECÇÃO DE CLUSTER NA IMAGEM DA FOLHA COM KMEANS.....	40

FIGURA 20 – TRABALHO DE CAMARGO E SMITH (2009): EXEMPLO DE FOLHA DE ALGODÃO COM SINTOMAS VISUAIS DE DANOS CAUSADOS POR 3 TIPOS DE DOENÇAS .....	41
FIGURA 21 – TRABALHO DE ROTHE E KSHIRSAGAR (2014): SINTOMA DE DOENÇA EM FOLHA DE ALGODÃO .....	42
FIGURA 22 – TRABALHO DE ORILLO ET AL. (2014): SINTOMAS VISUAIS DE TRÊS DOENÇAS EM FOLHAS DE ARROZ.....	43
FIGURA 23 – TRABALHO DE MOLINA <i>ET AL.</i> (2015): EXEMPLO DE REGIÃO DE INTERESSE SELECIONADA.....	43
FIGURA 24 – TRABALHO DE RATNASARI <i>ET AL.</i> (2014): EXEMPLOS DE SINTOMAS VISUAIS DE DOENÇAS EM FOLHAS DE ARROZ .....	44
FIGURA 25 – TRABALHO DE AKHTAR <i>ET AL.</i> (2013): EXEMPLO DO PROCESSO DE SEGMENTAÇÃO DA DOENÇA.....	45
FIGURA 26 – TRABALHO DE RAMAKRISHNAN E SAHAYA (2015): EXEMPLOS DE DOENÇAS NAS FOLHAS .....	46
FIGURA 27 – CAIXA COM MUDA COLOCADA EM LOCAL PADRÃO UTILIZADO PARA A CAPTURA DAS IMAGENS PARA CONSTRUIR O BANCO DE IMAGENS DIGITAIS UTILIZADO NOS TESTES .....	48
FIGURA 28 – EXEMPLO DE IMAGEM DE MUDA A) SAUDÁVEL E B) DOENTE PARA OS TESTES .....	50
FIGURA 29 – EXEMPLO DE SEGMENTAÇÃO DE MUDA SAUDÁVEL COM FUNDO AZUL MENOR QUE 20% DA ÁREA TOTAL: FOLHA COM TEXTURA SEM SINAIS DE DOENÇA.....	50
FIGURA 30 – EXEMPLO DE SEGMENTAÇÃO DE MUDA DOENTE: SINTOMAS DA DOENÇA COM MANCHAS MARROMES ESCURAS NA FOLHA.....	51
FIGURA 31 – EXEMPLO DE IMAGEM COM A) E SEM B) ESPINHO NO CAULE .....	56
FIGURA 32 – EXEMPLO DE IMAGEM SEM ESPINHO NO CAULE COM FILTRO LAPLACIANO .....	58
FIGURA 33 – EXEMPLO DE IMAGEM DE MUDA: A) MORTA E B) VIVA, UTILIZADAS NOS TESTES ...	59
FIGURA 34- EXEMPLO DE IMAGEM DE MUDA A) GRANDE E B) PEQUENA UTILIZADAS NOS TESTES .....	60
FIGURA 35- EXEMPLO DE IMAGEM DE MUDA A) GRANDE E B) PEQUENA SEMELHANTES.....	61

## LISTA DE TABELAS

TABELA 1 – SÍNTESE DO MSL DOS TRABALHOS RELACIONADOS COM DOENÇAS EM PLANTAS ..	49
TABELA 2 – CONSTANTES DE SEGMENTAÇÃO DAS IMAGENS .....	51
TABELA 3 – TESTE A1: RESULTADOS DA CLASSIFICAÇÃO COM UTILIZAÇÃO DE SEGMENTAÇÃO POR JANELAS: SEGMENTOS 15/10 .....	52
TABELA 4 – TESTE A2: RESULTADOS DA CLASSIFICAÇÃO COM UTILIZAÇÃO DE SEGMENTAÇÃO POR JANELAS: SEGMENTOS 15/15 .....	52
TABELA 5 – TESTE A3: RESULTADOS DA CLASSIFICAÇÃO COM UTILIZAÇÃO DE SEGMENTAÇÃO POR JANELAS: SEGMENTOS 20/15 .....	53
TABELA 6 – TESTE A4: RESULTADOS DA CLASSIFICAÇÃO COM UTILIZAÇÃO DE SEGMENTAÇÃO POR JANELAS: SEGMENTOS 25/15 .....	53
TABELA 7 – RESULTADO DA CLASSIFICAÇÃO FINAL DO TESTE A, COM DESCRIPTOR BIC E CLASSIFICADOR SVM (SGD) COM BASE DE IMAGENS DA SEGMENTAÇÃO 15/15 .....	54
TABELA 8 – TESTE B: RESULTADOS DA CLASSIFICAÇÃO COM IMAGEM INTEIRA.....	54
TABELA 9 – TESTE C: RESULTADOS DA CLASSIFICAÇÃO COM DESCRIPTORES MPEG-7 .....	55
TABELA 10 – TESTE A: RESULTADOS DA CLASSIFICAÇÃO DOS TESTES EM MUDAS DE PUPUNHA COM/SEM ESPINHOS.....	56
TABELA 11 – TESTE B: RESULTADOS DA CLASSIFICAÇÃO DOS TESTES EM MUDAS DE PUPUNHA COM/SEM ESPINHOS COM ALTERAÇÕES NO BRILHO E CONTRASTE DAS IMAGENS .....	57
TABELA 12 – TESTE C: RESULTADOS DA CLASSIFICAÇÃO DOS TESTES EM MUDAS COM/SEM ESPINHOS COM FILTRO LAPLACIANO. ....	58
TABELA 13 – TESTE D: COMBINAR ALTERAÇÃO DE BRILHO E CONTRASTE COM FILTRO LAPLACIANO .....	58
TABELA 14 – TESTE EM MUDAS DE PUPUNHA MORTAS/VIVAS COM DESCRIPTOR CSD E CLASSIFICADORES SVM.....	60
TABELA 15 – TESTE COM MUDAS PEQUENAS/GRANDES COM DESCRIPTORES MPEG E CLASSIFICADORES SVM.....	61

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO.....</b>	<b>11</b>
1.1	AGRONEGÓCIO DO PALMITO.....	11
1.2	PUPUNHA PARA PRODUÇÃO DO PALMITO .....	12
1.3	MUDAS DE PUPUNHA PARA O CULTIVO.....	13
1.4	VISÃO COMPUTACIONAL NA AGRICULTURA .....	15
1.5	OBJETIVO .....	16
1.6	METODOLOGIA .....	16
1.7	ESCOPO.....	17
1.8	ESTRUTURA DO TEXTO.....	17
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA .....</b>	<b>18</b>
2.1	VISÃO COMPUTACIONAL.....	18
2.1.1	<b>Sistemas de imagem .....</b>	<b>18</b>
2.1.2	<b>Técnicas de iluminação .....</b>	<b>18</b>
2.2	RECONHECIMENTO DE PADRÕES .....	19
2.3	DESCRITORES.....	21
2.3.1	<b>Descritores de cor.....</b>	<b>21</b>
2.3.1.1	<i>Global Color Histogram (GCH).....</i>	22
2.3.1.2	<i>Color Structure Descriptor (CSD).....</i>	22
2.3.1.3	<i>Scalable Color Descriptor (SCD).....</i>	24
2.3.1.4	<i>Color Layout Descriptor (CLD) .....</i>	25
2.3.1.5	<i>Border/Interior pixel Classification (BIC) .....</i>	25
2.3.1.6	<i>Auto Color Correlogram (ACC) .....</i>	26
2.3.2	<b>Descritores de textura .....</b>	<b>26</b>
2.3.2.1	<i>Local Binary Pattern (LBP).....</i>	26
2.3.2.2	<i>Homogeneous Texture Descriptor (HTD) .....</i>	27
2.3.2.3	<i>Edge Histogram Descriptor (EHD) .....</i>	27
2.3.2.4	<i>Statistical Analysis of Structural Information (SASI) .....</i>	27
2.3.2.5	<i>Invariant Steerable Pyramid Decomposition (SID) .....</i>	28
2.3.2.6	<i>Steerable Mean Standard Deviation (SMS).....</i>	28
2.4	CLASSIFICADORES .....	28
2.4.1	<b><i>Support Vector Machine (SVM) .....</i></b>	<b>30</b>
2.4.2	<b><i>Redes Neurais Artificiais.....</i></b>	<b>31</b>

2.5	CONSIDERAÇÕES.....	36
<b>3</b>	<b>TRABALHOS RELACIONADOS .....</b>	<b>37</b>
3.1	MAPEAMENTO SISTEMÁTICO DA LITERATURA .....	37
3.2	APLICAÇÕES DE VISÃO COMPUTACIONAL PARA DETECTAR DOENÇA EM PLANTAS .....	40
3.3	DISCUSSÃO .....	46
<b>4</b>	<b>DESENVOLVIMENTO E TESTES.....</b>	<b>47</b>
4.1	BASE DE IMAGENS .....	47
4.2	CLASSIFICAR MUDAS DOENTES/SAUDÁVEIS.....	49
4.2.1	Teste A – Utilizar região de interesse por segmentação por regiões .....	49
4.2.2	Teste B – Utilizar imagem inteira .....	54
4.2.3	Teste C – Utilizar imagem inteira e descriptores MPEG-7.....	55
4.3	CLASSIFICAR MUDAS COM/SEM ESPINHO NO CAULE .....	55
4.3.1	Teste A – Utilizar descriptores de cor e textura e classificador SVM .....	55
4.3.2	Teste B – Alterar brilho e contraste das imagens.....	57
4.3.3	Teste C – Utilizar filtro Laplaciano para realçar borda dos espinhos .....	57
4.3.4	Teste D – Combinação de alteração de brilho e contraste com filtro Laplaciano.....	58
4.4	CLASSIFICAR MUDAS MORTAS/VIVAS .....	59
4.5	CLASSIFICAR MUDAS PEQUENAS/GRANDES .....	60
4.6	DISCUSSÃO .....	61
<b>5</b>	<b>CONCLUSÃO .....</b>	<b>63</b>
5.1	DISCUSSÃO .....	63
5.2	RESULTADOS.....	64

## 1 INTRODUÇÃO

A agricultura é uma atividade exercida há milênios pelo ser humano para a produção de alimentos. O aumento de produção de alimentos, a melhoria da qualidade e a diminuição dos custos podem ser alcançadas com a melhoria das técnicas de produção (RIBEIRO, 2016). Os fatores responsáveis pelo aumento da produção na agricultura são (ALVES; DA SILVA E SOUZA; ROCHA, 2012): a tecnologia (68%); o trabalho (23%) e a terra (9%). A tecnologia mostra-se como a maior influência para o aumento da produção. O agronegócio brasileiro, antes do início da década de 1970, era improutivo e com baixa sustentabilidade, mas uma transformação ocorreu com a atuação do Governo Federal, promovendo medidas no setor, culminando com aumento produtivo. No início do século XXI o Brasil se destaca como um dos principais países do setor do agronegócio mundial, com sólidos fundamentos de sustentabilidade (GAZZONI, 2013). Na economia brasileira, o agronegócio possui papel fundamental pois gera emprego e renda e é destaque no comércio internacional (ZANELLA; LEISMANN, 2017).

### 1.1 AGRONEGÓCIO DO PALMITO

O palmito é um alimento da parte superior do caule de diversas palmeiras, formado por tecidos macios de bainhas e folhas em formação, conforme exemplificado na Figura 1 com os diversos tipos de processamento de palmitos realizados pelas indústrias de beneficiamento (RESENDE *et al.*, 2009). O Brasil é um dos maiores produtores e consumidores de palmito do mundo (NEVES *et al.*, 2007).

O cultivo do palmito é uma prática sustentável para produzir e proteger o meio ambiente (IBGE, 2011; NEVES *et al.*, 2007). Das 20 mil espécies de plantas existentes no Bioma Mata Atlântica, existem 276 espécies ameaçadas em extinção, dentre elas o palmito juçara (*Euterpe edulis*), sendo fundamental na dinâmica do seu ecossistema pois é considerada uma espécie-chave, ou seja, em caso de extinção poderia ocasionar a perda de diversas outras espécies dependentes diretamente dela para a sua sobrevivência (CARDOSO, 2016). Em Santa Catarina a extração ilegal de palmito juçara é um dos fatores que causam a diminuição das florestas (CARDOSO, 2016). Utilizar outras espécies produtoras de palmito é fundamental para a preservação das florestas tanto em Santa Catarina quanto na mata atlântica.

Figura 1 – Palmito processado para comercialização em conservas



Fonte: Disponível em: <[projetomaravilhas.com.br](http://projetomaravilhas.com.br)>. Acesso em: 08 fev. 2018.

## 1.2 PUPUNHA PARA PRODUÇÃO DO PALMITO

A pupunha (*Bactris Gasipaes*) é uma espécie cultivada para produção de palmito, conforme ilustrado na Figura 2, com a apresentação de uma lavoura de pupunha em formação. As vantagens do cultivo da pupunha em relação a outras espécies produtoras de palmito (juçara, açaizeiro, palmeira real australiana) são (IBGE, 2011; NOGUEIRA *et al.*, 1995):

Figura 2 – Cultivo de pupunha para produção de palmito



Fonte: Disponível em: <[palmitosupremo.com.br](http://palmitosupremo.com.br)>. Acesso em: 08 fev. 2018.

- Possuem mais estudos sobre o cultivo, seleção genética e melhoramento, manejo da adubação;
- É a palmeira mais cultivada para a produção de palmito, com aceitação por importadores por não ser um produto do extrativismo;
- Produção em plantios organizados;
- Precocidade na produção, com cortes a partir de 18 meses após o plantio;

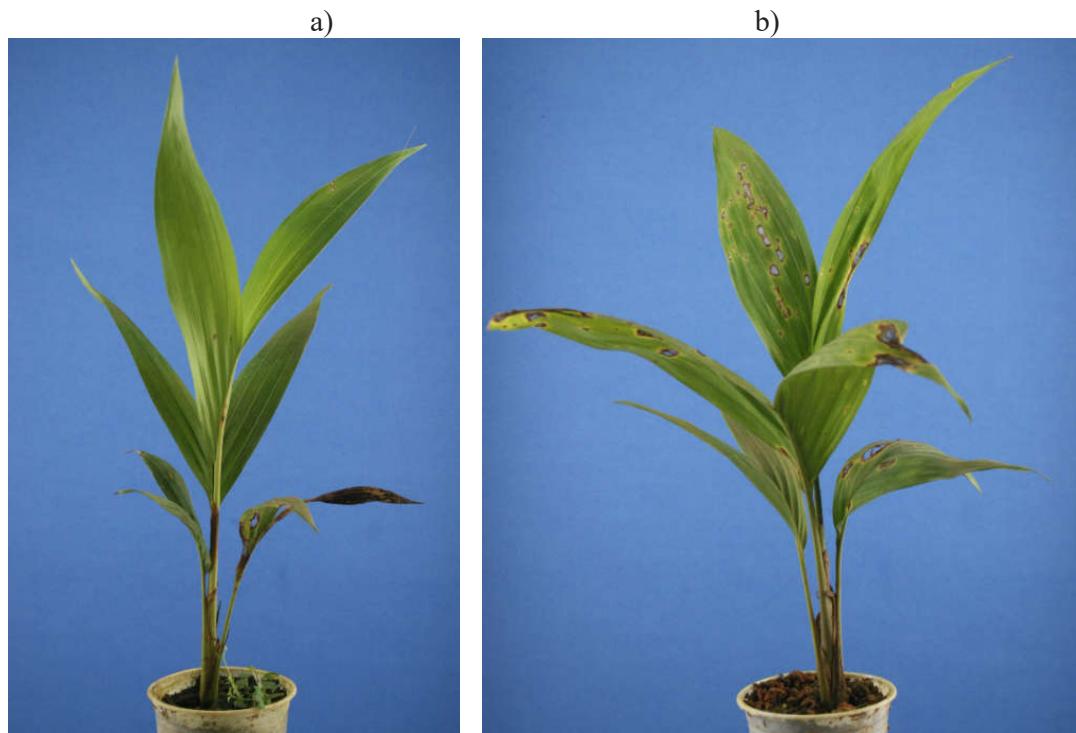
- Cortes sucessivos devido aos perfilhos sem necessidade de novo plantio após o corte;
- Apresenta baixo teor de taninos, permite o consumo in natura, cru, refogado ou assado;
- Alta produtividade: atinge entre 5000 e 12000 palmitos (hastes) por hectare por ano;
- Palmito pode permanecer na lavoura, com o corte realizado quando valores de mercado ou clima forem mais favoráveis;
- O cultivo pode ser realizado a pleno sol, nas áreas agrícolas tradicionais, sem causar danos às matas nativas;
- Adaptação a diferentes tipos de solos;
- Não escurece após o corte, fator que facilita a produção e processamento.

O palmito de pupunha é nutritivo, tem baixo teor calórico, rico em fibras e em minerais como potássio, cálcio, fósforo e outras vitaminas e aminoácidos, sendo uma alternativa em dietas com restrições calóricas (RESENDE *et al.*, 2009). As oportunidades de negócios que os mercados internos e externos proporcionam para a produção de palmito de pupunha são maximizados pela conscientização dos clientes consumidores sobre a necessidade de alimentos com qualidade, procedência conhecida e sustentáveis (IBGE, 2011).

