



UNIVERSIDADE FEDERAL DE CAMPINA GRANDE  
CENTRO DE CIÊNCIAS E TECNOLOGIA  
PÓS - GRADUAÇÃO EM ENGENHARIA DE PROCESSOS



**TESE**

***SELEÇÃO E CLASSIFICAÇÃO INTELIGENTE DE MANGAS POR  
ANÁLISE DE IMAGENS.***

**JOELSON NOGUEIRA DE CARVALHO**

Campina Grande (PB)

2015

**JOELSON NOGUEIRA DE CARVALHO**

***SELEÇÃO E CLASSIFICAÇÃO INTELIGENTE DE MANGAS POR  
ANÁLISE DE IMAGENS.***

Tese apresentada à Universidade Federal de Campina Grande, como requisito parcial à obtenção do título de Doutor em Engenharia de Processos.

Thesis submitted to the Federal University of Campina Grande, as a partial fulfilment of the requirements to the degree of Doctor in the area of Processes Engineering.

Orientadores:

Prof. Dr. Mario Eduardo Rangel M. Cavalcanti Mata.

Prof<sup>a</sup>. Dr<sup>a</sup>. Maria Elita M. Duarte.

Campina Grande (PB)

2015


II




PARECER FINAL DA AVALIAÇÃO DA TESE DE DOUTORADO

*Joelson Nogueira de Carvalho*


**Título: SELEÇÃO E CLASSIFICAÇÃO INTELIGENTE DE MANGAS POR ANÁLISE DE IMAGENS**

  
Prof. Dr. Mario Eduardo R. M. Cavalcanti Mata  
Orientador – UAEA/CTRN/UFCA

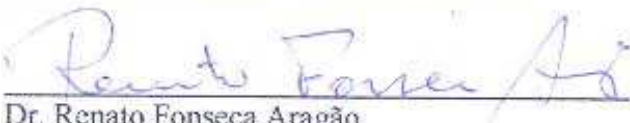
A PROVA DO

  
Prof. Dra. Maria Elita Martins Duarte  
Orientadora – UAEA/CTRN/UFCA

APROVADO

  
Prof. Dr. Edmar Candeia Gurjão  
Examinador Externo UAEE/CEEI/UFCA

APROVADO

  
Dr. Renato Fonseca Aragão  
Examinador Externo UAEE/CTRN/UFCA

Aprovado

  
Prof. Dra. Adriana Zenalde Clericuzi  
Examinador Externo DEXX/UFPA

APROVADO

Campina Grande, 09 de março de 2015



UNIVERSIDADE FEDERAL DE CAMPINA GRANDE  
CENTRO DE CIÊNCIAS E TECNOLOGIA  
PÓS - GRADUAÇÃO EM ENGENHARIA DE PROCESSOS



## **COORDENAÇÃO DO DOUTORADO EM ENGENHARIA DE PROCESSOS**

Diretor do Centro: Ricardo Cabral de Vasconcelos

Coordenador do Curso de Pós-graduação: Prof. Dr. Severino Rodrigues de Farias Neto

## ***Dedicatória***

*À minha família, como homenagem à minha mãe.*

## ***Agradecimentos***

*É com muita satisfação que expresso aqui o meu profundo agradecimento a todos aqueles que tornaram possível este trabalho.*

*A Deus, pela luz que nos permite perceber as cores e as formas de sua criação.*

*Aos meus pais que me deram a vida e exemplos que me orientaram a enveredá-la da maneira correta.*

*À minha esposa Lilian e aos meus filhos Daniella e Arthur, que me dão amor, paz e felicidade incessantes, além do incentivo maior para a realização deste trabalho.*

*Aos meus amados irmãos Joabson e Januse e aos meus sobrinhos, pelo incentivo e pela torcida.*

*Aos meus professores orientadores, Dr. Mário Eduardo Rangel Moreira Cavalcanti-Mata e Dr<sup>a</sup>. Maria Elita Duarte, pela paciência e atenção oferecidas durante essa jornada, pelo exemplo de profissionalismo e pela amizade.*

*Ao professor Dr. Edmar Candeia Gurjão, pela ajuda, incentivo, comentários e cobrança que foram perenes ao longo deste trabalho.*

*Ao professor Emir Candeia pela “instigação inicial”.*

*Ao Dr. Renato Aragão pela atenção, apoio e amizade.*

*Aos professores Antônio Gilson, Wilton Pereira, Marcelo Grilo, Alexandre Queiroz, João Evangelista e Antônio “Diassis” Almeida, por compartilharem comigo seus conhecimentos.*

*A todos os técnicos e funcionários com os quais interagi no âmbito do PRODEP.*

*Aos meus colegas do curso pela amizade e companheirismo.*

*Aos meus colegas professores do DCE/CCAUE/UFPB, pela concessão do meu afastamento por um ano, período que foi fundamental para o desenvolvimento do meu trabalho de Tese.*

*“Não ande apenas pelo caminho traçado, pois ele conduz somente até onde os outros já foram.”*

**– Alexander Graham Bell –**

---

## SELEÇÃO E CLASSIFICAÇÃO INTELIGENTE DE MANGAS POR ANÁLISE DE IMAGENS

**Autor:** Joelson Nogueira de Carvalho

**Orientadores**

Prof. Dr. Mario Eduardo R. M. Cavalcanti Mata

Prof<sup>ª</sup>. Dra. Maria Elita Martins Duarte

### RESUMO

O Brasil está hoje inserido entre os principais produtores mundiais de frutas, onde a manga se apresenta como um importante componente da sua pauta de exportações; para manter-se na vanguarda desse mercado, multiplicam-se esforços no sentido de prover frutos de alta qualidade ao consumidor, onde os avanços na tecnologia da informação permitem o desenvolvimento de sistemas de automação para tarefas de suma importância que envolvem aspectos cognitivos, como a seleção e a classificação de frutas, o que garante um rendimento superior. Considerando essa premissa, este trabalho apresenta o desenvolvimento de um sistema de automação não destrutivo para classificação e seleção da manga *Tommy Atkins*, empregando um sistema de visão computacional associado a um sistema de aprendizagem de máquina, capaz de especificar e utilizar qualquer padrão comercial para avaliação pela cor e pela forma. A estimação de parâmetros como massa, volume, posição relativa do seu pedúnculo e outras informações relevantes são também implementadas. Este sistema foi desenvolvido vislumbrando a possibilidade de ser implantado numa esteira de classificação de baixo custo, em benefício do pequeno produtor rural, onde a interface desenvolvida permite sua operação por operadores com pouca qualificação.

**Palavras Chaves:** Automação agrícola, seleção e classificação de frutas, visão computacional, inteligência artificial, aprendizagem de máquina.



***SELECTION AND CLASSIFICATION INTELLIGENT OF MANGO PER IMAGE ANALYSIS***

***Author:*** Joelson Nogueira de Carvalho

***Supervisors:***

Dr. Mario Eduardo R. M. Cavalcanti Mata (UAEA/CTRN/UFCG).

Dr. Maria Elita Martins Duarte (UAEA/CTRN/UFCG).

**ABSTRACT**

Brazil is today one of the major world producers of fruit, where the mango is presented as an important component of its exports. To remain at the forefront of this market, efforts are multiplied in order to provide the consumer high quality fruits, where advances in information technology allow the development of automation systems for tasks of major importance involving cognitive aspects, such as selection and sorting of fruit, which ensures a higher yield. Given this premise, this paper presents the development of a non-destructive automation system for classification and selection of Tommy Atkins mango, employing a computer vision system associated with a machine learning system that can specify and use any trade standard for review by color and shape. The estimation of parameters such as mass, volume, position on the stem and other relevant information are also implemented. This system was developed glimpsing the possibility of being embedded into a low cost classification conveyor belt, for the benefit of small farmers, where the developed interface allows operation by operators with little qualification.

**Keywords:** agricultural Automation, selection and classification of fruits, computer vision, artificial intelligence, machine learning.

---

**SUMÁRIO**

<b>1. INTRODUÇÃO.....</b>	<b>1</b>
1.1. Objetivos .....	4
1.1.1. Objetivos específicos.....	4
<b>2. REVISÃO BIBLIOGRÁFICA .....</b>	<b>5</b>
2.1. A manga Tommy Atkins .....	5
2.1.1. Fases do desenvolvimento.....	6
2.1.2. A relação respiração × pericibilidade .....	7
2.1.3. A cor da superfície .....	9
2.1.4. A classificação de frutas.....	9
2.1.5. Defeitos em mangas .....	11
2.1.6. A classificação de mangas.....	11
2.1.7. Doenças e pragas da mangueira .....	14
2.1.8. Manchas pretas na superfície da manga.....	16
2.1.9. Doenças que causam manchas pretas.....	16
2.1.10. Pragas que causam manchas negras .....	19
2.2. Cores e imagens .....	20
2.2.1. A radiação eletromagnética.....	21
2.2.2. A percepção da cor.....	22
2.2.3. A formação das cores .....	26
2.2.4. Padrões de cores .....	28
2.2.5. O espaço dos atributos de cores .....	33
2.2.6. O conceito de imagem.....	37
2.2.7. Arquivos de imagens .....	45
2.2.8. Descritores de cor.....	49
2.2.9. O processamento de imagens .....	52

---

2.2.10. Detecção de objetos em imagens.....	56
2.2.11. Reconhecimento de padrões em imagens.....	56
2.3. Inteligência artificial e aprendizagem de máquina.....	57
2.3.1. O conceito de inteligência .....	57
2.3.2. Definição de “Inteligência Artificial” .....	57
2.3.3. Sistemas baseados em conhecimento - SBC .....	59
2.3.4. Visão computacional .....	61
2.3.5. Aprendizagem de máquina.....	64
2.3.6. Lógica “ <i>Fuzzy</i> ” .....	74
2.3.7. Redes neurais artificiais.....	76
2.4. Mecanismos para seleção e classificação.....	78
2.4.1. Processos de avaliação Pós-colheita.....	78
2.4.2. Atributos de avaliação .....	79
2.4.3. Parâmetros para avaliação .....	81
2.4.4. A cor da superfície .....	82
2.4.5. Firmeza.....	87
2.4.6. Forma, tamanho e massa .....	87
2.5. Métodos para avaliação.....	88
2.5.1. Métodos de avaliação pela cor .....	88
2.5.2. Métodos de avaliação pela forma: volume e massa .....	90
2.5.3. Métodos mistos .....	93
2.5.4. Classificadores que utilizam visão computacional.....	95
2.5.5. Equipamentos para análise automática de frutas.....	99
<b>3. MATERIAIS E MÉTODOS .....</b>	<b>102</b>
3.1. Métodos de análise pela cor .....	102
3.1.1. Método de classificação inteligente .....	102
3.1.2. Método para detecção de manchas pretas .....	126

---

3.1.3. Método “ <i>Fuzzy</i> ” para estimação da maturidade .....	127
3.2. Métodos de análise pela forma .....	140
3.2.1. Método de estimação de propriedades físicas .....	140
3.2.2. Método para estimação da orientação do pedúnculo.....	155
3.2.3. Método inteligente de seleção de mangas pela forma.....	155
<b>4. RESULTADOS E DISCUSSÕES.....</b>	<b>165</b>
4.1. Métodos de avaliação pela cor .....	165
4.1.1. Resultados dos métodos de avaliação pela cor.....	165
4.1.2. Discussões sobre os métodos de avaliação pela cor.....	181
4.2. Métodos de avaliação pela forma.....	187
4.2.1. Resultados dos métodos de avaliação pela forma .....	187
4.2.2. Discussão sobre os métodos de avaliação pela forma.....	200
<b>5. CONCLUSÕES E TRABALHOS FUTUROS .....</b>	<b>201</b>
5.1. Conclusões .....	201
5.1.1. Avaliação pela cor.....	201
5.1.2. Avaliação pela forma.....	202
5.2. Trabalhos futuros.....	203
5.2.1. Avaliação pela cor.....	203
5.2.2. Avaliação pela forma.....	204
<b>6. BIBLIOGRAFIA.....</b>	<b>205</b>
<b>7. APÊNDICE I .....</b>	<b>225</b>
<b>8. APÊNDICE II .....</b>	<b>253</b>

## LISTA DE FIGURAS

<b>Figura 2.1-1:</b> A manga e sua morfologia interna. ....	5
<b>Figura 2.1-2:</b> Estágios do desenvolvimento dos frutos.....	7
<b>Figura 2.1-3:</b> Longevidade pós-colheita de frutos em função da taxa de respiração.....	8
<b>Figura 2.1-4:</b> Manga atacada pela Antracnose.....	16
<b>Figura 2.1-5:</b> Manga atacada pela mancha angular. ....	17
<b>Figura 2.1-6:</b> Manga atacada pela Verrugose. ....	18
<b>Figura 2.1-7:</b> Podridão Peduncular.. ....	19
<b>Figura 2.1-8:</b> Manchas causadas por <i>Fusicoccum parvum</i> .....	19
<b>Figura 2.1-9:</b> O Tripes <i>Frankliniella Schultzei</i> .....	20
<b>Figura 2.1-10:</b> Manga atacada pelo tripes.....	20
<b>Figura 2.2-1:</b> Flutuações dos campos elétrico e magnético de uma onda.....	22
<b>Figura 2.2-2:</b> Anatomia do olho humano.....	23
<b>Figura 2.2-3:</b> Inversão da imagem de um objeto pela lente convexa.....	24
<b>Figura 2.2-4:</b> Projeção da imagem sobre a retina. ....	24
<b>Figura 2.2-5:</b> Anatomia da Retina – Disposição dos Cones e Bastonetes. ....	25
<b>Figura 2.2-6:</b> Sensibilidade das Células Cone à luz visível. ....	26
<b>Figura 2.2-7:</b> Espectro dos comprimentos de onda da luz visível. ....	26
<b>Figura 2.2-8:</b> Processos de composição de cores.....	27
<b>Figura 2.2-9:</b> Representação da cor azul em 256 níveis de intensidade no padrão RGB. ....	29
<b>Figura 2.2-10:</b> Cores diversas do Cubo RGB.. ....	29
<b>Figura 2.2-11:</b> Valores RGB para reproduzir todas as cores do espectro visível. ....	30
<b>Figura 2.2-12:</b> Paleta de cores RGB, com representação de alguns valores.....	31
<b>Figura 2.2-13:</b> Comprimento de ondas das componentes x, y e z. ....	32
<b>Figura 2.2-14:</b> Diagrama de cromaticidade do CIE.....	32
<b>Figura 2.2-15:</b> Variação da saturação do Matiz vermelho.....	33
<b>Figura 2.2-16:</b> Modelo cilíndrico de espaço de atributos de cores. ....	34
<b>Figura 2.2-17:</b> Modelo de espaço de cores HSV.. ....	35
<b>Figura 2.2-18:</b> Os cones invertidos do espaço de cores HSL. ....	36
<b>Figura 2.2-19:</b> Componentes HSL e seus valores. Fonte:.....	36
<b>Figura 2.2-20:</b> Defasagem geométrica das cores no modelo HSL.....	37
<b>Figura 2.2-21:</b> Sensores CCD montados em Cis. ....	42
<b>Figura 2.2-22:</b> Proporção da luz incidente sobre a área do pixel.....	42

<b>Figura 2.2-23:</b> Níveis de cinza resultantes sobre a área do pixel.....	43
<b>Figura 2.2-24:</b> Mesma imagem representada em diferentes resoluções. ....	44
<b>Figura 2.2-25:</b> Imagem no formato RGB (a) com seu histograma em escala de cinza (b)....	51
<b>Figura 2.2-26:</b> Imagem RGB(a) com histogramas azul(b), verde(c) e vermelho(d). ....	52
<b>Figura 2.2-27:</b> Parâmetros de uma imagem... ..	55
<b>Figura 2.3-1:</b> Áreas de conhecimento que contribuem com a IA. ....	59
<b>Figura 2.3-2:</b> Algumas das áreas desenvolvidas e pesquisadas pela IA. ....	59
<b>Figura 2.3-3:</b> Arquitetura de um SBC.....	60
<b>Figura 2.3-4:</b> Nível de processamento dos sistemas de visão. ....	63
<b>Figura 2.3-5:</b> Formas de difícil descrição/representação. ....	63
<b>Figura 2.3-6:</b> Fases do aprendizado de Máquina. ....	65
<b>Figura 2.3-7:</b> Algoritmo de aprendizagem de máquina. ....	66
<b>Figura 2.3-8:</b> Algoritmo de aprendizagem não incremental. ....	71
<b>Figura 2.3-9:</b> Algoritmo de aprendizagem incremental.....	71
<b>Figura 2.3-10:</b> Valores da variável <i>fuzzy</i> “Temperatura do Ambiente”.....	75
<b>Figura 2.3-11:</b> O Neurônio Artificial.....	77
<b>Figura 2.3-12:</b> Rede Neural Artificial (RNA).....	77
<b>Figura 2.4-1:</b> Mangas associadas aos níveis do padrão Embrapa. ....	84
<b>Figura 2.5-1:</b> Padrão de cores para classificação de laranjas.....	88
<b>Figura 2.5-2:</b> Possíveis medições dos diâmetros máximo e mínimo. ....	90
<b>Figura 2.5-3:</b> Seções discoides da manga para estimação do volume. ....	91
<b>Figura 2.5-4:</b> Formatos do melão identificados pelo sistema.. ....	92
<b>Figura 2.5-5:</b> Quatro tipos de melancias deformadas. ....	93
<b>Figura 2.5-6:</b> PCA encontra diâmetros máximo e mínimo. ....	94
<b>Figura 3.1-1:</b> Diagrama contextual do Sistema de Classificação Inteligente.. ....	103
<b>Figura 3.1-2:</b> Interface para os sistemas de Análise de imagens e Aprendizagem. ....	104
<b>Figura 3.1-3:</b> Inter-relações entre os módulos dos sistemas. ....	104
<b>Figura 3.1-4:</b> Esquema de diretórios para armazenar imagens. ....	106
<b>Figura 3.1-5:</b> Câmara para aquisição de imagens. ....	108
<b>Figura 3.1-6:</b> Gamut para câmaras CCD da Ikonik Modelo IT8 E6.....	112
<b>Figura 3.1-7:</b> Imagens capturadas dos lados (A e B) de uma mesma manga. ....	113
<b>Figura 3.1-8:</b> Histogramas da componente H das Figuras 3.1-7-A e 3.1-7-B e sua soma. ..	115
<b>Figura 3.1-9:</b> Histograma da imagem de um objeto.. ....	116
<b>Figura 3.1-10:</b> Faixa do espectro cujos valores não são relevantes.. ....	116

<b>Figura 3.1-11:</b> Histograma resultante da eliminação das cores próximas ao azul e ciano. ..	116
<b>Figura 3.1-12:</b> Abstração dos planos de representação em Extensão e em Intensão. ....	119
<b>Figura 3.1-13:</b> Inconsistência da componente L com o padrão. ....	119
<b>Figura 3.1-14:</b> Ponto na faixa de valores de exemplos negativos.....	120
<b>Figura 3.1-15:</b> Instância atinge valor da faixa de valores de exemplos negativos.....	121
<b>Figura 3.1-16:</b> Efeito “fade” pela redução do valor S.....	127
<b>Figura 3.1-17:</b> Sistema fuzzy para controle de um processo. ....	129
<b>Figura 3.1-18:</b> Funções "fuzzy" de pertinência típicas.. ....	130
<b>Figura 3.1-19 -</b> Função fuzzy para representação de cores.....	133
<b>Figura 3.1-20:</b> Funções fuzzy para o maturidade.....	135
<b>Figura 3.1-21:</b> Funções fuzzy individuais para as cores. ....	135
<b>Figura 3.1-22 -</b> Estádios de Maturidade fuzzificados.. ....	136
<b>Figura 3.1-23:</b> Estratégia de Mamdani.....	137
<b>Figura 3.1-24:</b> Funções fuzzy individuais para os estádios de Maturidade.. ....	138
<b>Figura 3.1-25:</b> Centros de gravidades de superfícies planas retangulares e triangulares.....	140
<b>Figura 3.2-1:</b> Forma aproximada da manga <i>Tommy Atkins</i> : Esferóide Prolato. ....	142
<b>Figura 3.2-2:</b> Fluxograma funcional do método. ....	143
<b>Figura 5.1-3:</b> Pontos de definição da região Interpretável. ....	146
<b>Figura 5.1-4:</b> Detecção de quinas em um segmento. ....	149
<b>Figura 3.2-5:</b> Conjunto BORDER inscrito em um Retângulo. ....	150
<b>Figura 3.2-6:</b> Fluxograma funcional para encontrar o eixo principal. ....	151
<b>Figura 3.2-7:</b> Eixo principal divide a manga em regiões geometricamente distintas. ....	153
<b>Figura 3.2-8:</b> Medições extraídas de um exemplar da mangas <i>Tommy Atkins</i> . ....	154
<b>Figura 3.2-9:</b> Fluxograma funcional do modo de TREINAMENTO.....	156
<b>Figura 3.2-10:</b> Fluxograma funcional do modo SELEÇÃO. ....	157
<b>Figura 3.2-11:</b> Ramificação da árvore de decisão para uma instância POSITIVA. ....	161
<b>Figura 3.2-12:</b> Ramificação da árvore com decisão para uma instância NEGATIVA. ....	162
<b>Figura 3.2-13:</b> Proximidade entre a instância e os modelos positivos e negativos. ....	163
<b>Figura 3.2-14:</b> Avaliação da proximidade utilizando o desvio padrão.. ....	164
<b>Figura 4.1-1:</b> Procedimento de lavagem e acondicionamento das frutas.....	165
<b>Figura 4.1-2:</b> Algumas das sequencias típicas de imagens capturadas.....	166
<b>Figura 4.1-3:</b> Manga atingidas por manchas negras. ....	172
<b>Figura 4.1-4:</b> Grade sobre a manga para contagem dos pontos negros. ....	172
<b>Figura 4.1-5:</b> Influência das componentes S e L para o vermelho no intervalo 15-25%. ....	174

---

<b>Figura 4.1-6:</b> Interpretação de um valor de entrada específico ( $\lambda_0$ ).....	175
<b>Figura 4.1-7:</b> Distribuição por igual das cores.....	176
<b>Figura 4.1-8:</b> Imagens selecionadas para avaliação.....	176
<b>Figura 4.1-9:</b> Combinação de Funções fuzzy Cor x Estádio de Maturidade. . . . .	177
<b>Figura 4.1-10:</b> Planos definidos por uma combinação de cores específica. . . . .	178
<b>Figura 4.1-11:</b> Composição dos planos de saída ( $\text{MAX}(\mu[\lambda, m])$ ).....	179
<b>Figura 4.1-12:</b> Resultado escalar (crispy) para a maturidade para a entrada $\lambda_0$ .....	180
<b>Figura 4.1-13:</b> Problema de conversão 3D para 2D.....	181
<b>Figura 4.1-14:</b> Projeção Transversa de Mercator (ARENAS-RÍOS, 2012).. . . . .	182
<b>Figura 4.2-1:</b> Curva da perda de massa das mangas no intervalo de 15 dias.....	189
<b>Figura 4.2-2:</b> Correlação entre a massa fresca e volume da manga <i>Tommy Atkins</i> .....	190



## LISTA DE TABELAS

<b>Tabela 2.1-1:</b> Limites máximos de tolerâncias por categoria.....	14
<b>Tabela 2.2-1:</b> Alguns dos padrões de resolução para monitores de vídeo. ....	45
<b>Tabela 2.4-1:</b> Percentuais dos níveis do padrão Embrapa.....	85
<b>Tabela 2.4-2:</b> Níveis da Escala de Blush.....	85
<b>Tabela 2.4-3:</b> Níveis da Escala de LI. ....	85
<b>Tabela 2.4-4:</b> Padrão definido por GTZ (1992). ....	86
<b>Tabela 2.4-5:</b> Padrão definido por JACOBI et al. (1998). ....	86
<b>Tabela 2.4-6:</b> Escala de maturação para a manga <i>Tommy Atkins</i> , MILLER (1991).....	86
<b>Tabela 3.1-1:</b> Valor angular das cores Vermelho, Amarelo e Verde no Modelo HSL. ....	117
<b>Tabela 3.2-1</b> - Informações extraídas de cada instância.....	159
<b>Tabela 3.2-2:</b> Informações derivadas dos dados lidos das instâncias. ....	159
<b>Tabela 4.1-1:</b> Resultados das classificações no primeiro dia da avaliação. ....	167
<b>Tabela 4.1-2:</b> Resultados das classificações no sétimo dia da avaliação. ....	168
<b>Tabela 4.1-3:</b> Resultados das classificações no décimo quarto dia da avaliação.....	168
<b>Tabela 4.1-4:</b> Percentuais de cobertura do Matiz (H) aprendidos após o treinamento. ....	169
<b>Tabela 4.1-5:</b> Variação da cobertura do Matiz (H) em função do tempo.....	170
<b>Tabela 4.1-6:</b> Diferença entre os percentuais do padrão e das amostras (erro).....	170
<b>Tabela 4.1-7:</b> Valores médios dos componentes HSL do padrão. ....	171
<b>Tabela 4.1-8:</b> Valores médios normalizados dos componentes HSL do padrão. ....	171
<b>Tabela 4.1-9:</b> Percentual da área atingida em função dos valores das componentes SL. ....	173
<b>Tabela 4.1-10:</b> Avaliação Homem x Máquina para análise de pontos pretos. ....	174
<b>Tabela 4.1.11:</b> Percentual de cores da imagem retornada pelo sistema .....	177
<b>Tabela 4.1.12:</b> Defuzzificação por COG.....	180
<b>Tabela 4.2-1:</b> Medições manuais, estimativas e resposta do sistema.....	192
<b>Tabela 4.2-2:</b> Valores históricos extraídos do sistema.....	194
<b>Tabela 4.2-3:</b> Valores das médias calculada para o volume. ....	194
<b>Tabela 4.2-4:</b> Aproveitamento da manga <i>Tommy Atkins</i> . ....	195
<b>Tabela 4.2-5:</b> Aproveitamento da manga <i>Tommy Atkins</i> . ....	196
<b>Tabela 4.2-6:</b> Diferença dos percentuais de massa da manga <i>Tommy Atkins</i> . ....	197
<b>Tabela 4.2-7:</b> Estimação da massa das partes componentes da manga. ....	197

**LISTA DE QUADROS**

<b>Quadro 2.1-1:</b> Requisitos de qualidade para mangas. ....	12
<b>Quadro 2.1-2:</b> Insetos que atacam a mangueira. ....	15
<b>Quadro 2.1-3:</b> Doenças que atacam a mangueira. ....	15
<b>Quadro 2.2-1:</b> Formatos de arquivos de imagem mais difundidos. ....	46
<b>Quadro 2.3-1:</b> Formalismos para a representação do conhecimento. ....	61
<b>Quadro 3.1-1:</b> Principais componentes envolvidos na análise sensorial. ....	80
<b>Quadro 3.1-2:</b> Principais componentes envolvidos na análise sensorial. ....	81
<b>Quadro 3.4-1:</b> Sistemas classificadores por visão computacional. ....	95
<b>Quadro 3.4-2:</b> Principais métodos/técnicas aplicadas nos sistemas de classificação. ....	96
<b>Quadro 3.5-1:</b> Lista de alguns fabricantes de equipamentos para avaliação de frutos. ....	100
<b>Quadro 4.1-1:</b> Relação dos identificadores da base de conhecimento. ....	125
<b>Quadro 4.1-2:</b> Relação dos identificadores para instrução direta. ....	125
<b>Quadro 4.1-3:</b> Variáveis fuzzy associadas ao padrão TAFC. ....	132
<b>Quadro 4.1-4:</b> Regras fuzzy que relacionam as cores ao estágio de maturação. ....	134
<b>Quadro 5.1-1:</b> Dados da Base de Conhecimento para instâncias POSITIVAS. ....	158
<b>Quadro 5.1-2:</b> Dados da Base de Conhecimento para instâncias NEGATIVAS. ....	158

## 1. INTRODUÇÃO

O Brasil é atualmente o terceiro maior produtor de frutas do planeta, ficando atrás apenas da China e Índia, que ocupam o primeiro e segundo lugar respectivamente. O segmento de frutas frescas representa uma grande fatia desse mercado, mas a parcela de participação do país é pequena em relação a outros países. O Brasil exporta hoje apenas 7% das exportações chilenas nesse setor. Este fraco desempenho se deve, entre outras coisas, à falta de um modelo exportador (SILVA, 2013). Inserida nesse contexto a manga produzida no Brasil tem papel de destaque, aparecendo como o terceiro mais importante item de exportação do país no segmento, tornando-se líder de importações pelo mercado europeu. O Brasil detém hoje a sétima posição dentre os maiores exportadores desse produto com uma fatia de aproximadamente 3,3% do um mercado global, que é de 38,6 milhões de toneladas (PAN, 2013).

Apesar da pouca expressão da manga no mercado internacional de frutas e da existência de fatores limitantes ao comércio, o país vem apresentando uma taxa de crescimento médio anual das exportações desse produto duas vezes maior que a média mundial (CORREIA, 2010). Um desses fatores limitantes, que se constitui num dos principais gargalos para a exportação da manga reside no processo de seleção e classificação dessa fruta dentro de critérios estabelecidos por padrões internacionais.

As frutas, assim como outros produtos agrícolas, estão sujeitas a danos e perdas ao longo de todas as fases de sua produção, porém, é na pós-colheita que se concentram os maiores prejuízos, que são devidos principalmente ao processamento, embalagem, manuseio e transporte inadequados, além de técnicas de conservação incipientes. Tudo isso pode vir a produzir alterações mecânicas, fisiológicas ou patológicas, degradando a qualidade do produto. Por esse motivo, o processo pós-colheita de seleção e classificação de frutas vêm merecendo especial atenção, afinal, ele decide se determinado produto está ou não com a qualidade exigida pelo consumidor. Outro fator relevante é a necessidade cada vez mais premente de ofertar à população, produtos mais saudáveis, evitando doenças e riscos à saúde decorrentes da ingestão de produtos com elevados níveis de agrotóxicos, com fungos ou bactérias, ou produtos excessivamente maduros ou podres (PALTRINIERI *et al.*, 1997).

No processo de seleção e classificação, duas heurísticas básicas são adotadas: capacitar o efetivo de pessoal ou aplicar tecnologias de automação. Essas opções possuem prós e contras, mas a automação tem promovido a obtenção de resultados mais interessantes em termos de

custo e desempenho em praticamente todos os processos industriais em que é aplicada, sem contar com vantagens subalternas como a redução de acidentes de trabalho envolvendo humanos. Acontece que o alto custo dessa tecnologia tem representado um obstáculo para o setor agrícola, simplesmente porque ela não está ao alcance das pequenas e médias empresas desse setor. Dessa forma, sistemas de baixo custo para análise de imagens, aplicados à classificação e seleção de frutos, podem vir a representar um diferencial na balança da competitividade desse exigente mercado. Esses sistemas são constituídos de métodos de análise não invasivos, sendo adequados para a indústria alimentar. No processamento da manga, o processo de seleção e classificação, obedece a critérios definidos em padrões nacionais e internacionais que determinam as exigências para o mercado. Os padrões definem, dentre outros parâmetros, a correlação entre o estado de maturação e as cores da superfície, dimensões, massa, forma, etc. Alguns deles incluem procedimentos invasivos, como a avaliação das cores da polpa; esses não serão considerados no presente trabalho, por se tratarem de procedimentos destrutivos.

A seleção e a classificação são processos disjuntos, mas complementares, consistindo de um conjunto de tarefas, iniciadas pela separação daqueles frutos que apresentam anomalias diversas, como formas irregulares, cor e/ou tamanho discrepantes, aderências ou irregularidades superficiais expressivas, marcas da ação nociva de insetos e pragas ou mesmo, a presença de corpos estranhos ao fruto. Feito isso, o produto pode ainda apresentar variações em suas propriedades que venham a prejudicar sua qualidade e conseqüentemente, o seu valor de mercado. Para conseguir uma maior uniformidade de propriedades, o produto pode ser classificado por massa, tamanho, forma e cor, segundo normas específicas (padrões comerciais).

Apesar da natureza tradicionalmente manual dessas tarefas, os produtores estão buscando a utilização de processos de automação, por ser a opção mais adequada uma vez que todos os frutos em devem ser avaliados dentro dos mesmos critérios. A repetição exaustiva associada à meticulosidade da operação são fatores limitantes aos humanos, assim, a seleção e classificação automática de frutas pode se constituir em um fator decisivo para promover a melhoria na qualidade (KADER, 1992).

O processo de classificação pela cor envolve a extração de informações espectrais úteis que refletem algumas propriedades das superfícies de objetos, onde se busca descobrir a melhor descrição conhecida ou modelo de classe para implementar a tarefa de reconhecimento. Para isso são empregados sistemas de visão computacional, que permitem

ainda, realizar a estimaco de volume e massa, anlise de formas, contagem, posicionamento espacial, estimaco de textura, etc. Os sistemas de automaco que utilizam viso computacional so geralmente robustos, podendo operar em regime de misso crtica, em alta velocidade (sobre-humana) com operao contnua e sem alteraco na qualidade resultante de sua ao, promovendo a objetividade da classificaco dos produtos (BROSNAN e SUN, 2004).

A relevncia da manga *Tommy Atkins* no cenrio mercadolgico, aliada  carncia de sistemas de automaco para seleo e classificaco de produtos agrcolas no Brasil, so elementos que impulsionam a investigaco cientfica e o desenvolvimento desses mecanismos, que dentre outras coisas, trazem os seguintes benefcios (ZHANG, 2013):

- **Apresentaco:** melhorar a apresentaco do produto, uniformizando as caractersticas de tamanho, cor e forma, contribui para incrementar sua atratividade;
- **Desempenho controlvel e constante:** O desempenho das mquinas se mantm linear e independente do fator tempo, desde que o regime de manuteno seja obedecido. Durante sua ao (regime de produo), a resposta do sistema  a mesma (constante);
- **Agregaco de valor:** permitir recompensar economicamente produtos com qualidade superior, estimulando sua contnua melhoria;
- **Economia e sade:** evitar que produtos inadequados ao consumo sejam transportados e cuidados para depois serem descartados, evitando trabalho intil, assim como a contaminao de produtos sadios por aqueles contaminados com fungos e/ou bactrias;
- **Reduo de custos de pessoal:** Atravs da substituo de mo de obra humana em tarefas repetitivas, enfadonhas, perigosas, etc.
- **Otimizaco da distribuo:** economizar tempo de negociao e manuseio do produto at o consumidor final, reduzindo perdas ps-colheita e contribuindo para maior valor nutricional das hortalias;
- **Adequaco ao mercado:** Obteno de respostas rpidas s demandas do mercado, tanto em quantidade, quanto em qualidade, processamento de novos produtos, etc.
- **Satisfao do consumidor:** atender melhor ao consumidor, que compra um produto que corresponde plenamente ao seu desejo quando se decidiu pela compra.

## 1.1. Objetivos

O objetivo geral deste trabalho é o desenvolvimento de métodos para análise de atributos de qualidade de um produto específico – A manga da variedade *Tommy Atkins*.

Os métodos aqui definidos são 2:

- 1º Avaliação pela cor: Neste método as imagens são analisadas da superfície da fruta, possibilitando sua classificação em qualquer um dos padrões de cores existentes ou que venha a ser criado, permitindo inclusive a definição de novos padrões.
- 2º Avaliação pela forma: Método de estimativa de características físicas da manga: Neste método estão incluídos mecanismos de seleção que promovem a estimativa da maturidade, do volume e da massa, além de indicar a localização do pedúnculo e detectar a ocorrência de manchas negras.

