

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

UM MODELO DE VISÃO COMPUTACIONAL PARA IDENTIFICAÇÃO DO ESTÁGIO
DE MATURAÇÃO E INJÚRIAS NO PÓS-COLHEITA DE BANANAS (*Musa sapientum*)

Érika Sayuri Tezuka

SÃO CARLOS
Setembro/ 2009

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

UM MODELO DE VISÃO COMPUTACIONAL PARA IDENTIFICAÇÃO DO ESTÁGIO
DE MATURAÇÃO E INJÚRIAS NO PÓS-COLHEITA DE BANANAS (*Musa sapientum*)

Érika Sayuri Tezuka

Dissertação de Mestrado Apresentado ao
Programa de Pós-Graduação em Ciência
da Computação da Universidade Federal
de São Carlos, como parte dos requisitos
para obtenção do Título de Mestre em
Ciência da Computação.

Orientador: Prof. Dr. Paulo E. Cruvinel

SÃO CARLOS
Setembro/ 2009

**Ficha catalográfica elaborada pelo DePT da
Biblioteca Comunitária da UFSCar**

T356mv

Tezuka, Érika Sayuri.

Um modelo de visão computacional para identificação do estágio de maturação e injúrias no pós-colheita de bananas (*Musa sapientum*) / Érika Sayuri Tezuka. -- São Carlos : UFSCar, 2009.
163 f.

Dissertação (Mestrado) -- Universidade Federal de São Carlos, 2009.

1. Visão por computador. 2. Processamento de imagens.
3. Textura. 4. Pós-colheita. I. Título.

CDD: 006.37 (20^a)

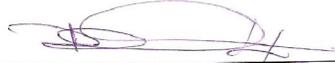
Universidade Federal de São Carlos
Centro de Ciências Exatas e de Tecnologia
Programa de Pós-Graduação em Ciência da Computação

**“Um Modelo de Visão Computacional para
Identificação do Estágio de Maturação e Injúrias
no Pós Colheita de Bananas (*Musa sapientum*)”**

ÉRIKA SAYURI TEZUKA

Dissertação de Mestrado apresentada ao
Programa de Pós-Graduação em Ciência da
Computação da Universidade Federal de São
Carlos, como parte dos requisitos para a
obtenção do título de Mestre em Ciência da
Computação

Membros da Banca:



Prof. Dr. Paulo Estevão Cruvinel
(Orientador - EMBRAPA/Instrumentação
Agropecuária)



Prof. Dr. José Hiroki Saito
(DC/UFSCar)



Prof. Dr. Maurício Fernando Lima Pereira
(UFMT)

São Carlos
Setembro/2009

Dedico este trabalho
aos meus pais pela
força, oportunidade e
apoio incondicional e
ao meu namorado pelo
amor e compreensão.

Agradecimentos

Aos meus pais por esta oportunidade, pelo incentivo e apoio incondicional nesta etapa da minha vida.

Ao meu orientador Prof. Dr. Paulo Estevão Cruvinel, por acreditar em mim, e me ajudar a alcançar o meu objetivo.

Ao meu namorado Fernando Alexandre Parra Garoso, pela sua cumplicidade, seu amor, apoio e dedicação em me ajudar a superar os obstáculos e conquistar este sonho.

À minha companheira de mestrado Ana Paula de Oliveira Santa, pelas discussões e convivência que me ajudaram a concluir este trabalho.

Ao Prof. Dr. Paulo Sérgio de Paula Herrmann Junior (Embrapa Instrumentação Agropecuária de São Carlos) e ao Prof. Dr. José Hiroki Saito (UFSCar/ Departamento de Computação), pelas críticas e sugestões apresentadas durante o exame de qualificação.

Aos Colegas Leonardo Castro Botega, Marcos Antonio de Matos Laia e Francisco de Assis Scannavino Junior, pelo apoio e incentivo.

Aos colegas de mestrado em Ciência da Computação turma 2007 que acreditaram na conclusão deste trabalho.

Ao programa de pós-graduação do departamento de computação da Universidade Federal de São Carlos (PPG-CC/UFSCar), à Embrapa Instrumentação Agropecuária (São Carlos/ SP).

“Perder tempo em aprender coisas
que não interessam, priva-nos de
descobrir coisas interessantes.”

Carlos Drummond de Andrade

RESUMO

Este trabalho apresenta o desenvolvimento de um sistema de visão computacional para análise de bananas (*Musa sapientum*), em estágio de pós-colheita, utilizando técnicas de processamento digital de imagens. Para o desenvolvimento foram consideradas as etapas de aquisição das imagens, pré-processamento, identificação baseada em textura, classificação em níveis de maturação e a obtenção do percentual de manchas marrons e injúrias. A validação foi desenvolvida considerando padrões geométricos gerados em laboratório, bem como considerando frutas reais. A obtenção do mapa de textura viabilizou a identificação da existência de manchas marrons ou injúrias em uma região da imagem. A avaliação método de classificação em nível de maturação foi realizada considerando os resultados obtidos com observadores humanos e visão computacional. A média da taxa de acerto dos observadores foi de 50% e a taxa de acerto da visão computacional foi de 100%. Além disso, os resultados da análise de manchas marrons e injúrias indicam uma taxa de acerto de 80,40% para manchas marrons em imagem de banana individual, 97,70% para manchas marrons em imagem de penca de bananas, 97,80% para injúrias em imagem de banana individual e 75,30% para injúrias em imagem de pencas. Adicionalmente, o desempenho global do sistema motiva a aplicação desta metodologia para avaliação da qualidade dos frutos no pós-colheita de bananas.

Palavras-chave: Visão computacional, Análise de textura, Processamento digital de imagens, Pós-colheita.

ABSTRACT

This dissertation presents the development of a computer vision system for bananas (*Musa sapientum*) analysis in post-harvest stage based on digital image processing techniques. The development used considerations about image acquisition, pre-processing, identification based on texture, percentage of brown spots and injuries on the fruits and classification of its maturity levels. The validation has been developed considering geometric patterns generated in laboratory, as well as real fruits. With the texture map it was possible to identify the existence of brown spots or injuries in a specific region of the images. The assessment of the level of maturation was performed considering both human observers and the computer vision system. The average of identification level of maturity was equal to 50% for human observers and 100% for computer vision. The results show identification rates of 80.40% for brown spots on the single image of banana, 97.70% for brown spots on the images of bundle of bananas, 97.80% for injuries for the set of single image of banana, and 75.30% for hand injuries considering the images of bundle of bananas. Besides, the method presents application for quality assessing of fruits in the post-harvest procedures.

Keywords: Computer vision, Texture analysis, Digital image processing, Post-harvesting.

Lista de Abreviaturas

A/D: Analógico/Digital

APS: Active-Pixel Sensor – sensores de Pixel Ativo

BP-ANN: *Back Propagation Artificial Neural Network*

CCD: *Charge Coupled Device*

CLG: *Color Layer Growing*

CMOS: *Complementary Metal-Oxide-Semiconductor*

CSC: *Color Structure Code*

CVE: Coeficiente de Variação Espacial

Embrapa: Empresa Brasileira de Pesquisa Agropecuária

FDH: *Fourier-Domain Holographic* – Domínio de Fourier Holográfico

FT-NIR: *Fourier Transform Near Infrared* – Transformada de Fourier do Infravermelho Próximo

HPLC: Cromatografia Líquida de Alta Eficiência

HSI: Modelo de cores que utiliza *Hue, Saturation e Intensity* – Matiz, saturação e intensidade

IBGE: Instituto Brasileiro de Geografia e Estatística

IBRAF: Instituto Brasileiro de Frutas

IPM: *Image Processing Method* – Método de Processamento de Imagens

IR: *Infrared* – Infravermelho

NIR: *Near Infrared* – Infravermelho Próximo

OFP: *Organization Feature Parameter* – Organização dos Parâmetros Característicos

PCA: *Principal Component Analysis* – Análise dos Componentes Principais

PF: *Feature Parameter* – Parâmetros Característicos

PLS: *Partial Least Square* – Mínimo Quadrado Parcial

PLSDA: *Partial Least Squares Discriminant Analysis* – Mínimo Quadrado Parcial da Análise Discriminante

RGB: Modelo de cores que utiliza Red, Green e Blue – Vermelho, verde e azul

RMN: *Nuclear Magnetic Resonance* - Ressonância Magnética Nuclear

RMSECV: *Root Mean Square Error of Cross-Validation* – Raiz Quadrada dos Erros Médios de Validação

SVM: *Support Vector Machine* – Máquina de Vetores de Suporte

TCP/ IP: *Trasmission Control Protocol/ Internet Protocol* – Protocolo de Controle de Transmissão/ Protocolo de Rede

WDM: *Water Displacement Method* – Método de Deslocamento de Água

Lista de Figuras

Figura 1 - Quantidade de frutas produzidas no Brasil em toneladas nos anos de 2003 a 2007 (Fonte: IBGE 2009).....	7
Figura 2 - Valor da produção de frutas no Brasil nos anos de 2003 a 2007 (Fonte: IBGE 2009).....	7
Figura 3 - Área plantada com frutas no Brasil nos anos de 2003 a 2007 (Fonte: IBGE 2009)..	8
Figura 4 - Rendimento médio de frutas no Brasil nos anos de 2003 a 2007 (Fonte: IBGE 2009).....	8
Figura 5 - Produção brasileira de frutas por região (Fonte: IBGE 2009).....	9
Figura 6 - Quantidade de banana produzida no ano de 2007 (Fonte: IBGE 2009).	10
Figura 7 - Valor de produção da banana no ano de 2007 (Fonte: IBGE 2009).....	11
Figura 8 - Área de banana plantada no ano de 2007 (Fonte: IBGE 2009).	11
Figura 9 - Rendimento médio da banana no ano de 2007 (Fonte: IBGE 2009).....	12
Figura 10 – Modo de apresentação da banana: (a) Dedo (1 fruto), (b) Buquê (2 a 9 frutos) e (c) Penca (10 ou mais frutos) (PBMH e PIF, 2006).....	14
Figura 11 – Defeitos graves em banana: (a) Ponta de charuto, (b) Podridão, (c) Amassado, (d) Dano por sol, (e) Dano profundo, (f) Passado, (g) Maturação precoce e (h) Infestação por praga (traça-da-banana) (PBMH e PIF, 2006).....	15
Figura 12 – Defeitos leves em banana: (a) Ausência de dedos, (b) Desenvolvimento diferenciado, (c) Germinado, (d) Restos florais e (e) Descoloração da casca (PBMH e PIF, 2006).....	16
Figura 13 – Defeitos variáveis em banana: (a) Abelha arapuá, (b) Ácaro de ferrugem, (c) Látex, (d) Fuligem, (e) Tripes de erupção, (f) Tripes de ferrugem e (g) Dano mecânico superficial (PBMH e PIF, 2006).....	17
Figura 14 – Imagem por computador: visão computacional e processamento de imagens.	19

Figura 15 – Uma vizinhança 3×3 ao redor de um ponto de coordenadas (x, y) em uma imagem.	21
Figura 16 – (a) Imagem Original (USC-SIPI <i>Image Database</i> , 1971), (b) Resultado da aplicação do filtro de média na imagem original.	22
Figura 17 – (a) Imagem Original (USC-SIPI <i>Image Database</i> , 1971), (b) Resultado da aplicação do filtro de mediana na imagem original.....	23
Figura 18 – (a) Imagem Original (USC-SIPI <i>Image Database</i> , 1971), (b) Histograma da imagem original.....	26
Figura 19 – (a) Imagem Original (USC-SIPI <i>Image Database</i> , 1971), (b) Histograma da imagem equalizada.	26
Figura 20 – (a) Imagem original (USC-SIPI <i>Image Database</i> , 1971), (b) Resultado obtido com o filtro detecção de <i>pixel</i> na imagem original.....	28
Figura 21 – (a) Imagem Original (USC-SIPI <i>Image Database</i> , 1971), (b) Resultado da aplicação do filtro vertical na imagem original e (c) Resultado da aplicação do filtro horizontal na imagem.	29
Figura 22 – (a) Imagem Original (USC-SIPI <i>Image Database</i> , 1971), (b) Resultado obtido com a aplicação do filtro Laplaciano na imagem original.....	31
Figura 23 – (a) Imagem original (USC-SIPI <i>Image Database</i> , 1971), (b) Imagem Limiarizada.	32
Figura 24 – Métodos de Análise de Texturas (Ribeiro Jr, 1995), adaptado de (JAIN, 1989)..	36
Figura 25 – Algoritmo para o agrupamento de primitivas de textura.	39
Figura 26 – Espectro visível da luz solar, demonstrando por decomposição que esta é formada por um conjunto de radiações visíveis que vão do vermelho ao violeta.	40
Figura 27 – Representação tridimensional das cores no sistema RGB e CMY.	41
Figura 28 – (a) Triângulo de cores HSI; (b) Sólido de cores HSI.....	43
Figura 29 - Eixos principais do tensor de inércia de um objeto para rotação em torno do centro de massa (JÄHNE, 1997).	47

Figura 30 – Estrutura de um sistema de visão computacional (MARQUES e NETO, 1999)..	51
Figura 31 – Diagramas em blocos do método de visão computacional para inferência da qualidade de frutas.....	74
Figura 32 – Algoritmo de identificação de manchas marrons e injúrias através da textura para a visualização da existência de manchas marrons e injúrias.	76
Figura 33 – Algoritmo para classificação de bananas em estágios de maturação baseado em cor.....	78
Figura 34 – Algoritmo para determinação do percentual de manchas marrons ou injúrias.	79
Figura 35 – Tela do sistema desenvolvido para identificação de manchas, injúrias e classificação da banana em estágio de maturação.....	81
Figura 36 – Tela do sistema de visão computacional: caixa de diálogo Abrir, que é ativada ao se pressionar o botão <Abrir Imagem> para que a imagem de entrada seja selecionada.	83
Figura 37 – Tela do sistema de visão computacional: Imagem de entrada selecionada na caixa de diálogo Abrir.....	83
Figura 38 – Tela do sistema de visão computacional: seleção da região de interesse para obtenção do mapa de textura.	84
Figura 39 – Tela do sistema de visão computacional: Região de interesse recortado para obtenção do mapa de textura.	84
Figura 40 – Tela do sistema de visão computacional: Representação da imagem na componente S para obtenção do mapa de textura.....	85
Figura 41 – Tela do sistema de visão computacional: Mapa de textura da imagem recortada e representada na componente S.	85
Figura 42 – Tela do sistema de visão computacional: Objeto de interesse segmentado.....	86
Figura 43 – Tela do sistema de visão computacional: Classificação da banana em estágio de maturação.	86
Figura 44 – Tela do Sistema com as áreas de injúrias selecionadas.....	87

Figura 45 – Tela do sistema: somente com as áreas de injúrias.....	87
Figura 46 – Tela do sistema com os resultados do processamento da imagem para gerar o relatório.....	88
Figura 47 – Relatório gerado pelo sistema exibido no navegador de internet padrão do sistema operacional.	88
Figura 48 – Escala de maturação de Von Loesecke (PBMH e PIF, 2006).....	90
Figura 49 – Paleta de cores, de verde a amarelo.	91
Figura 50 – Cores de níveis de maturação: (a) Estágio de maturação nível 1, (b) Estágio de maturação nível 2, (c) Estágio de maturação nível 3, (d) Estágio de maturação nível 4, (e) Estágio de maturação nível 5, (f) Estágio de maturação nível 6, (g) Estágio de maturação nível 7.....	91
Figura 51 – Imagens da forma círculo (1), nível de maturação 7, geradas para a validação do algoritmo para identificação de manchas marrons e injúrias, (a) Imagem círculo (1) com tom de marrom R=26, G=22 e B=22 e (b) Imagem círculo (1) com tom de marrom R=217, G=115 e B=41.	93
Figura 52 - Imagens da forma elipse (1), nível de maturação nível 7, geradas para a validação do algoritmo para identificação dos manchas marrons e injúrias, (a) Imagem elipse (1) com tom de marrom R=26, G=22 e B=22 e (b) Imagem elipse (1) com tom de marrom R=217, G=115 e B=41.	93
Figura 53 - Imagens da forma círculo (2), nível de maturação 7, geradas para a validação do algoritmo para identificação dos manchas marrons e injúrias, (a) Imagem círculo (2) com tom de marrom R=26, G=22 e B=22 e (b) Imagem círculo (2) com tom de marrom R=217, G=115 e B=41.	94
Figura 54 - Imagens da forma elipse (2), nível de maturação 7, geradas para a validação do algoritmo do mapeamento da área de risco, (a) Imagem elipse (2) com tom de marrom R=26, G=22 e B=22 e (b) Imagem elipse (2) com tom de marrom R=217, G=115 e B=41.	94
Figura 55 – Exemplos de imagens com formas geométricas compostas, nível de maturação 7: (a) Imagem com círculos em tons de marrom R=26, G=22, B=22 e R=128, G=87, B=57, (b)	

Imagem com elipses em tons de marrom R=26, G=22 e B=22 e R=128, G=87, B=57, (c) Imagem com círculos e elipses com os mesmos tons de marrom do item a e b..... 95

Figura 56 – Exemplos de representação da imagem: (a) Imagem Original, (b) Representação na componente H, (b) Representação na componente S e (c) Representação na componente I. 96

Figura 57 – Exemplos de imagem original e sua representação na componente S, nível de maturação 7: (a) Imagem original com círculo (1) em tom de marrom R=26, G=22, B=22, (b) Representação da imagem original na componente S, cujo valor do círculo é 38, (c) Imagem original com círculo (1) em tom de marrom R=128, G=87, B=57, e (d) Representação da imagem original na componente S, cujo valor do círculo é 206. 97

Figura 58 – Exemplos de imagem original e sua representação na componente S, nível de maturação 7: (a) Imagem original com elipse (1) em tom de marrom R=26, G=22, B=22, (b) Representação da imagem original na componente S, cujo valor do círculo é 38, (c) Imagem original com elipse (1) em tom de marrom R=128, G=87, B=57, e (d) Representação da imagem original na componente S, cujo valor do círculo é 206. 98

Figura 59 – Exemplos de imagem original e sua representação na componente S, nível de maturação 7: (a) Imagem original com círculo (2) em tom de marrom R=26, G=22, B=22, (b) Representação da imagem original na componente S, cujo valor do círculo é 38, (c) Imagem original com círculo (2) em tom de marrom R=128, G=87, B=57, e (d) Representação da imagem original na componente S, cujo valor do círculo é 206. 99

Figura 60 – Exemplos de imagem original e sua representação na componente S, nível de maturação 7: (a) Imagem original com elipse (2) em tom de marrom R=26, G=22, B=22, (b) Representação da imagem original na componente S, cujo valor do círculo é 38, (c) Imagem original com elipse (2) em tom de marrom R=128, G=87, B=57, e (d) Representação da imagem original na componente S, cujo valor do círculo é 206. 100

Figura 61 - Comparação dos valores de textura utilizando medida de contraste..... 101

Figura 62 – Comparação dos valores de textura utilizando a medida de entropia..... 102

Figura 63 – Comparação dos valores de textura utilizando medida de SMA..... 102

Figura 64 – Comparação dos valores de textura utilizando medida de contraste..... 103

Figura 65 – Comparação dos valores de textura utilizando medida de entropia.....	104
Figura 66 – Comparação dos valores de textura utilizando medida de SMA.	104
Figura 67 – Comparação dos valores de textura utilizando medida de contraste.....	105
Figura 68 – Comparação dos valores de textura utilizando medida de entropia.....	106
Figura 69 – Comparação dos valores de textura utilizando medida de SMA.	106
Figura 70 - Comparação dos valores de textura utilizando medida de contraste.....	107
Figura 71 – Comparação dos valores de textura utilizando medida de entropia.....	108
Figura 72 – Comparação dos valores de textura utilizando medida de SMA.	108
Figura 73 – Comparação dos valores de textura utilizando medida de contraste.....	109
Figura 74 – Comparação dos valores de textura utilizando medida de entropia.....	110
Figura 75 – Comparação dos valores de textura utilizando medida de SMA.	110
Figura 76 – Comparação dos valores de textura utilizando medida de contraste.....	111
Figura 77 – Comparação dos valores de textura utilizando medida de entropia.....	112
Figura 78 – Comparação dos valores de textura utilizando medida de SMA.	112
Figura 79 – Comparação dos valores de textura utilizando medida de contraste.....	113
Figura 80 – Comparação dos valores de textura utilizando medida de entropia.....	114
Figura 81 – Comparação dos valores de textura utilizando medida de SMA.	114
Figura 82 – (a) Imagem original, (b) Representação da imagem original na componente S.	115
Figura 83 – (a) Resultado da aplicação do filtro de mediana na imagem da Figura 82 (b), (b) Mapa de textura.	116
Figura 84 – Imagens de identificação de manchas marrons e injúrias: (a) Imagem original IMG_7817, (b) Representação da imagem original na componente S, (c) mapa de textura da região seleccionada, (d) Imagem original IMG_7816, (e) Representação da imagem original na componente S e (f) mapa de textura da região seleccionada.....	117

Figura 85 – Exemplo de segmentação no pré-processamento em uma imagem padrão simples: (a) imagem original e (b) objeto segmentado.....	118
Figura 86 – Exemplo de segmentação no pré-processamento em uma imagem padrão composta: (a) imagem original e (b) objeto segmentado.	118
Figura 87 – Exemplos de imagem classificadas pelo sistema: (a) Imagem original, (b) Imagem classificada no nível de maturação 7, (c) Imagem original e (d) Imagem classificada no nível de maturação 3.....	119
Figura 88 – Ficha de análise do índice de maturação da banana realizada por um observador e pela visão computacional.....	120
Figura 89 – Correlação entre a moda do índice de maturação obtido com a visão natural e o índice de maturação obtido com a visão computacional.	130
Figura 90 – Exemplos de imagens limiarizadas para obtenção do percentual de manchas marrons e injúrias em bananas: (a) Imagem original, (b) Imagem com aproximadamente 12,53% de manchas marrons, (c) Imagem com aproximadamente 11,82 % de injúrias.....	131
Figura 91 – Regressão linear para a identificação de manchas marrons de banana individual referente aos dados apresentados na tabela 30.	132
Figura 92 – Regressão linear para a identificação de manchas marrons de penca de bananas referente aos dados apresentados na tabela 31.	133
Figura 93 – Regressão linear para a identificação de injúrias de banana individual referente aos dados apresentados na tabela 32.....	134
Figura 94 – Regressão linear para a identificação de injúrias de penca de bananas referente aos dados apresentados na tabela 33.....	135

Lista de Tabelas

Tabela 1 – Classificação de bananas de acordo com o seu comprimento.	13
Tabela 2 – Gravidade do defeito medida pela porcentagem da área ocupada no fruto.	18
Tabela 3 – Quantidade percentual de verde a amarelo em cada nível de maturação.	92
Tabela 4 – Tonalidade de marrom das formas geométricas e seu respectivo valor na representação da imagem na componente S.	92
Tabela 5 – Valores de desvio padrão das medidas de textura encontradas para cada uma das formas consideradas no nível de maturação 1.	103
Tabela 6 – Valores de desvio padrão das medidas de textura encontradas para cada uma das formas consideradas no nível de maturação 2.	105
Tabela 7 – Valores de desvio padrão das medidas de textura encontradas para cada uma das formas consideradas no nível de maturação 3.	107
Tabela 8 – Valores de desvio padrão das medidas de textura encontradas para cada uma das formas consideradas no nível de maturação 4.	109
Tabela 9 – Valores de desvio padrão das medidas de textura encontradas para cada uma das formas consideradas no nível de maturação 5.	111
Tabela 10 – Valores de desvio padrão das medidas de textura encontradas para cada uma das formas consideradas no nível de maturação 6.	113
Tabela 11 – Valores de desvio padrão das medidas de textura encontradas para cada uma das formas consideradas no nível de maturação 7.	115
Tabela 12 – Comparação da classificação da banana IMG_7808 em nível de maturação obtida pela visão natural e pelo sistema.	121
Tabela 13 - Comparação da classificação da banana IMG_7809 em nível de maturação obtida pela visão natural e pelo sistema.	121
Tabela 14 – Comparação da classificação da banana IMG_7810 em nível de maturação obtida pela visão natural e pelo sistema.	122

Tabela 15 – Comparação da classificação da banana IMG_7811 em nível de maturação obtida pela visão natural e pelo sistema.	122
Tabela 16 – Comparação da classificação da banana IMG_7812 em nível de maturação obtida pela visão natural e pelo sistema.	123
Tabela 17 – Comparação da classificação da banana IMG_7813 em nível de maturação obtida pela visão natural e pelo sistema.	123
Tabela 18 – Comparação da classificação da banana IMG_7814 em nível de maturação obtida pela visão natural e pelo sistema.	124
Tabela 19 – Comparação da classificação da IMG_7815 em nível de maturação obtida pela visão natural e pelo sistema.	124
Tabela 20 – Comparação da classificação da banana IMG_7816 em nível de maturação obtida pela visão natural e pelo sistema.	125
Tabela 21 – Comparação da classificação da banana IMG_7817 em nível de maturação obtida pela visão natural e pelo sistema.	125
Tabela 22 – Comparação da classificação da banana IMG_7818 em nível de maturação obtida pela visão natural e pelo sistema.	126
Tabela 23 – Comparação da classificação da banana IMG_7819 em nível de maturação obtida pela visão natural e pelo sistema.	126
Tabela 24 – Comparação da classificação da banana IMG_7820 em nível de maturação obtida pela visão natural e pelo sistema.	127
Tabela 25 – Comparação da classificação da banana IMG_7821 em nível de maturação obtida pela visão natural e pelo sistema.	127
Tabela 26 – Comparação da classificação da banana IMG_7822 em nível de maturação obtida pela visão natural e pelo sistema.	128
Tabela 27 – Comparação da classificação da banana IMG_7823 em nível de maturação obtida pela visão natural e pelo sistema.	128

Tabela 28 - Comparação da classificação da banana IMG_7824 em nível de maturação obtida pela visão natural e pelo sistema.	129
Tabela 29 – Índices de maturação de amostras de bananas (<i>Musa sapientum</i>).....	130
Tabela 30 – Percentuais de manchas marrons em banana individual obtidos pela visão natural e pelo sistema utilizando limiarização.....	132
Tabela 31 – Percentuais de manchas marrons em penca de bananas obtidos pela visão natural e pelo sistema utilizando limiarização.....	133
Tabela 32 – Percentuais de injúrias em banana individual obtidos pela visão natural e pelo sistema utilizando limiarização.	134
Tabela 33 – Percentuais de injúrias em penca de bananas obtidos pela visão natural e pelo sistema utilizando limiarização.	135

SUMÁRIO

INTRODUÇÃO.....	1
CAPÍTULO 1 – QUALIDADE E CLASSIFICAÇÃO DE FRUTAS.....	3
1.1. A importância da fruticultura no Brasil.....	3
1.1.1. Rastreabilidade.....	5
1.1.2. Produção de mudas certificadas.....	6
1.1.3. Produção brasileira de frutas.....	6
1.2. A importância do cultivo de Banana (<i>Musa sapientum</i>) no Brasil.....	9
1.3. Normas para classificação de Bananas (<i>Musa sapientum</i>).....	12
CAPÍTULO 2 – PROCESSAMENTO DE IMAGENS E VISÃO COMPUTACIONAL.....	19
2.1. Imagem por Computador.....	19
2.2. Processamento de Imagens.....	20
2.2.1. Realce da Imagem.....	20
2.2.1.1. Filtragem no Domínio Espacial.....	21
2.2.1.2. Filtragem no Domínio da Frequência.....	21
2.2.1.3. Suavização de Imagens no Domínio Espacial.....	22
2.2.2. Técnicas de Modificação de Histograma.....	23
2.2.2.1. Conceito de Histograma.....	23
2.2.2.2. Transformação de Histograma.....	24
2.2.2.3. Equalização de Histograma.....	25
A Figura 19 ilustra a imagem equalizada e o seu histograma.....	26
2.2.3. Segmentação de Imagens.....	26
2.2.3.1. Descontinuidade.....	27
2.2.3.2. Similaridade.....	31
2.3. Textura.....	33
2.3.1. Análise de Textura.....	35
2.3.2. Abordagem Estatística.....	36
2.3.2.1. Matriz de co-ocorrência.....	37
2.3.3. Abordagem Estrutural.....	38
2.3.3.1. Agrupamento de Primitivas.....	39
2.4. Cor.....	40
2.4.1. Fundamentos da Cor.....	41

2.4.1.1. Modelo RGB	41
2.4.1.2. Modelo CMY.....	42
2.4.1.3. Modelo YIQ	42
2.4.1.4. Modelo HSI.....	43
2.5. Medida de área e perímetro	44
2.5.1. Forma.....	45
2.5.1.1. Medidas de tamanho.....	45
2.5.1.2. Medidas de tamanho baseado em regiões	46
2.6. Técnicas de Classificação de Imagens.....	47
2.6.1. Classificação não Supervisionada	47
2.6.2. Classificação Supervisionada	48
2.6.2.1. Classificação Bayesiana.....	48
2.7. Visão Computacional	50
CAPÍTULO 3 – SISTEMA DE VISÃO COMPUTACIONAL PARA CLASSIFICAÇÃO DE FRUTAS	56
3.1. Principais trabalhos desenvolvidos entre 1989 e 2000	56
3.2. Principais trabalhos desenvolvidos entre 2003 e 2005	57
3.3. Principais trabalhos desenvolvidos entre 2006 e 2008	59
3.4. Principais trabalhos desenvolvidos em 2009	70
CAPÍTULO 4 – DESENVOLVIMENTO DO SISTEMA PARA CLASSIFICAÇÃO DE BANANAS (<i>Musa sapientum</i>) BASEADA EM VISÃO COMPUTACIONAL	73
4.1. Modelagem do sistema	73
4.2. Aquisição das imagens	75
4.3. Pré-Processamento.....	75
4.4. Identificação de manchas marrons e injúrias através da textura	75
4.5. Classificação baseado em cor	78
4.6. Percentual de manchas marrons e injúrias.....	79
4.7. Modelagem da interface com o usuário.....	80
CAPÍTULO 5 – RESULTADOS E DISCUSSÕES	90
5.1. Imagens geradas para validação dos algoritmos.....	90
5.2. Método baseado em textura.....	96
5.2.1. Pré-processamento para o método de textura	96
5.2.2. Identificação baseada em textura.....	101
5.2.3. Aplicação em produção agrícola pós-colheita.....	116

5.2.3.1. <i>Validação do método em nível pós-colheita</i>	116
5.3. Método baseado em cor.....	117
5.3.1. Pré-processamento para o método de cor e área	117
5.3.2. Aplicação em produção agrícola pós-colheita.....	118
5.3.2.1. <i>Validação do método em nível pós-colheita</i>	119
CONCLUSÕES	136
REFERÊNCIAS BIBLIOGRÁFICAS	137

INTRODUÇÃO

Seleção e classificação de frutas são tarefas trabalhosas que geralmente são realizadas de maneira manual. A falta de um preparo e consistência para o processo pode ocasionar perdas.

A linha de estudos relacionados ao uso de visão computacional para o auxílio na classificação de frutas despertou a atenção de diversos pesquisadores por todo o mundo preocupados em garantir um produto de qualidade aos consumidores.

A classificação do fruto em níveis de maturação pode ser determinada por inspeção visual e análise de imagem. Estas inspeções determinam o preço de mercado. Tradicionalmente, a inspeção de qualidade é realizada por inspetores humanos treinados, porém é um método caro e altamente variável. As decisões nem sempre são coerentes entre os inspetores. Outro problema é a ocorrência de manchas marrons e injúrias devido ao armazenamento e transporte inadequados que depreciam o valor do produto.

Neste trabalho aplicou-se técnicas de visão computacional e processamento de imagens de bananas (*Musa sapientum*), tanto para identificação de injúrias como para classificação do nível de maturação em produção agrícola no pós-colheita, visando reduzir os custos e agilizar o processo de seleção. Com o sistema desenvolvido foi possível classificar o fruto em níveis de maturação de modo rápido e preciso, a identificação do percentual de manchas marrons e injúrias foi satisfatória. Através do mapa de textura foi possível distinguir áreas de manchas marrons e áreas de injúrias e dessa forma obter o percentual dos mesmos, utilizando o modelo HSI e com a contagem de *pixels* foi feita a relação do percentual de padrões encontrados com padrões previamente conhecidos para obter o estágio de maturação do fruto com base na escala de maturação de Von Loesecke.

O texto foi organizado em seis capítulos, conforme descrito a seguir, incluindo a bibliografia consultada.

Capítulo 1 – Qualidade e classificação de frutas: apresenta uma contextualização sobre a importância da fruticultura no Brasil, produção brasileira de frutas, cultivo e normas de classificação de bananas.

Capítulo 2 – Processamento de imagens e visão computacional: relata as técnicas de processamento de imagens para análise de bananas, abordando a aquisição de imagens, técnicas de pré-processamento, segmentação, análise de textura e visão computacional.

Capítulo 3 – Sistema de visão computacional para classificação de frutas: apresenta o estado da arte em sistema de visão computacional para esta aplicação, tomando por base a revisão da literatura.

Capítulo 4 – Desenvolvimento do sistema para classificação de bananas baseada em visão computacional: apresenta a modelagem do sistema desenvolvido, detalhado todas as etapas do mesmo.

Capítulo 5 – Resultados e discussões: relata e discute a validação e os resultados apresentados pelo sistema, bem como sua aplicação em um ambiente de pós-colheita agrícola.

Capítulo 6 – Conclusões: descreve as conclusões obtidas pela análise dos resultados apresentados pelo sistema.

CAPITULO 1 – QUALIDADE E CLASSIFICAÇÃO DE FRUTAS

Processos de certificação da qualidade são redutores de custos de transação e logística e revelam mecanismos essenciais que permitem aos agentes cooperar e se coordenar em suas atividades de pesquisa e inovação. A classificação de frutas e sua certificação apresentam os objetivos de facilitar e agilizar a sua comercialização para que comprador e vendedor não necessitem de visualização direta sobre os produtos.

1.1. A importância da fruticultura no Brasil

A fruticultura é uma das atividades agrícolas que mais cresce no Brasil, o qual é o terceiro produtor mundial (EMBRAPA, 2008). O grande potencial produtivo do país, favorecido pela diversidade climática, permite a produção de vários tipos de frutas. Em um setor tão importante economicamente, o estabelecimento de normas de certificação, torna-se fundamental para a comercialização *in natura*, pois são destinadas ao mercado externo e submetidas aos padrões de qualidade estabelecidos por organismos internacionais (DORNFELD et al., 2005).

Na região Norte há frutas nativas, que ainda não foram exploradas comercialmente. Por outro lado, a região Centro-Oeste se caracteriza por ser uma grande produtora de grãos, com uma fruticultura pouco significativa. Deste modo, a fruticultura se concentra nas regiões Nordeste, Sudeste e Sul, onde as condições de clima são bem distintas, permitindo o cultivo de um número variado de plantas frutíferas, tanto as tropicais como as de clima temperado. O estado de Minas Gerais é privilegiado em razão das condições climáticas para a exploração de frutas. Além, da sua extensão, possui microclimas bem distintos, próprios para o cultivo de um número variado de plantas frutíferas. O Brasil é um dos poucos do mundo que poderá suprir a demanda por frutas frescas, tanto em âmbito nacional como internacional. Portanto, a exploração do cultivo de frutas poderá ser um instrumento para proporcionar o fortalecimento econômico da atividade agrícola de diversas regiões. Contudo para que essa perspectiva se realize é necessário superar algumas dificuldades tais quais incluem:

- falta de uma política de defesa fitossanitária em âmbito nacional.
- carência de infra-estrutura organizada para as frutas, abrangendo transporte armazéns frigoríficos e crédito para comercialização

Por se tratar de uma atividade mais intensiva e emprega mais em mão-de-obra e com uma rentabilidade superior por hectares que as culturas de grãos (tais como arroz, feijão, milho, soja, entre outros) a produção integrada e a implantação de sistemas agroecológicos para frutas têm atraído uma quantidade crescente de agricultores familiares, havendo a contratação de trabalhadores temporários na época da colheita dos frutos. Desta forma, a produção familiar contribui para o sustento da família e gera empregos, proporcionando boas condições de vida para as pessoas. A fruticultura demanda mão-de-obra intensiva e qualificada, fixando o homem no campo, e na maioria dos casos permite boas condições de vida para uma família que tenha pequena propriedade.

Uma linha de classificação de frutas é composta por diversas etapas, tais como: recebimento, pré-seleção, lavagem, secagem. A utilização dos sistemas de classificação é um meio eficiente de organizar e desenvolver a sua comercialização.

Vários atributos das matérias-primas são adotados para critério de classificação, como: tamanho, cor, maturação, ausência de manchas ou outros defeitos causados por fungos e insetos, simetria, textura, sabor e odor. Esses atributos são relevantes para a seleção e classificação das frutas que geralmente é realizada de maneira manual (SIMÕES e COSTA, 2003).

A automação deste processo baseada em imagens digitais apresenta algumas dificuldades como:

- não há uma descrição formal dos padrões das frutas;
- não há ferramentas computacionais e modelos consolidados para a classificação de frutas;
- dependência das condições de iluminação do ambiente.

Os consumidores preferem frutas de peso igual e de formato uniforme (WASEEM et al., 2002). Com a expansão dos meios de comunicação e da informática, a tendência é agilizar operações de comercialização sem visualização direta do produto em

negociação e, para que isto ocorra, a classificação de frutas com base em sua qualidade é condição básica e necessária para viabilizar negócios. A estimação do tamanho das frutas também é útil no processo de empacotamento, comercialização e transporte (TABATABAEEFAR et al., 2000).

A fruticultura é considerada uma das atividades mais dinâmicas da economia brasileira, apresentando uma evolução contínua. Atende o mercado interno e vem ganhando espaço no mercado internacional, com frutas tropicais, subtropicais e de clima temperado, aumentando o volume das exportações, o número de empresas exportadoras, as variedades de frutas exportadas e os países de destino das exportações (IBRAF, 2008).

De acordo com o IBRAF, esta atividade contribui para o crescimento brasileiro nas seguintes formas:

- é geradora de emprego para a população, pois cada hectare plantado com fruticultura gera em média dois empregos diretos. Atualmente o país tem em torno de 2,5 milhões de hectares plantados com frutas, o que proporciona em torno de 5 milhões de empregos. Além disso, gera empregos indiretos antes e depois das colheitas;
- é geradora de divisas, através das exportações de suco de laranja e de frutas frescas e secas;
- o valor da produção da fruticultura é superior a 10 bilhões de reais anuais;

As exportações brasileiras de frutas e derivados ainda são muito concentradas em frutas como uva, melão, manga, maçã, banana, limão e mamão, para mercados restritos como a Europa e os Estados Unidos que juntos representam 90% dos destinos das exportações.

1.1.1. Rastreabilidade

A rastreabilidade da cadeia produtiva passou a ser exigida pelo consumidor como forma de garantir informação imediata e transparente sobre os perigos que possam afetar a segurança do alimento que consome. Ela visa atender a essa necessidade mantendo um registro confiável, ágil e seguro de todos os passos envolvidos nos processos da cadeia produtiva, desde o fornecedor de insumos até a disponibilização do produto ao consumidor

(DIGIOVANI, 2002). A rastreabilidade é um requisito fundamental nos sistemas de gestão da qualidade e possui a finalidade de garantir:

- Assegurar o direito à informação do consumidor;
- Destacar a origem e qualidade da produção;
- Aperfeiçoar a organização das cadeias produtivas através da valorização do trabalho e inovações tecnológicas.

1.1.2. Produção de mudas certificadas

Investimentos governamentais foram realizados em parceria com universidades, centros de pesquisa e Embrapa para a instalação de 25 viveiros, com o objetivo de produzir material de origem genética conhecida e com garantias fitossanitárias (CORRÊA, 2002). Está sendo amplamente utilizada a técnica de micropropagação, que se constitui no desenvolvimento de plantas em meio artificial sob condições assépticas e controladas, possibilita a obtenção de mudas saudáveis, rapidamente, independente da época do ano, diminui a possibilidade de disseminação de patógenos (víruses).

Essa técnica também garante a manutenção de características desejáveis como resistência às pragas e doenças, tolerância às condições de solo e clima, contenção do vigor da planta, sendo de grande importância para a viabilização econômica no processo de produção de mudas frutíferas garantindo a produtividade e longevidade dos pomares.

1.1.3. Produção brasileira de frutas

O Brasil apresenta grande potencial para se tornar um dos maiores pólos produtivos de frutas frescas para o mercado mundial. Já foram registrados 30 pólos de produção espalhados em mais de 50 municípios.

As Figuras 1, 2, 3 e 4 ilustram respectivamente a quantidade produzida, valor da produção, área plantada e rendimento médio das frutas nos anos de 2003 a 2007 no Brasil.

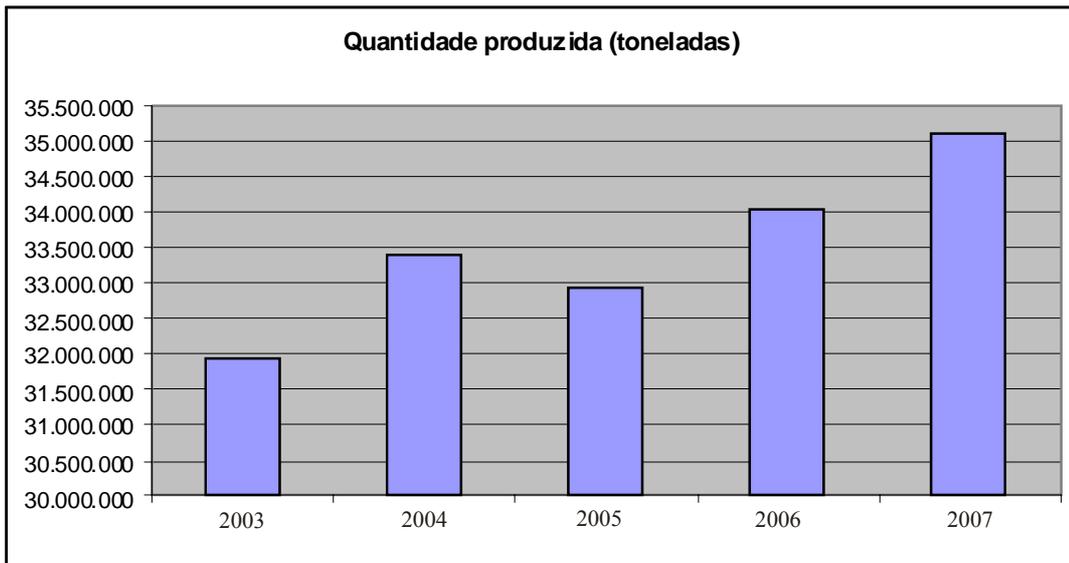


Figura 1 - Quantidade de frutas produzidas no Brasil em toneladas nos anos de 2003 a 2007 (Fonte: IBGE 2009).

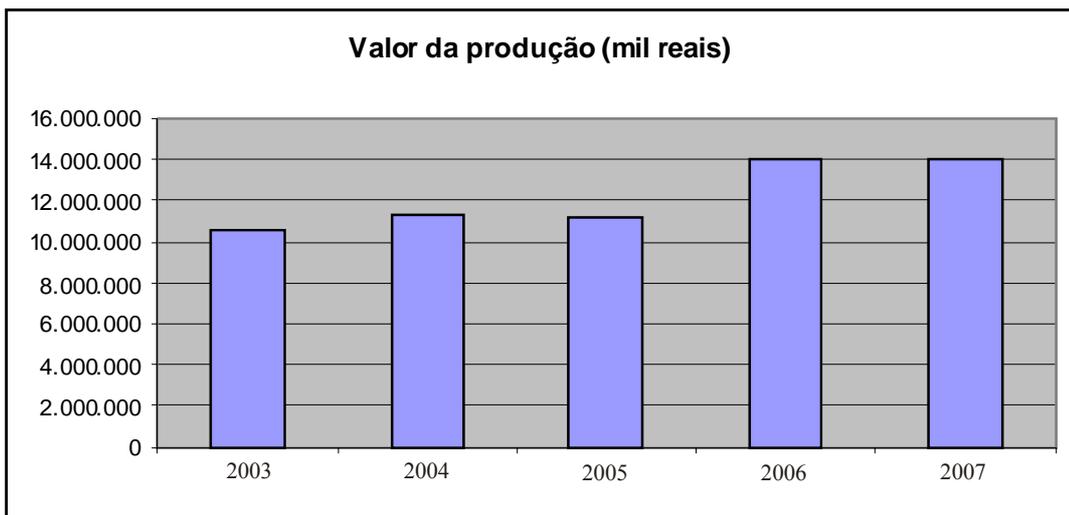


Figura 2 - Valor da produção de frutas no Brasil nos anos de 2003 a 2007 (Fonte: IBGE 2009).

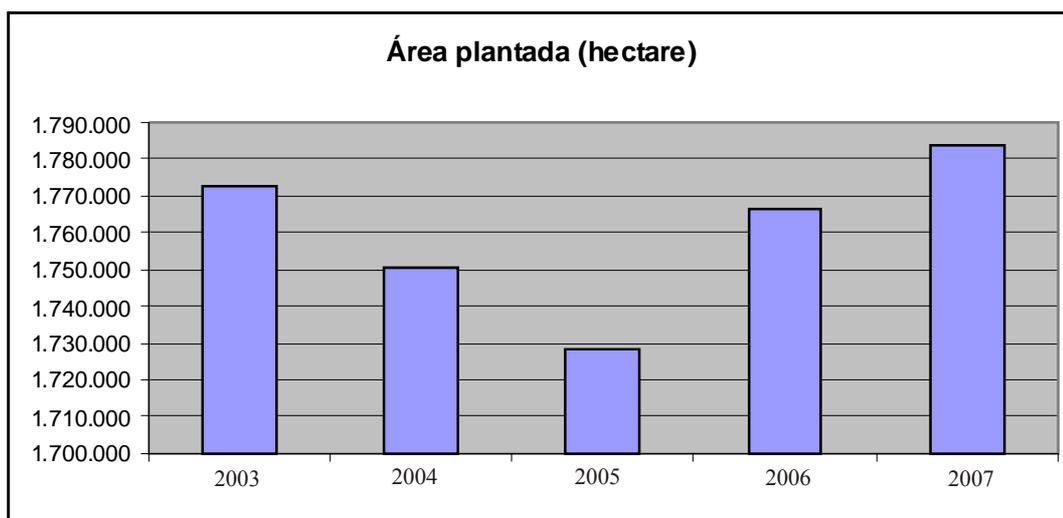


Figura 3 - Área plantada com frutas no Brasil nos anos de 2003 a 2007 (Fonte: IBGE 2009).

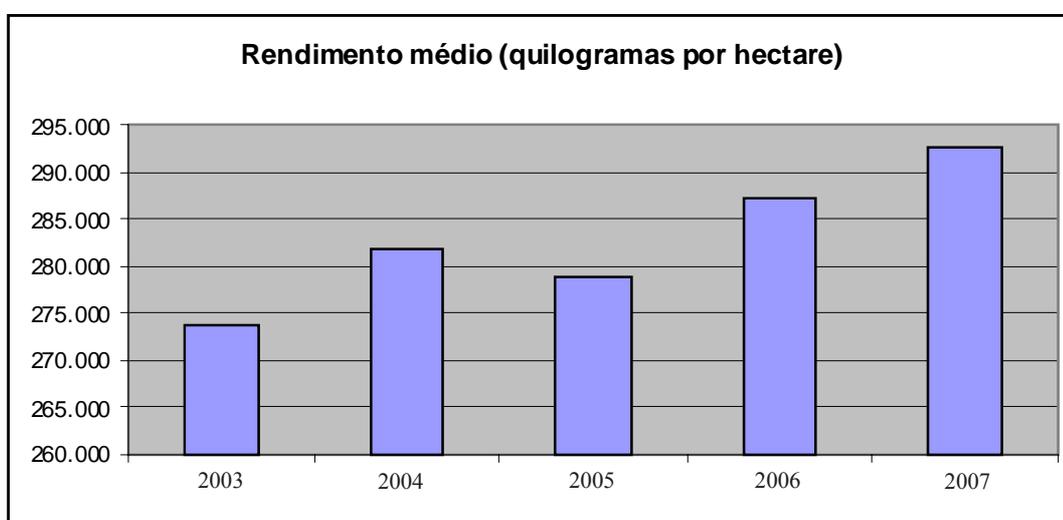


Figura 4 - Rendimento médio de frutas no Brasil nos anos de 2003 a 2007 (Fonte: IBGE 2009).

A região Sudeste do país é a maior responsável pela produção de frutas (60%) em seguida a região Nordeste (22%) e a região Sul (13%). De acordo com IBRAF (2007) o consumo per capita de frutas no Brasil é de 57 quilos/ ano. A Figura 5 ilustra a produção de frutas por região (%) no ano de 2007.

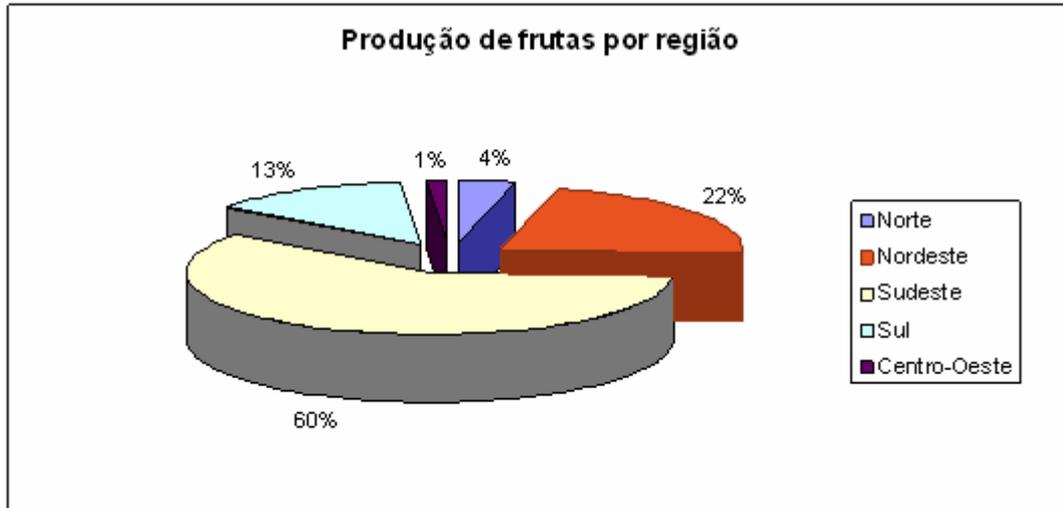


Figura 5 - Produção brasileira de frutas por região (Fonte: IBGE 2009).