### 1.3 MUDAS DE PUPUNHA PARA O CULTIVO

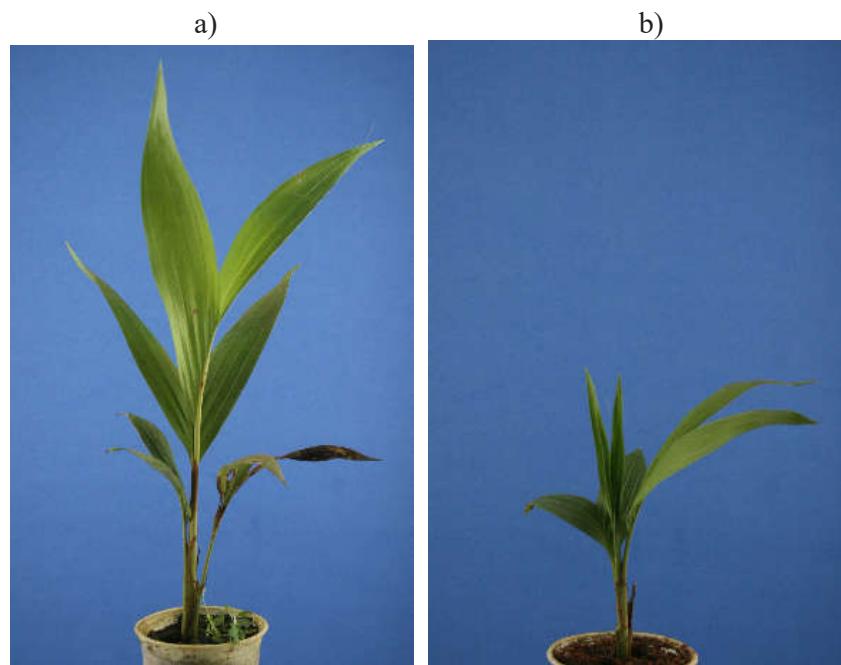
A alta demanda por palmito exige mudas para formar as plantações (SANTOS *et al.*, 2007). As mudas necessitam de tratos culturais no viveiro para: manter as mudas livres de plantas daninhas, pragas e doenças (NEVES *et al.*, 2007; SANTOS *et al.*, 2007). As inspeções periódicas das mudas (para detectar e diagnosticar a doença precocemente) devem ser realizadas para encontrar qualquer anormalidade nas plantas. As mudas saudáveis (Figura 3a) devem ser separadas das mudas doentes (Figura 3b). As mudas com a quantidade maior de folhas e com diâmetro do caule maior (Figura 4a) são selecionadas para o plantio no campo; mudas com má formação e doentes devem ser removidas do viveiro; as demais (mudas pequenas conforme Figura 4b) permanecem no viveiro (NEVES *et al.*, 2007; SANTOS *et al.*, 2007). As mudas sem espinhos (Figura 5a) são da variedade utilizadas para o plantio no campo, sendo que as mudas com espinhos (Figura 5b) são descartadas. As mudas mortas (Figura 6) devem ser removidas do viveiro (SANTOS *et al.*, 2007). A inspeção visual realizada nos viveiros produtores de mudas é manual (humanos). A aplicação da Visão Computacional pode melhorar o processo e a qualidade de seleção.

Figura 3 – Exemplo de estado sanitário de mudas de pupunha: a) saudável/ b) doente



Fonte: Elaborado pelo autor, 2017.

Figura 4 – Exemplo de tamanho de muda: a) grande/ b) pequena



Fonte: Elaborado pelo autor, 2017.

Figura 5 – Exemplo de variedade de muda: a) sem/ b) com espinhos no caule



Fonte: Elaborado pelo autor, 2017.

Figura 6 – Exemplo de uma muda de pupunha morta



Fonte: Elaborado pelo autor, 2017.

#### 1.4 VISÃO COMPUTACIONAL NA AGRICULTURA

A Visão Computacional tem como objetivo tomar decisões sobre objetos físicos do mundo real baseadas em suas imagens digitais (SHAPIRO; STOCKMAN, 2000). A aplicação da visão computacional na agricultura tem registrado um aumento nos últimos anos, com trabalhos relacionados nas áreas de: monitoramento de culturas, agricultura de precisão, robótica, orientação automática, inspeção não destrutiva das propriedades do produto, controle de qualidade, classificação e automação do processo (CUBERO *et al.*, 2011). A inspeção da

qualidade de produtos agrícolas é realizada, tradicionalmente, por pessoas (BROSNAN; SUN, 2002). No processo de inspeção manual as decisões são afetadas por fatores psicológicos: como a fadiga ou hábitos adquiridos por exigir precisão e rapidez sendo fatores que aumentam o risco de ocorrer erros na inspeção (CUBERO *et al.*, 2011; GOMES; LETA, 2012).

As vantagens dos sistemas de inspeção visual incluem velocidade e precisão superiores ao método manual (BROSNAN; SUN, 2002). Os sistemas de inspeção visual são compostos por uma fonte de luz, um dispositivo para a captura das imagens e um sistema computacional para a extração de características das imagens e o processamento (GOMES; LETA, 2012). A inspeção visual é uma solução para a análise da qualidade de produtos agrícolas, com avaliação das características de dimensão, cor, textura e forma (GOMES; LETA, 2012). A aplicação de um sistema de inspeção visual para o reconhecimento de doenças em plantas, através do reconhecimento de padrões, pode reduzir a atuação de técnicos e profissionais na proteção fitossanitária das plantas (WANG *et al.*, 2012).

A agricultura pode se beneficiar com a automatização de processos que exigem a inspeção visual. Para o fornecimento de mudas com baixos custos de produção, redução da mão-de-obra e para atender as exigências de fitossanidade e tamanho adequado para o plantio no campo, a aplicação da visão computacional pode garantir os resultados esperados, com precisão, velocidade e baixos custos.

## 1.5 OBJETIVO

O presente trabalho tem como objetivo geral facilitar a análise da qualidade de lotes de mudas de pupunha.

Os Objetivos Específicos incluem:

- Disponibilizar um banco de imagens digitais com mudas de pupunha;
- Classificar mudas quanto a doenças, espinhos, mortas e pequenas com a aplicação de visão computacional;
- Avaliar desempenho de classificação e tempo de processamento.

## 1.6 METODOLOGIA

A pesquisa bibliográfica é a busca de trabalhos relacionados a um problema em referências publicadas, analisando as suas contribuições científicas. Com isso é fornecido conhecimento teórico e científico para possibilitar a produção do trabalho. A pesquisa também

pode ser utilizada para identificar trabalhos semelhantes aos problemas estudados, para verificar se já foram realizadas outras investigações com os mesmos objetivos e se a nova pesquisa pode fornecer alguma contribuição para a comunidade científica. Com isso pode-se analisar se o escopo da pesquisa está adequado ao tipo de trabalho desejado (MARCONI; LAKATOS, 2003).

### 1.7 ESCOPO

O presente trabalho tem o seguinte escopo: fonte de luz controlada; câmera digital; utilização de imagem digital como entrada no sistema; não irá identificar o tipo de doença, nem o nível de acometimento da doença, apenas a presença ou não de algum sintoma de doença, sem alimentação automática das mudas, com fonte de luz artificial para a aquisição das imagens digitais. Visa um sistema para viveiros de mudas e não para aplicação no campo (área de cultivo de plantas). Não irá abordar as Redes Neurais Convolucionais - *Convolutional Neural Networks*<sup>1</sup>(CNN) nem descritores globais de forma por limites de tempo de pesquisa.

### 1.8 ESTRUTURA DO TEXTO

O texto segue a seguinte estrutura: no capítulo 2 é apresentada a fundamentação teórica com os conceitos principais utilizados no trabalho: visão computacional, reconhecimento de padrões, descritores e classificadores; no capítulo 3 expõe o mapeamento sistemático da literatura e os trabalhos relacionados com as técnicas utilizadas e o desempenho alcançado; no capítulo 4 são apresentados os testes com todas as classes de mudas de pupunha e os resultados; o capítulo 5 apresenta a conclusão do trabalho.

---

<sup>1</sup> *Convolutional Neural Networks*. Disponível em: <<http://deeplearning.net/tutorial/lenet.html>>. Acesso em: 02 nov. 2018.

## 2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo serão apresentados alguns conceitos fundamentais para entender as técnicas utilizadas nos trabalhos relacionados e neste projeto de mestrado. Primeiramente serão introduzidos conceitos de Visão Computacional, os critérios de desempenho dos algoritmos de visão computacional; as técnicas de iluminação e sua importância para o resultado; e o reconhecimento de padrões, que envolve desde a captura da imagem, a descrição da imagem e a classificação na classe correspondente.

### 2.1 VISÃO COMPUTACIONAL

Um sistema de Visão Computacional envolve o processo de: adquirir, processar, analisar e compreender dados complexos para exploração científica e técnica (NIXON; AGUADO, 2002). A tomada de decisões requer, quase sempre, a construção de alguma descrição ou modelo a partir de uma imagem (JAHNE; HAUBECKER, 2000).

#### 2.1.1 Sistemas de imagem

Os sistemas de imagem abordam todos os processos de formação de uma imagem através de objetos e sensores com a conversão da radiação em sinais elétricos, a seguir em sinais digitais que podem ser processados por um computador. Uma boa qualidade de imagem aumenta a precisão de classificação e a confiabilidade do algoritmo de visão por computador mas reduz a velocidade de processamento (JAHNE; HAUBECKER, 2000).

Os três principais critérios para o desempenho de algoritmos de visão computacional são (JAHNE; HAUBECKER, 2000):

- Solução bem-sucedida da tarefa: definição adequada do algoritmo para a tarefa do sistema e seus limites;
- Acurácia: análise dos erros estatísticos e sistemáticos;
- Velocidade: critério da velocidade do sistema (tempo de processamento) para a aplicabilidade de um algoritmo.

#### 2.1.2 Técnicas de iluminação

Existe uma grande variedade de possibilidades para organizar geometricamente várias fontes de luz e, eventualmente, combiná-las com componentes óticos, para formar uma configuração de iluminação adequadas para diferentes aplicações visuais. Em muitos casos a

alteração do arranjo geométrico (posição da câmera, distância, etc.) ou as características de iluminação (intensidade, tipo de lâmpada) é realizada ao invés de tentar utilizar algoritmos caros de visão computacional para resolver a mesma tarefa. É uma opção para buscar melhores resultados na classificação, economizando a tarefa de programar outro algoritmo ou tentar outra técnica computacional (JAHNE; HAUBECKER, 2000).

## 2.2 RECONHECIMENTO DE PADRÕES

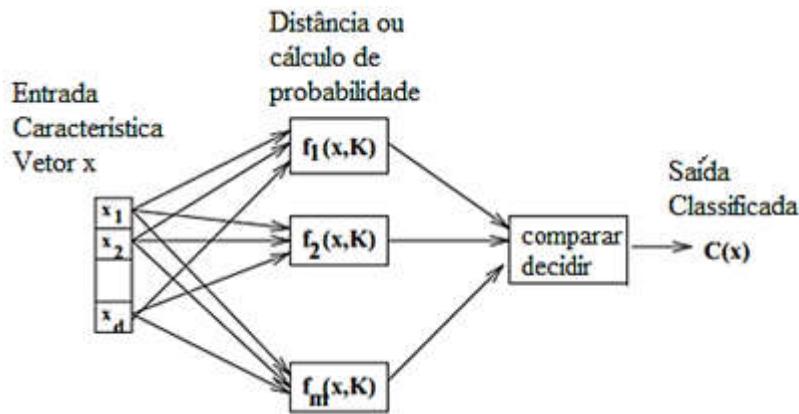
Kuncheva (2004) define reconhecimento de padrões como o processo de descrever as características ou atributos de um objeto com a atribuição de rótulos. O objetivo fundamental do reconhecimento de padrões envolve a extração de características para reconhecer e classificar objetos (JAHNE; HAUBECKER, 2000). Uma imagem (objeto) é formada de padrões que são reconhecidos através de uma descrição da imagem em um vetor de medidas (características ou atributos) (SHAPIRO; STOCKMAN, 2000). Em problemas práticos é necessário tomar decisões sobre o conteúdo de uma imagem ou sobre a classificação de um objeto que ela contém. O modelo de classificação das imagens é formado por (SHAPIRO; STOCKMAN, 2000):

- Classes: uma classe é um conjunto de objetos com propriedades em comum. Cada classe, para cada objeto, é definida por um rótulo. A classificação é o processo que assume um rótulo para um objeto de acordo com a representação das propriedades deste objeto, ou seja, tenta classificar cada objeto, com seu rótulo e conjunto de atributos, em sua classe correspondente;
- Sensor ou transdutor: deve haver algum dispositivo para detectar o objeto físico real e exibir uma representação dele para seu processamento (exemplo: câmera fotográfica digital);
- Extração de características: extrai informações relevantes para a classificação de dados de entrada fornecidos por um sensor. Frequentemente a extração de características é realizada através de um software. Os objetos são comparados por similaridades baseadas em suas representações em um vetor de características;
- Classificador: o classificador utiliza as características extraídas dos dados do objeto detectado para atribuir ao objeto uma das  $m$  classes designadas  $C_1, C_2, \dots, C_{m-1}, C_m$ . Para simplificar o entendimento o diagrama de blocos de um sistema de classificação é apresentado na Figura 7. Um vetor de características  $x$   $d$ -dimensional representa a entrada do objeto para ser classificado. O sistema possui um bloco para cada possível classe com conhecimento  $K$

sobre a classe (rótulo) e capacidade para o processamento. Os resultados de  $m$  computações são transmitidos para o estágio final de classificação, o qual decide a classe do objeto.

- Construir o sistema de classificação: cada parte do sistema possui muitas alternativas de implementação de acordo com: sensor de imagem utilizado; tipos de características extraídas (textura, cor, forma, etc.); pré-processamento aplicado à imagem. Entre o sensor e a classificação as aplicações de filtro ou redução de ruído na imagem fazem parte do pré-processamento;

Figura 7 – Diagrama do sistema de classificação: funções discriminantes  $f(x, K)$  realizam alguma computação no vetor de características de entrada  $x$  usando algum conhecimento  $K$  para treinar e passar resultados para um estágio final que determina a classe.



Fonte: Adaptado (SHAPIRO; STOCKMAN, 2000)

- Medição dos erros do sistema: A taxa de erro de um sistema de classificação é uma medida que define o quanto o sistema é eficiente no sentido de quão bem ele resolve o problema a que foi projetado. Outras medidas são: velocidade, em termos de quantos objetos podem ser processados por unidade de tempo, e; custos, em termos de *hardware*, *software* e custos de desenvolvimento;
- Falso positivo e falso negativo: alguns problemas de duas classes em que existem um objeto “bom” versus um objeto “ruim” tem nos erros um sentido especial e não simétrico. Por exemplo: se o sistema incorretamente diz que o objeto é bom então o erro é chamado falso positivo, enquanto que se o sistema incorretamente diz que o objeto é ruim então o erro é chamado de falso negativo.

Dada uma série de exemplos de treinamento (chamados de amostras, padrões ou observações) associados aos resultados desejados, o processo de reconhecimento de padrões consiste em encontrar a relação entre os padrões e os resultados utilizando apenas os exemplos

de treinamento (GUYON *et al.*, 2008). Por exemplo: os dados ou amostras são observações das imagens de mudas e o resultado é o estado fitossanitário: saudável ou doente. O objetivo é prever o resultado desconhecido para novas amostras de teste (o estado fitossanitário de novas mudas). O desempenho no teste de dados é chamado de generalização. Para executar esta tarefa é preciso construir um modelo de classificação com parâmetros ajustáveis conhecido como aprendizado de máquina (*machine learning*). Os exemplos de treino são usados para selecionar um conjunto ótimo de parâmetros (GUYON *et al.*, 2008).

## 2.3 DESCRIPTORES

Na construção das características das imagens, considerando o problema de visão computacional, em particular na utilização de imagens digitais, os dados são representados por um número fixo de características que podem ser binárias, categóricas ou contínuas (NIXON; AGUADO, 2002). Extrair as características (descrever) é um dos passos chaves no processo de análise, amplamente condicionado ao sucesso de qualquer projeto com aprendizagem de máquinas ou mais especificamente através da utilização de classificadores (GUYON *et al.*, 2008). O limite conceitual entre a extração de características e a classificação adequada é arbitrário: um extrator de características ideal resultaria em uma representação que torna trivial o trabalho do classificador; inversamente, um classificador onipotente não precisaria da ajuda de um extrator de características sofisticado. A distinção é obrigatória por razões práticas, e não teóricas. De uma maneira geral, a extração de características é mais dependente do problema do que a própria classificação e, portanto, requer conhecimento do problema (DUDA; HART; STORK, 2012).

Conforme Bernal, Vilarino e Sanchez (2010), para o contexto de visão computacional, existem três categorias principais de descritores globais de imagem: descritores de cor, textura e forma. Cor e textura estão entre as mais expressivas características visuais. Uma quantidade considerável de trabalhos foi desenvolvida para a criação de descritores eficientes para aplicações como recuperação por semelhança.

### 2.3.1 Descritores de cor

Os descritores de cores utilizam diferentes espaços de cores: monocromático, RGB, HSV, HSI, YCrCb, HMMD,  $L^*a^*b^*$ , (MANJUNATH *et al.*, 2001; PLATANIOTIS; VENETSANOPoulos, 2000). O espaço de cor RGB e o espaço de cor HSV são escolhas populares para manipular a cor, com uma representação intuitiva da cor, com aproximação da

forma que os seres humanos percebem e manipulam a cor (PLATANIOTIS; VENETSANOPoulos, 2000). Dentre os inúmeros descritores de cor existentes podem ser citados (MANJUNATH *et al.*, 2001):

### 2.3.1.1 Global Color Histogram (GCH)

O descritor *Global Color Histogram* (GCH), na tradução literal: Histograma Global de Cores. Trata-se de um conjunto de valores ordenados, um para cada cor distinta, representando a probabilidade de um pixel ser daquela cor. Para obter as características, a imagem é requantizada em um número de cores arbitrário (em geral 64 cores) e, em seguida, calculado o histograma, que representa as características globais de cor da imagem. Apesar de simples, esse método se mostra bastante útil em diversas aplicações. O vetor resultante é composto por  $n$  características com a distribuição global das cores da imagem (SWAIN; BALLARD, 1991).

### 2.3.1.2 Color Structure Descriptor (CSD)

Manjunath et al (2001) afirmam que o descritor *Color Structure Descriptor* (CSD), na tradução literal: Descritor de Estrutura de Cores, representa a estrutura local de cor de uma imagem a partir do uso de um elemento estruturante  $8 \times 8$  realizando a contagem da ocorrência que uma determinada cor está contida dentro da posição onde o elemento estruturante encontra-se localizado. O mesmo percorre toda a extensão da matriz de pixels da imagem compondo  $m$  histogramas da estrutura de cores  $h(m)$ , onde  $m$  representa o número de cores consideradas. Cada compartimento (*bin*) do histograma, ou seja, representa o número de elementos estruturantes na imagem que contêm um ou mais pixels da cor em questão. O CSD é especificado por três aspectos fundamentais: o espaço de cores, o método pelo qual são gerados histogramas compactos, e o esquema utilizado para quantificar os valores da amplitude do *bin*. O espaço de cores utilizado pelo descritor é o HMMD (MANJUNATH *et al.*, 2001; MESSING; BEEK; ERRICO, 2001).