### 1.1.1. Objetivos específicos

Para alcançar os objetivos deste trabalho, torna-se necessário desenvolver:

- Um método de aprendizagem de padrões de classificação pela cor, capaz de identificar os frutos de acordo com um determinado padrão;
- Um método que permita identificar a localização espacial do pedúnculo da manga;
- Um método para detecção de manchas pretas na superfície das mangas;
- Um método para estimar a massa e do volume da manga a partir de imagens;
- Um método para estimar a maturidade por lógica nebulosa;

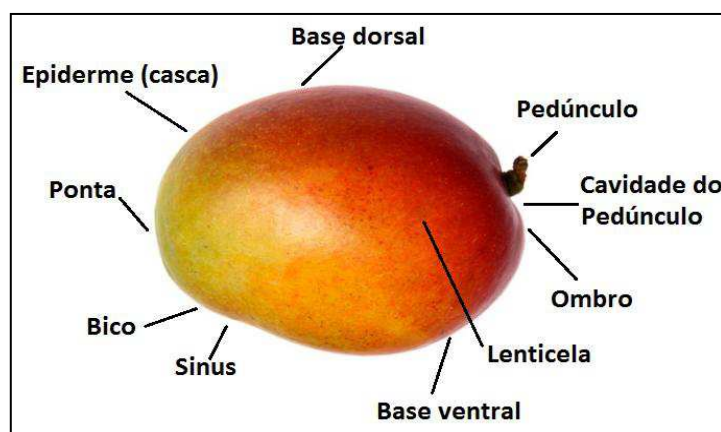
## 2. REVISÃO BIBLIOGRÁFICA

### 2.1. A manga Tommy Atkins

O estudo da manga *Tommy Atkins* foi a primeira atividade relacionada à pesquisa neste trabalho, tendo se constituído em parte importante para a sua definição. A motivação deste trabalho emergiu a partir do conhecimento da relevância dessa fruta para mercado mundial, combinado com a necessidade de melhorias nos sistemas pós-colheita atualmente empregados, principalmente no que diz respeito à automação dos métodos de seleção e classificação. O conteúdo resultante desse estudo que se refere a características da manga relevantes para o desenvolvimento dos métodos de análise está inserido nesta parte; outras informações que inclui a análise da biologia da fruta, origem, introdução e disseminação no Brasil, os sistemas de produção, etc foram incluídas incluem no Apêndice I.

O nome da fruta vem da palavra “*Malayalam manga*”. Foi trazida para a Europa pelos portugueses que colonizaram o sudoeste da Índia no século XV, e que conheceram a fruta em Kerala, no extremo sudoeste da Índia (SIMÃO, 1960).

É sem dúvida, um dos melhores e mais largamente aproveitados frutos de origem tropical cultivados no mundo, se posicionando logo após a banana, o abacaxi e o abacate (PSF, 2012).



**Figura 2.1-1:** A manga e sua morfologia interna. Fonte: Montagem do autor

A manga se apresenta em várias formas geométricas similares, variando, segundo sua variedade. As formas vão o arredondado ao alongado. Seu comprimento pode variar de 2,5 cm a pouco mais do que 30 cm, dependendo da variedade.

Sua massa pode também variar enormemente, indo de poucas gramas e chegando até dois quilos. O endocarpo (caroço) é lenhoso, grosso e fibroso, com as fibras do mesocarpo emergindo a partir do endocarpo.

A semente é achatada, interna ao caroço, de tamanho variável. A polpa é de espessura variável, carnosa, suculenta, comestível, de coloração amarela ou amarelo-alaranjada, fibrosa em algumas variedades (NETO, 2012). As dez principais estruturas da morfologia externa da manga estão indicadas na Figura 2.1-1; algumas dessas estruturas se apresentam de forma bastante discretas em alguns frutos e bem definidas noutros, como é o caso do bico e da cavidade peduncular.

As variedades comerciais mais conhecidas e exportadas têm as seguintes características: *Haden*<sup>1</sup>: superfície amarelo-avermelhada, massa médio 480 gramas; *Tommy Atkins*: superfície vermelho-verde/amarelada, massa média de 580 gramas e *Keitt*<sup>2</sup>: superfície amarelo-esverdeada, massa média de 600 gramas.

### 2.1.1. Fases do desenvolvimento

Os produtos agrícolas, como frutas e hortaliças, se mantêm vivos mesmo após serem colhidos e seus processos biológicos vitais continuam ativos por períodos que variam de uma espécie para outra.

Existe um período no qual o fruto se apresenta com as melhores condições tanto para colheita quanto para o consumo; esse período é definido por um conjunto específico de condições, que dependem do fruto e da finalidade da colheita.

O desenvolvimento desses produtos tem início desde o rebento e passa por vários estádios ou eventos, seguindo até a morte.

Uma das fases mais interessantes é a maturação; nesta fase, ocorrem uma série de transformações bioquímicas, tais como a diminuição da acidez, aumento dos teores de açúcares, alterações na cor e aroma, entre outras. O aumento do tamanho ocorre fundamentalmente devido ao acúmulo de água.

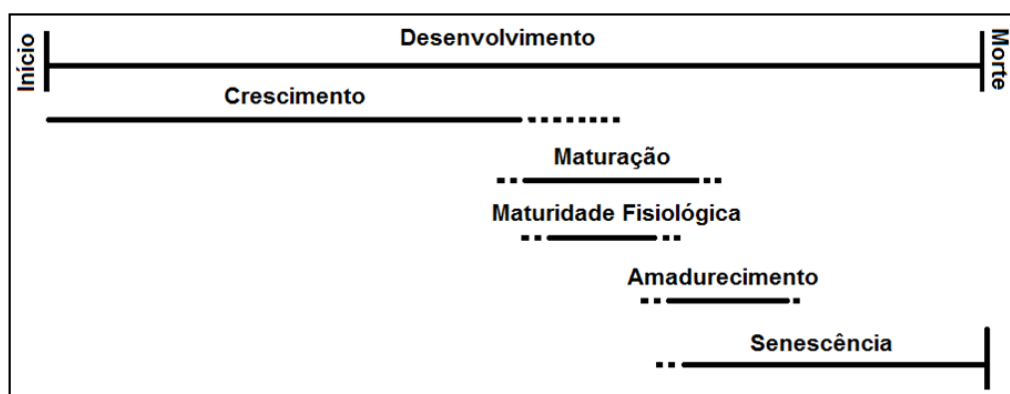
As fases do desenvolvimento e suas relações temporais, divididas em um conjunto de seis estádios, são apresentadas na Figura 2.1-2.

---

<sup>1</sup> É considerada a manga-pai da *Tommy Atkins*

<sup>2</sup> A manga *Keitt* é considerada uma irmã próxima da *Tommy Atkins*





**Figura 2.1-2:** Estágios do desenvolvimento dos frutos. Fonte: Extraído de ALMEIDA (2007).

ALMEIDA (2007) e MEDINA (1995) estabelecem o perfil de desenvolvimento para os estágios de maturidade, afirmando que de acordo com as mudanças metabólicas ao longo do seu desenvolvimento, a ontogenia dos frutos pode ser dividida nos seguintes estádios:

1. **Juvenildade:** fase caracterizada pelo rápido crescimento celular da fruta, com elevada atividade respiratória e baixa relação Carbono-Nitrogênio (C/N).
2. **Amadurecimento ou adolescência:** fase caracterizada por alta razão de crescimento, redução das taxas respiratórias, produção de compostos voláteis aromáticos e aumento da relação C/N.
3. **Maturação ou climatérico:** é um estado intermediário do desenvolvimento que leva à maturidade fisiológica (estado em que o fruto pode ser colhido sem prejuízo da continuidade do seu desenvolvimento - ascensão climatérica), caracterizado pelo conteúdo médio de amido e alta relação C/N.
4. **Senescência:** existe nesta fase uma série processos que ocorrem após a maturidade fisiológica e levam à morte dos tecidos; é um período pós-climatérico, redução no teor de sacarose, aumento na glicose, com alta elevação da relação C/N.

As mangas são geralmente colhidas no início da sua maturidade fisiológica; a partir de então, procedimentos pós-colheita devem ser aplicados no sentido de manter latente sua vitalidade. A morte da fruta se dá ao final da senescência, quando cessa sua respiração (WATADA *et al.*, 1984).

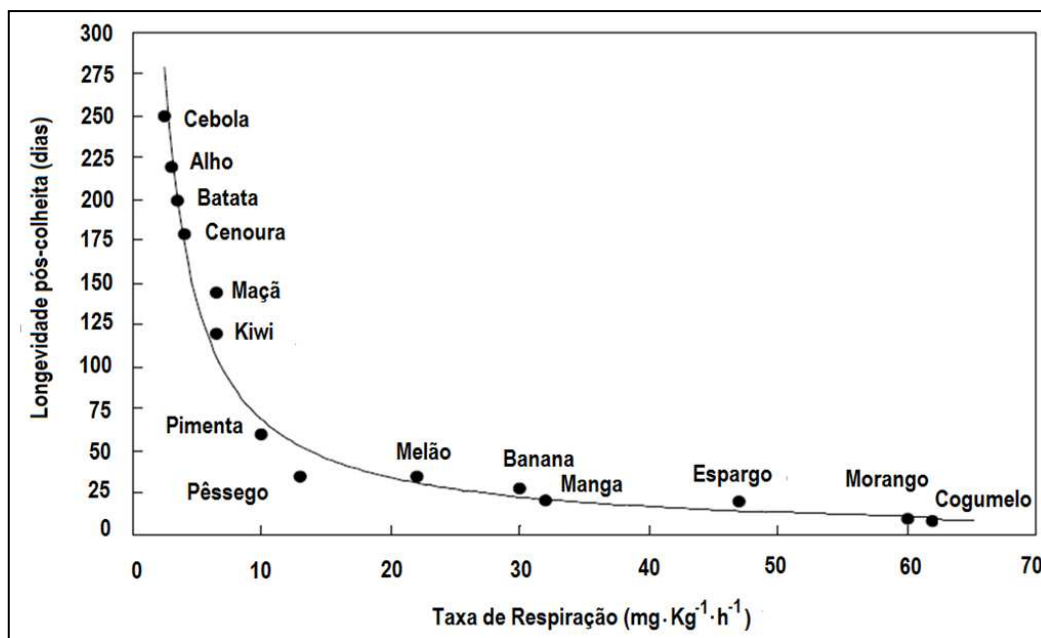
### 2.1.2. A relação respiração × pericibilidade

A respiração pode ser considerada o principal fator envolvido na fisiologia pós-colheita desses produtos, caracterizando-se como o processo de queima dos compostos energéticos das plantas, obtidos pela fotossíntese, como açúcares e amido, transformando e canalizando essa

energia para outras atividades vitais da planta, como o seu metabolismo (CALBO *et al.* - 2007).

A respiração é muito importante porque influencia no período de colheita e na degradabilidade dos frutos e, por conseguinte, os procedimentos pós-colheita, como a armazenagem. A longevidade pós-colheita dos frutos é inversamente proporcional à taxa de respiração.

Durante a fase de amadurecimento, ao final do desenvolvimento ou maturação de alguns frutos, ocorre um aumento na taxa de respiração, fenômeno que se denomina “climatério”. Os frutos “climatéricos” são aqueles que no final do seu período de maturação, apresentam significativo aumento na sua taxa de respiração, provocado pelo aumento da produção de etileno. Os valores mais altos das taxas respiratórias definem para esses frutos, sua maturidade fisiológica. Já os frutos “não-climatéricos”, apresentam declínio lento e constante de sua taxa respiratória após a colheita, de maneira independente do período de maturação no qual foram colhidos, devido às suas baixas produções de etileno. Esses frutos não podem ser colhidos antes de sua maturação, pois sua senescência se inicia com a colheita.



**Figura 2.1-3:** Longevidade pós-colheita de frutos em função da taxa de respiração. Fonte: Extraído de ALMEIDA (2007).

A Figura 2.1-3 apresenta a relação respiração X longevidade pós-colheita de alguns frutos, incluindo a manga (ALMEIDA, 2007), que é um fruto climatérico e de baixa longevidade, como pode ser notado pelo pequeno intervalo entre a colheita e a senescência dessa fruta, sem procedimentos próprios de armazenagem, que é inferior a 25 dias; por isso, a

rapidez do seu processamento para disponibilização ao mercado define sua viabilidade comercial.

### **2.1.3. A cor da superfície**

A cor da superfície é considerada um dos fatores externos mais importantes da qualidade de frutos, pois é o instrumento que determina de maneira mais rápida, a empatia dos consumidores, sendo ainda considerada como um critério relevante para julgar sua maturidade (AWAD, 1993).

Vários critérios são utilizados para a determinação da maturidade de frutos; em sua grande maioria, são baseados na aparência (tamanho, diâmetro, cor), geralmente aferidos por métodos não destrutivos, e também na sua composição química (sólidos solúveis, acidez titulável). É importante ressaltar que esses critérios possuem índices que podem variar consideravelmente, dependendo de fatores como o local de cultivo, as cultivares utilizadas e as condições meteorológicas durante seu crescimento (BIALE e YOUNG, 1964).

É durante o amadurecimento da manga que ocorre a mudança na cor da superfície. No caso da variedade *Tommy Atkins*, a mudança consiste inicialmente, da mudança do verde oliva característica dos estágios iniciais do desenvolvimento do fruto, para a cor verde clara brilhante; posteriormente, desaparece a cor verde, surgindo várias cores que vão do violeta, passando para o vermelho até o amarelo, predominante nos estágios avançados da maturação e durante a senescência (BROISLER, 2007). Essas cores são oriundas das sínteses de pigmentos, como os “carotenoides” e os “flavonoides” (antocianinas) associados à degradação da clorofila (AWAD, 1993).

Carotenóides (KAUFMAN, 2013) são substâncias químicas relacionadas ao caroteno, que são pigmentos amplamente difundidos na natureza. Caracterizam-se por apresentar moléculas oxidáveis, exibir cores que vão do amarelo ao vermelho.

Flavonoides (BEHLING *et al.*, 2004) são os pigmentos vegetais mais importantes para a coloração de flores e frutos, produzindo pigmentação amarela ou vermelho/azul em pétalas, cuja função natural é promover a atração de animais polinizadores.

### **2.1.4. A classificação de frutas**

A classificação é “o ato de determinar as qualidades intrínsecas e extrínsecas de um produto vegetal, com base em padrões oficiais, físicos ou descritos”. Essa definição é

encontrada na lei Nº 9.972 de 25 de maio de 2000, que institui a classificação de produtos vegetais, subprodutos e resíduos de valor econômico, dentre outras providências.

A classificação de produtos agrícolas é obrigatória e deve ser realizada pelos órgãos dos setores público e/ou privado, através de credenciamento junto ao Ministério da Agricultura, Pecuária e Abastecimento.

Os produtos agrícolas são caracterizados por um conjunto de atributos, divididos em duas classes: atributos quantitativos e atributos qualitativos. Os quantitativos referem-se ao tamanho e a massa, e os qualitativos abrangem a forma, coloração natural, turgidez, grau de maturação, sinais de danos mecânicos, ataques de doenças e pragas, presença de resíduos de produtos químicos e sujeira.

Os padrões são modelo estabelecido sobre os produtos agrícolas em função dos limites dos atributos desses produtos, e servem como referência para a avaliação. Além disso, a padronização pode abranger outros aspectos, referentes aos processos de embalagem, identificação, comercialização, etc. Os atributos gerais de um padrão são (WALTER, 2010):

- Utilizar o lote como unidade de trabalho, considerando possíveis variações no seu tamanho (fragmentação).
- Promover a homogeneidade do lote (aspecto visual, massa).
- Utilizar atributos mensuráveis do produto.
- Atender às exigências do mercado consumidor, sendo aplicável por parte do produtor.
- Promover a valoração do produto no mercado.
- Considerar a evolução característica do produto durante todo o processo de comercialização.

Os padrões para classificação são estruturados da seguinte forma:

- **Grupo e Subgrupo:** agrupa os cultivares com características de variedade semelhantes.
- **Classe e Subclasse:** Estabelece os parâmetros para garantir a homogeneidade visual, de tamanho, massa e maturação.
- **Categoria:** Estabelece níveis de qualidade, através de tolerâncias (%) diferentes sobre os defeitos graves, leves e variáveis e à obediência a padrões mínimos de qualidade para alguns atributos.

### 2.1.5. Defeitos em mangas

As perdas pós-colheita de frutos tropicais no Brasil são grandes, dentre as maiores do mundo, chegando a 30% do total de produtos comercializados. As mangas apresentam defeitos que são causados por fatores diversos nos processos pré e pós-colheita; esses defeitos variam em severidade quanto em quantidade (área ou volume afetados), podendo ainda ocorrer simultaneamente nos frutos, em qualquer etapa da produção, sendo classificados em dois grandes grupos (SOUZA *et al.*, 2010):

- **Bióticos:** abrangem os danos causados por agentes vivos, como doenças, pragas e desordens fisiológicas. São de extrema importância para a segurança alimentar do consumidor e influenciam o tempo vida pós-colheita dos produtos. Dentre as causas promotoras de perdas fitopatológicas, as doenças causadas por fungos ocorrem com maior frequência e intensidade, sendo responsáveis por perdas que chegam a uma média de 85% do total das perdas causadas por fitopatógenos. Dentre as principais doenças que acometem as mangueiras, estão incluídas a Antracnose, a Podridão seca (*Lasiodiplodia theobromae*), a Malformação vegetativa e floral (*Fusarium subglutinans* / *F. sacchari*), a Mancha-angular (*Xanthomonas campestris* *pv.* *mangiferae indicae*), a Seca-da-mangueira (*Ceratocystis fimbriata*), o Oídio (*Oidium mangiferae*) e o Colapso interno. Já as principais pragas que atacam a manga são as saúvas (*Atta spp.* e *quemquês* - *Acromyrmex spp.*), as moscas-da-fruta (*Anastrepha obliqua*, *Anastrepha fraterculus*, *Ceratitis capitata*), a colchonilha branca (*Aulacaspis tubercularis*), a arapuá (*Trigona spinipes*) e o besouro amarelo (*Costalimaita ferruginea vulgata*).
- **Abióticos:** referem-se aos danos causados por fatores não bióticos, como os danos físicos e mecânicos; esses danos estão relacionados às deformações mecânicas ou plásticas, com repercussões incidentes na parte mais exterior do fruto, que são originadas em resposta à forças de origem externa, como a aplicação de pressões sobre a superfície externa do fruto, exercida por outro fruto, paredes das embalagens etc. Geralmente, os cortes, ferimentos ou abrasões são originados de colisões entre as superfícies dos frutos e objetos ásperos que provocam a ruptura da epiderme.

### 2.1.6. A classificação de mangas

A qualidade da manga deve merecer atenção em todas as fases de sua produção e comercialização. A adoção da Produção Integrada de Frutas (PIF), apresentada no apêndice I,

apresenta-se como um caminho seguro para obter produtos que agregam qualidade e custo reduzido, porém, nem sempre os produtos agrícolas chegam aos compradores dentro das melhores condições.

Para a comercialização de produtos de qualidade, existe um grande número de certificações exigíveis para a sua importação, cada um deles com seu próprio protocolo de exigências; essas exigências são invariavelmente relacionadas a uma série de atributos de qualidades genéricos, aplicáveis a uma grande variedade de produtos. Esses atributos permitem então verificar a qualidade da manga, como mostra o Quadro 2.1-1. Deve ser observado que esses atributos são verificados tanto pelo fornecedor, quanto pelo comprador.

**Quadro 2.1-1:** Requisitos de qualidade para mangas. Fonte: Adaptado pelo autor a partir de BORGES (2011), (FILGUEIRAS, 2000).

<b>Atributos de qualidade - Requisitos mínimos</b>	
<b>Requisito</b>	<b>Descrição</b>
Forma.	O pedúnculo não deve apresentar tamanho superior a 10mm.
Consistência.	Firmeza, sem regiões moles.
Higiene.	Livre de insetos ou doenças que afetam sua qualidade interna.
Integridade.	Inteiro, livre de danos mecânicos e de umidade externa anormal.
Frescor.	Frutos devem estar frescos.
Cheiro e sabor.	Livre de odores ou de sabores estranhos.
Limpeza.	Livres de qualquer matéria estranha visível.
Segurança.	Livre de contaminadores.
Cores	Apresentar as cores características, livres de manchas negras ou manchas que se prolonguem para abaixo da superfície.
<b>2. Requisitos de Maturação</b>	
<b>Requisito</b>	<b>Descrição</b>
Estádio de maturação	Deve estar suficientemente desenvolvido e apresentar maturação adequada.
Tabela de cores.	Varia de acordo com o padrão; distribuição de cores varia de acordo com diferentes estádios de maturação.
Outros critérios da maturação.	TSS, pH, acidez, etc.

## Continuação...

**Quadro 2.1-1:** Requisitos de qualidade para mangas. Fonte: Adaptado pelo autor a partir de BORGES (2011), (FILGUEIRAS, 2000).

<b>3. Requisitos de Classificação</b>	
<b>Requisito</b>	<b>Descrição</b>
Critérios de classificação de produtos em diferentes categorias.	Tamanho e massa da fruta.
	Sem considerar tamanho, massa e cor, as mangas são classificadas em: <ul style="list-style-type: none"> <li>• Classe Extra: Livre de defeitos e com até 5% de unidades fora do padrão (em número ou massa).</li> <li>• Classe I: Com defeitos, desde que não cubram mais do que 10% da superfície.</li> <li>• Classe II: Com defeitos, desde que não cubram mais do que 15% da superfície.</li> </ul>
<b>4. Requisitos de Tolerância</b>	
<b>Requisito</b>	<b>Descrição</b>
Tolerâncias admissíveis.	Conforme Tabela. 2.1-1
<b>5. Requisitos de Apresentação</b>	
<b>Requisito</b>	<b>Descrição</b>
Uniformidade.	O conteúdo de cada caixa deve ser uniforme, com cores, massa e tamanho aproximados.
Embalagem.	A embalagem deve proteger adequadamente as frutas.
<b>6. Requisitos de Etiquetamento</b>	
<b>Requisitos</b>	<b>Exemplos</b>
Empacotamento para grosso ou varejo.	Etiquetas devem atender à legislação específica.
Manga embalada para venda direta	Informar: Calibre e categoria. A palavra "manga", seguida da marca comercial do produto (quando houver). Identificação da variedade ou da cultivar ou do nome comum da manga. Identificação do lote. Nome empresarial, o registro no Cadastro Nacional de Pessoa Jurídica (CNPJ) ou no Cadastro Nacional de Pessoa Física (CPF) e o endereço da empresa embaladora ou do responsável pelo produto.
Manga a granel no varejo	Deverá ser identificada e as informações colocadas em lugar de destaque, contendo, no mínimo, a palavra manga seguida da variedade ou da cultivar ou do nome comum e a origem do produto.

**Continuação...**

**Quadro 2.1-1:** Requisitos de qualidade para mangas. Fonte: Adaptado pelo autor a partir de BORGES (2011), (FILGUEIRAS, 2000).

<b>7. Contaminantes</b>	
<b>Requisitos</b>	<b>Exemplos</b>
Metais Pesados.	Deve atender aos requisitos de níveis máximos de metais pesados.
Resíduos de Pesticidas.	Deve atender aos requisitos de níveis máximos de resíduos.
<b>8. Higiene</b>	
Os produtos devem estar de acordo com os códigos de recomendação internacionais.	

**Tabela 2.1-1:** Limites máximos de tolerâncias por categoria. Fonte: Adaptado pelo autor a partir de BORGES (2011), FILGUEIRAS (2000).

<b>ENQUADRAMENTO / DEFEITO</b>	<b>Extra</b>	<b>Categoria I</b>	<b>Categoria II</b>	<b>Fora de Categoria</b>
Deformação (% de frutas)	0	5	10	Maior que 10
Dano mecânico (% de frutas)	0	10	20	Maior que 20
Dano profundo (% de frutas)	0	0	5	Até 15
Queimadura por sol (% de frutas)	0	0	5	Até 10
Dano por inseto (% da área atingida)	0	5	10	Até 33
Distúrbio fisiológico (% de frutas)	0	5	10	Até 20
Imatura, Passada e Podridão (% de frutas)	0	0	2	Até 5
Mancha difusa (% da área atingida)	5	15	25	Até 50
Mancha escura (% da área atingida)	3	4	5	Até 15
Mancha rugosa (% da área atingida)	2	4	6	Até 20
Mancha profunda (% da área atingida)	2	3	4	Até 8

BORGES (2011) apresenta uma compilação de componentes para um padrão de avaliação de qualidade para frutas e verduras frescas. Essa compilação foi adaptada para incluir especificações da Instrução Normativa (I.N) N° 38, de 19 de dezembro de 2012, além das considerações encontradas em FILGUEIRAS (2000), resultando nos requisitos apresentados no Quadro 2.1-1 e na Tabela 2.1-1.

### **2.1.7. Doenças e pragas da mangueira**

O Ministério da Agricultura, Pecuária e Abastecimento do Brasil (MAPA), possui um catálogo para as pragas e doenças de frutas, incluindo a mangueira; tanto os insetos quanto as doenças estão catalogadas sob o indexador geral "Pragas". Existem vinte e três insetos (Quadro 2.1-2) e oito doenças (Quadro 2.1-3) oficialmente classificados.



**Quadro 2.1-2:** Insetos que atacam a mangueira. Fonte: Adaptado de BARBOSA (2013).

<b>Agente (Inseto)</b>	<b>Nome popular</b>
<i>Aethalion reticulatum</i>	Cigarrinha-das-frutíferas ou Cigarrinha-do-pedúnculo
<i>Anastrepha fraterculus</i>	Mosca-das-frutas ou Mosca-Sul-Americana
<i>Anastrepha obliqua</i>	Mosca-das-frutas.
<i>Anastrepha pseudoparallela</i>	Mosca-das-frutas.
<i>Aulacaspis tubercularis</i>	Cochonilha-branca.
<i>Bactrocera carambolae</i>	Mosca-da-carambola
<i>Ceratitidis capitata</i>	Mosca-das-frutas ou Mosca-do-mediterrâneo.
<i>Chrysomphalus dictyospermi</i>	Cabeça-de-prego-rosa ou Cochonilha-cabeça-de-prego.
<i>Costalimaita ferruginea vulgata</i>	Besouro-amarelo.
<i>Crimissa cruralis</i>	Besouro-vermelho.
<i>pleuroprucha asthenaria</i>	Traça dos cachos.
<i>Sternocolaspis quatuordecimcostata</i>	Besouro-de-limeira.
<i>Trigona spinipe</i>	Abelha-arapuá ou Irapuá.
<i>Eriophyes mangiferae</i>	Ácaro-da-mal-formação-das-gemas ou Eriofídeo-da-mangueira.
<i>Erosomyia mangiferae</i>	Cecidomiídeos.
<i>Hypocryphalus mangiferae</i>	Broca-da-mangueira.
<i>Leptoglossus stigma</i>	Percevejo-das-frutas.
<i>Megalopyge lanata</i>	Lagarta-de-fogo ou Taturana
<i>Pinnaspis aspidistrae</i>	Cochonilha-escama-farinha
<i>Pseudaonidia trilobitiformis</i>	Cochonilha
<i>Pseudococcus adonidum</i>	Cochonilha ou Cochonilha-pulverulenta
<i>Saissetia coffeae</i>	Cochonilha-parda
<i>Selenothrips rubrocinctus</i>	Tripes-do-cacaueiro

**Quadro 2.1-3:** Doenças que atacam a mangueira. Fonte: Adaptado de BARBOSA (2013).

<b>Agente (Doença)</b>	<b>Nome popular</b>
<i>Botrytis cinerea</i>	Mofo-cinza ou Podridão-da-flor.
<i>Ceratocystis fimbriata</i>	Seca-da-mangueira.
<i>Colletotrichum gloeosporioides</i>	Antracnose.
<i>Elsinoe mangiferae</i>	Verrugose-da-mangueira.
<i>Glomerella cingulata</i>	Antracnose.
<i>Helicotylenchus dihystra</i>	Nematóide espiralado.

**Continuação...**

**Quadro 2.1-3:** Doenças que atacam a mangueira. Fonte: Adaptado de BARBOSA (2013).

<i>Lasiodiplodia theobromae</i> ; <i>Fusicoccum aesculis</i> ; <i>Neofusicoccum parvum</i> .	Podridão-de-frutos; podridão peduncular.
<i>Oidium mangiferae</i>	Cinza ou Oídio.


### 2.1.8. Manchas pretas na superfície da manga

Algumas das doenças e pragas que atacam a manga causam o surgimento de manchas negras sobre a superfície da fruta; esse é um fato relevante, tanto que é referenciado em mais de uma entrada na lista de defeitos especificados na Tabela 2.1-1, sendo de especial interesse para um dos objetivos deste trabalho de Tese. Por este motivo, são apresentados em seguida, alguns dos mais importantes agentes causadores de danos para a manga e seus respectivos efeitos:

### 2.1.9. Doenças que causam manchas pretas

#### 2.1.9.1. Antracnose

A antracnose é a principal doença que atinge a mangueira nos estágios pré e pós-colheita.



**Figura 2.1-4:** Manga atacada pela Antracnose. Fonte: Extraído de BATISTA (2010).

A antracnose é causada pelo fungo *Colletotrichum gloeosporioides* e se manifesta inicialmente, na forma de manchas pardo avermelhadas, que podem se estender por todo o fruto; em seguida, surgem pontos escuros. Nesse ponto, a doença pode ser confundida com outras, como a podridão amarga e a sarna da manga. Os frutos afetados ficam enrugados e caem (KIMARI, 1980).

A incidência de infecção por esse agente patogénico é favorecida por temperaturas variando entre 20 e 30 °C, associada à uma alta humidade, superior a 95 %, além da suscetibilidade da planta hospedeira, considerando sua variedade. Essa doença ocorre em muitas espécies vegetais além da mangueira, como o abacateiro e o cajueiro, e não é comum em regiões quentes e secas, tendo pouca importância no Nordeste brasileiro.

Os frutos são afetados em todas as fases, mesmo após a colheita; a antracnose pode permanecer latente no fruto atacado e suas lesões só serão notadas posteriormente, durante o armazenamento, quando a fruta está em fase de maturação; essas lesões são normalmente restritas à superfície, porém, nos casos onde o ataque é mais severo, o fungo atinge a polpa, como mostra a Figura 2.1-4 (BATISTA, 2010).

### 2.1.9.2. Mancha angular

A mancha angular é uma doença causada pela bactéria patogénica *Xanthomonas campestris pv. mangiferae indica*, que causa danos económicos para produtores dos países da Ásia e do Pacífico. Ela sobrevive em brotações recentes e é disseminada principalmente pela ação das águas de chuvas, respingos da irrigação ou de insetos.



**Figura 2.1-5:** Manga atacada pela mancha angular. Fonte: Extraído de [www.infonet-biovision.org](http://www.infonet-biovision.org).

Geralmente provoca danos em todas as peças da planta localizadas acima da superfície, que são afetadas pela infecção através de ferimentos e aberturas naturais, sendo a alta humidade e a alta temperatura, condições favoráveis à sua proliferação. Os sintomas mais comuns ocorrem em folhas e frutos, embora algumas vezes cancrios apareçam em galhos e arbustos em infecções mais severas (TAVARES *et al.*, 2005) .

Nos frutos, as lesões são geralmente circulares, com coloração verde-escura, chegando a confundir com uma mancha preta (daí o seu nome em inglês: *Bacterial Black Spot*), como

mostra a Figura 2.1-5. Rachaduras ocorrem em toda a superfície na medida em que os frutos se desenvolvem. Quando a parte atacada é o pedúnculo, o fruto mumifica e murcha (BATISTA, 2010).

### 2.1.9.3. Verrugose

Os Frutos afetados pela verrugose, como o da Figura 2.1-6, apresentam lesões acinzentadas escuras ou marrons, de aspectos irregulares e salientes. Com o desenvolvimento dos frutos, as áreas afetadas são expandidas e podem apresentar fendas na parte central, expondo porções de tecido sadio.



**Figura 2.1-6:** Manga atacada pela Verrugose. Fonte: Plantwise.org.

Geralmente, os danos limitam-se à superfície, afetando a aparência, minando valor comercial, porém, em situações mais graves, as lesões atingem a polpa, inutilizando os frutos para o consumo.

### 2.1.9.4. Patógenos emergentes

Segundo BATISTA (2010), o emprego de várias práticas de manejo consideradas inadequadas para o cultivo da mangueira, tem propiciado o surgimento e a intensificação de doenças que até pouco tempo tinham baixa prevalência no submédio do Vale São Francisco.

Os patógenos *Alternaria alternata*, *Fusicoccum aesculis* e *Neofusicoccum parvum* têm provocado perdas importantes no pós-colheita; os sintomas em manga variam de acordo com o agente envolvido na infecção (fungo) e com a região da manga infectada. A fruta apodrece com a infecção que tem origem na região do pedúnculo ou na superfície do fruto.

No caso da podridão peduncular (Figura 2.1-7), mais de um fungo pode estar envolvido. Infecções pedunculares causados pelos agentes *L. theobromae*, *F. aesculis* e *N. parvum*, são semelhantes, tornando quase impossível a distinção do agente causal.



**Figura 2.1-7:** Podridão Peduncular. Fonte: Extraído de FILGUEIRAS (2000).



**Figura 2.1-8:** Manchas causadas por *Fusicoccum parvum*. Fonte: Extraído de FILGUEIRAS (2000).

Já as infecções na superfície da manga, causadas por *A. alternata*, *F. aesculis* e *N. parvum*, originam manchas que podem ser facilmente confundidas com a antracnose (Figura 2.1-8).

## 2.1.10. Pragas que causam manchas negras

### 2.1.10.1. Tripes


O Tripes (*F. schultzei*), mostrado na Figura 2.1-9, pertence à ordem *Thysanoptera*, família *Thripidae*; é um inseto de pequenas dimensões, medindo na sua fase adulta cerca de 1,5 mm de comprimento; tem coloração amarelada e asas franjadas. O ciclo de vida é muito

rápido, em média 15 dias entre as fases de ovo e adulto. As ninfas e os insetos adultos são raspadores-sugadores, e se alimentam do pólen e da seiva extravasada das pétalas das flores. (BARBOSA *et al.*, 2001), (MONTEIRO *et al.*, 2001).



**Figura 2.1-9:** O Tripes *Frankliniella Schultzei*. Fonte: Extraído de jsalmazo.com.br

Na mangueira, o tripses atua também como um polinizador da cultura, mas também danifica os frutos em formação, devido à grande infestação de insetos que atacam principalmente os chumbinhos, que são raspados e ficam com danos em forma de verrugas.



**Figura 2.1-10:** Manga atacada pelo tripses. Fonte: Extraído de FILGUEIRAS (2000).

A manga atacada apresenta injúrias na forma de manchas negras (Figura 2.1-10), que diminuem a qualidade estética da fruta, desvalorizando o produto (OLIVEIRA *et al.*, 2010).

O tripses está incluído entre as pragas importantes da mangueira, representando um grave problema fitossanitário (BARBOSA e PARANHOS, 2005).

## **2.2. Cores e imagens**

Nesta parte estão inseridas as informações pesquisadas sobre a formação de cores, indo desde sua origem como elemento de radiação eletromagnética, até o seu efeito biológico mais importante: a percepção e interpretação pelos mecanismos humanos. A pesquisa inclui os padrões estabelecidos para a manipulação da cor e alguns métodos construídos para sua

descrição e análise, concluindo com a formação da imagem, onde se apresenta uma breve discussão filosófica que enfatiza sua relevância como objeto de representação da realidade. Este estudo foi importante, sobretudo, para identificar o padrão de cor mais adequado para o emprego em análise de imagens para o caso específico deste trabalho, bem como definir o mecanismo para sua representação e análise.