1.2. A importância do cultivo de Banana (*Musa sapientum*) no Brasil

A banana é uma das frutas mais importantes do mundo, tanto no que se refere à produção quanto à comercialização. Para muitos países a banana apresenta grande relevância social e econômica, servindo como fonte de renda para muitas famílias de agricultores, gerando postos de trabalho no campo e na cidade e contribuindo para o desenvolvimento das regiões envolvidas em sua produção.

No Brasil a bananeira é cultivada de Norte a Sul, tendo grande expressão econômica e elevado alcance social, sendo responsável por mais de 500 mil empregos diretos. É uma cultura versátil, cultivável em diferentes ambientes, produz o ano todo e auxilia na manutenção da fertilidade do solo, o que se caracteriza como um fator adicional de valor para sua produção por pequenos produtores. A fruta é colhida ainda verde e quando conservada em temperatura ambiente, amadurece em alguns dias.

A bananeira exige calor constante, precipitações bem distribuídas e elevada umidade para o seu bom desenvolvimento e produção. A faixa de temperatura ótima para o desenvolvimento das bananeiras comerciais é de 26-28°C, com mínimas não inferiores a 15°C e máximas não superiores a 35°C. Abaixo de 15°C a atividade da planta é paralisada e, acima

de 35°C, o desenvolvimento é inibido, principalmente devido à desidratação dos tecidos, especialmente das folhas.

A banana é extremamente rica em potássio, carboidratos e fibras solúveis, além de conter fósforo, cálcio, magnésio e vitaminas A, B e C. Ela se destaca pela multiplicidade de uso, excelente sabor e ampla aceitação entre todas as faixas etárias e níveis sociais.

Olorunda (OLORUNDA, 2000) expõe que as perdas em bananas podem ter origens mecânicas, fisiológicas e microbiológicas. Os danos de origem mecânica devem ser considerados da maior importância para a conservação da qualidade dos frutos após sua colheita. Além de, causarem ferimentos, amassamentos e cortes, influenciam em outros tipos de danos - os fisiológicos e os microbiológicos.

As Figuras 6, 7, 8 e 9 ilustram respectivamente a quantidade produzida, valor da produção, área plantada e rendimento médio da banana nos anos de 2003 a 2007.

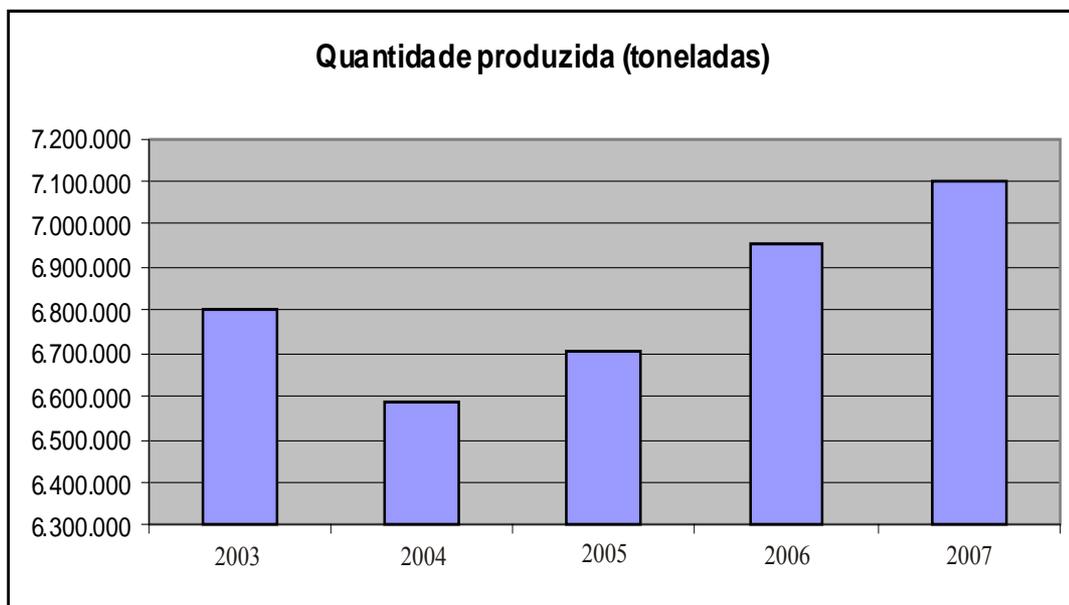


Figura 6 - Quantidade de banana produzida no ano de 2007 (Fonte: IBGE 2009).

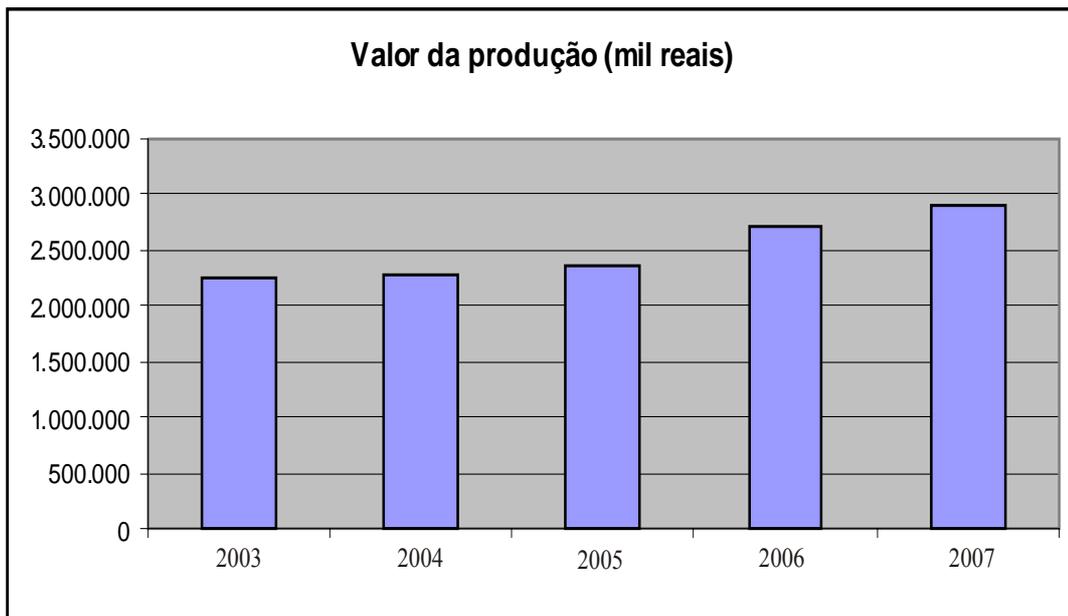


Figura 7 - Valor de produção da banana no ano de 2007 (Fonte: IBGE 2009).

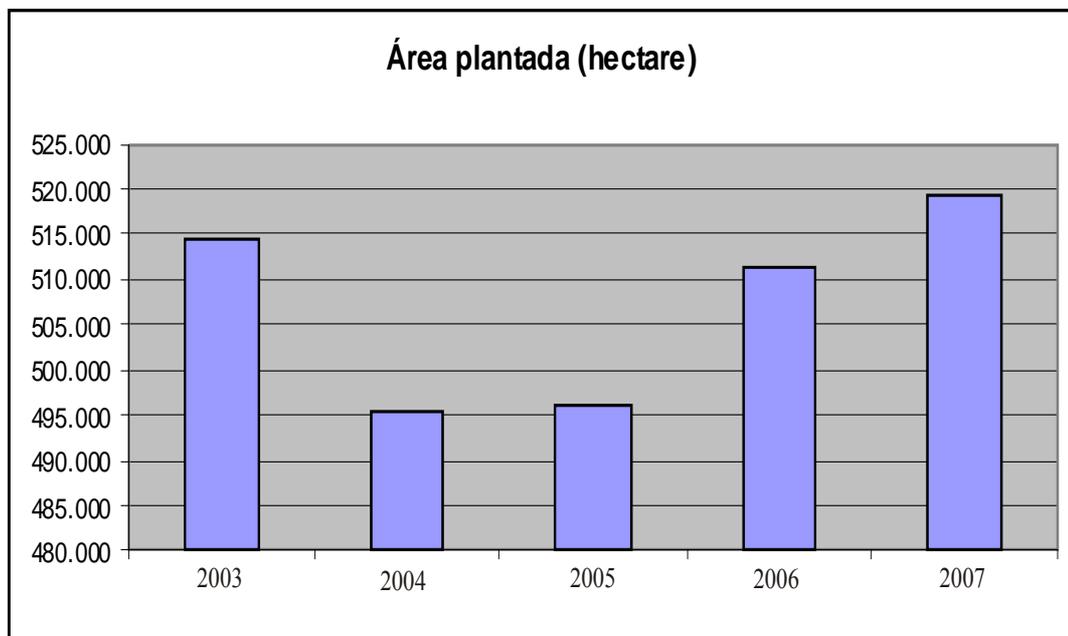


Figura 8 - Área de banana plantada no ano de 2007 (Fonte: IBGE 2009).

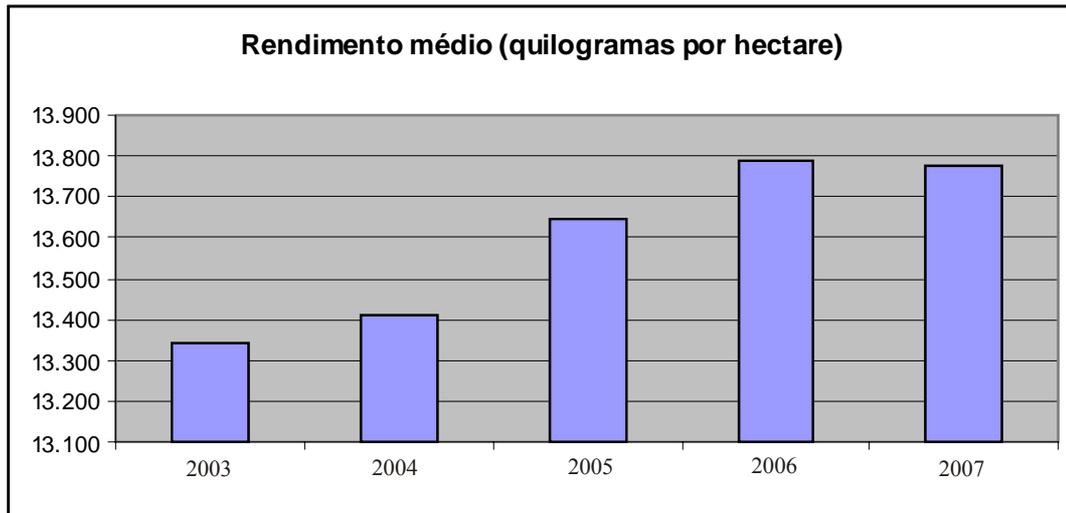


Figura 9 - Rendimento médio da banana no ano de 2007 (Fonte: IBGE 2009).

O Brasil está entre os grandes principais produtores mundiais. A produção anual brasileira, estimada entre 6 a 7 milhões de toneladas, concentra-se nos estados de São Paulo, Bahia, Santa Catarina, Minas Gerais e Pará, os quais produzem 56% desse total. A área cultivada anual é de cerca de 500 mil hectares. Noventa e nove por cento da produção destina-se ao mercado interno, com consumo de 31 quilogramas por habitante ao ano.

1.3. Normas para classificação de Bananas (*Musa sapientum*)

As normas de classificação da banana foram desenvolvidas pelo Programa Brasileiro para Modernização da Horticultura, imprescindível à modernização e transparência na comercialização.

A atividade classificatória é excelente mapeadora dos problemas da produção. Os cultivares comerciais de banana é híbrido de duas espécies: *Musa acuminata* (genoma¹ A) e a *Musa Balbisiana* (genoma B).

O agrupamento em classe garante a homogeneidade de tamanho entre frutos do mesmo lote. A classe da banana é determinada pelo comprimento de acordo com a tabela 1.

¹ Genoma: Em biologia é toda a informação hereditária de um organismo que está codificado em seu DNA.

CLASSE	COMPRIMENTO (cm)
6	Maior que 6 até 9
9	Maior que 9 até 12
12	Maior que 12 até 15
15	Maior que 15 até 18
18	Maior que 18 até 22
22	Maior que 22 até 26
26	Maior que 26

Tabela 1 – Classificação de bananas de acordo com o seu comprimento.

As bananas também podem ser classificadas pelo nível do estágio de maturação. De acordo com o Programa Brasileiro para Modernização da Horticultura as bananas podem ser divididas em 7 níveis:

- Nível 1: Totalmente verde.
- Nível 2: Verde com traços amarelos.
- Nível 3: Mais verde do que amarelo.
- Nível 4: Mais amarelo do que verde.
- Nível 5: Amarelo com pontas verdes.
- Nível 6: Amarelo.
- Nível 7: Amarelo com áreas marrons.

Existe ainda a classificação feita pelo tipo de agrupamento que a fruta apresenta, como mostra a Figura 10.

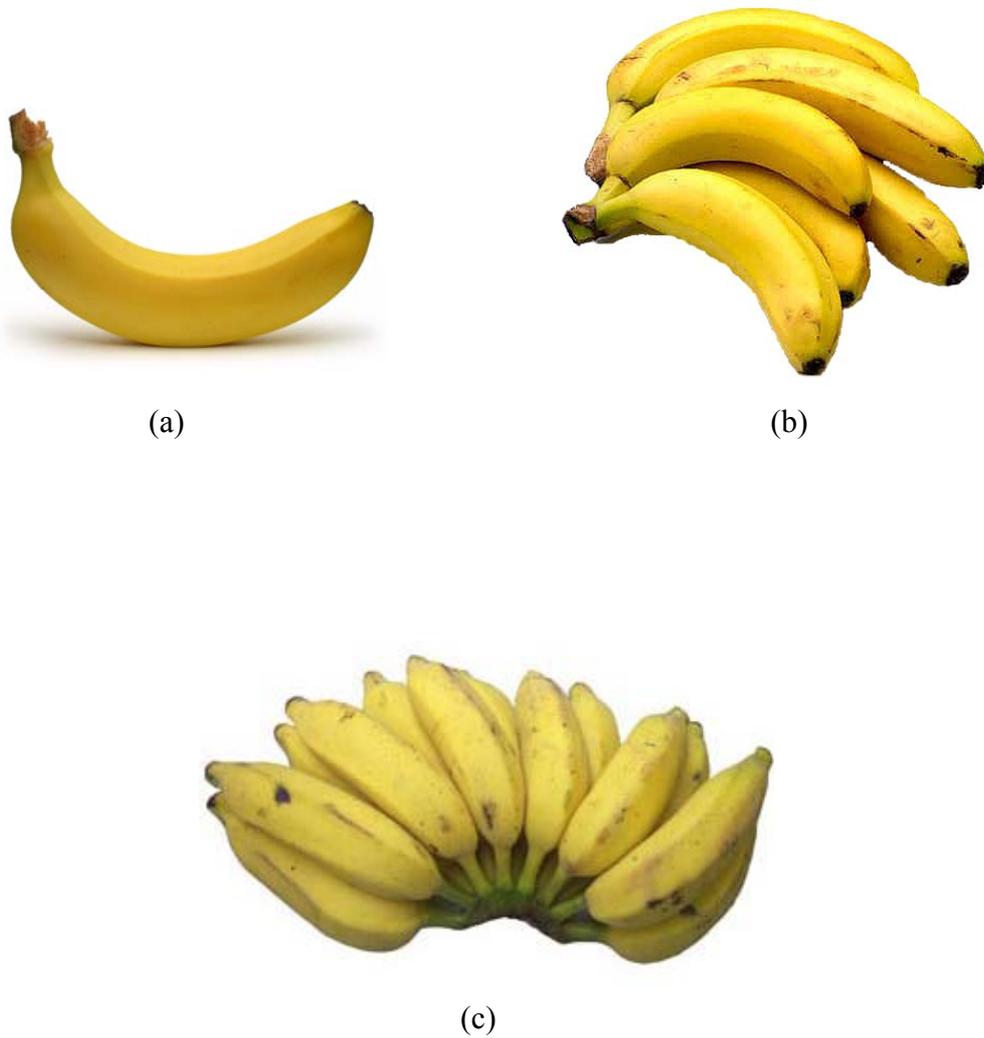


Figura 10 – Modo de apresentação da banana: (a) Dedo (1 fruto), (b) Buquê (2 a 9 frutos) e (c) Penca (10 ou mais frutos) (PBMH e PIF, 2006).

Toda e qualquer lesão causada por fatores de natureza fisiológica, fitossanitária, mecânica (danos causados durante a etapa de beneficiamento, transporte e embalagem) ou por agentes diversos, que venha a comprometer a qualidade e a apresentação da banana. Os defeitos podem ser divididos em 3 categorias: defeitos graves, defeitos leves e defeitos variáveis.

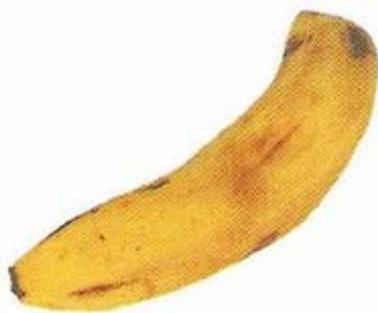
Os defeitos graves inviabilizam o consumo e depreciam muito a aparência e o valor do produto como mostra a Figura 11.



(a)



(b)



(c)



(d)



(e)



(f)



(g)



(h)

Figura 11 – Defeitos graves em banana: (a) Ponta de charuto, (b) Podridão, (c) Amassado, (d) Dano por sol, (e) Dano profundo, (f) Passado, (g) Maturação precoce e (h) Infestação por praga (traça-da-banana) (PBMH e PIF, 2006).

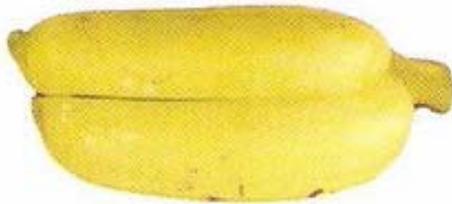
Os defeitos leves não impedem o consumo do produto, mas depreciam o seu valor como ilustra a Figura 12.



(a)



(b)



(c)



(d)



(e)

Figura 12 – Defeitos leves em banana: (a) Ausência de dedos, (b) Desenvolvimento diferenciado, (c) Germinado, (d) Restos florais e (e) Descoloração da casca (PBMH e PIF, 2006).

Os defeitos variáveis podem ser graves, leves ou desconsiderados em função de sua intensidade de ocorrência como apresenta a Figura 13.



(a)



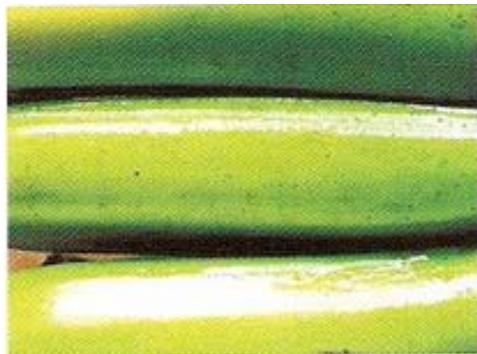
(b)



(c)



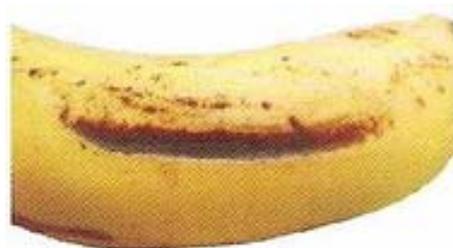
(d)



(e)



(f)



(g)

Figura 13 – Defeitos variáveis em banana: (a) Abelha arapuá, (b) Ácaro de ferrugem, (c) Látex, (d) Fuligem, (e) Tripes de erupção, (f) Tripes de ferrugem e (g) Danos mecânicos superficiais (PBMH e PIF, 2006).

Os defeitos variáveis podem ser considerados como graves ou leves de acordo com a porcentagem da área ocupada no fruto como mostra a tabela 2.

GRAVIDADE DO DEFEITO MEDIDO PELO % DA ÁREA OCUPADA NO FRUTO		
Defeitos	Grave	Leve
Ácaro e tripes de ferrugem	área ≥ 10	$5 \leq \text{área} < 10$
Dano mecânico superficial, abelha arapuá, mancha de fuligem e mancha de látex	área ≥ 3	$1 \leq \text{área} < 3$

Tabela 2 – Gravidade do defeito medida pela porcentagem da área ocupada no fruto.

A classificação do fruto é feita pela separação do produto em lotes homogêneos, obedecendo a padrões de qualidade e homogeneidade em função da gravidade do defeito avaliado.

CAPÍTULO 2 – PROCESSAMENTO DE IMAGENS E VISÃO COMPUTACIONAL

Informações geométricas que envolvem tamanho e forma, bem como informações de cor e textura podem ser utilizadas em conjunto com técnicas de classificação para a caracterização da qualidade de produtos. Este capítulo trata da construção de indicadores de qualidade de bananas (*Musa sapientum*) baseados no processamento de imagens digitais e sistema de visão computacional.

2.1. Imagem por Computador

Imagem por computador é definida pela aquisição e processamento de informações visuais pelo computador. Trabalhos sobre imagens podem ser divididos em duas categorias: processamento de imagens e visão computacional (UMBAUGH, 1998). Estas categorias não são, entretanto totalmente separadas e distintas e a Figura 14 ilustra como estão relacionadas.

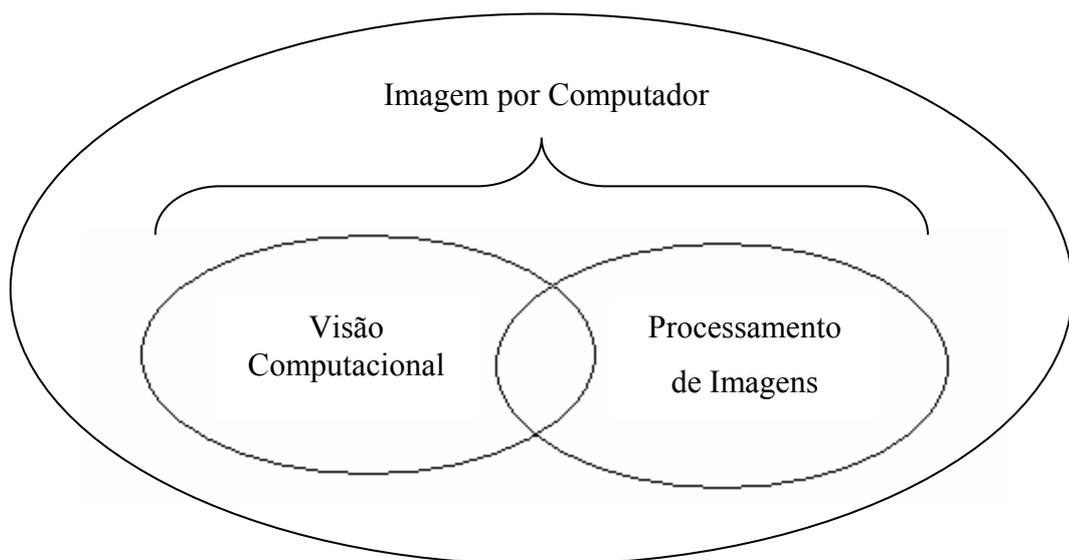


Figura 14 – Imagem por computador: visão computacional e processamento de imagens.

2.2. Processamento de Imagens

Um sinal analógico de vídeo, obtido de um dispositivo de aquisição, deve ser submetido a uma discretização espacial e em amplitude para tomar o formato desejável ao processamento computacional. A digitalização dos valores das coordenadas é chamada de amostragem e a digitalização dos valores de amplitude é chamada de quantização.

Uma imagem pode ser definida como uma função $f(x, y)$, onde x e y são as coordenadas espaciais (planas) e a amplitude de f em qualquer par de coordenadas (x, y) é a intensidade do nível de cinza da imagem (GONZALEZ e WOODS, 1992).

Basicamente, a amostragem converte a imagem analógica em matriz de M por N pontos, cada qual denominado *pixel*.

$$f(x, y) \cong \begin{bmatrix} f(0, 0) & f(0, 1) & \dots & f(0, N-1) \\ f(1, 0) & f(1, 1) & \dots & f(1, N-1) \\ \vdots & \vdots & & \vdots \\ f(M-1, 0) & f(M-1, 1) & \dots & f(M-1, N-1) \end{bmatrix} \quad (1)$$

Onde maiores valores de M e N implicam em uma imagem de maior resolução.

2.2.1. Realce da Imagem

O principal objetivo das técnicas de realce de imagens é processar uma imagem de modo que a imagem resultante seja mais adequada, que a imagem original, para uma aplicação específica (MARQUES e NETO, 1999). Os métodos de filtragem que são normalmente empregados se caracterizam em duas categorias: as técnicas de filtragem espacial e as técnicas de filtragem no domínio da frequência.

2.2.1.1. Filtragem no Domínio Espacial

As técnicas de filtragem no domínio espacial são aquelas que atuam diretamente sobre a matriz de *pixels* que é a imagem digitalizada. Logo, as funções de processamento de imagens no domínio espacial podem ser expressas como:

$$g(x, y) = T[f(x, y)] \quad (2)$$

onde: $g(x, y)$ é a imagem processada, $f(x, y)$ é a imagem original e T é um operador em f , definido em uma certa vizinhança de (x, y) .

A vizinhança definida ao redor de (x, y) é a vizinhança de 8 conectivos do *pixel* de referência, o que equivale a uma região 3×3 , na qual o *pixel* central é o de referência como indica a Figura 15. Uma vizinhança pode ser de outra ordem, dependendo da aplicação, formando as regras 5×5 , 7×7 ou maior.

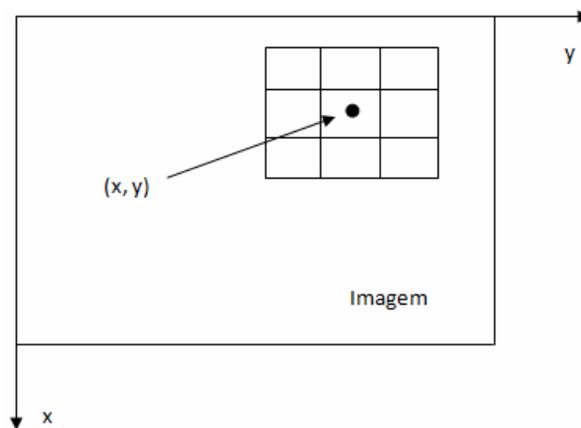


Figura 15 – Uma vizinhança 3×3 ao redor de um ponto de coordenadas (x, y) em uma imagem.

2.2.1.2. Filtragem no Domínio da Frequência

A base matemática das técnicas de filtragem no domínio da frequência é obtida com base no teorema da convolução. Se $g(x, y)$ é a imagem formada pela convolução (denotada pelo símbolo $*$) da imagem $f(x, y)$ com um operador linear $h(x, y)$, então:

$$g(x, y) = f(x, y) * h(x, y) \quad (3)$$

Pelo teorema da convolução, a seguinte relação no domínio da frequência também é válida:

$$G(u, v) = F(u, v) H(u, v) \quad (4)$$

onde G, F, H são as transformadas de Fourier de $g(x,y)$, $f(x,y)$ e $h(x,y)$ respectivamente.

2.2.1.3. Suavização de Imagens no Domínio Espacial

O uso de máscaras espaciais no processamento de imagens é normalmente denominado filtragem espacial. Dentre as técnicas mais conhecidas de suavização estão a filtragem pela média e o filtro da mediana.

Filtro da Média

O filtro da média é uma técnica que permite a redução de ruído em uma imagem (MARQUES e NETO, 1999). Considerando uma dada vizinhança, o método consiste em calcular a média de todos os pontos dentro desta vizinhança para cada *pixel* da imagem original. O filtro da média é útil por ser uma técnica simples, relativamente rápida de ser aplicada, pois não necessita de nenhum processamento mais complexo do que somas e divisões. Contudo, o filtro da média apresenta perda nos detalhes da imagem, dando o efeito de borramento. A Figura 16 apresenta a imagem original e a imagem filtrada.



Figura 16 – (a) Imagem Original (USC-SIPI *Image Database*, 1971), (b) Resultado da aplicação do filtro de média na imagem original.

Filtro da Mediana

Nesta técnica, o nível de cinza do *pixel* central da janela é substituído pela mediana dos *pixels* situados em sua vizinhança. A mediana (m) de um conjunto de (n) elementos é um valor tal que metade dos (n) elementos do conjunto situa-se abaixo de (m), e a outra metade acima de (m). Quando (n) é ímpar, a mediana é calculada pela média aritmética dos dois elementos mais próximos do centro (GONZALEZ e WOODS, 1992). Esse método é eficiente quando a imagem contém ruídos elevados e o realce das bordas é importante. A Figura 17 ilustra um exemplo da aplicação do filtro de mediana.



Figura 17 – (a) Imagem Original (USC-SIPI *Image Database*, 1971), (b) Resultado da aplicação do filtro de mediana na imagem original.

2.2.2. Técnicas de Modificação de Histograma

2.2.2.1. Conceito de Histograma

O histograma de uma imagem é simplesmente um conjunto de números que indicam a frequência de ocorrência de *pixels* em suas diferentes tonalidades ou valores em níveis de cinza naquela imagem. Estes valores são representados por um gráfico de barras que fornece para cada nível de cinza o número de *pixels* correspondentes na imagem. Através da visualização do histograma de uma imagem obtém-se uma indicação de sua qualidade quanto ao nível de contraste e quanto ao seu brilho médio (MARQUES e NETO, 1999).

Cada elemento do conjunto de um histograma é calculado como:

$$p_r(r_k) = \frac{n_k}{n} \quad n \neq 0 \quad (5)$$

onde $0 \leq r_k \leq 1$; $k = 0, 1, \dots, L-1$, onde L é o número de níveis de cinza da imagem digitalizada; n = número total de *pixels* na imagem; $p_r(r_k)$ = probabilidade do k -ésimo nível de cinza; e n_k = número de *pixels* cujo nível de cinza corresponde a k .

O conceito de histograma também é aplicável a imagens coloridas. Neste caso, a imagem é decomposta de alguma forma (por exemplo, em seus componentes R, G, B) e para cada componente é calculado o histograma correspondente.

2.2.2.2. Transformação de Histograma

As técnicas de modificação de histograma são conhecidas como técnicas *pixel-a-pixel*, uma vez que o valor de tom de cinza de um *pixel*, após o processamento, depende apenas de seu valor original. Em contraste, nas técnicas de processamento orientadas a vizinhança, o valor resultante depende também, de alguma forma, dos *pixels* que circundam o elemento de imagem original. Diversas técnicas de modificação da distribuição dos *pixels* na escala de cinza podem ser implementadas a partir do conceito de transformações de intensidade, apresentado formalmente a seguir.

Seja uma variável f , representando o nível de cinza dos *pixels* na imagem a ser processada. Por simplicidade, assume-se inicialmente que a escala de cinza é normalizada, ou seja,

$$0 \leq f \leq 1 \quad (6)$$

Onde $f = 0$ representa um *pixel* preto e $f = 1$ indica *pixel* branco.

Para qualquer f no intervalo $[0, 1]$, denomina-se transformações de intensidade as funções do tipo:

$$g = T(f) \quad (7)$$

o novo valor g levará em um novo tom de cinza, g , na imagem destino. Estas funções devem satisfazer duas condições:

(i) devem retornar um único valor para cada valor distinto de f e devem crescer monotonicamente no intervalo $0 \leq f \leq 1$;

(ii) $0 \leq T(f) \leq 1$ para $0 \leq f \leq 1$;

2.2.2.3. Equalização de Histograma

A equalização de histograma é uma técnica a qual se preocupa em redistribuir os valores de tons de cinza dos *pixels* em uma imagem, de modo a obter um histograma uniforme, no qual o número de *pixels* de qualquer nível de cinza é praticamente o mesmo. Para tanto, utiliza-se uma função auxiliar, denominada função de transformação (SCHOWENGERDT, 1997). A forma mais usual de se equalizar um histograma é utilizar a função de distribuição acumulada da distribuição de probabilidade original (Eq. 8).

$$s_k T(r_k) = \sum_{j=0}^k \frac{n_j}{n} = \sum_{j=0}^k p_r(r_k) \quad (8)$$

onde $0 \leq r_k \leq 1$; $k = 0, 1, \dots, L-1$.

A inversa desta função é dada por:

$$r_k = T^{-1}(s_k) \quad \text{para} \quad 0 \leq s_k \leq 1 \quad (9)$$

A Figura 18 mostra a imagem original e o seu histograma.

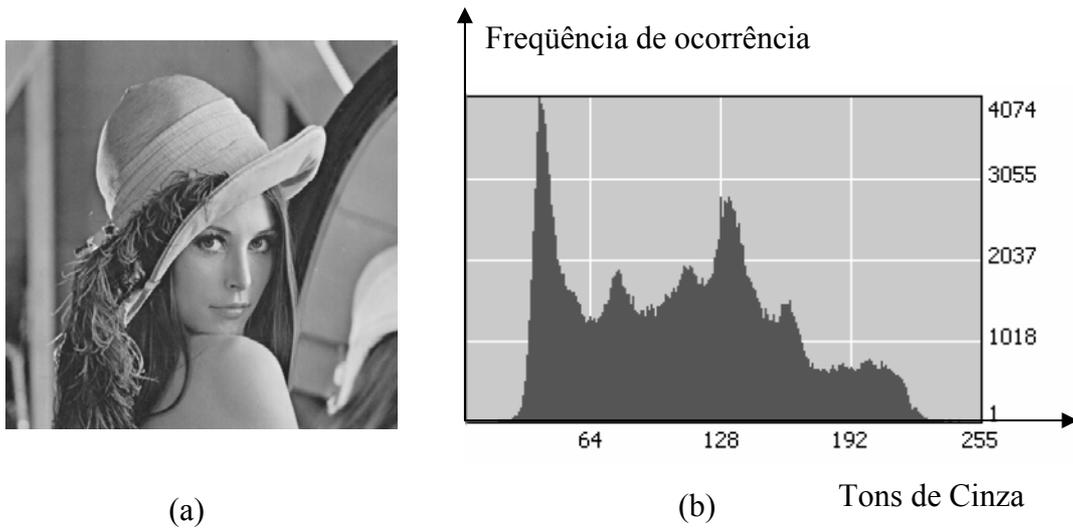


Figura 18 – (a) Imagem Original (USC-SIPI *Image Database*, 1971), (b) Histograma da imagem original.

A Figura 19 Ilustra a imagem equalizada e o seu histograma.

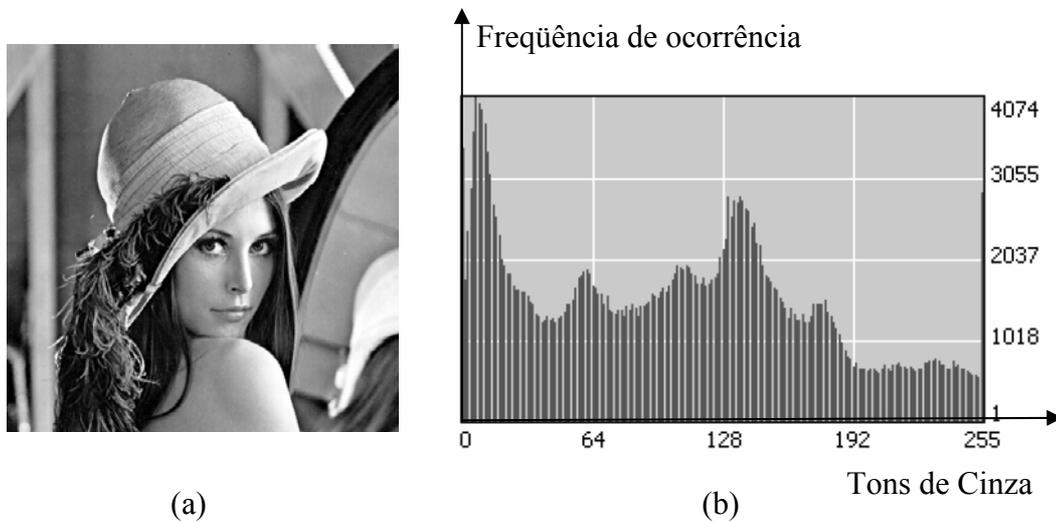


Figura 19 – (a) Imagem Original (USC-SIPI *Image Database*, 1971), (b) Histograma da imagem equalizada.

2.2.3. Segmentação de Imagens

A segmentação consiste em usar o computador para definir na imagem, recortes automáticos de objetos de interesse. A segmentação subdivide uma imagem em suas partes ou objetos constituintes. O nível até o qual essa subdivisão deve se realizada, assim

como a técnica utilizada, depende do problema que está sendo resolvido. Algoritmos de segmentação permitem achar diferenças entre dois ou mais objetos, e distinguir as partículas umas das outras e do fundo. Os algoritmos de segmentação para imagens monocromáticas são geralmente baseados em uma das seguintes propriedades básicas de valores de níveis de cinza: descontinuidade e similaridade (MARQUES e NETO, 1999). Na descontinuidade, a abordagem é particionar a imagem baseado em mudanças bruscas nos níveis de cinza. As principais áreas de interesse são: detecção de pontos isolados, detecção de linhas e bordas na imagem. Na similaridade as principais abordagens baseiam-se em limiarização e crescimento de regiões.

2.2.3.1. Descontinuidade

A descontinuidade é representada pelas mudanças bruscas de níveis de cinza. Os objetos que podem ser localizados por técnicas baseadas em descontinuidades são de três tipos: pontos, linhas e bordas. Essas técnicas são definidas por uma operação orientada à vizinhança.

Operações lógicas e aritméticas orientadas à vizinhança utilizam o conceito de convolução com máscaras. A cada posição relativa da máscara sobre a imagem, o *pixel* central da sub-imagem em questão será substituído, em uma matriz denominada imagem destino, pela soma dos produtos dos coeficientes com os níveis de cinza contidos na sub-região envolvida pela máscara. Isto é, a resposta da máscara em algum ponto na imagem é dada por:

$$R = w_1z_1 + w_2z_2 + w_1z_1 + \dots + w_9z_9 = \sum_{i=1}^9 w_i z_i \quad (10)$$

em que z_i é o nível de cinza do *pixel* associado com o coeficiente w_i da máscara.

Detecção de pixel

A detecção de *pixels* isolados em uma imagem pode ser obtida de maneira direta. Diz-se que um ponto foi detectado na posição da máscara se $|R| > L$, em que L é um limiar não-negativo e R é definido pela equação 10. Essa formulação mede as diferenças ponderadas entre o ponto central e seus vizinhos. A idéia é que o nível de cinza de um ponto isolado será completamente diferente do nível de cinza dos seus vizinhos. A Figura 20 apresenta a imagem original e a imagem filtrada.



Figura 20 – (a) Imagem original (USC-SIPI *Image Database*, 1971), (b) Resultado obtido com o filtro detecção de *pixel* na imagem original.

Detecção de linha

Se a primeira máscara, conforme apresentado no item (a), fosse movida por toda uma imagem, ela responderia a linhas orientadas horizontalmente. Um experimento similar revelaria que a máscara apresentada no item (b), responde melhor a linhas orientadas a +45 graus; a terceira máscara, item (c), a linhas verticais; e a quarta, item (d), a linhas na direção -45 graus (GONZALEZ e WOODS, 1992).

$$\begin{array}{cccc}
 \begin{bmatrix} -1 & -1 & -1 \\ 2 & 2 & 2 \\ -1 & -1 & -1 \end{bmatrix} & \begin{bmatrix} -1 & -1 & 2 \\ -1 & 2 & -1 \\ 2 & -1 & -1 \end{bmatrix} & \begin{bmatrix} -1 & 2 & -1 \\ -1 & 2 & -1 \\ -1 & 2 & -1 \end{bmatrix} & \begin{bmatrix} 2 & -1 & -1 \\ -1 & 2 & -1 \\ -1 & -1 & 2 \end{bmatrix} \\
 \text{Horizontal} & +45 \text{ graus} & \text{Vertical} & -45 \\
 (a) & (b) & (c) & (d)
 \end{array}$$

Os quatros filtros de Sobel são: (a) filtro horizontal, (b) filtro diagonal +45 graus, (c) filtro vertical e (d) filtro diagonal -45 graus. A Figura 21 ilustra a imagem original, imagem obtida com o filtro vertical e a imagem obtida com o filtro horizontal.

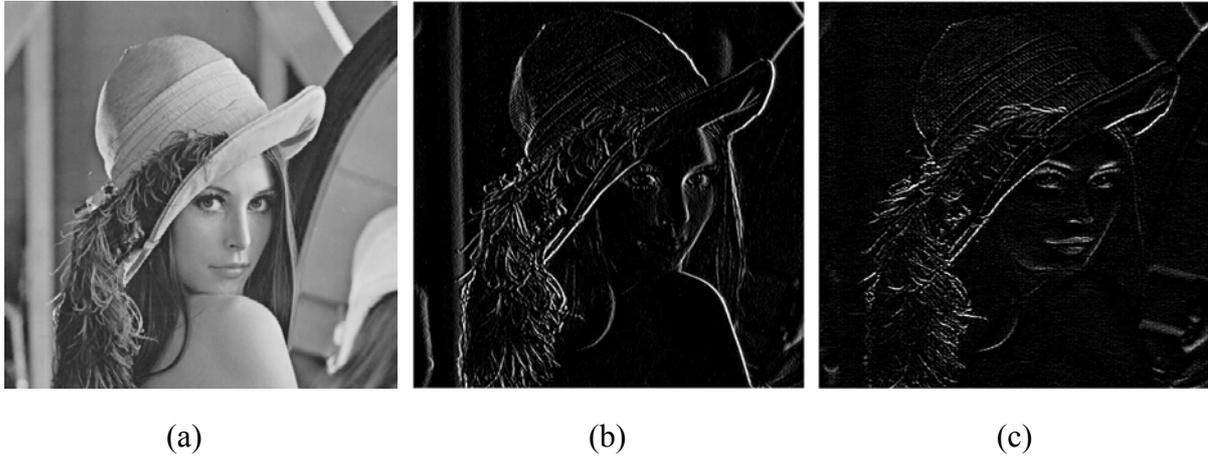


Figura 21 – (a) Imagem Original (USC-SIPI *Image Database*, 1971), (b) Resultado da aplicação do filtro vertical na imagem original e (c) Resultado da aplicação do filtro horizontal na imagem.

Detecção de borda

Uma borda é o limite entre duas regiões com propriedades distintas de nível de cinza. Para a detecção de bordas, aplicam-se filtros espaciais lineares de dois tipos: baseados no gradiente da função luminosidade da imagem, e baseados no Laplaciano.

Operadores de Gradiente

O gradiente de uma imagem $f(x, y)$ na localização (x, y) é dado pelo vetor

$$\nabla f = \begin{bmatrix} G_x \\ G_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix} \quad (11)$$

Sabe-se que a partir da análise vetorial o vetor gradiente aponta na direção de mudança mais rápida de f na posição (x, y) . Em detecção de bordas, a magnitude desse vetor é uma quantidade importante, geralmente chamada de gradiente e denotada por ∇f , onde:

$$\nabla f = \text{mag}(\nabla f) = [G_x^2 + G_y^2]^{1/2} \quad (12)$$

Essa quantidade equivale à maior taxa de aumento de $f(x, y)$ por unidade de distância na direção de ∇f . É comum aproximar o gradiente com valores absolutos:

$$\nabla f \approx |G_x| + |G_y| \quad (13)$$

o qual é muito mais simples de se implementar.

Para uma imagem digital $f(x, y)$, o módulo do gradiente pode ser aproximado por operadores 3×3 ou máscaras de convolução. A seguir, são mostrados exemplos dessas máscaras, os quais são conhecidos como operadores de Sobel: (a) região de uma imagem de tamanho 3×3 , (b) máscaras no cômputo de G_x no ponto central da região 3×3 , (c) máscara usada no cômputo G_y naquele ponto.

$$\begin{array}{ccc} \begin{bmatrix} Z_1 & Z_2 & Z_3 \\ Z_4 & Z_5 & Z_6 \\ Z_7 & Z_8 & Z_9 \end{bmatrix} & \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} & \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \\ (a) & (b) & (c) \end{array}$$

Operador Laplaciano

O Laplaciano de uma função bidimensional $f(x, y)$ é uma derivada de segunda ordem dada por:

$$\nabla^2 f = \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2} \quad (14)$$

A operação de gradiente é decorrente da aplicação da máscara 3×3 para operação do Laplaciano, como apresentado a seguir:

$$\begin{bmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{bmatrix}$$

A Figura 22 mostra a imagem original e a imagem obtida com a aplicação do filtro Laplaciano.



Figura 22 – (a) Imagem Original (USC-SIPI *Image Database*, 1971), (b) Resultado obtido com a aplicação do filtro Laplaciano na imagem original.

Embora o Laplaciano seja insensível à rotação e, portanto capaz de realçar ou detectar bordas em qualquer direção, seu uso é restrito devido a sua grande suscetibilidade a ruído.

2.2.3.2. Similaridade

A similaridade baseia-se nos limites dos níveis de cinza, subdivisão da imagem em regiões homogêneas e crescimento de regiões. Os objetos são separados de acordo com um critério de similaridade entre pixels de uma mesma região.

Limiarização (*Thresholding*)

Limiarização é uma das mais importantes abordagens para a segmentação de imagens (MARQUES e NETO, 1999). Na limiarização é analisada a similaridade dos níveis de cinza da imagem extraíndo os objetos de interesse através da seleção de um limiar L que separa os agrupamentos de níveis de cinza.

Uma imagem limiarizada $g(x,y)$ é definida como:

$$g(x,y) = \begin{cases} 1 & \text{se } f(x,y) \geq L \\ 0 & \text{se } f(x,y) < L \end{cases} \quad (15)$$

onde $f(x,y)$ corresponde ao nível, de cinza do ponto, os *pixels* rotulados com 1 correspondem aos objetos e os *pixels* rotulados com 0 correspondem ao fundo e L é um valor de tom de cinza predefinido denominado limiar.

A Figura 23 apresenta a imagem original e a imagem limiarizada.



Figura 23 – (a) Imagem original (USC-SIPI *Image Database*, 1971), (b) Imagem Limiarizada.

A qualidade de uma imagem limiarizada depende do valor de L . Assim, é importante definir um valor ótimo para L de forma que a imagem não sofra uma limiarização inadequada para sua aplicação.

Quando a limiarização é definida de forma manual pode-se escolher o melhor valor para L de forma visual. No entanto, a maioria das aplicações requer que valor de L seja obtido de forma automática. Desta forma, é necessário empregar alguma técnica de limiarização.

Existem diversas técnicas para se definir L . Não se pode dizer qual a melhor técnica, dependendo das condições da imagem (contraste, iluminação, complexidade da cena) e também do resultado esperado com a limiarização, pode-se obter resultados melhores com uma ou outra técnica.

Crescimento de Regiões

Assim como na limiarização, na segmentação orientada a regiões analisamos a similaridade dos níveis de cinza da imagem. Como seu nome implica, o crescimento de regiões é um procedimento que agrupa *pixels* ou sub-regiões em regiões maiores. A mais simples dessas abordagens é a agregação de *pixels*, que começa com um conjunto de pontos "semente" e, a partir deles, cresce as regiões anexando a cada ponto semente aqueles *pixels* que possuam propriedades similares (como nível de cinza, textura ou cor) (PRATT, 1991).

A seleção de critérios de similaridade depende não apenas do problema em consideração, mas também de dados (imagem) disponíveis.

Por outro lado, a disponibilidade de imagens multiespectrais e de outros tipos complementares é exceção, em processamento de imagens. Tipicamente, o crescimento de regiões deve ser realizado com um conjunto de descritores baseados em intensidade e em propriedades espaciais (como momentos ou textura) de uma única fonte de imagens. Os descritores sozinhos podem levar a resultados enganosos, se a informação de conectividade ou de adjacência não for levada em consideração no processo de crescimento de regiões.

2.3. Textura

Em muitos algoritmos de visão de máquina e processamento de imagens, são feitas suposições simplificadas sobre a uniformidade de intensidades nas regiões da imagem. Entretanto, imagens de objetos reais muitas vezes não exibem regiões de intensidades

uniformes. Por exemplo, a imagem da superfície da madeira não é uniforme, mas contém variações de intensidades que certamente forma um padrão repetido chamado textura visual. O padrão pode ser o resultado das propriedades semelhantes da superfície física como irregularidade (rugosidade) ou a margem orientada freqüentemente tem uma qualidade tangível, ou eles podem ser os resultados de diferentes reflexões das cores em uma superfície (CHEN et al., 1993).

A textura constitui uma característica diretamente relacionada com as propriedades físicas que a superfície de um objeto apresenta (lisa, rugosa, macia, áspera ou ondulada). Ela descreve o padrão de variação de tons de cinza ou cor numa determinada área. Trata-se de um termo intuitivo e de largo emprego, mas que, apesar de sua grande importância, não possui uma definição precisa.