Segundo Manjunath *et al.* (2001) o descritor CSD representa a estrutura de cor local em uma imagem utilizando um elemento de estruturação  $8 \times 8$ . Ele conta o número de vezes que uma cor particular está contida no elemento estruturante, pois o elemento estruturante explora ou sonda a imagem. Suponha  $c_0, c_1, c_2, \dots, c_m - 1$  denotado por  $M$  cores quantizadas. Um histograma de estrutura de cores indicado por  $h(m)$ ,  $m = 0, 1, \dots, M - 1$ , onde o valor de cada *bin* representa o número de elementos estruturantes na imagem contendo um ou mais pixels com cor  $c_m$ . O descritor CSD é definido usando quatro pontos de operação de quantificação do

espaço de cores: 184,120,64 e 32 bin. Para construir uma cor quantizada com nível 184, o espaço de cores HMMD é quantificado de forma não uniforme, da seguinte forma: todo o espaço de cores do HMMD é dividido em cinco subespaços. Para os respectivos subespaços, a quantização de cor uniforme nos valores Matiz e Montante resulta em uma quantificação de cor de 184 níveis. Para calcular o CSD, um elemento estruturante  $8 \times 8$  é utilizado para percorrer toda a imagem e mesmo que o número total de amostras seja mantido fixo em 64, a extensão espacial do elemento estruturante é escalonada com o tamanho da imagem. A seguinte regra determina a extensão espacial do elemento estruturante, dado o tamanho da imagem (MANJUNATH *et al.*, 2001):

$$p = \max\{0, \text{round}(0.5 \log_2 WH - 8)\} \quad K = 2^p, E = 8K$$

onde:

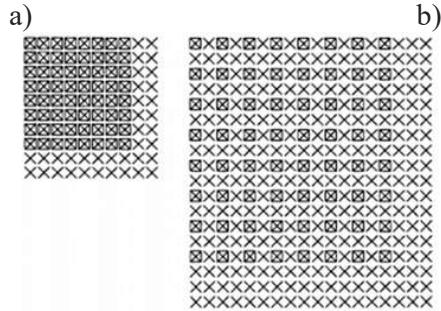
$W, H$  largura e altura da imagem, respectivamente;

$E \times E$  extenção espacial do elemento extruturante;

$K$  fator de sub-amostragem.

Para imagens menores que  $256 \times 256$  pixels é usado um elemento  $8 \times 8$  sem sub amostragem (MANJUNATH *et al.*, 2001). Outro exemplo: se o tamanho da imagem é  $640 \times 480$ , então  $p = 1, K = 2, e E = 16$ . Então, para calcular o histograma é usado, para cada amostra, ao longo das linhas e colunas um elemento estruturante  $16 \times 16$ . Um elemento estruturante desliza sobre a imagem e é deslocado por um pixel, Figura 8 (a) e por dois pixels no caso da Figura 8 (b). O caso da Figura 8 (b) corresponde à sub amostragem da imagem por dois, em ambas as direções, e subsequentemente aplicando o mesmo elemento de estruturação  $8 \times 8$ . Cada *bin* do CSD  $h(m)$  representa o número de locais do elemento estruturante no qual um pixel com cor  $c_m$  cai dentro do elemento. A origem do elemento estruturante é definida pela amostra de cima para a esquerda. As posições do elemento de estrutura sobre as quais o descritor é acumulado são definidas pela grade de pixels da possível sub amostra da imagem de entrada.

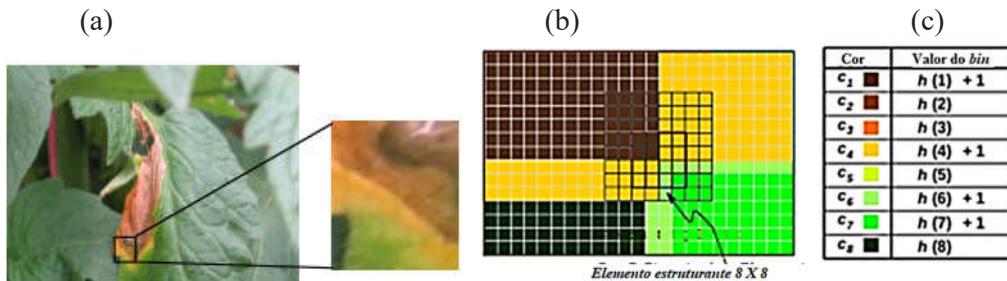
Figura 8 – Elementos estruturantes para imagens com diferentes resoluções: a)  $320 \times 240$  e b)  $640 \times 480$  pixels



Fonte: (MANJUNATH *et al.*, 2001)

Um exemplo do funcionamento é apresentado na Figura 9 (a) com uma imagem de uma folha com doença, e na imagem ampliada (Figura 9 (b)) encontra-se o elemento estruturante  $8 \times 8$  que percorre a imagem, com a tabela (Figura 9 (c)) que apresenta o resultado da quantificação de cor para cada *bin*.

Figura 9 – Exemplo de funcionamento do CSD: a) imagem de folha com doença; b) elemento estruturante; c) resultado de quantificação de cor



Fonte: Adaptado (MOLINA *et al.*, 2015)

### 2.3.1.3 Scalable Color Descriptor (SCD)

O descriptor *Scalable Color Descriptor* (SCD), na tradução literal: Descritor de Cores Escalonável, é derivado de um histograma de cores definido no espaço de cores HSV com quantização de espaço de cores fixo. A representação de 4 bits do histograma HSV de 256 bin requereria 1024 bits / histograma. Para diminuir esse número e tornar o aplicativo escalável, os histogramas são codificados usando uma transformação *Haar* (MANJUNATH *et al.*, 2001).

A unidade básica da transformada de *Haar* consiste em uma operação de soma e uma operação de diferença que se relacionam com filtros de passa baixa e alta. Somando pares de linhas de histograma adjacentes é equivalente ao cálculo de um histograma com metade do número de caixas. Se esse processo for executado iterativamente o uso de subconjuntos dos

coeficientes na representação de *Haar* é equivalente a histogramas de 128, 64, 32 bins, que são todos calculados a partir do histograma de origem (MANJUNATH *et al.*, 2001).

#### 2.3.1.4 *Color Layout Descriptor (CLD)*

O descriptor *Color Layout Descriptor* (CLD), na tradução literal: Descritor de Arranjo de Cores, foi projetado para capturar a distribuição espacial de cores em uma imagem ou em uma região de forma arbitrária (MANJUNATH *et al.*, 2001). A distribuição espacial da cor constitui um descriptor efetivo para recuperação de imagem baseada em esboço, filtragem de conteúdo, usando indexação de imagem e visualização. A funcionalidade deste descriptor também pode ser alcançada usando uma combinação de descriptor de estrutura de grades e cores dominantes em grade. No entanto, tal combinação exigiria um número relativamente grande de bits e a correspondência será mais complexa e dispendiosa. Para várias aplicações, é necessário um descriptor compacto e eficaz, e o CLD satisfaz essas necessidades. O CLD é um descriptor compacto que usa cores representativas em uma grade seguida por uma transformada discreta de cosseno (*Discrete Cosine Transform – DCT* (AHMED; NATARAJAN; RAO, 1974)) e codificação dos coeficientes resultantes. O processo de extração de recursos consiste em duas partes: seleção de cor representativa baseada em grade e transformada DCT com quantização. O espaço de cores adotado para o descriptor CLD é o YCrCb (MANJUNATH *et al.*, 2001).

#### 2.3.1.5 *Border/Interior pixel Classification (BIC)*

O descriptor *Border/Interior pixel Classification* (BIC), na tradução literal: Classificação Borda/Interior de pixels, é formado por três componentes principais: um algoritmo que classifica os pixels de borda ou interior da imagem; uma medida com a distância logarítmica (*dLog*) utilizado para a classificação de similaridade entre as imagens; e uma representação compacta das características extraídas da imagem (STEHLING; NASCIMENTO; FALCÃO, 2002). Um histograma é calculado para os pixels da borda e outro para os pixels do interior do objeto da imagem, concatenados para compor um único vetor de características (STEHLING; NASCIMENTO; FALCÃO, 2002). O cálculo de similaridade (ou distância) entre os vetores de

duas imagens distintas é realizada através da aplicação de medida de distância  $dLog$ . A distância  $dLog$  é calculada pelo logaritmo da distância  $L1$  (*Manhattan*<sup>2</sup> ou *Taxicab*<sup>3</sup>) entre os histogramas.

### 2.3.1.6 Auto Color Correlogram (ACC)

O descriptor *Auto Color Correlogram* (ACC), na tradução literal: Correlograma Automático de Cor, mapeia a correlação espacial das cores dos pixels em diferentes distâncias através do cálculo de um correlograma de cor em uma tabela indexada por pares de cores. Uma entrada  $k$  para as cores  $(i, j)$  corresponde à probabilidade de encontrar a cor  $j$  em um *pixel* localizado a uma distância  $k$  de um pixel de cor  $i$ . Após realizar todo o mapeamento o resultado é um pequeno vetor de características da imagem (HUANG *et al.*, 1997).

## 2.3.2 Descritores de textura

A textura pode ser definida como uma característica visual geralmente utilizada para descrever a estrutura da superfície, sendo descrita através das propriedades (PAGET; LONGSTAFF, 1998): regularidade, contraste, direcionalidade, delineamento e rugosidade. Descritor de textura é de baixo nível, como o de cor, poderoso para a busca de imagens e aplicações de recuperação de imagem (MANJUNATH *et al.*, 2001). Vale ressaltar que o MSL destacou como sendo os descritores de textura os mais utilizados em trabalhos de reconhecimento de padrões envolvendo doenças em plantas (PELLENS; HOUNSELL; SILVA, 2016). Dentre os diversos descritores de textura existentes na literatura, pode-se citar:

### 2.3.2.1 Local Binary Pattern (LBP)

O descriptor *Local Binary Pattern* (LBP), na tradução literal: Padrão Binário Local, é estruturado com base na premissa de que certos padrões binários locais são propriedades indispensáveis. O descriptor LBP permite detectar padrões binários locais uniformes em vizinhos circulares de qualquer quantização do espaço angular e em qualquer resolução espacial (OJALA; PIETIKÄINEN; MÄENPÄÄ, 2002). É definida uma janela de raio  $R$  que translada pela imagem quantificando a ocorrência de variações positivas e negativas de valores de níveis de cinza entre os *pixels* da vizinhança e o *pixel* central da posição onde encontra-se a janela.

<sup>2</sup> Manhattan. Disponível em: <<https://www.itl.nist.gov/div898/software/dataplot/refman2/auxiliar/mandis.htm>>. Acesso em 27 out. 2018.  
<sup>3</sup> Taxicab. Disponível em: <<http://mathworld.wolfram.com/TaxicabMetric.html>>. Acesso em 27 out. 2018.

Desta forma, quando a diferença resulta em um valor positivo, considera-se 1 e, atribui-se 0 quando esta variação é negativa. Em seguida, o número de transições 0-1 são quantificadas, a partir do qual obtém-se o valor LBP. O histograma é formado pelos valores LBP calculados a cada posição em que a janela foi deslocada pela imagem.

#### 2.3.2.2 *Homogeneous Texture Descriptor (HTD)*

O descritor *Homogeneous Texture Descriptor* (HTD), na tradução literal: Descritor de Textura Homogêneo, fornece uma caracterização quantitativa da textura para a correspondência baseada na similaridade entre as imagens. Este descritor é calculado primeiro pela filtragem da imagem por filtros de Gabor sensíveis a orientação e a escala; calculando a média e o desvio padrão das saídas filtradas no domínio da frequência (MANJUNATH *et al.*, 2001).

#### 2.3.2.3 *Edge Histogram Descriptor (EHD)*

O descritor *Edge Histogram Descriptor* (EHD), na tradução literal: Descritor de Histograma de Borda, desenvolvido a partir do princípio de que as bordas das imagens constituem um recurso importante para representar seu conteúdo. Uma maneira de representar um recurso de borda é usar um histograma. Um histograma de aresta no espaço da imagem representa a frequência e a direcionalidade da alteração do brilho na imagem. É uma característica única para imagens que não podem ser duplicadas por um histograma de cores ou pelas características de textura homogênea. Para representar esse recurso exclusivo, o MPEG-7 possui o descritor EHD (WON; PARK; PARK, 2002). O EHD captura a distribuição espacial das bordas, semelhante ao princípio do CLD (MANJUNATH *et al.*, 2001). O EHD representa basicamente a distribuição de 5 tipos de bordas em cada área local chamada de sub-imagem. A sub-imagem é definida dividindo o espaço da imagem em blocos  $4 \times 4$  não sobrepostos. Assim, a partição de imagem produz sempre 16 sub-imagens de tamanho igual, independentemente do tamanho da imagem original (WON; PARK; PARK, 2002).

#### 2.3.2.4 *Statistical Analysis of Structural Information (SASI)*

O descritor *Statistical Analysis of Structural Information* (SASI), na tradução literal: Análise Estatística de Informação Estrutural, é apresentado como uma representação da textura. O SASI é baseado em estatísticas de coeficientes de autocorrelação calculados sobre janelas de estruturação. O descritor define um conjunto de janelas para extrair e medir várias propriedades estruturais da textura usando um método de multi-resolução espacial. Resultados experimentais, realizados em vários bancos de dados de imagens, indicam que o SASI é mais

bem-sucedido do que os descritores de Filtro Gabor na captura de pequenas granularidades e descontinuidades, como cantos agudos e mudanças abruptas. Devido à flexibilidade em projetar grupos exclusivos de janelas, o SASI atinge taxas de recuperação médias mais altas em comparação com os descritores de Filtro Gabor. No entanto, tem maior complexidade computacional (ÇARKACIOGLU; YARMAN-YURAL, 2001).

#### 2.3.2.5 *Invariant Steerable Pyramid Decomposition* (SID)

O descritor *Invariant Steerable Pyramid Decomposition* (SID), na tradução literal: Decomposição Invariante da Pirâmide Direcionável representa a característica de textura com a decomposição piramidal direcionável. A imagem é decomposta em múltiplas resoluções, subdividida em um conjunto de sub-bandas de escalas e rotações diversas. A princípio a decomposição gera duas sub-bandas com dois filtros passa-baixa e passa-alta ( $L_0$  e  $H_0$ , respectivamente). A banda gerada por  $L_0$  é decomposta recursivamente em  $k - 1$  sub-bandas ( $B_0, \dots, B_{k-1}$ ), resultado da aplicação de filtros passa-banda e uma banda obtida por passa-baixa  $L_1$  (MONTOYA-ZEGARRA; LEITE; TORRES, 2007).

#### 2.3.2.6 *Steerable Mean Standard Deviation* (SMS)

O descritor *Steerable Mean Standard Deviation* (SMS) na tradução literal: Desvio Padrão Médio Dirigível é uma variação do SID. O vetor de características contém a média, o desvio padrão da distribuição de energia das imagens conforme o método SID (MONTOYA-ZEGARRA; LEITE; TORRES, 2007).

### 2.4 CLASSIFICADORES

Os classificadores são responsáveis por separar em classes correspondentes os objetos do sistema. Por exemplo: separar as mudas de pupunha doentes das saudáveis. Qualquer método que incorpore informações de amostras de treinamento no *design* de um classificador emprega aprendizado porque a decisão de classificação de quase todos os problemas práticos de reconhecimento de padrões não são possíveis de prever, sendo necessário o processo de aprendizagem (DUDA; HART; STORK, 2012). A criação de classificadores envolve, então, a apresentação de um modelo de classificador com padrões de treinamento para aprender ou estimar os parâmetros desconhecidos do modelo. A aprendizagem refere-se a algum modelo de algoritmo para reduzir o erro em um conjunto de dados de treinamento (DUDA; HART; STORK, 2012). Os métodos para a classificação podem ser divididos em duas categorias principais (DUDA; HART; STORK, 2012; KUNCHEVA, 2004): aprendizado supervisionado

e não supervisionado. O método de aprendizado supervisionado possui um conjunto de dados rotulados para cada padrão (objeto) em um conjunto de treinamento, utilizados na etapa de testes, para definir qual classe pertence um objeto não rotulado. De maneira usual, é utilizada uma função para verificar a semelhança entre as características do objeto com as amostras da base de treinamento. O método de aprendizado não supervisionado ou agrupamento (*clustering*) possui amostras sem rótulos e o sistema forma *clusters* ou “agrupamentos naturais” dos padrões existentes nas amostras, conforme a similaridade de suas características (DUDA; HART; STORK, 2012; KUNCHEVA, 2004). Para a presente pesquisa foi utilizado o método de aprendizado supervisionado devido as imagens serem rotuladas. A maneira mais típica de treinar um classificador é apresentar uma entrada, computar o rótulo da categoria e usar o rótulo da categoria alvo conhecido para melhorar o classificador.

Um conjunto de dados  $Z$  de tamanho  $N \times n$ , com vetor de características com  $n$  dimensões, descritos por objetos, é utilizado para a construção de um classificador (KUNCHEVA, 2004). É recomendado utilizar a maior quantidade de dados possíveis para construir um classificador, com a maior quantidade dos dados para utilizar nos testes. Caso todos os dados sejam utilizados para treinamento e alguns selecionados para os testes, ocorrerá o excesso de treinamento do classificador. Por isso a importância do classificador possuir conjuntos de dados separados. Existem algumas alternativas para solucionar o problema de treinamento (KUNCHEVA, 2004):

- *R-method* (Resubstituição): Classificador criado em um conjunto e testado no mesmo conjunto;
- *H-method (Hold-out)*: tradicionalmente o conjunto de dados é dividido pela metade, uma para treinamento e a outra para testes de tamanho  $N/K$ . O processo é repetido  $K$  vezes, com um subconjunto diferente para testes em cada iteração. O resultado da classificação é uma média das  $K$  estimativas. Quando  $K = N$  o método é conhecido por *leave-one-out*;
- *Bootstrap*: método utilizado para solucionar a *bias* do método da substituição através da criação randômica de  $L$  conjuntos de cardinalidade  $N$  do conjunto original de dados, com substituição. A média de erros do classificador é calculado para estes conjuntos;
- *Cross-validation* (Validação Cruzada): é definido um inteiro  $K$  (de preferência um fator de  $N$ ) e o conjunto de dados é dividido aleatoriamente em  $K$  subconjuntos.

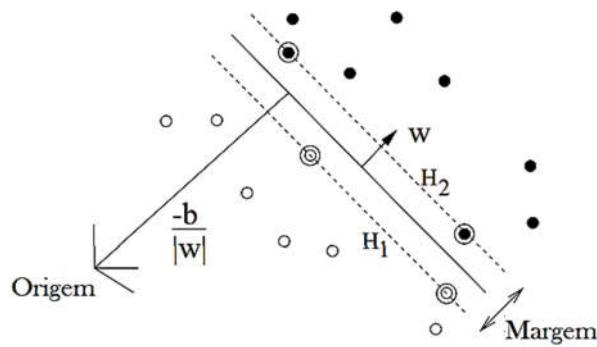
A seleção do método adequado depende do problema, sendo fatores como tamanho da base de dados e performance, levados em consideração para determinar qual método utilizar.