### 2.2.1. A radiação eletromagnética

A radiação eletromagnética (REM) é resultante da emissão de pulsos de energia a partir de uma fonte, que formam ondas que se propagam pelo espaço; trata-se de uma oscilação, em fase, dos campos elétricos e magnéticos, configurando-se numa propagação de uma onda transversal, onde as oscilações são perpendiculares à direção do movimento da onda, que pode se deslocar através do vácuo. Esse modelo pode ainda ser visto na física quântica, como o deslocamento de pequenas partículas (fótons).

A REM não precisa de um meio material para se propagar, e desloca-se na forma de ondas eletromagnéticas à velocidade da luz (300.000 km/s). Uma vez que a velocidade de propagação das ondas eletromagnéticas é diretamente proporcional à sua frequência e comprimento de onda, esta pode ser expressa por:


$$c = f \cdot \lambda \quad (\text{Eq. 2.2-1})$$

Onde:

- $c$ : velocidade da luz: A velocidade da luz no vácuo, simbolizada pela letra  $c$ , é, por definição igual a 299 792 458 metros por segundo.
- $f$ : frequência: A frequência é uma grandeza física de natureza ondulatória, referindo-se ao número de ciclos ou oscilações que ocorrem em determinado intervalo de tempo; assim, sua unidade é (ciclos/s ou Hz (Hertz)).
- $\lambda$ : comprimento de onda: O comprimento de onda é definido como a distância entre valores idênticos repetidos de um fenômeno ondulatório; ou seja, é o comprimento de um ciclo.

Os valores de  $f$  e  $\lambda$  estão relacionados de maneira inversa, como mostra a Equação 2.2-1.

A sensação de cores percebidas pelo sistema visual humano está diretamente relacionada ao comprimento de onda da radiação, onde o maior comprimento de onda do espectro de radiação luminosa provoca a sensação de vermelho, e o menor, violeta..



**Figura 2.2-1:** Flutuações dos campos elétrico e magnético de uma onda. Fonte: Desenho do autor a partir de NOVO (1989).

A Figura 2.2-1 apresenta um esquema da representação dos campos elétrico e magnético e as oscilações mencionadas; o campo elétrico (E) oscila no eixo z e o campo magnético (B) no eixo x de um sistema cartesiano, onde (NOVO, 1989):

- yz: plano de excitação do campo elétrico
- xy: plano de excitação do campo magnético
- y: direção de propagação da onda eletromagnética

Parte do espectro da REM pode ser percebida através do olho de diversos animais; a essa porção do espectro eletromagnético, denomina-se “luz visível”. Dado que a faixa de frequências da luz visível é exatamente a qual o sol emite com maior abundância, pode-se deduzir que o ser humano e os animais tenham evoluído de tal forma a melhorar a sensibilidade à luz visível, pois assim obteria mais informações do meio onde está inserido (EISBERG e RESNICK, 1979).

## 2.2.2. A percepção da cor

### 2.2.2.1. O olho humano e seus componentes


O olho humano é o órgão que possibilita a visão, através da percepção da luz; ele está montado numa estrutura que possui a forma de um globo, que se encaixa na cavidade ocular denominada órbita, no esqueleto da face, e é protegido pelas pálpebras.

O olho possui uma lente convexa denominada “cristalino” (Figura 2.2-2), cujo papel é fazer convergir os raios de luz que por ela passa e conduzi-los para área sensível à luz denominada “retina”. O cristalino tem a capacidade de alterar sua forma, de maneira a ajustar



o foco do objeto visto, em função da distância em que ele se encontra. As câmaras fotográficas funcionam de maneira similar. Esta capacidade de variação do foco pelo cristalino denomina-se “poder de acomodação”. O cristalino é protegido do ambiente externo por uma película denominada “córnea”, e localiza-se logo atrás de uma estrutura que permite regular quantidade de luz incidente, através de um mecanismo de abertura e fechamento, denominado pupila (McMINN, 1990).

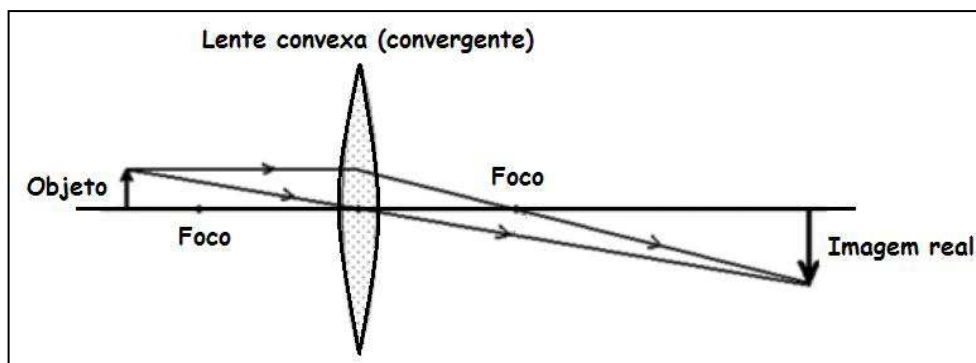
No exterior do olho, um grupo de seis músculos é responsável pelos movimentos oculares. Dentro do olho, a camada média é formada pela íris, a coroide, o corio, e o corpo ciliar. Finalmente, a camada mais interna é constituída pela retina.



**Figura 2.2-2:** Anatomia do olho humano. Fonte: ENCICLOPÉDIA Multimídia do Corpo Humano. Editora Planeta De Agostini.


A retina é o seu principal componente, sendo composta por células nervosas que levam a imagem através do nervo óptico para que o cérebro, que as interpreta. Existe ainda no olho, um “ponto cego”, assim denominado porque não existe nesse local nenhum receptor sensorial e, portanto, nenhuma resposta a qualquer estímulo por luz. (DANGELO e FATTINI, 2011).

Os raios de luz emitidos ou refletidos pelos objetos do ambiente entram no olho através da córnea, passando pela pupila, atravessando o cristalino e se concentrando sobre a retina, que transforma a luz em sinais nervosos. A imagem formada sobre a retina é invertida, pois a retina fica após o foco do cristalino. Como o cristalino é uma lente convexa, que concentra a luz no foco, os raios que passam desse foco são invertidos. Portanto, quando a imagem se forma após o foco, ela se torna invertida (Figuras 2.2-3, 2.2-4).



**Figura 2.2-3:** Inversão da imagem de um objeto pela lente convexa. Fonte: Abstração do autor.

O cérebro que decodifica estes sinais que lhe chegam através do nervo óptico, de forma a que se possa enxergar.



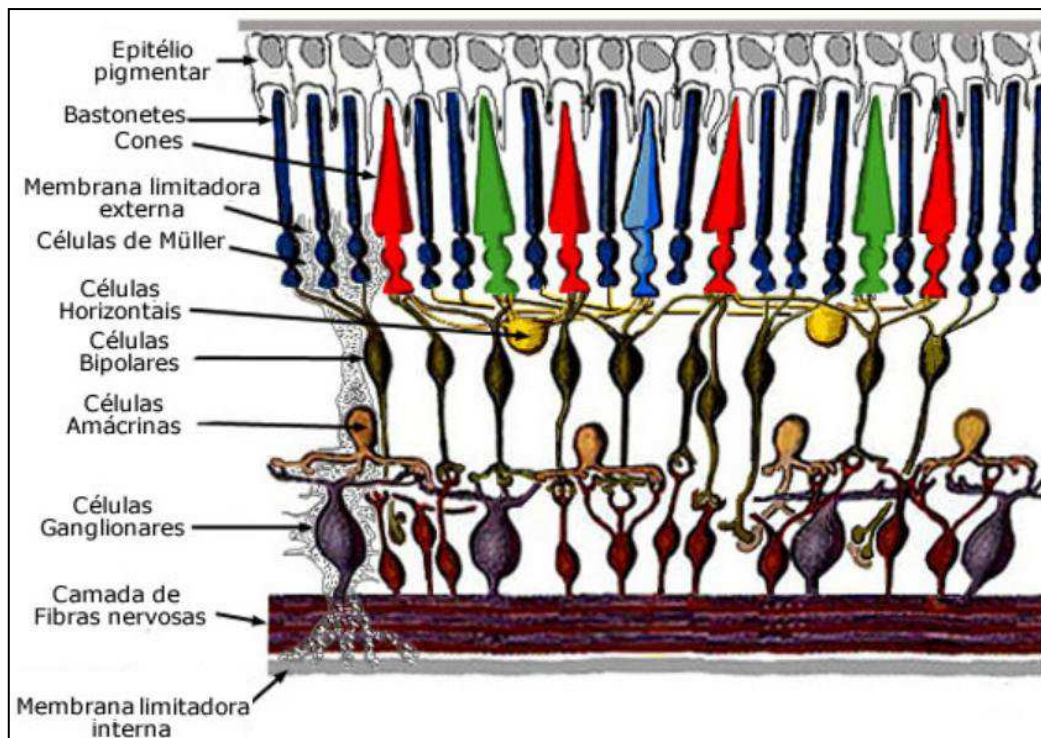
**Figura 2.2-4:** Projeção da imagem sobre a retina<sup>3</sup>. Fonte: Extraída de E-FISICA, (2013).

#### 2.2.2.2. O funcionamento do olho humano

O processo psicofisiológico da percepção de cores pelos humanos ainda não é inteiramente compreendido, mas o modelo proposto por Thomas Young, denominado “Modelo Tricromático”, que foi posteriormente verificado e consubstanciado pelo físico alemão *Hermann Von Helmholtz*, prevalece até hoje. Esse modelo é conhecido por “Teoria de *Young-Helmholtz*”.

De acordo com essa teoria, uma cor é a sensibilização de células especializadas da retina, por um determinado comprimento de onda da REM. A retina humana possui dois tipos de células: os cones, que são responsáveis pela percepção da cor e os bastonetes (Figura 2.2-5), que não distinguem cor, e são responsáveis pela visão noturna (THOMPSON e TROSKIANKO, 2011).

<sup>3</sup> Fonte: (E-FISICA, 2013).



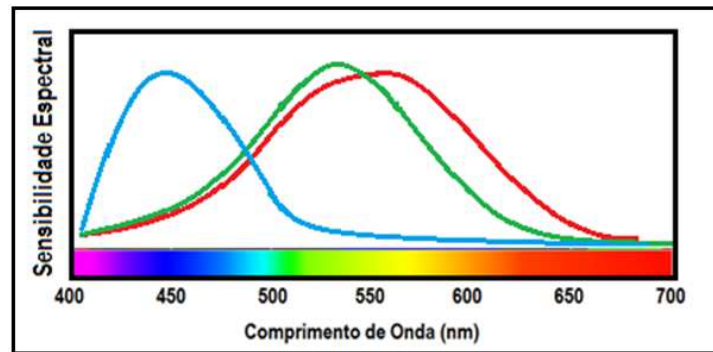
**Figura 2.2-5:** Anatomia da Retina – Disposição dos Cones e Bastonetes. Fonte: Extraído de EMMCH, (2005).

Os cones são células de três tipos distintos, e cada um deles responde a diferentes bandas do espectro colorido, ou seja, cada tipo de cone é sensível a um determinado comprimento de onda. Esses três tipos de cones distintos podem ser classificados da seguinte maneira:

- **Cone tipo S** - comprimentos de onda curtos, alcançando a cor azul, sensível à faixa compreendida entre 420 a 440 nm.
- **Cone tipo M** - comprimentos de onda médios, alcançando a cor verde, sensível à faixa compreendida entre 564-580 nm.
- **Cone tipo L** - comprimentos de onda longos, alcançando a cor verde, sensível à faixa compreendida entre 534-545 nm.

A sensibilidade espectral dos cones é apresentada no gráfico da Figura 2.2-6.

O conjunto de sinais possíveis dos três tipos de cones define a gama de cores que o Ser humano consegue perceber (por esse motivo, o homem é denominado “tricromata”). O gráfico da Figura 2.2-6 ilustra a sensibilidade relativa de cada um dos tipos de células cone para todo o espectro de luz (CAMBRIDGE 2013).

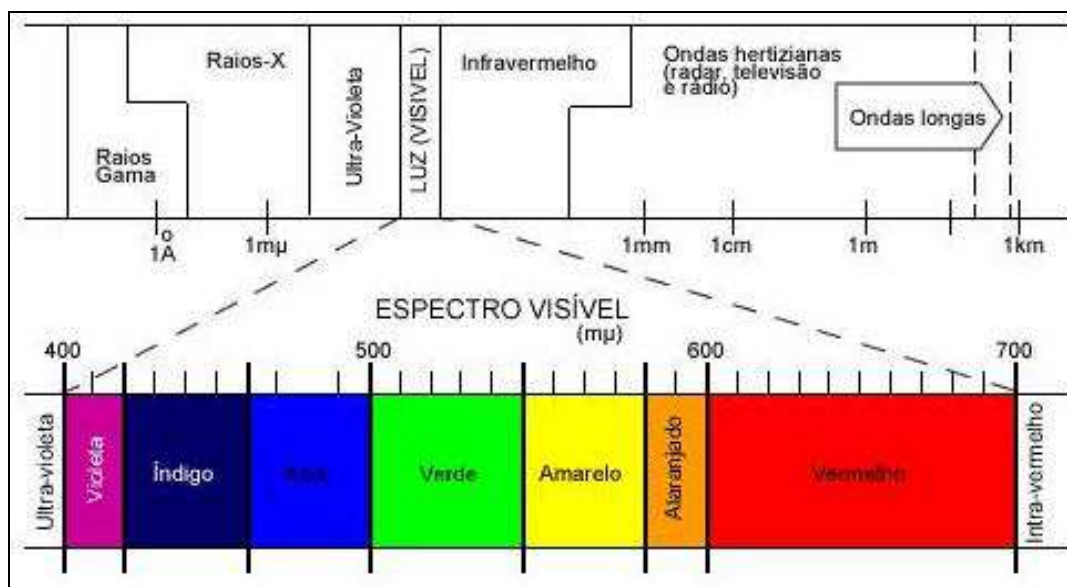


**Figura 2.2-6:** Sensibilidade das Células Cone à luz visível. Fonte: Extraído de SOUTO (2000).

### 2.2.3. A formação das cores

As cores são formadas por composições de diferentes matizes, através de diferentes modelos. As cores primárias são conjuntos de cores que podem ser combinadas para criar outras cores, e não se constituem numa propriedade fundamental da luz, mas geralmente estão relacionadas à resposta fisiológica do olho à luz.

Sir Isaac Newton foi o primeiro cientista a provar que a sensação de luz branca era o resultado da existência simultânea de "luzes" de vários matizes, através da refração dessa luz incidente num prisma. O fato de o prisma promover a decomposição da luz branca comprova a natureza ondulatória da radiação, devido à variação do índice de refração do prisma para diferentes comprimentos de onda ( $\lambda$ ).



**Figura 2.2-7:** Espectro dos comprimentos de onda da luz visível. Fonte: Extraído de SOUTO (2000).

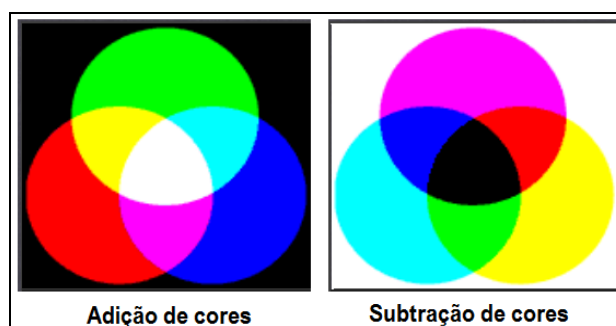
Cada matiz decomposto está associado a uma determinada frequência de radiação ou comprimento de onda.

A luz visível compõe uma estreita parcela do espectro eletromagnético, estendendo-se de 400 nm a 700 nm aproximadamente (Figura 2.2-7).

### 2.2.3.1. Cores aditivas e subtrativas

Praticamente todas as cores visíveis podem ser produzidas utilizando alguma mistura de cores primárias, por combinação “aditiva” ou “subtrativa”. O processo aditivo cria cores adicionando luz a um fundo preto; o processo subtrativo, inversamente, utiliza pigmentos ou tinturas para seletivamente, bloquear ou subtrair a luz branca.

Na Figura 2.2-8, as cores nos três círculos exteriores são chamadas de primárias e são diferentes em cada um dos diagramas. Aparatos que se baseiam em cores primárias para representar cores só podem produzir uma gama limitada de cores. Os monitores de vídeo de computador e os aparelhos de televisão, por exemplo, emitem luz para produzir cores através do processo aditivo; já as impressoras usam tinta, ou pigmento, para absorver a luz, através do processo subtrativo. Os círculos representando as cores primárias e secundárias do sistema aditivo apresentam em suas interseções, as cores resultantes da soma entre as cores dos círculos correspondentes; conforme SOUTO (2000), a luz branca é produzida na intersecção dos três círculos de cores, sendo uma composição entre as cores primárias; e mais, nenhuma das cores primárias pode ser produzida por qualquer mistura das outras duas; por isso são definidas como cores primárias aditivas. A mesma intersecção dos círculos de cores subtrativas resulta na ausência total de luz branca – o preto.



**Figura 2.2-8:** Processos de composição de cores. Fonte: Extraído de (CEPSRM, 2013).

Várias outras cores não primárias ou derivadas, são produzidas quando duas cores se misturam, como por exemplo, na combinação:

- vermelho + azul = magenta
- vermelho + verde = amarelo
- verde + azul = ciano

Com a variação da quantidade relativa das cores primárias, uma enorme gama de cores pode ser produzida. Usando-se filtros, as cores podem ser subtraídas da luz branca, obtendo-se as cores primárias subtrativas:

- subtração de vermelho = ciano
- subtração de verde = magenta
- subtração de azul = amarelo

A grande maioria dos dispositivos de adição de cores usa uma combinação das cores RGB. As impressoras, por sua vez, usam cores ciano, magenta e amarelo (cores CMY, de “cyan”, “magenta” e “yellow”). Algumas impressoras dispõem do cartucho de tinta preta, pois o CYM não reproduz o preto profundo; nesse caso, o padrão de cor se denomina CMYK, onde o K provém de “black”).

#### 2.2.4. Padrões de cores

##### 2.2.4.1. Padrão de cores CIE-RGB

Em 1931, o CIE (acrônimo de “*Commission Internationale de l'Eclairage*”) adotou um sistema de representação do espaço de cores, que é constituído por três cores denominadas primárias – Vermelho, Verde e azul. Os valores dessas cores no espectro visível são respectivamente: 435,8 nm, 546,1 nm e 700 nm (PEDRINI, 2008). Esse padrão é conhecido como CIE-RGB, ou simplesmente, RGB.


O modelo de espaço de cores RGB é provavelmente o mais usado entre os modelos de cores. A teoria do espaço de RGB (vermelho-verde-azul), de *Thomas Young* (1773-1829), é baseada no princípio de que diversos efeitos cromáticos são obtidos pela projeção da luz branca através dos filtros vermelho, verde e azul, e pela superposição de círculos nas cores projetadas (GONZALES E WOODS, 2010).

O espaço de cores RGB é tradicionalmente representado através de uma Figura geométrica denominada de “cubo das cores”, que é apresentada na Figura 2.2-10.

É possível identificar cada cor no sistema RGB por uma tripla ordenada (R, G, B) de números inteiros, onde cada cor é definida entre 0 (zero) e 255. A grande maioria dos arquivos digitais em uso utilizam números inteiros entre 0 e 255 para especificar estas quantidades; o 0 (zero) indica ausência de intensidade e o 255 indica o máximo de intensidade possível. Existem ainda outras representações que utilizam números reais; assim, é possível associar cada cor RGB a coordenadas inteiras de um cubo com arestas de tamanho 255. A cor

azul do padrão é apresentada na Figura 2-2.9, em toda a escala (0-255). Os zeros iniciais da tripla indicam a ausência das cores R e G.


Logo, no sistema RGB, as cores são definidas pela quantidade de vermelho (*Red*), verde (*Green*) e azul (*Blue*) que as compõem.



**Figura 2.2-9:** Representação da cor azul em 256 níveis de intensidade no padrão RGB. Fonte: Abstração do autor.

Pode-se notar na Figura 2.2-9, que uma representação em números reais poderia ser utilizada, já que a variação da intensidade da cor é contínua. Isso aumentaria indefinidamente a capacidade de representação do sistema de cores.

A representação num intervalo com 256 níveis discretos é suficiente para a percepção humana, pois dificilmente seria possível para o olho humano distinguir alguma diferença na intensidade da cor entre pontos vizinhos.




**Figura 2.2-10:** Cores diversas do Cubo RGB. Fonte: Extraído de CDMEUFF (2012).

Na Figura 2.2-10, os valores sobre os eixos R, G e B variam de 0 a 1 (normalizados), e os vértices do cubo representam as cores aditivas primárias e secundárias, à exceção dos vértices referentes ao preto e ao branco, onde estão localizados os tons de cinza.

Um problema inerente ao sistema RGB é que para representar todas as cores do espectro visível, existem valores negativos em algumas faixas de comprimento de onda. A Figura 2.2-

11 apresenta o gráfico dos componentes de cor RGB na faixa compreendida entre 350 e 700 nm; pode ser observado que a componente R apresenta um trecho com valores negativos entre 450 e 540 nm. Isso limita os sistemas artificiais construídos para representar cores; num monitor de vídeo, por exemplo, não seria possível reproduzir algumas cores do espectro visível pela combinação ponderada de luzes das cores vermelho, verde e azul, pois aquelas com valores negativos não poderiam ser incluídas.



**Figura 2.2-11:** Valores RGB para reproduzir todas as cores do espectro visível<sup>4</sup>. Fonte: Extraído de McADAM (1981).

Uma gama de cores RGB e seus respectivos valores são apresentados na Figura 2.2-12; existem evidentemente, outras cores geradas por outras combinações.

A Figura 2.2-12 mostra que as cores do padrão são representadas por números hexadecimais (base 16), onde o valor de “F” é 15 na notação decimal, pois  $15 \cdot 16^0 = 15$ ; assim, “FF” representaria o valor decimal  $15 \cdot 16^1 + 15 \cdot 16^0$ , que é igual a 255.

Pode ser observado que o valor RGB para a cor amarelo, por exemplo, é dado pela composição dos valores máximos de vermelho e verde (255), sem a inclusão da componente azul (0), ou seja, é representada internamente pelo computador pela sequência hexadecimal FF FF 00. Seguindo esse esquema de representação, a cor preta é formada pela ausência de qualquer valor de qualquer componente; ou seja,  $R=0$ ;  $G=0$  e  $B=0$ , ou na notação hexadecimal: 000000<sub>H</sub>. Já a cor branca é formada pela união de todas as componentes em seus valores máximos:  $R=255$ ,  $G=255$ ,  $B=255$ ; ou na notação hexadecimal: FFFFFFFF<sub>H</sub>.

<sup>4</sup> Fonte: (McADAM, 1981).



Nome da Cor	RGB Hexadecimal	RGB Decimal	Cor	Nome da Cor	RGB Hexadecimal	RGB Decimal	Cor	Nome da Cor	RGB Hexadecimal	RGB Decimal	Cor	Nome da Cor	RGB Hexadecimal	RGB Decimal	Cor
Amarelo	#FFFF00	255,255,0		Cinza Brilhante	#A8A8A8	168,168,168		Plum	#EADEEA	234,173,234		Verde Hunter	#215E21	33,94,33	
Amarelo Esverdeado	#99CC32	153,204,50		Cinza Claro	#C0C0C0	205,205,205		Preto	#000000	0,0,0		Verde Limão	#32CD32	50,205,50	
Aquamarine	#70D893	112,219,147		Cobre	#D98719	217,135,25		Púrpura Escuro	#871F78	135,31,120		Verde Oceano	#426F42	66,111,66	
Aquamarine Médio	#32CD99	50,205,153		Cobre Claro	#85A642	181,165,66		Quartz	#D909F3	217,217,243		Verde Oceano claro	#238E68	35,142,104	
Azul	#0000FF	0,0,255		Cobre Escuro	#8B7333	184,115,51		Rosa	#FF6EC7	255,192,203		Verde Oliva Escuro	#4F4F2F	79,79,47	
Azul Ardósia	#007FFF	0,127,255		Coral	#FF7F00	255,127,0		Rosa Temperado	#FF1CAE	255,28,174		Verde Primavera	#7FFF00	0,255,127	
Azul Ardósia Escuro	#6B238E	107,35,142		Cyan	#00FFFF	0,255,255		Salmão	#6F4242	111,66,66		Verde Primavera	#00FF7F	127,255,0	
Azul Brilhante	#C0D0D0	192,217,217		Escarlata	#8C1717	140,23,23		Semi-Sweet Chocolate	#6B4226	107,66,38		Vermelho	#FF0000	255,0,0	
Azul Celeste	#3299CC	50,153,204		Firebrick	#8E2323	142,35,35		Sienna	#8E6B23	142,107,35		Verde Índiano	#4E2F2F	78,47,47	
Azul Claro	#5F9F9F	95,159,159		Goldenrod Médio	#EAAEAE	234,234,174		Silver	#E6E8FA	230,232,250		Verde Índiano	#CC3299	204,50,153	
Azul Corn Flower	#42426F	66,66,111		Goldenrod	#D8D870	219,219,112		Steel Azul	#23688E	35,107,142		Vermelho Violeta	#4F2F4F	79,47,79	
Azul Escuro	#00009C	0,0,156		Laranja	#FF7F00	255,165,0		Summer Sky	#3880DE	56,176,222		Violeta	#4F2F4F	79,47,79	
Azul Marinho	#23238E	35,35,142		Laranja Mandanan	#E47833	228,120,51		Tan Escuro	#97694F	151,105,79		Violeta Vermelho Médio	#DB7093	219,112,147	
Azul Médio	#3232CD	50,50,205		Light Steel Blue	#8F8FBD	143,143,189		Thistle	#D8BFD8	216,191,216		Wheat	#D8D88F	216,216,191	
Azul Neon	#4D4DFF	77,77,255		Light Wood	#E9C2A6	233,194,166		Turquesa	#A0E0E0	173,234,234		Wood Médio	#A68064	165,128,100	
Azul Rich	#5959AB	89,89,171		Magenta	#FF00FF	255,0,255		Turquesa Escuro	#7093DB	112,147,219					
Azul Violeta	#9F5F9F	159,95,159		Marrom	#8E2368	142,35,107		Turquesa Médio	#70D8DB	112,219,219					
Baker's Chocolate	#5C3317	92,51,23		Marrom	#A62A2A	165,42,42		Verde	#00FF00	0,255,0					
Branco	#FFFFFF	255,255,255		Marrom Escuro	#5C4033	92,64,51		Verde Amarelado	#93DB70	147,219,112					
Bright Ouro	#D90919	217,217,25		Medium Slate Blue	#7F00FF	127,0,255		Verde Cobre	#527F76	82,127,118					
Bronze	#DB9370	219,147,112		Orquídea Escuro	#9932CD	153,50,205		Verde Cobre Escuro	#4A766E	74,118,110					
Bronze Claro	#EBC79E	235,199,158		Orquídea Médio	#9370DB	147,112,219		Verde Escuro	#2F4F2F	47,79,47					
Bronze Escuro	#8C7853	140,120,83		Ouro	#CD7F32	205,127,50		Verde Floresta	#238E23	35,142,35					
Caqui	#9F9F5F	159,95,159		Ouro Velho	#CFB53B	207,181,59		Verde Floresta Médio	#68E23	107,142,35					
Cinza	#C0C0C0	190,190,190													


Figura 2.2-12: Paleta de cores RGB, com representação de alguns valores. Fonte: Adaptado pelo autor de CDMEUFF (2012).

### 2.2.4.2. Padrão de cores CIE-XYZ


O CIE criou um modelo teórico definindo três outras cores primárias: X, Y e Z. Essas cores são composições cromáticas denominadas “valores triestímulos”, cujos comprimentos de onda são mostrados na Figura 2.2-13.

Uma representação gráfica dos coeficientes tricromáticos foi proposta e o modelo recebeu o nome de “Diagrama de Cromaticidade”, como mostra a Figura 2.2-14 (MOROVIC e LUO, 2000). Esse padrão é conhecido como CIE-XYZ. As três cores do padrão são apresentadas no gráfico individualmente, com aspectos senoidais, representando os valores da resposta espectral (C) para os comprimentos de onda  $\lambda$ . A cor azul, por exemplo, expande-se por todo o eixo  $\lambda$ , mas com valores significativos de C entre 350 e 550 nm, atingindo seu ponto de máximo próximo a 445 nm.

Esta representação é linear e não possui valores negativos; sendo assim, não é interessante para representar fielmente o modelo de percepção humano, desde que este último permeia valores negativos para a componente vermelha.



**Figura 2.2-13:** Comprimento de ondas das componentes x, y e z. Fonte: Extraído de GONZALES E WOODS (2010).



**Figura 2.2-14:** Diagrama de cromaticidade do CIE. Fonte: Extraído de McADAM (1981).

O triângulo localizado no interior do diagrama de cromaticidade delimita a região onde estão todas as cores que as cores primárias aditivas - vermelho, verde e azul, são capazes de reproduzir; este triângulo é denominado “*Gamut*”; nele, os vértices situam-se exatamente sobre as cores primárias básicas.

De acordo com GONZALES E WOODS (2010), um espaço de cores é um sistema tridimensional de coordenadas, onde cada eixo refere-se a uma cor primária. A quantidade de cor primária necessária para reproduzir uma determinada cor, é atribuída a um valor sobre o eixo correspondente.

Cor saturada não significa cor pura. A cor saturada está restrita ao espaço de cores a qual a mesma está inserida, e este espaço de cores por sua vez, está restrito às cores delimitadas pelo *gamut*. Enquanto que pura somente é aquela localizada no contorno do diagrama de cromaticidade mostrado na Figura 2.2-14. Portanto, cor totalmente pura o espaço RGB não é capaz de reproduzir (SOUTO, 2000).


No sistema XYZ as coordenadas das cores primárias (RGB) são dadas pelos vetores  $R = (0.73467, 0.26533, 0.0)$ ;  $G = (0.27376, 0.71741, 0.00883)$ ;  $B = (0.16658, 0.00886, 0.82456)$ , que correspondem respectivamente aos vetores  $R = (1,0,0)$ ,  $G = (0,1,0)$  e  $B = (0,0,1)$ .

### 2.2.5. O espaço dos atributos de cores

No espaço de cores RGB, cada um de seus eixos representa uma quantização da energia referente aos comprimentos de onda das cores primárias vermelho, verde e azul do espectro da luz visível.

Uma cor nesse espaço é resultante da combinação das três cores primárias. Acontece que cada cor possui três outros atributos:

- **Intensidade** (ou “brilho”), que descreve o quão claro ou escuro parece uma cor, com respeito à sua cor padrão.
- **Saturação** (ou “croma”), que é função da quantidade de luz branca, representa a pureza ou intensidade de uma cor particular, a vivacidade ou palidez da mesma, e pode se relacionar com a largura de banda da luz. As cores puras do espectro estão completamente saturadas.
- **Matiz** – É a cor pura predominante, sem o branco ou o preto agregado. Esse atributo está associado à longitude de onda dominante na mistura das ondas luminosas, como mostra a Figura 2.2-15.

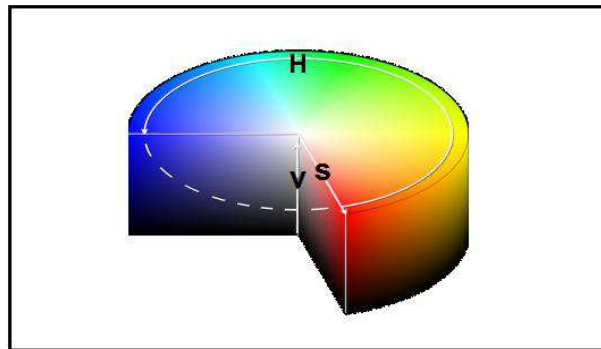


**Figura 2.2-15:** Variação da saturação do Matiz vermelho. Fonte: Montagem do autor.

Com esses três atributos (intensidade, saturação e matiz), é possível construir uma representação espacial que para a mesma cor obtida pelo espaço de cores, denominado “Espaço de atributos de cores” (Figura 2.2-16).

No espaço de atributos de cores, os valores de intensidade e de saturação variam entre 0 e 1, e os valores de matiz variam entre os ângulos 0 e 360 graus. Para  $\theta = 0, 120$  e  $240$  graus, o matiz será vermelho, verde e azul respectivamente, isto é, as três cores primárias. (SOUTO, 2000).

Outros modelos de cores que fazem uso de representação através dos atributos de cores foram criados; dentre eles, destacam-se o modelo HSV e o modelo HSL.



**Figura 2.2-16:** Modelo cilíndrico de espaço de atributos de cores. Fonte: Extraído de CEPSSRM (2013).


### 2.2.5.1. O modelo CIE-HSV

HSV é a abreviatura para o sistema de cores formadas pelas componentes “*Hue* (tonalidade), “*Saturation*” (Saturação) e “*Value*” (Valor). Esse sistema também é conhecido como HSB e define o espaço de cor conforme descrito abaixo, utilizando seus três parâmetros:

- **Tonalidade** ou **Matiz**: medida do comprimento de onda médio da luz que ele reflete ou emite define a cor do objeto. Atinge valores de  $0^\circ$  a  $360^\circ$ , mas para algumas aplicações, esse valor é normalizado de 0 a 100%.
- **Saturação**: também chamado de "pureza". Quanto menor esse valor, mais com tom de cinza aparecerá a imagem. Quanto maior o valor, mais "pura" é a imagem. Expressa o intervalo de comprimentos de onda ao redor do comprimento de onda médio no qual a energia é refletida ou transmitida. Atinge valores de 0 a 100%.
- **Valor** ou **Brilho**: define o brilho da cor. Atinge valores de 0 a 100%.

Esse sistema foi inventado no ano de 1978, por *Alvy Ray Smith*, sendo uma transformação não linear do sistema RGB. A geometria desse espaço é muito parecida com a do modelo RGB, e é representado pelo hexágono da Figura 2.2-17 (GONZALES E WOODS, 2010).

Na Figura 2.2-17, a altura do eixo principal do hexágono corresponde ao eixo acromático do cubo RGB (nível de cinza); Quanto mais próximo do 0 (zero), mais próximo do preto, independentemente da cor. Todas as cores estão totalmente anuladas em  $V=0$  (preto total). Os valores do eixo V variam de 0 na origem, até 1 na área maior do hexágono.



**Figura 2.2-17:** Modelo de espaço de cores HSV. Fonte: Adaptado de CEP SRM, (2013).

Supondo um ponto P qualquer na seção transversal, como descreve a Figura 2.2-17, sua distância até o eixo V, indica o seu nível de saturação, ou seja, a pureza da cor. A saturação varia no intervalo entre 0 e 1.

O Matiz (H) é representado pelo ângulo formado pelos segmentos de reta que ligam o ponto P ao eixo V.