Uma textura se caracteriza pela repetição de um modelo sobre uma região, sendo este modelo repetido em sua forma exata ou com pequenas variações. Através de sua análise é possível distinguir regiões que apresentem as mesmas características de refletância, e portando, mesmas cores em determinada combinação de bandas. Isso torna a textura um excelente descritor regional, contribuindo para uma melhor precisão dos processos de reconhecimento, descrição e classificação de imagens (HARALICK, 1973; PRATT, 1991; RIBEIRO Jr., 1995; TUCERYAN E JAIN, 1998; STEIN, 2005; DE-HUI et al., 2006; NUNES e CONCI, 2007).

As imagens das frutas podem ser caracterizadas pela suavidade ou pela rugosidade. De acordo com Haralick, a textura de uma imagem pode ser decomposta em duas dimensões básicas, sendo a primeira as primitivas da qual a imagem é composta e a segunda a descrição da dependência espacial ou interação das primitivas da textura de uma imagem (HARALICK, 1979). A primeira dimensão está relacionada com a tonalidade ou propriedades locais, e a segunda está relacionada com a organização espacial das primitivas tonais.

Uma primitiva é um conjunto conectado de células de resolução caracterizado por uma lista de atributos, sendo um *pixel* o mais simples com o seu atributo nível de cinza. Tons de cinza e propriedades locais não são os únicos atributos possíveis das primitivas. Outros atributos, como medidas de forma de regiões conectadas e homogeneidade das propriedades locais também podem ser utilizadas. Muitos tipos de primitivas podem ser gerados ou construídos de dados de imagens por uma ou mais aplicações de operadores de vizinhança.

Primitivas tonais são regiões com propriedades tonais, que incluem tanto tons de cinza como propriedades regionais destes tons. Elas podem ser descritas em termos de tonalidade média, máxima ou mínima de uma região. A região é um conjunto de *pixels* ligados por uma determinada propriedade tonal. A textura de uma imagem é descrita pelo número, tipos e a organização espacial ou esboço de suas primitivas. A organização espacial pode ser aleatória, pode ter uma dependência de um par discreto de primitivas sobre um vizinho primitivo, ou pode ter uma dependência de n primitivas ao mesmo tempo. Esta dependência pode ser estrutural, probabilística ou funcional (como uma dependência linear).

Uma vez que as primitivas forem construídas, é necessário avaliar a lista de primitivas, suas coordenadas centrais e seus atributos. É possível avaliar alguma informação topológica sobre as primitivas, como quais são adjacentes. A partir destes dados, é possível selecionar um relacionamento espacial simples com adjacência ou proximidade das primitivas e contar quantas primitivas de cada tipo ocorrem em um relacionamento espacial especificado.

A textura de uma imagem pode ser avaliada qualitativamente como tendo uma ou mais das seguintes propriedades: fineza, grossura, suavidade, granularidade, aleatoriedade, padronização, ou sendo irregular ou acidentado.

Para utilizar objetivamente a tonalidade e os elementos texturais padrões, os conceitos de características tonais e texturais devem estar explicitamente definidos. Com essa definição explícita tem-se que os conceitos de tonalidade e textura não são independentes, os dois definem um único conceito de tonalidade-textura.

As bases de inter-relações no conceito de tonalidade-textura são relacionadas de forma que quando uma pequena área de uma imagem tem pouca variação da primitiva tonal, a propriedade dominante daquela área é a tonalidade, caso contrário, a propriedade dominante naquela área é a textura. Para se caracterizar textura, devem-se caracterizar as propriedades das primitivas tonais assim como a inter-relação entre elas.

2.3.1. Análise de Textura

As três principais abordagens usadas no processamento de imagens para descrever a textura de uma região são (JAIN, 1989): Estrutural: as regiões da textura são

consideradas como padrões bidimensionais compostos por primitivas que se relacionam. Métodos estatísticos, por sua vez, produzem melhores resultados quando aplicados sobre imagens texturais estruturais. Estatística: utiliza um conjunto de medidas estatísticas locais para representar uma imagem texturizada. Métodos estatísticos, por sua vez, produzem melhores resultados quando aplicados sobre texturas naturais. Espectral: baseada em propriedades de espectros de frequência, obtidos através de transformadas tais como Fourier e a Wavelets. A Figura 24 ilustra com diagrama de blocos os principais métodos de abordagem para medida de textura.

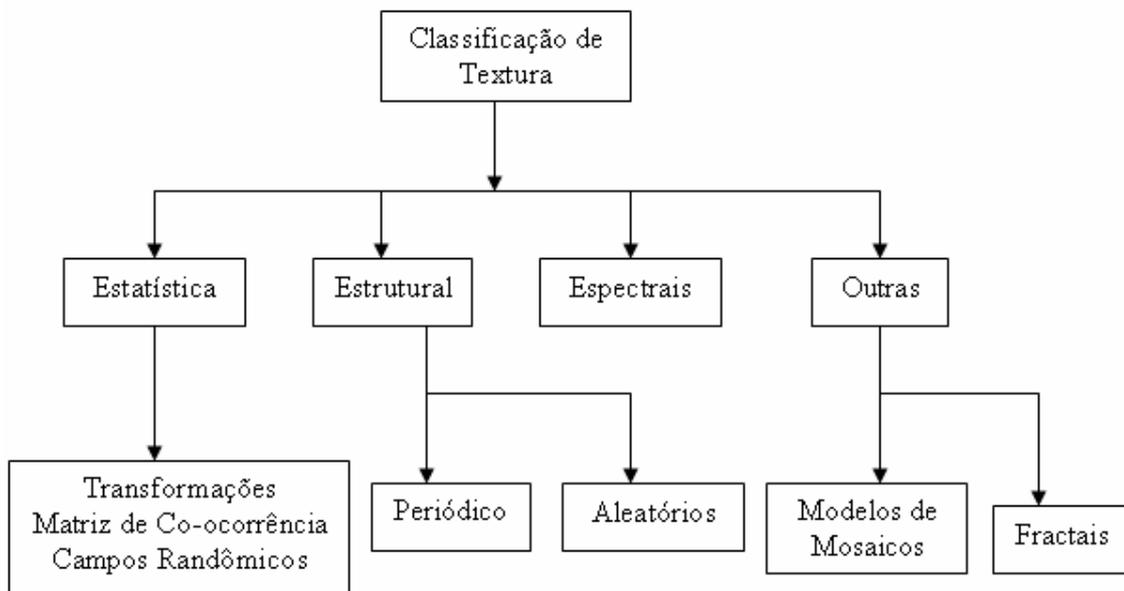


Figura 24 – Métodos de Análise de Texturas (Ribeiro Jr, 1995), adaptado de (JAIN, 1989).

A abordagem é estrutural quando as primitivas são explicitamente definidas, e é estatística quando a interação espacial, ou a falta, é medida pelas probabilidades.

2.3.2. Abordagem Estatística

A abordagem estatística propicia a descrição de imagens por meio de regras estatísticas que governam tanto a distribuição quanto à relação dos diferentes níveis de cinza. A abordagem estatística pode ser dividida em duas vertentes: a de primeira ordem, na qual se

extraem características a partir de histogramas de primeira ordem, e a segunda, que leva em conta o posicionamento relativo da ocorrência dos níveis de cinza (HARALICK, 1979).

As matrizes de co-ocorrência formam a base para elaboração de diversas medidas estatísticas conhecidas como descritores de Haralick.

2.3.2.1. Matriz de co-ocorrência

O método freqüentemente citado para análise de textura estatística está baseado na extração de várias características texturais de uma matriz de co-ocorrência nivelada em cinza (GLCM). Um GLCM é uma matriz de tamanho $N_g \times N_g$ (N_g é o número de níveis de cinzas) definido para um deslocamento de uma distância δ junto com uma determinada direção θ . A entrada $P(i, j)$ desta matriz é o número de ocorrências de um par de níveis cinza, i e j , para o deslocamento especificado. Uma vez que o GLCM é definido, vários descritores texturais podem ser avaliados (BILLY et al., 2006). São considerados os mais usados: a entropia, a energia, o contraste, homogeneidade local assim como a correlação, que são definidos a seguir:

Energia: também conhecida como segundo momento angular avalia a uniformidade textural em uma imagem.

$$energia = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P_{\delta,\theta}(i, j)^2 \quad (16)$$

Entropia: mede a desordem em uma imagem, ou seja, o grau de dispersão de níveis de cinza.

$$entropia = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P_{\delta,\theta}(i, j) \log(P_{\delta,\theta}(i, j)) \quad (17)$$

Contraste ou variância: mede a presença de transição abrupta de níveis de cinza (bordas) na imagem.

$$contraste = \sum_{k=0}^{N_g-1} k^2 \left[\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P_{\delta,\theta}(i,j) \right], se \quad |i-j|=k \quad (18)$$

Homogeneidade local: como o próprio nome sugere, mede a homogeneidade da imagem.

$$homogeneidade = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{1}{1+(i-j)^2} P_{\delta,\theta}(i,j) \quad (19)$$

Correlação: mede a dependência linear de um nível de cinza em relação aos vizinhos.

$$correlação = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{(i-\mu_x)(j-\mu_y)P_{\delta,\theta}(i,j)}{\sigma_x\sigma_y} \quad (20)$$

onde μ_x e μ_y representam as médias nas direções x e y, respectivamente e σ_x e σ_y representam os desvios padrões.

2.3.3. Abordagem Estrutural

O modelo estrutural é baseado na idéia de que texturas são compostas de primitivas dispostas de forma aproximadamente regular e repetitiva, de acordo com regras bem definidas. Para descrever textura é necessário descrever as primitivas e as regras de localização (HARALICK, 1979).

2.3.3.1. Agrupamento de Primitivas

Os níveis de primitivas podem ser detectados em texturas hierárquicas – primitivas de nível mais baixo formam alguns padrões específicos os quais podem ser considerados com maior nível de descrição. O agrupamento de primitivas é o processo de detecção destes padrões de primitivas (unidades) em uma textura. Estas novas unidades podem formar novos padrões, e até mesmo um nível de descrição maior, este processo de agrupamento deve ser repetido até que novas unidades não possam ser formadas (SONKA et al., 1998).

O agrupamento torna possível a segmentação de textura por abordagem estrutural. Ele utiliza as mesmas regras do cálculo local das características de textura em reconhecimento de textura estatístico. As primitivas que são diferentes ou relacionamentos espaciais diferentes representam texturas diferentes.

Sonka e colaboradores (SONKA et al., 1998) descrevem o algoritmo de agrupamento de primitivas como: Regiões formadas a partir de primitivas de baixo nível podem ser consideradas como primitivas de nível mais alto e o processo de agrupamento pode ser repetido para estas novas primitivas. Entretanto, é necessário o controle sofisticado do processo de agrupamento para arquivar os resultados significativos – isto deve ser controlado por um subsistema de visão de entendimento de textura de alto nível. A Figura 25 mostra a estrutura do algoritmo desenvolvido por Sonka e colaboradores em 1998.

Algoritmo 1: Agrupamento de Primitivas de Textura

1. Determinar as propriedades da primitiva de textura e classificá-las em classes.
2. Encontrar o primeiro e o segundo vizinhos mais próximos de cada primitiva de textura. Utilizando a classe de primitivas e as distancias das duas primitivas vizinhas d_1 e d_2 mais próximas, classificar essas primitivas de baixo nível em novas classes.
3. Primitivas com as mesmas novas classificações, que estão conectadas (próximas umas a outras), são ligadas e formam primitivas de nível mais alto.
4. Se duas regiões homogêneas quaisquer resultarem em sobreposição de primitivas conectadas, a região de sobreposição se torna uma região de separação.

Figura 25 – Algoritmo para o agrupamento de primitivas de textura.

2.4. Cor

O processo de seleção de frutas consiste normalmente na inspeção humana considerando características como cor e tamanho. Um sistema automático para tal finalidade deve ser capaz de identificar os parâmetros de forma adequada. A caracterização da luz é essencial para a ciência das cores.

A cor é uma percepção visual provocada pela ação de um feixe de fótons sobre as células especializadas da retina, que transmitem através de informação pré-processada no nervo óptico, impressões para o sistema nervoso. A cor está relacionada com os diferentes comprimentos de ondas do espectro eletromagnético (UMBAUGH et al., 1998). A Figura 26 ilustra o comprimento de onda das cores: vermelho, laranja, amarelo, verde, ciano, azul e violeta.

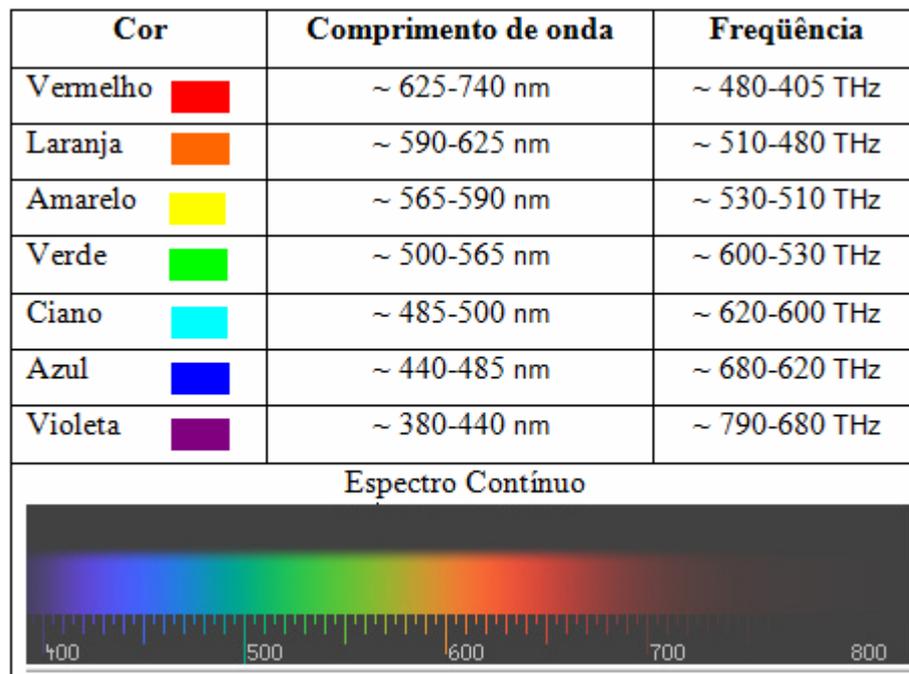


Figura 26 – Espectro visível da luz solar, demonstrando por decomposição que esta é formada por um conjunto de radiações visíveis que vão do vermelho ao violeta.

2.4.1. Fundamentos da Cor

Com o propósito de facilitar a especificação das cores em uma forma padrão e de aceitação geral, vários modelos de cores foram propostos para o processamento de imagens digitais (PID). Um modelo de cor, de uma maneira geral, é um sistema de coordenadas tridimensionais onde cada cor é representada por um único ponto (GONZALEZ e WOODS, 1992). Existem vários modelos de cores, sendo os mais comuns: o RGB (red, green, blue – vermelho, verde, azul), usado para representação da cor em monitores coloridos e câmeras de vídeo; o CMY (cyan, magenta, yellow – ciano, magenta, amarelo), usado em impressoras coloridas; o YIQ é o padrão para transmissão de TV colorida; o HSI (hue, saturation, intensity - matiz, saturação, intensidade), sendo o último usado para manipulação de imagens coloridas. A maioria dos sistemas relaciona-se entre si. A Figura 27, por exemplo, apresenta a relação em um espaço tridimensional entre os sistemas RGB e CMY.

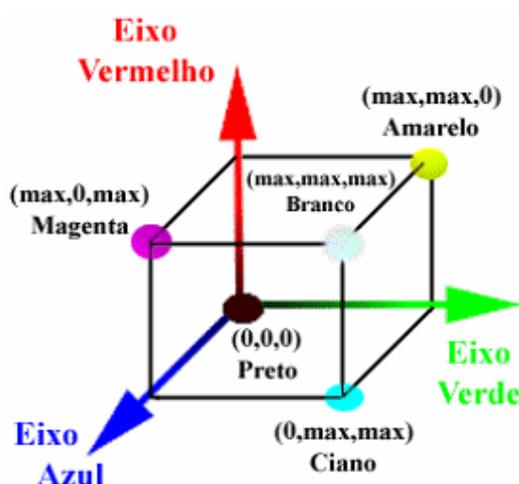


Figura 27 – Representação tridimensional das cores no sistema RGB e CMY.

2.4.1.1. Modelo RGB

Baseando-se no modelo RGB, uma matriz (ou *bitmap*) representa uma imagem colorida digital na memória de um computador (BAXES, 1994). Um *bitmap* é constituído de fileiras ou carreiras de *pixels* dispostas em colunas. Cada *pixel* tem um valor particular que determina a sua cor. Esse valor é determinado por três números que representam a decomposição de cada cor nas três cores primárias.

Toda a cor visível ao olho humano pode ser representada desta maneira. A decomposição de uma cor nas três cores primárias gera três valores entre 0 e 255. Por exemplo, o branco que constitui a soma de todas as cores é codificado como $R = 255$, $G = 255$, $B = 255$; o preto, ao contrário do branco, caracteriza-se pela ausência de cor e, por isso, é representado como $R = 0$, $G = 0$, $B = 0$; o amarelo é representado pela soma do vermelho com o verde, logo seria $R = 255$, $G = 255$, $B = 0$.

2.4.1.2. Modelo CMY

A maioria dos dispositivos que depositam pigmentos coloridos sobre papel, como impressoras coloridas e copiadoras, requerem dados de entrada CMY ou desempenham uma conversão de RGB para CMY internamente (GONZALEZ e WOODS, 1992).

$$\begin{bmatrix} C \\ M \\ Y \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix} - \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad \begin{bmatrix} C \\ M \\ Y \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix} - \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (21)$$

Assume-se que todos os valores de cores foram normalizados no intervalo $[0,1]$.

2.4.1.3. Modelo YIQ

O modelo YIQ é uma recodificação de RGB para eficiência da transmissão e para manutenção da compatibilidade com os padrões monocromáticos de TV (GONZALEZ e WOODS, 1992).

$$\begin{bmatrix} Y \\ I \\ Q \end{bmatrix} = \begin{bmatrix} 0.299 & 0.587 & 0.114 \\ 0.596 & -0.275 & -0.321 \\ 0.212 & -0.523 & 0.311 \end{bmatrix} = \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (22)$$

2.4.1.4. Modelo HSI

O HSI é de grande interesse, uma vez que permite separar as componentes de matriz, saturação e intensidade da informação de cor em uma imagem. Sua utilização é mais intensa em um sistema de visão artificial, pois suas características tornam-se uma ferramenta ideal para o desenvolvimento de algoritmos de processamento de imagens fortemente baseados no modelo de percepção de cor pelo ser humano (GONZALEZ e WOODS, 1992). Como exemplos: projeto de sistemas de imageamento para determinação automática do amadurecimento de frutas e vegetais ou sistemas para correspondência de amostras de cores, ou para inspeção de qualidade de produtos coloridos. A Figura 28 ilustra o triângulo de cores e o sólido de cores HSI.

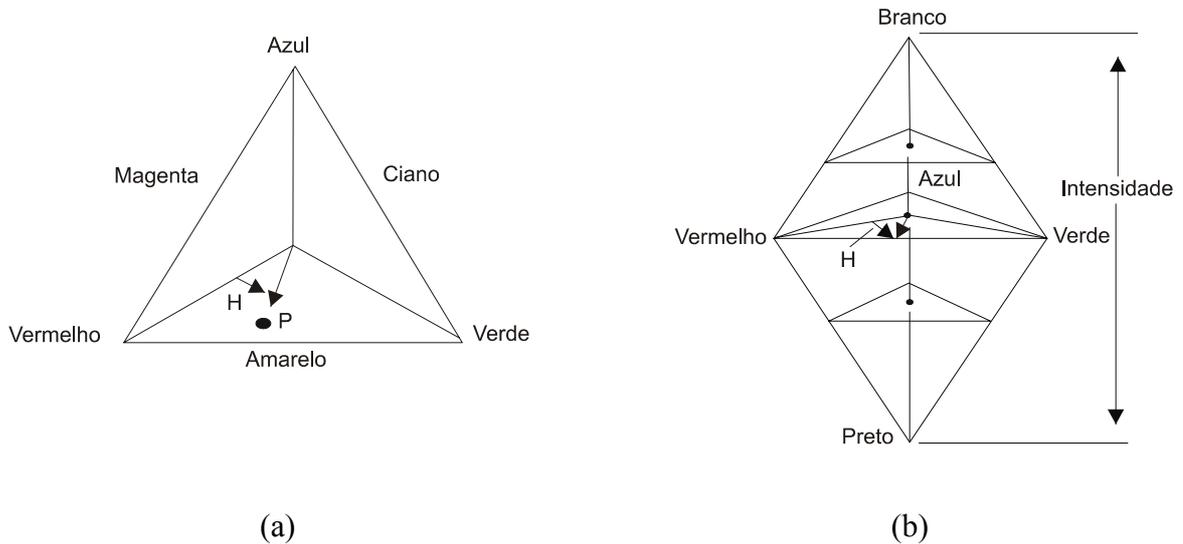


Figura 28 – (a) Triângulo de cores HSI; (b) Sólido de cores HSI.

As fórmulas de conversão de RGB para HSI e vice-versa são consideravelmente mais complicadas do que para outros modelos.

A combinação do matiz, saturação, e intensidade num espaço de cores tridimensionais resultam na estrutura piramidal de três lados mostrada na Figura 28(b). Qualquer ponto na superfície dessa estrutura representa uma cor puramente saturada.

As cores no modelo HSI são definidas com respeito aos valores normalizados do vermelho, verde e azul, dados termos das primárias RGB por:

$$\left. \begin{aligned} r &= \frac{R}{R+G+B} \\ g &= \frac{G}{R+G+B} \\ b &= \frac{B}{R+G+B} \end{aligned} \right\} \quad (23)$$

em que, como antes, assume-se que R, G e B foram normalizadas de modo que estejam no intervalo [0, 1]. As equações 24 mostram que r, g e b também estão no intervalo [0, 1] e que $r+g+b=1$.

A conversão de RGB para HSI é dada por:

$$\left. \begin{aligned} I &= \frac{1}{3}(R+G+B) \\ S &= 1 - \frac{3}{R+G+B}[\min(R,G,B)] \\ H &= \cos^{-1} \left\{ \frac{\frac{1}{2}[(R-G)+(R-B)]}{[(R-G)^2 + (R-B)(G-B)]^{\frac{1}{2}}} \right\} \end{aligned} \right\} \quad (24)$$

2.5. Medida de área e perímetro

Informações relativas a informações 3D dos objetos são perdidas durante a aquisição da imagem, medidas de tamanho de objetos em imagens digitais são restritas em uni e bidimensional. As medidas de volume e de superfície se encontram em objetos 3D, por isso são menos populares. As medidas de largura, área e perímetro são as mais utilizadas para determinar o tamanho do objeto.

A área e o perímetro são calculados simplesmente através da contagem do número de *pixels* pertencentes a um objeto. A área refere-se à parte interior do objeto, computada como o número total de *pixels* dentro do objeto, incluindo o seu contorno. O perímetro mede a quantidade de *pixels* em torno do objeto. Para medir o perímetro com precisão, quando o *pixel* do contorno é conectado com seu vizinho verticalmente ou horizontalmente a distância de *pixel* é uma unidade (1) , ou quando o *pixel* é conectado com seu vizinho na diagonal a distância de *pixel* é $\sqrt{2}$ (1, 414). Não importa se a forma do objeto é irregular, a medida de área e perímetro é estável e eficiente uma vez que o objeto tenha sido segmentado de forma adequada do fundo. O cálculo do comprimento e largura é muito mais complexo, pois os objetos alimentares têm formas muito irregulares.

2.5.1. Forma

A forma é outra medida geométrica de interesse para produtos alimentares. Além disso, a forma tem um papel importante na decisão de compra pelos clientes (LEEMANS e DESTAIN, 2004), e isso estabelece um valor na medida da forma nas aplicações de visão computacional para a inspeção da qualidade dos alimentos.

Alguns métodos foram desenvolvidos para caracterizar a forma dos produtos, incluindo duas grandes categorias: dependente das medidas de tamanho e independente das medidas de tamanho.

2.5.1.1. Medidas de tamanho

O SDM (Size-dependent measurements) são descritores de forma. Estes descritores são formados pela combinação das medidas de tamanho.

- Densidade: é a razão de área sobre o quadrado do perímetro.
- Alongamento: é a razão do eixo maior sobre o eixo menor.
- Convexidade: é a razão do perímetro convexo sobre o perímetro.
- Rugosidade: é a razão da área sobre o quadrado do maior eixo.

2.5.1.2. Medidas de tamanho baseado em regiões

A medida ideal de forma é aquela que pode ser utilizada para discriminar uma forma de outra adequadamente. Em outras palavras, com esta medida, cada forma tem um valor único (circularidade, elipsóide, etc.) (RUSS, 1999). Portanto, a SDM pode não ser suficiente para caracterizar a forma de cada produto, devido à irregularidade de forma. A chance de dois produtos com formas diferentes e irregulares resultarem em um mesmo valor de medida quando utilizado uma das combinações da SDM é muito grande. Um método que pode ser utilizado na medida independente de tamanho é o baseado em região.

O método baseado em região, também conhecido como momento espacial, é baseado na característica estatística da região do objeto. Como *pixels* são os elementos básicos que formam a região do objeto em imagens digitais, o momento espacial consiste em estatísticas relativas a informações geográficas de todos os *pixels* no interior do objeto (JAIN, 1989). A medida mais simples do momento espacial é o centro de massa (\bar{x}, \bar{y}) , que pode ser calculado pelas seguintes equações:

$$\left. \begin{aligned} \bar{x} &= \frac{1}{N} \sum_x \sum_y x \\ \bar{y} &= \frac{1}{N} \sum_x \sum_y y \end{aligned} \right\} \quad (25)$$

onde N é o número total de *pixel* dentro do objeto, e (x, y) é a coordenada do *pixel*. O momento central (p, q) pode ser obtido por:

$$M_{pq} = \sum_x \sum_y (x - \bar{x})^p (y - \bar{y})^q \quad (26)$$

onde p e q são a ordem dos momentos.

Os momentos centrais são invariantes sob uma tradução das coordenadas e dessa forma, são características úteis para descrever a forma do objeto (JÄHNE, 1997). A Figura 29 apresenta os eixos principais do tensor de inércia de um objeto.

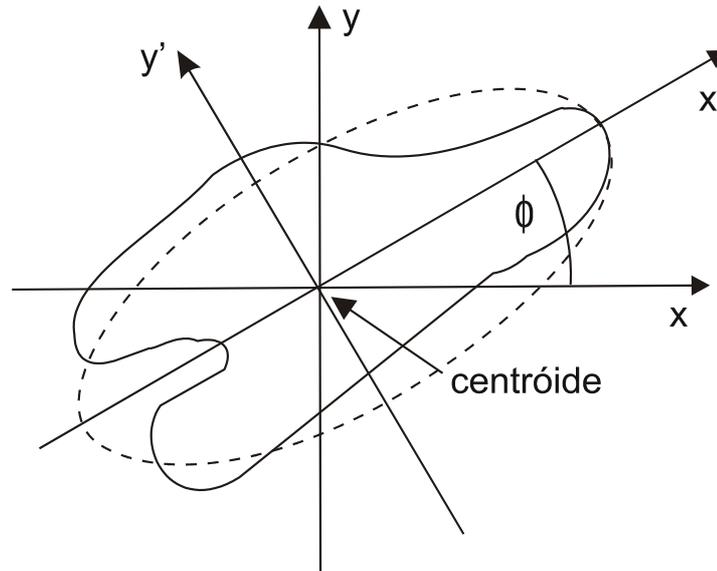


Figura 29 - Eixos principais do tensor de inércia de um objeto para rotação em torno do centro de massa (JÄHNE, 1997).

2.6. Técnicas de Classificação de Imagens

A maior tarefa após a extração de características de uma imagem é caracterizada pela classificação do objeto extraído em alguma categoria (JAIN, 1989). A classificação de imagens e extração de características tem objetivos muito próximos. A classificação pode levar a segmentação e vice-versa. Existem duas abordagens de classificação de imagens que são: não supervisionada e supervisionada.

2.6.1. Classificação não Supervisionada

A classificação não supervisionada é a opção mais adequada quando a área investigada é desconhecida, ou quando suas características não são bem definidas.

O objetivo é a identificação de agrupamentos (denominados clusters) na imagem. Um agrupamento é um grupo de pontos na imagem que possui uma densidade local elevada comparada com a densidade de outras áreas da imagem. Esta técnica é utilizada para segmentação ou para compressão, pois pode identificar padrões em imagens, permitindo assim definir grupos não relevantes para codificação (JAIN, 1989).

2.6.2. Classificação Supervisionada

As técnicas de classificação supervisionadas baseiam-se na disponibilidade de uma amostra representativa de cada classe identificada. Estas amostras são informações a respeito do comportamento médio das classes e podem ser denominadas como "*pixels* de treinamento" do sistema. A seleção das amostras de treinamento é essencial para que o processo classificatório seja bem sucedido, é importante que as amostras sejam bastante homogêneas (COSTA e CESAR Jr., 2001).

As técnicas de classificação supervisionadas apresentam dois métodos: distribuição livre e estatística, isto é:

Distribuição livre: não necessita de nenhum tipo de conhecimento, visto que funções de probabilidade são suficientes para a aplicação deste método. Pode ser entendida supondo-se que existem K diferentes objetos, ou classes de padrões definidas por S_1, S_2, \dots, S_k , cada classe caracterizada por apresentar M_k diferentes protótipos em uma imagem. Uma função fundamental de reconhecimento de padrões, chamada função discriminante, irá dividir o espaço em k diferente regiões, cada uma delas apresentando padrões similares.

Classificação estatística: baseia-se em modelos de distribuição de probabilidades que podem ou não ser parametrizadas. São caracterizadas por apresentar, para cada classe de padrões, uma função densidade de probabilidade, que, associada a cada grupo, define a probabilidade existente de uma determinada classe e seus respectivos objetos estarem presentes na imagem e com que densidade. É caracterizado por ter um fundamento explícito do modelo de probabilidade, por exemplo, a teoria *Bayesiana*, que é matematicamente rigorosa e fornece uma abordagem probabilística para inferência. Baseado em domínio matemático bem estabelecido, a classificação estatística foi provada com sucesso em aplicações de visão computacional para a avaliação da qualidade de produtos alimentares.

2.6.2.1. Classificação Bayesiana

A teoria de decisão *Bayesiana* é uma abordagem estatística fundamental para o problema de classificação de padrões. Ela se baseia em quantificar a troca entre as diversas decisões de classificação utilizando probabilidade e os custos que acompanham essas decisões (DUDA et al., 2000). Um classificador *Bayesiano* classifica um objeto na classe a que é mais

provável pertencer baseado nas características observadas. Cada classe de padrões tem sua probabilidade conhecida, porém seus padrões podem ser completamente conhecidos ou não, muitas vezes devem-se estimar os atributos dos padrões para análise. Os estados da natureza possíveis são chamados de classes ω , sendo que $\omega = \omega_1$ para uma primeira classe, $\omega = \omega_2$ para uma segunda classe e $\omega = \omega_n$ para uma classe n .

A probabilidade a priori² ω_j é o conhecimento anterior ao problema e é denotado por $P(\omega_j)$. Como esta informação não é suficiente para decidir em favor de uma classe ou outra é necessário levar em conta os atributos das classes em questão.

Um dado vetor de atributos X cujo domínio é uma variável aleatória com d -componentes, a função densidade de probabilidade condicional $p(X | \omega_j)$, é a probabilidade de ocorrer X sendo ω_j a classe verdadeira. Pela regra de *Bayes* temos:

$$P(\omega_j | X) = \frac{p(X | \omega_j)P(\omega_j)}{p(X)} \quad (27)$$

onde

$$p(X) = \sum_{j=1}^N p(X | \omega_j)P(\omega_j) \quad (28)$$

onde N é o número de classes.

Assim o critério de decisão pode ser definido como:

$$Decidir \begin{cases} \omega_1 & \text{caso } P(\omega_1 | X) > P(\omega_2 | X) \\ \omega_2 & \text{caso } P(\omega_2 | X) > P(\omega_1 | X) \end{cases} \quad (29)$$

E a probabilidade de erro da decisão:

² Probabilidade a priori: Probabilidade que precede a experiência. Conhecimento proposicional adquirido antes da experiência através de informações obtidas pela percepção.

$$P(e) = \begin{cases} P(\omega_1 | X) & \text{caso } \omega_2 \text{ escolhido} \\ P(\omega_2 | X) & \text{caso } \omega_1 \text{ escolhido} \end{cases} \quad (30)$$

E a média de erro (ou risco médio) é dada por

$$P(e) = \int_{-\infty}^{\infty} p(e | X) p(X) dx \quad (31)$$

A regra de decisão de *Bayes* ocorre pela máxima probabilidade a posteriori, ou critério MAP, onde a decisão será em favor da probabilidade que minimiza o erro.

2.7. Visão Computacional

O objetivo da área de Visão Computacional é determinar as características dos objetos em uma imagem. Baseada em Análise e Processamento de imagens, a visão computacional é uma nova tecnologia de reconhecimento de objetos que extrai informação quantitativa a partir de imagens digitais a fim de fornecer informações objetivas, de maneira rápida, sem-contato e não-destrutiva para a avaliação da qualidade (GUNASEKARAN, 1996).

O desenvolvimento de algoritmos capazes de extrair informações presentes em uma imagem é influenciado pela compreensão dos processos de aquisição de imagens e de sua percepção no sistema visual. O processo de visão abrange a visão de “baixo nível” (pré-processamento da imagem), visão de nível intermediário (Extração de características) e processamento em alto nível (formação e reconhecimento de objetos), conforme ilustra a Figura 30.

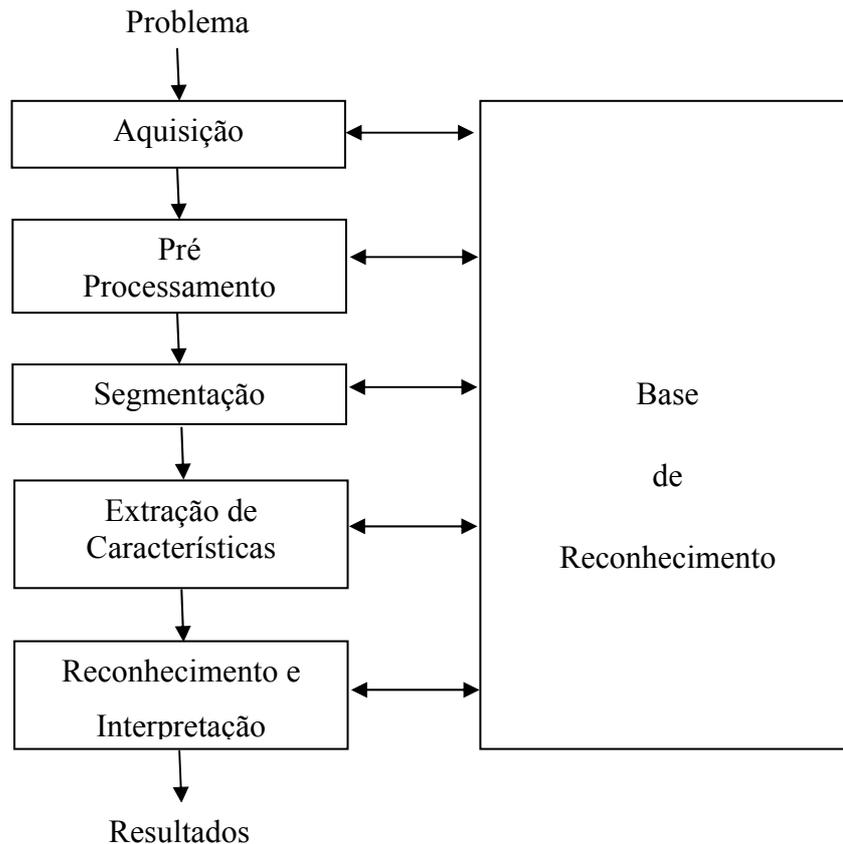


Figura 30 – Estrutura de um sistema de visão computacional (MARQUES e NETO, 1999).

O primeiro passo no processo é a aquisição de imagens do objeto de interesse. Para tanto, são necessários um sensor e um digitalizador. O sensor converterá a informação óptica em sinal elétrico e o digitalizador transformará a imagem analógica em imagem digital. Uma imagem pode ser considerada uma distribuição de energia luminosa em uma posição espacial. Parte dessa energia luminosa é absorvida pelo objeto, parte é transmitida e parte é refletida, sendo capturada pela câmera. Os dispositivos de aquisição de imagens mais utilizados atualmente são a câmera CCD (*Charge Couple Device*) e a câmera CMOS (*Complementary Metal-Oxide-Semiconductor*). Eles são formados por uma matriz de células semicondutoras fotossensíveis que atuam como capacitores, armazenando carga elétrica proporcional à energia luminosa incidente. Para aquisição de imagens coloridas utilizando CCD, é necessário um conjunto de prismas e filtros de cor encarregados de decompor a imagem colorida em suas componentes RGB, cada qual capturada por um CCD independente. Em geral, as imagens são formadas pela luz incidente no espectro visível, com os fótons sendo recolhidos pela lente da câmera e convertidos em sinais elétricos por tubo a vácuo ou pelo CCD (JÄHNE, 1997).

Nos sensores CMOS, os elementos fotossensíveis estão diretamente acoplados em resistores, permitindo uma contínua transformação da quantidade luminosa recebida em um sinal elétrico proporcional. Uma das tecnologias básicas desses sensores são os sensores de Pixel Ativo, APS (Active-Pixel Sensor). A característica principal de um APS é o uso de pelo menos um elemento ativo dentro de cada pixel. As amostras analógicas de cada pixel são endereçadas por colunas, e depois lidas por conversores A/D (Analogico/Digital) fora da matriz de pixels. Nos APS, normalmente cada coluna possui seu próprio conversor A/D, mas também existem implementações de apenas um conversor A/D de alta velocidade para a matriz inteira (RUSS, 2007).

Além disso, a alta qualidade da iluminação é absolutamente decisiva na aquisição de imagens em sistemas de visão computacional. Para garantir um bom nível de iluminação é necessário seguir 3 regras:

- Compreender a função da componente de iluminação artificial nas aplicações de visão de máquina.
- Conhecer o comportamento da luz em uma determinada superfície.
- Conhecer as técnicas básicas disponíveis de iluminação artificial que permitirá que a luz crie o recurso desejado.

Quando a luz é de baixa intensidade, podem ocorrer os seguintes efeitos:

- Relação sinal ruído insuficiente na câmera.
- O ruído elétrico tende a aumentar à medida que a luz fica obscura ou menos intensa.
- Uma menor intensidade luminosa causa uma perda significativa da profundidade do campo na câmera.

Quando a luz é muito mais intensa do que deveria ser, podem ocorrer os seguintes efeitos:

- Menor sinal ruído.
- Alta intensidade de brilho na superfície dos objetos, dificultando a distinção de outros e do plano de fundo.
- Aumento da reflexão difusa ou especular.

As lâmpadas incandescentes possuem uma fonte de distribuição normal ao longo do espectro visível, enquanto que as fluorescentes apresentam picos acentuados em

algumas regiões. Isto significa que os objetos em uma fonte incandescente produzem um menor sinal ruído. Isto não é aceitável em alguns casos, especialmente aqueles que estão preocupados com a transformação da cor em uma imagem (DALEY et al., 1993). As lâmpadas fluorescentes são inerentemente mais eficientes, produzem uma iluminação intensa em determinados comprimentos de onda. No entanto, é necessário ter cuidado quando se utiliza a luz fluorescente, pois esta fonte é normalmente AC (*Alternating Current*). Além da luz, a geometria da superfície também é importante no desenho da iluminação. O fator chave é determinar se a superfície é especular ou difusa. Em superfície difusa a luz é dispersa por causa de inúmeros ângulos na superfície e em uma superfície especular a luz é refletido no ângulo de incidência. Portanto a posição de uma luz é muito importante para atingir um alto contraste na imagem. O próximo passo trata da captura da imagem, o que envolve dois elementos chaves que são responsáveis por esta situação: a câmera e o capturador de *frames*. A câmera converte fótons em sinais elétricos, e o capturador de *frames* digitaliza esses sinais.

O pré-processamento da imagem resultante do passo anterior pode apresentar diversas imperfeições, tais como: presença de *pixels* ruidosos, contraste ou brilho inadequado, caracteres interrompidos ou indevidamente conectados, etc. Ao se trabalhar em processamento de imagens, as operações de realce e restauração são básicas. O realce tem por objetivo destacar detalhes da imagem que são interessantes para análise. A restauração busca compensar deficiências específicas, geradas no momento de aquisição, na transmissão ou em alguma etapa do processamento. A imagem resultante desta etapa é uma imagem digitalizada de melhor qualidade que a original.

A segmentação divide uma imagem em suas unidades significativas, ou seja, nos objetos de interesse que a compõem. A operação de segmentação mais simples é a limiarização ou separação por “tom de corte”. A partir da separação e caracterização dos objetos, as operações de extração de características podem ser consideradas. Essa abordagem é interessante quando as imagens apresentam duas classes (fundo e objeto). Se a intensidade dos valores dos *pixels* do objeto encontra-se num intervalo e a intensidade do fundo encontra-se fora desse intervalo, uma imagem obtida pode ser binária usando-se uma operação de limiarização que agrupa os pontos do primeiro intervalo com o valor 1 e o do segundo com o valor 0.

Extração de característica é a etapa que procura extrair características das imagens resultantes da segmentação através de descritores que permitem caracterizar com

precisão cada objeto de interesse. Utilizando-se imagens já segmentadas ou binárias, torna-se possível obter dados relevantes ou atributos das regiões ou dos objetos destacados. Os tipos de atributos ou características mais comuns são: número total de objetos, dimensões, geometria, propriedades de luminosidade e textura. As características dimensionais são, por exemplo: área, perímetro, centro de gravidade, larguras máxima e mínima, comprimentos, etc. As propriedades geométricas descrevem as formas dos objetos, tais como circularidade, retilinearidade, concavidade, eixos principais, etc. As propriedades de luminosidade e textura devem ser obtidas da imagem original antes da binarização, a partir da informação de posição dos diversos objetos, fornecida pela imagem segmentada. Conhecendo-se a região da imagem original correspondente ao objeto segmentado, extraem-se dessa região as características de luminosidade e textura.

Denominamos reconhecimento o processo de atribuição de um rótulo a um objeto baseado em suas características, traduzidas por seus descritores. A tarefa de interpretação consiste em atribuir significado a um conjunto de objetos reconhecidos. Uma vez que os descritores da imagem e dos objetos segmentados encontram-se disponíveis, passa-se à etapa seguinte, que consiste em distinguir objetos na imagem agrupando esses parâmetros de acordo com sua semelhança para cada região de *pixels* encontrados. O processo de reconhecimento pode ocorrer em dois momentos em um sistema de visão computacional: a) as características são extraídas com o objetivo de que os objetos sejam reconhecidos como pertencentes a um mesmo grupo e então sejam classificados em uma base de imagens. b) novos objetos são apresentados ao sistema, que os reconhece, comparando suas características com aquelas dos objetos das classes previamente estabelecidas.

Na base de conhecimento pressupõem a existência de um conhecimento, cujo tamanho e complexidade podem variar. Idealmente, esta base deveria, não somente guiar o funcionamento de cada etapa, mas também permitir a realimentação entre elas.

A visão computacional utiliza algoritmos e representações que aproximem a imagem do modelo, ou seja, busca gerar um conjunto de representações que conectem a entrada (Imagem) com a saída (descrição, decisão ou interpretação) de maneira não rígida (BALLARD e BROWN, 1982).

A palavra visão está relacionada à capacidade que um ser tem de ver e entender o mundo em que habita. A imagem é formada na mente através das organizações física, química e biológica dos olhos. O mesmo se sucede na visão computacional. Ao invés dos

olhos, câmeras são utilizadas para se obter imagens digitais. Em cima dessas imagens são aplicadas técnicas computacionais para extrair informações desejadas do mundo tridimensional.

Finalmente, considera-se que o objetivo de um sistema de visão computacional é tomar decisões a partir da extração de informações do mundo real através de imagens. A tomada de decisão pode ser feita a partir de indagações simples a respeito de parâmetros extraídos dos objetos ou de algoritmos mais complexos de inteligência artificial (CONCI et al., 2008).

CAPÍTULO 3 – SISTEMA DE VISÃO COMPUTACIONAL PARA CLASSIFICAÇÃO DE FRUTAS

O controle de qualidade em frutas requer métodos seguros, capazes de avaliar com precisão e possivelmente de um modo não-destrutivo suas características físicas, contudo a utilização de visão computacional tem sido explorada visando o processo de veicular a qualidade de decisão do consumidor. Este capítulo apresenta uma revisão da literatura no tema para o período de 2003 a 2009.

3.1. Principais trabalhos desenvolvidos entre 1989 e 2000

Estudos preliminares realizados por Chen e colaboradores (CHEN et al., 1989) indicam a MRI (*Magnetic Resonance Imaging*) como uma poderosa ferramenta para fornecer informações sobre a estrutura interna de frutas inteiras, relacionado-as à qualidade, como a ocorrência de injúrias mecânicas, regiões desidratadas, danos por larvas, amolecimento interno e estágio de maturação.

Segundo Nascimento e Biscegli (NASCIMENTO et al., 1999; BISCEGLI et al., 2000) a condição fundamental para analisar se algum material por tomografia de ressonância magnética nuclear (MNR) é a presença de núcleos com momento magnético. No caso de frutas, o núcleo mais indicado é o do hidrogênio, que, devido a sua abundância, resulta num alto valor da relação sinal/ruído permitindo a obtenção de espectros e imagens em tempos curtos. A mobilidade desses núcleos de hidrogênio nos frutos varia com os processos metabólicos e maturação. Considerando que os parâmetros da ressonância magnética da água em alimentos são dependentes de sua arquitetura celular, as mudanças que afetam a sua estrutura podem ser detectadas por tomografia por ressonância magnética através da formação de imagens.

3.2. Principais trabalhos desenvolvidos entre 2003 e 2005

Simões e colaboradores (SIMÕES et al., 2003) apresentaram um estudo sobre classificação de laranjas (*Citrus sinensis*) baseadas em padrões visuais e propuseram um sistema automático completo para tarefa de classificação baseado no padrão brasileiro de cores e investigaram a aplicabilidade de quantização vetorial para a tarefa da comparação de padrões. A aplicação prática desta metodologia foi fortemente estimulada pelos resultados obtidos, que tiveram como característica inerente à robustez e à variação das condições de iluminação do ambiente. Para a tarefa de automação da classificação de laranjas baseada nas informações visuais, foi proposta uma abordagem utilizando: redes neurais artificiais do tipo *perceptron* multicamada para a classificação de *pixels* e a segmentação de imagens pelo algoritmo do crescimento de região. Tal algoritmo foi adotado devido principalmente à sua simplicidade e baixo custo computacional, contagem simples para a extração de padrões e agrupamento em Células de *Voronoi*³ para a comparação dos padrões. Após a calibração do sistema, um conjunto de testes foi proposto para examinar o poder de classificação. Foram utilizados imagens de 120 laranjas distintas, igualmente divididas em cada uma das classes. Para o teste de classificação de *pixels*, uma imagem com uma laranja típica de cada classe válida foi oferecida à rede e a um indivíduo para classificação da cor de seus *pixels*. A classificação realizada por humanos foi tomada como base para determinar a taxa de acerto da classificação da rede. Definiu-se a taxa T para cada classe (cor) de *pixels* como:

$$T = \left(\frac{100N_c}{N_T} \right) \% \quad (32)$$

onde N_c é o número de *pixels* classificados (pela rede) na classe considerada e N_T é o número total de *pixels* da classe atual (segundo o humano). Para avaliar a classificação do sistema, a totalidade das 120 laranjas foi apresentada ao sistema, e a taxa de acerto na classificação foi

³ Células de *Voronoi*: é a intersecção de todos semi-espacos definidos pelos bissetores.

anotada. De forma similar à análise anterior, a classificação realizada por um humano foi tomada como referência. Houve 100% de acerto nesta fase, para todas as classes.

Mendoza e Aguilera (MENDOZA e AGUILERA, 2004) implementaram um sistema de visão computacional para identificar o estágio de maturação de bananas (*Musa sapientum*) baseado na cor, desenvolvimento de manchas marrons, e informação da textura na imagem. Nove características de aparência (valores L^* , a^* , b^* ; porcentual de áreas marrons, números de manchas marrons por cm^2 , homogeneidade, contraste, correlação e entropia) foram extraídos de imagens de bananas e utilizados para classificação. A aquisição da imagem foi feita com uma câmera digital colorida. As imagens digitais foram processadas usando filtro linear passa baixo Gaussiano que permitiu pré-suavizar o ruído das imagens melhorando a sua qualidade. A segmentação foi um passo crítico para o processamento da imagem de bananas. O fundo foi removido usando o limiar 50 na escala de cinza combinada com uma técnica de detecção de extremidade baseada no Laplaciano. As imagens foram binarizadas utilizando o limiar 130, assim todos os *pixels* com valores mais alto que 130 pertenciam a manchas marrons da casca de banana. Para uma determinada orientação direcional e distância dos padrões, 14 características texturais de uma imagem foram extraídas com a matriz de tons de cinzas. Como a textura de imagens da banana pode representar características como cor, tamanho, e arranjo de características, isso pode ser direta ou indiretamente relacionado com os estágios de maturação. Somente 4 características texturais, homogeneidade, contraste, correlação e entropia, foram extraídos das imagens, outras características foram consideradas redundantes no estudo apresentado. Usando uma simples técnica de análise discriminante como critério de classificação esse método possibilitou a identificação de 49 bananas e seus 7 estágios de maturação com uma precisão de 98%. Esta aproximação se mostrou versátil, consistente, eficiente e econômico para a identificação de fases de maturação de bananas.