### 2.4.1 Support Vector Machine (SVM)

O Classificador *Support Vector Machine* (SVM) faz o mapeamento de vetores em um espaço de características, podendo ser de alta dimensionalidade, através de um mapeamento não linear, com uma superfície de decisão linear com alta generalização (CORTES; VAPNIK, 1995). Dado um conjunto de amostras rotuladas (duas classes) para treinamento e separáveis linearmente  $\{x_i, y_i\}; i = 1, 2, \dots, l; y_i \in \{-1, +1\}; x_i \in R^d$  em um espaço  $d$ -dimensional. Supõe-se que um hiperplano separe as duas classes. Toda a amostra que esteja no hiperplano satisfaz a equação  $w \cdot x + b = 0$ , onde  $w$  é a normal até o hiperplano e  $b$  é a distância perpendicular da origem até o hiperplano e  $\|w\|$  é a norma Euclidiana de  $w$ .  $d+$  e  $d-$  são a menor distância entre o hiperplano e a amostra positiva e negativa mais próxima, sendo  $d+$  e  $d-$  a margem de separação do hiperplano (BURGES, 1998). O treinamento do SVM busca encontrar um hiperplano que consiga separar as amostras das duas classes da melhor maneira possível. A capacidade de generalização do classificador está diretamente relacionada com o tamanho da margem de separação (DUDA; HART; STORK, 2012). Os dados de treinamento devem satisfazer a restrição  $y_i(x_i \cdot w + b) - 1 \geq 0 \forall i$  (BURGES, 1998). Os pares de hiperplanos com a margem máxima pode ser encontrada minimizando  $\|w\|^2$  satisfazendo a restrição (BURGES, 1998). Os pontos que se encontram sobre os hiperplanos  $H_1$  e  $H_2$  são os vetores de suporte conforme apresentado, circulados, na Figura 10.

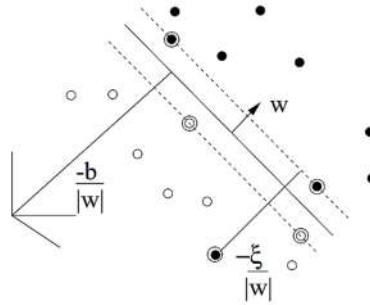
Geralmente algumas amostras passam as fronteiras do seu hiperplano (BURGES, 1998). Para tentar superar esse problema a função de minimização é alterada de  $\|w\|^2$  para  $\|w\|^2/2 + C(\sum_i \xi_i)^k$ , onde  $C$  é um parâmetro definido pelo usuário e que a penalidade para erros é proporcional ao valor de  $C$ , conforme Figura 11.

Figura 10 – Hiperplanos de separação linear. Vetores de suporte circulados



Fonte: Adaptado de Burges (1998)

Figura 11 – Hiperplanos de separação linear para casos não separáveis

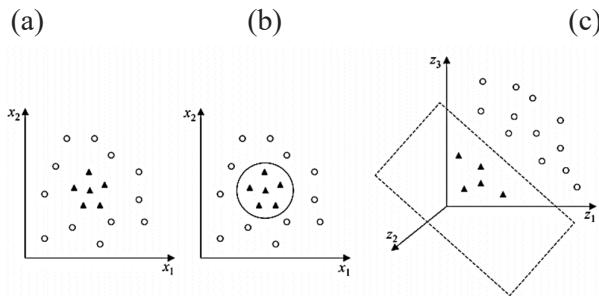


Fonte: Burges (1998)

Em muitos casos não é possível separar as classes de maneira satisfatória através da alteração da função de minimização (BURGES, 1998). Nesses casos a solução pode ser alcançada projetando as características de entrada do espaço  $R^d$  em um novo espaço de características  $H$  de maior dimensionalidade, conforme Figura 12.

Assim o algoritmo de treinamento dependerá somente dos dados dos produtos escalares de  $H$  com funções  $\Phi(x_i) \cdot \Phi(x_j)$  (BURGES, 1998). Utilizando a função de *kernel*, tal que  $K(X_i, X_j) = \Phi(x_i)\Phi \cdot (x_j)$ , apenas será necessário utilizar a constante  $K$  para treinamento do classificador sem necessidade de conhecer  $\Phi$ .

Figura 12 – a) Conjunto de dados não linear no espaço 2-D; b) Fronteira não linear no espaço de entrada; c) Dados projetados do espaço 2-D para um espaço 3-D, produzindo uma fronteira com separação linear



Fonte: Lorena e Carvalho (2007)

#### 2.4.2 Redes Neurais Artificiais

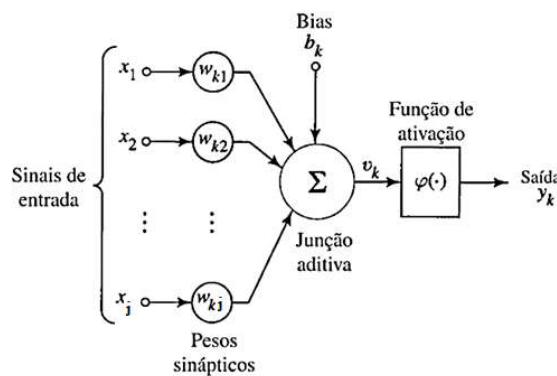
Os trabalhos com Redes Neurais Artificiais (RNA) ou *Artificial Neural Network* têm sido movidos pelo reconhecimento de que o cérebro humano é não-linear e paralelo (HAYKIN,

SIMON, 2001). O cérebro por exemplo realiza de forma rotineira tarefas de reconhecimento perceptivo rapidamente e com grande precisão; tem uma habilidade de aprendizado e, portanto, de generalização. A generalização se refere a produção adequada de saídas, dado entradas não conhecidas, durante o treinamento (aprendizagem). Mas a complexidade de uma rede neural pode ser abstraída através da utilização de engenharia de sistemas, que decompõe um sistema complexo em um número de tarefas relativamente simples (HAYKIN, SIMON, 2001).

Uma RNA oferece as seguintes capacidades e propriedades úteis (HAYKIN, SIMON, 2001): não-linearidade; mapeamento de entrada-saída através do aprendizado supervisionado; adaptabilidade, com a capacidade de adaptar seus pesos sinápticos na mudança do ambiente; resposta a evidências, rejeitando padrões ambíguos; informação contextual, sendo que cada neurônio é potencialmente afetado por todos os neurônios da rede; tolerância a falhas; implementação em *Very-Large-Scale-Integration* (VLSI), sendo um meio de capturar comportamentos complexos de maneira hierárquica; uniformidade de análise e projeto; analogia neurobiológica.

Um neurônio é uma unidade de processamento de informação fundamental para o funcionamento da RNA (HAYKIN, SIMON, 2001). A Figura 13 mostra o modelo de um neurônio, base de projeto para uma RNA. O modelo de um neurônio é formado por três elementos básicos (HAYKIN, SIMON, 2001):

Figura 13 – Modelo não-linear de um neurônio



Fonte: Haykin (2001)

1. Um conjunto de sinapses ou elos de conexão, definidos por um sinal  $x_j$  na entrada da sinapse  $j$  (terminal de entrada da sinapse à qual o peso se refere) conectada ao neurônio  $k$  e multiplicado pelo peso sináptico  $w_{kj}$ ;

2. Um somador que soma os sinais de entrada ponderados pelas sinapses do neurônio (combinador linear);
3. Uma função de ativação que restringe a amplitude de saída de um neurônio.

O modelo do neurônio apresentado na Figura 19 apresenta o *bias*, representado por  $b_k$ . O *bias* tem o efeito de ajustar a função de ativação. Matematicamente um neurônio  $k$  pode ser expresso pelas equações (HAYKIN, SIMON, 2001):

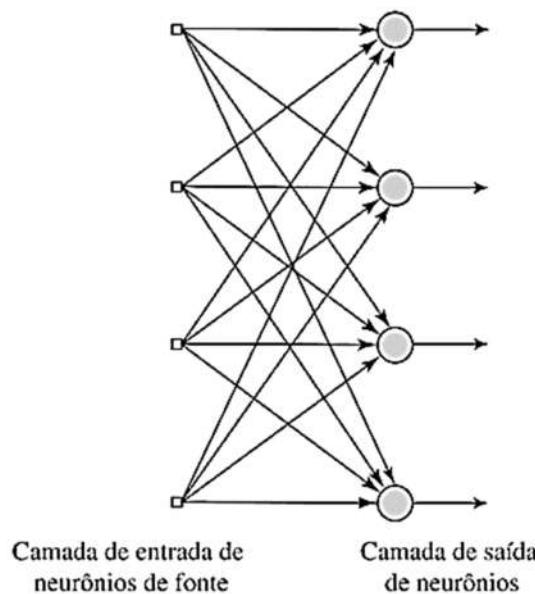
$$u_k = \sum_{j=1}^m w_{kj} x_j \quad y_k = \varphi(u_k + b_k)$$

Onde  $x_1, x_2, \dots, x_m$  são os sinais de entrada;  $w_{k1}, w_{k2}, \dots, w_{km}$  são os pesos sinápticos do neurônio  $k$ ;  $u_k$  é a saída do combinador linear por causa dos sinais de entrada;  $b_k$  é o *bias*;  $\varphi(\cdot)$  é a função de ativação; e  $y_k$  é o sinal de saída do neurônio.

A forma que os neurônios de uma rede neural são estruturados depende do algoritmo de aprendizagem utilizado no treinamento da rede. As classes de arquitetura de rede podem ser apresentadas por (HAYKIN, SIMON, 2001):

1. Redes alimentadas adiante (*feedforward*) com camada única: em uma rede neural em camadas, os neurônios têm a arquitetura em camadas. Na forma mais simples de rede em camadas existe apenas uma camada de entrada que se projeta sobre uma camada de saída de neurônios, mas não vice-versa (acíclica), conforme Figura 14.

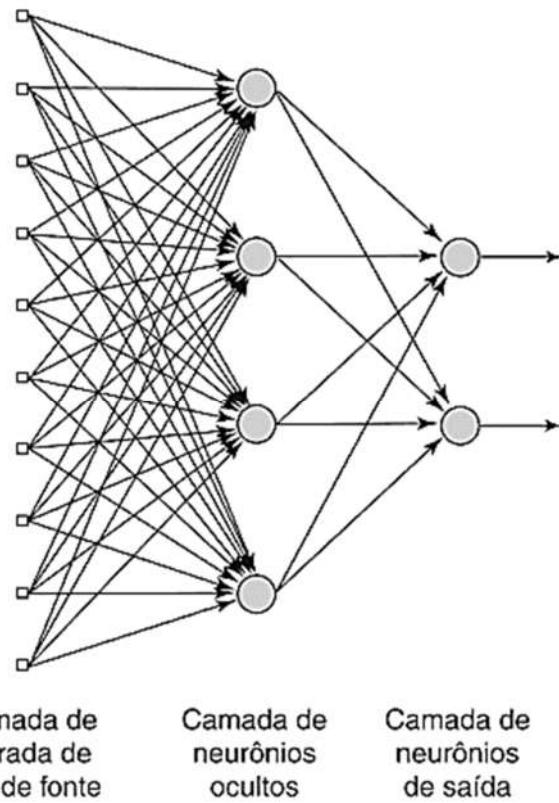
Figura 14 – Rede acíclica com uma única camada de neurônios



Fonte: Haykin (2001)

2. Redes alimentadas diretamente (*feedforward*) com múltiplas camadas: se distingue em relação a rede alimentada adiante com camada única por possuir uma ou mais camadas ocultas, sendo os nós computacionais chamados de neurônios ocultos, conforme apresentado na Figura 15. A adição de camadas ocultas torna a rede capaz de extrair estatísticas de ordem elevada, sendo particularmente utilizado quando o tamanho da camada de entrada tem muitos elementos.

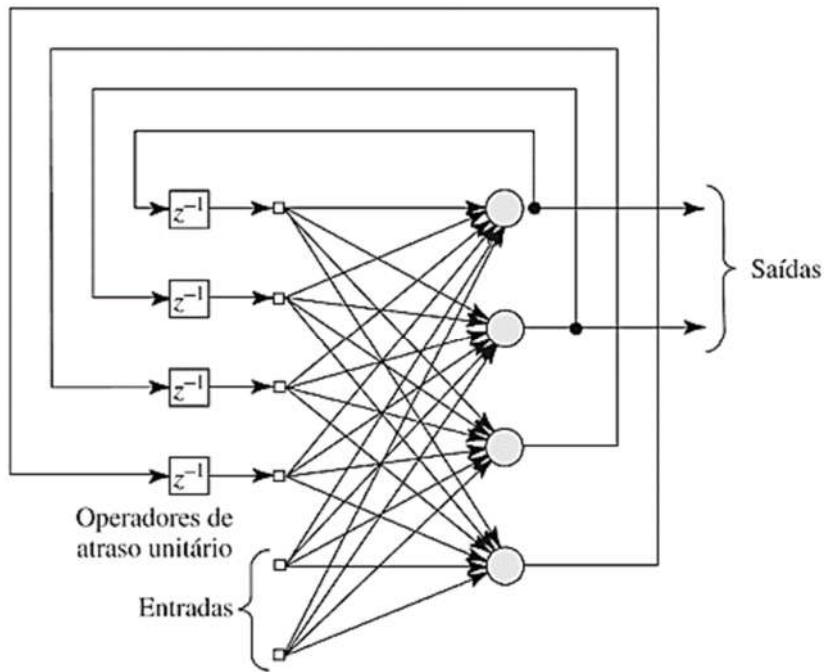
Figura 15 – Rede acíclica totalmente conectada com uma camada oculta e uma camada de saída



Fonte: Haykin (2001)

3. Redes recorrentes: a diferença entre a rede neural acíclica está na presença de pelo menos um laço de realimentação. A presença de laços de realimentação, conforme a Figura 16, tem um impacto significativo na capacidade de aprendizagem da rede e no seu desempenho.

Figura 16 – Rede recorrente com neurônios ocultos



Fonte: Haykin (2001)

O *Multilayer Perceptrons* (MLP) é uma estrutura de rede neural bastante conhecida na literatura. Três pontos destacam os recursos básicos das MLP (HAYKIN, S., 2008):

1. O modelo de cada neurônio na rede inclui uma função de ativação não linear que é diferenciável;
2. A rede contém uma ou mais camadas ocultas dos nós de entrada e saída;
3. A rede exibe um alto grau de conectividade, cuja extensão é determinada pelos pesos sinápticos da rede.

Essas mesmas características, no entanto, também são responsáveis pelas deficiências sobre o comportamento da rede. Em primeiro lugar, a presença de uma forma distribuída de não-linearidade e a alta conectividade da rede tornam difícil a análise teórica de um MLP. Em segundo lugar, o uso de neurônios ocultos dificulta a visualização do processo de aprendizado. Em um sentido implícito, o processo de aprendizagem deve decidir quais características do padrão de entrada devem ser representadas pelos neurônios ocultos. O processo de aprendizado torna-se portanto, mais difícil, porque a pesquisa deve ser conduzida em um espaço muito maior de funções possíveis, e a escolha deve ser feita entre representações alternativas do padrão de

entrada. Um método popular para o treinamento de MLP é o algoritmo de retropropagação (HAYKIN, S., 2008).

O treinamento procede em duas fases (HAYKIN, S., 2008):

1. Na fase direta, os pesos sinápticos da rede são fixos e o sinal de entrada é propagado através da rede, camada por camada, até atingir a saída. Assim, nesta fase, as mudanças estão limitadas aos potenciais de ativação e saídas dos neurônios na rede;
2. Na fase de retorno, um sinal de erro é produzido comparando a saída da rede com uma resposta desejada. O sinal de erro resultante é propagado através da rede, novamente camada por camada, mas desta vez a propagação é realizada na direção inversa. Nesta segunda fase, ajustes sucessivos são feitos nos pesos sinápticos da rede. A avaliação dos ajustes para a camada de saída é simples, mas é muito mais desafiadora para as camadas ocultas.

## 2.5 CONSIDERAÇÕES

Neste capítulo foram apresentados conceitos fundamentais para o embasamento teórico. A extração de características é realizada por descritores que extraem as informações pertinentes da imagem, como detalhes globais de cor e textura, que com o auxílio dos classificadores é possível classificar as imagens nas classes correspondentes. Subsídios teóricos que serão úteis para o entendimento dos trabalhos relacionados e para a seleção das técnicas e para o desenvolvimento deste trabalho de mestrado.

Devido a quantidade e variedade de descritores de cor e textura presentes na literatura é inviável para o presente trabalho testar todas as possíveis combinações. Portanto analisar as tendências na literatura parece ser uma boa alternativa.

### 3 TRABALHOS RELACIONADOS

A busca por trabalhos relacionados foi realizada através de um Mapeamento Sistemático da Literatura (MSL). O MSL busca encontrar o estado da arte para uma área de pesquisa. Com os resultados do MSL foi possível identificar os trabalhos que mais se aproximam do proposto e assim conhecer suas técnicas para servir de guia para a seleção das técnicas e execução dos testes.

#### 3.1 MAPEAMENTO SISTEMÁTICO DA LITERATURA

A realização de um MSL tem o objetivo de determinar como tem sido a aplicação de visão computacional para identificar características e classificar plantas. Para o trabalho foi realizado um MSL que resultou em um artigo científico (PELENS; HUNSELL; SILVA, 2016).

A metodologia seguiu o protocolo proposto por Petersen *et al.* (2008). Os passos essenciais do processo são (PETERSEN *et al.*, 2008): definição das questões da pesquisa, busca nos mecanismos de busca acadêmicos por documentos relevantes, triagem dos documentos para manter apenas os relevantes, criação de palavras-chave para cada definição, extração dos dados e mapeamento sistemático. A questão principal (Passo 1) do MSL foi: “*Como tem sido a aplicação de visão computacional para identificar características e classificar plantas?*”. As questões secundárias foram: “*Quais características das plantas são estudadas? Quais classificações são realizadas? Quais tipos de plantas são abordados nos artigos? Quais técnicas de visão computacional têm sido usadas?*”. A frase de busca utilizada para a pesquisa de trabalhos relevantes nos Mecanismos de Busca Acadêmicos (Passo 2) foi:

**“(Plant? OR Vegetab\* OR Horti\* OR Greenery) AND (“Pattern Recog\*” OR “Image? Pattern?” OR “Computer Vision” OR “Image Processing” OR “Image Analy\*”) AND (Feature? OR Classif\*) AND NOT (Tree? OR GIS OR Fruit? OR Root? OR Seed? OR \*Medical OR Mapping OR Grain? OR Soil)”**

Os MBA utilizados foram: *ACM (dl.acm.org)*; *IEEE Xplore (ieeexplore.ieee.org)* e *Science Direct (sciencedirect.com)*.

A triagem de documentos (Passo 3) utilizou como critério objetivo os trabalhos dos últimos 10 anos, e como critérios de exclusão: aborda árvores, ou sistema de informação geográfica, ou frutas, ou sementes, ou raízes; trabalhos duplicados; trabalho não aborda planta.

Os critérios de inclusão para a realização do mapeamento incluíram: trabalhos com características ou classificações para plantas; com métodos de reconhecimento de padrões, ou computação visual, ou processamento de imagem, ou análise de imagem; apenas pesquisas primárias.

Antes de aplicar os critérios haviam 831 artigos e após o processo de triagem restaram 196 artigos que permaneceram no processo. O Esquema de classificação (Passo 4) é a etapa da criação de palavras-chave para definir o artigo e o contexto da pesquisa, sendo utilizados três enfoques principais: métodos, plantas e objetivos. Os principais métodos de visão computacional utilizados nos artigos foram selecionados, subdividido em dois subgrupos: descritores e classificadores de imagens digitais. Os trabalhos foram separados quanto ao objetivo: “identificação dos tipos de plantas, detecção de uma planta, detecção de doenças, ou nutrição das plantas”.