#### 2.2.5.2. O modelo CIE-HSL

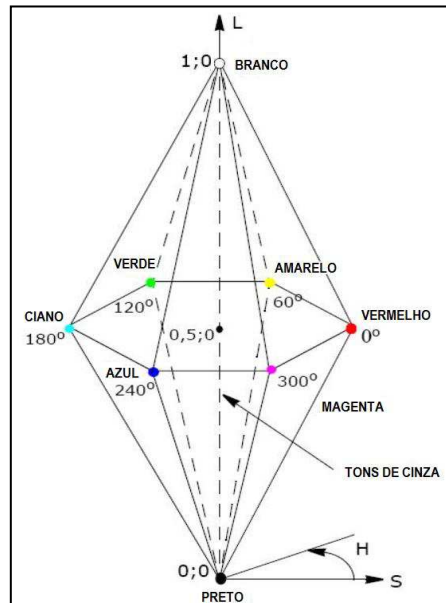
O modelo de cores HSL também foi definido pelo CIE e consiste em decompor a cor de acordo com os seguintes critérios fisiológicos:

- **Matiz** ou **Tonalidade** (H, “*Hue*”), correspondendo à percepção da cor;
- **Saturação** (S, “*Saturation*”), descrevendo a pureza da cor;
- **Luminosidade** (L, “*Lightness*”), indicando a quantidade de luz da cor, ou seja o seu aspecto claro ou sombrio.

A representação gráfica do modelo HSL é formada por dois cones cuja soma dos eixos é 1,0 (normalizado), e cujas bases são coincidentes (Figura 2.2-18). Pode ser observado que:

- O matiz é determinado pelos pontos no círculo da borda das duas bases comuns aos cones,
- A saturação também é normalizada, e varia de 0 a 1, conforme a distância ao eixo do cone. Quanto mais próxima da borda externa, maior a saturação da cor (Figura 2.2-19).

- A luminosidade também varia de 0 (preto) a 1 (branco) ao longo do eixo comum aos dois cones, onde se encontra a escala de cinza (Figura 2.2-19).
- Os matizes puros são encontrados no plano onde a luminosidade é igual a 0,5 (junção dos cones) e a saturação é igual a 1.




**Figura 2.2-18:** Os cones invertidos do espaço de cores HSL. Fonte: Adaptado de CEPSRM, (2013).

As cores puras primárias são defasadas em  $120^\circ$  entre si, enquanto as secundárias são defasadas em  $60^\circ$  das primárias, como mostra a Figura 2.2-20.



**Figura 2.2-19:** Componentes HSL e seus valores. Fonte: Montagem do autor a partir de CEPSRM, (2013).

O modelo HSL é um modelo de representação dito “natural”, ou seja, próximo da percepção fisiológica da cor pelo olho humano, ao contrário do modelo RGB, que é facilmente implementado em máquinas, mas de difícil utilização pelos seres humanos, visto que não se percebe naturalmente a cor como uma composição das três cores básicas, apesar de se poder identificar com facilidade as cores básicas primárias (vermelho, verde e azul) e secundárias (amarelo, ciano e magenta).



**Figura 2.2-20:** Defasagem geométrica das cores no modelo HSL<sup>5</sup>. Fonte: Abstração do autor

O modelo RGB pode ser convertido para o padrão HSL; dessa maneira, a tarefa de comparação de cores se dará utilizando apenas um valor (H), ao invés dos três componentes RGB. Além disso, as informações de saturação e brilho podem ser utilizadas separadamente. Isso é interessante, pois em muitos fenômenos onde a percepção de cores é utilizada como fonte de análise, tanto o brilho (ou liminosidade) quanto a saturação podem ser influenciados, e em alguns casos, de maneira até mais intensa do que o matiz (cor).

### 2.2.6. O conceito de imagem

O conceito de imagem não é de simples definição; essa afirmação pode ser melhor compreendida a partir da definição eclética encontrada para o termo no dicionário HOUAISS (2001):

imagem

substantivo feminino ( *sXIII* )

**1** representação da forma ou do aspecto de ser ou objeto por meios artísticos  
 < *i. desenhada, gravada, pintada, esculpida* >

**1.1** representação de seres que são objeto de culto, de veneração  
 < *a i. de Cristo* > < *uma i. de são Francisco* >

**1.2** estampa, sem caráter de obra original ou rara, que reproduz temas diversos ou, mais esp., motivos religiosos  
 < *um álbum de i.* > < *algumas i. marcavam as páginas do missal* >

**2** aspecto particular pelo qual um ser ou um objeto é percebido; cena, quadro  
 < *imagens da rua* > < *i. urbanas* >

**3** reprodução invertida de um ser ou de um objeto, transmitida por uma superfície refletora

**4** reprodução estática ou dinâmica de seres, objetos, cenas etc. obtida por meios técnicos  
 < *i. fotográfica* > < *i. televisada* > < *i. magnética* >

**5** *Figura* pessoa muito bonita; cromo

**6** *Figura* aquilo que apresenta uma relação de analogia, de semelhança (simbólica ou real); réplica, retrato, reflexo  
 < *ela é a i. do pai* > < *a casa era a i. da dona* >

<sup>5</sup> Abstração do autor

**7** *Figura* pessoa que representa, simboliza ou faz lembrar alguma coisa abstrata; personificação

⟨ *ela era a própria i. da tristeza e solidão* ⟩ ⟨ *o rapaz é a i. da saúde* ⟩

**8** *Figura* opinião (contra ou a favor) que o público pode ter de uma instituição, organização, personalidade de renome, marca, produto etc.; conceito que uma pessoa goza junto a outrem

⟨ *um político precisa cuidar de sua i.* ⟩ ⟨ *teve a i. abalada pelo escândalo* ⟩

**9** *lit* qualquer maneira particular de expressão literária que tem por efeito substituir a representação precisa de um fato, situação etc. por uma alegoria, visão, evocação etc.

⟨ *i. bíblicas* ⟩ ⟨ *i. camonianas* ⟩ ⟨ *i. vulgares* ⟩

**10** *mat* elemento determinado pela aplicação de uma função em um determinado ponto

**11** *ópt* representação de um objeto que emite ou recebe luz e que é formada por raios luminosos que passam por uma lente, espelho ou qualquer outro sistema óptico

**12** *psic* representação ou reprodução mental de uma percepção ou sensação anteriormente experimentada

⟨ *i. visual, olfativa* ⟩

**13** *psic* representação mental de um ser imaginário, um princípio ou uma abstração

⟨ *a i. do demônio, da realeza, da democracia, do círculo* ⟩

Abstraindo as demais definições, as definições 4, 6 e 11 representam com maior proximidade seu conceito mais elementar, objetivo, manipulável.

O termo “imagem” é derivado do latim *imago*, que significa “a representação visual de um objeto”. Em grego antigo é traduzido pelo termo “*eidós*”, raiz etimológica do termo “ideia” ou “abstração”.

Uma das mais exaustivas discussões realizadas pelos filósofos durante os séculos, focaliza justamente a complexa relação entre imagem e realidade (*εικόνα και πραγματικότητα*<sup>6</sup>), tendo entre Platão e Aristóteles seus principais debatedores antagônicos. Platão em sua Teoria do Idealismo define imagem como a ideia de um objeto, uma projeção da mente (PLATÃO, 2000). Já Aristóteles considerava a imagem como sendo uma aquisição dos sentidos humanos; a representação mental de um objeto (PEREIRA, 1971). Essas duas correntes filosóficas tem propagado suas divergências até hoje.

Uma divisão particularmente interessante é estabelecida entre imagens naturais – produzidas sem intervenção humana, e imagens artificiais – as que exigem intervenção humana. No segundo caso, cinco parâmetros distintos podem ser estabelecidos pelos seguintes critérios (VILLEFANE, 1988):

---

<sup>6</sup> *Imagem e Realidade; traduzindo do grego antigo.*



- **Materialidade** – Estabelece a distinção entre imagens materiais (pintura, desenho, fotografia ou mesmo uma estátua) e não-materiais (uma imagem mental, uma projeção holográfica);
- **Espacialidade** - Estabelece a distinção entre imagens bidimensionais e imagens tridimensionais;
- **Temporalidade** - Separa imagens estáticas e imagens móveis;
- **Intenção Sêmica** – Separa imagens representativas e não representativas;
- **Produção** - Imagens produzidas por meios mecânicos e imagens produzidas por meios humanos

#### **2.2.6.1. Elementos de análise da imagem fixa**

A imagem é estudada a partir de dois pontos de vista distintos:

- **Textual:** onde a imagem é entendida como um texto, onde se busca descobrir os seus “constituintes mínimos”. Nessa abordagem, qualquer imagem pode ser analisada através de um conjunto de treze elementos fundamentais distribuídos em três categorias “gramaticais”:
  - Elementos morfológicos (ponto, linha, plano, textura, cor e forma);
  - Elementos dinâmicos (movimento, tensão e ritmo);
  - Elementos escalares (dimensão, formato escala e proporção).
- **Semiótico:** onde a imagem é entendida como signo; aqui, se busca estabelecer um paralelo entre a expressão da imagem e o seu conteúdo, ou seja, o que ela mostra e o que ela significa.

Assim, percebe-se uma clara relação entre o conteúdo físico da imagem e o seu significado, assim como existe uma relação entre esse mesmo conteúdo físico e a sua semelhança com a realidade exterior.

A análise de uma imagem é uma tarefa multifacetada, abordando diversos pontos distintos, dentre os quais:

- A **materialidade** e **dimensionalidade** - possui estrutura bi ou tridimensional, é natural ou artificial, é material (real) ou abstrata (ilusória);

- O **processo de elaboração** – Quais “ferramentas” são empregadas produzir a imagem em questão (humana, mecânica, informática...);
- A **matéria** – qual a organização interna da imagem (tamanho, semelhanças, cores, linhas, efeitos de escala, etc.);
- As **funções icônicas** - relações entre a imagem e o seu objeto de representação.

O conceito de imagem remete, em senso comum, ao objeto real ou imaginário, gerado pelo ser humano através de expressões artísticas, ou simplesmente registrado por meio de pintura, desenho, fotografia, gravura, ou qualquer outra forma visual.

Nas ciências exatas, o termo "imagem" é entendido como representação de um objeto, que exige técnicas e ferramentas especiais; dentre as técnicas mais difundidas, está a fotografia.

A palavra fotografia tem origem etimológica na fusão das palavras gregas *φως* ("luz") e *γραφη* ("gráfico"). Trata-se de uma técnica de impressão de uma imagem sobre uma superfície plana fotosensível a partir de exposição luminosa de um objeto.

#### 2.2.6.2. A imagem analógica e a imagem digital

A fotografia teve o seu princípio na descoberta da câmara escura. Conta-se que durante um eclipse parcial do sol, Aristóteles observou a projeção de uma meia lua no solo, pelos raios solares que passavam por um pequeno orifício na folha de uma árvore. Ele observou ainda que outras folhas com orifícios menores tornavam a projeção mais nítida. Este princípio foi utilizado por Aristóteles para suas observações astronômicas (STEFFENS, 2007).

No século XI, o notório cientista árabe *Ibn Al-Haitham (Al-Hazen)*, nascido em *Basra*, também utilizou esse princípio como apoio à observação de um eclipse solar, descrevendo o processo em seu trabalho “O livro da ótica”. Nele, Al-Haitham desmistificava a antiga idéia grega de que o olho humano lançava luz sobre a imagem e capturava seu reflexo, tendo inclusive dissecado várias peças do olho humano para estudar seu funcionamento (STEFFENS, 2007).

No período renascentista, artistas, pintores, desenhistas e ilustradores utilizavam a câmara escura como ferramenta para registrar cenas da natureza, das pessoas e do mundo. O princípio de funcionamento é bastante simples: a luz que penetra por um orifício da parede de um quarto escuro e forma na parede oposta, a imagem invertida do objeto que estiver do lado de fora do quarto. A pintura era aplicada sobre a imagem formada, na superfície de um dado

suporte. A câmara escura uso intenso e largamente disseminado até o surgimento da fotografia, o que ocorreu em meados do século XIX (KUBRUSLY, 1982).

A história registra que dois inventores *Henry Talbot* da Inglaterra, e *Louis D'aguerre* da França, desenvolveram um método para fixar imagens. *Talbot* usava papel tratado com cloreto de prata, que poderia ser exposto à uma imagem no interior de uma câmara escura e que depois de mergulhado em uma solução de sal, produziria um negativo, e podia ser copiado diversas vezes. Já *D'aguerre*, capturava as imagens em uma chapa de cobre delgada, revestida com sais de prata, que depois de sensibilizada na câmara escura, recebia vapor de mercúrio para garantir a fixação. O resultado era uma imagem positiva e diferente do negativo de *Talbot*, não podia mais ser copiada (GODINHO, 2013).

Durante aproximadamente 150 anos a fotografia se desenvolveu por meio do uso desta tecnologia, com melhoramentos, evidentemente, mas a partir da década de 1970, com o advento da revolução da informática e com o surgimento da tecnologia de imagem digital, a fotografia ampliou as suas possibilidades de percepção, incorporando também as formas simbólicas.


### **2.2.6.3. O pixel**

Com o surgimento da tecnologia de imagem digital, a fotografia ampliou as suas possibilidades de percepção, incorporando também as formas simbólicas.

A tecnologia digital está baseada no processo físico-numérico, onde a luz que passa pela objetiva da câmara sensibiliza um sensor eletrônico inscrito num chip (Figura 2.2-21), que pode contar com dezenas de milhões de transdutores fotossensíveis (*photosites*), denominados pixels.

A palavra “pixel” é um acrônimo para *picture element*; cada um dos pixels de uma imagem é capaz de converter a energia luminosa de um ponto da imagem em carga elétrica para ser lida ou gravada posteriormente na forma de imagem digitalizada em valores numéricos.


A Imagem digital é uma representação matricial bidimensional, onde cada ponto ou célula é um pixel, associado a um valor (intensidade da imagem) e representa alguma propriedade, como cor, tonalidade, brilho etc. (GONZALES E WOODS, 2010).



**Figura 2.2-21:** Sensores CCD montados em Cis. Fonte: site de Ken Rockwell, em <http://www.kenrockwell.com/>.


O pixel é um objeto indivisível, associado a apenas um valor. Ele registra a intensidade da luz que o atinge. É considerado a menor unidade “endereçável” num dispositivo que manipula imagens.

As Figuras 2.2-22 e 2.2-23 apresentam detalhes de um círculo preto sobre fundo branco projetado sobre uma determinada área da superfície do CCD. As linhas azuis projetadas sobre a superfície do CCD representam os pixels de um pequeno trecho da borda do círculo (BAPTISTA, 2012). As Figuras mostram um conjunto de pixels que recebem diferentes quantidades de luz, com percentuais que variam de 0% (sem incidência de luz) até 100% (incidência de luz em sua área total), com alguns valores intermediários (40% e 90%) de incidência de luz na área do pixel. Esses percentuais representam a quantidade de cor cinza que cada célula contém. As diferentes intensidades do cinza podem ser facilmente observadas na Figura 2.2-23.



**Figura 2.2-22:** Proporção da luz incidente sobre a área do pixel<sup>7</sup>. Fonte: Adaptado pelo autor a partir de BAPTISTA (2013).

<sup>7</sup> Adaptado de (BAPTISTA, 2012).



**Figura 2.2-23:** Níveis de cinza resultantes sobre a área do pixel. Fonte: Adaptado pelo autor a partir de BAPTISTA (2013).

Um pixel pode ser considerado o menor componente de uma imagem digital. Essa definição deve ser relacionada à capacidade e meio de representação do dispositivo que manipula a imagem. Pode-se ter, por exemplo:

- Número de pixels imprimíveis em uma folha em determinada impressora;
- Número de pixels exibidos em um determinado monitor.
- Número de pixels presentes na malha de uma câmera digital.


São termos sinônimos de “Pixel”: PEL, dot, spot.

#### 2.2.6.4. Resolução de imagens digitais

A qualidade da imagem está diretamente associada à espessura da malha (distância entre pixels ou número de pixels por unidade de área). Quanto mais fina a malha for maior será a qualidade da imagem. Além disso, o número de informações associado a cada pixel determina a quantidade de cores presentes e, portanto, a qualidade da imagem.

A Resolução de uma imagem descreve o nível de detalhe que uma imagem comporta. O termo se aplica igualmente a imagens digitais, imagens em filme e outros tipos de imagem. Resoluções mais altas significam mais detalhes na imagem. Trata-se de um dos mais importantes parâmetros de uma imagem digital, pois está diretamente ligada à sua qualidade. É definida como a quantidade de unidades de informação gráfica ou óptica (pixels) que compõe a imagem por unidade de área.

CCDs de mesmo tamanho podem ter diferentes quantidades de pixels, como mostra a Figura 2.2-24; quanto mais pixels por unidade de área, maior a resolução e, portanto, maior a fidelidade da imagem.



**Figura 2.2-24:** Mesma imagem representada em diferentes resoluções. Fonte: Adaptado pelo autor a partir de BAPTISTA (2013).

### 2.2.6.5. Estrutura da imagem digital

A imagem digital pode ser estruturada sob duas formas de construção – O Rastreo e o Vetor. Uma imagem vetorial faz uso de vetores e de funções geométricas (retas pontos, curvas, etc). Isso faz com que a representação dos elementos da imagem seja parametrizada; portanto, esses elementos podem ser ampliados ou reduzidos sem perda de qualidade, através da multiplicação ou divisão. A imagem vetorial ainda possui outra vantagem: ocupa pouco espaço de memória.

A imagem de rastreo é formada pela associação direta entre os elementos da imagem e uma malha de pixels. Como não existe nenhuma função estabelecida, não há parametrização, e a imagem não pode ser ampliada ou reduzida sem a ocorrência de perda da qualidade (MICROSOFT, 2013).

### 2.2.6.6. Resolução de dispositivos de representação de imagens

Existem diversos tipos de equipamentos para manipulação de imagens digitais; a resolução dos mesmos varia rapidamente, pois a tecnologia possibilita maior definição a cada nova geração de aparelhos. Esses dispositivos são basicamente classificados em duas classes: Dispositivos de leitura (Scanners, câmaras fotográficas, câmaras de vídeo, dispositivos de memória secundária) e dispositivos de escrita (Impressoras e monitores dos mais variados tipos, além dos dispositivos de memória secundária). A resolução desses dispositivos é bastante variada e a captura em um dispositivo de entrada de alta definição, pode não ser fielmente reproduzida num dispositivo de saída de menor resolução.

Uma convenção popular para a definição dos dispositivos de manipulação de imagens é indicar a resolução como a quantidade total de pixels na imagem, por unidade de área. Os institutos de padronização têm estabelecido vários padrões de resolução para os mais diversos equipamentos.

Os monitores digitais tem sua resolução medida em quantidade de pixels, com dois valores de resolução utilizados; o primeiro indica a quantidade máxima de pixels, e o

segundo, a quantidade de pixels utilizada ajustada no momento. Alguns padrões de resolução definidos para diversos dispositivos de vídeo estão indicados na Tabela 2.2-1.

**Tabela 2.2-1:** Alguns dos padrões de resolução para monitores de vídeo. Fonte: <http://www.banco.daimagem.com.br/curso/html/cap03-4.html>

Padrão	Resolução	MPixels	Área(cm) <sup>8</sup>
QSIF	160 x 120	0.019	1,35 x 1
QCIF	176 x 144	0.025	1,5 x 1,22
CVGA	320x200	0.064	2,7 x 1,7
QVGA ou SIF	320 x 240	0.077	2,7 x 2
CIF	352 x 288	0.101	3 x 2,44
HVGA	640 x 240	0.154	5,4 x 2
VGA	640 x 480	0.307	5,4 x 4
NTSC	720 x 480	0.346	6 x 4
PAL	768 x 576	0.442	6,5 x 4,8
WVGA	854 x 480	0.410	7,2 x 4
SVGA	800 x 600	0.480	6,7 x 5
XGA ou XVGA	1024 x 768	0.786	8,7 x 6,5
HD 720	1280 x 720	0.922	10,8 x 6
WXGA	1280 x 768 (/800)	0.983 /1.024	10,8 x 6,5 (/ 6,7)
SXGA	1280 x 1024	1.311	10,8 x 8,7
WXGA+	1440 x 900	1.296	12,2 x 7,6
SXGA+	1400 x 1050	1.470	11,85 x 8,9
WSXGA+	1680 x 1050	1.764	14,2 x 8,9
UXGA	1600 x 1200	1.920	13,5 x 10
HD 1080	1920 x 1080	2.074	16,256 x 9,144
WUXGA	1920 x 1200	2.304	16,256 x 10,16
QXGA	2048 x 1536	3.146	17,3 x 13
WQXGA	2560 x 1600	4.096	21,7 x 13,5
QSXGA	2560 x 2048	5.243	21,7 x 17,3
WQSXGA	3200 x 2048	6.554	27 x 17,3
QUXGA	3200 x 2400	7.680	27 x 20,3
WQUXGA	3840 x 2400	9.216	32,5 x 20,3
WUQSXGA	4200 x 2690	11.298	35,5 x 22,7

## 2.2.7. Arquivos de imagens

### 2.2.7.1. Formato de arquivos de imagens

Os arquivos de imagens são construídos sob vários formatos; O formato de uma imagem refere-se à forma de como a estrutura dos dados que representam a imagem está armazenada

<sup>8</sup> Tamanho da imagem impressa em qualidade fotográfica -300 Pixels Por Polegada.

em um arquivo. Isso é fundamental para a correta associação entre o arquivo de imagem e o equipamento que o manipula. A opção pelo formato mais adequado deve levar em consideração alguns fatores como a riqueza de detalhes a se preservar, quantidade de dados, tamanho máximo do arquivo, quantidade de cores (nº de bits), etc. CARVALHO (2003). O Quadro 2.2-1 apresenta alguns dos tipos de arquivos de imagens mais utilizados.

**Quadro 2.2-1:** Formatos de arquivos de imagem mais difundidos. Fonte: <http://www2.ic.uff.br/~aconci/curso/formatos.htm>.

<b>Formatos de arquivos de imagem</b>	
JPEG ou JPG	<i>Joint Photographic Experts Group</i> - É o formato mais utilizado e conhecido atualmente. Quase todas as câmaras dão esta opção para guardar as imagens. Arquivo muito utilizado na Internet e em multimídia, por ter uma compactação excelente, algo fundamental ao meio, e por suportar até 16.777.216 cores distintas.
TIFF	<i>Tagged Image File Format</i> - Arquivo padrão para impressão industrial também muito usado como opção nas câmaras fotográficas. É um formato de arquivos que praticamente todos os programas de imagem aceitam. Foi desenvolvido em 1986 pela Aldus e pela Microsoft numa tentativa de criar um padrão para imagens geradas por equipamentos digital. O TIFF é capaz de armazenar imagens true color (24 ou 32 bits) e é um formato muito popular para transporte de imagens do desktop para bureaus, para saídas de scanners e separação de cores. O TIFF permite que imagens sejam comprimidas usando o método LZW e permite salvar campos informativos (caption) dentro do arquivo. No Photoshop, use o comando File Info do menu File para preencher tais campos informativos
GIF	<i>Graphics Interchange Format</i> - Criado para ser usado extensivamente na Internet. Suporta imagens animadas e 256 cores por frame. Foi substituído pelo PNG.
BMP	<i>Windows Bitmap</i> - Normalmente usado pelos programas do Microsoft Windows. Não utiliza nenhum algoritmo de compressão, daí esse formato apresentar as fotos com maior tamanho.
PNG	<i>Portable Network Graphics</i> - É um formato livre de dados utilizado para imagens, que surgiu em 1996 como substituto para o formato GIF, devido ao fato de esse último incluir algoritmos patenteados. Suporta canal alfa, não tem limitação da profundidade de cores, alta compressão (regulável). Permite comprimir as imagens sem perda de qualidade, ao contrário de outros formatos, como o JPG.

Uma imagem digital não é adstrita de qualquer informação semântica objetiva, portanto, os objetos presentes na imagem não estão associados a qualquer conceito ou valor, além daqueles específicos da própria imagem.

O formato de arquivos gráficos BMP define gráficos utilizando mapas de bits. Trata-se portanto de um arquivo do tipo Rasteiro, que é o padrão das aplicações Windows que manipulam imagens e possui uma estrutura simples, mas o tamanho dos arquivos é muito grande. O formato BMP foi desenhado para sistemas operacionais que rodem sobre a plataforma INTEL não sendo manipulado por outras plataformas. Talvez por esse motivo, seu



uso na Internet é limitado, sendo preterido por outros formatos mais leves, como PCX, GIF, TIFF etc.

### 2.2.7.2. O formato BMP

Arquivos de bitmap (BMP) são armazenados sob o formato DIB (I), que especifica a cor do pixel de maneira independente do dispositivo que a manipulará. A disposição dos bytes (conjunto de dígitos binários) no arquivo é de natureza posicional, não sendo possível modificar essa estrutura, ao contrário dos arquivos vetoriais.

Os arquivos BMP são geralmente classificados pelo número de bits necessários para representar 1 pixel (bit/Pixel). Algumas das relações bit/pixel são:

- 1 bit/pixel (2=2 cores);
- 4 bits/pixel (2<sup>4</sup>=16 cores);
- 8 bits/pixel (2<sup>8</sup>=256 cores);
- 24 bits/pixel (true color com 16 milhões de cores);
- 32 bits (true color com 4 bilhões de cores).

#### 2.2.7.2.1. Divisões do arquivo BMP

Todo arquivo BMP apresenta 3 ou 4 divisões:

- a. **Cabeçalho de arquivo:** contém informações sobre o tipo, o tamanho e o formato do arquivo BMP.
- b. **Cabeçalho de mapa de bits:** contém as informações da imagem contida no arquivo, define as dimensões, tipo de compressão (se houver) e informações sobre a codificação das cores da imagem.
- c. **Paleta ou mapa de cores (opcional):** necessária em arquivos de imagens que usam 16 ou 256 cores (4 e 8 bits/pixel); nos demais casos, não é incluída, e em seu lugar é incluída a área de dados da imagem.
- d. **Área de dados da imagem contida no arquivo:** dados que permitem a formação da imagem; trata-se do conjunto de pixels a ser manipulado, admitindo a possibilidade de compressão<sup>9</sup>.

Existe na estrutura BMP alguns campos denominados “reservados”, que são destinados a implementações futuras do padrão. Esses espaços devem ser preenchidos.

---

<sup>9</sup> Método de redução do tamanho do arquivo de imagem

### 2.2.7.3. O formato PNG

O formato de arquivos de imagens **PNG** (*Portable Network Graphics*) é também um arquivo de bitmap. Surgiu em 1995 como uma alternativa ao formato GIF, já que o formato GIF é um formato proprietário e inclui algoritmos patenteados, ou seja, os direitos são patrimônio da empresa Unisys, e qualquer editor gráfico que venha manipular esse tipo de arquivo, será obrigado a pagar direitos à esta empresa.

O PNG permite admitir as seguintes codificações de imagens:

- **Preto e branco** (até 16 bits por pixels);
- **Cores reais** (até 48 bits por pixels);
- **Imagens indexadas** (paleta de 256 cores).

O PNG suporta 256 níveis de transparência por camada alfa e possui uma função de entrelaçamento que permite a afixação progressiva da imagem. Além disso, sua compressão não admite perda (*lossless compression*).

#### 2.2.7.3.1. Estrutura do formato PNG

Um arquivo PNG possui uma “assinatura”, uma estrutura que identifica seu tipo, seguido por um conjunto de elementos denominados “*chunks*” (segmentos). A assinatura de um arquivo PNG (em notação hexadecimal) é a seguinte:

89 50 4E 47 0D 0A 1A 0A

Cada segmento é composto por 4 partes:

- **Dimensão:** um número inteiro de 4 bytes, que indica o tamanho do segmento.
- **Tipo:** tipo do segmento, um código de 4 caracteres (4 bytes) compostos por caracteres ASCII (TER- A-Z, a-z, 65 a 90 e 97 a 122) .
- **Dados:** os dados do segmento.
- **CRC:** é um código corretor de 4 bytes que permite verificar a integridade do segmento.

Não existe uma ordem para a distribuição dos segmentos, mas esses são sempre iniciados pelo segmento de identificação, cabeçalho ou assinatura (IHDR chunk) e terminados pelo segmento que indica o fim da estrutura (IEND chunk)

Os principais segmentos são:

- IHDR *Image header*
- PLTE *Palette*
- IDAT *Image data*
- IEND *Image trailer*
- bKGD *Background color*
- cHRM *Primary chromaticities and white point*
- gAMA *Image gamma*
- hIST *Image histogram*
- pHYs *Physical pixel dimensions*
- sBIT *Significant bits*
- tEXt *Textual data*
- tIME *Image last-modification time*
- tRNS *Transparency*
- zTXt *Compressed textual data*

### **2.2.8. Descritores de cor**

Existem várias formas de representar uma imagem; as representações devem ter a capacidade de alocar em algum meio, a informação contida na imagem, para que possa ser utilizada de algum modo posteriormente. Quando se utiliza a cor como característica para a representação / recuperação de imagens, as formas contidas nas imagens são abstraídas. Com isso, parte da informação é perdida, pois a forma é definida pela distribuição dos pixels na área da imagem. Isso tem uma consequência interessante: poder analisar aspectos relevantes que envolvem as cores presente numa imagem, independentemente da posição física do objeto no espaço.

A cor é na verdade, uma das características mais amplamente utilizadas em sistemas de análise de imagens por ser relativamente independente quanto ao tamanho, orientação e resolução da imagem e é computacionalmente menos cara quando comparada a outros descritores (BENDER *et al.*, 2000).

### 2.2.8.1. Histogramas

O Histograma de cores representa a distribuição quantitativa de cores de uma imagem. Para representar a cor de um determinado objeto em uma imagem, diferentes espaços de cores, como o RGB e o HSL, podem ser empregados. As imagens são formadas por um grande número de pixels. Dentre os descritores de cor, o Histograma é de longe o mais largamente utilizado em recuperação de imagens (TORRES *et al*, 2006).

O histograma é construído a partir da contagem dos pixels de cada cor diferente em um determinado espaço de cor. Os histogramas podem ser definidos em  $\mathbb{R}^2$  ou  $\mathbb{R}^3$ . A construção de um histograma se baseia na construção de diversas regiões de cores, uma para cada cor presente na imagem, dentro de um determinado espaço de cores. Em seguida, efetua-se o somatório da ocorrência de uma cor na imagem, incrementando a cada vez, as regiões de cores. Enfim, o histograma nada mais é do que um gráfico que tem num dos seus eixos a representação numéricas das cores de um sistema ou espaço, e no outro a quantidades de pontos para cada cor que uma determinada imagem contém.

### 2.2.8.2. Histogramas de uma imagem

Seja uma imagem definida com  $L$  níveis de cinza  $c$ , com  $c = \{0,1,2, \dots, L-1\}$ ; onde  $c = 0$  corresponde ao preto e  $c = L-1$  ao branco. Para o padrão RGB, por exemplo,  $L = 256$ , correspondendo a uma imagem 8 bits/pixel. As cores são associadas aos níveis de cinza.

O histograma de uma imagem, com nível de cinza na faixa de  $[0, L-1]$ , é uma função discreta  $h(r_k)$  que indica o número de pixels que apresentam um determinado nível de cinza:

$$h(r_k) = n_k.$$

onde:

$r_k$  = k-ésimo nível de cinza;

$n_k$  = número de pixels na imagem com nível de cinza  $r_k$ .

Varrendo todos os pixels da imagem e computando seu número de pixels para cada nível de cinza  $c$ , define-se a proporção:

$$p_c(r_c) = \frac{n_c}{n} \quad (\text{Eq. 2.2-2})$$

$$r_c = \frac{c}{L-1} \quad (\text{Eq. 2.2-3})$$

onde:

- $n_c$  é o número de pixels da imagem com nível de cinza  $c$ ;
- $n$  é o número total de pixels da imagem;
- $r_c$  é o nível de cinza normalizado entre 0 e 1:  $0 \leq r_c \leq 1$ .

Logo,  $p_c(r_c)$  indica a fração de pixels do nível de cinza  $c$  da imagem.

Considerando que uma imagem seja a produção de um processo aleatório, a probabilidade da ocorrência do nível de cinza  $c$  na imagem  $p_c(r_c)$ .

Com estas definições acima, têm-se as seguintes relações:

$$\sum_{c=0}^{c=(L-1)} n_c = n \quad (\text{Eq. 2.2-4})$$


$$\sum_{c=0}^{c=(L-1)} n_c = n \quad (\text{Eq. 2.2-5})$$

O histograma de níveis de cinza da imagem é exatamente o conjunto de valores  $p_c(r_c)$ , o qual é geralmente representado por um gráfico de barras.

O histograma corresponde então à função densidade de probabilidade da variável nível de cinza da imagem.

Pode-se obter a média de um histograma, que é dada pela cálculo da média da função densidade de probabilidade da variável  $c$ :


$$\bar{m} = \frac{0 * n_0 + 1 * n_1 + \dots + (L - 1) * n_{(L-1)}}{n_0 + n_1 + \dots + n_{(L-1)}} = \sum_{c=0}^{(L-1)} c p_c \quad (\text{Eq. 2.2-6})$$



**Figura 2.2-25:** Imagem no formato RGB (a) com seu histograma em escala de cinza (b). Fonte: Extraído de Tutorial Python OpenCV Library em <http://docs.opencv.org/doc/tutorials/tutorials.html>.

O histograma pode trazer a informação da frequência dos níveis de cinza na imagem (Figura 2.2-25), abstraindo qualquer informação sobre a localização espacial dos pixels da imagem.

Em imagens coloridas, como a da Figura 2.2-26, que é constituída utilizando o modelo RGB, os histogramas representam três planos de imagens independentes, um para cada cor primária. Nesse caso, três histogramas, um para cada componente de cor, pode ser construído, como pode ser observado na figura.



**Figura 2.2-26:** Imagem RGB(a) com histogramas azul(b), verde(c) e vermelho(d)<sup>10</sup>. Fonte: Montagem do autor a partir de *Tutorial Python OpenCV Library* em <http://docs.opencv.org/doc/tutorials/tutorials.html>.

## 2.2.9. O processamento de imagens

Uma imagem é na realidade, um arcabouço físico que transporta uma determinada informação, que pode estar associada a uma medida de um sinal relacionado a algum fenômeno físico, ou pode ainda estar associada a um nível cognitivo relacionado a algum conhecimento; o Processamento de Imagem é uma forma de processamento de dados computacionais, onde a entrada é uma imagem a partir da qual são identificadas e extraídas tais informações, obtendo-se uma descrição de alto nível de seus componentes. Trata-se de um estágio inicial cuja saída é tipicamente submetida a processamentos adicionais, que têm por objetivo, analisar a imagem sob esses aspectos. Sistemas computacionais que tratam dados desse tipo são denominados “Sistemas de Análise de Imagens”.

### 2.2.9.1. Sistemas de análise de imagens

Um sistema de análise de imagem é um programa de computador que utiliza técnicas de processamento de imagens e de Inteligência Artificial para derivar informação a partir dos dados básicos contidos em imagens.

<sup>10</sup> Fonte: *Tutorial Python OpenCV library* em <http://docs.opencv.org/doc/tutorials/tutorials.html>

São tarefas comuns de um sistema de análise de imagens o “reconhecimento” e a “classificação”. Os pontos que permeiam as imagens são definidos na forma de objetos e esses em classes de objetos. A disposição de um conjunto particular de pontos podem expressar uma relação entre eles. A grande maioria dos métodos existentes para a classificação de formas opera através da identificação de similaridades de pontos entre formas para definição de medida de similaridade (*scores*), que são utilizadas para a classificação. Uma vez estabelecidos os scores, podem ser empregados os mecanismos de aprendizagem para classificação.

- **Reconhecimento:** é a parte do processamento de imagens responsável pela classificação dos objetos a partir de informações encontradas na imagem.
- **Classificação:** é a parte responsável pelas tomadas de decisões, baseando-se geralmente no sistema de *scores*. A classificação pode ser realizada através de vários mecanismos, onde quase sempre se empregam estimativas de distribuições probabilísticas ou métodos de Inteligência Artificial, como a Aprendizagem de Máquina. Essa tarefa compreende duas abordagens: A classificação binária, onde se escolhe entre duas respostas simétricas ou binárias (S/N) e a classificação multiclasse, onde dentre uma gama de possíveis valores, um deve ser escolhido.