Para Gómez (GÓMEZ et al., 2005) a imagem termográfica é baseada no simples fato de que todos os objetos emitem certa quantidade de radiação térmica em função de sua temperatura. No entanto, ao contrário da visão computacional, as imagens térmicas não exigem uma fonte de iluminação. Além disso, muitas das grandes propriedades fisiológicas dos alimentos (firmeza, sólidos solúveis, conteúdo, e acidez) parecem estar altamente correlacionadas com o sinal IR (Infravermelho), o que implica que a análise de imagem termográfica IR é adequada para a avaliação da qualidade de um número de frutos e produtos agrícolas.

3.3. Principais trabalhos desenvolvidos entre 2006 e 2008

De acordo com Xu e colaboradores (XU et al., 2006) a medida de área da superfície e do volume fornece informações importantes para a agricultura e aplicações de processamento de alimentos. Eles apresentaram uma máquina de sistema de visão para medir volume e a área da superfície de objetos com formato irregular. Tal equipamento viabilizou a visualização de uma série de silhueta de um objeto em diferentes direções rotativas e com um intervalo angular fixo. O modelo de armação tridimensional do objeto pode ser reconstruído por integração da silhueta obtida de diferentes ângulos de visão. Silhuetas extraídas de duas imagens consecutivas formaram dois pedaços, um em cada lado de um eixo z. A imagem foi cortada em várias fatias com o mesmo intervalo angular, e a área de cada uma delas foi somada para encontrar a área total. Com a equação da área, o volume pode ser estimado e similarmente o perímetro pode ser aproximado e expressado como a soma de N linhas de segmentos. Assim, a área da superfície pode ser calculada como a soma dos perímetros. Um objeto esférico, como uma bola cuja área de superfície é calculada facilmente, foi usado para ajustar os resultados das medidas. Quatro tipos de frutas foram medidas: melão (*Cucumis melo*), morango (*Fragaria vesca*), maçã (*Malus domestica*) e tomate (*Lycopersicon esculentum*). A comparação foi executada entre os resultados medidos pelo sistema de visão de máquina apresentado no trabalho e por outro baseado no princípio de Arquimedes (*Instron Corp., Canton, MA*). Quando a fruta foi completamente submergida em água, o peso da água deslocado foi igual ao seu volume multiplicado pelo peso específico da água. O erro de porcentagem comum de medir todas as 20 amostras também foi calculado resultando em 2,4% para área de superfície e 2,5% para volume. Em comparação com outros métodos tradicionais esse método se mostrou rápido e preciso. A medida de volume depende fortemente do número de visualizações sobre as posições e concavidades do objeto em análise.

Song e colaboradores (SONG et al., 2006) verificaram a variação das características de vibração de uma pêra (*Pyrus communis*), fizeram simulações com elementos finitos. Com base em técnica de processamento de imagens obtiveram o modelo geométrico assimétrico e não esférico de uma pêra. Foram investigadas as características de vibração de peras com a correlação de seu comportamento, configurações geométricas e características de material usando análise modal numérica. O sistema de processamento de imagens usado consistiu de uma máquina fotográfica e um cartão de captura. O objeto de interesse foi

colocado em uma mesa e foram tiradas fotos de vários ângulos. Um *software* de análise digital foi usado para carregar as imagens da memória para exibição na tela. Um valor de limiar foi utilizado para separar os pontos do objeto com o fundo. Após filtrar o ruído, o programa determinou as extremidades do objeto e extraiu os pontos limites. Um *software* escrito em *Visual Basic* foi utilizado para mapear e obter as coordenadas do esboço, e então uma série de círculos foi obtida com base no esboço da seção do eixo realizado pelo programa. Finalmente, o modelo geométrico foi completado unindo o esboço externo da superfície da pêra. O modelo de análise de elemento finito é um procedimento numérico os quais as frequências naturais e o modelo (o padrão das deformações durante a vibração) de objetos são calculados e analisados. As primeiras 50 formas do modelo de uma pêra foram calculadas e as formas do modelo foram identificadas examinando o enredo de deformação e pela exibição do modelo animado. Volumes de três peras diferentes (volume de 325 cm³, volume de 250 cm³ e volume de 200 cm³), foram utilizados e as frequências de vibração foram calculadas separadamente. Para investigar o comportamento dinâmico deste tipo de pêra e a correlação de seu comportamento com configurações geométricas as propriedades como densidade, módulo de elasticidade⁴ foram usados para analisar a correlação entre volumes e frequências.

Para Santulli e Jeronimidis (SANTULLI e JERONIMIDIS, 2006) o controle de qualidade em frutas requer métodos seguros, capazes de avaliar com precisão razoável e possivelmente de modo não-destrutivo suas características físicas e químicas. Mais especificamente, uma firmeza diminuída indica a presença de dano ou defeitos na fruta, ficando inadequado para consumo. A firmeza não pode ser medida facilmente a partir de uma observação de textura, mudanças de cor ou desigualdade de superfície de frutas, e o uso de técnicas não-destrutivas é altamente recomendável. Em particular, a aplicação de vibração a laser, baseado em efeito *Doppler*⁵, uma técnica sensível sem contato para diferentes deslocamentos inferiores, mostrou-se ideal com um possível controle de alimentos *on-line*. Resultados anteriores indicaram que a mudança de fase pode ser uma maneira repetitiva associada à presença de danos sobre os frutos, enquanto que uma diminuição de firmeza é resultado de diferenças significativas no deslocamento das frutas sob o mesmo sinal de excitação. No trabalho, foram sugeridas faixas de frequência para controle de qualidade

⁴ Módulo de Elasticidade: é um parâmetro mecânico que proporciona uma medida da rigidez de um material sólido.

⁵ Efeito Doppler: característica observada nas ondas quando emitidas ou refletidas por um objeto que está em movimento com relação ao observador.

através da aplicação de um ruído *chirp*⁶, com base na medição da coerência do sinal. O programa experimental tinha como objetivo avaliar a possibilidade de utilizar varredura por vibração a laser para medir a firmeza dos frutos, através do acompanhamento da frequência do sinal e espectros de amplitudes sobre a grade de pontos uniformemente distribuída sobre uma superfície do fruto. Um dos principais requisitos para tentar criar um processo de inspeção em linha de frutas é definir uma faixa de frequência em que um número suficiente de sinal-ruído possa ser obtido. Para medir o valor do sinal-ruído, muitas vezes, a variável “coerência” é utilizada. Em geral, o conceito de coerência está relacionado com a estabilidade, ou previsibilidade de fase. Coerência espacial descreve a correlação entre a entrada (*chirp*) e saída (vibrações da superfície da fruta) de sinais na rede em diferentes pontos. Coerência temporal descreve a correlação ou relação previsível entre os dois sinais observados em diferentes momentos. Coerência espacial e temporal, por sua vez, estão relacionadas com a largura de interferência dos padrões de luz laser e, conseqüentemente, com o sinal-ruído. A excitação dos frutos com o ruído *chirp* razoavelmente próximo ao ruído branco (200-2000 Hz) rendeu um ótimo sinal ruído sobre os frutos abaixo de 800-900 Hz, e os resultados foram consistentes na maioria dos pontos até mesmo acima dessas frequências.

Rashidi (RASHIDI, 2007) estudou um método para determinar o volume do kiwi (*Actinidia chinensis*) usando métodos de processamento de imagens, a área das imagens de cada kiwi foi capturada com uma câmera digital. O volume foi determinado com método de processamento de imagens (IPM - *Image Processing Method*) e comparado com o volume determinado pelo método de deslocamento da água (WDM - *Water Displacement Method*). Para a calibração cada kiwi foi colocado no centro do campo visual da câmera. A primeira imagem da superfície foi capturada com o sistema de aquisição de imagens sem alterar a posição da fruta. O número de *pixels* representando o comprimento e o maior diâmetro do kiwi foi medido na primeira imagem capturada com um calibrador digital. Então, o kiwi foi manualmente rotacionando em 90° graus em torno do eixo longitudinal e o menor diâmetro do kiwi foi medido pelo calibrador digital. A dimensão em milímetros foi dividida pela dimensão em *pixels* e a conversão do fator médio foi calculada para cada kiwi. A conversão do fator médio de 15 kiwis foi calculada e um único fator de conversão foi determinado. O mesmo fator de conversão foi usado para calcular o volume de cada kiwi. Para calcular o volume foi utilizada a técnica de disco. Foi assumido que cada imagem bidimensional do kiwi era

⁶ Chirp: é um sinal em que a frequência aumenta ou diminui com o tempo.

composta de elementos retangulares individuais. Girando a altura de cada elemento retangular ao redor do eixo x produziu-se um disco cilíndrico com um diâmetro y. A soma do volume de cada disco foi usada para estimar o volume total e finalmente o fator de conversão foi utilizado para calcular o volume do kiwi. O resultado dos testes com as amostras mostrou que o volume determinado com o processamento de imagem não era significativamente diferente do volume medido com o deslocamento de água. A diferença de volume entre os dois métodos foi inferior a $2,23 \text{ cm}^3$. A divergência inicial das diferenças de volume foi de $8,10 \text{ cm}^3$. A diferença de porcentagem comum para estimação de volume da imagem processada e deslocamento de água foi de 7.8%.

Sun e colaboradores (SUN et al., 2007) apresentaram um novo método de monitoramento do contorno da imagem de frutas baseado em código de cadeia. A característica de forma da imagem da fruta é extraída de acordo com as características do código de cadeia, incluindo circunferência, área, grau circular, raio inscrito, complexidade gráfica, altura e largura. A extração do contorno da imagem do fruto é a primeira etapa da extração de características. A fim de obter a imagem binária que reflete a forma do fruto, a imagem é melhorada com o realce da primitiva da imagem em cinza, aprimorando a qualidade da imagem em cinza. A coordenada e o código de cadeia podem descrever o desenho de uma linha na imagem. Código de cadeia é definido com o *pixel* central e os seus oitos *pixels* coincidente. O contorno da imagem da fruta é extraído da seguinte forma: cada linha da imagem da fruta é varrida e tem o fundo retirado. O *pixel* do fundo é definido como 0, na linha varrida um *pixel* (x, y), cujo nível de cinza não é 0, seria um *pixel* do contorno externo da fruta. O *pixel* que está de um lado do *pixel* (x, y) e não é 0, é rotulado como *pixel* fronteira. Dessa forma todos os *pixels* fronteira podem ser obtidos. Depois de receber toda a informação do contorno, o monitoramento deve ser realizado pelo código de cadeia. Em seguida com essa informação é possível estudar outras características como, circunferência, área, etc. Resultados experimentais mostraram que esse método é muito simples, eficaz e preciso, com menor armazenamento de dados. Oferece um método efetivo de extração de características para a automatização da agricultura.

Yang e colaboradores (YANG et al., 2007) desenvolveram um método para detectar e reconhecer grupos de tomates maduros em uma estrutura complexa pertencente a um tomateiro com o propósito de automatizar a colheita. No método proposto as imagens são obtidas por uma câmera estérea para criar um ambiente 3D para posterior processamento. O método CLG (*Color Layer Growing*) é introduzido para segmentação de frutas maduras das

folhas, caule, fundo e ruídos. O grupo alvo pode então ser localizado através da segmentação por profundidade. No pré-processamento das imagens originais é aplicado um filtro passa-baixa para suavizar as imagens, a fim de corrigir as imagens. Retificação é o processo de corrigir as distorções das lentes para as imagens. A segmentação da imagem é uma etapa essencial para o reconhecimento do objeto de interesse. Os métodos comuns incluem detecção de borda, *clustering* e crescimento de regiões que podem ser classificados como locais e globais. O método do trabalho combina as vantagens da técnica local (simplicidade e rapidez) e global (robustez e precisão). O CLG (*Color Layer Growing*) foi desenvolvido com base no código de cores estruturado (CSC – *Color Structure Code*), que segmenta uma imagem conectando suas regiões homogêneas dividindo as regiões pela semelhança de cor. O algoritmo de segmentação opera essencialmente nas seguintes fases: pré, inicialização e conexão. Na fase pré, a seleção da banda de cor é realizada por um filtro e a supressão das cores de banda é executada por um filtro não-linear. Na inicialização a imagem é dividida em pequenas regiões de cores dentro de uma ilha de nível 1. Essas pequenas regiões de cor crescem com a conexão das fases para completar as regiões. A segmentação por profundidade é uma combinação da reconstrução 3D e segmentação por cor. O reconhecimento baseado no formato é eficiente e preciso, utilizando a representação do histograma de profundidade. Inicialmente foi extraído o histograma de profundidade do objeto de interesse. A distribuição estatística do histograma de profundidade da fruta segmentada pode ser usada para caracterizar a forma dos objetos alvo. A segmentação por cor pode ser utilizada para isolar os *pixels* que representam o fruto em 3D. Os testes de robustez do método foram feitos com forte luz solar e grave poluição sonora e mesmo assim foi possível detectar e localizar o grupo alvo e os dados experimentais foi coletado de tomates plantados em estufa.

Vittayapadung e colaboradores (VITTAYAPADUNG et al., 2008) indicaram a possibilidade de usar Espectroscopia Infravermelho Próximo (NIR - *Near Infrared Spectroscopy*) como um método rápido de prever a firmeza de maçãs quantitativamente. Cem maçãs do tipo Fuji foram utilizadas para a experiência. Um algoritmo de mínimos quadrados parciais (PLS - *Partial Least Square*) foi usado para executar a calibração. Para decidir sobre o número de fatores incluídos no PLS, o modelo foi escolhido de acordo com a menor raiz quadrada dos erros médios de validação cruzada (RMSECV - *Root Mean Square Error of Cross-Validation*) em treino. O coeficiente de correlação entre os NIR preditos e os resultados de referência estabelecidos para o teste foram utilizados como parâmetro para uma avaliação dos modelos. Os resultados globais da pesquisa indicam que é possível utilizar essa

técnica pra medir a firmeza dos frutos. A firmeza da maçã Fuji pode ser determinada por espectroscopia FT-NIR utilizando a faixa espectral de $10,000 - 4,000 \text{ cm}^{-1}$. O método PLS tem o potencial para estimar o modelo de calibração e predição de seus espectros do infravermelho próximo. Os melhores resultados foram obtidos com 12 fatores PLS.

Jorge e colaboradores (JORGE et al., 2007) apresentaram uma metodologia utilizada na geração de modelos tridimensionais de imagens de frutas, obtidas por ressonância magnética nuclear (RMN - *Nuclear Magnetic Resonance*) e empregadas na sua descrição volumétrica precisa. Uma imagem gerada por RMN é o resultado do mapa do sinal de hidrogênio (1H) presente na amostra analisada, possibilitando distinguir diferenças em densidade e mobilidade do hidrogênio. Em frutas, estes sinais vêm do 1H livre em moléculas de água (95%). Foram obtidas 46 imagens de frutas através da ressonância magnética nuclear usando um ímã de 14 cm de diâmetro e 30 cm de comprimento, numa frequência de 85,5 MHz. O processo de limiarização foi utilizado para se conseguir realizar a segmentação das estruturas das frutas que se tenha interesse para reconstrução 3D. O algoritmo de reconstrução 3D utilizado foi a triangulação de *Delauney*⁷. A validação do processo de reconstrução foi feito com o uso de '*phantoms*', objetos com geometria e forma conhecidas. Devido à geometria e volumes conhecidos, após a reconstrução é feito o cálculo do volume pelo modelo gerado e então determinado o erro. A precisão das medidas feitas com esse procedimento foi de 97,7% a 99,85%, qualificando-o como fortemente adequado para cálculo de volumes.

Para Blasco e colaborades (BLASCO et al., 2007) a presença de defeitos da pele é um dos fatores mais influentes no preço das frutas. A detecção de defeitos durante operações de embalagem assegura que apenas frutas com boa qualidade cheguem ao mercado. Além disso, a identificação do tipo de cada defeito vai aumentar tanto a qualidade das frutas e também o lucro do produtor. Neste momento frutas ligeiramente defeituosas são comercializadas em conjunto com uma fruta boa, depreciando a qualidade do lote, ou ele é removido juntamente com frutas gravemente danificadas, causando perdas econômicas. No entanto, informações não visíveis, como aqueles fornecidos por infravermelho ou regiões do espectro ultravioleta, podem melhorar o controle através da detecção de defeitos específicos ou que permitem a detecção de danos não visíveis. O trabalho resumiu a investigação da

⁷ Triangulação de *Delauney*: conjunto de todos os segmentos de reta que une pontos próximos, formando um agrupamento de triângulos com ângulos internos não muito agudos.

aplicação do infravermelho, ultravioleta e sistemas de fluorescência de visão computacional para a identificação dos defeitos mais comuns das frutas cítricas, e propôs um algoritmo que combina essas diferentes informações espectrais para seleção de frutas (incluindo visíveis) para classificar as frutas de acordo com o tipo de defeito. Os resultados mostraram que a combinação das informações não visíveis pode melhorar a detecção e identificação de alguns defeitos. Em comparação com os resultados de cor da imagem, a detecção de antracnose a precisão aumentou 86% utilizando NIR de imagens, e da precisão do bolor verde foi aumentada de 65% a 94% por meio de imagens de fluorescência.

Xing e colaboradores (XING et al., 2007) relataram à experiência da utilização de um sistema de imagem hiperespectral na detecção de contusões em maçãs. O sistema de imagem hiperespectral foi construído na região do comprimento de onda entre 400 e 1000nm. Ferramentas quimiométricas como o PCA (*Principal Component Analysis*) e PLSDA (*Partial Least Squares Discriminant Analysis*) foram utilizadas para extrair e resumir as informações espectrais da imagem hiperespectral. Métodos de processamento de imagens tornaram possível a segmentação na região de interesse, de acordo com as características espaciais. Algoritmos de classificação baseados em resultados PCA e PLSDA foram desenvolvidos. O desempenho com relação à precisão da classificação e viabilidade para a execução de seleção *on-line* foi comparado. As ferramentas quimiométricas são capazes de extrair e resumir as informações baseado em *pixels*, enquanto o método de processamento de imagens baseado em regiões fornece a análise de diferentes segmentos da superfície da maçã. Esta combinação de técnicas de processamento de imagens e ferramentas quimiométricas prevê uma abordagem muito promissora para estudo da qualidade de maçã.

Koc (KOC, 2007) mediu o volume da melancia (*Citrullus vulgaris Schrad*) utilizando o método do deslocamento da água, aproximação elipsóide e processamento de imagens. O comprimento do diâmetro maior e menor de cada melancia foi utilizado no método de aproximação elipsóide. As imagens da superfície de cada melancia foram capturadas com uma câmera CMOS de baixo custo e foram utilizados métodos de processamento de imagens. O volume obtido a partir da aproximação elipsóide e pelo processamento de imagens foram comparados com o volume determinado pelo método do deslocamento de água. O volume estimado pela aproximação elipsóide foi significamente diferente do volume determinado pelo deslocamento de água, enquanto que o volume determinado pelo processamento de imagens não foi significamente diferente do volume determinado pelo deslocamento de água. Houve uma diferença média de 0,467 L (intervalo de

confiança de 0,625 a 0,310 L) entre o método de deslocamento de água e a aproximação elipsóide. A média da diferença entre deslocamento de água e o processamento de imagem foi 0,218 L (intervalo de confiança de 0,603 a 0,166 L). O processamento de imagens proporcionou uma metodologia simples para estimar o volume da melancia e pode ser facilmente aplicada no controle da taxa de crescimento de melancia no campo, acompanhamento do rendimento durante a colheita mecanizada, a estimativa do peso de cada uma das melancias após a colheita.

Xiabo e colaboradores (XIABO et al., 2007) apresentaram um sistema de classificação de maçãs por cor em 4 classes, de acordo com as normas estipuladas na China. Para qualificar automaticamente a cor da maçã, foi desenvolvido um sistema de visão de máquina no laboratório, que constou de uma câmera CCD (*Charge-Coupled Device*) colorida equipada com um dispositivo de captura de imagem, um dispositivo cilíndrico bi-cone controlado por um motor, e uma fonte de iluminação. Quatro imagens, uma para cada rotação de 90°, foram capturadas de cada maçã. Dezesete parâmetros de características de cor foram extraídos de cada maçã da imagem processada. Trezentos e dezoito maçãs Fuji foram analisadas pelo sistema, e foram divididos em 2 grupos, com 200 em grupo de treinamento e 118 para grupo de teste. Um método chamado organização do parâmetro de características, com base em árvores de fórmulas de expressão utilizando algoritmos genéticos, foi utilizado. Quando a sensibilidade inicial PF (*Feature Parameter*) não pode distinguir entre diferentes classes de maçãs, a PF foi organizada em OFP (*Organization Feature Parameter*) utilizando um novo algoritmo genético. Ao aplicar o passo do algoritmo de árvore de decisão em combinação com o método OFP, foi alcançado alto grau de relação de julgamento na classificação de duas das quatro cores de classes. Em comparação com a BP-ANN (*Back Propagation Artificial Neural Network*) e SVM (*Support Vector Machine*), o método OFPs foi mais preciso do que a BP-ANN, mas foi pouco menor do que SVM para identificação dos resultados.

Segundo Zeng e colaboradores (ZENG et al., 2008) as dinâmicas de medida do diâmetro da fruta para entender como as plantas respondem à variação diária de água e as condições de crescimento em longo prazo. As técnicas atuais para medir o diâmetro das frutas são na maioria das vezes por toque. O contato dos sensores causa estresse sobre as uvas (*Vitis labrusca*) podendo alterar os resultados. O método óptico apresentado não entra em contato com a fruta para medir com precisão o seu diâmetro. O sistema de visão para medida consiste de uma câmera CMOS (*Complimentary Metal-Oxide Semiconductor*) equipada com uma

lente telecentrica. Esse sistema elimina o contato da fruta com o sensor devido ao uso de transdutores de deslocamento. Eles selecionaram uma única videira para medição contínua. Para facilitar a manipulação na análise de imagens, somente as uvas que não estavam em contato com outras foram escolhidas. A medida da uva foi monitorada durante 5 dias e as imagens eram gravadas a cada meia hora. Para medir precisamente o diâmetro dos frutos, o sistema de visão foi calibrado. A calibração da câmera foi baseada na imagem modelo de um orifício e proporcionou uma transformação na relação entre as coordenadas do mundo 3D e as coordenadas da imagem 2D no computador. No pré-processamento das imagens esse método utilizou um filtro passa-baixa *Gaussiana* para reduzir o ruído existente nas imagens. As uvas são segmentadas do fundo por limiarização. Para segmentar as uvas, objeto de interesse, foi implementado o algoritmo OSTU. Após a segmentação das uvas, é necessário determinar o seu diâmetro. O diâmetro da fruta se desvia da direção horizontal devido o seu crescimento. Para localizar o diâmetro da uva é necessário rodar a fruta para obter um bom ângulo e para que o diâmetro esteja na direção horizontal. O ângulo de rotação é difícil de ser determinado com a imagem, por isso é necessário definir um ângulo de rotação. O desvio angular do diâmetro do fruto não deve exceder o intervalo de variação definido para o ângulo de rotação. Após ser determinada a posição do diâmetro da fruta, este pode ser calculado. No entanto iluminação inadequada e ruído na aquisição da imagem irão introduzir um erro na medida. Para que a medição seja precisa, as linhas que estão dentro de 100 *pixels* na direção vertical a partir do diâmetro dos frutos são detectadas. O comprimento médio das linhas é considerado como o diâmetro dos frutos. Isso é considerado razoável porque a medida do diâmetro dos frutos é utilizada para detectar distúrbios fisiológicos e não para descrição das características das uvas. Os experimentos mostraram que o sistema é preciso e robusto. O sistema apresentou uma precisão de aproximadamente de 7 μ m para medida do diâmetro e proporcionou uma ferramenta eficaz para melhor detecção de doenças fisiológicas das plantas.

Quevedo e colaboradores (QUEVEDO et al., 2008) analisaram que a textura fractal reflete uma mudança na intensidade do *pixel*, e este pode conter informações sobre a estrutura de objetos, uma vez que uma grande mudança de intensidade pode geralmente indicar mudanças no objeto. Nas imagens das superfícies de banana, a imagem de textura pode, para certa medida, refletir as mudanças e, portanto, ele pode ser usado como indicador da última fase do processo de amadurecimento (excesso de maturação). Neste experimento, banana (*Musa cavendish*) foi analisada durante 10 dias a 20°C. Imagens da superfície de bananas foram registradas usando um sistema de visão computacional. O longo processo de

amadurecimento de bananas foi representado por um incremento no valor da derivada fractal de textura de análises do fractal de Fourier. Fractal refere-se às entidades, especialmente conjunto de *pixels*, que exibem um grau de auto-similaridade em uma escala diferente. A dimensão do fractal de uma superfície grosseira é superior à dimensão de uma lisa. A dimensão fractal (FDH - *Fourier-Domain Holographic*) é determinada a partir da potência do espectro de Fourier da imagem de dados. Todas as imagens de bananas foram transformadas para o formato negativo a fim de observar o aparecimento de manchas da superfície. Nestas imagens é atribuído um valor zero a cor preta e um valor de 255 é atribuído para a cor branca. Foi calculada a variação linear em uma parcela de logaritmo para uma banana e a mesma tendência de linear foi observada para todas as outras bananas. O logaritmo da magnitude dos coeficientes da transformação de Fourier de uma curva fractal linear diminui com o logaritmo de frequência na imagem. Deste modo, o comportamento linear da distribuição dos valores de *pixels* em cinza de uma imagem de banana é fractal. Foi demonstrado que o declive da linha é mais fortemente influenciado por altas frequências. Ruídos de alta frequência podem reduzir a amplitude do espectro aumentando o declive. Em outras palavras os valores de baixa frequência mais espaçados no eixo logarítmico podem determinar com mais precisão a inclinação da linha. O resultado mostrou que a textura fractal derivado da análise espectral de Fourier monotonicamente aumentada pode ser utilizada como um indicador do processo de reconhecimento da senescência⁸ da casca de banana.

De acordo com Jiang e colaboradores (JIANG et al., 2008) embora os raios-X sejam freqüentemente usados em aeroportos ou alfândegas para inspeção de segurança, a aplicação prática de imagem de raios-X em quarentena para inspeção e prevenção da propagação de insetos-praga estrangeiros em frutas importadas ainda não está disponível. O primeiro passo para identificar infestação de insetos em frutas por técnicas de imagens de raios-X é a aquisição da imagem. Este é seguido pelo processo de segmentação da imagem, que pode localizar a infestação. Visto que os níveis de cinza da imagem de raios-X dependem da densidade e espessura das amostras, a relação de contraste para a infestação local e a região interna intacta de uma fruta típica varia com sua posição. Para determinar com precisão se uma fruta tem sinais de infestação por insetos, nós desenvolvemos um algoritmo de segmentação de imagem adaptativa baseado na intensidade local dos *pixels* sem limiarização de supervisão. O trabalho apresentou o processamento detalhado da imagem incluindo a

⁸ Senescência: Processo de envelhecimento, fase do desenvolvimento da planta.

formação de grade, limiar local, interpolação do valor de limiar, remoção do fundo, e filtragem morfológica para a determinação do local de infestação de uma fruta em imagem de raios-X. O processamento da imagem em tempo real foi testado com imagens de raios-X de vários tipos de frutas como citros (*Citrus*), pêsego (*Prunus pérsica*), goiaba (*Psidium guayaba L.*), etc. Análises e Testes adicionais foram realizados utilizando o algoritmo desenvolvido nas imagens de raios-X obtidas com diferentes parâmetros na aquisição da imagem. Com o processo de segmentação adaptativa desenvolvido nessa pesquisa, foi possível lidar com o problema do gradiente dos níveis de cinza nas imagens de raios-X apropriado para figura ou espessura irregular da fruta para maioria dos casos testados. Porém o local de infestação pode não ser segmentado usando o tradicional algoritmo de limiarização. Conseqüentemente, as variações nas características das frutas e o grau de infestação podem ser sancionados com o ajuste no número de iterações morfológicas da filtragem.

Com o objetivo de garantir a qualidade e homogeneidade da cor de romãs (*Punica granatum*) em lotes comerciais Blasco e colaboradores (BLASCO et al., 2008) propuseram um novo protótipo para o controle automático de romã, ejetores de ar foram desenvolvidos para a separação do produto em categorias. Imagens de romãs foram adquiridas utilizando duas câmeras para permitir a estimativa da qualidade, e então são expulsas através de diferentes saídas de acordo com a categoria. Um novo *software* para o controle da sincronização das correias transportadoras foi desenvolvido, tanto a aquisição de imagens como a separação por ejetores de ar inclui mecanismos para a sincronização e comunicação entre a visão computacional e o controle por computador. Um novo sistema de visão computacional foi desenvolvido para a inspeção de romã que distingue a romã de materiais grosseiros calculando a cor dos objetos e classificando a romã por tamanho e cor. Algoritmos de visão computacional devem estimar a cor de cada romã sendo capaz de distingui-lo de pedaços de pele e membranas internas. Os algoritmos de controle devem gerenciar a sincronização entre a aquisição de imagem, processamento de imagens e o movimento das correias transportadoras e a ativação dos ejetores de ar. As romãs representam o objeto de interesse na imagem enquanto as correias representam o fundo. Para permitir uma boa segmentação é importante escolher adequadamente a cor das correias transportadoras. Foram testadas diferentes cores para as correias como, branco, azul, verde escuro, verde claro e cinza, e foram segmentados por limiarização. O sistema de visão confundiu as correias na cor branca com as membranas internas de romã, no caso de verde escuro e cinza foram confundidas com as romãs mais escuras. No entanto utilizando o azul ou o verde claro o

sistema foi capaz de segmentar a imagem de forma adequada. O protótipo foi criado utilizando correias na cor azul. Quando esta cor é medida em coordenada RGB (*Red, Green, Blue*) o principal componente é o B, enquanto que o menor valor normalmente corresponde ao R. Conseqüentemente a técnica de segmentação utilizada foi a limiarização na banda R da imagem. Tanto a localização e a qualidade de cada objeto são enviadas para o controle na seqüência de um protocolo específico do computador implementado usando o TCP/ IP (*Transmission Control Protocol/ Internet Protocol*). Todas as informações sobre os objetos encontrados em uma imagem são enviadas em único pacote. O protótipo foi testado por um período de seis meses, atingindo o objetivo de inspecionar a fruta de acordo com a sua qualidade. Os resultados dos testes laboratoriais mostraram que o protótipo é capaz de separar corretamente os objetos em uma produção mínima de 100 kg de romã por hora.

3.4. Principais trabalhos desenvolvidos em 2009

Okamoto e Lee (OKAMOTO e LEE, 2009) desenvolveram um método para detectar frutas cítricas verdes, esta tecnologia pode ser aplicada para estimação da colheita no campo numa fase muito anterior de crescimento do fruto, proporcionando benefícios para os citricultores. Foi utilizada uma câmera hiperespectral (comprimento de onda 369-1042 nm) para adquirir as imagens de frutos verdes de três diferentes variedades cítricas (Tangelo, Valencia e Hamlin). A câmera funcionou como um *scanner*, a entrada de luz no sentido vertical no prisma embutido resultou em componentes espectrais. Portanto, a imagem de saída, a partir da câmera incluía informação espacial e espectral ao longo dos eixos horizontal e vertical, respectivamente. Dados digitalizados foram transferidos para um computador. Antes da discriminação dos frutos verdes e folhas, a área do fundo que consistia de áreas brilhantes (céu) e áreas escuras (sombra e ramos) foi retirada da imagem hiperespectral. Para esta análise, foram coletadas 500 amostras de *pixels* a partir da formação das imagens para cada condição: fundo brilhante, fundo escuro e frutos verdes, uma vez que 500 *pixels* foram considerados como um número adequado para desenvolver o método da eliminação do fundo. A análise dos dados, tais como cálculo aritmético para limiarização, criando histograma e determinação do limiar foi realizada utilizando o software R (Development Core Team, 2007). R é um software livre de código fonte aberto para computação estatística. Para a segmentação entre frutas e folhas verdes, em primeiro lugar foi gerada uma função de pixel discriminante em uma análise linear discriminante e aplicada a todos os *pixels* de uma

imagem para a segmentação da imagem hiperespectral. Técnicas de processamento de imagens espaciais (filtragem, limiarização da área, classificação), foram aplicadas na imagem segmentada para detectar as frutas cítricas. O algoritmo foi dividido em duas partes, ou seja, processamento espectral do *pixel* e processamento espacial. Primeiro o processamento espectral foi aplicado a cada *pixel* individualmente, em seguida, foi aplicado o processamento espacial para detectar a fruta. Foram consideradas 3 variedades de frutas cítricas (Tangelo, Valencia, Hamlin), e para cada variedade foi desenvolvido a função discriminante. Os resultados dos testes para identificação de *pixel* tiveram uma taxa de sucesso de 70-85%, dependendo das variedades das frutas cítricas. Os testes para identificação dos frutos revelaram 80-89% de acerto, porém muitos objetos foram identificados incorretamente como fruto. Atualmente, estes resultados podem não ser suficientes para estimativa da produção de frutas, melhorias futuras serão necessárias. No entanto, o estudo demonstrou potencial uso na detecção de frutas verdes utilizando imagens hiperespectrais.

Segundo Balasundaram e colaboradores (BALASUNDARAM et. al, 2009) a presença de um dos frutos infectados com o cancro cítrico pode tornar todo o embarque inegociável. Por isso, é importante a classificação dos frutos infectados com cancro cítrico nas empacotadoras antes do embarque dos produtos. O objetivo da pesquisa foi determinar a onda significativa que poderia ser utilizada para classificar o cancro cítrico, entre outras doenças, na casca de toranja (*Citrus paradisi Macfad*), uma variedade suscetível ao cancro. O espectrofotômetro⁹, cujo comprimento de onda é de 200-2500 nm, foi utilizado para medir os dados de refletância espectral da cascas de frutas com qualidade para comercialização e frutos que foram infectados com melanose¹⁰, queimadura, cancro e mancha. Foi feita a análise estatística dos dados da refletância espectral para identificar o comprimento de onda que tinha o maior potencial discriminatório entre as diferentes condições de pele para derivar uma função discriminante que identifique os comprimentos de onda. Os comprimentos de ondas discriminatórias foram identificados na gama visível e próximo ao infravermelho. A imagem colorida foi captada por referência usando uma imagem visível de um sistema composto por 3 câmeras CCD, um placa receptora de *frame*, um computador e duas iluminações de alta frequência. Como esperado a partir da média da refletância de espectros obtidos de frutas em diferentes condições tinham características distintas, especialmente na gama visível e NIR. As propriedades espectrais do cancro e de frutas de mercado demonstraram uma diferença na

⁹ Espectrofotômetro: são instrumentos de análise que permitem selecionar o comprimento de onda, medir a intensidade I, determinar a concentração de uma espécie em solução.

¹⁰ Melanose: presença de depósitos anormais de melanina na pele e em outros tecidos.

assinatura espectral que tem potencial para classificar frutas com cancro cítrico de frutas com qualidade para comercialização. A possibilidade de utilizar informações de refletância espectral para classificar as condições dos frutos foi analisada estatisticamente. Comprimentos de onda com maior poder discriminatório foram identificados e uma função discriminante foi formada por três faixas espectrais: a) onda acima de 1100 nm, não tem grande poder discriminatório; b) onda entre 500 e 800 nm, tem maior potencial discriminatório e c) um sistema de imagem com uma gama de infravermelho visível seria mais eficaz na busca do cancro. Além disso, a classificação baseada na derivação da função discriminante resultou em 100% de classificação do cancro.

Foi visto neste capítulo o estado da arte da utilização da visão computacional na fruticultura, direcionando a importância dos avanços da pesquisa nessa área para a obtenção de produtos de qualidade no mercado.

CAPÍTULO 4 – DESENVOLVIMENTO DO SISTEMA PARA CLASSIFICAÇÃO DE BANANAS (*Musa sapientum*) BASEADA EM VISÃO COMPUTACIONAL

Neste capítulo é apresentado o sistema de classificação de frutas utilizando textura, área e cor. É discutida além de sua modelagem, cada uma das etapas que o compõem, bem como é estabelecido o algoritmo para obtenção do mapeamento das áreas defeituosas, obtenção do percentual de ocorrência de manchas marrons, injúrias e classificação de acordo com o estágio de maturação do fruto.

4.1. Modelagem do sistema

O padrão brasileiro de classificação de bananas segundo o Programa Brasileiro para a Modernização da Horticultura adotado neste trabalho – propõe a classificação segundo dois aspectos distintos: cor e qualidade. O parâmetro qualidade é observado segundo a ocorrência de defeitos. O parâmetro cor, as bananas são agrupadas em sete diferentes níveis de maturação.

O sistema de classificação de bananas foi projetado com o objetivo de se aplicar técnicas de processamento de imagens e visão computacional para a classificação utilizando textura, cor e área. A Figura 31 ilustra o diagrama de blocos do sistema de classificação desenvolvido. O processamento de textura visa a avaliação prévia de uma região da banana ilustrando a existência de manchas marrons ou injúrias. A partir da imagem da área de interesse é feito o mapa de textura. O processamento de área fornece a informação do percentual de manchas marrons ou injúrias nos diferentes estágios de maturação da banana. Por fim, com o processamento de cor é dada a classificação do fruto em níveis de estágio de maturação. Também foi previsto o armazenamento das imagens adquiridas e processadas nas várias etapas do processo de análise e a geração de um relatório para o usuário.

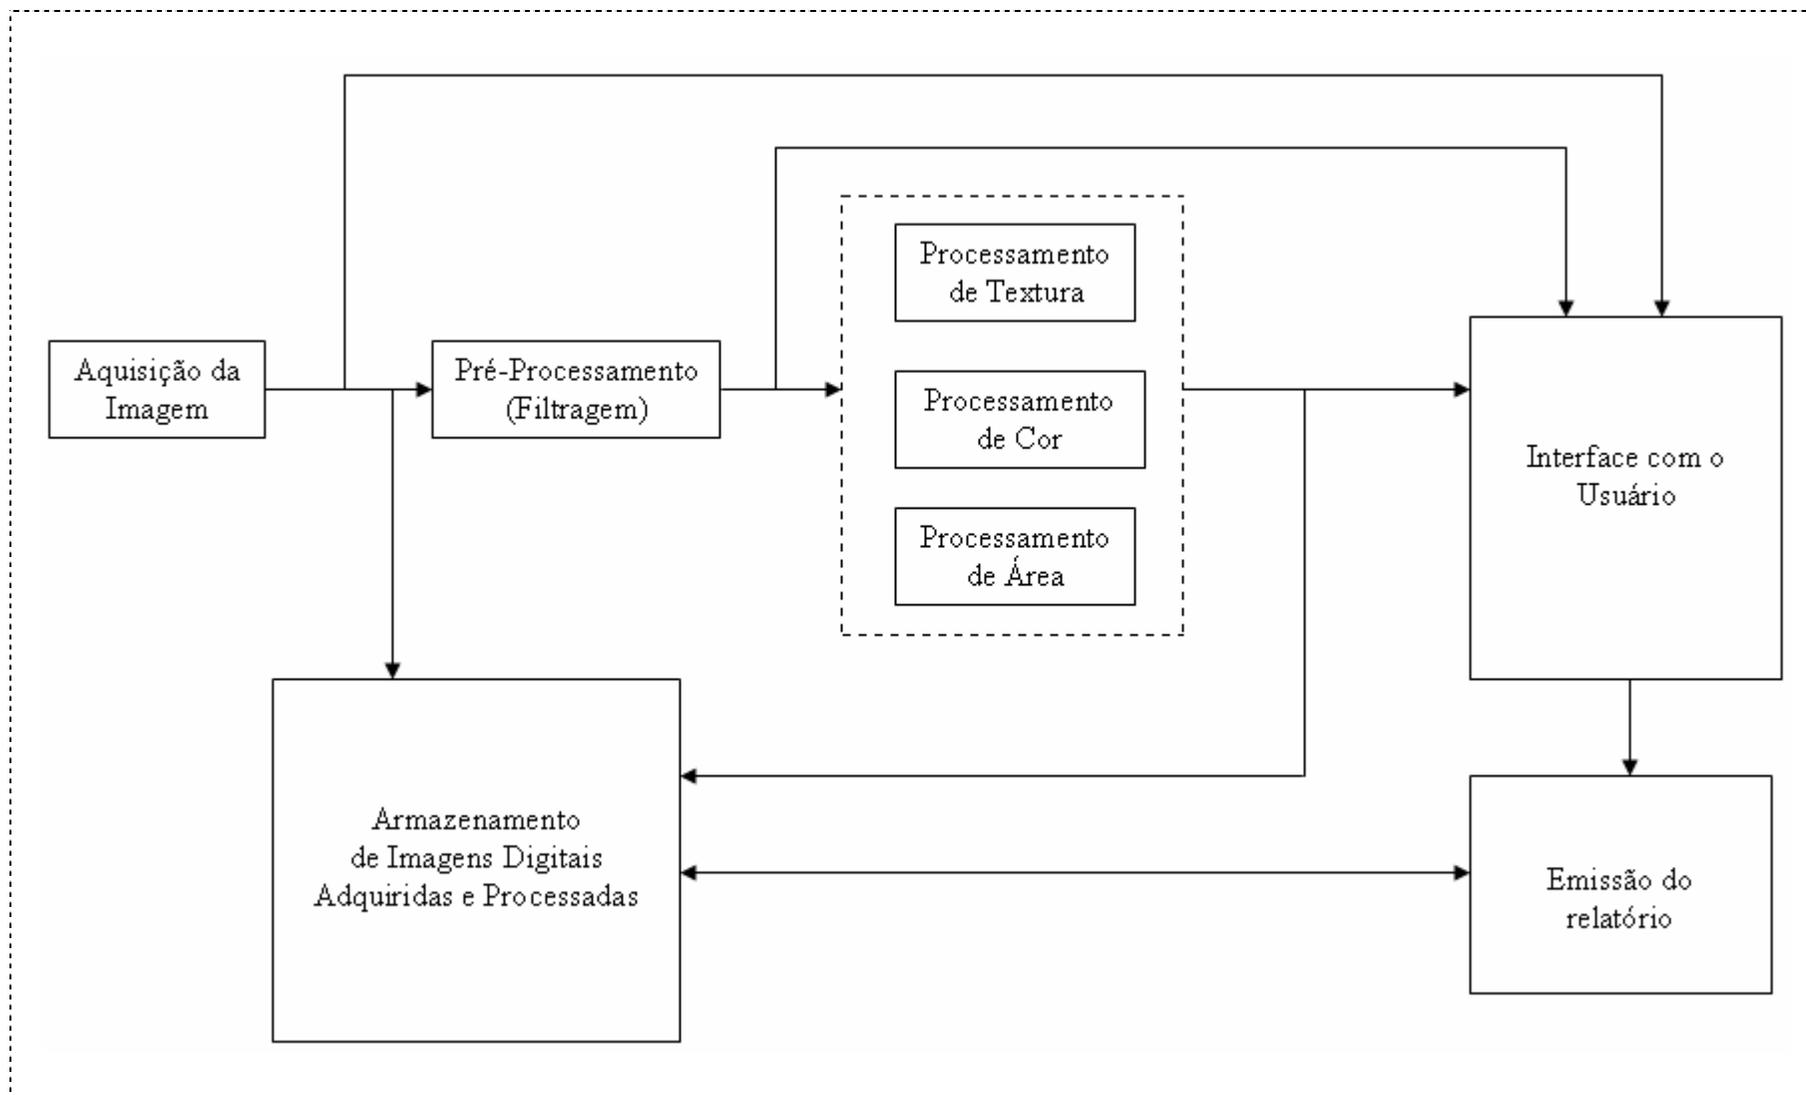


Figura 31 – Diagramas em blocos do método de visão computacional para inferência da qualidade de frutas.

4.2. Aquisição das imagens

Para aquisição de imagens de bananas (*Musa sapientum*) foi utilizado uma câmera fotográfica Canon Tipo LHDC10 (PowerShot Pro 1) em um laboratório, somente com iluminação ambiente. As imagens obtidas possuem resolução de 71 *pixels/cm* a qual apresenta tamanho de 600×600 *pixels*.

4.3. Pré-Processamento

No método de textura é obtida uma representação da imagem original na componente S do modelo HSI, para isso é utilizada a equação (33):

$$S = 1 - \frac{3}{R + G + B} [\min(R, G, B)] \quad (33)$$

Após obtido a representação da imagem na componente S foi aplicado o filtro de mediana, que uniformiza a região, sem perder os detalhes de borda.

No método de cor foi feita a limiarização para eliminar o fundo. Uma imagem limiarizada $g(x,y)$ foi assim definida como:

$$g(x, y) = \begin{cases} 1 & \text{se } f(x, y) \geq L \\ \text{rosa} & \text{se } f(x, y) < L \end{cases} \quad (34)$$

onde $f(x,y)$ corresponde a cor de *pixel*, os *pixels* rotulados com rosa correspondem aos objetos e os *pixels* rotulados com 255 correspondem ao fundo e L é um valor de cor predefinido denominado limiar. A cor rosa foi utilizada, pois é uma cor que não se confunde com as cores encontradas na banana, como por exemplo, o *pixel* 0 seria confundido com as injúrias.

4.4. Identificação de manchas marrons e injúrias através da textura

O método para identificação de manchas marrons e injúrias em banana baseado em textura foi desenvolvido baseado no algoritmo 1 (apresentado na seção 2.3.3.1), o qual

encontra em uma imagem a região de interesse, baseando-se no valor de textura que cada região apresenta. Neste contexto, o primeiro passo da identificação é a seleção da área que se deseja analisar, em seguida, obter a representação da imagem na componente S. O próximo passo é a obtenção do mapa de textura dividindo a imagem em sub-imagens, ou janelas, de tamanho $n \times n$ e calcular o valor de textura em cada uma dessas janelas.

O valor de textura é encontrado a partir de medidas estatísticas obtidas pela matriz de co-ocorrência, a qual é normalizada, ficando sempre entre 0 e 1. A partir das informações de textura em cada janela, pode-se obter um mapa de textura, cujos valores foram redistribuídos dentro da paleta de cinza (0-255) para que a visualização fosse possível. Paralelamente, são encontradas as regiões de interesse que cada área de injúria ocupa na imagem original. Após ser criado o mapa de textura foi necessário encontrar as classes que podem ser conectadas, ou seja, aquelas que possuíam vizinhos de valores iguais, ou com uma diferença dentro de um limite pré-estabelecido, as mesmas foram unidas, gerando uma nova classe de primitiva. O mapa é utilizado para identificar a existência de manchas marrons ou injúrias na região selecionada. O algoritmo 2 (Figura 32) descreve este procedimento como parte do modelo de abordagem. Este método foi utilizado para identificar na imagem do fruto as áreas que são manchas marrons e injúrias.

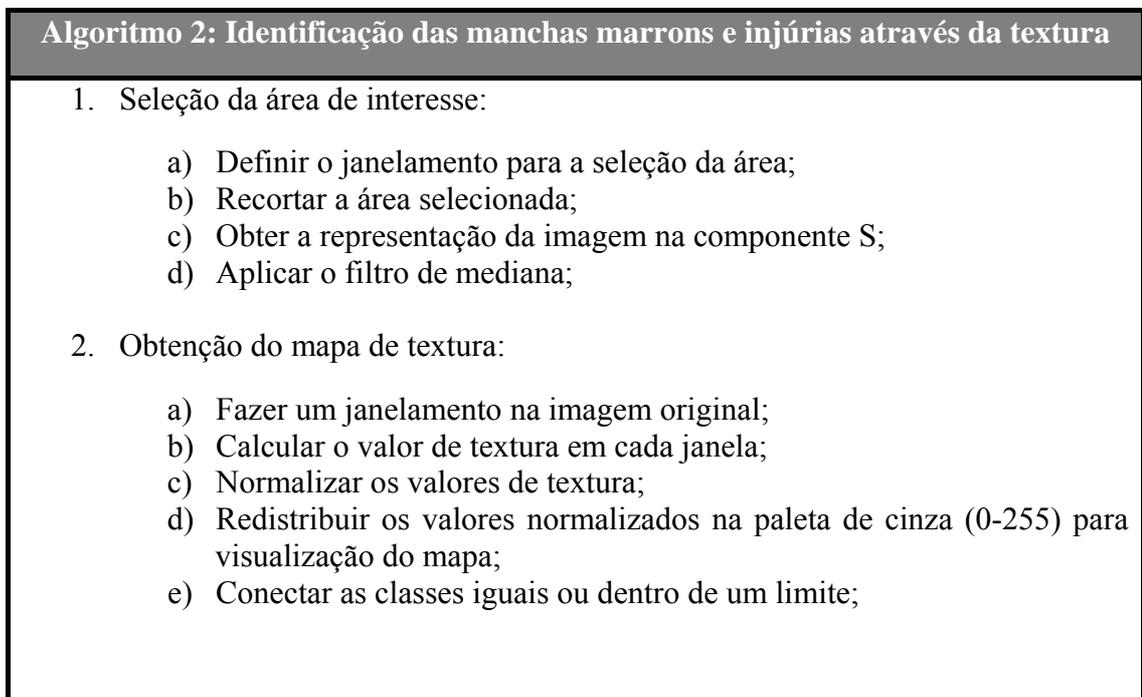


Figura 32 – Algoritmo de identificação de manchas marrons e injúrias através da textura para a visualização da existência de manchas marrons e injúrias.

O algoritmo 2 pode ser detalhado como:

Passo 1:

- a) O janelamento para a seleção da área de interesse é supervisionado. Com o cursor sobre a imagem clica-se em um ponto inicial e em um ponto final para delimitar a área, que deseja ser selecionado.
- b) Recortar a área da imagem selecionada que é delimitada por um retângulo ou quadrado, dependendo do janelamento que o usuário determinou.
- c) Antes de obter o mapa de textura da imagem selecionada é necessário convertê-la em uma imagem da componente S, para isso é utilizada a equação 35:

$$S = 1 - \frac{3}{R + G + B} [\min(R, G, B)] \quad (35)$$

- d) Para aplicação do filtro mediana foi considerada uma máscara 3×3 que percorre toda a imagem, substituindo o *pixel* central pela mediana dos *pixel* pertencentes a máscara.