O objetivo de Reconhecer Planta envolve trabalhos que tem como objetivo principal a separação por espécies; Detectar planta quer encontrar alguma planta específica na imagem; Detectar doença envolvem trabalhos que tenham alguma relação com doenças nas plantas, Nutrição planta busca os trabalhos que envolvem analisar o estado nutricional da planta e Característica Geral agraga todos os trabalhos que não encontram-se nos outros citados.

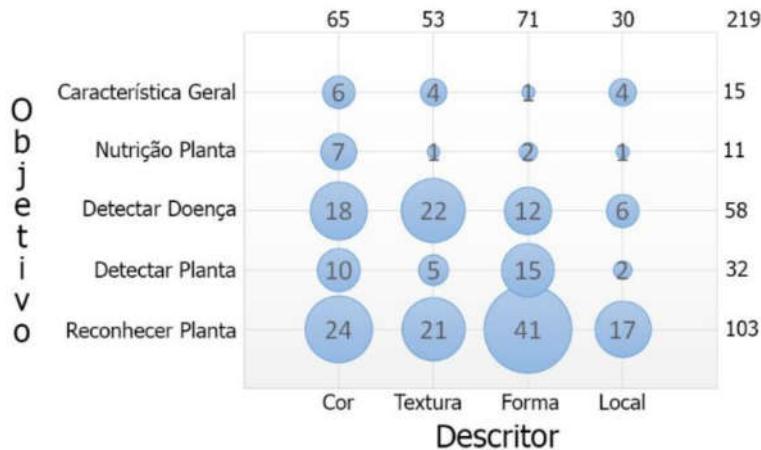
O MSL identificou as principais ferramentas e técnicas para serem utilizadas na tentativa de solucionar o problema proposto (Passo 5). Dentre os descritores de imagens, quando o objetivo do trabalho é detectar doença, existe predominância pela utilização de descritores globais de textura e cor, conforme apresentado na Figura 17. Para a classificação, quando o objetivo do trabalho é detectar doença, os resultados indicam maior utilização dos classificadores SVM e RNA, conforme a Figura 18, quando o objetivo é detectar doença.

A divisão dos trabalhos para os descritores foi geral para o tipo de descritor devido a quantidade de tipos de descritores utilizados pelos trabalhos. O conjunto Descritor Cor agrupa os trabalhos que utilizaram as cores para a extração de características; o Descritor Textura envolve os trabalhos com descritores globais de textura; o Descritor Forma com os trabalhos envolvendo descritores globais de textura e Descritor Local com os trabalhos envolvendo descritores Locais.

Para a divisão dos classificadores, devido a grande quantidade de classificadores o conjunto Classificador Diversos apresenta todos os trabalhos que envolvem um classificador citado em menos de 5 trabalhos; o conjunto Classificador RNA apresenta os trabalhos com

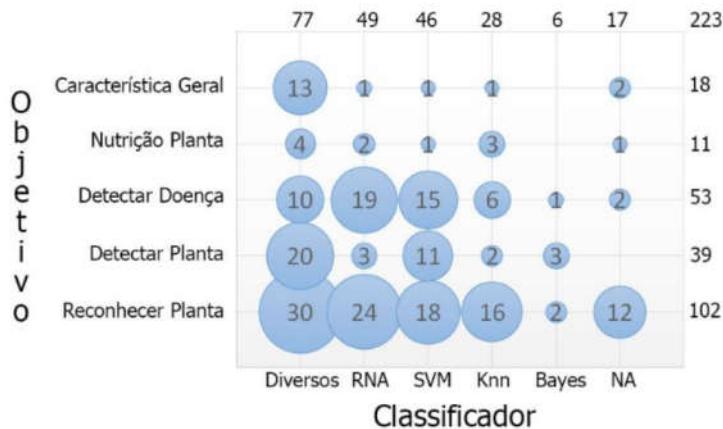
classificadores de Redes Neurais Artificiais; o conjunto Classificador SVM agrupa os trabalhos com a utilização de SVM; o Classificador Knn com todos os trabalhos envolvendo o classificador kNN; o Classificador Bayes com os classificadores Bayesianos e o Classificador NA com os trabalhos que não apresentavam nenhum classificador.

Figura 17 – Resultado do MSL com relação entre o descritor e o objetivo do trabalho



Fonte: (PELLENS; HOUNSELL; SILVA, 2016)

Figura 18 – Resultado do MSL com relação entre o classificador utilizado e o objetivo do trabalho



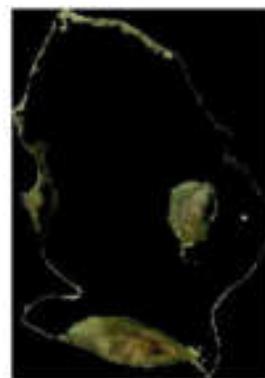
Fonte: (PELLENS; HOUNSELL; SILVA, 2016)

A seguir são apresentados os trabalhos que mais se assemelham ao objetivo do presente trabalho. Foram selecionados os que apresentavam: sintomas de doenças semelhantes as encontradas em mudas de pupunha; os métodos de descrição das imagens e classificação implícitos. Trabalhos com características semelhantes ao problema de detecção de espinhos nos caules, ou classificação entre com/sem espinhos, não foram encontrados no MSL.

### 3.2 APLICAÇÕES DE VISÃO COMPUTACIONAL PARA DETECTAR DOENÇA EM PLANTAS

Bashish, Braik, e Bani-Ahmad (2010) propuseram um sistema para detectar doenças em plantas. O trabalho tem como objetivo classificar cinco tipos de doenças em folhas. Segundo os autores, a detecção de doenças a olho nu realizada por especialistas pode custar caro, especialmente em países desenvolvidos. A proposta de um sistema baseado em processamento de imagem rápido, automático, barato pode ser significativo. Para a segmentação foi utilizado o algoritmo de cluster *Kmeans*<sup>4</sup>, conforme apresentado na Figura 19. Para extrair as características das imagens das plantas foi utilizado o método de Co-ocorrência de cores (*Color Co-occurrence Method*<sup>5</sup>) ou CCM, através do uso de *Spatial Gray-level Dependence Matrices*<sup>6</sup> (SGDM). A imagem RGB foi convertida para o espaço de cor HSI e calculadas as características para H e S, com o canal de intensidade I não utilizado por não apresentar informação extra. O classificador utilizado foi o *Back-Propagation Neural Networks*. A média de acerto após os testes foi de 92,7% para classificar as 6 classes (5 doenças diferentes e a planta sem doença).

Figura 19 – Trabalho de Bashish, Braik, e Bani-Ahmad (2010): Exemplo de detecção de cluster na imagem da folha com *Kmeans*



Fonte: Bashish, Braik, e Bani-Ahmad (2010)

---

<sup>4</sup> *Kmeans*. Fonte: Disponível em: <<http://stanford.edu/~cpiech/cs221/handouts/kmeans.html>>. Acesso em: 12 set. 2018.

<sup>5</sup> *Color Co-occurrence Method* . Fonte: <<https://prism.ucalgary.ca/handle/1880/51900>>. Acesso em: 12 set 2018.

<sup>6</sup> *Spatial Gray-level Dependence Matrices*. Fonte: (HARALICK; SHANMUGAN; DINSTEIN, 1973)

Para os autores Camargo e Smith (2009), a disseminação de doenças é o que motiva o desenvolvimento de sistemas de visão computacional para identificar doenças. Com um sistema é possível identificar os primeiros sintomas das doenças em plantas por amostras de imagens das culturas. O banco de imagens foi composto de 117 imagens da cultura de algodão em diferentes áreas da planta (folhas, fruto e caule): 26 imagens para danos causado por percevejo verde, 60 por danos causados por bactérias, e 31 por vírus, conforme apresentado na Figura 20. As características extraídas das imagens foram: forma, textura, dimensão fractal, caixa de lacunaridade, dispersão, níveis de cinza para os canais RGB e HSV, discriminação do histograma cinza para os canais RGB e HSV, descritor de *Fourier*. Para a classificação utilizou-se SVM. Os testes de classificação foram avaliados por validação cruzada. Para superar problemas de não-linearidade e múltiplas classes foi utilizado o classificador SVM. Quando todas as características foram utilizadas os acertos foram de 90%. Retirando algumas características até atingir o melhor desempenho, foi possível atingir 93,1% de acertos na classificação. Os autores concluem que as medidas de textura podem ser utilizadas como discriminante útil para determinar os tipos de doenças das imagens; e sistemas de aprendizado de máquina podem ser utilizados para identificar sintomas visuais de doenças em plantas, sendo uma aplicação que pode ser utilizada por agricultores e produtores de alimentos em áreas remotas.

Figura 20 – Trabalho de Camargo e Smith (2009): Exemplo de folha de algodão com sintomas visuais de danos causados por 3 tipos de doenças



Fonte: Camargo e Smith (2009)

Rothe e Kshirsagar (2014) propõem um sistema para identificar doenças em folhas de algodão. São 3 doenças com necroses marrons escuras nas folhas, conforme Figura 21. As imagens foram coletadas diretamente dos campos de algodão, na Índia, através de câmeras digitais. Para a extração de características os autores dividiram a imagem em 64 blocos. A

média de cor dos pixels no bloco foi selecionado como cor representante do bloco. O resultado é uma imagem de tamanho 8x8 convertida de RGB para o espaço de cor YCbCr. Foi aplicado uma fórmula DCT (*Discrete Cosine Transform*) para encontrar três conjuntos de 64 coeficientes para luminescência Y, crominância para cada uma das cores azul e vermelho. O resultado são 3 matrizes de tamanho 8x8 representando 64 coeficientes para DCTY, DCTCb e DCTCr. O escaneamento *zigzag*, que converte uma matriz 2D em um vetor 1D, foi executado nesses três conjuntos de 64 DCT, para agrupar os coeficientes de baixa frequência das matrizes 8x8. Esses 3 conjuntos de *zigzag* correspondem aos descritores de cor. A combinação de rede neural com a lógica difusa foi utilizada para a classificação. O resultado da classificação com o método proposto atingiu aproximadamente 95% de acertos.

Figura 21 – Trabalho de Rothe e Kshirsagar (2014): Sintoma de doença em folha de algodão



Fonte: Adaptado de Rothe e Kshirsagar (2014)

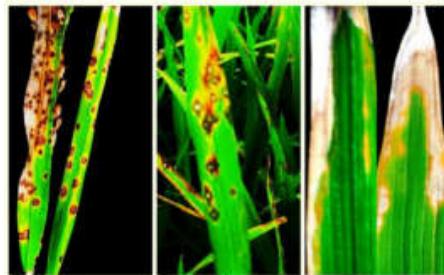
Os autores Orillo *et al.* (2014) propõem um sistema para identificar 3 tipos de doenças do arroz, conforme apresentado na Figura 22, sendo que 2 apresentam manchas marrons escuras (na forma de pintas) e outra apresenta manchas marrons nas extremidades das folhas. O objetivo do trabalho é identificar a doença na planta de arroz com processamento de imagem e redes neurais.

As imagens foram adquiridas através de uma caixa com luz controlada (led branco internos a caixa, com papel difusor da luz para dispersar a luz de forma uniforme). Foram coletadas 134 amostras de imagens (55/37/42 para cada tipo de doença).

Foram aplicados filtros para redução do ruído e do contraste, conversão do espaço de cor de RGB para HSV, bem como o ajuste da intensidade da imagem. A segmentação foi realizada através do método *Otsu's* (OTSU, 1979). Esse método seleciona um limiar automaticamente do histograma de nível de cinza e é caracterizado por ser não paramétrico e não supervisionado. A imagem da folha segmentada foi convertida para o espaço de cor L\*a\*b e o plano da cor a foi utilizado para extrair a “doença”. Quatro características foram extraídas para analisar a doença: fração coberta pela doença na folha, calculada pela divisão da medida da área da doença pela máscara da folha total; média aritmética dos valores de R, G, B das cores

componentes da doença; desvio padrão das cores componentes R, G, B da doença; média dos valores de H, S, V da doença. Essas 4 características foram selecionadas através de análise heurística. A implementação utilizando *BPNN* obteve resultados de 100% de acertos para a identificação das doenças (3 tipos).

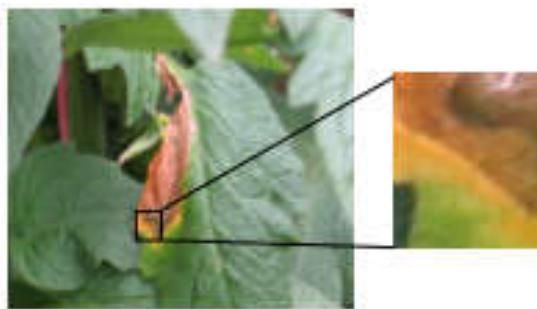
Figura 22 – Trabalho de Orillo et al. (2014): Sintomas visuais de três doenças em folhas de arroz



Fonte: Orillo et al. (2014)

O trabalho de Molina *et al.* (2015) tem como objetivo a detecção automática de infecção de doenças em culturas de tomate, conforme sintomas apresentados na Figura 23, usando uma estratégia de classificação baseada em cores. A base de dados é formada por imagens de plantas saudáveis e doentes, 95 de cada tipo. Para a extração de características das imagens (distribuição de cores na superfície da folha) foi utilizado um subconjunto de descritores padrão MPEG-7: CSD, SCD e CLD. Os descritores CSD e SCD foram testados em 32, 64 e 128 *bin* e o CLD foi testado para 15, 21 e 28 *bin* e o classificador utilizado foi o kNN. CSD64 obteve acurácia de 100%, CSD32 e CSD128 obteve 99%, os demais descritores foram inferiores a 90% de acurácia.

Figura 23 – Trabalho de Molina *et al.* (2015): Exemplo de região de interesse selecionada



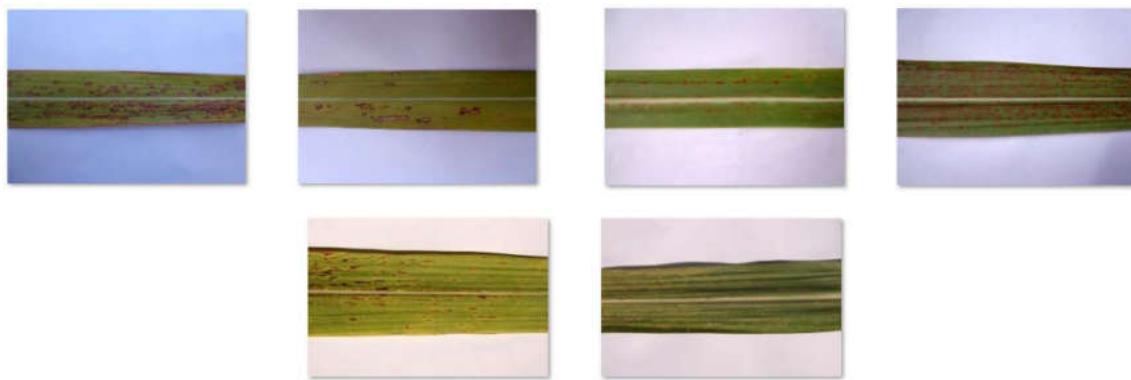
Fonte: Molina *et al.* (2015)

O trabalho de Ratnasari *et al.* (2014) aborda a classificação de doenças em folhas de cana de açúcar. Para a aquisição de dados o trabalho utiliza 30 imagens digitais das folhas de

cana de açúcar para formar a base de dados, para 3 tipos de doenças, com sintomas visuais apresentados na Figura 24. Os autores utilizam a seleção de uma região de interesse (ROI): o sistema precisa selecionar uma área com o máximo de doença. Esta área possui uma janela de 100x100 pixels que move com 50% de área sobreposta na imagem da folha inteira. Para a segmentação foi utilizado o método *Otsu*, que seleciona as manchas das doenças provocadas nas folhas para o canal  $a^*$  do espaço de cor  $L^*a^*b$ . O método utiliza as diferenças entre as variâncias das intensidades dos níveis de cinza para separar o fundo da folha. Após calcular a probabilidade de distribuição, é calculada a média do fundo e da folha.

A estimativa de severidade da doença é a área da lesão das folhas que apresentam sintomas de doença pontual e é mais frequentemente expressa como uma percentagem. A medida é realizada através da quantidade de pixels da área da lesão pela área total da folha a partir da imagem segmentada. Para a extração de características foi utilizado características de cor e textura. Foram testados 4 *kernels* do SVM: linear, quadrático, polinomial de ordem 3 e *Radial Basis Function (RBF)*. O SVM com *kernel* linear atingiu 80% de acertos, com melhor desempenho na classificação, com a combinação de características de cor e textura.

Figura 24 – Trabalho de Ratnasari *et al.* (2014): Exemplos de sintomas visuais de doenças em folhas de arroz



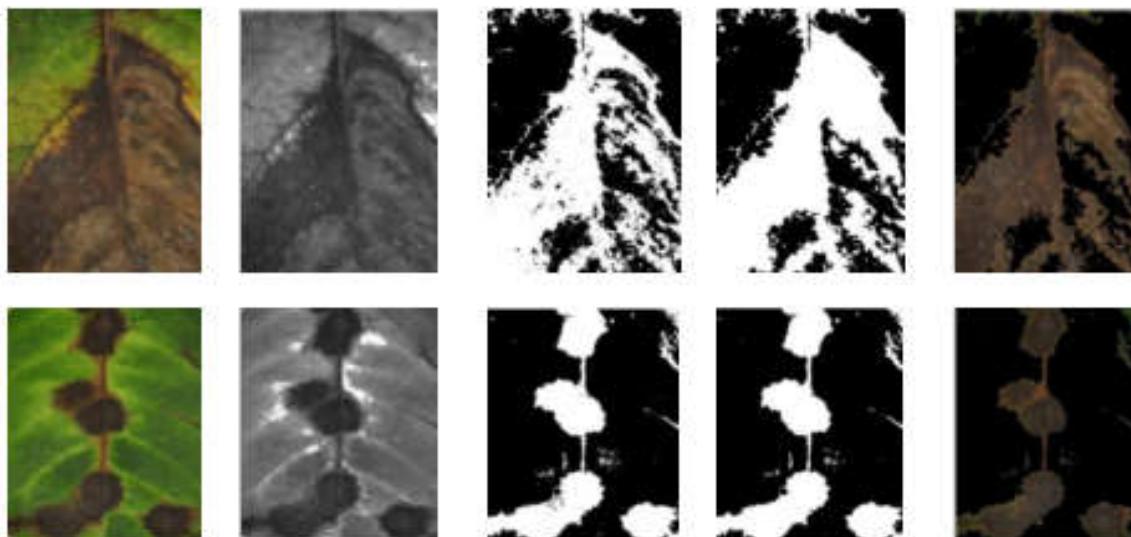
Fonte: Adaptado de Ratnasari *et al.* (2014)

Akhtar *et al.* (2013) realiza um trabalho para identificar o tipo de doença presente em folhas de rosas. As amostras de folhas de rosas doentes foram adquiridas no total de 40 imagens para a base de dados, 20 para cada tipo de doença. A segmentação foi utilizada para separar regiões doentes (ROI) das saudáveis, através do algoritmo *Otsu's* apresentado na Figura 25. O trabalho utilizou 3 diferentes técnicas de extração de características das áreas segmentadas:

*Statistical Features, Discrete Cosine Transform (DCT), e Discrete Wavelet Transform*<sup>7</sup>(DWT).