Tipicamente, o processamento de imagens se faz através das seguintes etapas:

- **Aquisição de dados:** é simplesmente a disponibilização da imagem na forma digital para a entrada do sistema. Isto pode ser feito de várias maneiras. Para o caso da detecção de problemas em frutos a partir de uma imagem, o meio mais comum será através de câmeras digitais de alta resolução.
- **O pré-processamento:** consiste na utilização de técnicas de computação gráfica, como transformações lineares e não-lineares para ajustes de contraste, remoção de ruído, seleção de regiões de interesse, reamostragem dos pixels em uma nova escala, extração de características de imagem para segmentação, etc.
- **A segmentação de imagens:** permite particionar a imagem em regiões disjuntas através de critérios relevantes para a aplicação. Pode-se por exemplo, separar um objeto de interesse do resto dos pixels da imagem, particionando-a em duas regiões distintas. A saída da segmentação pode ser a fronteira do objeto com seu exterior.
- **A representação:** consiste das várias formas de armazenar o conjunto resultante da segmentação. Esta representação da imagem contém informações sobre a forma e a

topologia dos objetos; a descrição quantitativa dessas informações, através da extração de características estruturais, complementam a representação.


- **O reconhecimento** associa um identificador (ou rótulo) a cada objeto segmentado, enquanto a interpretação associa um significado a objetos segmentados ou a um conjunto desses.

### 2.2.9.2. Sistemas de aquisição de imagens

O sistema de aquisição de imagens é o componente inicial de um sistema de análise de imagens, e é constituído basicamente pelo equipamento de captura (câmara digital), que coleta a radiação luminosa proveniente do objeto de interesse para o sensor de aquisição (CCD). Para a definição desse sistema, torna-se necessário definir vários parâmetros de ajuste ou configuração, que estão diretamente relacionados à qualidade da imagem a ser adquirida. Alguns desses parâmetros são (Figura 2.2-27):

- **Distância de Trabalho** ou **Distância focal** (*WD- Working Distance*): É a distância da parte frontal das lentes até a superfície do objeto.
- **Resolução** (*R- Resolution*): É a menor porção do objeto em estudo representada pelo sistema, que pode ser distinguida (geralmente dada em pixels).
- **Profundidade de Campo** (*DOF- Depth Of Field*): representa a maior distância que pode ser mantida em foco no objeto em estudo para uma determinada distância de trabalho, com nitidez aceitável. Geralmente, é especificada em um intervalo.
- **Tamanho do Sensor** (*SS- Sensor Size*): representa o tamanho da área ativa do sensor, especificada horizontalmente. Os tamanhos mais comuns disponíveis no comércio são de 1/4, 1/3, 1/2, 2/3 e 1 polegada.
- **Campo de Visão** (*FOV- Field Of Vision*): representa a área visível do objeto em estudo que incide sobre o sensor, ou seja, a porção do objeto que preenche e sensibiliza a área do sensor.





**Figura 2.2-27:** Parâmetros de uma imagem.. Fonte: Montagem do autor a partir de BAPTISTA (2013).

O sistema de aquisição de imagens deve ser bem configurado, pois da qualidade da captura das imagens tem grande importância na correta resposta do sistema. Isso implica na escolha adequada e precisa do hardware do sistema de visão. Erros advindos na configuração destes equipamentos, como por exemplo, obtenção de imagens escuras ou com sombras perturbadoras, foco inapropriado, tempo de aquisição inadequado e ruídos demasiados (de iluminação) podem inviabilizar a implementação da aplicação.

O projeto e construção de um bom sistema de aquisição de imagens é iniciado a partir da especificação dos parâmetros fundamentais (*FOV*, *DOF*, *WD*, *R*, *SS*), para que se possa obter a boa formação das imagens no elemento ativo de captura. Em seguida, um pré-projeto do sistema de processamento de imagens pode ser implementado para manipular a imagem de acordo com as restrições da aplicação.

Um sensor para aquisição das imagens deve ser escolhido, levando-se em conta parâmetros como o tipo de varredura, a taxa de aquisição por unidade de tempo e a resolução, necessários para a aplicação.

### 2.2.9.3. Iluminação de um sistema de aquisição de imagens

Além do sistema de aquisição de imagens, é necessário construir o sistema de iluminação. O objetivo do sistema de iluminação é a projeção adequada de luz sobre o objeto em estudo.

Para a construção de um sistema de iluminação, devem ser considerados os parâmetros do ambiente de aquisição de imagens, como: as suas dimensões, as cores de fundo, a distancia

entre o objeto e a luz, o tipo de iluminação, a disposição das luzes, etc. Uma iluminação adequada é imprescindível para capturar as características do objeto em estudo, sendo esta importante para sensibilizar adequadamente (sem distorções) o sensor de aquisição de imagem.

### 2.2.10. Detecção de objetos em imagens

Dada uma imagem qualquer, a detecção de objetos consiste em determinar se os objetos previamente especificados estão presentes ou ausentes na mesma. Caso estejam presentes, determina-se os locais e tamanhos de cada objeto.

A pesquisa para detecção de objetos e reconhecimento está se concentrando em

- **Representação:** Como representar um objeto,
- **Aprendizado:** algoritmos de aprendizado para aprender a propriedade comum de uma classe de objetos
- **Reconhecimento:** identificar o objeto em uma imagem usando modelos já aprendidos.

A possibilidade de detectar objetos em imagens é parte importante de uma disciplina associada à Inteligência Artificial: o Reconhecimento de Padrões.

### 2.2.11. Reconhecimento de padrões em imagens

O reconhecimento de padrões (*Pattern Matching*) é a área do processamento em que se utilizam técnicas computacionais para aproximar a performance das máquinas a do ser humano, de modo a reconhecer padrões dentro de uma imagem.

Existem duas grandes motivações para o estudo nesta área: a necessidade das pessoas em se comunicarem com máquinas computacionais através de linguagens naturais, e o interesse na ideia de projetar e construir autômatos (máquinas inteligentes) que possam realizar certas tarefas com habilidades comparáveis ao desempenho humano.

O reconhecimento de padrões é uma ciência não exata. Esta natureza não estruturada do padrão a ser reconhecido torna o problema de reconhecimento difícil de ser tratado por paradigmas tradicionais de computação.

### 2.3. Inteligência artificial e aprendizagem de máquina

Nesta parte encontra-se um resumo dos conceitos associados à Inteligência Artificial empregados nos mecanismos desenvolvidos neste trabalho. Embora resumidos, esses conceitos foram comentados de maneira suficiente ao entendimento de suas aplicações. Alguns conceitos preliminares da IA foram abordados de uma maneira mais abrangente, porquanto suas definições encontram várias instâncias nas diferentes visões de diversos autores.

A subárea conhecida como “Aprendizagem de Máquina”, que consiste em um verdadeiro paradigma no contexto deste trabalho, é enfatizada em termos da construção de um sistema baseado em conhecimento; no final, uma breve introdução à lógica difusa (*fuzzy*) é encontrada.

#### 2.3.1. O conceito de inteligência

O termo “inteligência” deriva do latim *inteligere*; essa palavra que é uma composição de dois termos: *intus* (“entre”) e *legere* (“escolher”) (CUNHA, 2010). Logo, a origem etimológica do conceito de inteligência, aplica-se a um ente que sabe escolher.

O conceito de inteligência é muito complexo e diversificado; segundo alguns autores, a inteligência pode ser tipada, e um tipo de inteligência associa determinadas atividades às aptidões cognitivas naturais dos indivíduos; como: a inteligência lógica, a inteligência musical, a inteligência literária, a inteligência espacial, etc.

Esses argumentos explicam por que algumas pessoas com baixos resultados no QI são extremamente bem-sucedidas em uma área específica (talento): Cada um de nós possui, em grau maior ou menor, vários tipos de inteligência; *Albert Einstein*, *Nils Bohr* e *Stephen Hawkins* seriam exemplos de inteligência lógica e matemática; *Pablo Picasso*, *Buonarioti Michelangelo* e *Paul Martin* seriam exemplos de inteligência espacial enquanto *Wolfgang A. Mozart*, *Ludwig Van Beethoven* e *Antonio Vivaldi* seriam representantes do grupo de indivíduos com inteligência musical superior (GOULD, 1983); (GARDNER, 1993).

#### 2.3.2. Definição de “Inteligência Artificial”

As definições de IA são diversas, variando de autor para autor em função da abordagem adotada. Seguem oito definições dentre as mais difundidas:

- "O novo e excitante esforço para fazer o computador pensar ... máquinas dotadas de mente, no sentido completo e literal" (HAUGELAND, 1997).

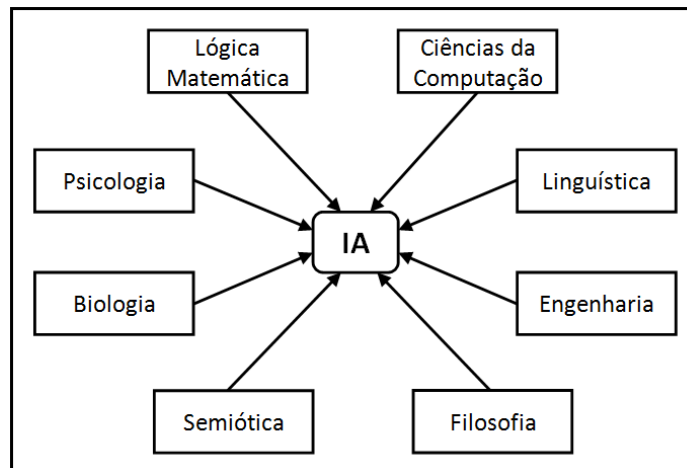
- "A automação de atividades que nós associamos ao pensamento humano, atividades como tomada de decisões, resolução de problemas, aprendizagem, ..." (BELLMAN, 1978).
- "A arte de criar máquinas que executam funções que requerem inteligência quando realizadas por pessoas" (KURZWEIL, 1990).
- "O estudo de como fazer computadores realizarem coisas que no momento as pessoas realizam melhor" (RICH e KNIGHT, 1991).
- "O estudo das faculdades mentais através do uso de modelos computacionais" (CHARNIAK e McDERMOTT, 1985).
- "O estudo de computações que tornam possível perceber, raciocinar e agir" (WINSTON, 1992).
- "Um campo de estudo que procura explicar e emular conhecimento inteligente em termos de processos computacionais" (SCHALKOFF, 1990).
- "O ramo da Ciência da Computação que se preocupa com a automação do comportamento inteligente" (LUGER E STUBBLEFIELD, 1993).

Nenhuma dessas definições de IA é universalmente aceita, mas é possível compilar um conceito equidistante para a grande maioria dos escritores: "IA é a área de estudos voltada para a produção de sistemas artificiais que realizam tarefas que, quando realizadas por seres humanos, exigem inteligência".

Esta definição é bastante efêmera e esconde a sua abrangência, sua característica interdisciplinar e a enorme complexidade dos problemas presentemente enfrentados; apesar disso, esta definição indica claramente seu objetivo e a peculiaridade de sua natureza.

Em outras palavras, a IA é em resumo, um ramo da ciência da computação que se propõe ao desenvolvimento de técnicas e dispositivos que simulem a capacidade humana de resolver problemas (WINSTON, 1992).

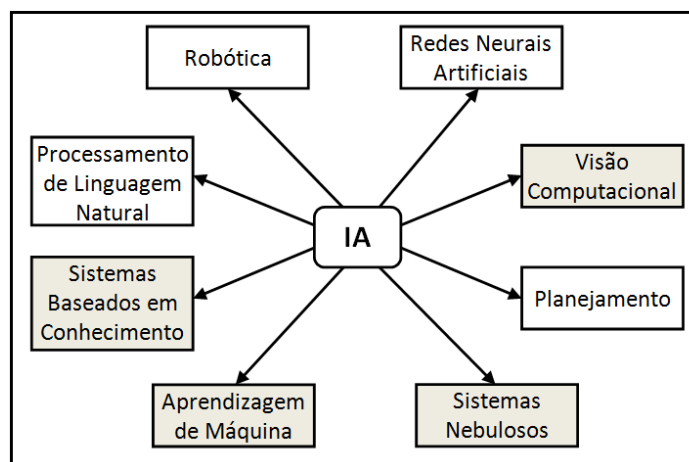
São várias as disciplinas de IA; as ciências que contribuem fortemente com o desenvolvimento da IA são mostradas na Figura 2.3-1.



**Figura 2.3-1:** Áreas de conhecimento que contribuem com a IA. Fonte: Adaptação do autor baseado em (RUSSEL e NORVIG, 2004).

A IA está distribuída em muitas áreas de aplicação; algumas de suas principais áreas de pesquisa e desenvolvimento na atualidade, são apresentadas na Figura 2.3-2. As áreas em destaque são abordadas em diferentes níveis de detalhe neste trabalho.

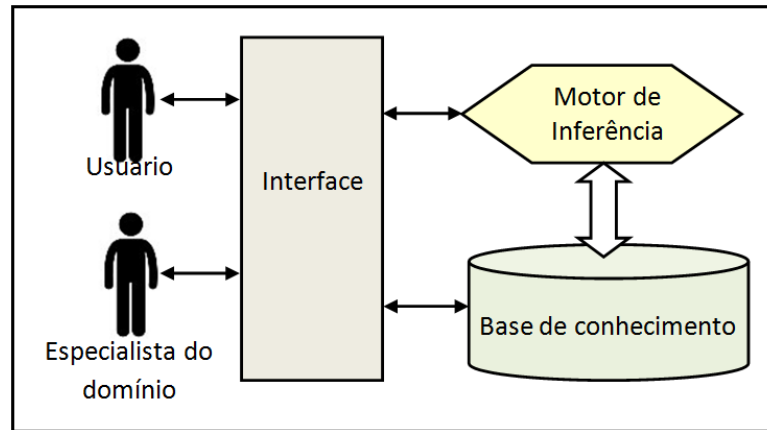
A IA tem se afirmado cada vez mais como um campo de estudo multidisciplinar e interdisciplinar, que se apóia no conhecimento e evolução de outras áreas do conhecimento, mas que também contribui, de maneira simbiótica, com essas áreas.



**Figura 2.3-2:** Algumas das áreas desenvolvidas e pesquisadas pela IA. Fonte: Adaptação do autor baseado em (RUSSEL e NORVIG, 2004).

### 2.3.3. Sistemas baseados em conhecimento - SBC

São sistemas computacionais que utilizam o conhecimento de especialistas no domínio de determinada área, para solucionar problemas sobre esse domínio; SBCs são utilizados em problemas que requerem uma quantidade considerável de conhecimento ou perícia humana para serem resolvidos.



**Figura 2.3-3:** Arquitetura de um SBC. Fonte: abstração do autor.

Segundo MICHALSKY *et al.* (1983a), os elementos que constituem um SBC são o usuário, um especialista do domínio, uma interface, uma base de conhecimento e um motor de inferência (Figura 2.3-3).

- **Base de conhecimento:**

- Contém o conhecimento do domínio do problema; é construído por um especialista, geralmente humano (pode ser outro SBC).
  - Representa as ações e acontecimentos do mundo onde se insere.
  - O conhecimento pode ser representado de diversas maneiras, admitindo vários *formalismos de representação*.
- Propriedades desejáveis em uma base do conhecimento:
  - **Consistência:** impossibilidade de armazenar informações conflitantes.
  - **Completo:** o conhecimento é suficiente para resolver os problemas submetidos.
  - **Coerência:** os resultados são sempre o mesmo para um dado problema específico.
  - **Redundância:** pode até haver conhecimento redundante, mas em representações diferentes.
  - **Corretismo** ou **Corretude**<sup>11</sup>: as versões das unidades do conhecimento são compatíveis entre si.

- **Mecanismo de inferência:**

<sup>11</sup> Neologismo *informata*; refere-se à característica de um axioma ou conjunto ser completo.

- Permite a exploração do conhecimento.
- Responsável em aplicar as estratégias de inferência e controle.
- Usa alguma estratégia de raciocínio.
- Processa as informações da Base de Conhecimento, para tentar encontrar uma solução para o problema.

- **Interface**

- Promove o acesso e a interação do usuário e do especialista sobre o domínio do conhecimento com o sistema. Existem vários formalismos para a representação de conhecimento; isso porque a representação depende em grande parte, do tipo de problema que o SBC se propõe a resolver. Um SBC pode empregar mais de um formalismo para representar o conhecimento. Dentre esses vários formalismos, os mais difundidos estão resumidos no Quadro 2.3-1:

**Quadro 2.3-1:** Formalismos para a representação do conhecimento. Fonte: Composição do autor.

Base do Conhecimento	Descrição
Regras	Utiliza estruturas semânticas denominadas regras, ou regras de produção; Trata-se de um mecanismo simples, composto por duas partes: as premissas e a conclusão. em outras palavras, tem-se uma condição (se) e uma ação consequente (então). A inferência realiza a ação, caso as condições sejam observadas.
Procedimentos	O conhecimento está estruturado em um conjunto de funções ou procedimentos. O mecanismo de inferência é processado pela execução controlada desses procedimentos.
Hierarquias	O conhecimento é representado por estruturas de dados dispostas sob uma hierarquia. O mecanismo de inferência é processado pelas operações de busca e de atualização nessas estruturas.
Objetos	O conhecimento é representado em estruturas autônomas individualizadas, denominadas objetos; O mecanismo de inferência opera mediante a interação entre esses objetos.
Lógica	O conhecimento é representado através de formalismos lógicos diversos em fatos da realidade. O mecanismo de inferência opera procurando verificar a asserção lógica dos fatos representados no banco de conhecimento (similar ao conhecimento baseado em regras).

#### 2.3.4. Visão computacional

Visão computacional é uma área multidisciplinar, que recebe importantes contribuições da IA, através do desenvolvimento de teorias e métodos que possibilitam a extração automática de informações contidas em imagens.

Dentre as diversas áreas onde a visão computacional tem sido aplicada, estão a análise automática de imagens de satélite (para previsão do tempo, mapeamento geográfico, identificação de alterações de curso de rios, etc), medição dimensional de peças, análise de imagens médicas (Raios-x, Ultra som, etc.), reconhecimento de faces humanas, a seleção e classificação de produtos agrícolas, dentre outras (DAVIES, 2005).

A criação de sistemas de visão computacional envolve a execução de um determinado conjunto de transformações sobre dados provenientes de sensores ópticos, como as câmaras digitais.

Uma faceta interessante da visão computacional, comum aos sistemas robóticos, é a busca pela construção de máquinas capazes de emular os sentidos humanos, viabilizando uma melhor comunicação com a realidade, ampliando as aplicações dos computadores.

#### **2.3.4.1. Desafios dos sistemas de visão computacional**

Existem vários fatores que impedem que os sistemas de visão computacional atinjam seu potencial pleno. Em primeiro lugar, essa área de estudo (visão computacional) está muito fragmentada e dispersa; talvez isso se deva à sua natureza interdisciplinar e ao rápido crescimento em função das potenciais aplicações. Talvez por isso, haja uma grande redundância de esforços para soluções de problemas similares, e os sistemas de visão computacional não têm identidade definida, sendo muitas vezes confundidos com produtos da Inteligência Artificial e da Robótica, especificamente.

A tarefa da visão computacional não é uma disciplina trivial; é muito fácil subestimar a complexidade de visão por computador em função da enorme facilidade aparente com que os seres humanos utilizam o seu próprio sistema visual; basta abrir os olhos e se reconhece facilmente os objetos e as estruturas do ambiente. Acontece que poucas pessoas tem idéia da enorme quantidade de recursos cerebrais envolvidos nessas simples tarefas humanas.

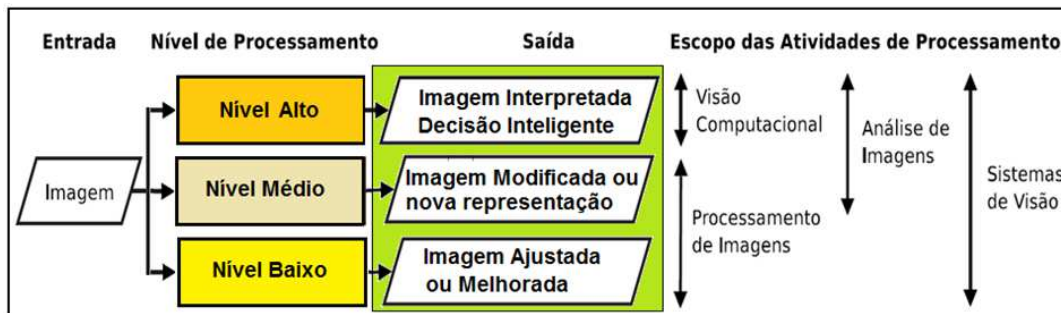
A área de visão computacional é bastante diversificada, porém imatura. Apesar de existirem trabalhos já reconhecidos, somente após o final da década de 1970 foram iniciados estudos mais aprofundados; isso se deve à grande capacidade de processamento dos exigidos dos computadores, o que não existia antes.

Um fato curioso, é que os primeiros estudos foram geralmente originados de outros campos de pesquisa, e como consequência, não foi elaborado um formalismo para o problema de visão computacional. Assim, existem atualmente diversos métodos para resolver várias



tarefas bem definidas; tais métodos são bastante específicos e de maneira geral não podem ser utilizados em outras aplicações, ainda que similares.

Os problemas de visão computacional exigem alto nível de processamento, como mostra a Figura 2.3-4; eles ocupam o patamar imediatamente superior aos problemas associados ao processamento de imagens. A visão computacional exige a interpretação semântica dos objetos que compõem a imagem. Problemas de associação de um objeto presente numa imagem com uma descrição semântica formal, representam o estado de arte dessa área de conhecimento.



**Figura 2.3-4:** Nível de processamento dos sistemas de visão. Fonte: Montagem compilada pelo autor a partir de fontes diversas.

A complexidade inerente aos sistemas de visão é mais notada nos métodos de análise de imagens, que tem a função de criar representações de objetos presentes em imagens que sejam semanticamente associadas a conceitos. Essas associações vão de um nível mais baixo, quando se trata com níveis de intensidade de cores, detecção de bordas, etc., até tarefas bem mais complexas, como por exemplo, identificar padrões abstratos, como mostrados na Figura 2.3-5. Fragmentos de imagens de ataques de insetos e doenças estão associados à sua descrição textual, mas o mapeamento entre eles não é fácil nem mesmo para humanos que não tenham treinamento e experiência suficientes para fazê-lo.



**Figura 2.3-5:** Formas de difícil descrição/representação. Fonte: Montagem do autor.

O domínio do conhecimento associado aos sistemas de análise de imagens é extremamente complexo e variado (RUEDA *et al.*, 2007).

O reconhecimento de imagens requer bastante conhecimento prévio sobre o mundo e bastante capacidade de julgamento para emitir conclusões sobre os dados da imagem e, então, tomar uma ação adequada às necessidades do sistema. Por exemplo, um sistema de controle de qualidade precisa ter um conhecimento prévio sobre o que é uma peça fora da especificação, e para isso, necessita conhecer a especificação e a ação tomar para essa peça (descarte, conserto, etc.). Porém, para julgar os objetos e dados residentes em imagem, o sistema precisa inicialmente, extraí-los e representá-los adequadamente. Isso inclui, dentre outras coisas, a habilidade para remover o ruído das imagens, para lidar com diferentes configurações de iluminação e sombra (por exemplo: saber que o cinza escuro na sombra e o branco no claro são a mesma cor), ter a noção de perspectiva, capacidade de perceber profundidade a partir de uma visão estereoscópica e principalmente, reconhecer e isolar os objetos, os elementos realmente relevantes ao contexto, de uma dada cena (CHAN e SHEN, 2005).


Como ainda se sabe pouco sobre o funcionamento dessas técnicas de visão nos seres vivos, é um enorme desafio pensar implementá-las de maneira viável usando um computador; apesar de todo o estudo realizado na área, ainda não existe uma solução definitiva, única, para “o problema da visão computacional”. Tudo o que existe são na verdade algumas definições gerais e soluções esparsas para algum problema (leitura de texto, reconhecimento facial, etc.), pois, novamente, pouco se sabe sobre como a visão funciona (SIMON, 2012).

### **2.3.5. Aprendizagem de máquina**

Para entender aprendizagem de máquina, é necessário inicialmente definir o conceito de aprendizagem. Esse conceito encontra várias definições, como:

- “Aprendizagem é o processo pelo qual uma entidade adquire conhecimento”. (RICH e KNIGHT, 1991).
- “Aprendizagem é uma forma de inferência que objetiva começar com informações sobre o domínio e então, estendê-las de alguma forma”. (GINSBERG, 1993).
- "Aprender significa se comportar melhor ao adquirir experiência. Todo aprendiz aprende a representação de uma função." (RUSSEL e NORVIG, 2004)

A aprendizagem de máquina é uma subárea da I.A. voltada ao desenvolvimento de algoritmos e técnicas que permitam ao computador aprender. Existem vários mecanismos de aprendizagem; cada um deles pode ser aplicado a um grupo de situações e finalidades específicas. O processo de aprendizagem de máquina segue as seguintes fases, de acordo com o esquema mostrado na Figura 2.3-6 (RICH e KNIGHT, 1997):



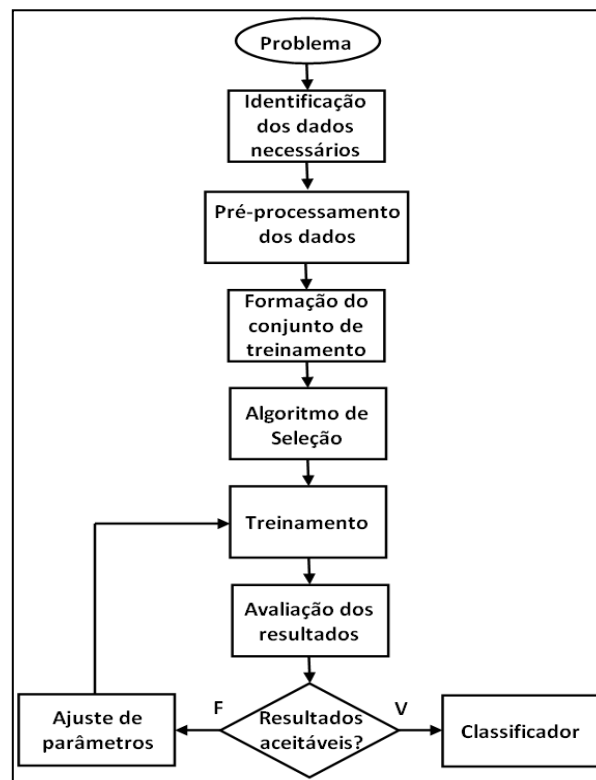
**Figura 2.3-6:** Fases do aprendizado de Máquina. Fonte: Montagem do autor a partir de RICH *et al.* (1997).

- **Treinamento:** Nesta fase, a informação sobre o que deve ser aprendido é de alguma forma inserida na máquina sob uma determinada representação. A representação do conhecimento aprendido é geralmente armazenada sob a forma de regras.
- **Validação** ou **Crítica:** Nesta fase, as regras são conferidas e, em caso de necessidade, um novo treinamento é realizado. A validação pode ser realizada com o auxílio de um especialista humano ou com o uso de outro componente baseado em conhecimento. É nesta fase que se verifica a qualidade da aprendizagem.
- **Aplicação:** As regras são usadas em resposta a uma nova situação.

Uma faceta bastante atraente dos sistemas de Aprendizagem de Máquina foi bem definida por *Herbert Simon*, um dos mais importantes pesquisadores da I.A.: “A aprendizagem denota mudanças no sistema que são adaptativas no sentido de que elas habilitam o sistema a realizar a mesma tarefa ou tarefas delineadas pela mesma população mais eficientemente a cada vez que são realizadas.” Ou seja, o sistema pode aperfeiçoar seu desempenho na medida em que aprende.

Um algoritmo mais refinado para aprendizagem de máquina é mostrado na Figura 2.3-7. Nele está incluída a tarefa de formação do *conjunto de treinamento*; tal informação, juntamente com o algoritmo de decisão, influencia diretamente na aprendizagem do sistema,

representando a “ponte” que leva o conhecimento do especialista à máquina.



**Figura 2.3-7:** Algoritmo de aprendizagem de máquina. Fonte: Montagem do autor Adaptado de (MICHALSKY *et al.*, 1983-a).

A complexidade relacionada à implementação de sistemas de aprendizagem aumenta conforme a facilidade de aprendizagem do sistema. Isto é definido pela estratégia adotada.

Em ordem crescente de complexidade e facilidade de aprendizagem, as principais estratégias usadas são:

- **Aprendizagem por memorização:** É a implantação direta do conhecimento; quando um computador armazena informação, ele está aprendendo de forma rudimentar. Esta forma de aprendizagem já é suficiente para permitir que um programa tenha melhor desempenho no futuro (MICHALSKY *et al.* 1983-a).
- **Aprendizagem por instrução:** A máquina recebe conselhos de fontes que tenha conhecimento de mais alto nível. Uma tarefa difícil nesta abordagem é que a instrução aconselhada deve ser operacional; (MICHALSKY *et al.* 1983-a);.
- **Aprendizagem por analogia:** Envolve a abstração de detalhes de um conjunto particular de problemas e a resolução de similaridades estruturais entre problemas previamente distintos. O raciocínio analógico se refere ao processo de reconhecimento e aplicação da solução do problema conhecido ao novo problema (RICH e KNIGHT, 1997).

- **Aprendizagem por exemplos:** Envolve a aprendizagem indutiva de conceitos. Os métodos que implementam esse tipo de aprendizagem tem o objetivo de classificar exemplos de maneira a construir uma definição de classe para os mesmos (RICH e KNIGHT, 1997).
- **Aprendizagem por observação e descoberta:** Esta abordagem procura eliminar o engenheiro do conhecimento do processo de descoberta, deixando para a máquina esta tarefa, utilizando-se do fato de que novos conhecimentos podem ser desenvolvidos mecanicamente pelo uso de heurísticas (LENAT, 1983).

#### 2.3.5.1. Sistemas de aprendizagem de máquina

Aprendizagem de Máquina da IA, que tem por objetivo o desenvolvimento de técnicas computacionais cognitivas, assim como a construção de sistemas capazes de adquirir conhecimento de forma automática.

Um sistema de aprendizado é um programa de computador capaz de tomar decisões baseado em experiências acumuladas através da solução bem sucedida de problemas anteriores, aprendidas automaticamente (MICHALSKY *et al.* 1983b).

- Processos associados aos sistemas de aprendizagem de máquina:
- Representação e manipulação de conhecimento.
- Desenvolvimento de técnicas motoras e cognitivas por meio de instrução ou prática.
- Generalização do conhecimento adquirido.
- Descoberta científica.

#### 2.3.5.2. Objetos e classes

Objetos e classes são elementos básicos constituintes dos sistemas de aprendizagem de máquina; são elementos necessários para representar os fatos da realidade, que pode ser moldada através do estabelecimento de relações entre instâncias desses elementos. Podem ser definidos da seguinte maneira (RUSSEL e NORVIG, 2004):

- **Objeto** é um conjunto de fatos ou propriedades associado um identificador; essas propriedades são suficientes para caracterizar o objeto de maneira unívoca, e representam o conhecimento, através de uma linguagem de descrição adequada. As propriedades podem variar de objeto para objeto. Um objeto pode ser parte de outros objetos.
- **Classe** é uma estrutura que permite o agrupamento de objetos semelhantes.

### 2.3.5.3. Classificação automática

Classificar é o processo de separar indivíduos, coisas e fenômenos, segundo alguns critérios, tomando como base algumas de suas características comuns. Os sistemas de aprendizagem utilizam mecanismos de classificação como base para sua operação. A classificação para um sistema deste tipo é o processo de atribuir a uma informação recebida (entrada do sistema) um nome que designa a classe à qual pertence; tal processo implica em estabelecer uma descrição para estas classes. Como as classes se apresentam de formas diferentes dependendo do uso ou aplicação a que são submetidas, tais descrições poderão ser realizadas de várias formas (MICHALSKY *et al.*, 1983.a).

Para que um sistema classificador possa atribuir a uma determinada entidade uma classe, é necessário que esta classe já tenha sido definida antes do processo de classificação ser iniciado. A definição das classes poder ser feita de várias maneiras, entre as quais, pela definição de cada classe como uma soma ponderada de características relevantes do domínio. Isso pode ser feito isolando-se um conjunto de características relevantes para o domínio da tarefa em um conjunto  $C$ , por exemplo (RICH e KNIGHT, 1997):

$$C = \{C_1, C_2, \dots, C_n\}.$$

Cada  $C_i$  representa o valor de um parâmetro relevante., ao qual é associado um valor  $p_i$  (discreto ou contínuo), como uma massa que exprime a existência ou a importância da característica associada. Uma classe pode então ser considerada como sendo uma função de avaliação do tipo:

$$f(C) = \sum_{i=1}^n C_i p_i \quad (\text{Eq. 2.3-1})$$

O termo “Aprendizagem de Máquina” (*machine learning*) pode ser definido como a tarefa de capacitar computadores para aprender um determinado comportamento ou padrão de maneira automática, a partir de exemplos ou observações.

### 2.3.5.4. Aprendizagem a partir de exemplos

A aprendizagem a partir de exemplos é um caso especial da aprendizagem por indução. Neste tipo de aprendizagem, é dado um conjunto de exemplos e contra-exemplos de um conceito. O aprendiz induz a descrição de um conceito geral que descreve todos os exemplos positivos e nenhum dos exemplos negativos. A quantidade de inferência realizada pelo aprendiz é bem maior que a da aprendizagem por instrução, onde nenhum conceito geral é

fornecido pelo instrutor, e é maior ainda que na aprendizagem por analogia, onde nenhum conceito similar é fornecido como “raíz”.

A aprendizagem a partir de exemplos pode ser caracterizada de acordo com a fonte dos exemplos (MICHALSKY *et al.* 1983b):

- **A fonte é um instrutor:** Neste caso, a fonte já conhece o conceito e gera sequências de exemplos deste conceito para o aprendiz; são escolhidos inicialmente, exemplos considerados os mais úteis possíveis, ou os mais relevantes. Se o instrutor conhece ainda o estado atual do aprendiz, os exemplos podem ser selecionados de maneira que a convergência para os conceitos a serem ensinados seja melhorada.
- **A fonte é o próprio aprendiz:** Neste caso, o aprendiz tem consciência do seu estado de conhecimento, mas não conhece o conceito a ser adquirido. O aprendiz gera então instâncias deste conceito, utilizando uma base de informações que ele acredite serem necessárias para discriminar entre as possíveis descrições do conceito. Essas instâncias são então classificadas como instâncias positivas ou negativas do conceito; para isso, o aprendiz deve recorrer ao auxílio de uma entidade externa, pois como ele não conhece o conceito, deve interrogar alguém que o conheça.
- **A fonte é o ambiente externo:** Neste caso, o processo de geração dos exemplos é operacionalmente aleatório, pois o aprendiz deve basear-se em observações relativamente não controladas. Pode-se ainda caracterizar esta aprendizagem considerando o tipo de exemplos apresentados ao aprendiz:
- **Apenas exemplos positivos estão disponíveis:** Os exemplos positivos fornecem as instâncias do conceito a ser adquirido. Eles não fornecem informações para a prevenção do problema da generalização em larga escala do conceito inferido. Neste tipo de situação, este problema pode ser evitado usando a mínima generalização necessária, ou então utilizar um conhecimento previamente adquirido sobre o domínio (restrição da inferência).
- **Exemplos positivos e negativos estão disponíveis:** Nesta situação, os exemplos positivos forçam a generalização e os negativos possibilitam evitar a generalização em larga escala.