Passo 2:

- a) Para o janelamento da imagem original, foram geradas pequenas imagens, com o tamanho 10×10, para que fossem realizados os cálculos de textura. Por exemplo, suponha uma imagem 50×50. O primeiro janelamento se refere aos *pixels* cujas posições variam de (0,0) até (9,9), o segundo janelamento se refere às posições de (0,10) até (9,19) e assim por diante.
- b) Em cada janelamento foi calculada sua respectiva matriz de co-ocorrência e a partir dela foi extraído o valor de textura correspondente à medida de textura do contraste.
- c) Os valores de texturas obtidos foram normalizados, para que ficassem na faixa entre 0 e 1. Para a normalização foi utilizada a seguinte expressão:

$$valor_{normalizado} = \frac{valor_{obtido}}{valor_{máximo}} \quad (36)$$

- d) Para a visualização dos valores de textura, os mesmos foram redistribuídos na paleta de cinza (0-255), tendo seus valores normalizados multiplicados por 255.

- e) A conexão das classes foi feita através da comparação do valor de textura de uma classe com as suas vizinhas. Aquela classe que possuía uma vizinha com o mesmo valor ou com valor dentro de um limite era conectada com sua vizinha, passando a formar uma nova região, e nesta região, ambas as janelas, assumia um valor novo valor de textura, igual à média das duas regiões. Esta operação foi repetida até que novas regiões não pudessem ser formadas.

4.5. Classificação baseado em cor

Para o método de classificação das bananas pelo estágio de maturação foi desenvolvido e utilizado o modelo de cor HSI. A classificação da banana é feita através da contagem de *pixels* verde, verde claro, amarelo claro e amarelo na imagem comparando-se os padrões encontrados com os padrões previamente conhecidos, avaliando os valores da componente H (matiz) e I (iluminação). O algoritmo 3 (Figura 33) apresenta a classificação do fruto em níveis de maturação.

Algoritmo 3: Classificação baseado em cor

1. Encontrar o valor de H e I.
2. Contagem simples para extração de padrões.
3. Comparação dos padrões encontrados com padrões previamente conhecidos.

Figura 33 – Algoritmo para classificação de bananas em estágios de maturação baseado em cor.

O algoritmo 3 pode ser detalhado como:

Passo1: É calculado o valor de H e I de cada *pixel* da imagem segmentada no pré-processamento utilizando as equações 37 e 38:

$$H = \cos^{-1} \left\{ \frac{\frac{1}{2}[(R - G) + (R - B)]}{[(R - G)^2 + (R - B)(G - B)]^{\frac{1}{2}}} \right\} \quad (37)$$

$$I = \frac{1}{3}(R + G + B) \quad (38)$$

Passo 2: É feita a contagem de *pixels* classificando-os em: verde, verde claro, amarelo claro e amarelo.

Passo 3: Calcula-se o valor percentual de cada padrão encontrado e é feita a relação dos valores obtidos com os valores dos padrões pré-definidos da escala de maturação de Von Loesecke, a quantidade de cada padrão é comparado para determinar a qual nível de maturação o fruto pertence.

4.6. Percentual de manchas marrons e injúrias

O processamento de áreas defeituosas é feito através da limiarização. A partir da escolha de um *pixel* semente e dada um limiar a imagem é segmentada, obtendo apenas a informação de defeito. Neste trabalho foram analisadas as manchas marrons e injúrias. Após a segmentação é feita a contagem dos *pixels* e é exibido o percentual de manchas ou injúrias da banana. O algoritmo 4 (Figura 34) ilustra este processamento.

Algoritmo 4: Percentual de manchas marrons e injúrias
<ol style="list-style-type: none"> 1. Obter a área da banana. 2. Seleção do <i>pixel</i> semente: <ol style="list-style-type: none"> f) Posicionar o mouse em uma região e clicar; g) Definir um limiar; h) Fazer a contagem de <i>pixels</i>; 3. Percentual de manchas marrons ou injúrias.

Figura 34 – Algoritmo para determinação do percentual de manchas marrons ou injúrias.

O algoritmo 4 pode ser detalhado como:

Passo 1: A área banana é obtido através da limiarização, eliminando dessa forma a informação de fundo.

Passo 2:

- a) Para seleccionar o *pixel* semente é necessário posicionar o cursor na área de interesse e clicar.
- b) Escolhe-se um limiar para obter apenas as informações desejadas, dentro de um intervalo definido.
- c) A contagem de *pixels* é feita tomando por base o seguinte pseudocódigo:

```

Begin
  Begin
    variáveis
      col, lin, soma: inteiro
    end;
  Begin
    para col <-1 até largura
      para lin <- 1 até comprimento
        Begin
          se pixel(col,lin) <> 255
            então soma=soma+1
          end;
        end;
      end;
    end;
  end.

```

Passo 3: Após a contagem de *pixel* o percentual de manchas marrons ou injúrias é dada pela equação 39.

$$\text{Percentual} = (Qt_{\text{pixel}} * 100) / \text{Pixels}_{\text{total}} \quad (39)$$

4.7. Modelagem da interface com o usuário

O sistema foi desenvolvido utilizando o Turbo C++, uma versão gratuita do Builder C++, e conta com uma interface com o usuário, que agrega todas as etapas do processo.

Para o processamento do método de textura, a primeira etapa é a entrada da imagem adquirida, a segunda é o pré-processamento, feita a seleção da área que deseja analisar é

obtida a imagem da componente S do modelo HSI, a imagem obtida é filtrada e por fim é obtido o mapa de textura. No método do percentual de manchas marrons e injúrias é feita a limiarização das áreas de interesse e contagem dos *pixels*. No processamento do método de cor após a entrada da imagem adquirida é feito o pré-processamento, aplicando a limiarização para a segmentação, selecionando o objeto de interesse e eliminando a informação de fundo, e por fim, é feita a classificação do fruto em um dos 7 níveis de maturação.

A Figura 35 ilustra a interface do sistema desenvolvido.

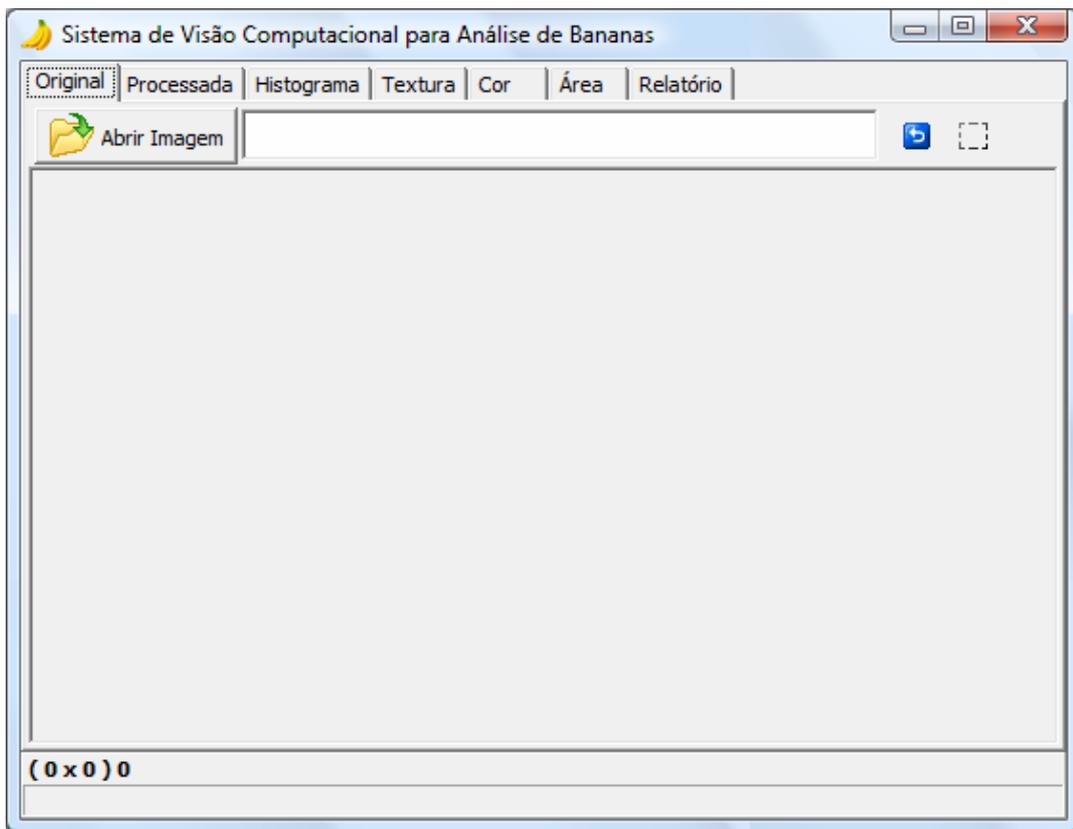


Figura 35 – Tela do sistema desenvolvido para identificação de manchas, injúrias e classificação da banana em estágio de maturação.

A seguir são apresentados os passos para a utilização do sistema:

- **Aba Original** – para abrir a imagem pressiona-se o botão <Abrir Imagem>, quando esse botão é pressionado abre-se a caixa de diálogo, como ilustra a Figura 36. Nesta caixa deve ser selecionada a imagem que se deseja fazer a análise de textura. Selecionada a imagem, clica-se no botão <Abrir>, e a mesma é exibida no espaço abaixo da interface, como apresentado na Figura 37. Nesta aba também é feito o

recorte da região de interesse na imagem para obter o mapa de textura da área selecionada. Para selecionar a área de interesse clica-se no ícone do retângulo de seleção ao lado do caminho do arquivo aberto, clica-se em um local da imagem com o cursor para dar início à seleção e depois se clica novamente em um outro local para finalizar, como mostra a Figura 38, em seguida clica-se no ícone da tesoura para recortar a área de interesse, como apresentado na Figura 39.

- **Aba Processada** - Para obter a representação da imagem na componente S seleciona-se no ambiente o “S” e na lista seleciona-se o item RGB_TO_HSI e clica-se no botão <Processar>, posteriormente é necessário clicar no botão <Enviar original>, para que essa imagem fique na **aba Original**, dessa forma o próximo processamento é feita sobre essa nova imagem A imagem processada será exibida no espaço abaixo da interface, como apresentado na Figura 40. Em seguida seleciona-se na lista o item Filtro Mediana e clica-se no botão <Processar>. No processamento de cor é necessário segmentar o objeto de interesse, na lista escolhe-se o item Limiarização RGB e clica-se no botão <Processar> e em seguida no botão <Aplicar>, a imagem segmentada é exibida no espaço abaixo da interface, como apresentado na Figura 42.
- **Aba Textura** - escolhe-se o ângulo e a distância para obter o mapa de textura e clica-se no botão <Calcular mapa de Textura>, a imagem obtida é exibida no espaço abaixo da interface, como ilustrado na Figura 41.
- **Aba Cor** - clica-se no botão <Obter Classificação> para que seja feita a classificação do fruto pelo nível do estágio de maturação e o resultado é apresentado na interface. É exibida na tela do sistema além da classificação, a imagem dos padrões encontrados, como mostrado na Figura 43.
- **Aba Área** – clica-se em uma região de injúria da banana para obter o *pixel* semente e define-se uma tolerância, clicando no botão <Aplicar> as áreas correspondentes aos valores determinados aparecem em rosa, como apresentado na Figura 44 e para eliminar o restante de informação da imagem clica-se no botão <Exibir Processado>, como ilustrado na Figura 45.
- **Aba Relatório** – São apresentados os resultados de todo o processamento de uma imagem que foram confirmados pelo usuário, como mostrado na Figura 46.



Figura 36 – Tela do sistema de visão computacional: caixa de diálogo Abrir, que é ativada ao se pressionar o botão <Abrir Imagem> para que a imagem de entrada seja selecionada.

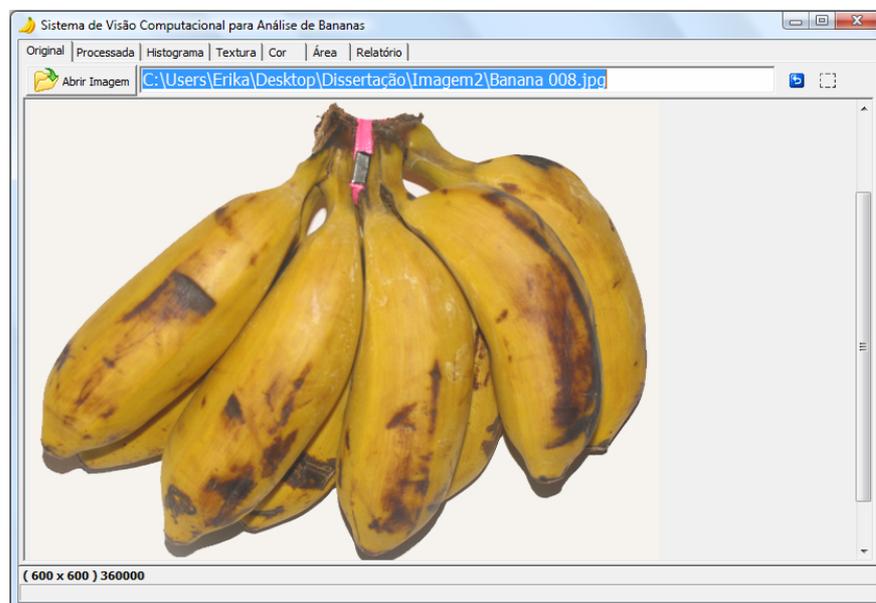


Figura 37 – Tela do sistema de visão computacional: Imagem de entrada selecionada na caixa de diálogo Abrir.

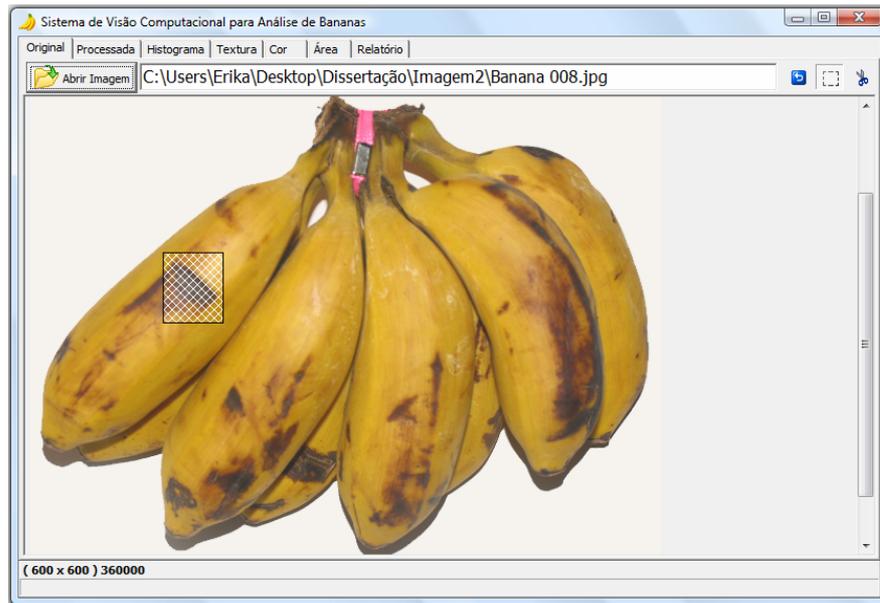


Figura 38 – Tela do sistema de visão computacional: seleção da região de interesse para obtenção do mapa de textura.

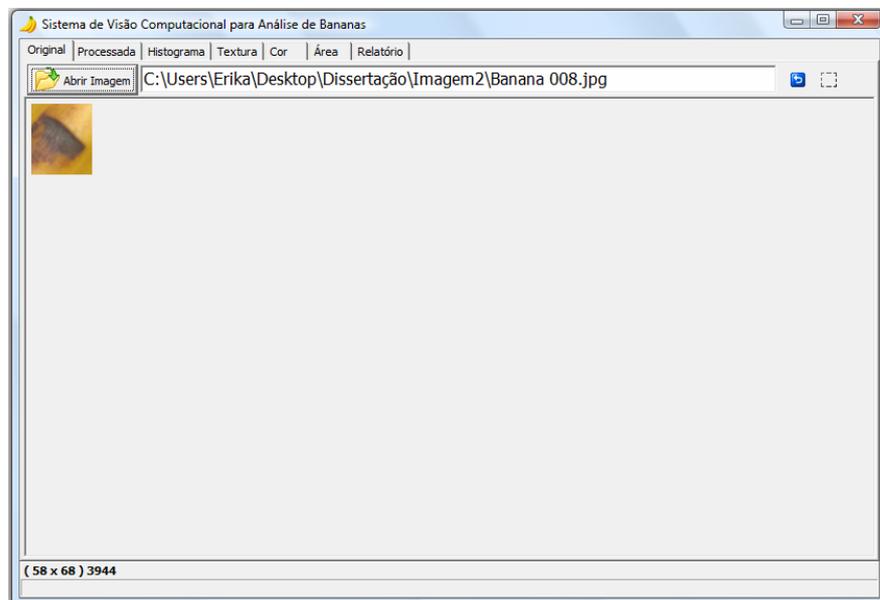


Figura 39 – Tela do sistema de visão computacional: Região de interesse recortado para obtenção do mapa de textura.

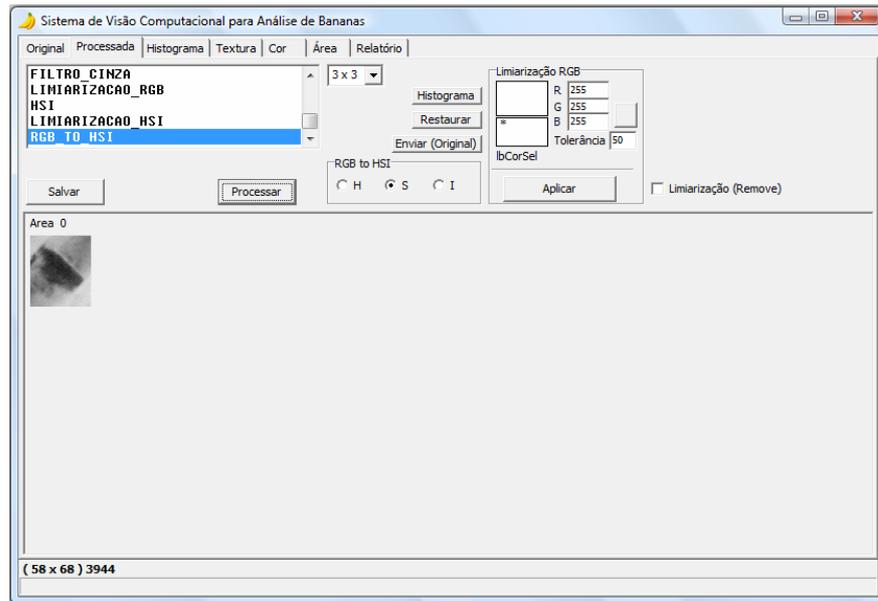


Figura 40 – Tela do sistema de visão computacional: Representação da imagem na componente S para obtenção do mapa de textura

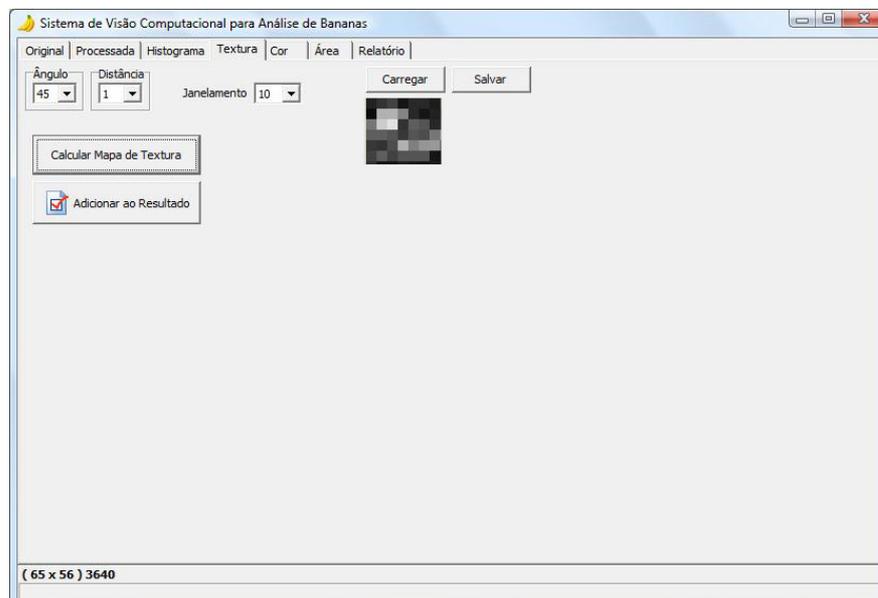


Figura 41 – Tela do sistema de visão computacional: Mapa de textura da imagem recortada e representada na componente S.

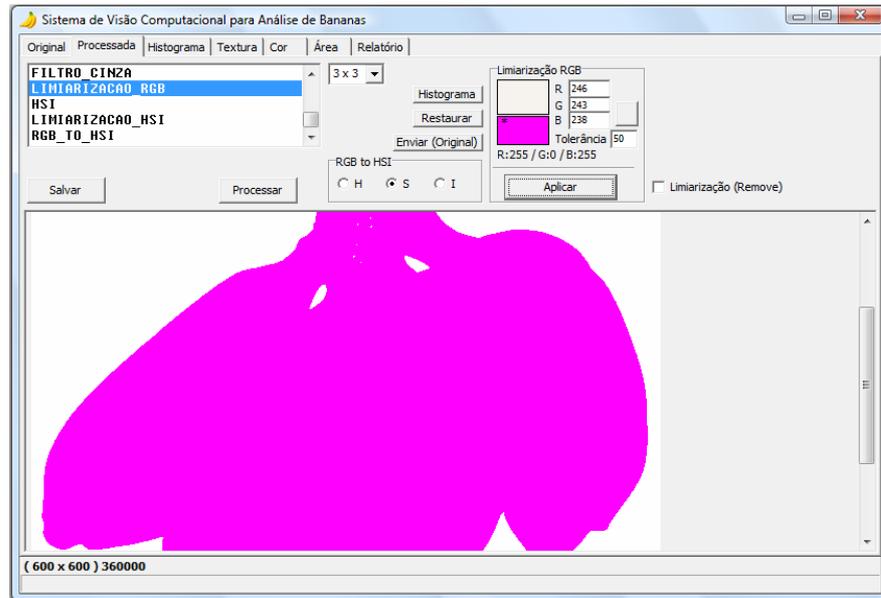


Figura 42 – Tela do sistema de visão computacional: Objeto de interesse segmentado.

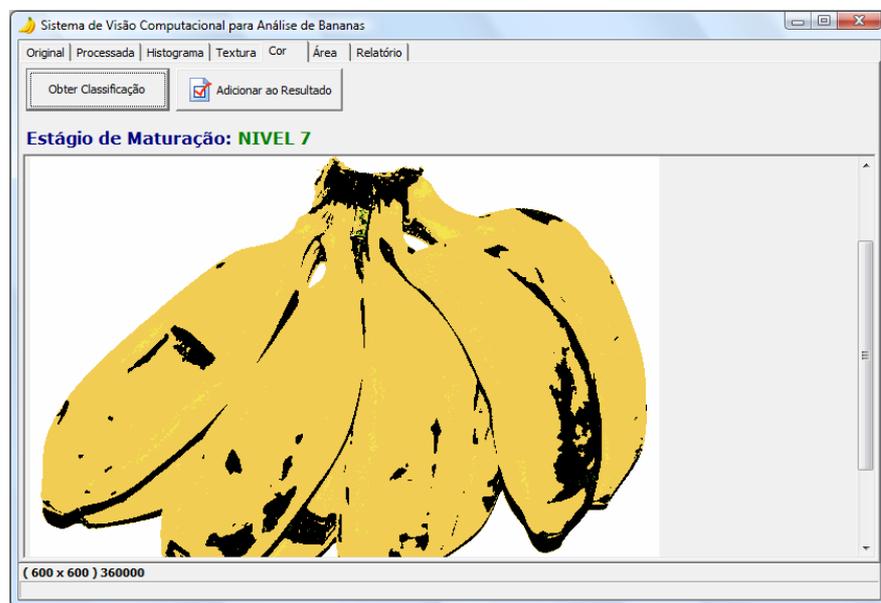


Figura 43 – Tela do sistema de visão computacional: Classificação da banana em estágio de maturação.

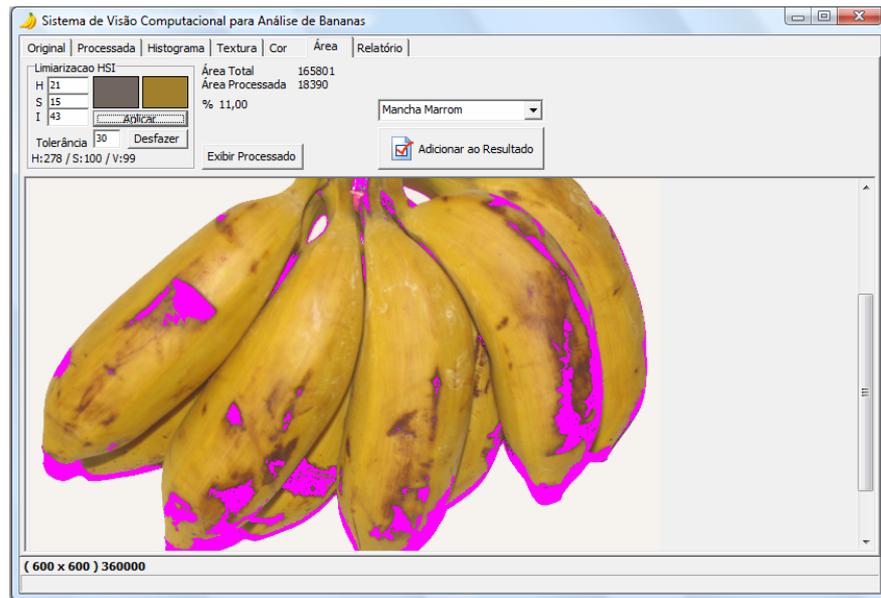


Figura 44 – Tela do Sistema com as áreas de injúrias selecionadas.

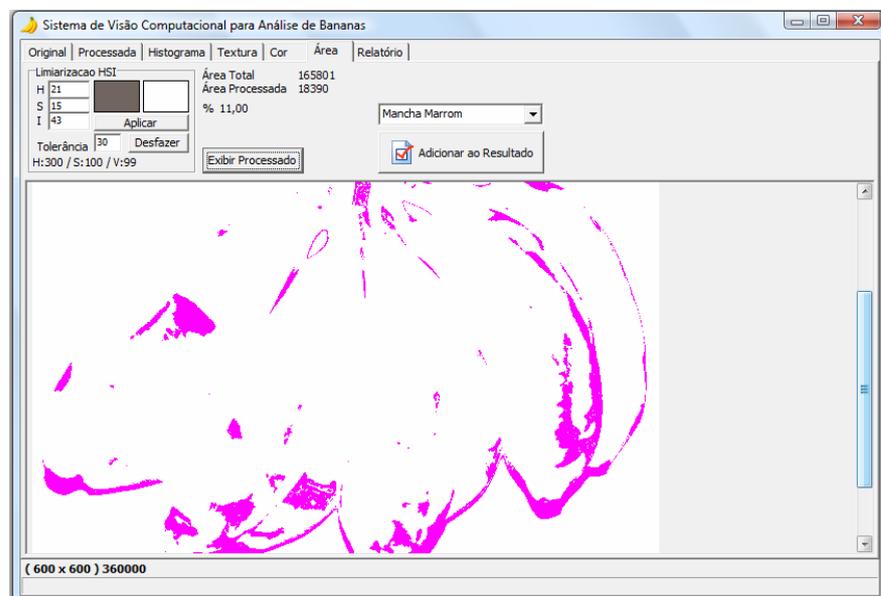


Figura 45 – Tela do sistema: somente com as áreas de injúrias.

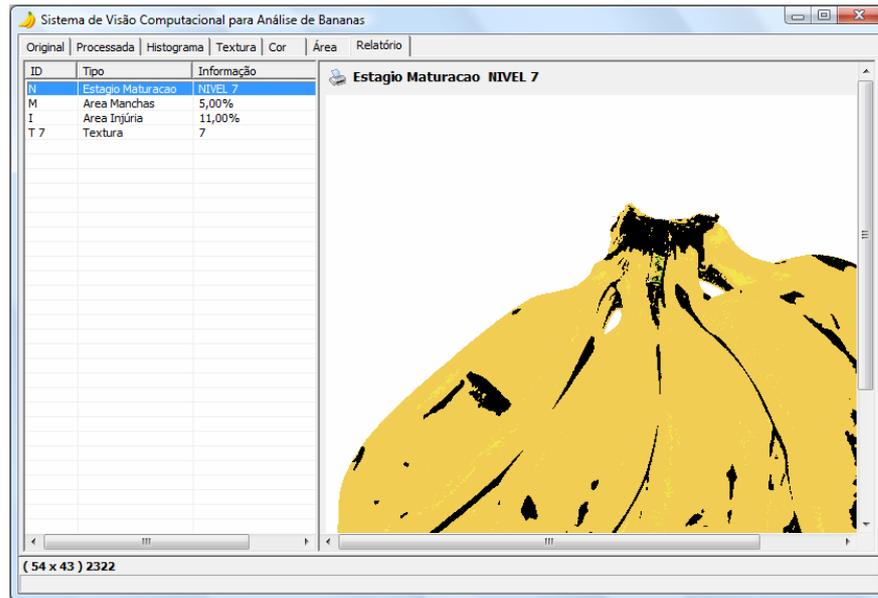


Figura 46 – Tela do sistema com os resultados do processamento da imagem para gerar o relatório.

O relatório é gerado em HTML, clicando no botão com o ícone de impressora o navegador de internet padrão do sistema operacional é chamado para exibir o conteúdo, como apresentado na Figura 47.

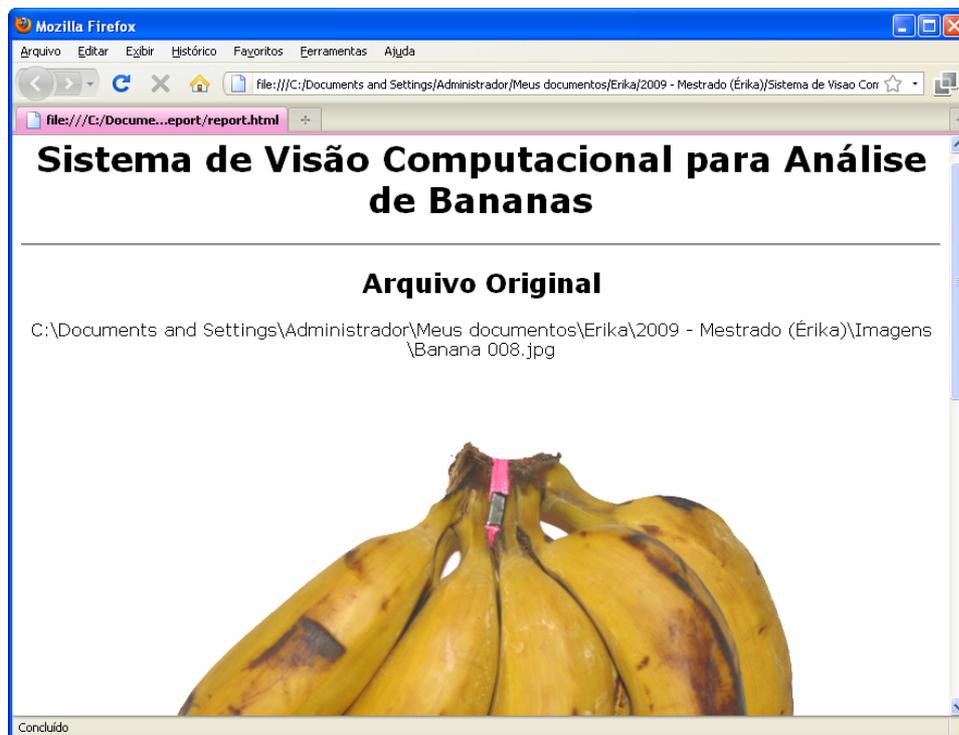


Figura 47 – Relatório gerado pelo sistema exibido no navegador de internet padrão do sistema operacional.

No relatório é exibido a imagem original e o seu endereço, a imagem obtida para encontrar o percentual de manchas marrons e injúrias e os valores percentuais, a imagem obtida na classificação em nível de maturação e a imagem do mapa de textura.

Este capítulo apresentou o desenvolvimento do sistema para classificação de bananas baseado em visão computacional, a seguir serão apresentados os resultados e discussões do modelo.

CAPÍTULO 5 – RESULTADOS E DISCUSSÕES

Neste capítulo são apresentados os resultados e as discussões que tratam da validação do método desenvolvido para classificação de acordo com o estágio de maturação e mapeamento de injúrias em bananas no pós-colheita.

5.1. Imagens geradas para validação dos algoritmos

O Programa Brasileiro de Modernização da Horticultura classificou a banana em sete níveis de maturação, como mostra a Figura 48.

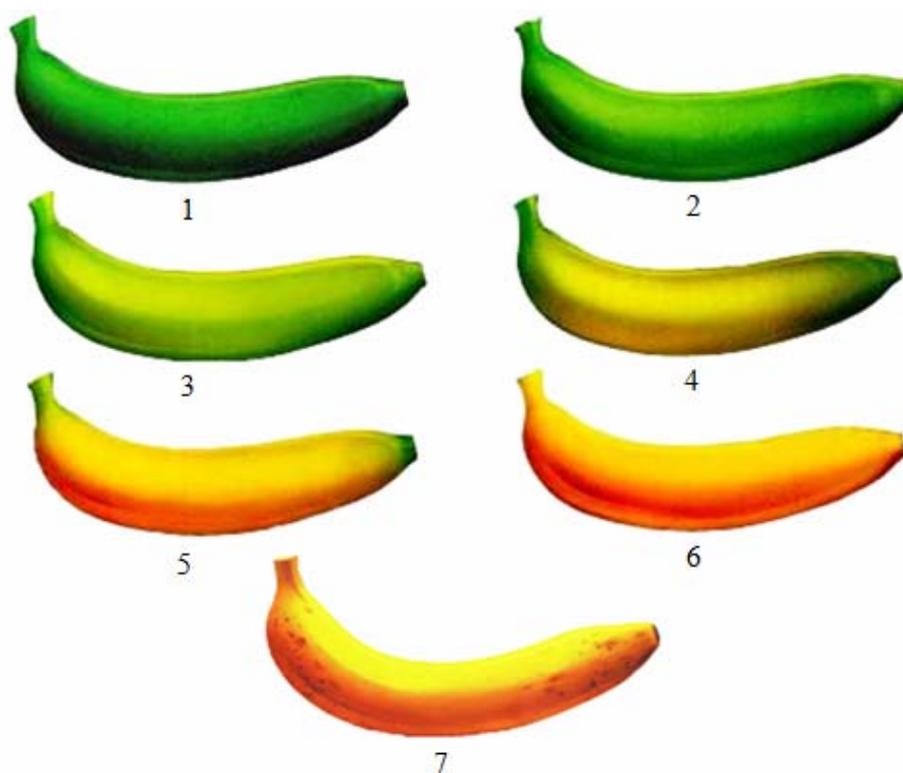


Figura 48 – Escala de maturação de Von Loesecke (PBMH e PIF, 2006).

Baseado na escala de maturação de Von Loesecke foi gerada uma paleta de cores, dividida em 7 partes, cada parte representando um nível de maturação. As cores da paleta foram utilizadas como fundo das imagens padrões geradas para validação. A Figura 49 ilustra a paleta de cores gerada e a Figura 50 mostra as cores componentes das partes para classificação.



Figura 49 – Paleta de cores, de verde a amarelo.

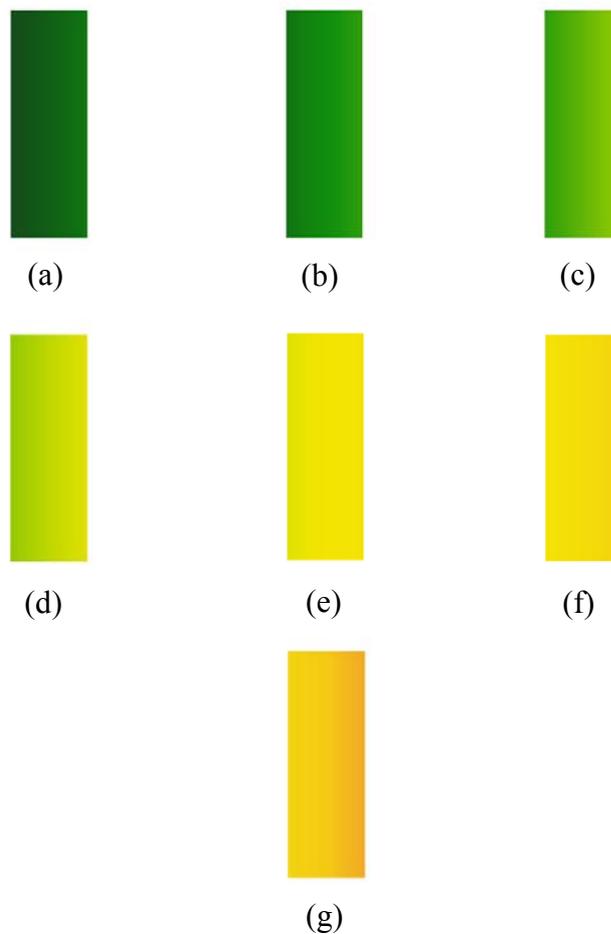


Figura 50 – Cores de níveis de maturação: (a) Estágio de maturação nível 1, (b) Estágio de maturação nível 2, (c) Estágio de maturação nível 3, (d) Estágio de maturação nível 4, (e) Estágio de maturação nível 5, (f) Estágio de maturação nível 6, (g) Estágio de maturação nível 7.

Gerada a paleta de cores, de verde a amarelo (verde, verde claro, amarelo claro e amarelo) e dividida em 7 partes, cada parte contextualizou o valor percentual de verde, verde claro, amarelo claro e amarelo em cada nível de maturação, como apresenta a tabela 3.

VERDE %	VERDE CLARO %	AMARELO CLARO %	AMARELO%	ESTÁGIO DE MATURAÇÃO
100	0	0	0	Nível 1
0	94	6	0	Nível 2
0	73	27	0	Nível 3
0	38	62	0	Nível 4
0	21	79	0	Nível 5
0	0	76	24	Nível 6
0	0	27	73	Nível 7

Tabela 3 – Quantidade percentual de verde a amarelo em cada nível de maturação.

Para validação dos algoritmos foram geradas imagens com padrões geométricos circulares, os tipos de imagens foram gerados com tamanho 600×600 *pixels* e resolução de 71 *pixels*/ cm.

O primeiro tipo de imagem gerada para validação foi elaborado considerando uma forma geométrica ao centro (círculo e elipse). Foram geradas imagens para cada nível de maturação e áreas geométricas com tonalidades de marrom de acordo com a tabela 4.

TONS DE MARROM			VALOR NA REPRESENTAÇÃO DA DA IMAGEM NA COMPONENTE S
R	G	B	
26	22	22	38
51	40	38	63
77	56	50	89
102	71	56	114
128	87	57	140
142	85	30	188
161	109	35	198
217	115	41	206
173	105	8	242
196	118	6	244

Tabela 4 – Tonalidade de marrom das formas geométricas e seu respectivo valor na representação da imagem na componente S.

Ao total foram gerados 280 padrões de imagens com o fundo retangular, sendo 10 intensidades diferentes para cada forma geométrica considerada, considerando 2 tipos de tamanhos para cada padrão. A Figura 51 ilustra exemplos de imagens com círculo (1), geradas para os testes dos algoritmos.

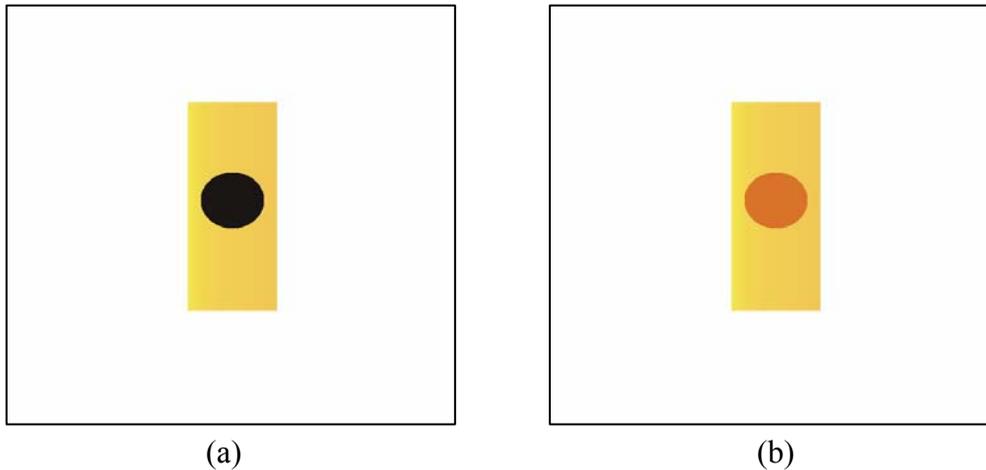


Figura 51 – Imagens da forma círculo (1), nível de maturação 7, geradas para a validação do algoritmo para identificação de manchas marrons e injúrias, (a) Imagem círculo (1) com tom de marrom R=26, G=22 e B=22 e (b) Imagem círculo (1) com tom de marrom R=217, G=115 e B=41.

A Figura 52 ilustra exemplos de imagens com elipse (1), geradas para os testes dos algoritmos.

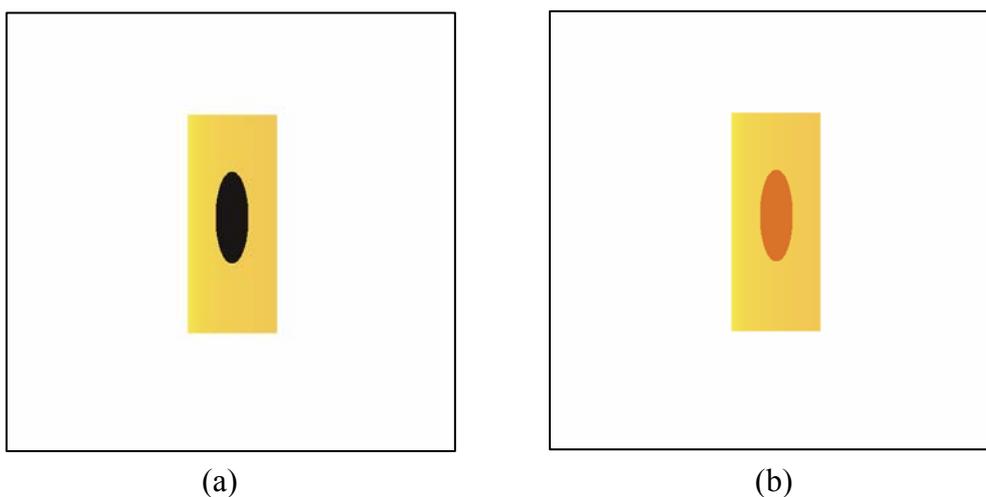


Figura 52 - Imagens da forma elipse (1), nível de maturação nível 7, geradas para a validação do algoritmo para identificação dos manchas marrons e injúrias, (a) Imagem elipse (1) com tom de marrom R=26, G=22 e B=22 e (b) Imagem elipse (1) com tom de marrom R=217, G=115 e B=41.

A Figura 53 ilustra exemplos de imagens com círculo (2), geradas para os testes dos algoritmos.

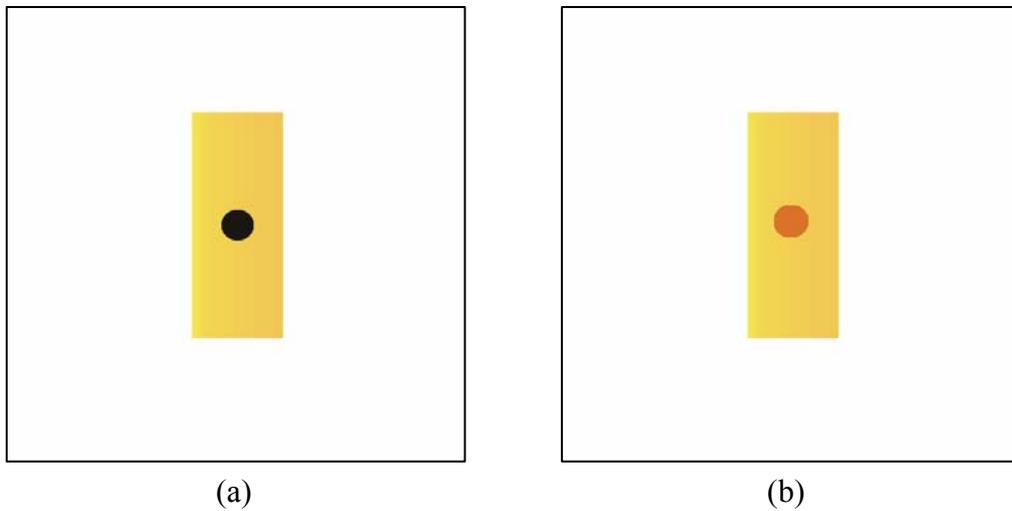


Figura 53 - Imagens da forma círculo (2), nível de maturação 7, geradas para a validação do algoritmo para identificação dos manchas marrons e injúrias, (a) Imagem círculo (2) com tom de marrom R=26, G=22 e B=22 e (b) Imagem círculo (2) com tom de marrom R=217, G=115 e B=41.

A Figura 54 ilustra exemplos de imagens com elipse (2), geradas para os testes dos algoritmos.

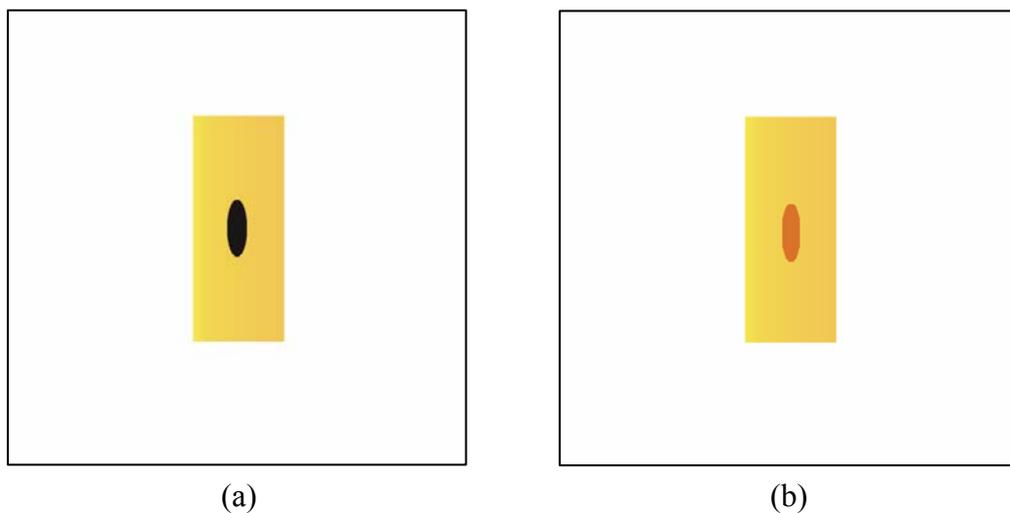


Figura 54 - Imagens da forma elipse (2), nível de maturação 7, geradas para a validação do algoritmo do mapeamento da área de risco, (a) Imagem elipse (2) com tom de marrom R=26, G=22 e B=22 e (b) Imagem elipse (2) com tom de marrom R=217, G=115 e B=41.

Considerou-se ainda um segundo tipo de imagem utilizada para a validação dos algoritmos com padrões compostos. As imagens com formas geométricas compostas que foram geradas possuíam misturas de padrões (círculo e elipse). A Figura 55 ilustra alguns exemplos de imagens com formas geométricas geradas, as quais sua análise totalizou um número de 105 imagens.