Para a classificação foram utilizados cinco diferentes técnicas de aprendizado de máquina: kNN; com  $k = 1$ ; SVM, com kernel linear; árvore de decisão, baseado em um conjunto de regras de decisão, ou tabela de decisão, se (condição) então (resultado) através de uma árvore; *Naive Bayesian* (estatístico); e RNA. Várias combinações de características foram testadas. A classificação utilizou validação cruzada com 10 divisões. Na média, Árvore de Decisão obteve o melhor resultado com 91,95% de acertos com DCT, seguido de kNN com 91,85% com DWT e SVM com 90,45% com características de textura. A combinação de características de DCT e DWT obteve um resultado superior aos anteriores com o classificador SVM, atingindo 94,45% de acertos na classificação das doenças.

Figura 25 – Trabalho de Akhtar *et al.* (2013): Exemplo do processo de segmentação da doença



Fonte: Adaptado de Akhtar *et al.* (2013)

Ramakrishnan e Sahaya (2015) realizou um trabalho com 300 imagens, 100 de cada tipo de doença em folhas, com sintomas visuais como os apresentados na Figura 26. No processo de segmentação o formato de cor RGB foi convertido para HSV. A área verde da imagem foi definida como zero, através de um limiar, sendo assim o tempo de processamento é reduzido. A textura da imagem dá informações sobre o arranjo espacial da coloração da imagem, são utilizadas duas maneiras para analisar as texturas: abordagem estrutural e abordagem estatística.

---

<sup>7</sup> *Discrete Wavelet Transform*. Disponível em: <DOI: 10.1049/el:19900766>. Acesso em: 13 set. 2018.

A abordagem estatística é utilizada no trabalho através de matriz de coocorrência. As características extraídas foram: contraste, energia, homogeneidade local, entropia e correlação. A classificação foi realizada com BPNN, para detectar doenças nas folhas. Primeiro a rede é treinada para detectar doença. A rede foi treinada com 90% das imagens de cada tipo, com 10% para os testes. Cerca de 10% das imagens de treinamento foram utilizadas para validação do modelo de classificador projetado. O trabalho obteve 97,41% de acertos.

Figura 26 – Trabalho de Ramakrishnan e Sahaya (2015): Exemplos de doenças nas folhas



Fonte: Adaptado de Ramakrishnan e Sahaya (2015)

### 3.3 DISCUSSÃO

Os trabalhos apresentam base de imagens criadas para tentar solucionar o problema particular, não utilizam bases de imagens públicas. Em sua maioria utilizam poucas imagens de cada classe. Nas buscas por trabalhos similares não foi encontrado trabalhos que envolvessem plantas para a produção de palmito, como a pupunha, utilizada no presente trabalho.

Para a classificação de mudas com e sem espinhos não foi possível identificar trabalhos semelhantes para serem utilizados como referência. Para a classificação de mudas mortas será realizado testes com base nos trabalhos de Bashish, Braik, e Bani-Ahmad (2010), Akhtar *et al.* (2013) e Molina *et al.* (2015) por apresentarem sintomas semelhantes aos das mudas mortas.

## 4 DESENVOLVIMENTO E TESTES

Para alcançar o objetivo do trabalho propõe-se um sistema de classificação de mudas com a aplicação das técnicas levantadas no MSL. As etapas envolvem: a captura das imagens; aplicação de filtros; testes com a combinação de descritores e classificadores; e os resultados alcançados.

O processo de classificação das mudas, em suas respectivas classes, está organizado e apresentado na seguinte ordem:

1. Classificar mudas doentes/saudáveis: para classificar com a máxima porcentagem de acertos foi realizado uma série de experimentos com descritores de cor e textura combinados com classificadores; a classificação com a imagem inteira, descritor CSD e classificador SVM obteve 100% de acertos e tempo para descrição por imagem de 1,10 segundos;

2. Classificar mudas com/sem espinho no caule: Os testes para a classificação foram realizados em diversas combinações de descritores e classificadores, com a alteração do brilho e contraste e aplicação de filtros. A combinação que obteve a maior porcentagem de acertos foi a alteração do brilho (+60%) e contraste (+50%), aplicação do filtro Laplaciano para realçar as bordas dos espinhos, com 96,86% de acertos e desvio padrão de 5,73 com tempo de 0,777 segundos por imagem de processamento para a descrição das imagens;

3. Classificar mudas mortas/vivas: para o teste foi utilizado CSD com SVM e os resultados foram 100% de acertos;

4. Classificar mudas pequenas/grandes: para esse teste foi utilizado uma série de descritores e o classificador SVM com resultado de 97,8% de acertos com o descritor SCD e desvio padrão de 5,04 com tempo para o processamento da descrição de 1,13 segundos por imagem.

### 4.1 BASE DE IMAGENS

Devido à falta de uma base de dados com imagens de mudas de pupunha, fundamentais para o estudo de classificação foi necessário o desenvolvimento de uma base de imagens. Para a captura das imagens foi confeccionada uma caixa iluminada por luz de LED nas laterais e na parte superior conforme apresentado na Figura 27. As luzes foram dispostas fora da caixa. A caixa foi confeccionada com janelas nas laterais e na parte superior cobertas com papel manteiga. As imagens foram obtidas todas da mesma posição. A base de imagens é formada

por fotos de mudas saudáveis e doentes nos tamanhos pequenos e grandes (ideais para o plantio no campo), mudas mortas, mudas com espinhos no caule e sem espinhos no caule.

Figura 27 – Caixa com muda colocada em local padrão utilizado para a captura das imagens para construir o banco de imagens digitais utilizado nos testes



Fonte: Elaborado pelo autor, 2017.

A câmera utilizada para a aquisição das imagens foi uma *Canon EOS DIGITAL REBEL XTi*. A base de imagens é formada por 4 pares de classes distribuídas em: Com/Sem Doença: 100 imagens para cada classe. Dimensão: 2592x3888 pixels. 72 dpi. 24 bits. RGB; Com/Sem Espinhos: 50 imagens para cada classe. Dimensão: 2000x1400 pixels. 72 dpi. 24 bits. RGB; Mortas/Vivas: 200 imagens para cada classe. Dimensão: 1500x2000 pixels. 72 dpi. 24 bits. RGB; Pequenas/Grandes: 50 imagens para cada classe. Dimensão: 2000x2000 pixels. 72 dpi.

24 bits. RGB. A base de imagens encontra-se disponível no link: <[https://1drv.ms/f/s!Ar3grlnHKUf2lQLg\\_jPv6DKsyI5b](https://1drv.ms/f/s!Ar3grlnHKUf2lQLg_jPv6DKsyI5b)>.

## 4.2 CLASSIFICAR MUDAS DOENTES/SAUDÁVEIS

Para determinar a melhor solução para o problema de seleção de mudas com/sem doenças nas folhas das mudas realizaram-se testes com base no estudo dos trabalhos relacionados. Os resultados do estudo de suas técnicas, métodos de captura de imagem, processamento e classificação são apresentados sintetizados na Tabela 1, de acordo com os dados possíveis de serem coletados nos artigos. Os resultados apresentam predominância na utilização dos descritores de textura e cor e classificadores RNA e SVM. Para treinar o SVM nos testes do trabalho foram utilizados dois algoritmos: *Sequential Minimal Optimization*<sup>8</sup> (SMO) com *kernel* linear e *Stochastic Gradient Descent*<sup>9</sup> (SGD) com *kernel* linear.

Tabela 1 – Síntese do MSL dos trabalhos relacionados com doenças em plantas

	Espaço de Cor	L*a*b	16%
Pré-Processamento	Segmentação	Kmeans	25%
	Cor		40%
Descritores	Textura		49%
	RNA		42%
Classificadores	SVM		34%

Fonte: Elaborado pelo autor, 2017.

### 4.2.1 Teste A – Utilizar região de interesse por segmentação por regiões

Os testes têm o objetivo de encontrar a melhor combinação de descritor de imagem e classificador para a correta classificação das imagens, de acordo com sua classe correspondente: doente e saudável. As imagens adquiridas apresentam a muda inteira e como os trabalhos relacionados estudados, exceto o de Ratnasari *et al.* (2014), utilizam segmentações de regiões das folhas, sem deixar implícito no trabalho a técnica utilizada para alcançar esta etapa, decidiu-se por utilizar a segmentação por regiões. O primeiro teste foi baseado em Ratnasari *et al.*

---

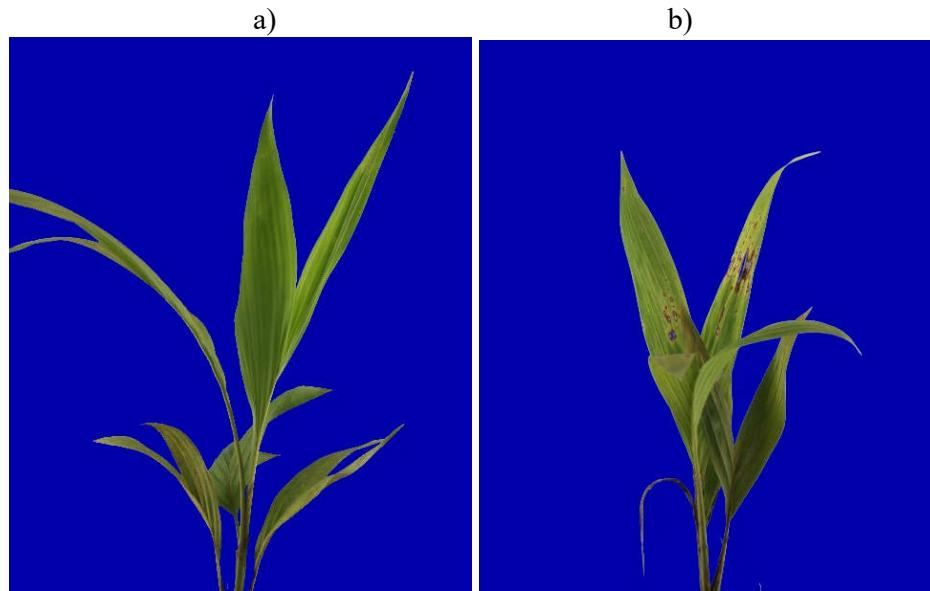
<sup>8</sup> Sequential Minimal Optimization (SMO). Disponível em: <[http://khalilghorbal.info/assets/spa/papers/ML\\_GradDescent.pdf](http://khalilghorbal.info/assets/spa/papers/ML_GradDescent.pdf)>. Acesso em 12 set. 2018.

<sup>9</sup> Stochastic Gradient Descent (SGD). Disponível em: <<http://www.cs.utsa.edu/~bylander/cs6243/smobook.pdf>>. Acesso em 12 set. 2018.

(2014) em que o autor apresenta uma janela que desloca-se sobre a imagem para encontrar a região de interesse (ROI).

A base de dados utilizada nos testes é formada por 125 imagens de mudas saudáveis, conforme Figura 28(a), e 49 imagens de mudas doentes, Figura 28(b). O fundo da imagem, de cor azul, foi eliminado/identificado através de limiarização.

Figura 28 – Exemplo de imagem de muda a) saudável e b) doente para os testes



Fonte: Elaborado pelo autor, 2017.

A segmentação das imagens foi realizada através da movimentação de uma janela sobre toda a área da figura, sem sobreposição. Cada segmento foi salvo em um banco de imagens, conforme exemplos da Figura 29. O tamanho da janela foi obtido através da divisão da imagem por constantes de largura e altura, conforme Tabela 2.

Figura 29 – Exemplo de segmentação de muda saudável com fundo azul menor que 20% da área total: folha com textura sem sinais de doença



Fonte: Elaborado pelo autor, 2017.

Tabela 2 – Constantes de segmentação das imagens

Teste	Divisões da Largura	Divisões da Altura	Largura da Janela ( <i>pixels</i> )	Altura da Janela ( <i>pixels</i> )
A1	15	10	141	255
A2	15	15	141	163
A3	20	15	106	163
A4	25	15	85	163

Fonte: Elaborado pelo autor, 2017.

As janelas com predominância de cor azul foram excluídas da base de dados através da proporção do número de *pixels* azuis em relação a quantidade total de pixels da janela. As imagens com menos de 20% de *pixels* azuis (fundo) foram salvas com o nome da imagem original com o índice relativo da janela salva (Figura 29). Após a segmentação das imagens de mudas doentes, foi realizada uma análise manual para excluir todas as imagens que não apresentavam sinal visual da doença, permanecendo apenas imagens com sintomas visuais, conforme exemplos de sintomas da Figura 30.

Figura 30 – Exemplo de segmentação de muda doente: sintomas da doença com manchas marrons escuras na folha



Fonte: Elaborado pelo autor, 2017.

Para a classificação na classe correspondente foram utilizados os classificadores: RNA (MLP); SVM (SMO); SVM (SGD) e kNN (IBk) com  $k = 3$ . Os testes utilizaram validação cruzada com 10 divisões (*folds*) e 10 repetições dos testes.

A Tabela 3 apresenta o resultado da classificação para a combinação de descritores, classificadores e segmentação das imagens 15/10. Os descritores foram escolhidos por serem descritores de cor e textura em uma tentativa primária de testar o desempenho geral de uma série de descritores. Os testes apresentam melhores resultados de classificação com a utilização de descritor BIC e classificador SVM (SMO); descritor SMS e classificador RNA (MLP) e descritor SMS e classificador SVM (SGD).

Tabela 3 – Teste A1: Resultados da classificação com utilização de segmentação por janelas: segmentos 15/10

Classificador											
SVM (SGD)			SVM (SMO)			kNN			RNA (MLP)		
Descriptor	%	$\sigma$	Descriptor	%	$\sigma$	Descriptor	%	$\sigma$	Descriptor	%	$\sigma$
SMS	91,89	6,46	BIC	92,63	7,81	ACC	90,47	7,42	SMS	92,08	7,22
BIC	91,78	8,31	SMS	90,96	7,34	LBP	83,06	8,23	BIC	90,44	8,24
ACC	90,24	6,63	ACC	90,03	6,19	CSD	80,32	11,48	ACC	89,54	7,92
GCH	89,31	8,49	CSD	87,90	10,35	BIC	80,22	11,79	HTD	86,37	7,53
CSD	87,93	10,75	HTD	85,62	7,25	HTD	79,56	9,60	CSD	85,13	9,86
HTD	87,66	7,24	GCH	85,05	7,04	SASI	78,99	9,53	SASI	84,53	6,99
SASI	86,76	8,29	SASI	84,52	9,02	GCH	78,66	9,32	GCH	83,79	8,23
LBP	83,97	8,66	LBP	83,23	7,36	SMS	74,58	7,61	LBP	81,4	8,15
SID	78,04	12,29	SID	79,00	7,06	SID	69,77	9,89	SID	77,33	8,20

Fonte: Elaborado pelo autor, 2017.

Na Tabela 4 são apresentados os testes com segmentação 15/15. Os testes apresentam melhores resultados pelo percentual de acertos com a utilização de descriptor BIC e classificador SVM (SMO) e descriptor BIC e classificador SVM (SGD).

Tabela 4 – Teste A2: Resultados da classificação com utilização de segmentação por janelas: segmentos 15/15

Classificador											
SVM (SGD)			SVM (SMO)			kNN			MLP		
Descriptor	%	$\sigma$	Descriptor	%	$\sigma$	Descriptor	%	$\sigma$	Descriptor	%	$\sigma$
BIC	96,36	3,62	BIC	96,91	3,37	SMS	87,86	5,78	SMS	95,37	3,74
SMS	95,80	3,80	ACC	95,50	4,57	BIC	87,42	6,29	ACC	94,94	5,30
ACC	94,85	4,23	SMS	94,92	3,97	ACC	91,63	4,77	BIC	94,92	3,78
CSD	93,94	5,21	CSD	91,94	5,69	GCH	79,89	7,97	CSD	91,84	5,34
GCH	86,22	5,95	HTD	84,96	5,88	HTD	82,22	5,49	GCH	85,53	7,74
SID	83,97	7,08	SID	83,88	6,45	SID	72,60	7,11	SASI	81,35	6,09
LBP	84,89	6,77	SASI	83,54	6,51	SASI	76,14	7,14	LBP	82,47	5,74
SASI	84,11	7,37	LBP	82,68	7,19	LBP	78,26	7,21	SID	82,32	6,46
HTD	87,53	6,04	GCH	81,46	4,48	CSD	87,52	5,99	HTD	91,16	5,42

Fonte: Elaborado pelo autor, 2017.

Na Tabela 5 é apresentado os testes com segmentação 20/15. Os testes apresentam melhores resultados em média com a utilização de descriptor BIC e classificador RNA (MLP).

Tabela 5 – Teste A3: Resultados da classificação com utilização de segmentação por janelas: segmentos 20/15

Classificador											
SVM (SGD)			SVM (SMO)			kNN			MLP		
Descriptor	%	$\Sigma$	Descriptor	%	$\sigma$	Descriptor	%	$\sigma$	Descriptor	%	$\sigma$
ACC	92,99	3,35	BIC	92,90	3,30	ACC	88,47	4,12	BIC	93,53	3,57
BIC	92,59	3,73	ACC	92,75	3,57	CSD	88,42	4,22	ACC	92,74	3,91
CSD	92,42	3,88	CSD	88,87	3,84	BIC	87,30	4,44	HTD	87,39	4,49
SMS	87,86	3,52	SMS	87,86	3,43	SMS	83,56	4,33	SMS	87,02	3,76
HTD	86,21	4,82	HTD	84,94	5,79	HTD	80,99	4,81	CSD	86,27	5,76
SID	84,70	5,09	SID	82,50	4,29	GCH	78,87	6,63	GCH	83,13	5,69
GCH	82,34	5,24	SASI	81,94	6,77	LBP	77,23	5,56	SID	82,42	4,80
LBP	81,95	5,68	LBP	80,37	5,64	SASI	76,43	6,77	SASI	82,34	5,80
SASI	81,62	5,82	GCH	79,96	5,57	SID	74,84	5,87	LBP	81,55	4,96

Fonte: Elaborado pelo autor, 2017.

Na Tabela 6 são apresentados os testes com segmentação 25/15. Os testes apresentam melhores resultados pelo percentual de acertos com a utilização de descriptor SMS e classificador RNA (MLP) e com a utilização de descriptor BIC e classificador SVM (SGD).