#### 2.3.5.5. Aprendizagem incremental e não incremental

A aprendizagem a partir de exemplos pode utilizar basicamente dois domínios, ou tipos de

conjuntos de exemplos de treinamento (CARBONELL, 1989):

- **Estático:** onde o método de aprendizagem utiliza apenas um único conjunto de treinamento, que é fixo, invariável;
- **Dinâmico:** onde o método utiliza diferentes conjuntos de treinamento, que apresentam alterações a cada vez que são utilizados.

A aprendizagem realizada sobre domínios dinâmicos é bem mais abrangente e complexa:

Considerando a situação onde tenha sido gerada uma determinada base de conhecimento a partir da aprendizagem realizada sobre um determinado conjunto de treinamento, e em seguida, torne-se necessário apresentar novos exemplos para enriquecer a base de conhecimento existente. Nesse caso, duas possibilidades, definidas pelo algoritmo de apresentação de exemplos, são admitidas para a aprendizagem; são elas:

- **Não-Incremental:** neste caso (Figura 2.3-8), a base de conhecimento existente é descartada à medida em que novos conjuntos de treinamentos são apresentados. Os conjuntos de treinamento são formados pelos exemplos já processados e também pelos novos exemplos. Aparentemente, este algoritmo não é muito eficiente, pois terá que reaprender muitas das coisas que já havia aprendido. Veja por exemplo, o caso de se apresentar um novo conjunto de exemplos de tamanho muito reduzido: o algoritmo construiria uma nova base de conhecimento quase idêntica à anterior. Alguns autores chegam a afirmar que o uso deste algoritmo torna-se inviável quando se utiliza um grande e diversificado número de exemplos (MICHALSKY *et al.* 1983-b).
- **Incremental:** nesta situação (Figura 2.3-9), o conjunto de treinamento é apresentado juntamente com a base de conhecimento já existente. Desta maneira, existe o incremento da base de conhecimento a partir das novas observações notadas no novo conjunto de treinamento apresentado. Um sistema que utilize este algoritmo deve formar uma ou mais hipóteses do conceito (ou conceitos) consistentes com os dados disponíveis, e subsequentemente, refinar a hipótese após considerar exemplos adicionais. Essa abordagem é bastante interessante, pois permite a utilização de conceitos parcialmente aprendidos e permite ao instrutor focalizar sobre os aspectos básicos do novo conceito antes dos aspectos menos importantes. Em outras palavras, esse algoritmo incorpora conhecimento adicional a partir dos dados que avalia em sua execução histórica, desde que devidamente validado. As técnicas de aprendizagem incremental envolvem geralmente a adaptação gradual das estruturas de



aprendizagem; essa adaptatividade reflete a capacidade que o algoritmo tem de modificar a sua estrutura em resposta ao seu histórico de operações e aos dados de entrada.

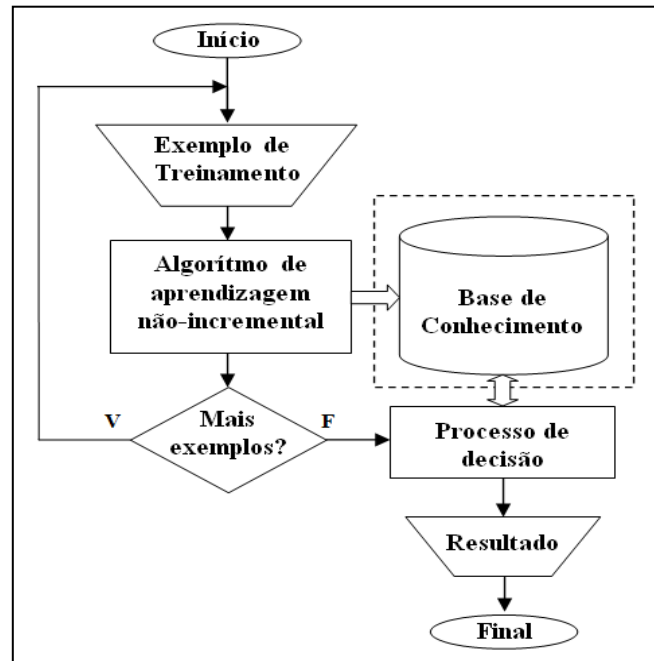


Figura 2.3-8: Algoritmo de aprendizagem não incremental. Fonte: Abstração do autor.

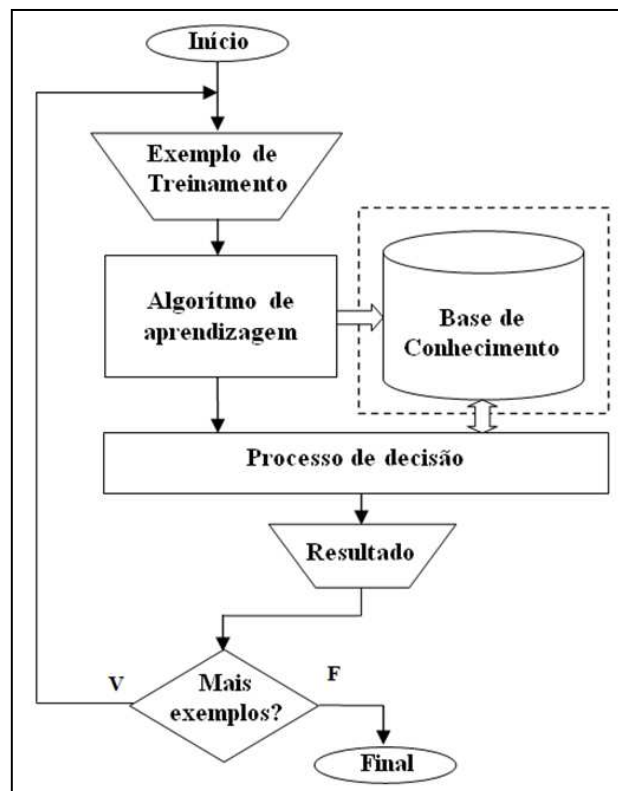


Figura 2.3-9: Algoritmo de aprendizagem incremental. Fonte: Abstração do autor.

Curiosamente, análises de desempenho mostram que os algoritmos não-incrementais são,

na maioria das vezes, mais eficientes que os algoritmos incrementais; para um único processamento utilizando domínios estáticos ou dinâmicos, os algoritmos incrementais são mais eficientes que os não-incrementais; a partir do segundo processamento, os algoritmos incrementais são mais eficientes sob certas situações utilizando domínios dinâmicos, mas de maneira geral os não-incrementais são mais eficientes (RICH e KNIGHT, 1997).

#### **2.3.5.6. Aprendizagem na presença de ruído**

O ruído pode ser definido como uma perturbação ou distúrbio, que ocorre em geral de maneira aleatória, reduzindo ou obscurecendo a qualidade de uma determinada informação. No contexto da aprendizagem de máquina a partir de exemplos, existem dois tipos de ruído (LIQUIÈRE e SALLANTIN, 1990):

- **Ruído de classe:** ocorre aleatoriamente alterando os valores das classes.
- **Ruído de atributo:** ocorre aleatoriamente alterando os valores dos atributos

Em sistemas de aprendizagem a partir de exemplos, estes erros têm sua origem fora do sistema; o conjunto de objetos da amostra já possui os erros (dados imperfeitos, imprecisos ou incoerentes) tanto nos exemplos positivos como nos exemplos negativos. Em alguns casos pode haver dados experimentais cujos atributos tenham valores com variações importantes (estatística experimental). Isto dificulta a tarefa de aprendizagem, pois no caso da presença de ruído, um exemplo positivo pode na verdade ser um exemplo negativo e vice-versa. Deve-se então, neste caso, descartar a indução de conceitos que correspondem a todos os exemplos positivos e nenhum negativo. Procedendo desta maneira, um sistema de aprendizagem a partir de exemplos portadores de ruído, realizará classificações sem considerar o erro presente em alguns dos exemplos, na esperança de que estes exemplos que contenham o erro sejam, de fato, exemplos positivos da classe ou um conceito aprendido. Desta maneira, este sistema teria se comportado como se tivesse ignorado os exemplos com erro, ou, numa visão mais otimista, os erros encontrados nos exemplos não teriam sido suficientes para descaracterizá-los.

Para aplicar os critérios de decisão, deve-se inicialmente estabelecer um filtro para a seleção. Isso pode ser feito através da inclusão de um limite positivo de validade majoritária, que seria (número mínimo de fatos que deverão ser verdadeiros para validar a característica), e um limite negativo de validade majoritária (número mínimo de fatos que devem ser falsos para invalidar a característica).

Na aprendizagem a partir de exemplos, uma das formas de analisar os critérios de

seleção, é a Aprendizagem Baseada em Similaridades (*SBL – "Similarity Based Learning"*), onde dados de um conjunto de exemplos de instâncias e de classes (ou categorias) às quais pertencem as instâncias é considerado. As instâncias são usualmente descritas em vetores de características. Para um sistema de reconhecimento, as classes devem ser constituídas de coisas naturais ou de conjuntos de estados do mundo onde alguma ação possa ocorrer. O resultado obtido por tal sistema é alguma representação operacional das classes. É possível então decidir classificar cada novo exemplo a partir de um procedimento bem formado, baseado na descrição aprendida nos exemplos anteriormente apresentados.

### 2.3.5.7. Discriminação e assimilação

Existem dois tipos de interpretação sobre os dados (LIQUIÈRE e SALLANTIN, 1990):

- **Assimilação:** Esse tipo de interpretação é identificado quando uma questão (função de busca) sobre um determinado conjunto de elementos abrange em sua resposta, todos os elementos do conjunto. Uma assimilação parcial é o resultado de uma busca que obtém como resposta quase todos os objetos do conjunto.
- **Discriminação:** Considere dois conjuntos de objetos E e C; Esse tipo de interpretação será identificado quando o resultado de uma questão fornecer um resultado R, tal que  $R \subseteq E$  e  $R \cap C = \emptyset$ . A discriminação parcial é observada quando o resultado da questão abrange quase todos os objetos do conjunto E e raros objetos do conjunto C.

### 2.3.5.8. Intensão e extensão

A “Intensão” é o princípio pelo qual os objetos são escolhidos ou, em outras palavras, a condição que um objeto tem de satisfazer para ser corretamente descrito pelo predicado; já a “extensão” de um predicado é a classe dos objetos que ele descreve (BRANQUINHO *et al.*, 2006).

Existem dois tipos de classes (LIQUIÈRE e SALLANTIN, 1990):

- A **Classe Intensional**<sup>12</sup>: é definida em intensão sobre um conjunto de fatos e um mecanismo de decisão. Esta classe é formada pelos objetos validados pela função de decisão.
- A **Classe Extensional**<sup>13</sup> é definida em extensão. E esta classe é definida pelo conjunto

---

<sup>12</sup> A intensão expressa as propriedades conotadas por um conceito.

<sup>13</sup> A extensão é a classe de objetos denotadas por um conceito específico.

de instâncias associadas à mesma. Esse conceito assemelha-se ao conceito do mesmo nome no campo da física, onde significa as propriedades da matéria pela qual os corpos ocupam uma parte do espaço.

### 2.3.6. Lógica “Fuzzy”

A ideia sobre conjuntos *fuzzy*, que deu origem à lógica *fuzzy*, surgiu em 1965, quando o matemático do Azerbaijão, *Lofti A. Zadeh* pensou em atribuir significados a termos linguísticos adstritos de cunho qualitativo e subjetivo, como por exemplo: “quente”, “perto”, “alto”. Através de tais conjuntos, seria possível manipular dados imprecisos em computadores, ou seja, lidar com informações vagas ou ambíguas. Esta capacidade está conceitualmente aproximada dos processos análogos ao raciocínio humano, encontrando sua utilização em várias aplicações da inteligência artificial (KLIR e YUAN, 1995).

O conceito denominado "fuzzy" denota ainda uma situação onde não é possível empregar objetivamente os termos (valores) "Sim" ou "Não", mas um termo entre "sim" e "não", como por exemplo "talvez", "quase", etc.

A lógica *fuzzy* trabalha com os conceitos de possibilidade, sendo diferenciada da probabilidade, já que não possui uma formalização matemática como a da probabilidade.

#### 2.3.6.1. Conjuntos “Fuzzy”


Na teoria dos conjuntos *fuzzy*, existe uma função de pertinência que atribui a cada elemento do universo um valor no intervalo  $[0,1]$ . Um conjunto definido como base desta função é denominado “Conjunto *Fuzzy*”, e o grau de pertinência é pré-estabelecido, dado por um avaliador especialista (COX, 1994).

Seja  $Z$  uma coleção de objetos denominados genericamente por  $\{z\}$ .  $Z$  é chamado de universo de discurso, seja contínuo ou discreto. Um conjunto *fuzzy*  $A$  em um universo de discurso  $Z$  é definido por uma função de pertinência  $\mu_A$  que assume valores em um intervalo  $[0,1]$ :  $\mu_A: Z \rightarrow [0,1]$ ; O conjunto *fuzzy*  $A$  em  $Z$  é um conjunto de pares ordenados:  $A = \{\mu_A(z)/z\}$ ,  $z \in Z$ .

As operações de conjuntos *fuzzy*, podem ser expressas da seguinte maneira: (COX, 1994):

- **Inclusão:** Se o grau de pertinência de cada elemento do universo  $U$  em um conjunto *fuzzy*  $A$  for menor ou igual ao grau de pertinência no conjunto *fuzzy*  $B$ , então diz-se que  $A$  é um subconjunto de  $B$ ; ou seja:  $\mu_A(x) \leq \mu_B(x)$ .
- A **igualdade** é definida por:  $\mu_A(x) = \mu_B(x)$
- O **complemento** é definido por:  $\mu_{\tilde{A}}(x) = 1 - \mu_A(x)$
- A **união** de dois conjuntos *fuzzy*  $A$  e  $B$  é um conjunto *fuzzy*  $A \cup B$  tal que:  $\mu_{A \cup B}(x) = \max[\mu_A(x), \mu_B(x)]$  para todo  $x \in U$ ; trata-se na verdade, do grau de pertinência em relação a  $A$ , ou ainda o grau de pertinência a  $B$ , o que for maior.
- A **interseção** de dois conjuntos *fuzzy*  $A$  e  $B$  é um conjunto *fuzzy*  $A \cap B$  tal que:  $\mu_{A \cap B}(x) = \min[\mu_A(x), \mu_B(x)]$  para todo  $x \in U$ . É na verdade, o grau de pertinência a  $A$  ou o grau de pertinência a  $B$ , o que for menor.

Uma “variável linguística” é na lógica *fuzzy*, uma entidade que representa um valor impreciso associado a um determinado conceito. A lógica *fuzzy* manipula variáveis linguísticas para representar o conhecimento (situação-problema), de maneira próxima à realidade, onde nem sempre os valores são precisos. Uma variável linguística pode ser representada por vários conjuntos *fuzzy* existentes num universo  $U$ , onde  $\mu_A(x)$  representaria o quanto o elemento  $x$  satisfaz o conceito linguístico associado ao conjunto *fuzzy*  $A$ .



**Figura 2.3-10:** Valores da variável *fuzzy* “Temperatura do Ambiente”. Fonte: Adaptado pelo autor de WEBER e KLEIN (2003).

A Figura 2.3-10 apresenta uma variável *fuzzy* associada à temperatura ambiente, e demonstra como os valores “fuzzificados” são representados. Se for perguntado a um grupo de pessoas, qual seria a temperatura associada aos conceitos “muito frio”, “frio”, “quente” e “muito quente”, as respostas obtidas não seriam certamente idênticas, mas variariam dentro de uma faixa de valores; por exemplo: todas as pessoas poderiam responder que uma temperatura “muito fria” estaria certamente abaixo de 10°C; um subgrupo bem menor dessas

pessoas poderia responder que 18°C seria “muito fria”. O gráfico mostra como esse grupo de pessoas entende esses conceitos.

### **2.3.7. Redes neurais artificiais**

Todos os mecanismos de aprendizagem de máquina apresentados nos itens anteriores são denominados “sistemas simbólicos”, pois o conhecimento é representado em uma linguagem de alto nível, a “lógica simbólica”; essa linguagem é a base para a maioria dos formalismos de representação e manipulação de conhecimento em I.A., seja de forma explícita como nos sistemas especialistas, seja disfarçada na forma de representações específicas, que podem facilmente ser interpretadas como proposições ou predicados lógicos.

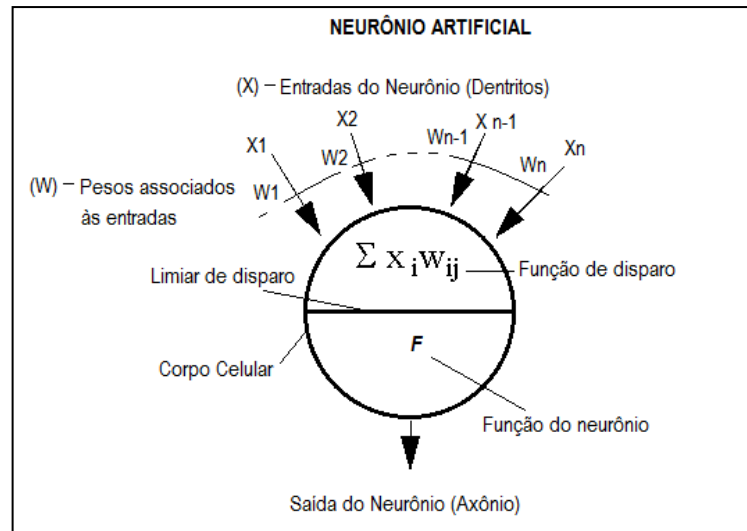
No entanto, problemas de eficiência, facilidade de uso e a necessidade de expressar conhecimento incerto e incompleto levaram ao desenvolvimento de diversos outros tipos de formalismos de representação de conhecimento, inclusive através de estruturas extralógicas, como por exemplo, as denominadas conexionistas, representadas pelas Redes Neurais Artificiais (RNAs).

RNAs são técnicas computacionais que utilizam modelos matemáticos inspirados na estrutura neural de organismos inteligentes, como os humanos, capazes de adquirir conhecimento através da experiência. O objetivo do desenvolvimento das RNAs é justificado por uma antiga aspiração do homem: criar máquinas que simulem a inteligência do cérebro humano (HAYKIN, 2001).

Uma rede neural artificial é composta por um arranjo de unidades funcionais, denominadas neurônios artificiais (Figura 2.3-11) interconectados, que trabalham em paralelo e são empregados em diversas tarefas, geralmente envolvendo classificação e generalização de dados de entrada em classes de saída.


Pesos ajustáveis são multiplicados aos valores presentes nas interconexões das entradas, determinado o nível de ativação da unidade na rede. A atividade de cada unidade influencia o nível de ativação das demais, até que o ajuste dos pesos alcance valores que permita à rede operar com resultados de saída esperados, quando se diz que a rede “aprendeu” sua tarefa. Assim, o aprendizado da rede é determinado por um processo repetitivo que tenta adequar os pesos a uma saída correta esperada, para cada amostra de treinamento.

É relevante salientar que um resultado significativo requer um conjunto de treinamento com amostras puras e representativas das classes (KOVÁCS, 2006).



**Figura 2.3-11:** O Neurônio Artificial. Fonte: Adaptado pelo autor de KÓVACS (2006).

Como os elementos das redes neurais são todos ligados por conexões, a denominação “Sistemas Conexionistas” tornou-se sinônimo de RNAs. Os sistemas conexionistas têm sido largamente utilizados no desenvolvimento das mais diversas aplicações, como controle e otimização, linguagem natural, sistemas caóticos, sistemas de predição (ex.: análise de aplicações financeiras), reconhecimento de voz, controle de manipuladores robóticos, classificação, visão artificial, reconhecimento de padrões em imagens, entre outros (KOVÁCS, 2006).



**Figura 2.3-12:** Rede Neural Artificial (RNA). Fonte: Abstração do autor.

As RNAs são geralmente organizadas em camadas (Figura 2.3-12) que por sua vez, são classificadas em três grupos:

- **Camada de Entrada:** onde os padrões são apresentados à rede para treinamento ou uso;
- **Camadas Intermediárias:** Também denominadas Camadas Ocultas – onde se realiza a maior parte do processamento, através das conexões ponderadas.

- **Camada de Saída:** onde o resultado final é apresentado.

Uma rede neural é especificada, principalmente pela sua topologia, pelas características dos nós e pelas regras de treinamento.

## 2.4. Mecanismos para seleção e classificação

Esta parte apresenta como único item, a pesquisa realizada sobre o atual estado de desenvolvimento dos mecanismos automáticos para classificação de produtos agrícolas, com interesse voltado sobretudo, para aqueles que classificam mangas e outras frutas através de imagens, com uso de sistemas de visão computacional. De início, foi pesquisada a tarefa de classificação, os objetos ou atributos envolvidos nesse processo, assim como os métodos atualmente disponíveis que analisam a cor da superfície e a forma. Em seguida, foi realizada uma busca por padrões estabelecidos dentro e fora do país para análise dos parâmetros utilizados. No final, procurou-se analisar a utilização desses dispositivos em aplicações reais, através da busca de fabricantes de equipamentos que empregam essas tecnologias.

Esta pesquisa foi guiada através de resumos encontrados em vários trabalhos, com destaque para: (SALDAÑA *et al.*, 2013), (GARCIA-RAMOS *et al.*, 2005), (GILL *et al.*, 2014) e (KAPACH *et al.*, 2012).

### 2.4.1. Processos de avaliação Pós-colheita

Os processos de avaliação de frutas são realizados após a colheita, e podem ser considerados sob os seguintes critérios ou visões:

- Quanto ao **objetivo**:
  - **Seleção:** vários parâmetros são avaliados, principalmente: estadio de maturação, dimensões, massa, volume, massa específica, uniformidade da forma, ocorrência de danos oriundos de pragas e/ou doenças.
  - **Classificação:** Permite associar um fruto a um padrão comercial, através de vários atributos.
- Quanto ao **mecanismo de manipulação**:
  - *Não automatizado:* Utilizando unicamente a mão-de-obra humana.
  - **Processo parcialmente automatizado:** Utilizando máquinas que substituem parcialmente a mão-de-obra humana em tarefas insalúbres, tediosa, etc.



- **Processo totalmente automatizado:** Utilizando máquinas apenas, sem qualquer intervenção humana objetiva.
- Quanto à **integralidade do fruto:**
  - **Análise destrutiva:** O fruto é parcialmente ou totalmente destruído durante a avaliação.
  - **Análise não-destrutiva:** O fruto é preservado para consumo após a avaliação.

Este trabalho propõe métodos de seleção e classificação para a manga *Tommy Atkins*, não destrutivos, que podem ser implementados para sistemas parcialmente ou totalmente automatizados.

- Quanto à **parte da fruta a ser analisada:**
  - **Interna:** Análise de parâmetros localizados no interior da fruta.
  - **Externo:** Análise de parâmetros localizados no exterior da fruta.

#### 2.4.2. Atributos de avaliação

Segundo KADER (1992), a qualidade dos frutos e vegetais é uma combinação de atributos que determinam o seu valor como alimento:

- **Aparência visual** (frescura, cor, defeitos, doenças)
- **Textura** (firmeza, suculência, integridade dos tecidos)
- **Gosto** (sabor, cheiro)
- **Valor nutritivo** (teor em vitaminas, minerais e fibras)
- **Segurança** (ausência de resíduos químicos e contaminação microbiana)

Os métodos de seleção e classificação devem ser adequados para mensurar esses atributos, que são qualitativos ou quantitativos. A medição das propriedades qualitativas é mais complexa do que medir as propriedades quantitativas; essa possibilidade permite supervisionar, normalizar e tipificar os produtos, de modo a aferir mais fielmente sua qualidade e estabelecer uma maior valorização econômica para os mesmos. Nesse contexto, as medidas instrumentais são majoritariamente preferidas, pois podem reduzir as variações introduzidas pela análise sensorial individual, através do uso de uma linguagem comum. Os parâmetros podem ser associados a características ou propriedades físicas e químicas; por exemplo, ABBOTT (1999) relaciona a aparência com propriedades da ótica; a textura com propriedades da mecânica, e o sabor e aroma, com propriedades químicas.

Os principais componentes de avaliação interna e externa são mostrados no Quadro 2.4-1, enquanto alguns dos vários parâmetros e sensores envolvidos nessas análises, juntamente com alguns dos diversos estímulos e grandezas psicofísicas envolvidas, estão resumidos no Quadro 2.4-2.

Os sistemas de avaliação automáticos empregam sensores artificiais em substituição aos sensores humanos, que atuam sobre uma ou mais grandezas para aferir seu valor quando associado à qualidade da fruta.

**Quadro 2.4-1:** Principais componentes envolvidos na análise sensorial. Adaptado pelo autor a partir de (SANTOS, 2012).

Área	Componente	
Externa	Tamanho	Massa Volume Dimensões
	Forma	Diâmetros Aproximação de figuras geométricas
	Cor	Uniformidade Intensidade Distribuição
	Defeito	Arranhões Cortes Pontos (pretos)
Interna	Sabor	Doçura Amargor Adstringência Aroma
	Textura	Firmeza Crocância Suculência
	Nutrição	Percentual de substâncias: Carboidratos, Proteínas, vitaminas, etc.
	Defeito	Doenças Pragas Danos por frio Podridão Contaminação

No presente trabalho, o interesse está centrado na parte exterior da fruta, onde a análise recai sobre a cor, tamanho, forma e defeitos (Quadro 2.4-1). Nesse caso, a visão é o estímulo de interesse para a análise da aparência visual das frutas; alguns outros atributos como o aroma e a firmeza são importantes para a avaliação de frutas; porém, como não são aferidos por sistemas baseados em imagens, não são explorados com maior detalhamento.

**Quadro 2.4-2:** Principais componentes envolvidos na análise sensorial. Adaptado pelo autor a partir de (SANTOS, 2012).

Sistema sensorial Humano	Natureza do estímulo	Grandeza psicofísica associada	Sensor Artificial
Visão	Fótons.	Cor, Brilho, Saturação.	Células solares, Fotodíodos, Fototransistores, Tubos fotoelétricos, CCDs , Câmeras, Resistores LSR.
Audição	Vibrações mecânicas do ar.	Tibre, Intensidade.	Microfones ultra-sensíveis; Transdutor eletroacústico.
Tato	Resistências mecânicas.	Rugosidade, Adstringência.	Nanopartículas associadas (ouro e sulfeto de cádmio))
Sensibilidade cinestésica.	Resistências mecânicas.	Dureza, Elasticidade, Plasticidade.	Acelerômetro, Giroscópios.
Sensibilidade térmica da pele	Calor e Temperatura.	Morno, Frio.	Bolômetro, Termômetros, Termopares.
Sensibilidade química geral	Molécula em contato direto.	Picante, Ardente, Irritante, etc.	Elétrodos seletivos, Reagentes químicos.
Gosto	Molécula em solução na saliva.	Ácido, Doce, Amargo, etc.	Colorímetros, Refratômetros (BRIX), Condutômetros (salinidade).
Olfato	Molécula em fase gasosa.	Intensidade do odor, Descritores de aromas.	Nariz Artificial, Gasômetros.
-	Radiação ionizante de alta energia	-	Contador Geiger, Dosímetros, Cintiladores.

### 2.4.3. Parâmetros para avaliação

#### 2.4.3.1. O aroma

O aroma pode ser definido como uma qualidade que é percebida pelo olfato, associada à presença de compostos químicos voláteis.

Com o amadurecimento da fruta, ocorre o aumento da concentração de compostos orgânicos voláteis, cujo aroma é um indicativo do seu estágio de amadurecimento. O aroma também pode indicar a ocorrência de danos de origem mecânica, térmica, doenças ou patógenos.

Para analisar o aroma de uma fruta de maneira automática, os produtos voláteis devem ser analisados em laboratório, utilizando métodos como cromatografia em fase gasosa e espectrometria de massa.

Recentemente, um dispositivo denominado nariz eletrônico (*E-nose*) foi desenvolvido por GARDNER e BARTLETT (1999); ele permite a identificação de substâncias voláteis a partir da “inalação” dos gases que a fruta emite. Existe uma versão portátil do aparelho, permitindo seu uso em campo.

Alguns trabalhos têm sido desenvolvidos com a utilização do E-nose para análise de qualidade de frutas, dentre os quais: maçã (BREZMES *et al.*, 2001), banana (LLOBET *et al.*, 1999), uva (PATTERSON, 2007), tangerina (GOMEZ *et al.*, 2007), pêssego (BENEDETTI *et al.*, 2008) e tomate (GOMEZ *et al.*, 2006) e frutas em geral (SALIM *et al.*, 2005).

A tecnologia do nariz eletrônico ainda é incipiente e não permite seu uso em larga escala, devido às especificidades do procedimento de medição.

Outras tecnologias emergentes são capazes de emular uma língua artificial; alguns aparelhos já são capazes de detectar, com razoável intervalo de valores, sensações associadas a algumas substâncias, como: azêdo (HCl - ácido clorídrico); salgado (KCl - cloreto de potássio); amargo, (Quinino) e doce (Sacarose - açúcar).

A análise do aroma não faz parte da abordagem deste trabalho; a avaliação do estágio de maturidade da manga se dará através de avaliação visual.

#### **2.4.4. A cor da superfície**

O aspecto visual das frutas é um dos principais fatores considerados pelos consumidores, sendo a cor um critério particularmente importante, por ser considerado em muitas normas como determinante de qualidade.

As frutas são em sua grande maioria objetos opacos, onde a maior parte da energia da luz incidente só penetra até uma distância muito pequena da superfície, sendo refletida. A energia luminosa refletida sofre a influência de alguns elementos presentes na fruta, como a concentração de pigmentos, como os carotenóides, dentre eles as antocianinas, e os flavonóides, além da clorofila (GROSS, 1987), (MAZZA e MINIATI, 1993).

A cor verde nas superfícies dos frutos ocorre essencialmente pela presença da clorofila; a quebra da estrutura desse pigmento, que é causada pela presença de sistemas oxidantes, implica na degradação dessa cor nos tecidos, tornando visíveis os pigmentos pré-existentes, ou mesmo ocorrendo a síntese de novos pigmentos (como os carotenóides e os flavonóides), que gradativamente se tornam responsáveis pela coloração característica de cada espécie ou de cada cultivar. Em muitas frutas, ocorre a substituição total do verde, como ocorre na

manga *Tommy Atkins*, onde surgem pigmentos amarelos, vermelhos ou púrpuros. (AWAD, 1993), (CHITARRA e CHITARRA, 2005).

As diferentes concentrações e alterações na distribuição desses pigmentos sobre a pele dos frutos, afetam a percepção da cor dos mesmos; a perda da cor verde é geralmente utilizada como indicativo ou guia da maturidade. Por estar diretamente relacionada ao amadurecimento das frutas, a cor da pele é frequentemente utilizada como um importante índice de maturação (TUCKER, 1993), além de ser evidentemente, um fator estético importante.

A cor da pele de frutas pode ser avaliada de maneira não-destrutiva através do uso de tecnologias capazes de mensurar componentes da luz, como:

- **Colorímetros:** São instrumentos que realizam a quantificação da cor de maneira similar à percepção humana, dividindo a informação da cor no espectro visível em três componentes, funcionando como as células-cone vermelho, verde e azul do olho humano.
- **Espectrofotômetros:** Funcionam de maneira similar aos colorímetros, sendo projetados para fornecer informações mais detalhadas sobre as propriedades ópticas da pele da fruta. Geralmente, a informação do espectro visível é dividida em quinze ou mais componentes.
- **Sistemas de visão baseados em computador:** Utilizam técnicas de computação gráfica e inteligência artificial para identificar padrões presentes na amostra e compará-los a outros padrões pré-estabelecidos.

#### **2.4.4.1. Padrões comerciais de cores para avaliação de qualidade de frutas**


A utilização de padrões de cores para selecionar frutas pelas cores da superfície é aplicada tanto para determinar a maturação da fruta, quanto para atender a critérios mais subjetivos, como a estética.

No caso da avaliação da maturação, os padrões são definidos em níveis, que indicam a aparência da fruta em determinado estágio de seu desenvolvimento. O estado de maturação de uma fruta não é um fenômeno linear, e mais: pode ser modificada e ter sua relação aparência versus tempo modificada, com o uso de técnicas agrícolas de aceleração e retardo do amadurecimento; como a imagem da fruta também é afetada por essas técnicas, a indicação do estado (e não do tempo) de maturação a partir da imagem da fruta torna-se possível.

De acordo com REID (2002), a colheita do fruto após sua maturidade é uma garantia de que a sua qualidade vai atingir o nível aceitável para a satisfação do consumidor. Para frutos climatéricos como a manga, a qualidade desejada não é obtida no instante em que estes se tornam maduros, sendo requerindo um período de maturação adicional que varia, dependendo da cultivar, de 8 a 10 dias, num ambiente cuja temperatura esteja em torno de 25°C, para que venha a atingir o sabor e textura desejados pelo consumidor. Apesar da importância dessa afirmação, não existem sistemas autônomos capazes de estimar o estado de maturidade da manga antes da colheita, pois as árvores são estruturas complexas e a fruta podem ser distribuídas sem qualquer ordem previsível (distribuição espacial caótica). Além disso, as árvores são submetidas a intempéries como o vento e as chuvas, que agitam os frutos e tornariam impossíveis quaisquer análises com os equipamentos atualmente disponíveis, sem intervenção humana. Logo, os estudos têm se concentrado em atividades pós-colheita.

A classificação dos frutos durante o beneficiamento (pós-colheita), pelo seu grau de maturidade, pode filtrar algumas deficiências provenientes do processo de colheita, como por exemplo, a colheita de mangas imaturas ou mal-formadas. Evidentemente, a manga filtrada não teria o aproveitamento inicialmente desejado, mas pode ter alguma outra utilidade, como a alimentação animal ou a produção de fertilizantes.

Os padrões são geralmente estabelecidos pelo comprador, que dita os critérios de avaliação. Um desses padrões é o definido pela EMBRAPA, descrito em ASSIS *et al.* (2008), que estabelece faixas de cobertura cromática para a manga *Tommy Atkins*, divididas em cinco níveis que vão da fruta totalmente verde, passando por faixas intermediárias de maturação, até a fruta madura (Figura 2.4-1):



**Figura 2.4-1:** Mangas associadas aos níveis do padrão Embrapa. Fonte: Extraída de ASSIS *et al.* (2008).

Este padrão define a sua função de pertinência como está definida na Tabela 2.4-1.

**Tabela 2.4-1:** Percentuais dos níveis do padrão Embrapa. Fonte: Extraída de ASSIS *et al.* (2008).

Nível	Cor (%)		
	verde	vermelho	amarelo
1	100	-	
2	75	25	
3	50	50	
4	25	75	
5	-	75	25

O padrão definido por AMORIM (2002) é também utilizado para avaliação da maturidade da manga a partir da coloração da superfície foi obtido através do uso de uma medida subjetiva, onde se considera o percentual de cor vermelha na manga (Tabela 2.4-2). Esse padrão denomina-se “Escala de Blush para coloração da superfície (EBCC)”. A escala é enumerada de 1 a 5, de maneira similar ao padrão Embrapa, onde cada número corresponde a uma faixa percentual da cor vermelha: 1-0%; 2->0-25%; 3->25-50%; 4->50-75%; e 5->75-100%.