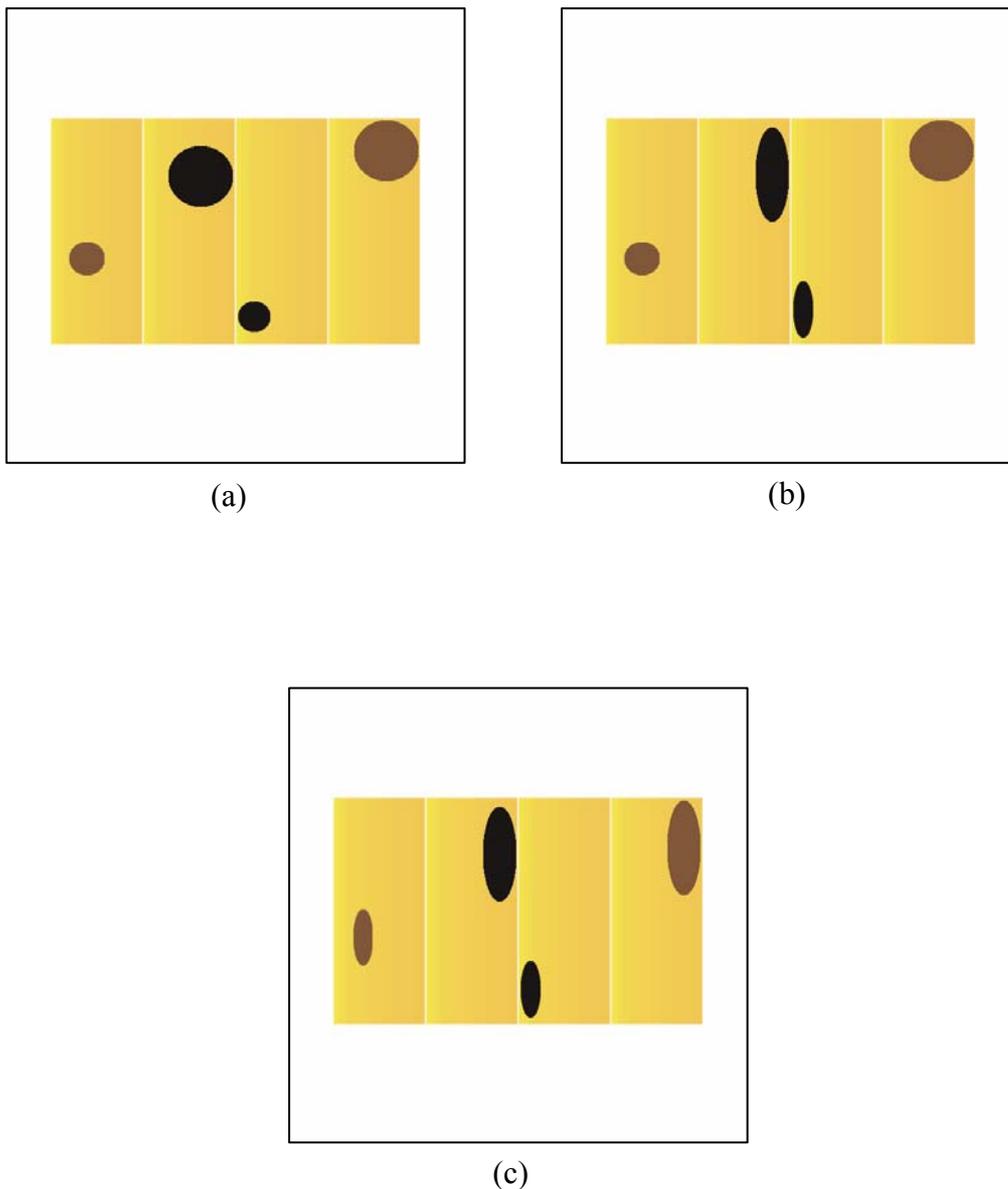


Figura 55 – Exemplos de imagens com formas geométricas compostas, nível de maturação 7: (a) Imagem com círculos em tons de marrom R=26, G=22, B=22 e R=128, G=87, B=57, (b) Imagem com elipses em tons de marrom R=26, G=22 e B=22 e R=128, G=87, B=57, (c) Imagem com círculos e elipses com os mesmos tons de marrom do item a e b.

5.2. Método baseado em textura

5.2.1. Pré-processamento para o método de textura

O mapa de textura é obtido a partir de uma imagem em tons de cinza. Para gerar o mapa foi feita uma análise das imagens que representam a componente H, S e I. O pré-processamento para a identificação das manchas marrons e injúrias foi aplicado para converter a imagem original em uma imagem do modelo HSI e em seguida foi aplicado o filtro de mediana para eliminar os ruídos da imagem. A Figura 56 ilustra a representação da imagem original na componente H, componente S e a componente I.

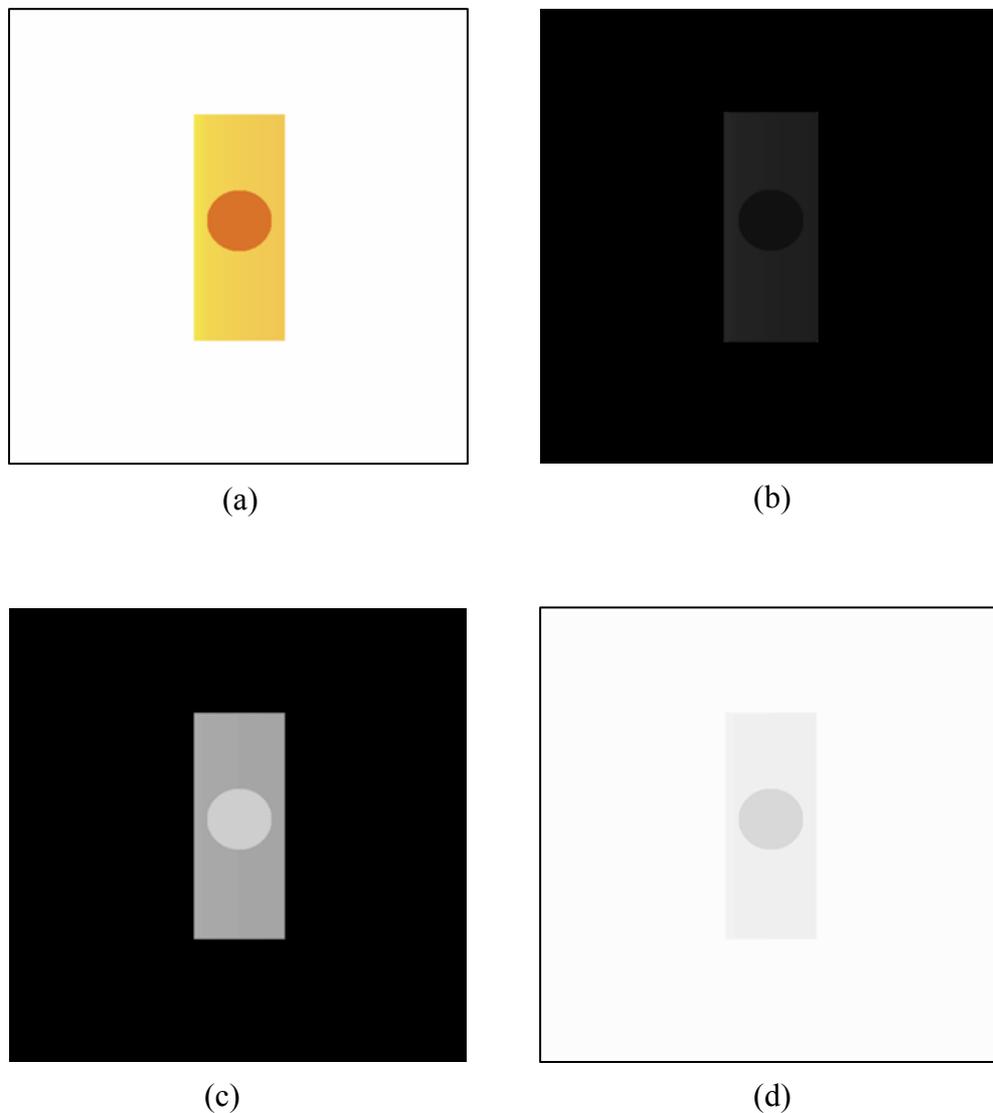


Figura 56 – Exemplos de representação da imagem: (a) Imagem Original, (b) Representação na componente H, (c) Representação na componente S e (d) Representação na componente I.

Com base nas análises feitas, observou-se que a representação da imagem pela componente S proporcionou o melhor resultado na obtenção do mapa de textura para identificar as manchas marrons e injúrias em bananas.

A Figura 57 ilustra a imagem original com círculo (1) e a representação da imagem original na componente S.

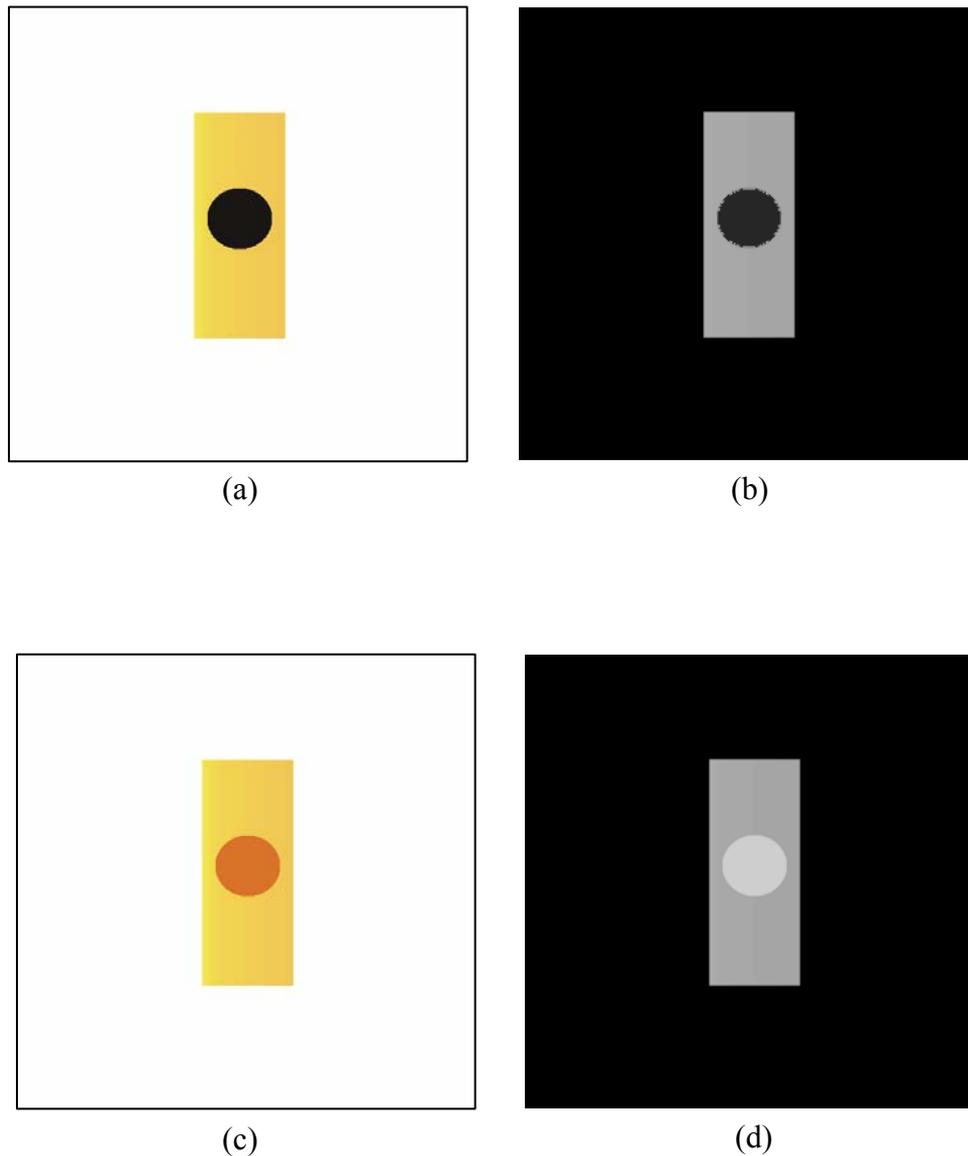


Figura 57 – Exemplos de imagem original e sua representação na componente S, nível de maturação 7: (a) Imagem original com círculo (1) em tom de marrom R=26, G=22, B=22, (b) Representação da imagem original na componente S, cujo valor do círculo é 38, (c) Imagem original com círculo (1) em tom de marrom R=128, G=87, B=57, e (d) Representação da imagem original na componente S, cujo valor do círculo é 206.

A Figura 58 ilustra a imagem original com elipse (1) e a representação da imagem original na componente S.

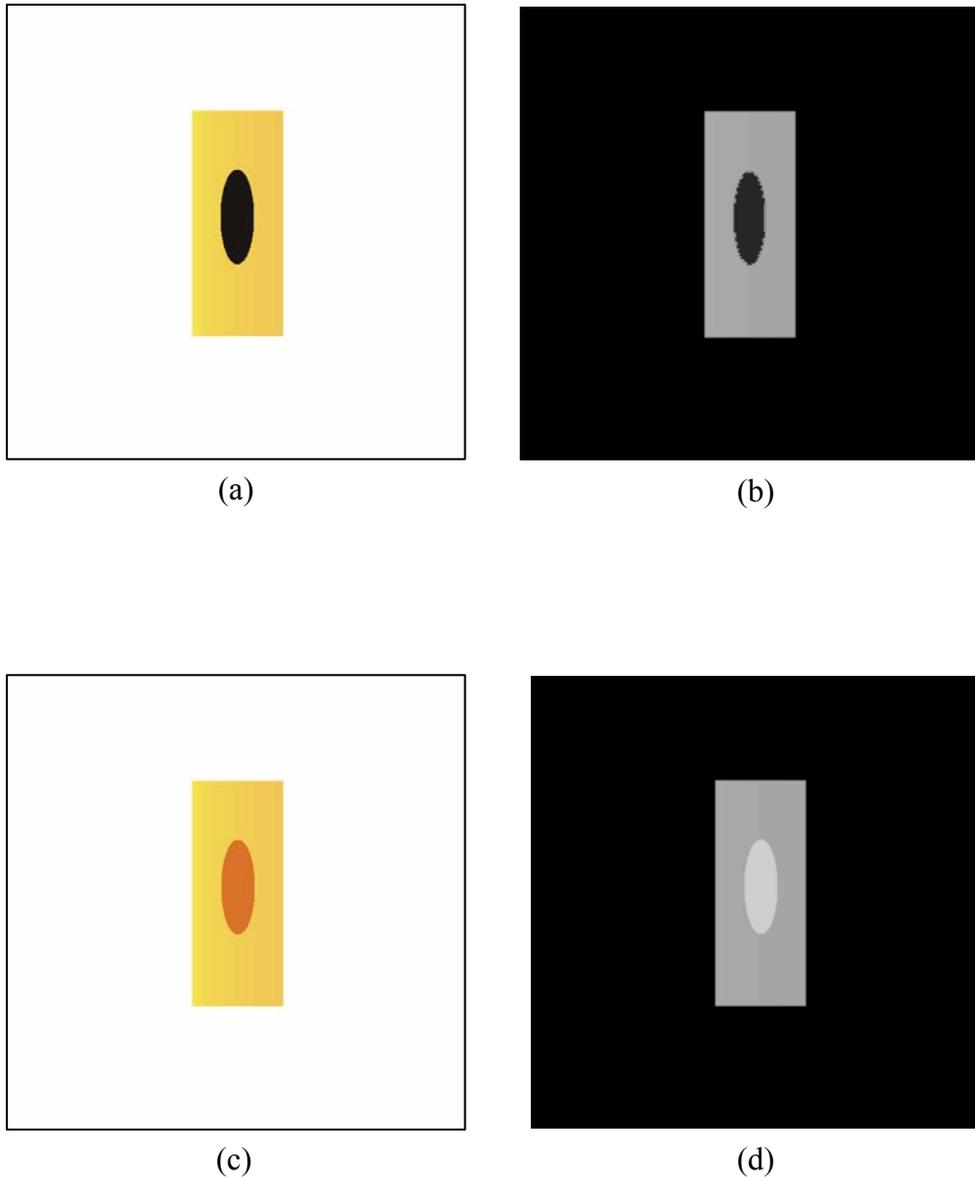


Figura 58 – Exemplos de imagem original e sua representação na componente S, nível de maturação 7: (a) Imagem original com elipse (1) em tom de marrom R=26, G=22, B=22, (b) Representação da imagem original na componente S, cujo valor do círculo é 38, (c) Imagem original com elipse (1) em tom de marrom R=128, G=87, B=57, e (d) Representação da imagem original na componente S, cujo valor do círculo é 206.

A Figura 59 ilustra a imagem original com círculo (2) e a representação da imagem original na componente S.

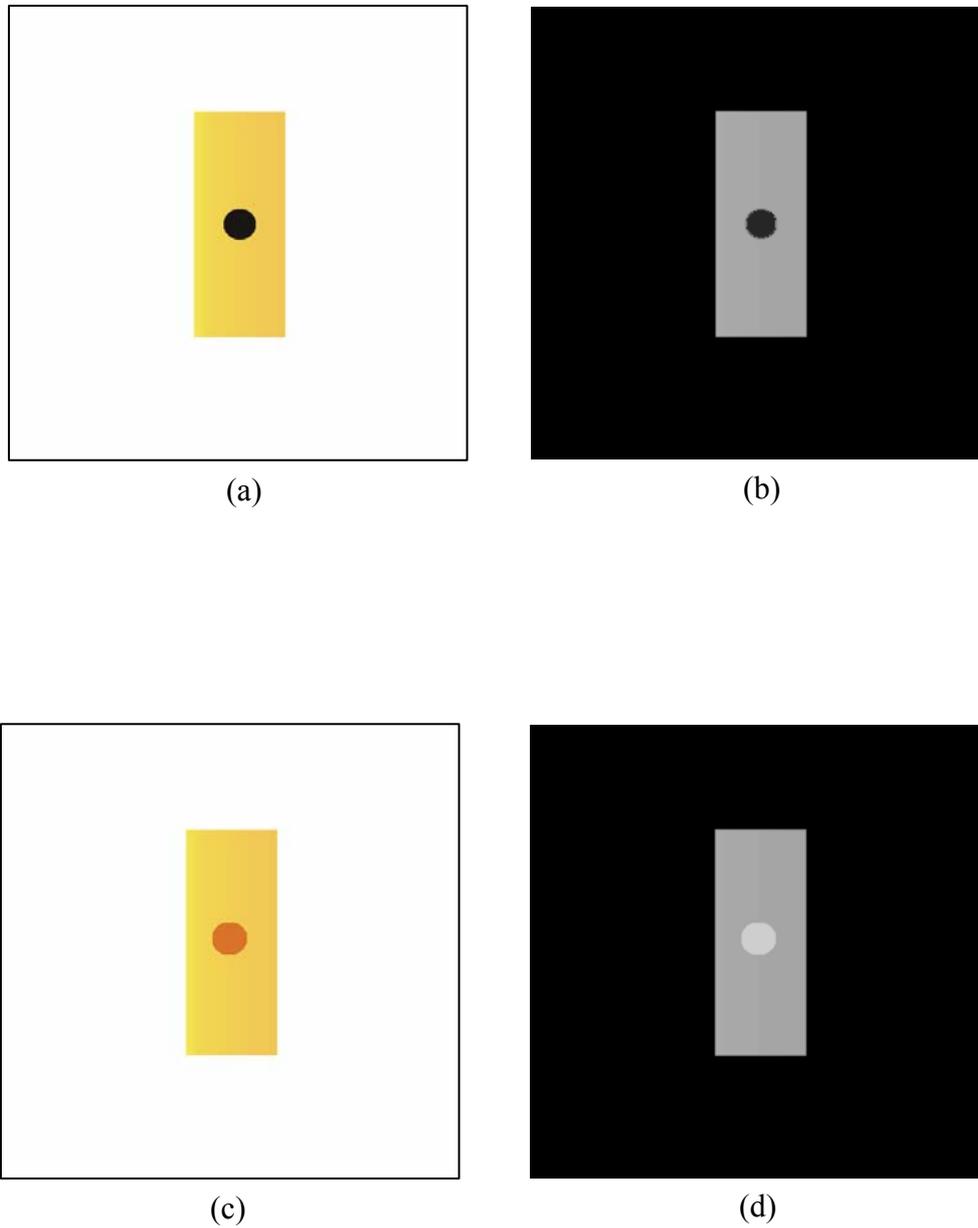


Figura 59 – Exemplos de imagem original e sua representação na componente S, nível de maturação 7: (a) Imagem original com círculo (2) em tom de marrom $R=26$, $G=22$, $B=22$, (b) Representação da imagem original na componente S, cujo valor do círculo é 38, (c) Imagem original com círculo (2) em tom de marrom $R=128$, $G=87$, $B=57$, e (d) Representação da imagem original na componente S, cujo valor do círculo é 206.

A Figura 60 ilustra a imagem original com elipse (2) e a representação da imagem original na componente S.

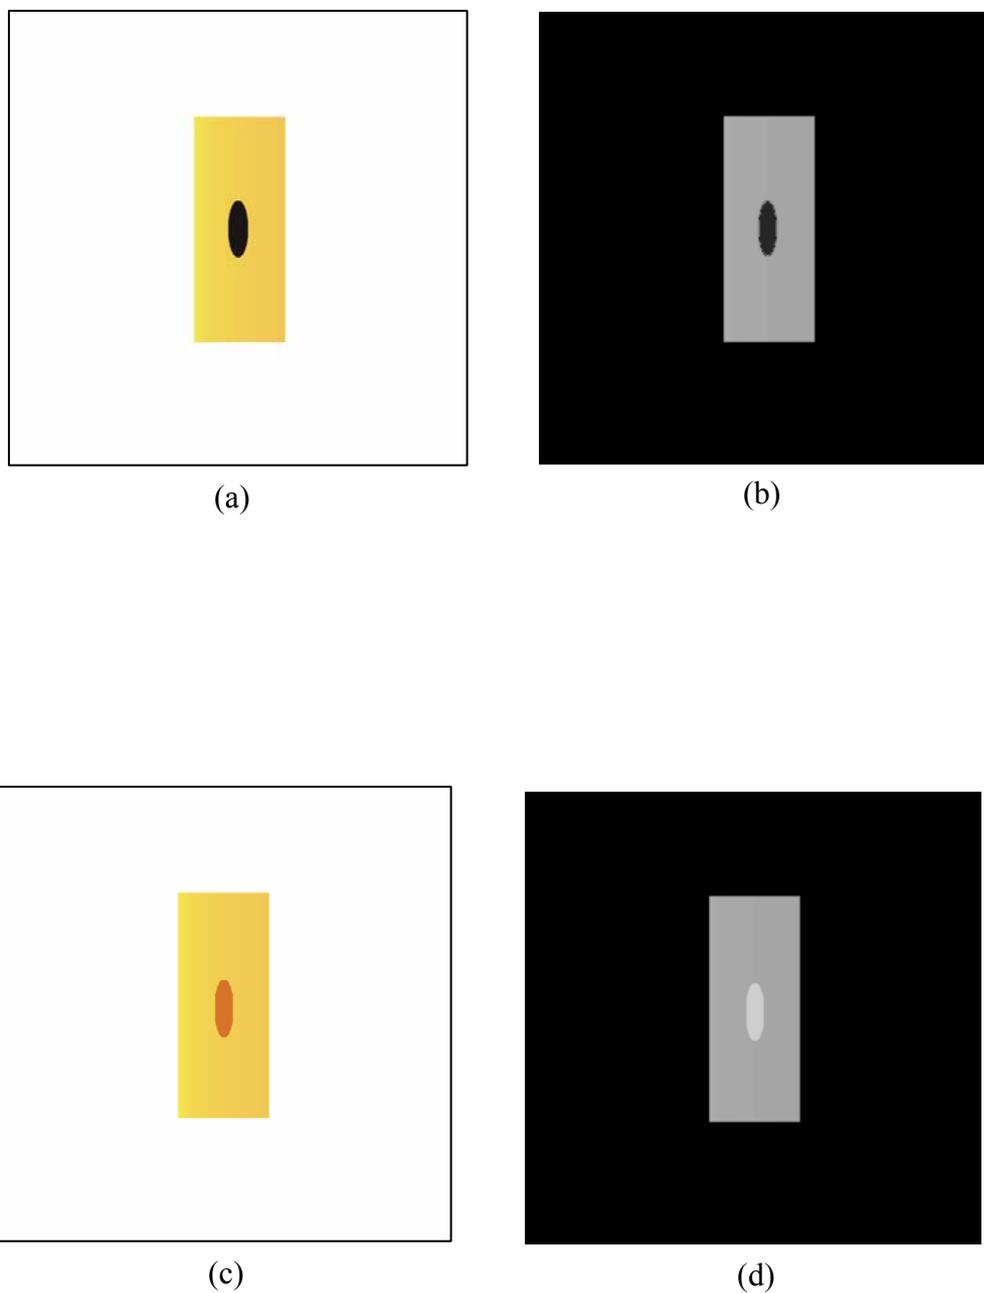


Figura 60 – Exemplos de imagem original e sua representação na componente S, nível de maturação 7: (a) Imagem original com elipse (2) em tom de marrom $R=26$, $G=22$, $B=22$, (b) Representação da imagem original na componente S, cujo valor do círculo é 38, (c) Imagem original com elipse (2) em tom de marrom $R=128$, $G=87$, $B=57$, e (d) Representação da imagem original na componente S, cujo valor do círculo é 206.

5.2.2. Identificação baseada em textura

A identificação da textura foi utilizada para encontrar em uma imagem a região que pertence a manchas marrons e a região que pertence a injúrias. Isto foi possível, pois para cada uma a tonalidade de cinza no mapa obtido é diferente, mais clara para injúrias e mais escura para manchas marrons.

O primeiro passo do algoritmo 2 descrito na página 76, tem a função de selecionar e recortar a área de interesse e obter a representação da imagem na componente S. Em seguida é obtido o mapa de textura da imagem resultante. Foram testadas diferentes medidas para encontrar aquela que apresentasse o menor erro na identificação das formas. As medidas testadas foram o contraste, segundo momento angular (SMA) e entropia, valores estatísticos obtidos através da matriz de co-ocorrência. Para a avaliação do erro de identificação foi utilizado o desvio padrão dos valores de textura encontrados para cada imagem geométrica, considerando as 10 tonalidades diferentes, em cada nível de maturação.

O teste do contraste apresentou variação nas diferentes tonalidades utilizadas, esta ocorrência foi associada ao posicionamento do objeto e ao tamanho do janelamento.

As Figuras 61, 62 e 63 apresentam os gráficos criados para análise das três medidas de textura consideradas no nível de maturação 1.

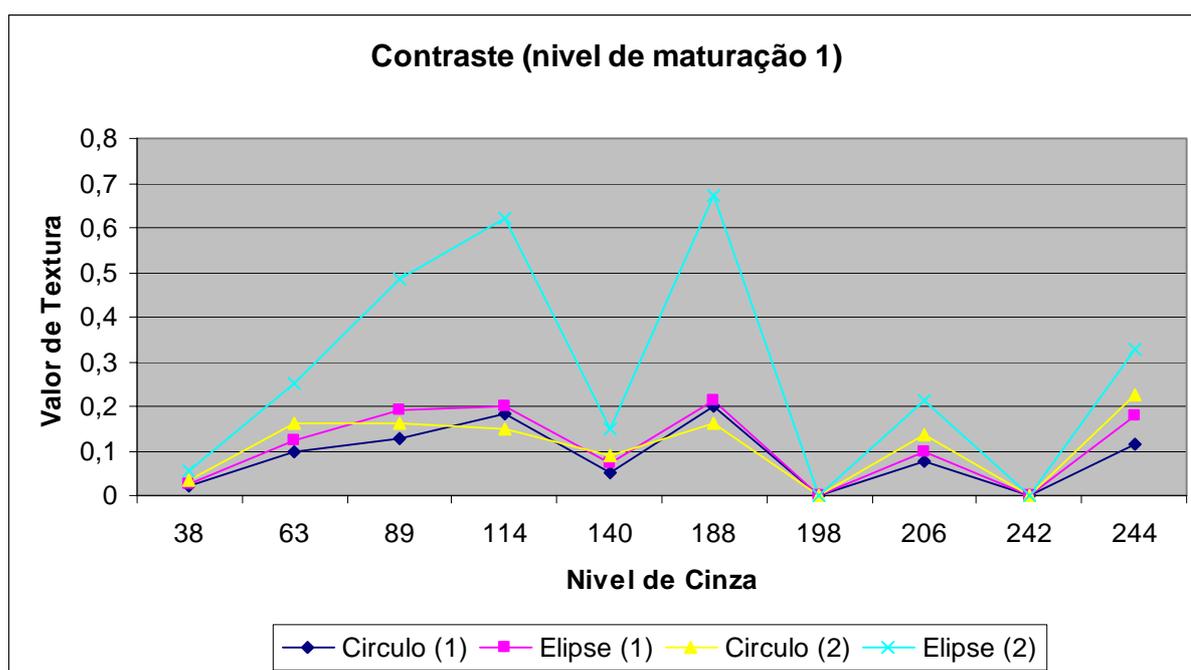


Figura 61 - Comparação dos valores de textura utilizando medida de contraste.

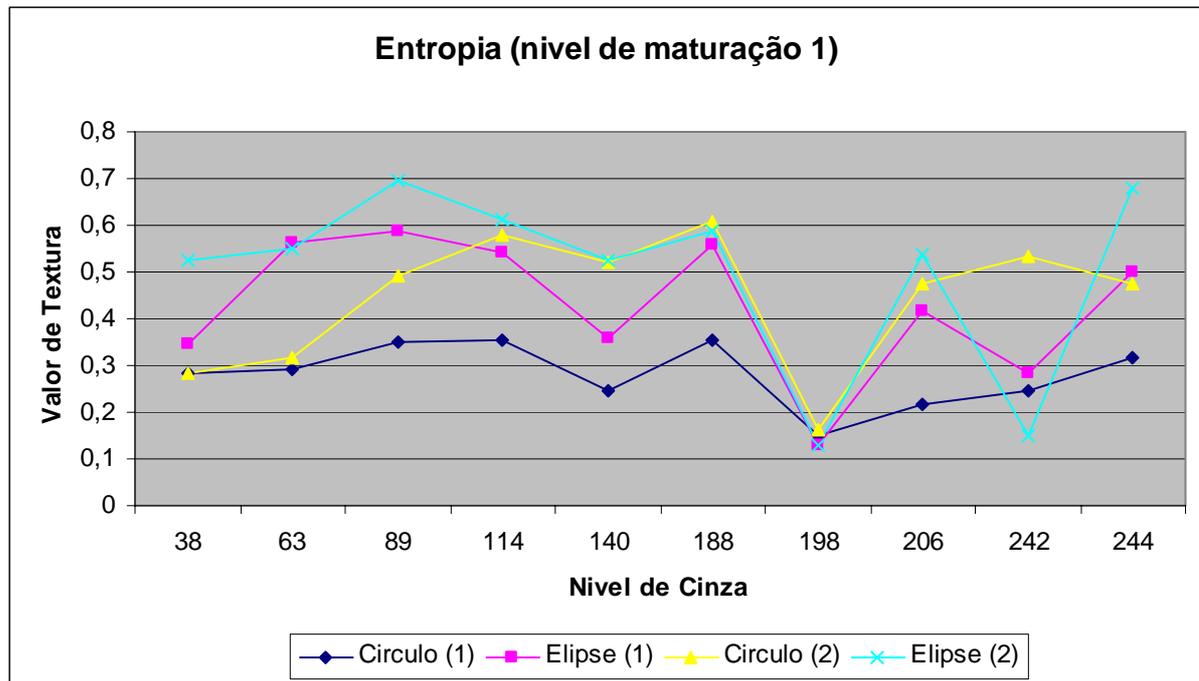


Figura 62 – Comparação dos valores de textura utilizando a medida de entropia.

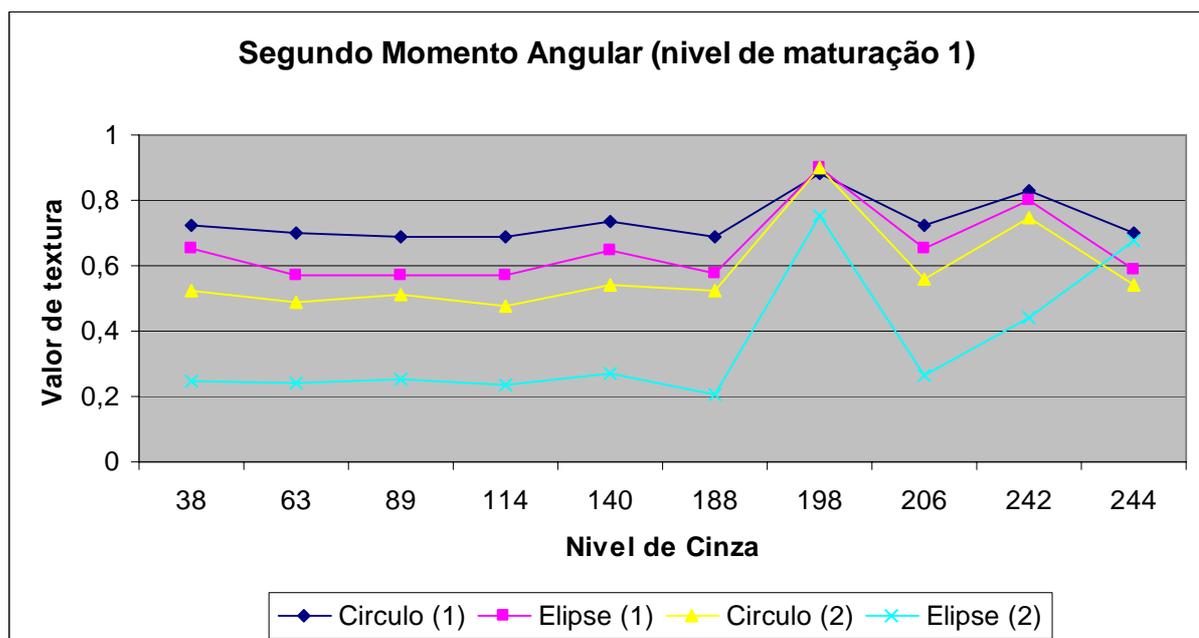


Figura 63 – Comparação dos valores de textura utilizando medida de SMA.

A tabela 5 apresenta os valores de desvio padrão para cada uma das medidas de textura consideradas no nível de maturação 1.

FORMA	DESVIO PADRÃO		
	Contraste	Entropia	SMA
Circulo (1)	0,071	0,067	0,067
Elipse (1)	0,084	0,150	0,111
Circulo (2)	0,077	0,144	0,134
Elipse (2)	0,247	0,199	0,199

Tabela 5 – Valores de desvio padrão das medidas de textura encontradas para cada uma das formas consideradas no nível de maturação 1.

As Figuras 64, 65 e 66 apresentam os gráficos criados para análise das três medidas de textura consideradas no nível de maturação 2.

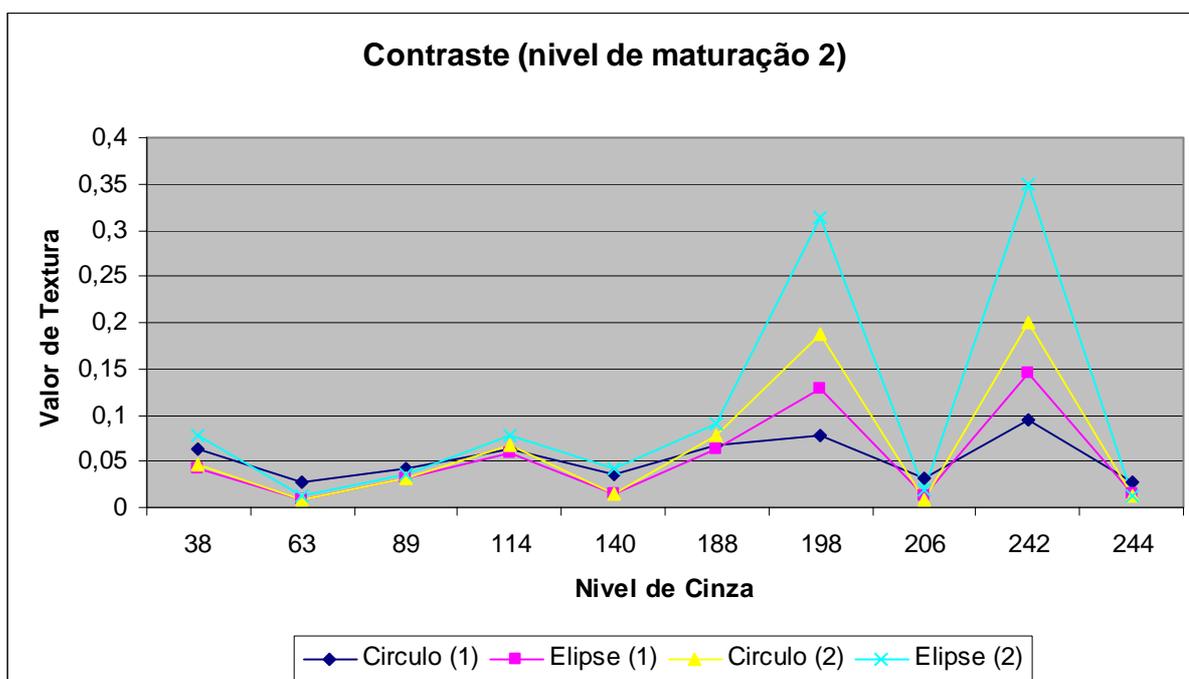


Figura 64 – Comparação dos valores de textura utilizando medida de contraste.

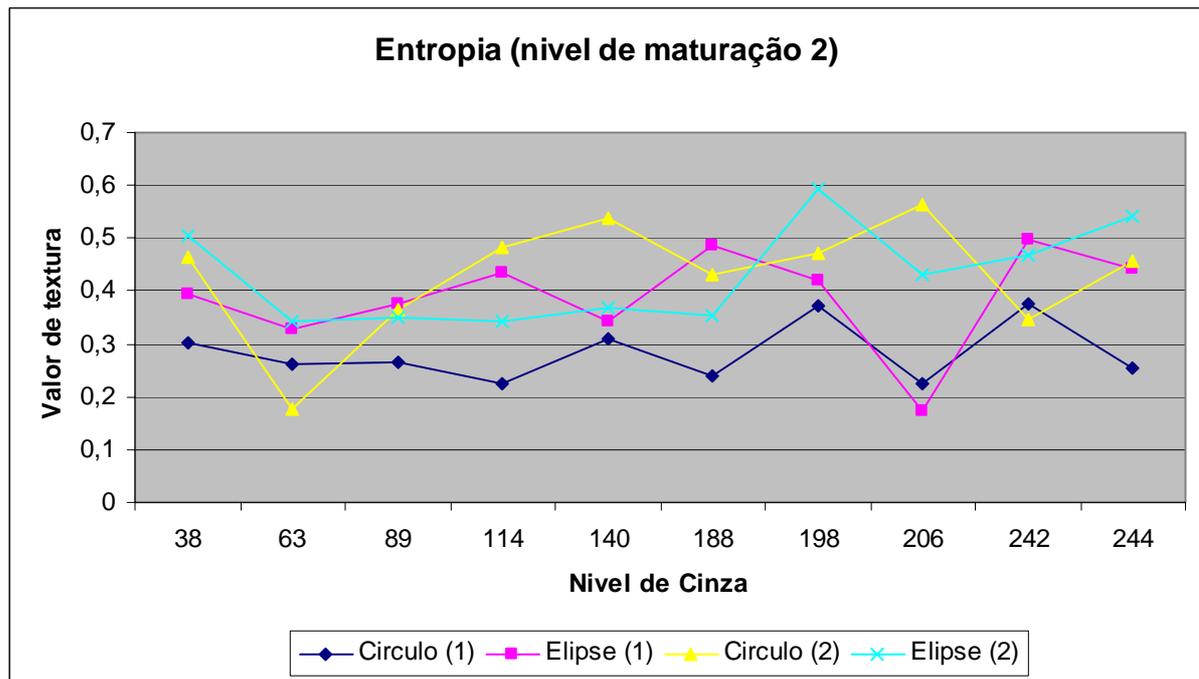


Figura 65 – Comparação dos valores de textura utilizando medida de entropia.

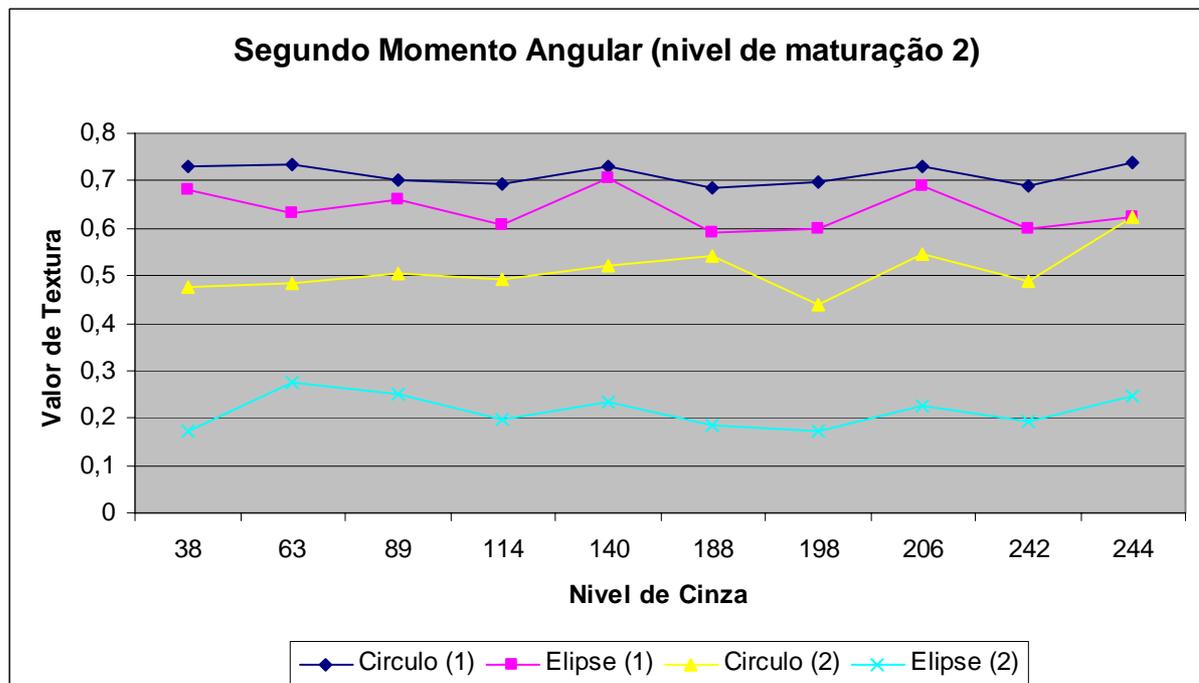


Figura 66 – Comparação dos valores de textura utilizando medida de SMA.

A tabela 6 apresenta os valores de desvio padrão para cada uma das medidas de textura consideradas no nível de maturação 2.

FORMA	DESVIO PADRÃO		
	Contraste	Entropia	SMA
Círculo (1)	0,023	0,056	0,020
Elipse (1)	0,049	0,094	0,042
Círculo (2)	0,072	0,111	0,050
Elipse (2)	0,124	0,093	0,036

Tabela 6 – Valores de desvio padrão das medidas de textura encontradas para cada uma das formas consideradas no nível de maturação 2.

As Figuras 67, 68 e 69 apresentam os gráficos criados para análise das três medidas de textura consideradas no nível de maturação 3.

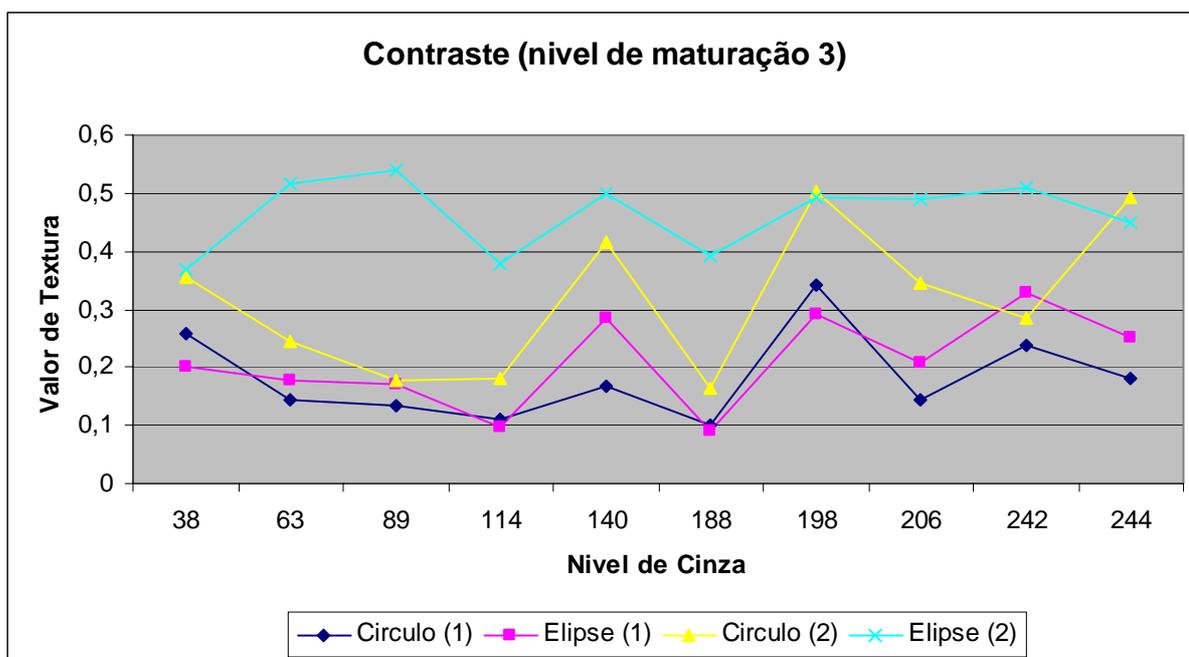


Figura 67 – Comparação dos valores de textura utilizando medida de contraste.

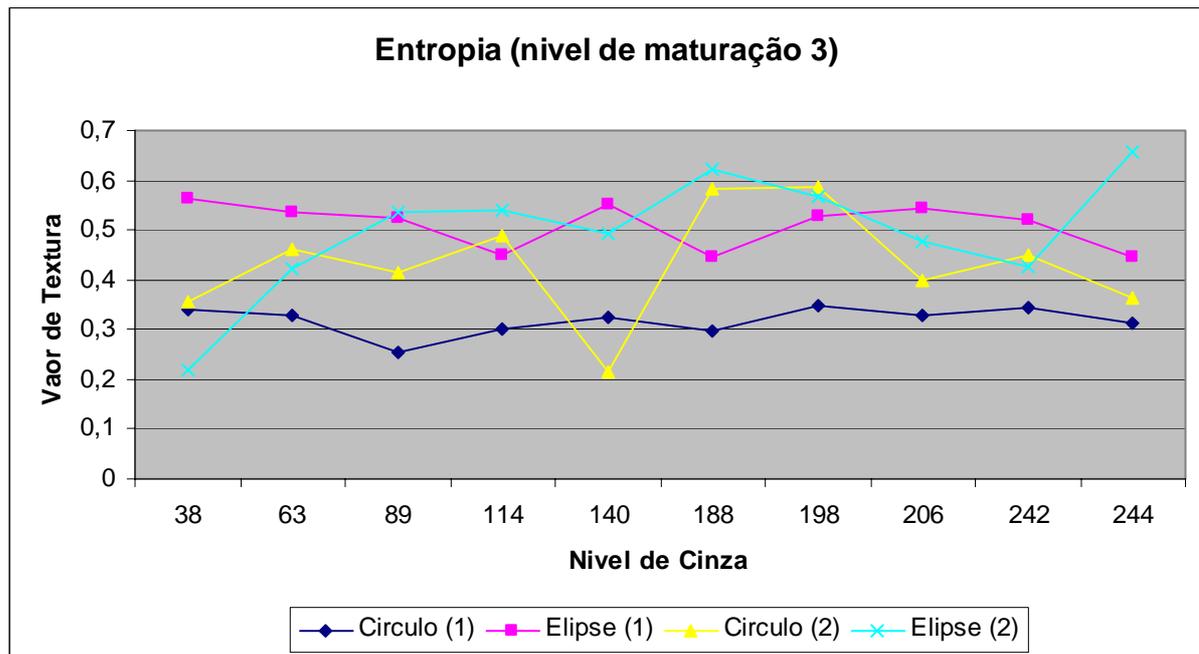


Figura 68 – Comparação dos valores de textura utilizando medida de entropia.

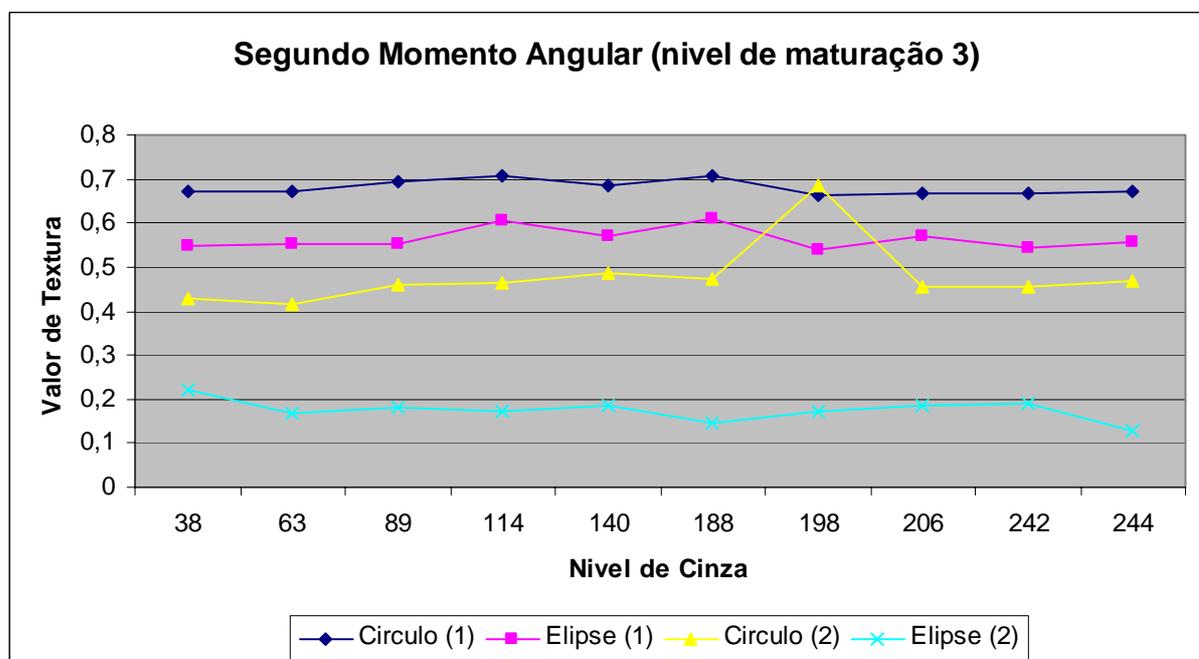


Figura 69 – Comparação dos valores de textura utilizando medida de SMA.

A tabela 7 apresenta os valores de desvio padrão para cada uma das medidas de textura consideradas no nível de maturação 3.

FORMA	DESVIO PADRÃO		
	Contraste	Entropia	SMA
Círculo (1)	0,076	0,028	0,017
Elipse (1)	0,080	0,046	0,025
Círculo (2)	0,127	0,111	0,076
Elipse (2)	0,062	0,124	0,024

Tabela 7 – Valores de desvio padrão das medidas de textura encontradas para cada uma das formas consideradas no nível de maturação 3.