Tabela 6 – Teste A4: Resultados da classificação com utilização de segmentação por janelas: segmentos 25/15

Classificador											
SVM (SGD)			SVM (SMO)			kNN			MLP		
Descriptor	%	$\sigma$	Descriptor	%	$\sigma$	Descriptor	%	$\sigma$	Descriptor	%	$\sigma$
BIC	95,52	3,03	SMS	94,61	2,64	CSD	92,28	3,56	SMS	95,85	3,12
ACC	95,39	2,42	BIC	94,29	3,29	ACC	90,72	3,23	ACC	95,72	3,37
SMS	94,61	3,22	ACC	93,71	3,35	BIC	88,57	3,68	BIC	94,61	2,92
CSD	93,89	3,35	CSD	91,69	3,81	SMS	88,04	3,37	CSD	91,13	6,66
HTD	89,94	4,81	HTD	88,50	4,42	HTD	83,95	4,51	HTD	89,09	4,87
SID	85,70	5,27	SASI	84,92	5,10	GCH	82,40	4,72	SASI	86,86	3,44
SASI	85,30	5,01	SID	84,09	4,26	SASI	81,99	4,73	GCH	85,06	4,04
GCH	84,87	3,88	GCH	82,93	3,83	SID	79,73	4,28	SID	84,60	5,49
LBP	81,47	5,44	LBP	81,60	5,14	LBP	79,00	5,51	LBP	82,52	5,50

Fonte: Elaborado pelo autor, 2017.

Os resultados apresentam o descriptor BIC combinado com o classificador SVM (SGD) e janela de 15/15 obtendo o melhor resultado na classificação pelo percentual de acertos. A Tabela 7 apresenta os resultados detalhados da configuração de descriptor BIC e classificador SVM (SGD) e segmentos 15/15 com as métricas: VP (Verdadeiro Positivo); FP (Falso Positivo); Precisão; Revocação; F-Measure (Medida F); MCC (Coeficiente de correlação de

Matthews); ROC (*Receiver Operating Characteristic*); PRC (*Precision-Recall Curves*) apresentando maior quantidade de erros na classe de mudas doente.

Tabela 7 – Resultado da classificação final do Teste A, com descritor BIC e classificador SVM (SGD) com base de imagens da segmentação 15/15

Classe	VP	FP	Precisão	Revocação	F-Measure	MCC	ROC	PRC
Saudável	0,985	0,075	0,96	0,985	0,972	0,92	0,955	0,955
Doente	0,925	0,015	0,971	0,925	0,947	0,92	0,955	0,925
Média	0,964	0,054	0,964	0,964	0,963	0,92	0,955	0,944

Fonte: Elaborado pelo autor, 2017.

#### 4.2.2 Teste B – Utilizar imagem inteira

Com o objetivo de tentar retirar o processo de segmentação por janelas, para não haver necessidade de uma seleção manual dos segmentos com sintomas da doença, foi realizado um teste sem o processo de segmentação, um teste com a imagem inteira. A base de dados utilizada nos testes foi formada por 50 imagens de mudas saudáveis e 50 imagens de mudas doentes com resolução de 2126x2126 pixels. A extração de características foi realizada com os descritores de cor: BIC e CSD. O descritor CSD foi utilizado porque em trabalhos relacionados foi alcançado 100% de acertos com sintomas de doenças semelhantes. O classificador utilizado foi SVM (SGD) e SVM (SMO), com configuração padrão. Os testes foram realizados com divisão da base de dados para treinamento e testes com validação cruzada com 10 divisões e 10 repetições. A Tabela 8 apresenta o resultado da classificação com melhor desempenho pelo percentual de acertos para o descritor CSD.

Tabela 8 – Teste B: Resultados da classificação com imagem inteira

Descriptor	SVM (SGD)		Descriptor	SVM (SMO)	
	% acertos	$\sigma$		% acertos	$\sigma$
CSD	88,60	9,21	CSD	91,00	8,35
BIC	87,00	10,40	BIC	89,20	9,29

Fonte: Elaborado pelo autor, 2017.

#### 4.2.3 Teste C – Utilizar imagem inteira e descritores MPEG-7

Bastan et al. (2010) apresenta um aplicativo com implementações de diversos descritores do padrão MPEG7 e utilizado nos novos testes com imagem inteira. A base de dados foi formada por 100 imagens de mudas saudáveis e 100 imagens de mudas doentes, com resolução de  $2126 \times 2126$  pixels. O classificador utilizado foi o SVM (SGD) e SVM (SMO) (configuração padrão). Os testes realizaram-se com validação cruzada com 10 divisões e 10 repetições. A Tabela 9 apresenta o resultado da classificação para cada descritor utilizado na extração de características das imagens, com melhor resultado pelo percentual de acertos obtido com descritor CSD com classificador SVM (SGD).

Tabela 9 – Teste C: Resultados da classificação com descritores MPEG-7

Descriptor	SVM (SGD)		Descriptor	SVM (SMO)		Tempo para descrição por imagem(s)
	% acertos	$\sigma$		% acertos	$\sigma$	
CSD	100,0	0,00	CSD	99,7	1,71	1,10
SCD	82,8	10,16	SCD	85,0	8,93	1,13
HTD	82,2	10,88	HTD	73,2	12,94	0,94
CLD	74,1	12,80	CLD	72,0	12,63	0,88
EHD	66,3	14,61	EHD	66,0	13,26	0,94

Fonte: Elaborado pelo autor, 2017.

### 4.3 CLASSIFICAR MUDAS COM/SEM ESPINHO NO CAULE

Para a realização dos testes nas imagens com/sem espinhos no caule foram selecionados alguns descritores de cor e textura para verificar o comportamento destes descritores. Alguns testes foram realizados conforme segue:

#### 4.3.1 Teste A – Utilizar descritores de cor e textura e classificador SVM

Para o primeiro teste da classe de mudas com (Figura 31 (a)) e sem espinhos (Figura 31 (b)) no caule foram utilizadas as imagens nas dimensões redimensionadas de  $2000 \times 1400$  pixels (original) para  $1000 \times 700$  pixels, sem aplicação de filtros (imagem original), com a utilização de uma série de descritores selecionados para um primeiro teste preliminar para verificar o desempenho de alguns descritores de textura, cor e forma; com 50 imagens de cada classe.

A Tabela 10 apresenta os resultados dos testes com os melhores resultados de classificação das imagens pelo percentual de acertos obtidos pelos descritores CSD e EHD com 10 divisões e 10 repetições dos testes.

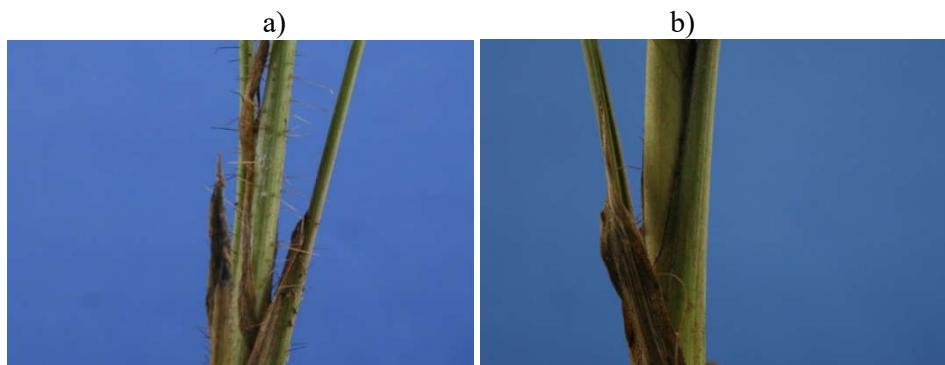
Tabela 10 – Teste A: resultados da classificação dos testes em mudas de pupunha com/sem espinhos.

Descriptor	Classificador SVM				Tempo para descrição por imagem(s)	
	SGD		SMO			
	% acertos	$\sigma$	% acertos	$\sigma$		
CSD	85,8	9,34	89,3	8,68	0,21	
EHD	85,7	10,75	86,3	9,81	0,14	
SCD	75,4	13,66	79,5	11,75	0,20	
HTD	61,4	16,14	60,2	11,80	0,18	
CLD	60,4	12,86	60,2	14,42	0,15	

Fonte: Elaborado pelo autor, 2017.

Um teste foi realizado com a dimensão das imagens de 2000x1400 pixels (original) para verificar o desempenho e com a aplicação do descritor CSD com o classificador SVM (SGD). O resultado foi de 85,30% de acertos com desvio padrão de 10,77; e com o classificador SVM(SMO) foi de 88,70% de acertos com desvio padrão de 10,22. Com isso, alterando a resolução das imagens, houve diferença de 0,5% de acertos para menos em média para o classificador SVM (SGD) e 0,4% para menos para o classificador SVM (SMO), com leve aumento no desvio padrão para ambos os classificadores. O tempo de processamento em média por imagem para a extração de características (descrição) foi de no máximo 0,21 segundos por imagem para o descritor CSD.

Figura 31 – Exemplo de imagem com a) e sem b) espinho no caule



Fonte: Elaborado pelo autor, 2017.

#### 4.3.2 Teste B – Alterar brilho e contraste das imagens

Considerando que a qualidade da imagem, como o brilho e contraste, influencia os resultados de classificação de imagens, foi proposto um teste com alterações no contraste e brilho da imagem e a aplicação dos descritores CSD e EHD com a utilização dos classificadores SVM (SGD e SMO) para tentar melhorar os resultados do TESTE A, com 50 imagens de cada classe na resolução de 1000x700 pixels. A Tabela 11 mostra que a alteração de brilho influencia os resultados na classificação. A configuração de 60% de acréscimo de Brilho e 50% de acréscimo de Contraste nas imagens com a utilização do Descritor CSD e o classificador SVM (SGD) obteve o melhor resultado de classificação pelo percentual de acertos com 94,9% de acertos e desvio padrão de 6,89.

Tabela 11 – Teste B: resultados da classificação dos testes em mudas de pupunha com/sem espinhos com alterações no brilho e contraste das imagens

Brilho	Contraste	SVM (SGD)				SVM (SMO)			
		CSD		EHD		CSD		EHD	
% adicional	% adicional	% acertos	$\sigma$						
0	0	85,8	9,34	85,7	10,75	89,3	8,68	86,3	9,81
30	30	85,9	10,26	87,4	10,88	83,8	10,42	86,1	10,81
50	40	82,5	11,75	87,3	10,72	80,7	10,75	87,0	10,40
50	50	89,3	9,77	89,2	9,92	91,4	8,53	90,5	8,21
55	50	93,3	7,39	89,7	9,37	93,0	6,89	90,7	9,24
60	50	94,9	6,89	88,4	10,02	93,3	7,92	90,4	8,40
60	60	89,2	7,48	87,7	10,62	88,2	10,48	88,4	9,18
70	60	89,7	8,58	86,7	10,83	89,2	9,07	88,9	9,73

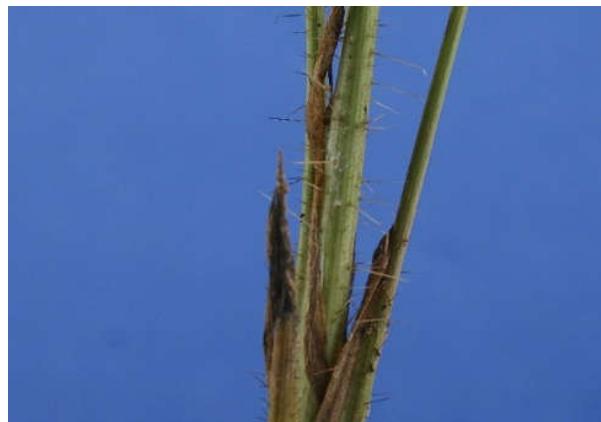
Fonte: Elaborado pelo autor, 2017.

#### 4.3.3 Teste C – Utilizar filtro Laplaciano para realçar borda dos espinhos

Para realçar a borda dos espinhos, conforme apresentado na Figura 32, foi utilizado o filtro Laplaciano (GONZALEZ; WOODS, 2010), na tentativa de que com definição nas bordas a descrição das imagens pudesse ser auxiliada. Para o teste foram utilizados as imagens nas dimensões originais de 2000x1400 pixels, sem aplicação de filtros, com 50 imagens de cada classe.

A Tabela apresenta o resultado de classificação com a utilização do filtro Laplaciano nas imagens e a combinação do descritor SVM (SMO) com o classificador CSD obtiveram o melhor resultado da classificação pelo percentual de acertos, mas inferiores ao Teste B.

Figura 32 – Exemplo de imagem sem espinho no caule com filtro Laplaciano



Fonte: Elaborado pelo autor, 2018.

Tabela 12 – Teste C: resultados da classificação dos testes em mudas com/sem espinhos com filtro Laplaciano.

Descriptor	Classificador SVM				Tempo para descrição por imagem(s)	
	SGD		SMO			
	% acertos	$\sigma$	% acertos	$\sigma$		
CSD	88,46	9,13	92,02	8,52	0,646	
EHD	89,56	8,40	90,02	8,65	0,5858	
SCD	84,91	11,26	85,14	11,07	0,697	
HTD	62,24	13,21	65,04	14,42	0,4545	
CLD	57,83	14,80	60,67	14,71	0,484	

Fonte: Elaborado pelo autor, 2017.

#### 4.3.4 Teste D – Combinação de alteração de brilho e contraste com filtro Laplaciano

Devido aos resultados do Teste C serem superiores ao Teste A foi testada uma combinação entre o Teste B (brilho e contraste) e Teste C (filtro Laplaciano). Para o teste foi utilizado as imagens nas dimensões de 2000x1400 pixels, com 50 imagens de cada tipo com acréscimo de 60% de brilho e 50% de contraste e aplicação de filtro Laplaciano. A Tabela 13 apresenta o resultado da classificação pelo percentual de acertos, superior aos testes anteriores.

Tabela 13 – Teste D: Combinar alteração de brilho e contraste com filtro Laplaciano

Descriptor	Classificador SVM				Tempo para descrição por imagem(s)	
	SGD		SMO			
	% acertos	$\sigma$	% acertos	$\sigma$		
CSD	96,86	5,73	94,86	7,24	0,777	

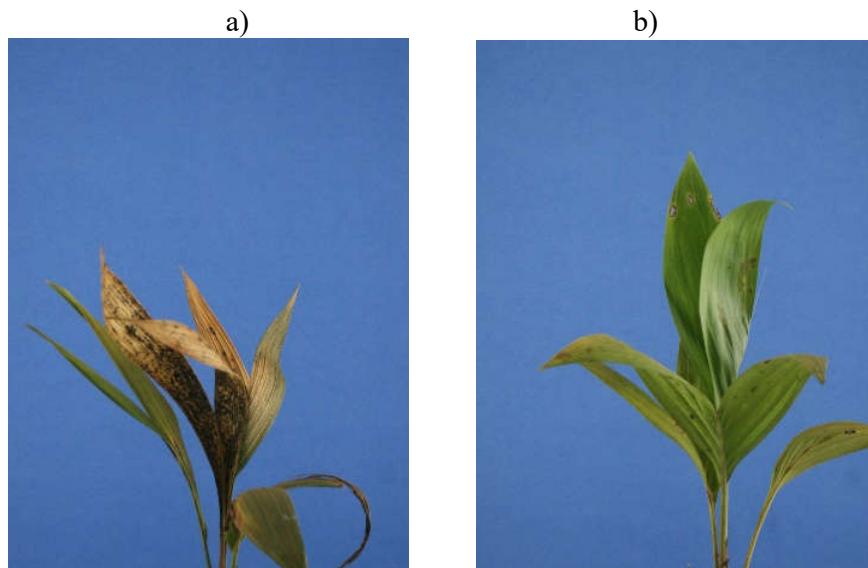
Fonte: Elaborado pelo autor, 2017.

Um teste com a dimensão das imagens redimensionadas para 1000x700 pixels foi realizado com o descriptor CSD para testar se a influência da resolução pudesse melhorar o resultado. O resultado foi de 94,03% de acertos com SVM (SGD) e desvio padrão de 7,20 e 93,83% de acertos para o SVM (SMO) e desvio padrão de 7,58, sendo que nessa combinação de filtros a resolução menor diminui a percentagem de acertos na classificação das imagens com/sem espinhos e aumenta o desvio padrão.

#### 4.4 CLASSIFICAR MUDAS MORTAS/VIVAS

A classificação da classe de mudas mortas (Figura 33 (a)) e vivas (Figura 33 (b)) foi realizada com o descriptor de cor CSD devido as mudas apresentarem sinais visíveis de diferença na estrutura das cores entre as classes. O teste foi realizado com a utilização de 200 imagens de mudas mortas e 200 vivas na resolução de 1500x2000 pixels, sem aplicação de filtros (imagem original).

Figura 33 – Exemplo de imagem de muda: a) morta e b) viva, utilizadas nos testes



Fonte: Elaborado pelo autor, 2017.

O resultado dos testes (Tabela 14), com a utilização dos classificadores SVM (SGD e SMO), obtiveram 100% de acertos com o tempo médio de processamento para o processo de descrição, por imagem, de 0,834 segundos.

Tabela 14 – Teste em mudas de pupunha mortas/vivas com descritor CSD e classificadores SVM

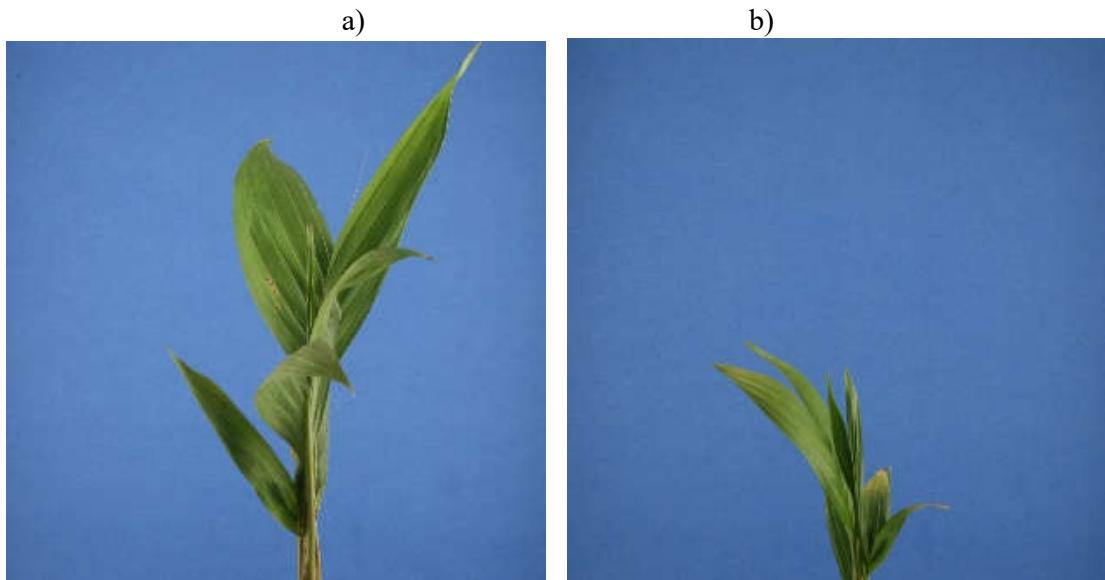
Descriptor	Classificador SVM				Tempo para descrição por imagem(s)	
	SGD		SMO			
	% acertos	$\sigma$	% acertos	$\sigma$		
CSD	100,0	0,0	100,0	0,0	0,834	

Fonte: Elaborado pelo autor, 2017.