**Tabela 2.4-2:** Níveis da Escala de Blush. Fonte: Extraída de AMORIM (2002).

Nível Blush	Cor vermelha (%)
1	0
2	0 - 25
3	25 - 50
4	50 - 75
5	75 - 100

A norma técnica NTC 5139 (ICONTEC, 2002) é um padrão Colombiano para classificação da manga segundo seu estágio de maturação. Também define cinco níveis, sendo em sua essência, idêntico ao estabelecido pela Embrapa.

Em complemento à escala de Blush, em LI *et al* (2009) encontra-se um padrão que define uma escala para estimação da maturação, que considera apenas as cores verde e amarelo, sendo também definido em cinco níveis, como mostra a Tabela 2.4-3.

**Tabela 2.4-3:** Níveis da Escala de LI. Fonte: Extraída de ICONTEC (2002).

Nível	Cor da superfície (%)	
	Verde	Amarelo
1	100	-
2	75	-
3	50	50
4	-	75
5	-	100

Um padrão similar ao de LI, que de igual maneira relaciona a cor da superfície da manga *Tommy Atkins* ao seu estágio de maturação, pode ser encontrado em GTZ (1992) e também em AMORIM (2002); ele está definido como mostra a Tabela 2.4-4.

**Tabela 2.4-4:** Padrão definido por GTZ (1992). Fonte: Extraída de GTZ (1992).

Nível	Cor	Percentual de cobertura
1	Verde-escuro	0
2	Verde-claro	25
3	Verde-amarelo	50
4	Amarelo-verde	75
5	Amarelo	100

Alguns padrões são definidos de maneira um mais abstrata, sem a especificação de percentuais de cobertura, mas de predominância de cores, como é o caso do padrão encontrado em JACOBI ET AL. (1998), que apresenta um padrão comercial de maturidade pela distribuição das cores na superfície das mangas das variedades *Kensington* e *Tommy Atkins*, definidas em cinco níveis. Uma curiosidade sobre esse padrão, é que a escala é invertida em relação às anteriores, iniciando pelo nível de maior maturidade (Tabela 2.4-5).

**Tabela 2.4-5:** Padrão definido por JACOBI et al. (1998). Fonte: Extraída de JACOBI ET AL. (1998).

Nível	Distribuição de cores na superfície
1	totalmente amarelo / vermelho
2	predominantemente amarelo-laranja / vermelho.
3	maior parte amarelo-laranja / vermelho com apenas um toque de verde
4	maior parte amarelo-laranja / vermelho que verde
5	metade verde, metade amarelo-laranja / vermelho

**Tabela 2.4-6:** Escala de maturação para a manga *Tommy Atkins*, MILLER (1991). Fonte: Extraída MILLER e McDONALD (1991).

Nível	Verde	Vermelho / Amarelo
1	100	0
2	75	1 - 25
3	50	26 - 50
4	25	51 - 75
5	0	76 - 100

Em MILLER e McDONALD (1991) encontra-se um padrão para estimação do estágio de maturação da manga *Tommy Atkins* através de uma escala que considera principalmente, a proporção da distribuição da cor verde sobre a superfície (Tabela 2.4-6); as cores típicas da manga são apresentadas como dado complementar. Essa abordagem é interessante, pois a distribuição das cores complementares (amarelo e vermelho) varia em função de vários fatores, dentre os quais a cultivar, a irradiação solar, etc. A cor amarela é predominante nos



estádios de maturação mais avançados. Pode ser observado que esse padrão é similar ao da EMBRAPA.

#### **2.4.5. Firmeza**

A firmeza dos frutos é uma medida importante de maturidade de frutos, pois afere a integridade dos tecidos do fruto, que se deterioram ao longo do processo de maturação. Existem métodos destrutivos e não-destrutivos para a estimação da firmeza de uma fruta; o mais tradicional deles, baseia-se num teste destrutivo: penetrometria (MAGNESS e TAYLOR, 1925). Alguns outros métodos de natureza não-destrutiva têm sido desenvolvidos (AWETA, 2013); (GREEFA, 2008); (SINCLAIR, 2013); (BORGES, 2011). Em GARCIA-RAMOS *et al.* (2005) encontram-se mecanismos para a avaliação das relações força-deformação, resposta acústica a impactos e vibrações em frutos.

A grande maioria dos métodos de medição de não-destrutivos da firmeza são baseados em resposta de aceleração (CHEN, 2001), (BORGES, 2011), análise resposta de sinais acústicos explorando várias faixas de frequência que são aplicadas de acordo com as especificidades do fruto, variando desde as faixas vibracionais mais baixas (200hz), passando pelas ondas sônicas - entre 5 e 10KHz; ultrassom - entre 50 Khz e 5 MHz (OLSEN *et al.*, 2006).

Assim como o aroma, a análise da firmeza das frutas não faz parte da abordagem deste trabalho.

#### **2.4.6. Forma, tamanho e massa**

A forma é um dos mais importantes parâmetros de qualidade para avaliação pela preferência do consumidor

Para analisar formas de frutas, são empregados métodos de natureza não-destrutiva, baseados principalmente em métodos de computação gráfica associados a métodos de inteligência artificial. Tais métodos consistem basicamente em encontrar similaridades entre os contornos do fruto e um padrão previamente definido. Outros métodos utilizam uma abordagem mais específica, extraindo dados morfométricos a partir de imagens das frutas e comparando com modelos geométricos.

Os métodos que possibilitam a estimação da forma, podem ser adaptados para extrair a informação das dimensões da fruta (tamanho). A massa é geralmente estimada a partir das informações relacionadas ao volume.

A estimação de massa e volume de mangas e outras frutas seguem frequentemente os métodos tradicionais, como descritos em MOHSENIN (1978); existem porém trabalhos que apresentam modificações, principalmente, no modelo matemático associado às frutas. São poucos os trabalhos que utilizam técnicas de processamento de imagens para estimar massa e volume de mangas.


## 2.5. Métodos para avaliação

Nos últimos anos, vários métodos tem sido desenvolvidos para a avaliação não destrutiva de frutos para a determinação da qualidade. Tais métodos são tão variados quanto os próprios atributos que eles verificam em suas análises. Algumas características externas dos frutos são considerados para essas avaliações e permitem a estimação da maturação; dentre eles:

### 2.5.1. Métodos de avaliação pela cor

Em IQBAL *et al.*, (2012) é apresentado um sistema eletromecânico para triagem e classificação de maçãs, além de outras frutas, utilizando tecnologia de visão computacional. A avaliação é feita sobre as cores, em busca de imperfeições, em um sistema mecânico onde uma garra giratória segura a fruta e a gira 360°, para a captura de imagens por uma câmera fixa. A alta taxa de resposta é uma das principais características do sistema, capaz de processar 5 maçãs por segundo. A tecnologia inclui ainda um dispositivo para a orientação da fruta.

Um trabalho desenvolvido por SIMÕES e COSTA (2003) apresenta um sistema automático para classificação de laranjas, com base no padrão brasileiro de cores para a laranja, utilizando como mecanismo de comparação entre as imagens obtidas e os padrões estabelecidos, a quantização vetorial. O sistema consegue detectar a ocorrência de cores em até cinco níveis (Figura 2.5-1). As cores estão relacionadas com o estado de maturação da fruta.



**Figura 2.5-1:** Padrão de cores para classificação de laranjas. Fonte: Extraído de SIMÕES E COSTA (2003).

Um sistema de classificação pela cor, baseado em visão computacional é apresentado em CHAN *et al.*(2007). Esse sistema utiliza funções do MATLAB<sup>14</sup> para analisar as cores dos objetos a serem inspeccionados (frutas em geral). Seus processos incluem problemas de decisão e o cálculo dos valores médios de histogramas de cores; o resultado, aplicados a quatro frutos tropicais. Uma das aplicações do sistema é separar os frutos maduros dos imaturos.

BULANON *et al.* (2013) desenvolveram um algoritmo de imagem multiespectral para detectar pontos negros em cítricos, com base em dados de imagens hiperespectrais na faixa de comprimento de onda de 480 nm a 950 nm. A análise se deu sobre diferentes condições de superfície das frutas e a classificação se deu empregando RNAs e discriminantes lineares. A precisão chegou a 92%, mas foi substancialmente melhorada para 96% , variando a faixa de detecção espectral para o intervalo de 713 nm a 781 nm

Em RIYADI *et al.* (2007), é encontrado um método para classificação de mamão para exportação, onde a estimacão da massa é o mais importante parâmetro. Utiliza a tecnologia de visão computacional. A metodologia envolve as medições do volume real e do real de amostras de mamão para estabelecer uma correlacão; os resultados obtidos demonstraram que os parâmetros de massa e de volume são altamente correlacionados. A imagem do mamão é utilizada para filtragem da cor verde, que tem contraste com a cor de fundo preto; a área do mamão é calculada através da medição do raio do objeto na área verde específica e a integracão ao longo do seu comprimento. A massa de cada mamão é estimada usando as informacões do volume. A capacidade de classificacão do sistema proposto obteve precisão superior a 90%.

Um algoritmo para identificar os pontos gerados em imagens hiperespectrais de manga infestadas com larvas da mosca de fruta foi desenvolvido por HAFF *et al.* (2013). O algoritmo incorpora a remocão do fundo da imagem, a aplicacão de um limiar e a análise de pontos calculados por uma função Gaussiana para identificar locais de infestacões. O algoritmo envolve ainda parâmetros ajustáveis que foram testados de forma iterativa para encontrar a combinacão ideal para a detecção desses pontos. O método apresenta diferentes precisões de acordo com o nível de empestacão das frutas pelas moscas; para níveis altos, a taxa de acerto chega a 94%, enquanto que para níveis baixos de empestacão, a precisão cai para 87,7%.

---


<sup>14</sup> MATLAB ® é uma linguagem de alto nível, possuindo um ambiente interativo, com viés para computacão numérica.

### 2.5.2. Métodos de avaliação pela forma: volume e massa

No trabalho de TEOH e SYAIFUDIN (2006), é apresentado um mecanismo para a estimação da massa das mangas da variedade “*Chok Anan*”, que utiliza técnicas de processamento e análise de imagem. Neste método, o número de pixels da imagem da manga é capturado e computado pelo software, que estabelece uma correlação entre os pixels da imagem de mangas e suas massas, por meio de um método estatístico de regressão.

SINGH (2012) utiliza diferentes modelos de regressão para ajustar a estimativa da massa das mangas das variedades indianas *Dashehari*, *Langra*, *Amrapali* e *Lucknow Safeda*, utilizando medições de comprimento e largura de frutas no centro (FBC), porém, com medições manuais, sem a utilização de técnicas de processamento de imagens.

BORGES (2011) mostra a dificuldade da realização das medidas dos diâmetros máximo e mínimo manualmente, com a utilização de paquímetro. A Figura 2.5-2 apresenta um conjunto eixos de medidas dispostos sobre uma manga. Observe que os eixos x(máximo) e y(mínimo) são perpendiculares por definição (MOHSENIN, 1978), sendo esta condição dificilmente obedecida por alguém que utilize paquímetros; além disso, existe um certo conjunto de pontos que podem ser tomados como terminais desses eixos, que podem não corresponder aos diâmetros máximos reais. Porém, o método de medição com paquímetros é o mais utilizado. Utilizando o MATLAB®, o autor estimou os diâmetros máximo e mínimo dos frutos através das funções embutidas *MajorAxisLength* e *MinorAxisLength*, respectivamente. Essas funções definem os eixos perpendiculares entre si.



**Figura 2.5-2:** Possíveis medições dos diâmetros máximo e mínimo. Fonte: extraído de BORGES (2011).

SPREER (2011) descreve um método baseado em fotografias obtidas a partir de duas câmaras digitais ortogonalmente dispostas. Os cálculos do volume e da massa são estimados a

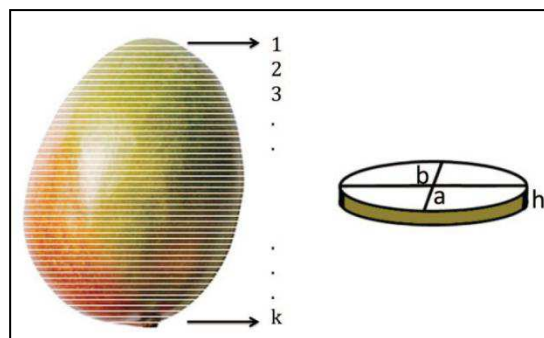
partir de equações que utilizam medições de três eixos, chegando a uma precisão de 96% para a manga da variedade “Chok Anan”.

BERMÚDEZ *et al* (2012) apresenta uma abordagem baseada na análise de várias imagens de amostras de frutas para estimar massa e volume, utilizando a análise da geometria espacial. As imagens das mangas são redefinidas em linhas ou seções transversais ao longo do comprimento do fruto, de espessuras pré-definidas (Figura 2.5-3).

O comprimento de todas as seções são somados para cálculo do volume. A massa é calculada com base em correlações obtidas por experimentação.

O método utiliza apenas um dispositivo de captura de imagem, empregando um modelo de cor denominado YcBCr. Os diâmetros da manga são estimados com base em análises anteriores e o número de sessões discóides varia de acordo com o tamanho da fruta.

Manchas negras também são detectadas a partir do uso de um segundo modelo de cor, o HSI, similar ao HSL, com base na informação da saturação apenas, permitindo uma classificação especificada em quatro variáveis linguísticas: “Ausente”, “Leve”, “Médio” e “Alto” associadas aos percentuais de cobertura.

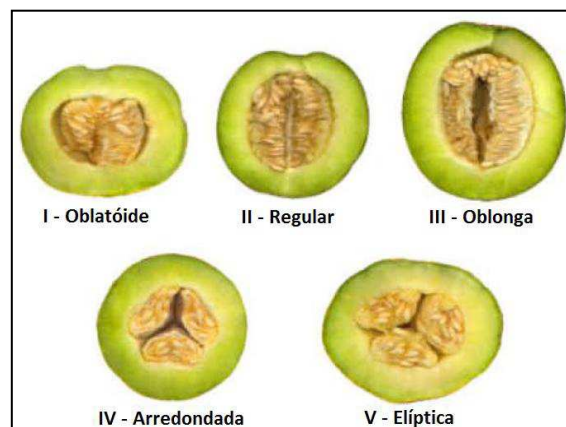


**Figura 2.5-3:** Seções discóides da manga para estimação do volume. Fonte: Extraído de BERMÚDEZ *et al* (2012).

BLASCO *et al.* (2009), apresenta o resultado dos trabalhos desenvolvidos pelo O IVIA - Instituto Valenciano de Investigaciones Agrarias ao longo de 15 anos de estudos em visão computacional para inspeção automática on-line de produtos agrícolas in-natura; com destaque para o desenvolvimento de uma máquina para a inspeção automática de romãs da cultivar *arils*, que individualiza, inspeciona, classifica e separa as frutas em quatro categorias diferentes, filtrando as que não cumprem as especificações mínimas exigidas. Esse método possui uma média de acertos em torno de 90 %.

Uma outra aplicação desenvolvida no âmbito do IVIA é uma máquina para classificar gomos de tangerina destinados para conserva; esse sistema distingue os gomos saudáveis dos quebrados ou duplos, sendo capaz de detectar a presença de sementes. As características morfológicas dos gomos são analisadas para classificá-los dentre vários padrões comerciais; seu índice de acerto é superior a 75 % .

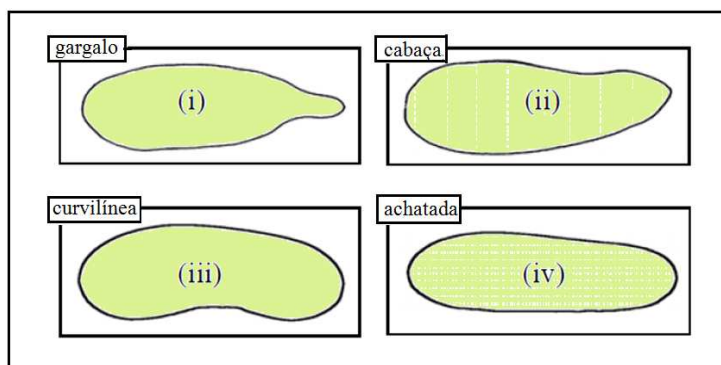
O sistema proposto em RASHIDI e SEYFI (2007) classifica frutas segundo seu formato; Uma aplicação foi implementada para a classificação do melão da variedade “*Cantaloupe*”, feita a partir de atributos geométricos, como o tamanho; dentre esses atributos, encontram-se o diâmetro principal e o diâmetro secundário, além disso, algumas outras informações estimadas sobre a massa, o volume e a densidade, foram empregados nas análises para comparações. Como resultado, a razão de circularidade e excentricidade da fruta se mostraram parâmetros suficientes para determinar a forma das frutas em pelo menos cinco categorias diferentes (Figura 2.5-4).



**Figura 2.5-4:** Formatos do melão identificados pelo sistema. Fonte: Extraído de RASHIDI e SEYFI. (2007).

Um método para classificação de melancias é encontrado em SADRNIA *et al.* (2007), onde o formato da fruta é analisado para detectar melancias deformadas. As características físicas como a massa, o volume, as dimensões, a densidade, o coeficiente de esfericidade e o diâmetro geométrico médio são estimadas.

A decisão se dá através da avaliação da correlação entre os valores obtidos e as características consideradas normais para o formato da fruta.



**Figura 2.5-5:** Quatro tipos de melancias deformadas. Fonte: Modificado pelo autor a partir de SADRNIA *et al.* (2007).


Para determinar as deformações, a relação entre o comprimento e espessura é empregada. A Figura 2.5-5 apresenta algumas das deformações da melancia. A estimativa de massa obtida para a melancia normal é de alta precisão, com erro médio de 2,42%.

### 2.5.3. Métodos mistos

Em ATENCIO *et al* (2009) é proposto um método de análise que inicia a partir do conjunto de pontos que descreve o contorno da manga, obtido por técnicas de segmentação; em seguida, emprega-se o PCA – Princípio do componente principal para encontrar os diâmetros máximo e mínimo.

No início, calcula-se o centro de massa do gráfico 2D, correspondente ao contorno da manga e em seguida, calcula a distância do ponto central até um dos pontos do contorno, calculando sua distância e projetando a mesma reta no sentido oposto até encontrar outro ponto do contorno, encontrando o segmento que representa um dos diâmetros da fruta (Figura 2.5-6).

Traçando uma reta perpendicular à primeira, sobre o mesmo centro de massa, encontra o segmento que representa o segundo diâmetro. Os comprimentos dos dois segmentos são comparados para determinar o máximo e o mínimo. Todos os pontos do conjunto que define o contorno da fruta são percorridos. Os eixos são perpendiculares entre si, dividindo a imagem em quatro áreas distintas com áreas de valores aproximados. Esses eixos são considerados para o cálculo do volume da manga.



**Figura 2.5-6:** PCA encontra diâmetros máximo e mínimo. Fonte: Montagem do autor a partir de ATENCIO *et al* (2009).

O trabalho de RENGANATHAN e SUDHAKARA (2002), permite a análise de frutas por parâmetros como o tamanho, a forma, e a cor. Detecta ainda alguns defeitos de superfície, como perfurações e outros problemas. Baseado no sistema proposto, foi construído um protótipo, que utiliza a tecnologia de visão computacional para extrair informações sobre os parâmetros de interesse da análise. O modelo de cor HSI é utilizado para obter um esquema eficiente para a discriminação de cor, representando a densidade média dos matizes como critério de classificação. O sistema apresenta alta precisão para inspeção da cor de maçãs, mas pode ser utilizado na análise de outros produtos, com pouca ou nenhuma alteração. Outros dispositivos incorporados no protótipo permitem a extração de parâmetros para análise da forma e do tamanho. A detecção de defeitos externos ainda está sendo desenvolvida.

Um novo sistema de reconhecimento de frutas foi proposto por SENG e MIRISA (2009), onde o método de análise combina diferentes características de cor e forma, que são extraídas e computados de maneira a aumentar a precisão do reconhecimento. O sistema é capaz de diferenciar frutas com cores similares e formas diferentes, ou ao contrário, com formas iguais e cores diferentes, considerando ainda o tamanho das frutas.

Em PLA *et al.* (1999), encontra-se o projeto de um novo sistema que integra dispositivos mecânicos e de visão computacional em um classificador de frutas, baseado em uma plataforma aberta e flexível, que permite que o sistema evolua, incorporando novas exigências dos clientes. O resultado deste trabalho foi um sistema capaz de controlar até 10 faixas classificação em função do seu tamanho, massa e cor, distribuindo o frutos selecionados em diferentes saídas.

Em NANDI *et al.*(2014b) é apresentado um sistema que utiliza várias características que podem ser detectadas na superfície da manga e que são sensíveis ao nível de maturação, tamanho e defeitos na superfície da fruta são extraídos a partir de imagens representadas no



modelo CIE-RGB; O índice ou nível de maturidade é estimado a partir de uma técnica denominada “Predição por Eliminação Recursiva”, que emprega um mecanismo de decisão por MVS. O tamanho da fruta é estimado através de vários métodos de processamento de imagem existentes no MATLAB ©, com mecanismos de decisão multivariada – AM. A precisão do sistema é de 90% para classificação e de 97% para estimação do tamanho do eixo principal.

Em GUILHERMIN *et al.* (2006), encontra-se o desenvolvimento de um sistema baseado em visão computacional, capaz de caracterizar amostras de produtos agrícolas da indústria de alimentos em grandes quantidades. A decisão do sistema se realiza pela análise da cor, da forma e do tamanho (multivariada). O sistema tem sido utilizado com sucesso para a caracterização da heterogeneidade de maçãs, mas é limitado pelo tamanho das amostras, que devem ter no mínimo 1 e no máximo 20 cm.

#### 2.5.4. Classificadores que utilizam visão computacional

O Quadro 2.5-1 resume vários trabalhos desenvolvidos para inspeção através de sistemas de visão computacional aplicada a inspeção de produtos agrícolas; já o Quadro 2.5-2 apresenta detalhamento das principais técnicas aplicadas para representação da informação e decisão.

**Quadro 2.5-1:** Sistemas classificadores por visão computacional. Fonte: Adaptado pelo autor a partir de (SALDAÑA, 2013), (GARCIA-RAMOS *et al.*, 2005) e (GILL *et al.*, 2014).

Produto Agrícola	Propósito	Técnica aplicada	Referência bibliográfica
Azeitona	Avaliação de cores e Detecção de defeitos.	RGB, HSV, AV	RIQUELME <i>et al.</i> , (2008)
Banana	Avaliação de cores	SRGB, HSV, L*a*b*	MENDOZA <i>et al.</i> (2006)
	Aspecto da Textura	Descritores de Fractais de Fourier	QUEVEDO <i>et al.</i> (2008)
Batata	Detecção de defeitos	Algoritmo Meta-heurístico para classificação - AdaBoost	BARNES <i>et al.</i> (2010)
Batata frita	Avaliação de cores	L* a* b*	PEDRESCHI <i>et al.</i> (2006)
		Medições e Correlação com Informação de Sensores	
Carambola	Avaliação de cores, Avaliação da forma.	Descritores de Fourier	ABDULLAH <i>et al.</i> , (2006)
Cogumelos	Avaliação de cores, Detecção de defeitos.	L*, PCA, ALD	GOWEN <i>et al.</i> , (2009)
Espinafre	Detecção da deterioração da qualidade	AMI	LUNADEI <i>et al.</i> , (2012)

## Continuação...

**Quadro 2.5-1:** Sistemas classificadores por visão computacional. Fonte: Adaptado pelo autor a partir de (SALDAÑA , 2013), (GARCIA-RAMOS *et al.*, 2005) e (GILL *et al.*, 2014).

Frutas em geral	Classificação	Funções da Biblioteca do MatLab para análise de histogramas de cor	CHAN <i>et al.</i> (2007).
			PLA <i>et al.</i> , (1999)
		K-NN	SENG e MIRISA, (2009)
		Densidade média dos matizes	RENGANATHAN e SUDHAKARA <i>et al.</i> , (2002)
Laranja	Avaliação da Forma	Descritores de Fourier	SIMÕES e COSTA, (2003)
	Classificação		COSTA <i>et al.</i> , (2009)
	Detecção de defeitos	AGE / Correlação de Limiares (thresholds)	SLAUGHTER <i>et al.</i> , (2009)
Lima	Detecção de defeitos	Correlação de Limiares (thresholds)	OBENLAND e NEIPP, (2005)
Frutas cítricas	Avaliação de cores, Detecção de defeitos	RGB, HSI, L*a*b*, XYZ, ALD	BLASCO <i>et al.</i> , (2007b)
	Avaliação de cores, Detecção da forma, Estimação de área, Detecção de defeitos.	RGB, HSI, Descritores de Fourier, ALD	BLASCO <i>et al.</i> , (2009)
	Avaliação de cores, Detecção de defeitos	RGB, HSI,	BLASCO <i>et al.</i> , (2007a)
	Detecção de defeitos	AMI	LOPEZ-GARCIA <i>et al.</i> , (2010)
	Avaliação de cores, Detecção de defeitos, Aspecto da Textura	AM	ZHAO <i>et al.</i> , (2009)
Maçã	Detecção de defeitos	RNA	ARIANA <i>et al.</i> , (2006a)
		MQP, SW	ELMASRY <i>et al.</i> , (2008)
		Detecção de defeitos RNA	ELMASRY <i>et al.</i> , (2009)
	Classificação		IQBAL <i>et al.</i> , (2012)
	Detecção de defeitos	Análise de Histogramas	LEFCOUT e KIM, (2006)
		MQP	LEFCOUT <i>et al.</i> , (2006)
	Avaliação de cores	RGB, amido, k-NN, MQP, ALD	UNAY e GOSSELIN (2007)
		RGB, HSI	XIAOBO <i>et al.</i> , (2007)
	Aspecto da Textura, Detecção de defeitos	MQP	XING <i>et al.</i> , (2007)

## Continuação...

**Quadro 2.5-1:** Sistemas classificadores por visão computacional. Fonte: Adaptado pelo autor a partir de (SALDAÑA , 2013), (GARCIA-RAMOS *et al.*, 2005) e (GILL *et al.*, 2014).

Maças e outras frutas	Classificação	AMI	GUILHERMIN <i>et al.</i> , (2006)
Mamão	Estimação de Massa e Volume		RIYADI <i>et al.</i> , (2007)
Mangas em geral	Detecção dos eixos principal e secundário	Técnicas de Segmentação / PCA	ATENCIO <i>et al.</i> , (2009)
	Estimação de Massa e Volume	AGE	BERMÚDEZ <i>et al.</i> , (2012)
	Avaliação de cores	L* a* b*	KANG e TRUJILLO (2008)
	Estimação de Massa e Volume	Segmentação em 3D / AGE	SPREER e MÜLLER, (2011)
		AGE / Regressão estatística	SINGH, (2012)
Manga ( <i>Tommy Atkins</i> )	Classificação e Seleção	Funções da Biblioteca do MatLab, cadeia de sensores eletromecânicos, fotos térmicas.	BORGES, (2011)
Manga ( <i>Chokanan</i> )	Estimação de Massa e Volume	AGE / Regressão estatística	TEOH e SYAIFUDIN, (2006)
Melancia	Estimação de volume	AGE	KOC, (2007)
	Classificação	AGE	SADRNIA <i>et al.</i> , (2007)
Melão ( <i>Cantalupe</i> )	Classificação	AMI	RASHIDI e SEYFI, (2007)
Morango desidratado	Avaliação da variação de cores	AMI	AGUDELO-LAVERDE <i>et al.</i> , (2013)
Pepino	Detecção de defeitos	PCA, proporção de faixa, as diferenças de faixa	ARIANA <i>et al.</i> , (2006b)
	Detectar Divergência em Análise Espectral	Análise Espectral	QIN <i>et al.</i> , (2009)
Pera	Estimação da maturação, Detecção de defeitos	Mineração de dados em Mapas auto-organizáveis (clustering R / NIR)	LLEÓ <i>et al.</i> , (2009)
Repolho	Estimação do frescor da fruta	AMI	ARCE-LOPERA <i>et al.</i> , (2012)
Romã	Classificação	AMI	BLASCO <i>et al.</i> , (2009)
Tangerina	Detecção de defeitos	SW, AG, AC, IM, ALD	GÓMEZ-SANCHIS <i>et al.</i> , (2008a)
	Avaliação da forma	Modelo digital de elevação é um modelo digital ou representação em 3D de superfícies	GÓMEZ-SANCHIS <i>et al.</i> , (2008b)

**Quadro 2.5-2:** Principais métodos/técnicas aplicadas nos sistemas de classificação. Fonte: Produção do autor.

Abreviação	Descrição
<b>AC:</b> Análise de Correlações.	A análise de correlação avalia as inferências estatísticas das medidas de associação linear, que podem ter coeficientes simples ou múltiplos. O coeficiente de correlação simples mede o grau de relacionamento linear entre duas variáveis, enquanto que o coeficiente de correlação múltiplo mede o grau de relacionamento entre uma variável dependente e um conjunto de outras variáveis (BUSSAB, 1988).
<b>AG:</b> Algoritmo Genético.	Algoritmos genéticos são programas que visam encontrar soluções aproximadas em problemas, através de um processo que promove evolução e busca, de maneira similar ao mecanismo de seleção e otimização genética das espécies vivas, através da criação de novas instâncias de soluções melhoradas (evoluídas por mutação ou recombinação) interativamente, até encontrar uma solução considerada ideal (HAUPT e HAUPT, 2004).
<b>AGE:</b> Análise da Geometria Espacial.	A partir de informações obtidas dos objetos, a análise da Geometria Espacial visa estabelecer relações desses objetos, como cálculos de comprimentos de curvas, as áreas de superfícies, volumes de regiões sólidas, etc.
<b>AM:</b> Análise Multivariada.	Visa reconhecer padrões em números abstratos para o nosso senso comum, que é feito matematicamente, pela análise das principais fontes de variação de dados complexos (muitas variáveis) com o objetivo de tornar as informações interpretáveis por meio de gráficos (BUSSAB, 1988).
<b>AMI:</b> Análise de imagem Multivariada.	Uma imagem multivariada consiste em uma série de imagens empilhadas, onde cada uma delas é medida em diferentes comprimentos de onda ou energia. Com isso, uma imagem multivariada em um plano de dimensão $n$ , é representada por matriz de terceira ordem $n+1$ . Se a observação é realizada ao longo do tempo, a matriz que descreve o sistema passa a ser de $n+2$ e a mudança é considerada para decisão (GELADI e GRAHN, 1996).
<b>AV:</b> Análise da Variância.	A análise de variância é utilizada quando se quer analisar se as diferenças amostrais observadas em uma situação são reais ou casuais. Conceitualmente, uma situação real existe quando as diferenças são causadas por discrepâncias significativas nas populações observadas; já nas situações causais, as diferenças são decorrentes da variação típica da amostra. O principal pressuposto dessa abordagem é que o acaso só produz pequenos desvios (BUSSAB, 1988), (MILONE, 2009).
<b>IM:</b> Análise de Informações Mútuas.	Nesse tipo de análise, a Informação mútua é a medida da quantidade de informação que uma determinada variável aleatória $X$ contém acerca da variável aleatória $Y$ , com o objetivo de deduzir a incerteza de $X$ , com o conhecimento de $Y$ . Nesse caso, se as variáveis forem independentes, o valor da análise de informação mútua é zero (SHANNON, 1993).
$L^*$ , $a^*$ , $b^*$ .	Trata-se de um Sistema de cores proposto pelo CIE (CIE, 1976), que representa a cor em termos de uma composição, onde: <ul style="list-style-type: none"> <li>• <math>L^*</math> – É a componente de luminosidade, com valores entre 0 (preto) e 100 (branco), e</li> <li>• <math>a^* &gt; 0</math> indica que a cor é vermelho/púrpura;</li> <li>• <math>a^* &lt; 0</math> indica que a cor é verde;</li> <li>• <math>b^* &gt; 0</math> indica que a cor é amarela;</li> <li>• <math>b^* &lt; 0</math> indica que a cor é azul;</li> <li>• <math>a^* = b^* = 0</math> indica que a cor é acromática (cinzento).</li> </ul>

**Continuação...**

**Quadro 2.5-2:** Principais métodos/técnicas aplicadas nos sistemas de classificação. Fonte: Produção do autor.

<b>MVS (SVM):</b> Máquinas de Vetor de Suporte.	Em aprendizagem de máquina, Máquinas de Vetor de Suporte MVS, também conhecidas por (SVM – Support Vector Machines), são modelos de aprendizagem supervisionada, que empregam algoritmos de aprendizagem que reconhecer padrões pela análise de regressão.
<b>MQP:</b> Mínimos Quadrados Parciais.	A regressão por Mínimos Quadrados Parciais é uma técnica de análise de dados multivariados, com uma matriz de variáveis independentes $X$ e uma matriz de variáveis dependentes $Y$ , que são representadas por escores e pesos. A relação entre as duas matrizes de dados pode ser obtida, correlacionando-se os escores de cada bloco, a fim de obter uma relação linear, gerando uma matriz resposta $T$ para uma série de amostras de calibração e uma componente que representa o ruído do espectro e os erros do modelo (KONZEN <i>et al.</i> , 2003).
<b>PCA:</b> Princípio do componente principal e <b>FA:</b> Análise de fatores.	Os métodos de análise de componentes principais (PCA) e de fatores (FA) são técnicas estatísticas geralmente aplicadas sobre um conjunto de variáveis para descobrir quais conjuntos de variáveis (subconjuntos coerentes) são relativamente independentes entre si. O objetivo é alcançar a redução de um grande conjunto de variáveis para um conjunto mais significativo, com um conjunto menor de variáveis, sem perda de representatividade (LOPES <i>et al.</i> , 2001).
<b>RNA:</b> Redes Neurais Artificiais.	As Redes Neurais Artificiais (RNAs) são ferramentas de Inteligência Artificial que modelam o neurônio humano e possuem a capacidade de se adaptar para aprender a realizar determinada tarefa ou comportamento, a partir de um conjunto de exemplos dados, criando um banco de conhecimento, que estará disponível na forma utilizada para representar o objeto da imagem, geralmente, uma descrição numérica (KOVÁCS, 2006).
<b>UVA:</b> Ultravioleta A Ondas Longas.	Neste tipo de análise, utiliza-se a Luz Ultravioleta de Onda Longa (também conhecida como luz negra), cujo comprimento de onda se estende de 320 a 380 nm, com pico de energia próximo a 365 nm. Aplica-se nos processos de identificação bacteriana, eletroforese, detecção de contaminação em alimentos, e muito mais. Trata-se de um método de detecção de fluorescência para contagem de contaminantes, através de mecanismos manuais ou automáticos. (AOCS, 1997).

### 2.5.5. Equipamentos para análise automática de frutas

Existem vários fabricantes de equipamentos para a automação de alguns sistemas de classificação não-destrutiva, avaliando a cor da pele e outros atributos de vários produtos agrícolas. Uma pequena relação de fabricantes é fornecida no Quadro 2.5-3. Até o presente trabalho, não foi possível encontrar qualquer equipamento comercial para automação da avaliação de maturidade, massa e volume de mangas *Tommy Atkins* por análise de imagem.