As Figuras 70, 71 e 72 apresentam os gráficos criados para análise das três medidas de textura consideradas, nível de maturação 4.

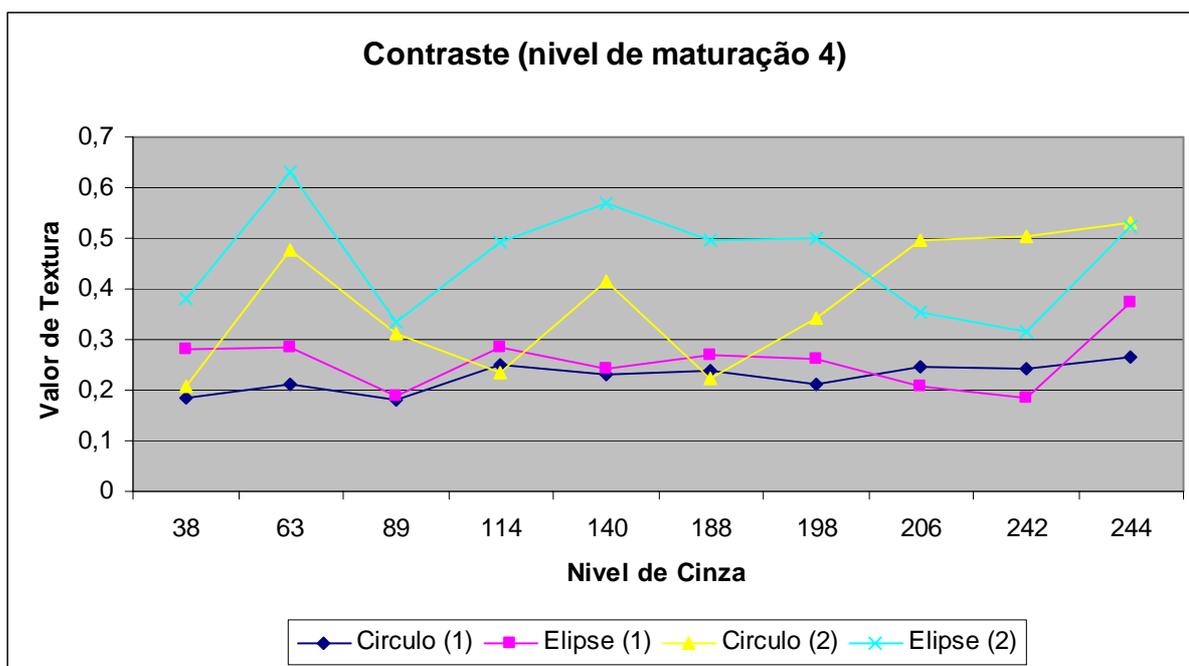


Figura 70 - Comparação dos valores de textura utilizando medida de contraste.

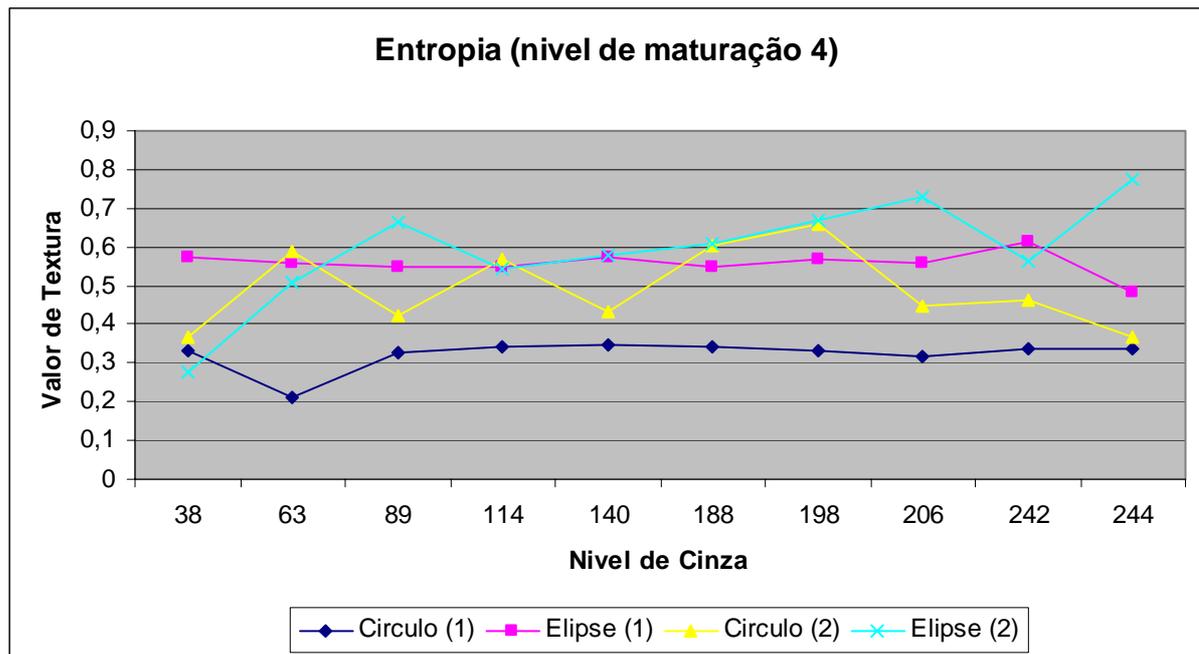


Figura 71 – Comparação dos valores de textura utilizando medida de entropia.

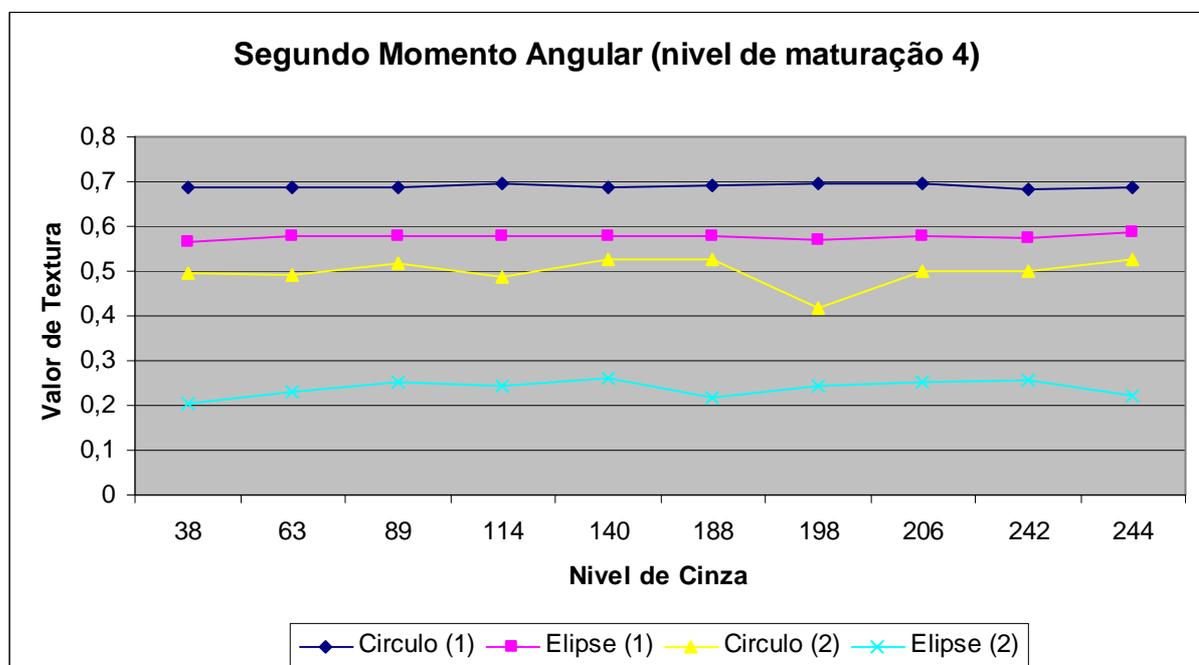


Figura 72 – Comparação dos valores de textura utilizando medida de SMA.

A tabela 8 apresenta os valores de desvio padrão para cada uma das medidas de textura consideradas no nível de maturação 4.

FORMA	DESVIO PADRÃO		
	Contraste	Entropia	SMA
Círculo (1)	0,029	0,040	0,004
Elipse (1)	0,056	0,033	0,007
Círculo (2)	0,127	0,105	0,032
Elipse (2)	0,108	0,138	0,018

Tabela 8 – Valores de desvio padrão das medidas de textura encontradas para cada uma das formas consideradas no nível de maturação 4.

As Figuras 73, 74 e 75 apresentam os gráficos criados para análise das três medidas de textura consideradas, nível de maturação 5.

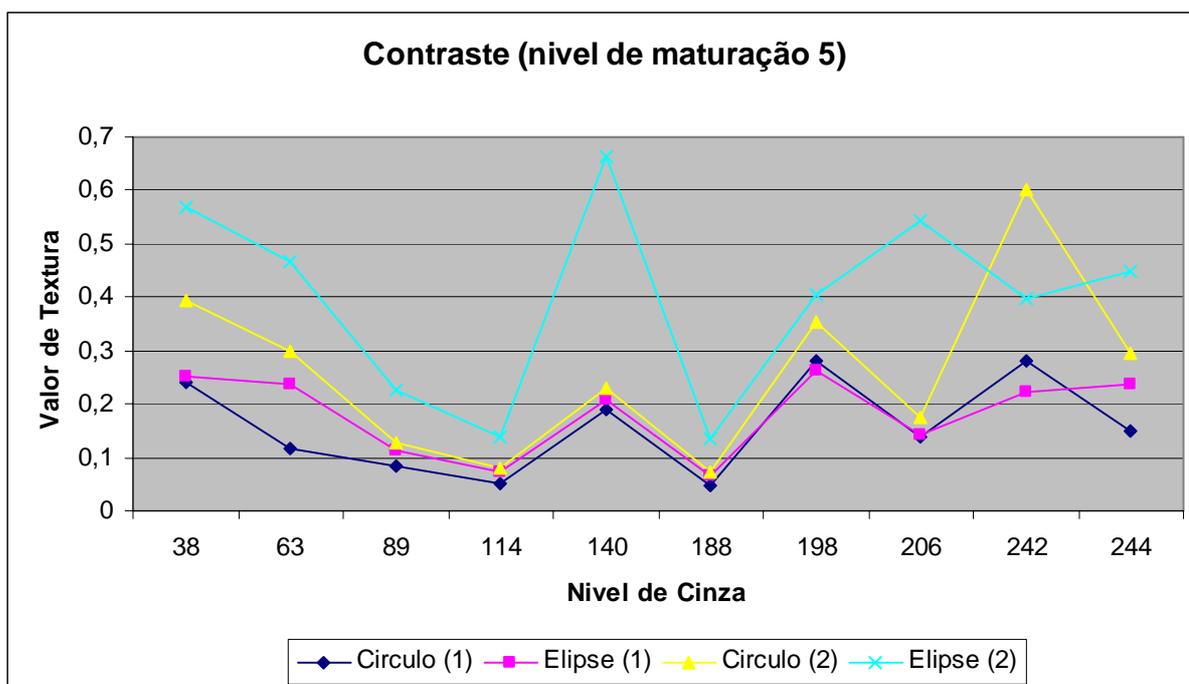


Figura 73 – Comparação dos valores de textura utilizando medida de contraste.

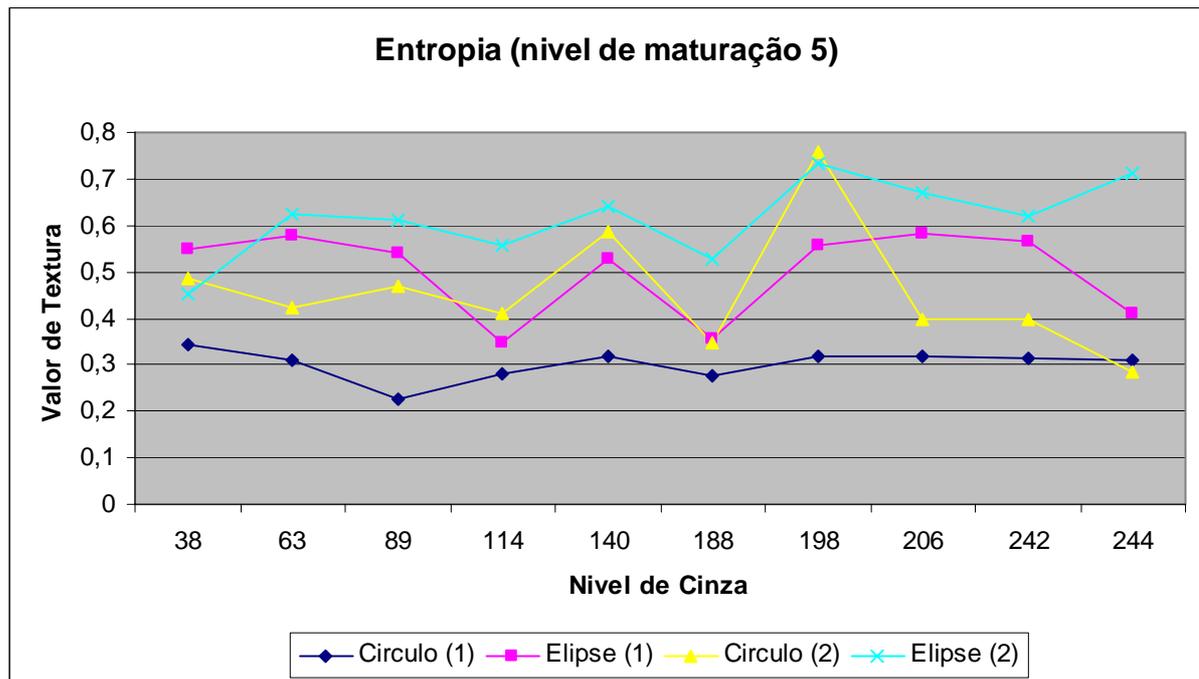


Figura 74 – Comparação dos valores de textura utilizando medida de entropia.

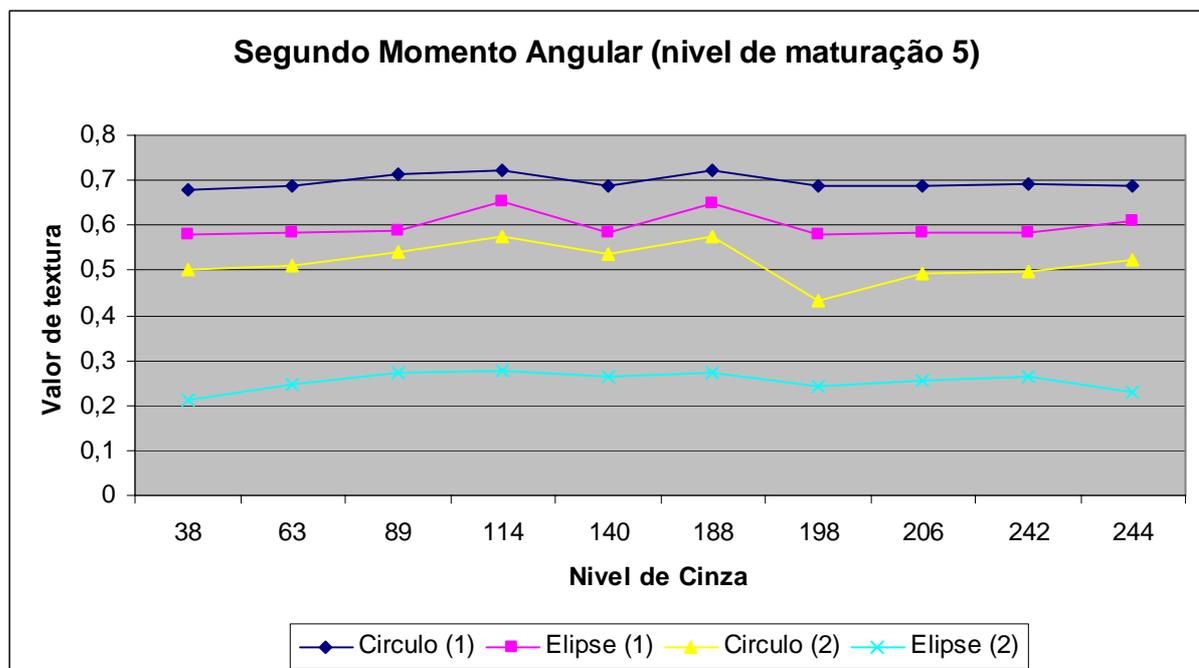


Figura 75 – Comparação dos valores de textura utilizando medida de SMA.

A tabela 9 apresenta os valores de desvio padrão para cada uma das medidas de textura consideradas no nível de maturação 5.

FORMA	DESVIO PADRÃO		
	Contraste	Entropia	SMA
Círculo (1)	0,088	0,032	0,016
Elipse (1)	0,075	0,091	0,029
Círculo (2)	0,162	0,133	0,043
Elipse (2)	0,181	0,085	0,021

Tabela 9 – Valores de desvio padrão das medidas de textura encontradas para cada uma das formas consideradas no nível de maturação 5.

As Figuras 76, 77 e 78 apresentam os gráficos criados para análise das três medidas de textura consideradas, nível de maturação 6.

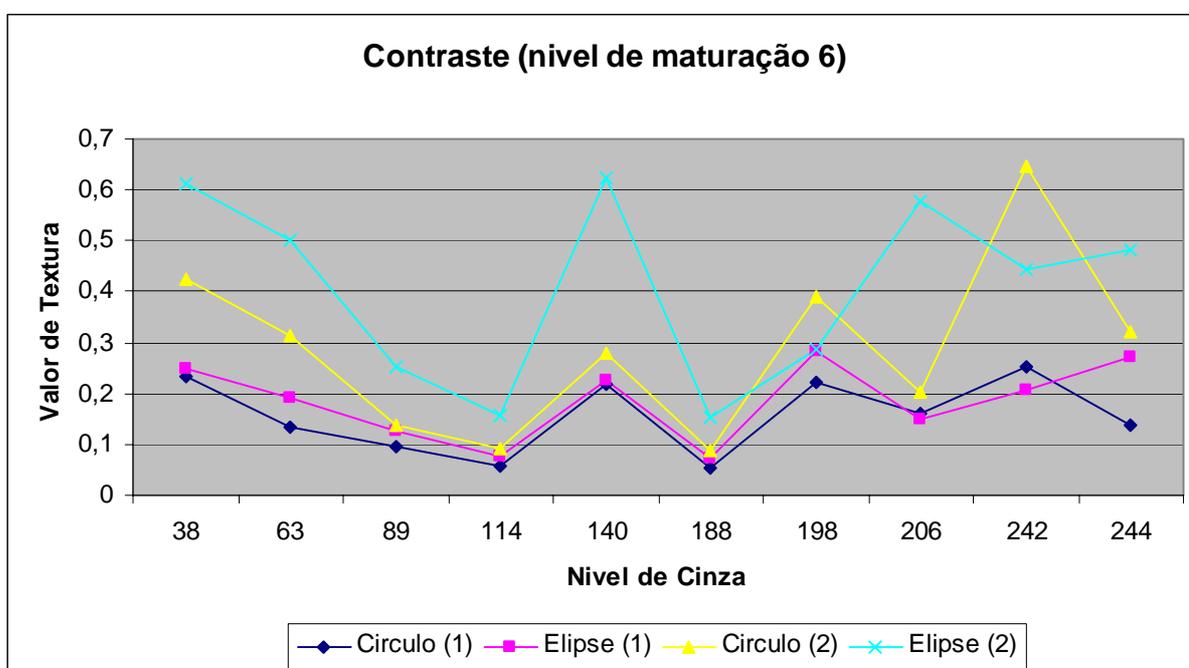


Figura 76 – Comparação dos valores de textura utilizando medida de contraste.

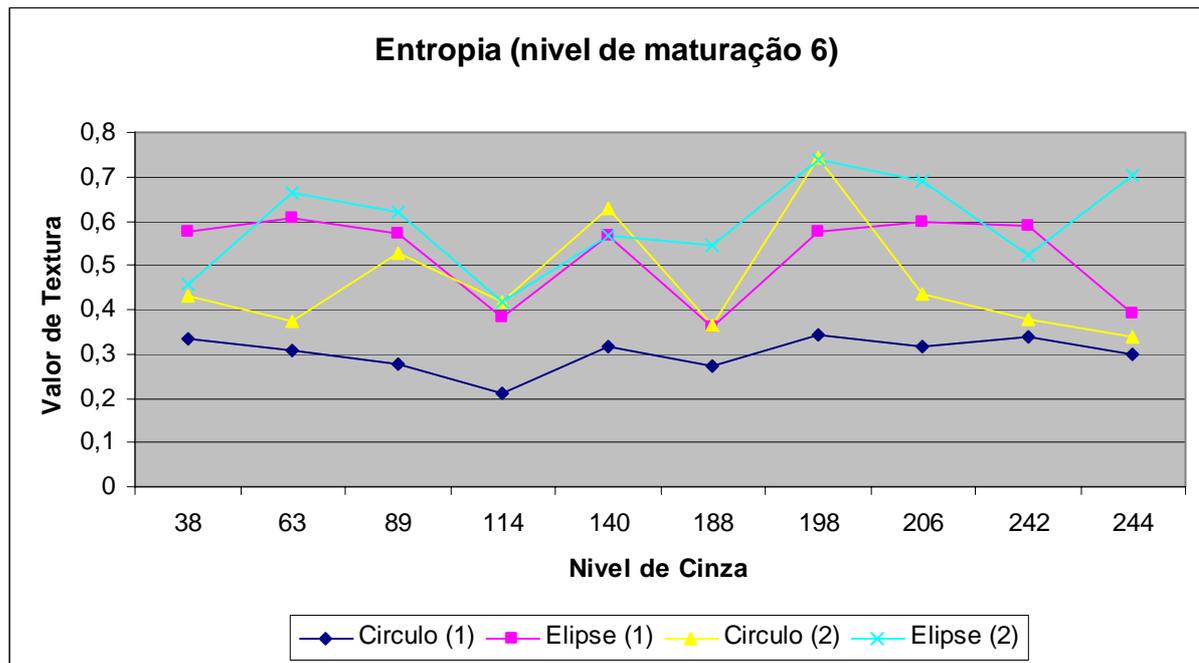


Figura 77 – Comparação dos valores de textura utilizando medida de entropia.

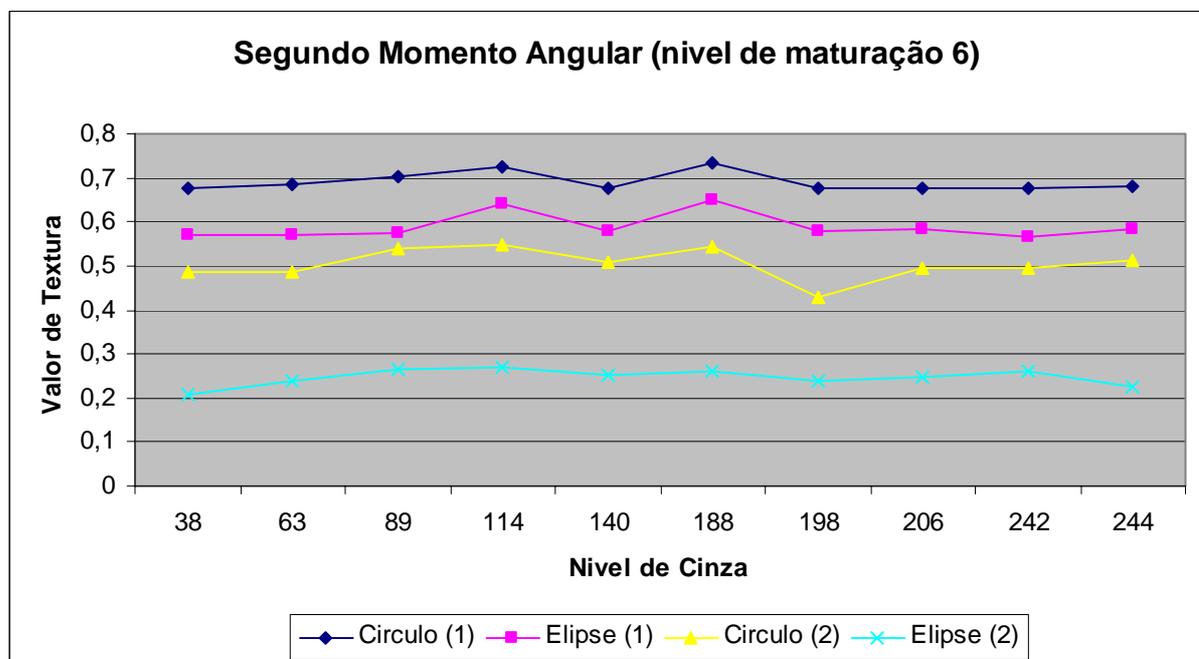


Figura 78 – Comparação dos valores de textura utilizando medida de SMA.

A tabela 10 apresenta os valores de desvio padrão para cada uma das medidas de textura consideradas no nível de maturação 6.

FORMA	DESVIO PADRÃO		
	Contraste	Entropia	SMA
Círculo (1)	0,073	0,039	0,022
Elipse (1)	0,076	0,101	0,0304
Círculo (2)	0,173	0,131	0,036
Elipse (2)	0,182	0,108	0,020

Tabela 10 – Valores de desvio padrão das medidas de textura encontradas para cada uma das formas consideradas no nível de maturação 6.

As Figuras 79, 80 e 81 apresentam os gráficos criados para análise das três medidas de textura consideradas, nível de maturação 7.

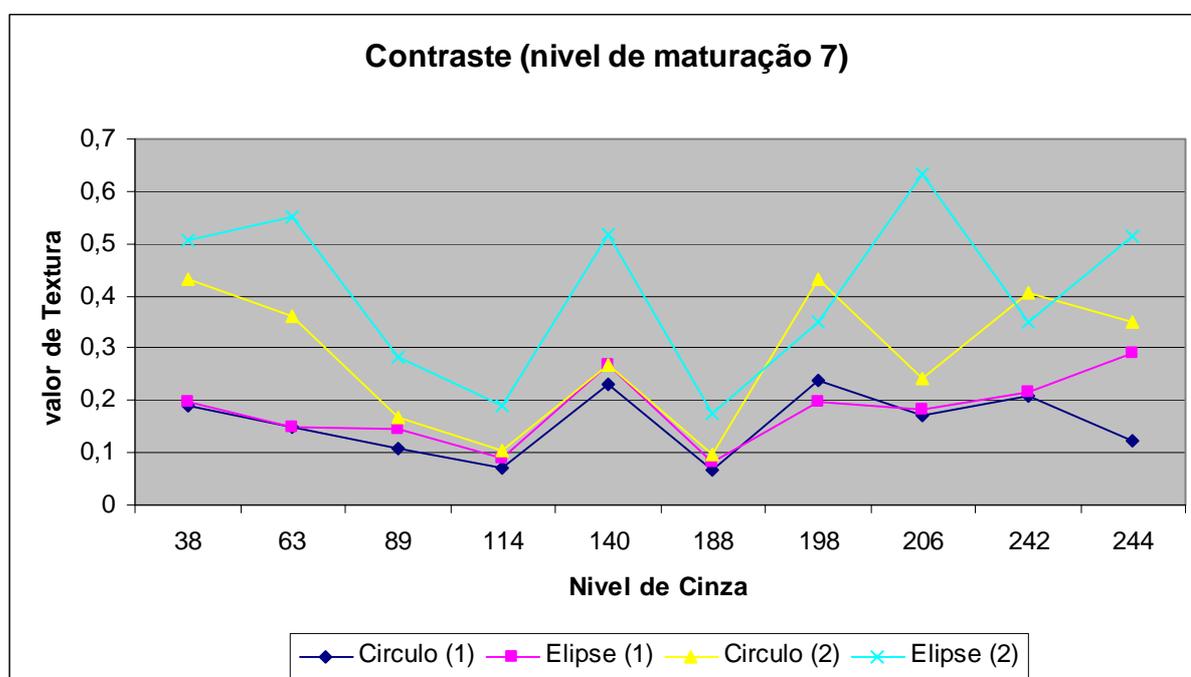


Figura 79 – Comparação dos valores de textura utilizando medida de contraste.

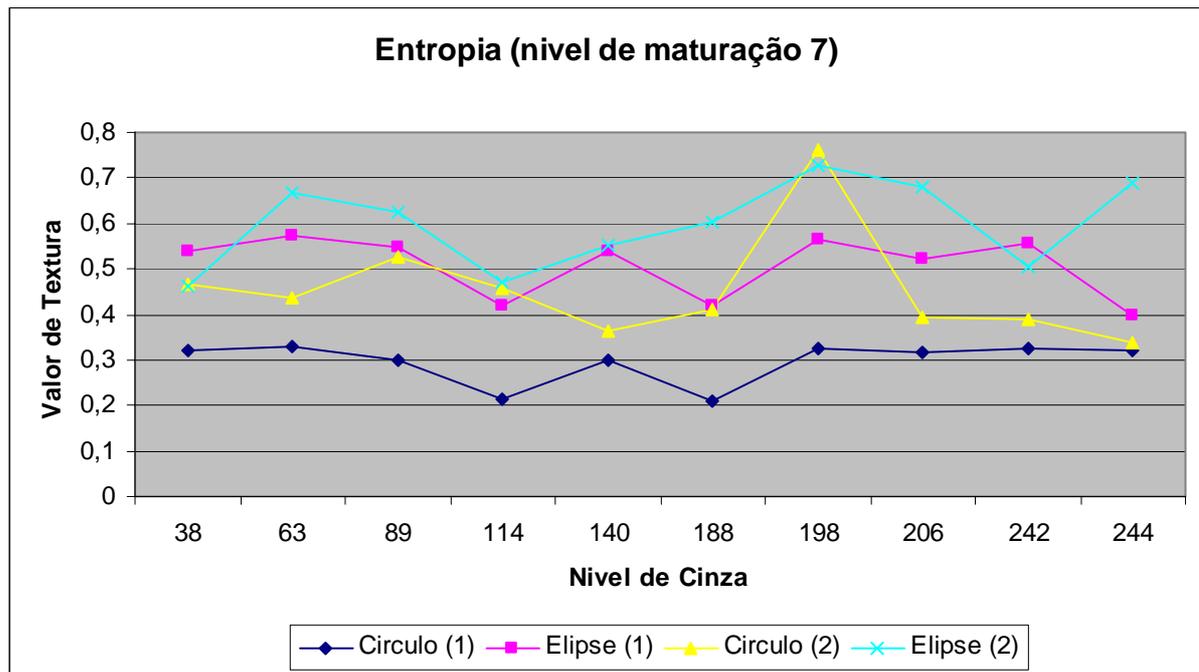


Figura 80 – Comparação dos valores de textura utilizando medida de entropia.

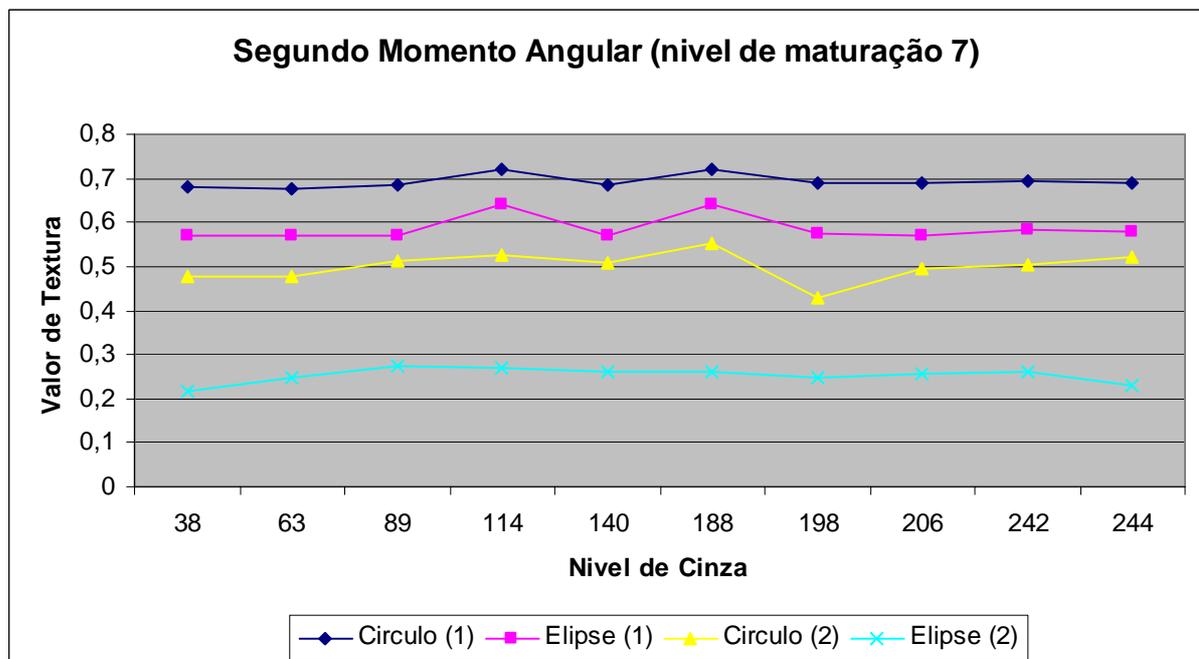


Figura 81 – Comparação dos valores de textura utilizando medida de SMA.

A tabela 11 apresenta os valores de desvio padrão para cada uma das medidas de textura consideradas, em cada um dos níveis de maturação.

FORMA	DESVIO PADRÃO		
	Contraste	Entropia	SMA
Circulo (1)	0,063	0,045	0,015
Elipse (1)	0,068	0,067	0,028
Circulo (2)	0,129	0,121	0,034
Elipse (2)	0,159	0,095	0,018

Tabela 11 – Valores de desvio padrão das medidas de textura encontradas para cada uma das formas consideradas no nível de maturação 7.

Analisando os gráficos, percebe-se que as medidas de SMA e entropia não apresentaram grandes variações, já a medida de contraste se diferenciou bem das demais. Com base nas análises realizadas, observou-se que o contraste foi a medida de textura mais variável e discriminativa em cada uma das formas geométricas consideradas na análise dos gráficos. Sendo assim, para aplicação ao método desenvolvido foi selecionado o contraste.

A Figura 82 ilustra a imagem original e a sua representação na componente S.

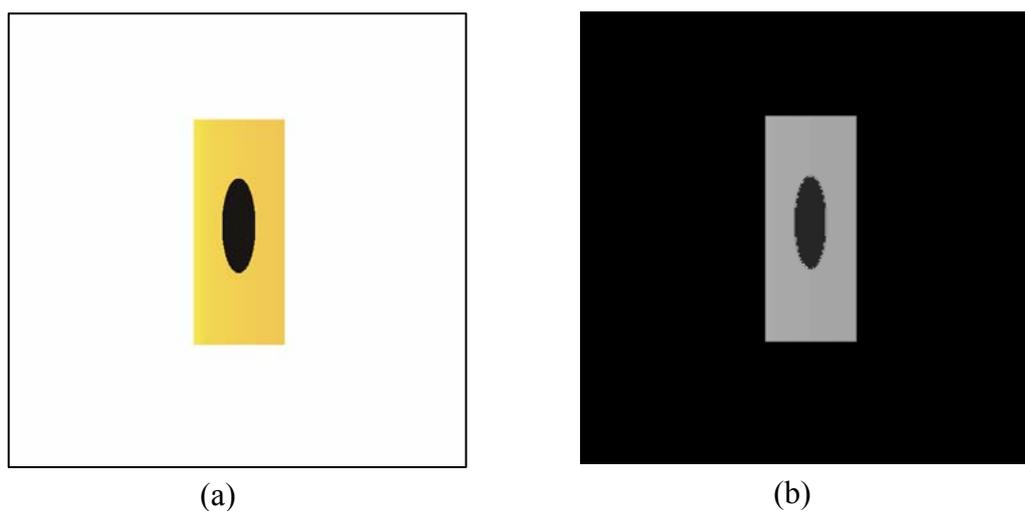


Figura 82 – (a) Imagem original, (b) Representação da imagem original na componente S.

A Figura 83 apresenta a aplicação do filtro de mediana na imagem da Figura 82 (b) e o mapa de textura.

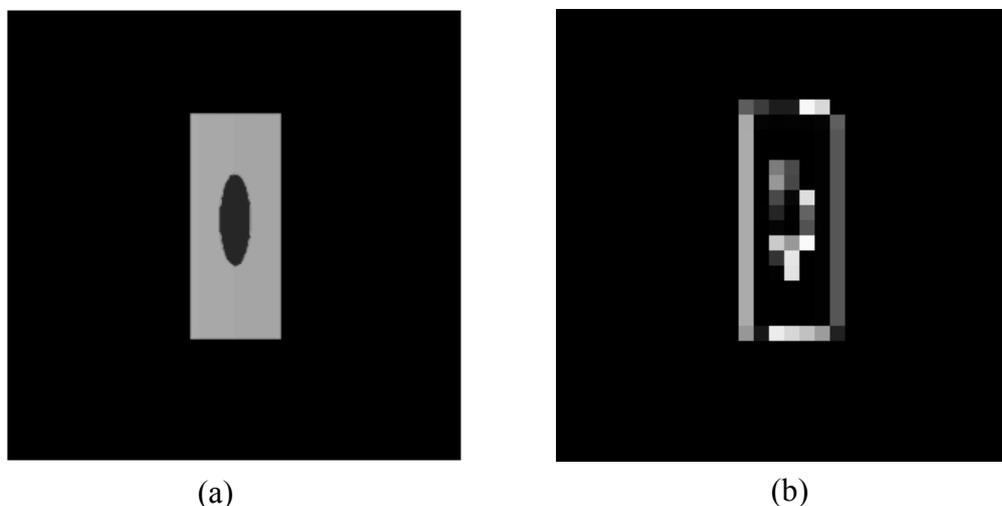


Figura 83 – (a) Resultado da aplicação do filtro de mediana na imagem da Figura 82 (b), (b) Mapa de textura.

5.2.3. Aplicação em produção agrícola pós-colheita

Nesta seção são apresentadas e discutidas as análises feitas para a validação do sistema de identificação de manchas marrons e injúrias através do mapa de textura.

5.2.3.1. Validação do método em nível pós-colheita

A Figura 84 ilustra a aplicação da identificação de manchas marrons ou injúrias baseada em textura em duas das imagens. Nelas é possível observar que o algoritmo é eficiente para o que se propôs, indicar a existências das manchas marrons e injúrias mencionados. É possível observar nos mapas que a ocorrência de injúrias acontece em locais onde os *pixels* são mais claros (próximo ao branco) e a ocorrência de manchas em regiões onde a tonalidade de cinza é mais escura.

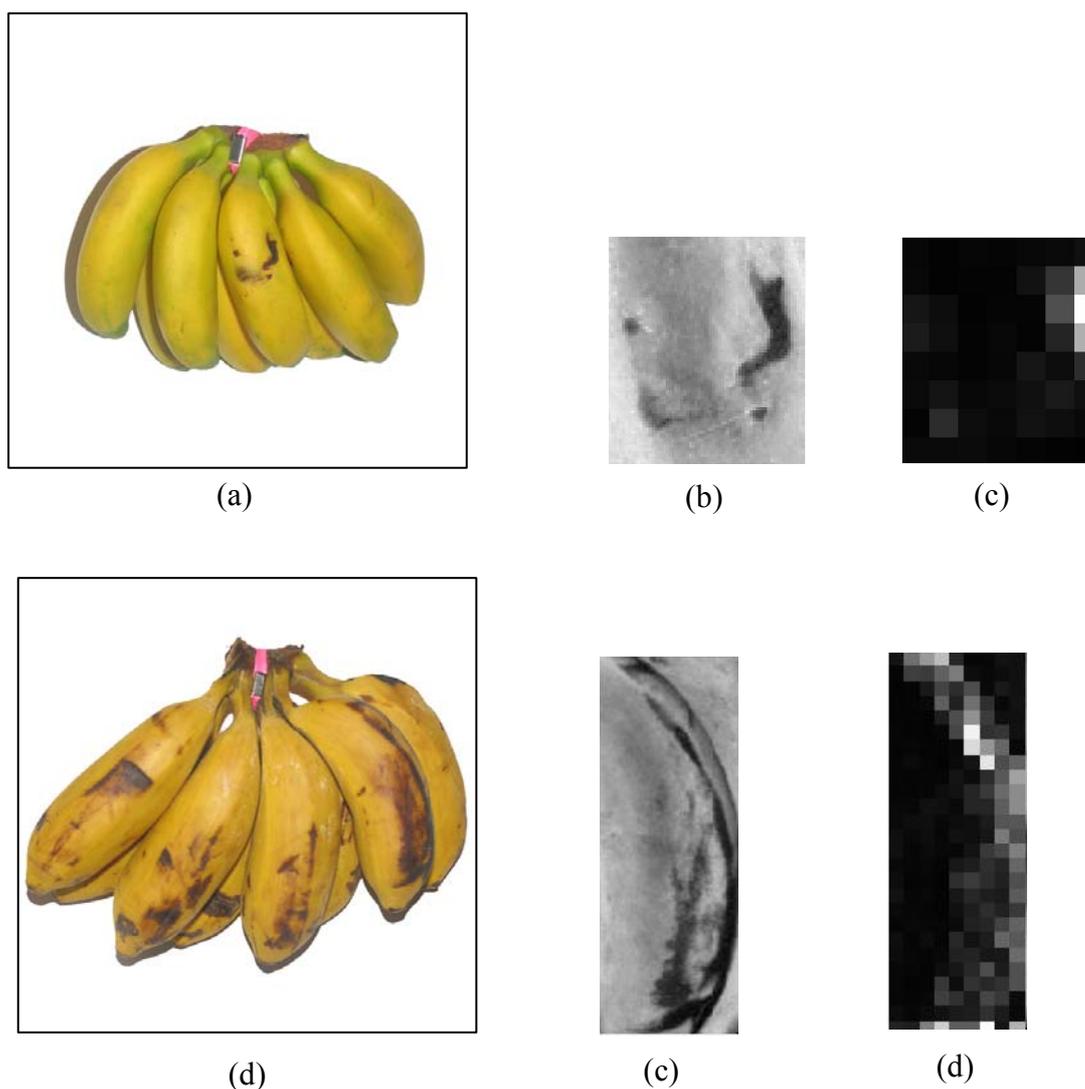


Figura 84 – Imagens de identificação de manchas marrons e injúrias: (a) Imagem original IMG_7817, (b) Representação da imagem original na componente S, (c) mapa de textura da região selecionada, (d) Imagem original IMG_7816, (e) Representação da imagem original na componente S e (f) mapa de textura da região selecionada.

5.3. Método baseado em cor

5.3.1. Pré-processamento para o método de cor e área

No pré-processamento do método de cor e área, a segmentação da imagem é feita pela limiarização. A Figura 85 e 86 ilustram um exemplo de segmentação do objeto de interesse, necessária para a contagem de *pixel* na classificação em estágio de maturação e para a obtenção da porcentagem de manchas marrons ou injúrias.

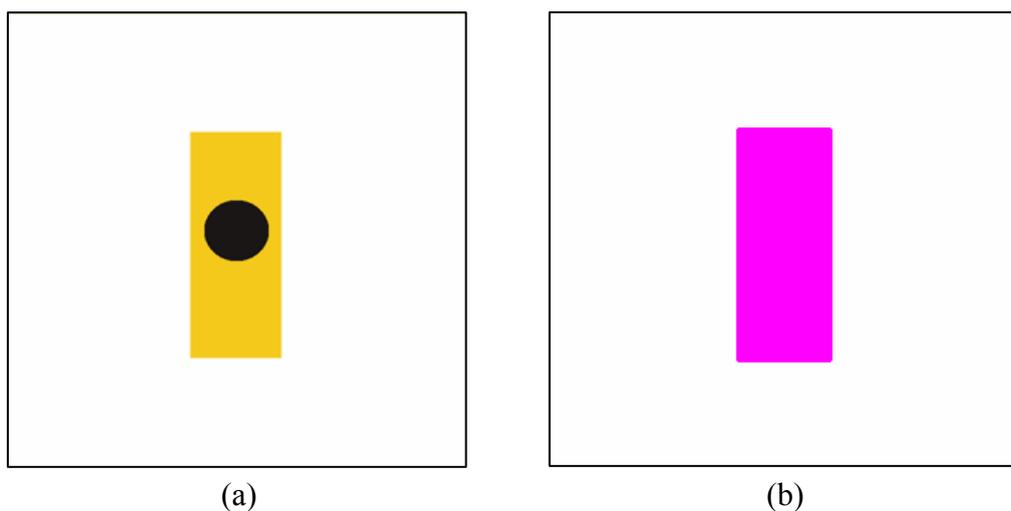


Figura 85 – Exemplo de segmentação no pré-processamento em uma imagem padrão simples: (a) imagem original e (b) objeto segmentado.

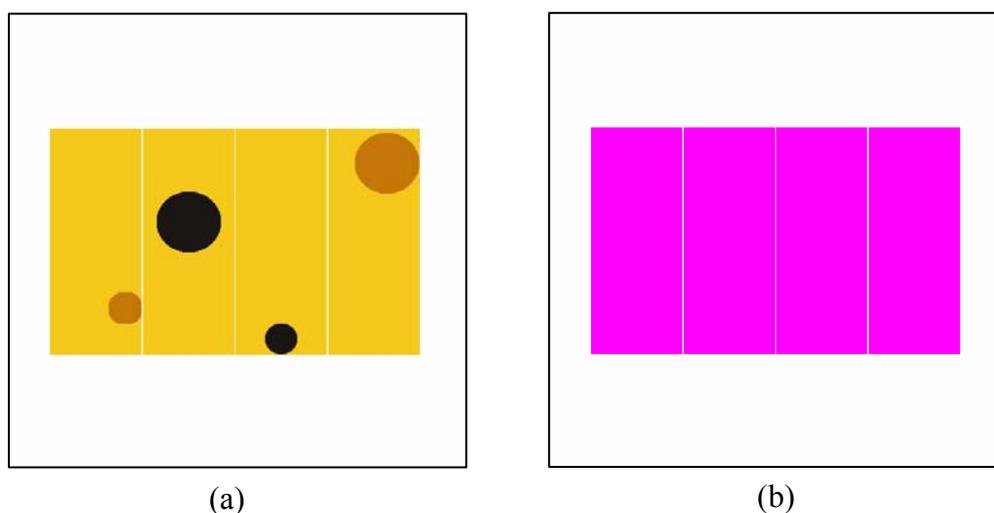


Figura 86 – Exemplo de segmentação no pré-processamento em uma imagem padrão composta: (a) imagem original e (b) objeto segmentado.

5.3.2. Aplicação em produção agrícola pós-colheita

Nesta seção são apresentadas e discutidas as análises feitas para a validação do sistema de identificação de manchas marrons, injúrias e classificação em estágio de maturação através de um estudo de caso com cachos de banana (*Musa sapientum*) pós-colheita.

5.3.2.1. Validação do método em nível pós-colheita

A Figura 87 ilustra a aplicação da classificação baseada em cor em duas imagens de bananas. Nelas é possível observar que o algoritmo é eficiente no que se propôs, classificar o fruto em seu nível de maturação.

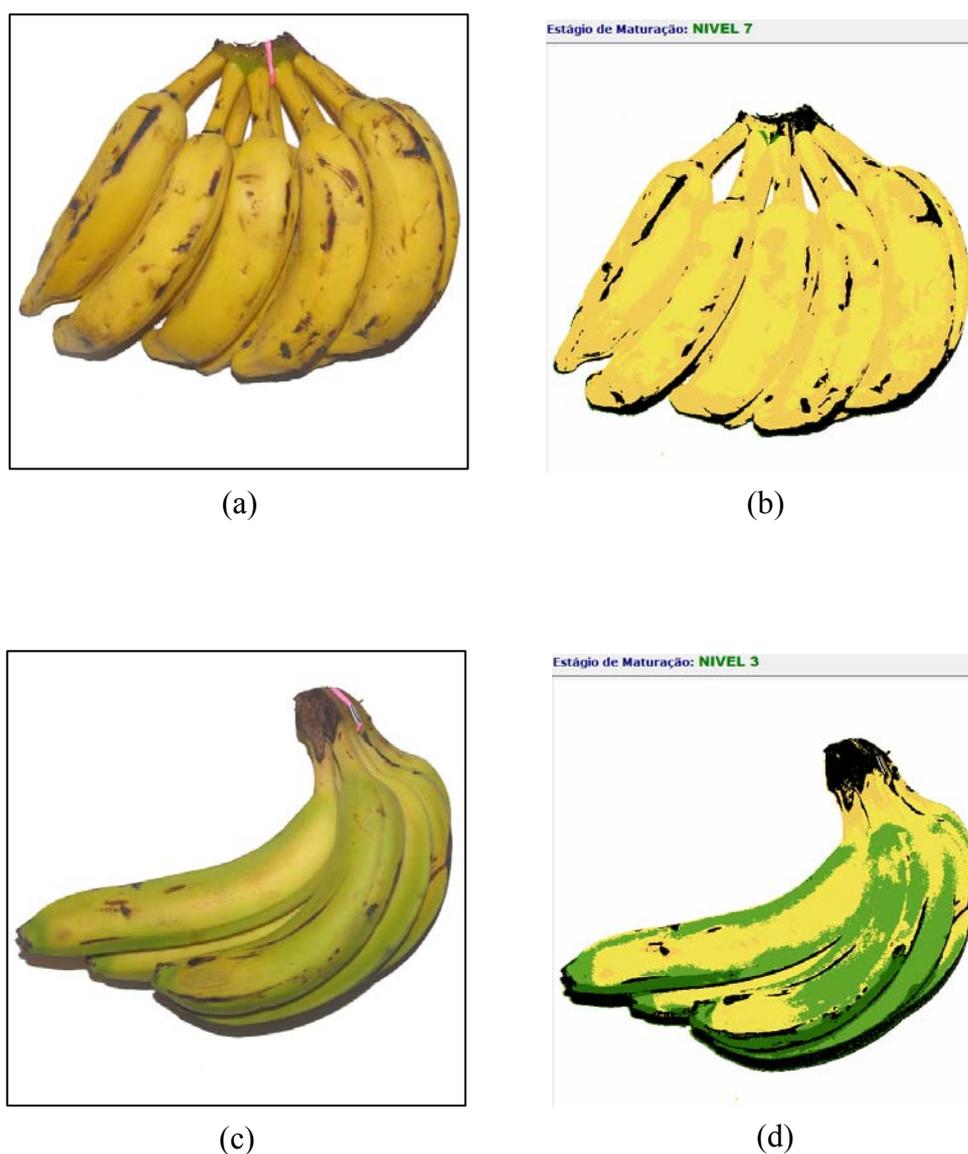


Figura 87 – Exemplos de imagem classificadas pelo sistema: (a) Imagem original, (b) Imagem classificada no nível de maturação 7, (c) Imagem original e (d) Imagem classificada no nível de maturação 3.