#### 4.5 CLASSIFICAR MUDAS PEQUENAS/GRANDES

O teste da classe de mudas pequenas (Figura 34 (a)) e grandes (Figura 34(b)) foi realizado com 50 imagens para cada classe com resolução de 2000x2000 pixels.

Figura 34- Exemplo de imagem de muda a) grande e b) pequena utilizadas nos testes



Fonte: Elaborado pelo autor, 2017.

O resultado da classificação (Tabela 15) apresenta a combinação do descritor SCD com o classificador SVM (SGD) como a melhor opção pelo percentual de acertos, dentre as propostas, para a classificação das mudas pequenas e grandes.

Tabela 15 – Teste com mudas pequenas/grandes com descritores MPEG e classificadores SVM

Descriptor	Classificador SVM				Processamento por imagem (s)	
	SGD		SMO			
	% acertos	$\sigma$	% acertos	$\sigma$		
SCD	97,8	5,04	94,4	8,33	1,13	
HTD	97,0	5,41	96,1	5,10	0,77	
CLD	95,9	6,37	96,5	6,26	0,85	
CSD	94,5	6,87	95,3	6,58	1,10	
EHD	94,0	6,67	94,0	7,65	0,80	

Fonte: Elaborado pelo autor, 2017.

A classificação poderia ser realizada através da proporção pixels fundo/planta, mas devido a algumas mudas grandes (Figura 35 (a)) terem o tamanho semelhantes ao tamanho das mudas pequenas (Figura 35(b)), pela posição da rotação da muda no momento da aquisição das imagens, foi descartada a possibilidade e também devido ao resultado anterior.

Figura 35- Exemplo de imagem de muda a) grande e b) pequena semelhantes



Fonte: Elaborado pelo autor, 2017.

#### 4.6 DISCUSSÃO

O desenvolvimento e testes através da utilização do MSL como base para a busca do estado da arte relacionado ao tema da pesquisa, resultou tanto na base fundamental para a seleção dos descritores e classificadores quanto para o sucesso na classificação de mudas doentes/saudáveis e mortas/vivas, com porcentagem de classificação máxima. Para a classificação de mudas com/sem espinhos no caule não foi possível a utilização do MSL, por não terem sido identificados trabalhos similares, mas, mesmo sem trabalhos similares a este problema, foi possível encontrar uma combinação entre descritor, brilho e contraste, e

classificador mostrando que a alteração do brilho e contraste na imagem pode alterar significativamente os resultados. Os testes combinados com o filtro Laplaciano obtiveram os melhores resultados de classificação. A classificação entre mudas pequenas e grandes não é um problema crítico para o cliente, uma vez a muda apenas terá um porte inferior, diferente do caso da muda estar morta, com espinho em que o cliente descarta a muda, ou doente em que a muda corre o risco de morrer, caso não for tratada, por isso o presente trabalho não procurou melhorar os resultados da classificação nesta categoria.

## 5 CONCLUSÃO

O reconhecimento de padrões é aplicado na agricultura em várias espécies para melhorar os processos de inspeção visual nas plantas. A aquisição das imagens tem um fator de impacto fundamental nos resultados da classificação, sendo que imagens com foco bem ajustado, iluminação adequada, influenciam a qualidade da imagem e posteriormente influenciam na descrição da imagem para a aquisição das características e minimizam erros de classificação. O presente trabalho envolve a tentativa de classificar mudas de pupunha para a produção de palmito.

A realização de um MSL subsidiou o trabalho com a identificação geral das técnicas. Foi possível através do MSL realizar os testes, principalmente para a classificação entre as mudas doentes/saudáveis, com segurança de não estar apenas de forma aleatória selecionando as técnicas, mas partindo de um longo estudo na literatura, com uma varredura minuciosa dos trabalhos da área em questão, com um estudo teórico dos principais trabalhos encontrados.

O agronegócio pode se beneficiar com o auxílio da visão computacional para solucionar, melhorar, agilizar diversos processos agrícolas, na identificação precoce de doenças na lavoura, através de imagens capturadas por *drones*, ou outra forma de captura conforme a necessidade. Trabalhos já estão sendo desenvolvidos, mas muitas culturas ainda não têm trabalhos realizados, como por exemplo o presente trabalho que aborda uma área particular e específica que é a fabricação de mudas de pupunha.

### 5.1 DISCUSSÃO

Devido aos trabalhos relacionados utilizarem, em sua maioria, segmentação das áreas doentes, foi proposto, a princípio, testes com segmentação por janelas sem sobreposição, mas devido a seleção dos segmentos com doença serem manuais, e pelos resultados já apresentarem bons resultados, considerando a quantidade de segmentos por imagem, foram testados combinações de descritores e classificadores com a imagem inteira. A aplicação do descritor de cor CSD, nas imagens inteiras, que possui a característica de encontrar estruturas de cor espalhadas por uma imagem, foi responsável, com a combinação do classificador SVM, por 100% de acertos na classificação das mudas de pupunha grandes (doentes/saudáveis), prontas para serem comercializadas. Devido ao fato do descritor CSD criar os elementos estruturantes e as cores serem agrupadas em, por exemplo 128 *bins*, e devido ao método realizar a quantificação unitária de cada faixa de cores para cada *bin*, a influência de cada pinta da doença

é significativa para as características extraídas das cores da folha, uma vez que folhas sem doença apresentam uniformidade de cor tendendo ao verde (natural da folha sem doença).

Para os testes em mudas de pupunha com e sem espinhos no caule foram realizados testes com descritores de cor e textura devido ao fato de, nas buscas de trabalhos relacionados, não ter sido encontrados trabalhos similares. Foram realizados testes com opções de descritores de cor e textura. O descritor de cor CSD obteve o melhor resultado de classificação combinado com o classificador SVM (SMO), com 89,3% de acertos, com desvio padrão de 8,68. Com a alteração de brilho e contraste e a combinação do descritor CSD com o classificador SVM (SGD), resultou em 94,9% de acertos e desvio padrão de 6,89, com tempo médio de processamento, processo de descrição por imagem, de 0,21 segundos. Um teste para tentar aumentar a nitidez da saliência das bordas foi realizado com a aplicação do filtro Laplaciano e os resultados combinados com o descritor CSD e classificador SVM (SMO), obtiveram 92,02% de acertos com desvio padrão de 8,52. Combinados os testes de filtro Laplaciano com alteração de brilho e contraste combinados com descritor CSD e classificador SVM (SGD) o resultado foi superior, atingindo 96,86% de acertos com desvio padrão de 5,73.

Para os testes em mudas de pupunha saudáveis/mortas foram realizados testes com a utilização dos classificadores SVM (SGD) e SVM (SMO) e descritor CSD, por apresentarem sintomas visuais nas folhas semelhantes a trabalhos relacionados, com 100% de acertos na classificação com zero de desvio padrão e tempo médio de processamento por imagem, para o processo de descrição, de 0,834 segundos.

Para o teste de classificação das mudas em pequenas e grandes, foram também selecionados uma série de descritores de cor e textura, com melhor resultado para o descritor SCD com o classificador SVM (SGD), com resultado de 97,8% de acertos e desvio padrão de 5,04, com tempo para o processo de descrição de 1,13 segundos para cada imagem.

## 5.2 RESULTADOS

Os trabalhos futuros podem automatizar o processo de seleção de mudas com a aplicação em um viveiro de mudas, com uma esteira que direciona as mudas para um estúdio de captura da imagem digital, que classifica as mesmas e as direciona ao local específico para cada tipo de muda: pequena, grande (pronta para ser comercializada), doente, com espinho, morta. A classificação de mudas com/sem espinhos pode ser melhorada com o estudo de outras alternativas que não foram elencadas neste trabalho, principalmente no estudo de descritores de

forma, ou na construção de um descritor específico para o problema, com isso melhorar a qualidade das mudas recebidas pelo cliente, uma vez que ao receber uma muda com espinho o cliente terá que descartá-la, por ser inviável para o plantio, manchando a imagem do viveiro fornecedor das mudas. Os resultados do trabalho podem ser sintetizados em: um artigo de Mapeamento Sistemático da Literatura publicado em evento internacional; base de imagens de mudas de pupunha disponível; processo de descrição e classificação de doença em plantas de pupunha com 100% de acertos; processo para classificação de mudas com/sem espinhos no caule com 96,86% de acertos; processo para a classificação de mudas mortas/vivas com 100% de acertos; processo de classificação de mudas pequenas/grandes com 97,8% de acertos.

## REFERÊNCIAS

- AHMED, Nasir; NATARAJAN, T.; RAO, Kamisetty R. Discrete Cosine Transform. *Computers, IEEE Transactions on*, v. C-23, n. 1, p. 90–93, 1974.
- AKHTAR, Asma *et al.* Automated Plant Disease Analysis (APDA): Performance Comparison of Machine Learning Techniques. *2013 11th International Conference on Frontiers of Information Technology*, p. 60–65, 2013.
- AL BASHISH, Dheeb; BRAIK, Malik; BANI-AHMAD, Sulieman. A framework for detection and classification of plant leaf and stem diseases. *Proceedings of the 2010 International Conference on Signal and Image Processing, ICSIP 2010*, p. 113–118, 2010.
- ALVES, Eliseu; DA SILVA E SOUZA, Geraldo; ROCHA, Daniela De Paula. Lucratividade da Agricultura. *Revista de Política Agrícola*, v. 21, n. 2, p. 45–63, 2012.
- BERNAL, J; VILARINO, F; SANCHEZ, J. Feature Detectors and Feature Descriptors: Where We Are Now. *Computer Vision Center and Computer Science Department UAB Campus UAB*, p. 112, 2010.
- BROSNAN, Tadhg; SUN, Da-wen. Inspection and grading of agricultural and food products by computer vision systems - a review. *Computers and Electronics in Agriculture*, v. 36, n. 2, p. 193–213, 2002.
- BURGES, Christopher J. C. A tutorial on support vector machines for pattern recognition. *Data Mining and Knowledge Discovery*, v. 2, n. 2, p. 121–167, 1998.
- CAMARGO, A.; SMITH, J. S. Image pattern classification for the identification of disease causing agents in plants. *Computers and Electronics in Agriculture*, v. 66, n. 2, p. 121–125, 2009.
- CARDOSO, Josiane Teresinha. A Mata Atlântica e sua conservação. *Revista Encontros Teológicos*, v. 31, n. 3, p. 441–458, 2016.
- ÇARKACIOGLU, A.; YARMAN-YURAL, F. SASI: a new texture descriptor for content based image retrieval. 2001, [S.l.: s.n.], 2001. p. 137–140. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=958443>>.
- CORTES, Corinna; VAPNIK, Vladimir. Support-Vector Networks. *Machine Leaming*, v. 20, n. 3, p. 273–297, 1995.
- CUBERO, Sergio *et al.* Advances in Machine Vision Applications for Automatic Inspection and Quality Evaluation of Fruits and Vegetables. *Food and Bioprocess Technology*, v. 4, n. 4, p. 487–504, 2011.
- DUDA, Richard O.; HART, Peter E.; STORK, David G. *Pattern classification*. New York, USA: John Wiley & Sons, 2012.
- GAZZONI, Décio Luiz. *Documentos 344: a sustentabilidade da soja no contexto do agronegócio brasileiro e mundial*. 1. ed. Londrina, PR: Embrapa Soja, 2013.

GOMES, Juliana Freitas Santos; LETA, Fabiana Rodrigues. Applications of computer vision techniques in the agriculture and food industry: A review. *European Food Research and Technology*, v. 235, n. 6, p. 989–1000, 2012.

GONZALEZ, Rafael C.; WOODS, Richard C. *Processamento digital de imagens*. 3. ed. [S.l.]: Pearson, 2010.

GUYON, Isabelle *et al.* *Feature extraction: foundations and applications (studies in fuzziness and soft computing)*. New York, USA: Springer, 2008. v. 207.

HARALICK, Robert; SHANMUGAN, K.; DINSTEIN, I. Textural features for image classification. *IEEE Transactions on Systems, Man and Cybernetics*, v. 3, p. 610–621, 1973.

HAYKIN, S. *Neural Networks and Learning Machines*. 3. ed. Ontario, Canadá: Prentice Hall, 2008.

HAYKIN, Simon. *Redes neurais: princípios e prática*. 2. ed. Ontário, Canada: Bookman Editora, 2001.

HUANG, Jing *et al.* Image indexing using color correlograms. 1997, [S.l.]: IEEE, 1997. p. 762–768.

IBGE. Produção agrícola municipal: culturas temporárias e permanentes. v. 37, 2011.

JAHNE, Bernd; HAUBECKER, Horst. *Computer vision and applications: a guide for students and practitioners*. San Diego, California: Academic Press, 2000.

KUNCHEVA, Ludmila I. *Combining pattern classifiers: methods and algorithms*. New Jersey: John Wiley & Sons, 2004.

LORENA, Ana C.; DE CARVALHO, André C.P.L.F. Uma introdução às Support Vector Machines. *Revista de Informática Teórica e Aplicada*, v. 14, n. 2, p. 43–67, 2007.

MANJUNATH, B S *et al.* Color and Texture Descriptors. 2001, [S.l.: s.n.], 2001. p. 703–715.

MARCONI, Maria; LAKATOS, Eva. *Fundamentos de metodologia científica*. 7. ed. São Paulo: Atlas, 2003.

MESSING, Dean .S.; BEEK, Peter Van; ERRICO, James H. The MPEG-7 colour structure descriptor: image description using colour and local spatial information. 2001, Thessaloniki, Greece: IEEE, 2001. p. 670–673.

MOLINA, Juan F. *et al.* Automatic detection of early blight infection on tomato crops using a color based classification strategy. *2014 19th Symposium on Image, Signal Processing and Artificial Vision, STSIVA 2014*, v. 1, p. 1–5, 2015.

MONTOYA-ZEGARRA, Javier A; LEITE, Neucimar J; TORRES, Ricardo S. Rotation-invariant and scale-invariant steerable pyramid decomposition for texture image retrieval. 2007, [S.l.: s.n.], 2007. p. 121–128.

NEVES, Edinelson José Maciel *et al.* *Circular técnica 143: cultivo da pupunheira para palmito nas regiões Sudeste e Sul do Brasil*. 1. ed. Colombo: Embrapa Florestas, 2007.

- NIXON, Mark S.; AGUADO, Alberto S. *Feature Extraction and Image Processing*. Massachusetts (EUA): Newnes, 2002.
- NOGUEIRA, Oscar Lameira *et al.* *A Cultura da Pupunha*. 1. ed. Belém, PA: EMBRAPA-SPI, 1995.
- OJALA, Timo; PIETIKÄINEN, Matti; MÄENPÄÄ, Topi. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 24, n. 7, p. 971–987, 2002.
- ORILLO, John William *et al.* Identification of diseases in rice plant (*oryza sativa*) using back propagation Artificial Neural Network. *2014 International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management, HNICEM 2014 - 7th HNICEM 2014 Joint with 6th International Symposium on Computational Intelligence and Intelligent In*, n. November 2013, 2014.
- OTSU, Nobuyuki. A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, v. 9, n. 1, p. 62–66, 1979.
- PAGET, Rupert; LONGSTAFF, Dennis. Texture synthesis via a non-parametric markov random field. *IEEE Transactions on Image Processing*, v. 7, n. 6, p. 925–931, 1998.
- PELENS, Marco Aurelio; HOUNSELL, Marcelo da Silva; SILVA, André Tavares Da. Técnicas de visão computacional para identificação e classificação de plantas: um mapeamento sistemático da literatura. *IV Conferência Ibero Americana Computação Aplicada. CIACA 2016*, p. 252–260, 2016.
- PETERSEN, Kai *et al.* Systematic mapping studies in software engineering. *12th International Conference on Evaluation and Assessment in Software Engineering*, 2008.
- PLATANIOTIS, Konstantinos N.; VENETSANOPoulos, Anastasios N. *Color Image Processing and Applications*. Berlin: Springer, 2000.
- RAMAKRISHNAN, M.; SAHAYA, Anselin Nisha A. Groundnut leaf disease detection and classification by using back propagation algorithm. *2015 International Conference on Communication and Signal Processing, ICCSP 2015*, p. 964–968, 2015.
- RATNASARI, Evy Kamilah *et al.* Sugarcane leaf disease detection and severity estimation based on segmented spots image. *Proceedings of 2014 International Conference on Information, Communication Technology and System, ICTS 2014*, p. 93–98, 2014.
- RESENDE, Josane Maria *et al.* *Palmito de Pupunha in Natura e em Conserva Palmito de Pupunha in Natura e em Conserva*. 1. ed. Brasília, DF: Embrapa Informação Tecnológica, 2009.
- RIBEIRO, Sérgio Silva. *Métodos computacionais aplicados à agricultura: Python & Weka*. Guarapuava, PR: Perse, 2016.
- ROTHER, P. R.; KSHIRSAGAR, R. V. Automated extraction of digital images features of three kinds of cotton leaf diseases. *2014 International Conference on Electronics, Communication and Computational Engineering, ICECCE 2014*, p. 67–71, 2014.

- SANTOS, Alvaro Figueredo Dos *et al.* Circular técnica 146: manejo fitossanitário em viveiros de palmeiras para palmito. Colombo, PR: Embrapa Florestas, 2007.
- SHAPIRO, Linda; STOCKMAN, George. *Computer Vision*. Washington, EUA: [s.n.], 2000. v. 9.
- STEHLING, Renato O; NASCIMENTO, Mario A; FALCÃO, Alexandre X. A Compact and efficient image retrieval approach based on Border / Interior pixel Classification. 2002, [S.l.]: ACM, 2002. p. 102–109.
- SWAIN, Michael J; BALLARD, Dana H. Color Indexing. *International Journal of Computer Vision*, v. 7, p. 11–32, 1991.
- WANG, H *et al.* Application of neural networks to image recognition of plant diseases. 2012 *International Conference on Systems and Informatics, ICSAI 2012*, n. Icsai, p. 2159–2164, 2012.
- WON, Chee Sun; PARK, Dong Kwon; PARK, Soo Jun. Efficient use of MPEG-7 edge histogram descriptor. *ETRI Journal*, v. 24, n. 1, p. 23–30, 2002.
- ZANELLA, Tamara Pereira; LEISMANN, Edison Luiz. Abordagem da sustentabilidade nas cadeias de commodities do agronegócio brasileiro a partir de sites governamentais. *Revista Metropolitana de Sustentabilidade*, v. 7, n. 2, p. 6–19, 2017.