Na avaliação do método, a visão natural foi feita com base na colaboração de um grupo de observadores formados por homens, mulheres e crianças, na faixa etária entre 7 e

60 anos. Para cada observador foram entre as fichas com as imagens do fruto e a escala de maturação de Von Loesecke. Utilizando a escala os observadores comparavam a imagem do fruto com as imagens dos níveis de maturação e colocavam na ficha no campo indicado qual o nível que a banana fazia parte.

A Figura 88 apresenta a ficha utilizada para análise da maturação do fruto de acordo com os observadores humanos e a visão computacional.

Área reservada para a imagem	<p>Nome: nome do arquivo Tamanho: tamanho em <i>pixels</i> Resolução: resolução <i>pixels/ cm</i></p>
<p>Caracterização de espécies</p> <p>Nome científico do fruto</p>	
Avaliação do estágio de maturação	Nível
Visão Natural	Nota atribuída pelo observador
Visão Computacional	Nota atribuída computacionalmente

Figura 88 – Ficha de análise do índice de maturação da banana realizada por um observador e pela visão computacional.

Os dados obtidos com as fichas de cada observador foram gerados uma tabela para cada imagem. A tabela 12 apresenta a classificação da banana IMG_7808 obtida pela visão natural e pela visão computacional.

	<p>Nome: IMG_7808 Tamanho: 600×600 pixels Resolução: 71 pixels/cm</p> <p>Caracterização da espécie Grupo: <i>Musa paradisiaca L.</i></p>									
	Obs #1	Obs #2	Obs #3	Obs #4	Obs #5	Obs #6	Obs #7	Obs #8	Obs #9	Obs #10
Visão Natural	7	7	7	6	7	7	7	7	7	6
Visão Computacional	7	7	7	7	7	7	7	7	7	7
Erro	0	0	0	1	0	0	0	0	0	1

Tabela 12 – Comparação da classificação da banana IMG_7808 em nível de maturação obtida pela visão natural e pelo sistema.

A tabela 13 apresenta a classificação da banana IMG_7809 obtida pela visão natural e pela visão computacional.

	<p>Nome: IMG_7809 Tamanho: 600×600 pixels Resolução: 71 pixels/cm</p> <p>Caracterização da espécie Grupo: <i>Musa Cavendish</i></p>									
	Obs #1	Obs #2	Obs #3	Obs #4	Obs #5	Obs #6	Obs #7	Obs #8	Obs #9	Obs #10
Visão Natural	4	4	4	3	4	4	3	3	3	4
Visão Computacional	4	4	4	4	4	4	4	4	4	4
Erro	0	0	0	1	0	0	1	1	1	0

Tabela 13 - Comparação da classificação da banana IMG_7809 em nível de maturação obtida pela visão natural e pelo sistema.

A tabela 14 apresenta a classificação da banana IMG_7810 obtida pela visão natural e pela visão computacional.

	<p>Nome: IMG_7810 Tamanho: 600×600 pixels Resolução: 71 pixels/cm</p> <p>Caracterização da espécie Grupo: <i>Musa paradisiaca L.</i></p>									
		Obs #1	Obs #2	Obs #3	Obs #4	Obs #5	Obs #6	Obs #7	Obs #8	Obs #9
Visão Natural	6	6	6	6	7	7	7	6	6	7
Visão Computacional	7	7	7	7	7	7	7	7	7	7
Erro	1	1	1	1	0	0	0	1	1	0

Tabela 14 – Comparação da classificação da banana IMG_7810 em nível de maturação obtida pela visão natural e pelo sistema.

A tabela 15 apresenta a classificação da banana IMG_7811 obtida pela visão natural e pela visão computacional.

	<p>Nome: IMG_7811 Tamanho: 600×600 pixels Resolução: 71 pixels/cm</p> <p>Caracterização da espécie Grupo: <i>Musa paradisiaca L.</i></p>									
		Obs #1	Obs #2	Obs #3	Obs #4	Obs #5	Obs #6	Obs #7	Obs #8	Obs #9
Visão Natural	6	6	6	6	7	7	7	6	7	7
Visão Computacional	7	7	7	7	7	7	7	7	7	7
Erro	1	1	1	1	0	0	0	1	0	0

Tabela 15 – Comparação da classificação da banana IMG_7811 em nível de maturação obtida pela visão natural e pelo sistema.

A tabela 16 apresenta a classificação da banana IMG_7812 obtida pela visão natural e pela visão computacional.

	<p>Nome: IMG_7812 Tamanho: 600×600 pixels Resolução: 71 pixels/cm</p> <p>Caracterização da espécie Grupo: <i>Musa paradisiaca</i> L.</p>									
	Obs #1	Obs #2	Obs #3	Obs #4	Obs #5	Obs #6	Obs #7	Obs #8	Obs #9	Obs #10
Visão Natural	7	7	7	7	6	7	7	7	7	7
Visão Computacional	7	7	7	7	7	7	7	7	7	7
Erro	0	0	0	0	1	0	0	0	0	0

Tabela 16 – Comparação da classificação da banana IMG_7812 em nível de maturação obtida pela visão natural e pelo sistema.

A tabela 17 apresenta a classificação da banana IMG_7813 obtida pela visão natural e pela visão computacional.

	<p>Nome: IMG_7813 Tamanho: 600×600 pixels Resolução: 71 pixels/cm</p> <p>Caracterização da espécie Grupo: <i>Musa paradisiaca</i> L.</p>									
	Obs #1	Obs #2	Obs #3	Obs #4	Obs #5	Obs #6	Obs #7	Obs #8	Obs #9	Obs #10
Visão Natural	7	7	6	7	6	7	7	7	5	6
Visão Computacional	7	7	7	7	7	7	7	7	7	7
Erro	0	0	1	0	1	0	0	0	2	1

Tabela 17 – Comparação da classificação da banana IMG_7813 em nível de maturação obtida pela visão natural e pelo sistema.

A tabela 18 apresenta a classificação da banana IMG_7814 obtida pela visão natural e pela visão computacional.

	<p>Nome: IMG_7814 Tamanho: 600×600 pixels Resolução: 71 pixels/cm</p> <p>Caracterização da espécie Grupo: <i>Musa Cavendish</i></p>									
		Obs #1	Obs #2	Obs #3	Obs #4	Obs #5	Obs #6	Obs #7	Obs #8	Obs #9
Visão Natural	3	4	4	4	4	4	4	4	4	3
Visão Computacional	3	3	3	3	3	3	3	3	3	3
Erro	0	1	1	1	1	1	1	1	1	0

Tabela 18 – Comparação da classificação da banana IMG_7814 em nível de maturação obtida pela visão natural e pelo sistema.

A tabela 19 apresenta a classificação da banana IMG_7815 obtida pela visão natural e pela visão computacional.

	<p>Nome: IMG_7815 Tamanho: 600×600 pixels Resolução: 71 pixels/cm</p> <p>Caracterização da espécie Grupo: <i>Musa Cavendish</i></p>									
		Obs #1	Obs #2	Obs #3	Obs #4	Obs #5	Obs #6	Obs #7	Obs #8	Obs #9
Visão Natural	6	5	6	6	6	7	5	6	6	7
Visão Computacional	7	7	7	7	7	7	7	7	7	7
Erro	1	2	1	1	1	0	2	1	1	0

Tabela 19 – Comparação da classificação da IMG_7815 em nível de maturação obtida pela visão natural e pelo sistema.

A tabela 20 apresenta classificação da banana IMG_7816 obtida pela visão natural e pela visão computacional.

	<p>Nome: IMG_7816 Tamanho: 600×600 pixels Resolução: 71 pixels/cm</p> <p>Caracterização da espécie Grupo: <i>Musa paradisiaca L.</i></p>									
		Obs #1	Obs #2	Obs #3	Obs #4	Obs #5	Obs #6	Obs #7	Obs #8	Obs #9
Visão Natural	6	7	6	6	7	7	7	7	7	6
Visão Computacional	7	7	7	7	7	7	7	7	7	7
Erro	1	0	1	1	0	0	0	0	0	1

Tabela 20 – Comparação da classificação da banana IMG_7816 em nível de maturação obtida pela visão natural e pelo sistema.

A tabela 21 apresenta classificação da banana IMG_7817 obtida pela visão natural e pela visão computacional.

	<p>Nome: IMG_7817 Tamanho: 600×600 pixels Resolução: 71 pixels/cm</p> <p>Caracterização da espécie Grupo: <i>Musa paradisiaca L.</i></p>									
		Obs #1	Obs #2	Obs #3	Obs #4	Obs #5	Obs #6	Obs #7	Obs #8	Obs #9
Visão Natural	6	5	5	5	6	5	4	5	4	5
Visão Computacional	5	5	5	5	5	5	5	5	5	5
Erro	1	0	0	0	1	0	1	0	1	0

Tabela 21 – Comparação da classificação da banana IMG_7817 em nível de maturação obtida pela visão natural e pelo sistema.

A tabela 22 apresenta classificação da banana IMG_7818 obtida pela visão natural e pela visão computacional.

		<p>Nome: IMG_7818 Tamanho: 600×600 pixels Resolução: 71 pixels/cm</p> <p>Caracterização da espécie Grupo: <i>Musa cavendishii</i></p>									
		Obs #1	Obs #2	Obs #3	Obs #4	Obs #5	Obs #6	Obs #7	Obs #8	Obs #9	Obs #10
Visão Natural		3	3	3	3	1	3	3	2	3	3
Visão Computacional		2	2	2	2	2	2	2	2	2	2
Erro		1	1	1	1	1	1	1	0	1	1

Tabela 22 – Comparação da classificação da banana IMG_7818 em nível de maturação obtida pela visão natural e pelo sistema.

A tabela 23 apresenta classificação da banana IMG_7819 obtida pela visão natural e pela visão computacional.

		<p>Nome: IMG_7819 Tamanho: 600×600 pixels Resolução: 71 pixels/cm</p> <p>Caracterização da espécie Grupo: <i>Musa cavendishii</i></p>									
		Obs #1	Obs #2	Obs #3	Obs #4	Obs #5	Obs #6	Obs #7	Obs #8	Obs #9	Obs #10
Visão Natural		1	2	3	2	2	2	2	1	3	2
Visão Computacional		2	2	2	2	2	2	2	2	2	2
Erro		1	0	1	0	0	0	0	1	1	0

Tabela 23 – Comparação da classificação da banana IMG_7819 em nível de maturação obtida pela visão natural e pelo sistema.

A tabela 24 apresenta classificação da banana IMG_7820 obtida pela visão natural e pela visão computacional.

	<p>Nome: IMG_7820 Tamanho: 600×600 pixels Resolução: 71 pixels/cm</p> <p>Caracterização da espécie Grupo: <i>Musa cavendishii</i></p>									
	Obs #1	Obs #2	Obs #3	Obs #4	Obs #5	Obs #6	Obs #7	Obs #8	Obs #9	Obs #10
Visão Natural	1	3	3	2	3	2	3	3	3	3
Visão Computacional	2	2	2	2	2	2	2	2	2	2
Erro	1	1	1	0	1	0	1	1	1	1

Tabela 24 – Comparação da classificação da banana IMG_7820 em nível de maturação obtida pela visão natural e pelo sistema.

A tabela 25 apresenta classificação da banana IMG_7821 obtida pela visão natural e pela visão computacional.

	<p>Nome: IMG_7821 Tamanho: 600×600 pixels Resolução: 71 pixels/cm</p> <p>Caracterização da espécie Grupo: <i>Musa cavendishii</i></p>									
	Obs #1	Obs #2	Obs #3	Obs #4	Obs #5	Obs #6	Obs #7	Obs #8	Obs #9	Obs #10
Visão Natural	3	3	3	1	2	3	2	2	2	1
Visão Computacional	2	2	2	2	2	2	2	2	2	2
Erro	1	1	1	1	0	1	0	0	0	1

Tabela 25 – Comparação da classificação da banana IMG_7821 em nível de maturação obtida pela visão natural e pelo sistema.

A tabela 26 apresenta classificação da banana IMG_7822 obtida pela visão natural e pela visão computacional.

		<p>Nome: IMG_7822 Tamanho: 600×600 pixels Resolução: 71 pixels/cm</p> <p>Caracterização da espécie Grupo: <i>Musa cavendishii</i></p>									
		Obs #1	Obs #2	Obs #3	Obs #4	Obs #5	Obs #6	Obs #7	Obs #8	Obs #9	Obs #10
Visão Natural		2	3	3	2	3	3	3	2	3	2
Visão Computacional		2	2	2	2	2	2	2	2	2	2
Erro		0	1	1	0	1	1	1	0	1	0

Tabela 26 – Comparação da classificação da banana IMG_7822 em nível de maturação obtida pela visão natural e pelo sistema.

A tabela 27 apresenta classificação da banana IMG_7823 obtida pela visão natural e pela visão computacional.

		<p>Nome: IMG_7823 Tamanho: 600×600 pixels Resolução: 71 pixels/cm</p> <p>Caracterização da espécie Grupo: <i>Musa cavendishii</i></p>									
		Obs #1	Obs #2	Obs #3	Obs #4	Obs #5	Obs #6	Obs #7	Obs #8	Obs #9	Obs #10
Visão Natural		2	2	2	2	2	2	2	1	2	1
Visão Computacional		2	2	2	2	2	2	2	2	2	2
Erro		0	0	0	0	0	0	0	1	0	1

Tabela 27 – Comparação da classificação da banana IMG_7823 em nível de maturação obtida pela visão natural e pelo sistema.

A tabela 28 apresenta classificação da banana IMG_7824 obtida pela visão natural e pela visão computacional.

	<p>Nome: IMG_7824 Tamanho: 600×600 pixels Resolução: 71 pixels/cm</p> <p>Caracterização da espécie Grupo: <i>Musa Cavendishii</i></p>									
		Obs #1	Obs #2	Obs #3	Obs #4	Obs #5	Obs #6	Obs #7	Obs #8	Obs #9
Visão Natural	3	2	2	1	2	2	3	2	2	3
Visão Computacional	2	2	2	2	2	2	2	2	2	2
Erro	1	0	0	1	0	0	1	0	0	1

Tabela 28 - Comparação da classificação da banana IMG_7824 em nível de maturação obtida pela visão natural e pelo sistema.

Para cada tabela foi calculado o percentual de acerto e baseando-se na taxa de acerto trabalhada pelos observadores é possível calcular a sua média tomando por base a relação:

$$Taxa \text{ média de acerto} = \frac{\sum_{i=1}^{Qt} (taxa \text{ de acerto})_i}{Qt_{imagens_analizadas}}$$

O resultado obtido, considerando o conjunto de 10 observadores foi de 50%.

A classificação obtida pela visão natural foi comparada com a análise feita pela visão computacional. A tabela 29 ilustra a moda do índice de maturação obtido com visão natural e o índice de maturação obtido com visão computacional, enquanto que a Figura 89 apresenta a correlação entre o índice de maturação obtido com visão computacional e a moda do índice obtido com visão natural.

IMAGEM		MODA DO ÍNDICE DE MATURAÇÃO OBTIDO COM VISÃO NATURAL	ÍNDICE DE MATURAÇÃO OBTIDO COM VISÃO COMPUTACIONAL
1	IMG_7808	7	7
2	IMG_7809	6	4
3	IMG_7810	6	7
4	IMG_7811	6	7
		7	
5	IMG_7812	7	7
6	IMG_7813	7	7
7	IMG_7814	4	3
8	IMG_7815	6	7
9	IMG_7816	7	7
10	IMG_7817	5	5
11	IMG_7818	3	2
12	IMG_7819	2	2
13	IMG_7820	3	2
14	IMG_7821	2	2
		3	
15	IMG_7822	3	2
16	IMG_7823	2	2
17	IMG_7824	2	2

Tabela 29 – Índices de maturação de amostras de bananas (*Musa sapientum*).

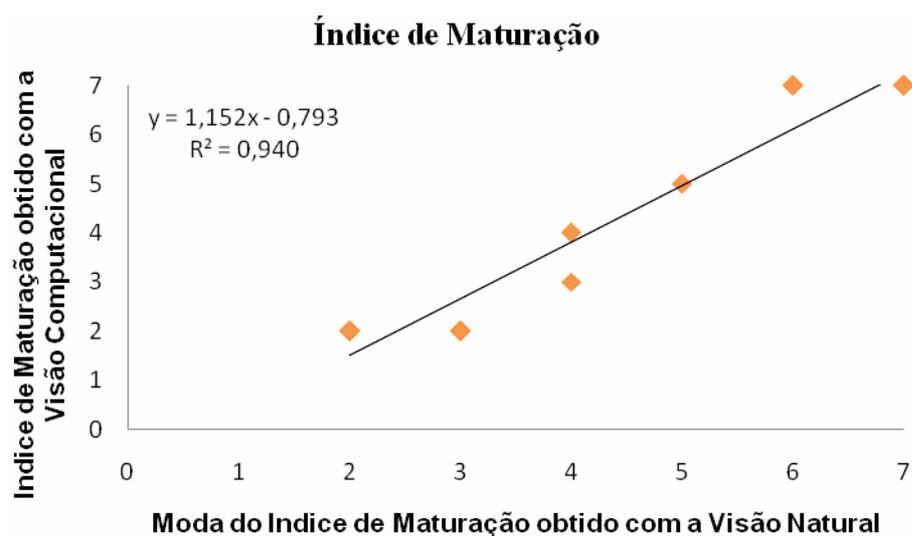


Figura 89 – Correlação entre a moda do índice de maturação obtido com a visão natural e o índice de maturação obtido com a visão computacional.

A Figura 90 ilustra a aplicação da obtenção do percentual de manchas marrons e injúrias em imagens de bananas. Nelas é possível observar que o algoritmo é eficiente no que se propôs, obter o percentual de áreas marrons e injúrias.

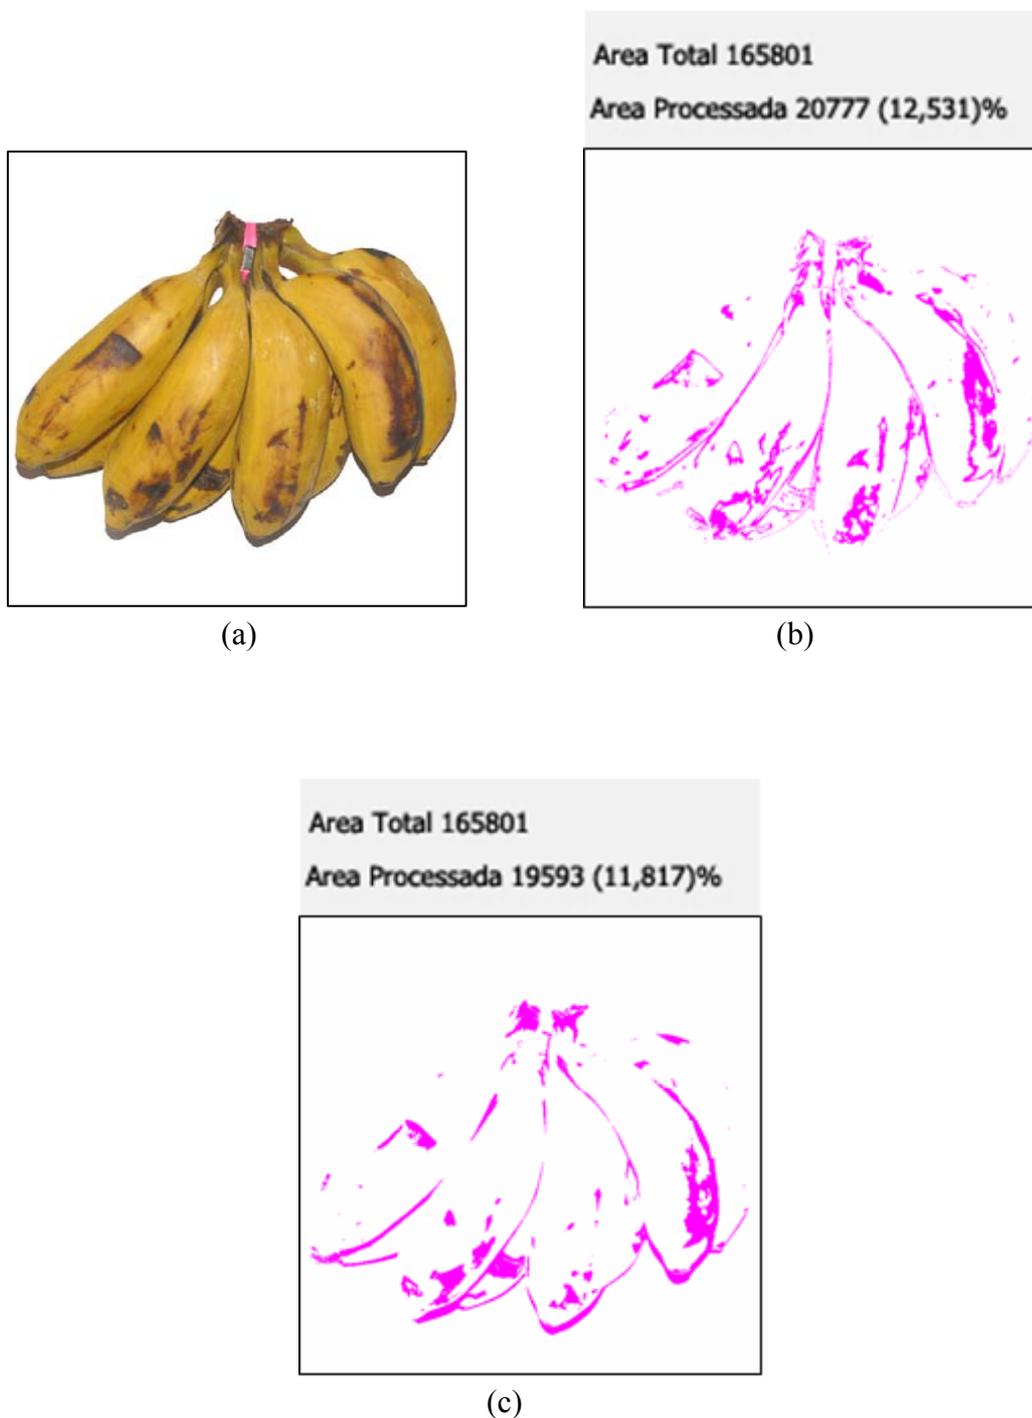


Figura 90 – Exemplos de imagens limiarizadas para obtenção do percentual de manchas marrons e injúrias em bananas: (a) Imagem original, (b) Imagem com aproximadamente 12,53% de manchas marrons, (c) Imagem com aproximadamente 11,82 % de injúrias.

Para o cálculo do percentual de manchas marrons e injúrias pela visão natural foi feita uma análise *pixel a pixel* da imagem com o programa *Adobe Photoshop*.

A tabela 30 apresenta a comparação dos percentuais de manchas marrons em imagem de banana individual obtidos pela visão natural e pela visão computacional, enquanto a Figura 91 apresenta a análise da tabela por meio da regressão linear, entre a medida de visão natural e cada uma das medidas de visão computacional.

IMAGEM		PERCENTUAL DE MANCHAS MARRONS	
		Visão Natural	Visão Computacional
1	IMG_7808	6,081	7,006
2	IMG_7809	0,842	5,353
3	IMG_7810	0,888	4,051
4	IMG_7811	1,309	4,783
5	IMG_7812	4,669	5,953

Tabela 30 – Percentuais de manchas marrons em banana individual obtidos pela visão natural e pelo sistema utilizando limiarização.

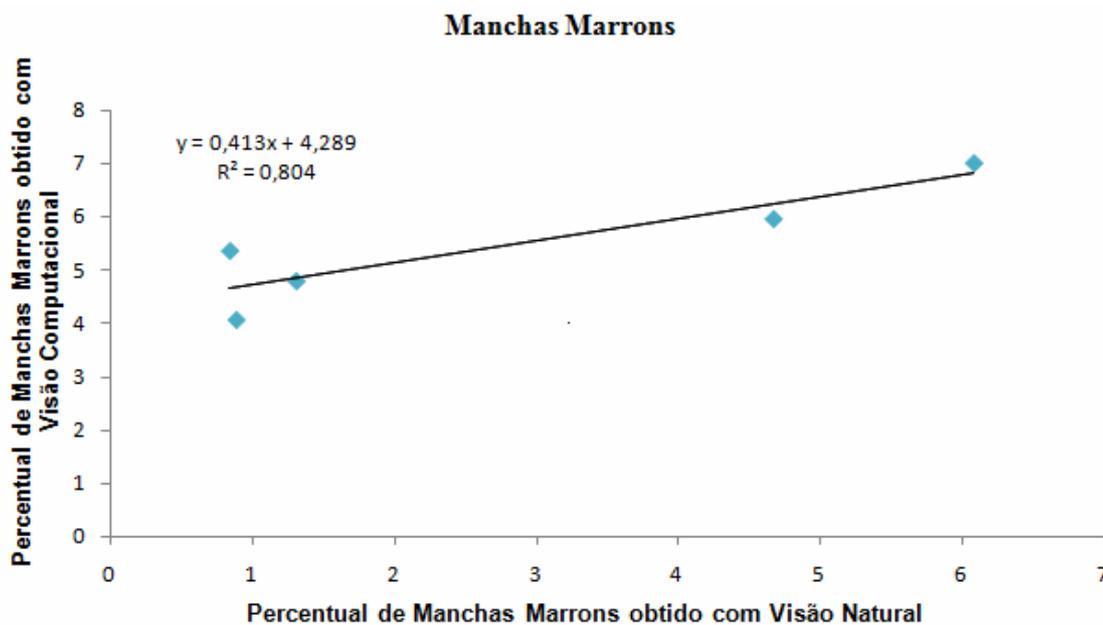


Figura 91 – Regressão linear para a identificação de manchas marrons de banana individual referente aos dados apresentados na tabela 30.

A tabela 31 apresenta a comparação dos percentuais de manchas marrons em imagem de penca de bananas obtidos pela visão natural e pela visão computacional, enquanto a Figura 92 apresenta a análise da tabela por meio da regressão linear, entre a medida de visão natural e cada uma das medidas de visão computacional.

IMAGEM		PERCENTUAL DE MANCHAS MARRONS	
		Visão Natural	Visão Computacional
1	IMG_7813	3,112	5,272
2	IMG_7814	1,677	3,724
3	IMG_7815	0,928	2,560
4	IMG_7816	8,937	12,531
5	IMG_7817	0,275	0,712
6	IMG_7818	0,185	1,278
7	IMG_7819	0,000	0,000
8	IMG_7820	0,000	0,000
9	IMG_7821	0,000	0,000
10	IMG_7822	0,000	0,000
11	IMG_7823	0,000	0,000
12	IMG_7824	0,000	0,000

Tabela 31 – Percentuais de manchas marrons em penca de bananas obtidos pela visão natural e pelo sistema utilizando limiarização.

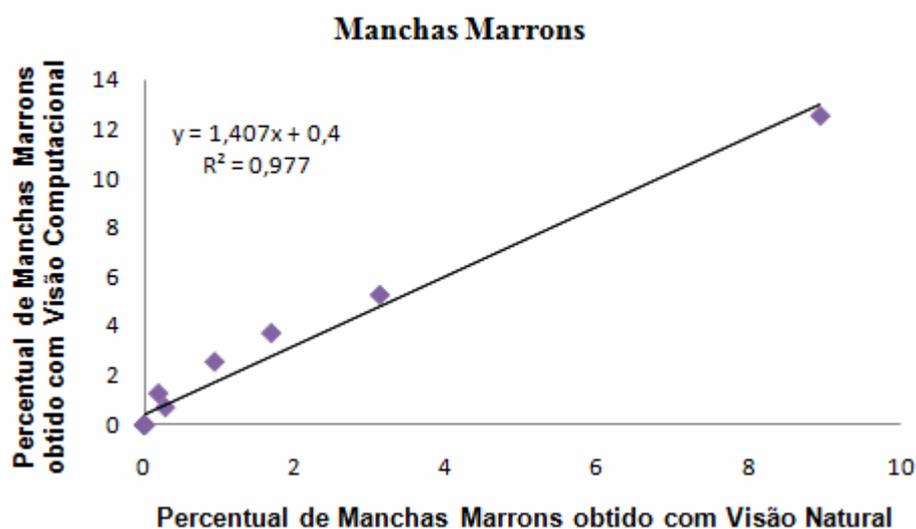


Figura 92 – Regressão linear para a identificação de manchas marrons de penca de bananas referente aos dados apresentados na tabela 31.

A tabela 32 apresenta a comparação dos percentuais de injúrias em imagem de banana individual obtidos pela visão natural e pela visão computacional, enquanto a Figura 93 apresenta a análise da tabela por meio da regressão linear, entre a medida de visão natural e cada uma das medidas de visão computacional.

IMAGEM		PERCENTUAL DE INJÚRIAS	
		Visão Natural	Visão Computacional
1	IMG_7808	5,860	8,175
2	IMG_7809	0,000	0,000
3	IMG_7810	0,000	0,000
4	IMG_7811	0,000	0,000
5	IMG_7812	6,066	10,694

Tabela 32 – Percentuais de injúrias em banana individual obtidos pela visão natural e pelo sistema utilizando limiarização.

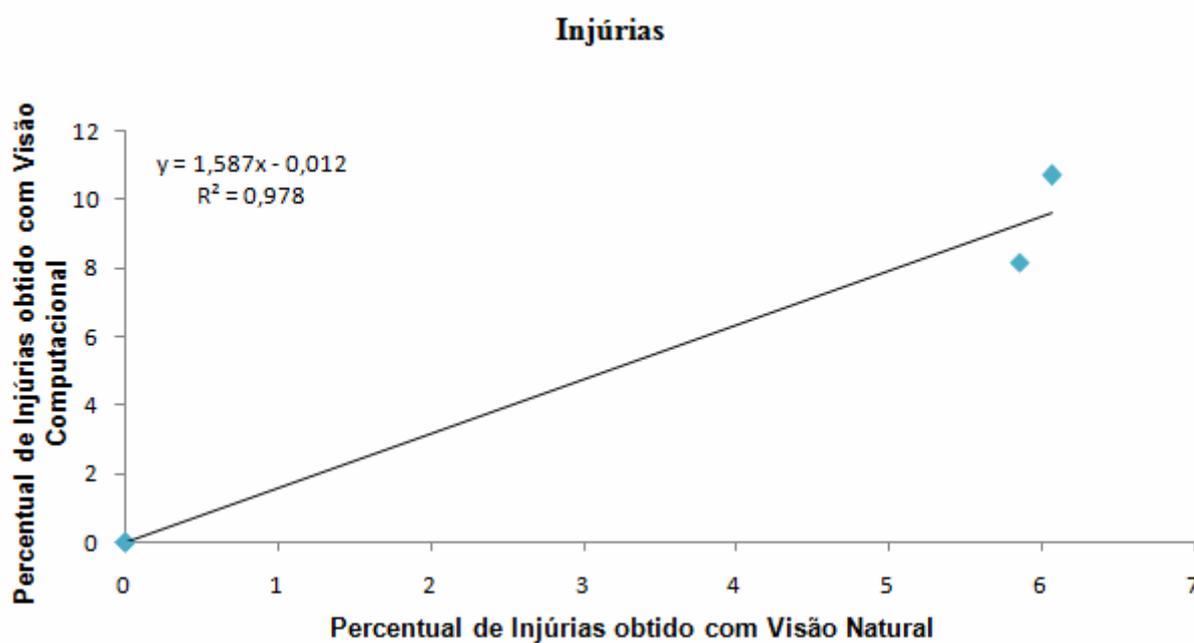


Figura 93 – Regressão linear para a identificação de injúrias de banana individual referente aos dados apresentados na tabela 32.

A tabela 33 apresenta a comparação dos percentuais de injúrias em imagem de penca de bananas obtidos pela visão natural e pela visão computacional, enquanto a Figura 94 apresenta a análise da tabela por meio da regressão linear, entre a medida de visão natural e cada uma das medidas de visão computacional.

IMAGEM		PERNCENTUAL DE INJÚRIAS	
		Visão Natural	Visão Computacional
1	IMG_7813	3,399	8,540
2	IMG_7814	1,820	9,404
3	IMG_7815	1,335	6,810
4	IMG_7816	6,511	11,817
5	IMG_7817	0,177	0,339
6	IMG_7818	0,424	2,388
7	IMG_7819	0,000	0,000
8	IMG_7820	1,013	2,472
9	IMG_7821	0,883	4,716
10	IMG_7822	1,762	4,805
11	IMG_7823	0,000	0,000
12	IMG_7824	0,263	2,618

Tabela 33 – Percentuais de injúrias em penca de bananas obtidos pela visão natural e pelo sistema utilizando limiarização.

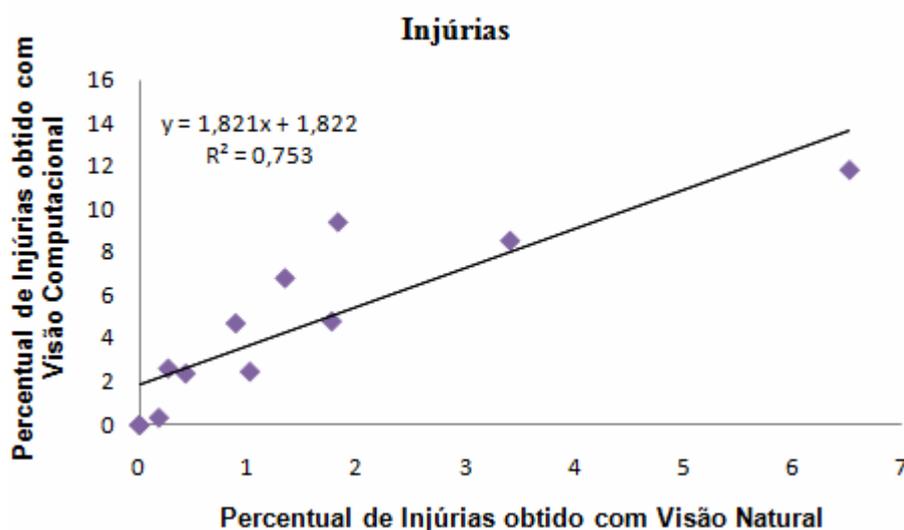


Figura 94 – Regressão linear para a identificação de injúrias de penca de bananas referente aos dados apresentados na tabela 33.

Tomando por base os resultados obtidos, no próximo capítulo são apresentadas as conclusões do modelo desenvolvido.

CONCLUSÕES

Foi apresentado neste trabalho o desenvolvimento de um sistema de visão computacional para análise de bananas (*Musa sapientum*) que identifica as manchas marrons e injúrias, obtém o percentual de manchas marrons e injúrias e ainda classifica o fruto em um dos seus 7 níveis de maturação. Assim, com base nos resultados apresentados e discutidos é possível concluir que:

1. Na etapa de pré-processamento, a utilização do filtro de mediana viabilizou a uniformização dos valores de intensidade da imagem representada na componente S, o que permitiu um melhor mapeamento das manchas marrons e injúrias.
2. Na identificação baseada em textura, o uso da informação de contraste foi adequado e discriminativo em nível dos padrões geométricos, utilizados para calibração. Adicionalmente, este método se mostrou capaz de identificar as manchas marrons e as injúrias corretamente.
3. O uso do modelo HSI para classificação do fruto em níveis de maturação auxiliou no desenvolvimento robusto do modelo.
4. A taxa de acerto do nível de maturação, em relação a escala de maturação de Von Loesecke, foi de 50% para os observadores e 100% com a visão computacional.
5. A identificação do percentual de manchas marrons e injúrias apresentou uma taxa de acerto de 80,40% para manchas marrons em imagem de banana individual, 97,70% para manchas marrons em penca de bananas, 97,80% para injúrias em imagem de banana individual e 75,30% para injúrias em imagem de penca de bananas.

Desta forma, conclui-se que o método desenvolvido pode ser aplicado no âmbito da inferência de qualidade do fruto de forma ágil e com precisão, sendo de interesse para uso em processo de pós-colheita.

REFERÊNCIAS BIBLIOGRÁFICAS

BALASUNDARAM, D.; BURKS, T. F.; BULANON, D. M.; SCHUBERT, T.; LEE, W. S. Spectral reflectance characteristics of citrus canker and other peel conditions of grapefruit. **Journal Postharvest Biology and Technology**. v. 51, n. 2, p. 220-226. 2009.

BALLARD, H. D.; BROWN, M. C. **Computer Vision**. 1 st ed. New Jersey: Prentice Hall, 1982.

BAXES, G. A. **Digital Image Processing: Principles and Applications**. 1 st ed. New York: John Wiley, 1994.

BILLY L.; ARVISENET G.; POINOT P.; CHEVALLIER S.; ROYER G.; VIGNEAU E.; PROST C. Image Texture Analysis of Apples Broken down in a Mastication Simulator Prototype. **IUFoST – 13º World Congress of Food Science and Technology**. p. 775-782. september 2006.

BLASCO, J.; ALEIXOS, N.; GÓMEZ, J.; MOLTÓ, E. Citrus Sorting by Identification of the most Common Defects using Multispectral Computer Vision. **Journal of Food Engineering**. v. 83, n. 3, p. 384-393. march 2007.

BLASCO, J.; CUBERO-GARCIA, S.; ALEGRE-SOSA, S.; GÓMEZ-SANCHÍS, J.; LÓPEZ-RUBIRA, V.; MOLTÓ, E. Short Comunication: Automatic Inspection of the Pomegranate (*Púnica granatum* L.) Arils Quality by Means of Computer Vision. **Spanish Journal of Agricultural Research**. v. 6, n. 1, p. 12-16. 2008.

CHEN, P.; McCARTHY, M.J.; KAUTEN, R. NMR for Internal Quality Evaluation of Fruits and Vegetables. **Transactions of the ASAE, St. Joseph**. v. 32, n. 5, p. 1747-1753, 1989.

CONCI, A.; AZEVEDO, E.; LETA, R. F. **Computação Gráfica: Teoria e Prática**. Rio de Janeiro: Elsevier, 2008.

CORRÊA, S. **Anuário Brasileiro da Fruticultura 2002**. Santa Cruz do Sul/RS: Gazeta do Sul, 176 p, 2002.

COSTA, L. F.; CESAR Jr., R. M. **Shape Analysis and Classification: Theory and Practice**. Boca Raton: CRC Press, 2001.

DALEY, W.; CAREY, R.; THOMPSON, C.; Poultry grading inspection using colour imaging. **SPIE Proceedings Machine Vision Applications in Industrial Inspection**. v. 1907, n. 124. 1993.

DE-HUI, K.; BAO-CAO Y.; YAN L.; YUN-HUI S. A rapid Texture Synthesis Algorithm Based on Clustering Preprocessing. **International Journal of Computer Sciencie and Network Security**. v. 6, n. 6, p. 85-90. june 2006.

DIGIOVANI, M. S. **Certificação, rastreabilidade e normatização**. Boletim Informativo da FAEP – Federação da Agricultura do Estado do Paraná, Curitiba, n. 708. 2002. Disponível em: <<http://www.faep.org.br>>. Acesso em: 5 de maio de 2008.

DORNFELD, C. H.; ALMEIDA, B. V. G.; MANCO, R. J. Analysis of the Quality and Valorization of Integrated Apples Production: An Study in the Wholesale Market of São Paulo. **V Internacional PENSA Conference**. 2005.

DUDA, R.; HART, P.; STORK, D. **Pattern Classification**. Wiley–Interscience, 2000.

EMBRAPA. **Exportação de frutas frescas cresce 35% no último ano**. Disponível em: <<http://blog.cnpat.embrapa.br/?p=247>>. Acesso em: 10 de Abril de 2008.

GÓMEZ, A. H.; HE, Y.; PEREIRA, A. G. Non-destructive measurement of acidity, soluble solids and firmness of Satsuma mandarin using Vis/NIR-spectroscopy techniques. **Journal of Food Engineering**. v. 77, n. 2, p. 313–319. 2005.

GONZALEZ, C. R.; WOODS E. R. **Processamento de Imagens Digital**. 2 nd Ed. Reading: Addison-Wesley, 1992.

GUNASEKARAN, S. Computer Vision Technology for Food Quality Assurance. *Trends in Food Science & Technology*, 7,245–256. 1996.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural Features for Image Classification. **IEEE Transactions on Systems Man and Cybernetics**. v. 3, n.6, p. 610-621, november 1973.

HARALICK, R. Statistical and structural approaches to texture. **Proceedings of the IEEE**. v. 67, n. 5, p. 786–804. may 1979.

IBGE. **Sistema IBGE de recuperação Automática – SIDRA**. Disponível em: <<http://www.sidra.ibge.gov.br/bda/agric/default.asp?t=4&z=t&o=11&u1=1&u2=1&u3=1&u4=1&u5=1&u6=1>>. Acesso em 05/06/2009.

IBRAF. **Perspectivas da Fruticultura Brasileira**. Disponível em: <http://www.ibraf.org.br/news/news_item.asp?NewsID=3345>. Acesso em 05 de março de 2009.

JAIN, K. A. **Fundamentals of Digital Image Processing**. 1 st ed. Englewood Cliffs: Prentice-Hall Information and System Science Series, 1989.

JÄHNE, B. **Image Processing for Scientific Application**. 1 st ed. United States: CRC Press, 1997.

JIANG, A. J.; CHANG, y. H.; WU, H. K.; OUYANG, S. C.; YANG, M. M.; YANG, C. E.; CHEN W. T.; LIN, T. T. An adaptive image segmentation algorithm for X-ray quarantine inspection of selected fruits. **Journal Computers and Electronics in Agriculture**. p. 190-200, 2008.

JORGE, L. A. C.; MINGHIM, R.; NONATO, L. G.; BISCEGLI, C. I.; PEDRINO, E. C.; RODA, V. O.; PAIVA, M. S. V. 3D Reconstruction, Visualization and volume calculation of fruits. **Computer Graphics International**. 2007.

KOC, B. A. Determination of watermelon volume using ellipsoid approximation and image processing. **Journal Postharvest Biology and Technology**. v. 45, n. 3, p. 366-371. march 2007.

LEEMANS, V.; DESTAIN, M. F. A real-time grading method of apple based on features extracted from defects. **Journal of Food Engineering**. v. 61, n. 1, p. 83–89. 2004.

MARQUES, F.O.; NETO, V.H. **Processamento Digital de Imagens**. 1. ed. Rio de Janeiro: Brasport, 1999.

MENDOZA, F.; AGUILERA, J. M. Application of Image Analysis for Classification of Ripening Bananas. **Journal of Food Science**. v. 69, n. 9, p. 471-477. 2004.

NASCIMENTO, A.S. do; BISCEGLI, C.I.; MENDONÇA, M. da C.; CARVALHO, R. da S. Avanços em tratamentos quarentenários para exportação de manga brasileira: tratamento hidrotérmico e tomografia de ressonância magnética. In: ALVES, R. E.; VELOZ, C. S. (Org.). **Exigências quarentenárias para exportação de frutas tropicais e subtropicais**. Fortaleza: EMBRAPA Agroindústria Tropical/CYTED/CONACYT, p.155-171. 1999.

NUNES, E. O.; CONCI A. Segmentação por textura e localização do contorno de regiões em imagens multibandas. **IEEE Latin America Transactions**. v. 5, n. 3, p. 185-192. November 2007.

OKAMOTO, H.; LEE, S. W. Green citrus detection using hyperspectral imaging. **Journal Computers and Eletronics in Agriculture**, v. 66, p. 201-208. 2009.

OLORUNDA, A. O. Recent advances in postharvest technologies of banana and plantain in Africa. **Acta Horticulturae**. Wageningen. n.540, p.517-597. 2000.

PBMH & PIF - PROGRAMA BRASILEIRO PARA A MODERNIZAÇÃO DA HORTICULTURA & PRODUÇÃO INTEGRADA DE FRUTAS. Normas de Classificação de Banana. São Paulo: **CEAGESP**, 2006. (Documentos, 29).

PRATT, W. K. **Digital Image Processing**. 2 nd ed. New York: John Wiley, 1991.

QUEVEDO, R.; MENDONZA, F.; AGUILERA, J.M.; CHAMONA, J.; LÓPEZ, G. G. Determination of senescent spotting in banana (*Musa Cavendish*). **Journal of Food Engineering**. v. 84, n. 4, p. 509-515. 2008.

RASHIDI, M. Determination of kiwifruit volume using image processing. **Journal of Agricultural and Biological Science**. v.2, n. 6, p. 17-22. november 2007.

RIBEIRO Jr. E. **Análise de Atributos Visuais em Imagens Texturais utilizando Técnicas Espectrais**: 1993-1995. Dissertação (Mestrado em Ciência da Computação), Universidade Federal de São Carlos, São Carlos.

- RUSS, J. C. *Image Processing Handbook*. 3rd ed. Boca Raton: CRC Press, 1999.
- RUSS, J. C. *Image Processing Handbook*. 5th ed. Boca Raton: CRC Press, 2007.
- SANTULLI C.; JERONIMIDIS G. Development of a Method for Nondestructive Testing of Fruits using Scanning Laser Vibrometry (Slv). **NDT net**. v. 11, n. 10. september 2006.
- SCHOWENGERDT, R. A. **Remote Sensing: Models and methods for image processing**. 2 nd ed. San Diego: Academic Press, 1997.
- SIMÕES, S.A.; COSTA, R. H. A. Classificação de Laranjas Baseadas em padrões Visuais. **6º Simpósio Brasileiro de Automação Inteligente**. p.77-81. agosto 2003.
- SONG, H.; WANG J.; LI Y. Studies on vibration characteristics of a pear using finite element method. **Journal of Zhejiang University SCIENCE B**. v. 7, n. 6, p. 491-496. march 2006.
- SONKA, M.; HLAVAC, V.; BOYLE, R. **Image processing: Analysis and Machine Vision**. 2 nd ed. Victoria: Thomson, 1998.
- STEIN T. **Avaliação de Descritores de Textura para Segmentação de Imagens: 2003-2005**. Dissertação (Mestrado em Ciência da Computação), Universidade Federal do Paraná, Paraná.
- SUN, X. Y.; ZHANG, M. C.; LIU, Z. P.; ZHU, M. H. Shape Feature Extraction of Fruit Image Based on Chain Code. **IEEE International Conference on Wavelet Analysis and Pattern Recognition**. v. 3, p. 1346-1349. november 2007.
- TABATABAEFFAR A.; VEFAGH-NEMATOLAHEE A.; JABIPOUR A. Modeling of orange based on dimensions. **Journal of Agricultural Science and Technology**. v. 2, n. 4, p. 299-305. october 2000.
- TUCERYAN, M.; JAIN A. K. **Texture Analysis. In: The Handbook of Pattern Recognition and Computer Vision**. 2 nd ed. Singapore: World Scientific, 1998.
- UMBAUGH, S. E. **Computer Vision and Processing Image: A Pratical Approach using CVIPtools**. 1 st ed. New Jersey: Prentice Hall, 1998.
- USC-SIPI Image Database. University of Southern California – Signal & Image Processing Institute – Electrical Engineering Departament, 1971. Disponível em <<http://sipi.usc.edu/database/database.cgi?volume=misc&image=12#top>>. Acesso em: 10 de Novembro de 2009.
- VITTAYAPADUNG, S.; JIEWEN, Z.; QUASHENG, C.; CHUAVIROJ, R. Application of FT-NIR spectroscopy to the measurement of fruit firmness of “Fuji” apples. **Maejo International Journal of Science and Technology**. v. 2, n. 1, p. 13-23. 2008.
- WASEEM K.; GHAFFOR A.; REHMAN S.U. Effect of fruit orientation on the quality of litchi (Litchi chinensis Sonn) under the agro-climatic conditions of Dera Ismail Khan-Pakistan. **International Journal Agriculture and Biology**. p. 503-505. september 2002.

XIAOBO, Z.; JIEWEN, Z.; YANXIAO, L. Apple color grading based on organization feature parameters. **Journal Pattern Recognition Letters**. v. 28, n. 15, p. 2046-2053, june 2007.

XING, J.; SAEYS, W.; BAERDMAEKER, D. J. Combination of Chemometric Tools and Image Processing for Bruise Detection on Apples. **Journal Computers and electronics in agriculture**. v. 56, n. 1, p. 1-13. january 2007.

44

XU, X.; EIFERT J.; ZHAN P. Area and volume measurements of objects with irregular shapes using multiple silhouettes. **Journal Optical Engineering**. v. 45, p. 027202.2-027202.11. february 2006.

YANG, L.; DICKINSON, J.; Yang, J. Dickinson, WU, J.; LANG, S. A Fruit Recognition Method for Automatic Harvesting. **IEEE International Conference on Mechatronics and Machine Vision in Practice**. december 2007.

ZENG, Q.; LIU, C.; MIAO, Y.; FEI, S.; WANG, S. A Machine Vision System for Continuous Field Measurement of Grape Fruit Diameter. **IEEE Second International Symposium on Intelligent Technology Application**. v.2, p. 1064-1068. december 2008.