**Quadro 2.5-3:** Lista de alguns fabricantes de equipamentos para avaliação de frutos. Fonte: Editado pelo autor.

<b>Fabricante</b>	<b>URL</b>	<b>Descrição do equipamento</b>
Agro Technologie, Forges Les Eaux, França.	<a href="http://www.durofel-penefel.com/">http://www.durofel-penefel.com/</a>	Desenvolve instrumentos de análise para produtos agro-alimentares, como durômetros, texturômetros, medidor de firmeza, tenderômetros, colorímetro para frutas, refratrômetros, balanças estatísticas para frutas e legumes.
Aweta BV, Nootdorp, Holanda	<a href="http://www.aweta.nl/index.html">http://www.aweta.nl/index.html</a>	Desenvolve máquinas de classificação não destrutivas, analisando a cor (pele), firmeza (acústica e de impacto), o conteúdo interno de açúcar (Brix, por NIR), forma, tamanho e massa.
Compac Sorting Equipment Limited, Auckland, Nova Zelândia.	<a href="http://www.compacsort.com/">http://www.compacsort.com/</a>	Desenvolve máquinas de classificação destrutivas e não-destrutivas, analisando a cor (pele), densidade, sabor (interno -NIR), forma, tamanho, volume e massa.
Durand-Wayland, Inc. LaGrange, GA, EUA.	<a href="http://www.durand-wayland.com/packing/index.html">http://www.durand-wayland.com/packing/index.html</a>	Tecnologias de classificação não-destrutivas para análise de manchas, cor (pele), densidade, volume e massa.
EquipNet, Inc., Canton, OH. EUA.	<a href="http://www.equipnet.com/">http://www.equipnet.com/</a>	Equipamento de pesagem e dosagem, cromatografia líquida de alta eficiência, equipamentos de análise fotométrica.
FMS Jansen GMBH & Co. KG HunterLAB. Murnau, Alemanha.	<a href="http://www.hunterlab.de/">http://www.hunterlab.de/</a>	Desenvolve aparelhos de medição de cor para a indústria alimentar.
Greefa, CA. Geldermalsen, Holanda.	<a href="http://www.greefa.nl/">http://www.greefa.nl/</a>	Desenvolve máquinas de classificação destrutivas e não-destrutivas, analisando manchas, cor (pele), a firmeza, o conteúdo interno de açúcar (Brix, por NIR), tamanho e massa.
MAF Roda Group, Montauban, França.	<a href="http://www.maf-roda.com/">http://www.maf-roda.com/</a>	Desenvolve máquinas de classificação destrutivas e não-destrutivas, analisando manchas, cor (pele), densidade, firmeza, açúcar (interno), conteúdo de matéria seca e porcentagem de óleo por NIR, forma, tamanho e massa.
Mettler-Toledo International Inc. Reifensee, Suíça.	<a href="http://www.mt.com/">http://www.mt.com/</a>	Desenvolve máquinas de acondicionamento para as indústrias de alimentos, dosadoras, sistemas de medição de paletes de alta precisão.
Sinclair Systems International, LLC., Fresno, CA, EUA.	<a href="http://www.sinclair-intl.com/pages/produce_pages/pear.html">http://www.sinclair-intl.com/pages/produce_pages/pear.html</a>	Desenvolve tecnologias de classificação não destrutivos para análise de firmeza.
Tews Elektronik GMBH & CO. KG, Hamburgo, Alemanha.	<a href="http://www.tews-elektronik.com/">http://www.tews-elektronik.com/</a>	fabricante de aparelhos de medição da humidade para produtos alimentares na europa

**Continuação...**

**Quadro 2.5.3:** Lista de alguns fabricantes de equipamentos para avaliação de frutos. Fonte: Editado pelo autor.

Tri-D-ax . Goussainville, França.	<a href="http://www.lm3d.fr/">http://www.lm3d.fr/</a>	Fornece máquinas sob medida para medição tridimensional de braço horizontal, incluindo os sensores, conversores, software e acessórios.
Yxlon International GMBH. Hamburgo, Alemanha.	<a href="http://www.yxlon.de/">http://www.yxlon.de/</a>	Sistemas de inspeção por radiologia

### **3. MATERIAIS E MÉTODOS**

#### **3.1. Métodos de análise pela cor**

Dentre os processos da pós-colheita, a seleção e a classificação de frutas (seção 2.1.4, 2.1.6) vêm merecendo especial atenção, afinal, esses processos decidem se determinado produto está ou não com a qualidade exigida pelo consumidor; nesse contexto, a avaliação precisa e rápida do estágio de maturação dos produtos na indústria de alimentos representa indubitavelmente, uma das questões críticas nesse setor, em virtude dos altos custos do tempo, exigidos por esse processo. Na tentativa de resolver esse problema, duas heurísticas básicas podem ser adotadas: aumentar o efetivo de pessoal ou aplicar tecnologias de automação. O alto custo dessas tecnologias tem representado um obstáculo para o setor, simplesmente porque esta tecnologia não está ao alcance das pequenas e médias empresas dedicadas a esta indústria. Dessa forma, sistemas de baixo custo para análise de imagens, aplicados à classificação e seleção de frutos, podem vir a representar um diferencial na balança da competitividade desse exigente mercado. Esses sistemas são constituídos de métodos de análise não invasivos, ou seja, são muito adequados para ser utilizado na indústria alimentar. No processamento da manga, a seleção obedece a critérios definidos em padrões nacionais e internacionais que determinam as exigências para o mercado. Os padrões definem a correlação entre o estágio de maturação (seção 2.1.1) e as cores da superfície (seção 2.1.3); alguns deles incluem ainda a avaliação das cores da polpa; esses não serão considerados no presente trabalho, por se tratarem de procedimentos invasivos e destrutivos.

#### **3.1.1. Método de classificação inteligente**

##### **3.1.1.1. Definição do Método**

O sistema proposto realiza a avaliação da manga *Tommy Atkins* pela análise da cor da sua superfície; a Figura 3.1-1 apresenta seu “diagrama de contexto”<sup>15</sup>, que permite a sua completa visualização. Os diferentes níveis de processamento (seção 2.2.9) encontram-se delineados por linhas tracejadas no gráfico. Tipicamente, esse tipo de descrição apresenta as entradas, saídas e a transformação ocorridas entres esses dois estágios; essa transformação não é geralmente apresentada com maiores detalhes. A entrada é a informação advinda do mundo real, no caso, a imagem (seção 2.2.6) da manga; ela é capturada pelo sistema de aquisição de

---

<sup>15</sup> *Gráfico que expressa a visão geral de um modelo computacional*

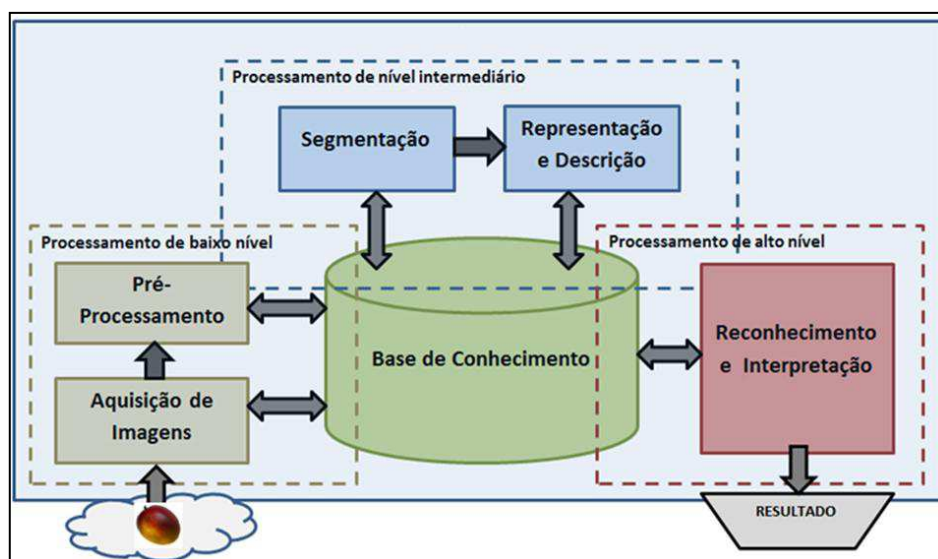


imagens (seção 2.2.9), responsável pela construção da matriz de pixel que a representa, assim como pela sua gravação na memória logo em seguida.

O estágio de pré-processamento desse sistema é bastante reduzido, por motivos que serão apresentados mais adiante.

No processamento da imagem (seção 2.2.9), a segmentação representa a separação dos objetos relevantes da imagem para o problema, formando um conjunto que será descrito de maneira apropriada pelo sistema de Representação e Descrição (seção 2.2.8).

Finalmente, o sistema de Reconhecimento e Interpretação realizará a análise sobre os dados já apropriadamente descritos para emitir sua resposta acerca do problema dado.



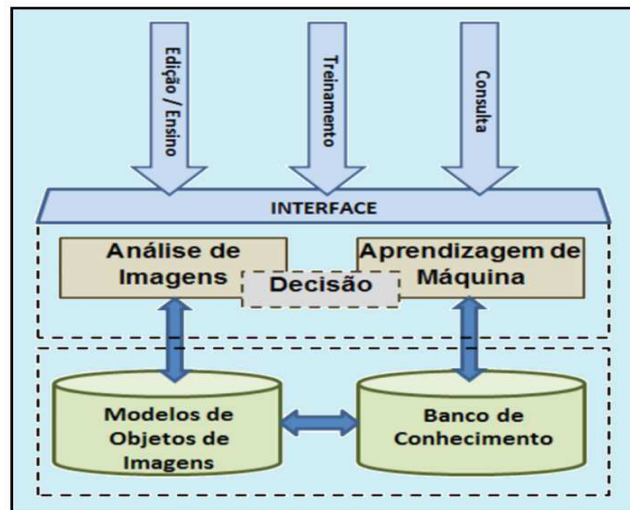
**Figura 3.1-1:** Diagrama contextual do Sistema de Classificação Inteligente. Fonte: Produção do autor.

Um repositório de dados, denominado “base de conhecimento” ou “KB” de “*Knowledge Base*” (seção 2.3.3) é utilizado para armazenar as informações de alto nível, ou seja, o conhecimento sobre os dados da imagem, suas interrelações e sua evolução histórico.

A metodologia da análise de imagens proposta foi definida pela composição de dois sistemas interdependentes:

- um **Sistema de Análise de Imagens** (seção 2.2.9) ;
- um **Sistema de Aprendizagem de Máquina** (seção 2.3.5),

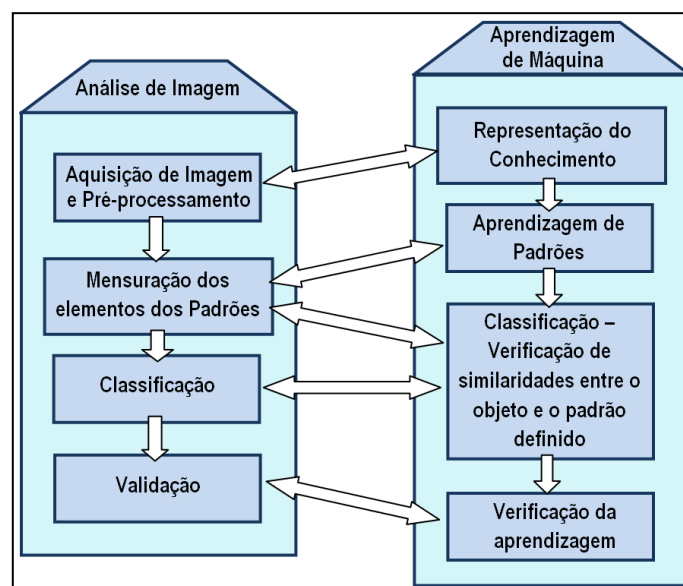
O aspecto da interrelação entre esses sistemas é apresentado na Figura 3.1-2.



**Figura 3.1-2:** Interface para os sistemas de Análise de imagens e Aprendizagem. Fonte: Produção do autor.

O sistema de análise de imagens tem por função construir a descrição dos objetos capturados na imagem, numa forma que possa ser manipulada por operações de programas de computador; essa descrição, por sua vez, será utilizada pelo sistema de aprendizagem, para associá-la às informações que descrevem um determinado padrão.

O sistema de aprendizagem tem por função a criação de representações de modelos (padrões comerciais), de maneira a comparar essas representações com as imagens das frutas, indicando o grau de pertinência da imagem ao padrão.



**Figura 3.1-3:** Inter-relações entre os módulos dos sistemas. Fonte: Produção do autor.

A aprendizagem será realizada pelo sistema, considerando dois casos distintos:

- **Aprendizagem de um novo padrão ou modificação de um padrão existente:** Emprega a associação de percentuais de cores aos níveis do padrão, mas nenhuma imagem é apresentada; nesse caso, o nome do padrão é criado e associado a  $n$  níveis. Para cada nível, as cores (H) são associadas a um percentual de cobertura da cor na pela da manga. Esse mecanismo assemelha-se ao modo de aprendizagem denominado intrução direta (seção 2.3.5). As componentes S e L do modelo de cor HSL não são utilizadas, mesmo porque seria extremamente difícil mensurar essas características associadas à cor, sem o uso de instrumentos adequados.
- **Aquisição ou atualização de conhecimento (padrão) a partir de exemplos:** É o caso da aprendizagem por exemplos, onde o conhecimento é adquirido pelo próprio sistema, cabendo ao operador apenas uma parte inicial da instrução – o treinamento, onde o sistema recebe a informação do nome do padrão, número de níveis e uma série de imagens de mangas; para cada uma dessas imagens, é informado qual o nível ao qual pertence a fruta. O conhecimento é expandido através da adaptabilidade dos valores em função da experiência.

O sistema é agora descrito com um maior detalhamento a partir de suas entradas, que são gerenciadas por uma *interface*, que coordena os seguintes módulos: **módulo de análise de imagem** e o **módulo de aprendizagem de máquina** (Figura 3.1-2). Foi definido para esses módulos, um conjunto de etapas ou procedimentos, suficiente para a realização das suas tarefas; essas etapas estão intrinsecamente conectadas, conforme mostra a Figura 3.1-3. O gerenciamento do sistema é realizado através das opções da interface, que são as seguintes: Edição, Treinamento e Consulta.

#### **3.1.1.1.1. Edição do conhecimento ou ensino direto**

A edição do conhecimento é uma abordagem que pode ser considerada um exemplo da aplicação da Aprendizagem de Máquina em dos seus níveis mais elementares: a aprendizagem por instrução (seção 2.3.5); neste módulo, as características das frutas consideradas para avaliação são inseridas diretamente na base de conhecimento; portanto torna-se necessário que o usuário (instrutor) tenha pleno conhecimento sobre como essas características são representadas (níveis associados às cores) e ainda, como essas características se relacionam com o padrão que se deseja construir.

Deve ainda ser observado que uma vez estabelecido um padrão, existirá o grande risco de erros humanos na classificação, porquanto a percepção de diferenças em escala de cores não é

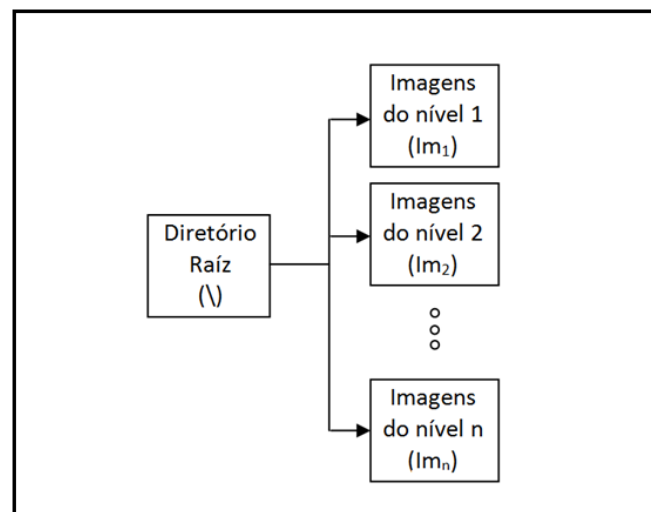
uma tarefa trivial, principalmente sem aparelhos de mensuração adequados; além disso, as cores são distribuídas de maneira não linear nas frutas; isso realça a importância dos métodos automáticos de classificação.

Logo, pode ser facilmente deduzido que a edição do conhecimento isenta o sistema de aprendizagem de qualquer ocorrência de erros de avaliação.

### 3.1.1.1.2. Treinamento a partir de exemplos

Neste módulo, o sistema constrói o padrão de análise a partir de imagens da fruta e do nível do padrão ao qual está associada, que é informado pelo usuário. Trata-se de um módulo cujo objetivo é definir um padrão com base na distribuição das componentes HSL das frutas. Assim, para uma determinada imagem colocada na entrada do sistema, a saída será o nível do padrão em que a fruta está associada. O nível ao qual a imagem estará associada, também será representado por um diretório, onde a referida imagem será armazenada.

A principal vantagem do módulo de treinamento (seção 2.3.5) reside na maior facilidade para o usuário definir uma avaliação mais complexa, que vai bem mais além da análise dos percentuais de cores, mas como as mesmas cores se diferenciam (mais claras, mais escuras, com muito brilho ou pouco brilho, etc).



**Figura 3.1-4:** Esquema de diretórios para armazenar imagens. Fonte: Produção do autor.

O treinamento é realizado simplesmente através da apresentação de exemplos de frutas através do sistema de aquisição de imagens, além do nível do padrão nos quais as mesmas se enquadram. As informações extraídas da imagem e a sua associação com o padrão informado são enviados para a base de conhecimento e o conjunto de imagens do treinamento no formato PNG (seção 2.2.7) é mantido num sistema de diretórios, como o apresentado na

Figura 3.1-4, mesmo após a aprendizagem das mesmas, para o caso de reavaliação da aprendizagem. Assim, esse módulo permite tanto a definição de um padrão comercial qualquer, quanto a definição de um novo padrão definido pelo usuário.

Esse mecanismo permite ainda a inserção de imagens fora do sistema, através da indicação dos arquivos de imagem, juntamente com o nível ao qual pertencem.

#### **3.1.1.1.3. Consulta sobre um padrão já existente**

É neste módulo que se realiza a análise autônoma da manga; nele, um padrão definido no módulo de instrução direta ou treinamento e é selecionado para servir de base para a análise de imagens de frutas submetidas ao sistema.

O algoritmo funcional do método que realiza a consulta para o padrão definido por aprendizagem a partir de exemplos é mostrado no Fluxograma IV do Apêndice II.

#### **3.1.1.2. Definição do modelo de cores**

Para trabalhar com informações sobre cores, torna-se necessário inicialmente definir um modelo de cor que possa ser manipulado por computador. A adoção do padrão HSL (seção 2.2.5.2) para o sistema proposto foi uma opção interessante, porque ele permite a aproximação da representação humana; esse critério torna-se óbvio porque o módulo de treinamento do sistema demanda a intervenção humana para avaliação de cores; assim, a representação das cores em um modelo próximo ao humano torna-se mais coerente. Sendo assim, o módulo de aquisição de imagens (seção 2.2.9) deve prover o arquivo de imagem no padrão HSL. Como tipicamente, os dispositivos de captura são baseados em modelos RGB, uma transformação se torna necessária.

A avaliação das cores da pele da manga envolve os componentes H, S e L do modelo. Muito embora a componente L do modelo represente apenas o aspecto da luminosidade, a sua inclusão no módulo de avaliação se torna relevante, uma vez que ao amadurecer, os frutos perdem água e suas superfícies se tornam mais opacas, perdendo o brilho; esse fenômeno pode ser detectado por essa componente.

#### **3.1.1.3. Construção de um ambiente controlado para aquisição de imagens**

Para capturar as imagens da manga, tornou-se necessária a construção de uma câmara que proporcionasse um ambiente bastante controlado. A iluminação é sempre um fator de grande relevância em fotografia; isso foi comprovado na prática, pois foram várias as tentativas para chegar a uma configuração correta, com mudanças de lâmpadas e de posicionamento. Uma

disposição adequada aos propósitos do experimento foi alcançada através da combinação de duas lâmpadas fluorescentes com de 7 W de potência com duas lâmpadas incandescentes de 15 W. As lâmpadas fluorescentes foram colocadas em estruturas similares a “ombros”, que são guias de luz, permitindo o direcionamento da luminosidade para as laterais e para a base, enquanto as lâmpadas incandescentes foram colocadas na parte superior da câmara, sendo essas reguladas por um *dimmer*<sup>16</sup>. Todas as lâmpadas foram envolvidas com filtros dispersores. As mangas foram posicionadas sobre uma base em “V”, que foi revestida com TNT<sup>17</sup> da cor preto-fosco, assim como de resto todo o interior da estrutura. Testes foram realizados para assegurar que a iluminação estava adequada, sem projeções de pontos de luz ou formação de sombras. O foco da câmera foi ajustado para a distância do objeto, sendo depois fixado, porque a distância à base do objeto (manga) era invariável e a distância para a superfície da manga não apresentava distorções nas imagens.



**Figura 3.1-5:** Câmara para aquisição de imagens. Fonte: Produção do autor.

A câmara contava ainda com um dispositivo que combinava dois termômetros e um exaustor, sendo um termômetro posicionado dentro da ambiente e outro fora, de maneira que quando havia diferenças de temperatura entre os dois aparelhos, o sistema de exaustão era acionado até atingir o equilíbrio térmico. As imagens foram obtidas por uma câmera digital de média resolução (5,0 M pixels), instalada na parte superior da câmara. A Figura 3.1-5 apresenta os componentes constituintes e o aspecto externo dessa câmara, que reduz o pré-

<sup>16</sup> São dispositivos utilizados para variar a intensidade de uma corrente elétrica média em uma carga, como uma lâmpada, fazendo variar sua luminosidade.

<sup>17</sup> Tipo de tecido à base de polipropileno e viscose

processamento da imagem para ajustes dos parâmetros distância focal (WD), profundidade de campo (DOF) e campo de visão (FOV).

#### **3.1.1.4. Construção de um dispositivo de calibração cromática**

Talvez o mais importante requisito da captura de imagens digitais seja manter a coerência de representação das cores do objeto fotografado, ou seja, a sua aproximação da realidade. Por isso, a calibração desses dispositivos é fundamental.

A calibração é em geral executada por pessoas especializadas nesse procedimento, utilizando ferramentas colorimétricas, empregando geralmente equipamentos sofisticados como colorímetros ou espectrofotômetros.

As câmaras digitais estão sujeitas a perturbações advindas do ambiente e do manuseio que podem alterar o seu funcionamento normal, fazendo que o dispositivo altere as suas características originais e apresente distorções nas imagens. Isso pode ser notado de várias maneiras, dependendo do tipo de distorção, que podem ser divididas em duas classes: As distorções cromáticas, relativas às cores capturadas pelo sensor, e as distorções relativas à perspectiva.

As lentes, por não serem perfeitas, podem produzir uma imagem imprecisa. Estes defeitos da imagem recebem o nome de aberrações. A combinação de lentes e de alguns elementos adicionais podem minimizar estes defeitos.

Algumas das principais distorções que ocorrem em câmaras digitais são:

- **Distância focal:** O foco da câmara não permite uma perfeita definição da imagem alvo; isso ocorre quando as lentes não são fabricadas para capturar uma imagem que esteja muito próxima da objetiva, por exemplo, quando se torna necessário a utilização de outras lentes para corrigir o problema.
- **Aberração esférica:** Causada geralmente pelo polimento das lentes, gerando efeitos diversos que comprometem a fidelidade da imagem ao chegar ao sensor.
- **Coma:** Opacidade causada pelo polimento das lentes com produtos abrasivos.
- **Deslocamento do ponto principal:** Ocorre quando não há coincidência entre o eixo ótico da câmera e o centro fiducial da fotografia; ou seja, o ponto central da imagem não é representado no centro da matriz do sensor.
- **Distorção radial simétrica:** Ocorre na presença de uma parcela não desejável da refração sofrida por um raio de luz ao atravessar uma lente. Desta forma, um raio de

luz que antes de penetrar na câmera, forma um ângulo  $\alpha$  com o eixo óptico, ao atravessar o sistema de lentes irá mudar o seu ângulo de incidência, causando um deslocamento na posição da imagem no plano do sensor.

- **Distorção descentrada:** Ocorre quando existe a impossibilidade do perfeito alinhamento dos eixos ópticos das lentes que compõe uma objetiva (geralmente é um defeito de fabricação), o que resulta em um deslocamento na imagem na matriz do sensor.
- **Aberração cromática:** Causada por diferentes características do material da lente, relativa à refração da luz.
- **Distorção no balanço de cores:** Ocorre quando há uma diferença entre as cores reais da imagem e as cores capturadas pelo dispositivo.

O principal problema associado ao uso de câmeras digitais reside na necessidade de se conhecer previamente os parâmetros de orientação interior, para que se possa posteriormente, na ocorrência de um problema, recuperar os parâmetros que permitem obter a geometria projetiva real. Estes procedimentos são determinados por processos de calibração que empregam equações matemáticas que modelam os efeitos da geometria projetiva, gerando valores ideais para os ajustes necessários.

O sistema de captura de imagens proposto neste trabalho, elimina as distorções relacionadas à perspectiva do objeto cuja imagem deverá ser capturada, já que emprega um dispositivo de foco fixo, com o objeto de interesse colocado em uma distância fixa, dentro dos requisitos de operação impostos pelo fabricante. Não há vibração nem outro fenômeno de natureza mecânica que comprometa a integridade da câmara. O conjunto passou por testes que comprovaram a ausência de distorções tangenciais.

A principal distorção que o sistema pode sofrer é referente ao seu balanço de cores, que se refere aos ajustes que são efetuados pelo fotógrafo ou pela câmera fotográfica (automaticamente) para obter imagens com fidelidade de cores próxima àquelas que os objetos apresentam iluminação ideal. Esse processo é relativo à percepção da cor real independentemente das condições de iluminação.

O balanço de cores na fotografia digital é efetuado previamente, a correção de cores no pós-processamento, quando necessária, é feita ou por algoritmos implementados em editores gráficos de maneira automática ou mesmo pelo próprio fotógrafo, que pode alterar a imagem inserindo uma grande variedade de efeitos digitais.




Existem vários mecanismos disponibilizados por diversos fabricantes que permitem a calibração do balanço de cores. Algumas câmaras profissionais tem a capacidade de adaptação cromática e a maior parte das câmeras digitais oferece opções pré-programadas para as situações mais comuns do dia-a-dia, como iluminação natural (luz do sol), situações de sombra (dias nublados) e iluminação artificial (lâmpadas fluorescentes, tungstênio e até mesmo vapor de mercúrio). Porém, para os propósitos deste trabalho, que envolve um ambiente controlado para aquisição de imagens, não se considera esses dispositivos, mas é proposto um método simplificado para a calibração das cores, seguindo o princípio de associação entre a representação interna e os dados reais, conhecido por “WYSIWYG” (*What You See Is What You Get*).

O mecanismo de calibração desenvolvido funciona da seguinte maneira:

- Inicialmente, uma matriz que relaciona cores aos valores de representação interna do dispositivo é apresentada ao sistema. Existe um grande número de padrões especificados em tabelas de calibração (Gamut) distribuídos por fabricantes de diversos dispositivos que utilizam imagens digitais; a Figura 3.1-6 apresenta o aspecto da matriz de referência utilizada, desenvolvida pela IKONYC inc ©.
- A câmara captura a imagem da matriz de referência, que é “varrida”; nesse procedimento, um pixel de cada quadro de cor é separado; os valores RGB de cada pixel são capturados e armazenados em uma estrutura de dados denominada “vetor de referência cromática RGB”; trata-se de uma estrutura bidimensional (28 x 31), capaz de armazenar os 868 pixels da matriz.
- Os valores dos vetores e impresso de maneira que possa ser comparado com os valores especificados na matriz de referência.
- Caso não haja distorções, o que é esperado no início das operações do equipamento, a matriz é armazenada para futuras comparações.
- Caso não esteja calibrada, o sistema permite edição da matriz com os valores indicados para a cor. Isso gera um novo vetor, denominado vetor de calibração, que calcula a diferença entre os valores capturados pela câmara e os valores indicados pela matriz de referência, corrigindo a distorção do equipamento.
- Decorrido um período de tempo de operação, o mesmo procedimento deve ser realizado, com a reapresentação da matriz de referência original. O sistema compara os valores lidos ao vetor de referência, verificando se há novas discrepâncias e dessa vez, realizando os ajustes necessários de maneira automática.

O intervalo entre as calibrações não pode ser determinado, pois embora o sistema desenvolvido tenha sido testado em termos da construção do vetor de referência cromática RGB e da sua resposta quando submetido a uma tabela de calibração alterada, o equipamento utilizado não ficou descalibrado em nenhuma ocasião.



**Figura 3.1-6:** Gamut para câmaras CCD da Ikonic Modelo IT8 E6. Fonte: IKONIC Inc ©.


A determinação a priori de um intervalo para calibração não pode ser feita a priori pelo fabricante, pois as condições de operação do equipamento podem ser as mais diversas. Um ponto importante é que em alguns casos, os sensores CCD têm sua característica de operação alterada em função de um evento, como por exemplo, exposição prolongada a raios UV, alterando sua funcionalidade e necessitando de calibração; acontece que eles retornam à sua condição de operação normal depois de algum tempo, e as informações inseridas no processo de calibração passam a atuar como distorções inseridas pelo sistema de calibração.

É fato notório que as cartas de calibração cromáticas têm suas características físicas alteradas em função da sua condição de uso, preservação e até mesmo da temperatura

ambiente e condições de iluminação. Por isso, devem ser utilizadas cartas dentro do prazo de validade e em perfeitas condições de preservação e limpeza.

### 3.1.1.5. Conversão do espaço RGB em HSL

O processo de classificação é iniciado pela captura de imagens das mangas na câmara apresentada no item anterior; duas imagens de cada amostra são necessárias, uma de cada lado da manga em posição de repouso, como mostra a Figura 3.1-7.



**Figura 3.1-7:** Imagens capturadas dos lados (A e B) de uma mesma manga. Fonte: Fotos do autor.

Como as imagens são capturadas em um sistema de representação de oito bits no padrão RGB, e o padrão HSL foi adotado para representar as imagens no sistema, uma conversão deve ser feita; isso se torna possível porque o sistema HSL pode ser definido como uma derivação paramétrica do espaço RGB.

Para efetuar a transformação do espaço de cor RGB para o HSL, realiza-se inicialmente a normalização das cores do espaço RGB, da seguinte maneira (GONZÁLES, 2010):

Somando os valores das componentes do espaço RGB, obtêm-se:

$$\Delta = R + G + B \quad (\text{Eq. 3.1-1})$$

Em seguida, a normalização transforma cada valor RGB em uma fração do intervalo [0,1]. Para isso, cada componente de cor pode agora ser descrito em relação ao somatório de cores do espaço RGB, da seguinte maneira:

$$r = \frac{R}{\Delta}, \quad g = \frac{G}{\Delta}, \quad b = \frac{B}{\Delta} \quad (\text{Eq. 3.1-2})$$

A componente matiz ( $H$ ) do espaço HSL é dada por:

$$H = \begin{cases} \theta & \text{se } b \leq g \\ 360 - \theta & \text{se } b > g \end{cases} \quad (\text{Eq. 3.1-3})$$

onde

$$\theta = \cos^{-1} \left[ \frac{\frac{1}{2} [(r - g) + (r - b)]}{[(r - g)^2 + (r - b)(g - b)]^{1/2}} \right] \quad (\text{Eq. 3.1-4})$$

A componente saturação (*S*) do espaço HSL é dada por:

$$S = 1 - \frac{3}{\Delta} [\min (r + g + b)] \quad (\text{Eq. 3.1-5})$$

Finalmente, a componente Luminosidade (*L*) do espaço HSL é dada por:

$$L = \frac{1}{3} (r + g + b) \quad (\text{Eq. 3.1-6})$$

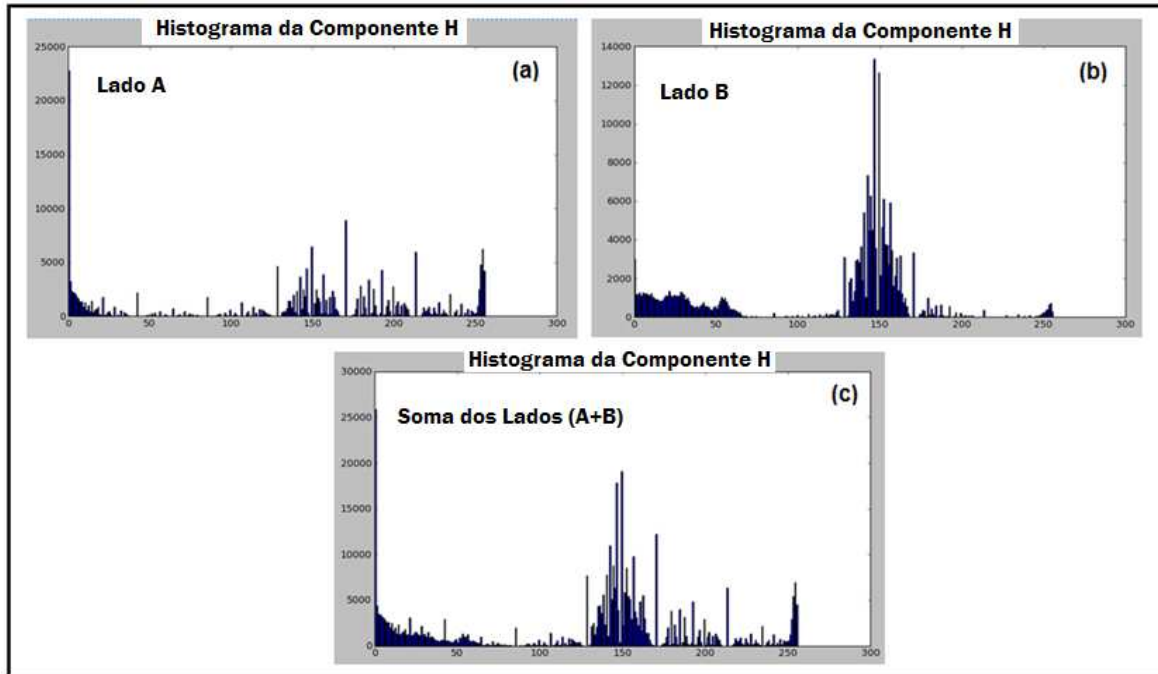
Agora todos os valores estão convertidos para o espaço HSL.

### 3.1.1.6. Construção dos histogramas das imagens

Uma vez que a imagem tenha sido capturada e convertida para o modelo HSL, o módulo que envolve a segmentação e a representação das imagens pode ser concluído com a construção de um descritor adequado (seção 2.2.8). Os histogramas das imagens (seção 2.2.8.1) são obtidos individualmente para cada componente do modelo, sendo descritos por matrizes que representam a imagem.

Cada píxel (seção 2.2.6) é descrito por três componentes, cada um representando diferentes bandas espectrais; assim, para cada ponto dessa matriz, existem três histogramas associados; um para cada componente HSL. Os gráficos dos histogramas da componente H (matiz) dos lados da manga apresentados na Figura 3.1-7, bem como a soma dessas componentes, são mostradas na Figura 3.1-8 (a), (b) e (c), respectivamente; esses histogramas foram desenvolvidos na plataforma Python 2.7.6 (linguagem de programação)/Linux (sistema operacional)<sup>18</sup>.

<sup>18</sup> Python é uma marca registrada da PSF; Linux é uma marca registrada da Linux Foundation.



**Figura 3.1-8:** Histogramas da componente H das Figuras 3.1-7-A e 3.1-7-B e sua soma. Fonte: Produzido pelo autor.


### 3.1.1.6.1. Redução do histograma de cores

A fim de minimizar o alto custo computacional (*throughput*<sup>19</sup>) inerente ao processamento de imagem, uma redução da área de leitura dos parâmetros HSL para o cálculo dos histogramas foi realizada; isso foi possível porque o histograma inclui todo o espectro de cores (Figura 3.1-9), e portanto, a faixa do espectro cuja componente de cor (H) não é observada em qualquer eventualidade possível, pode ser desconsiderada, sem trazer qualquer prejuízo à análise.

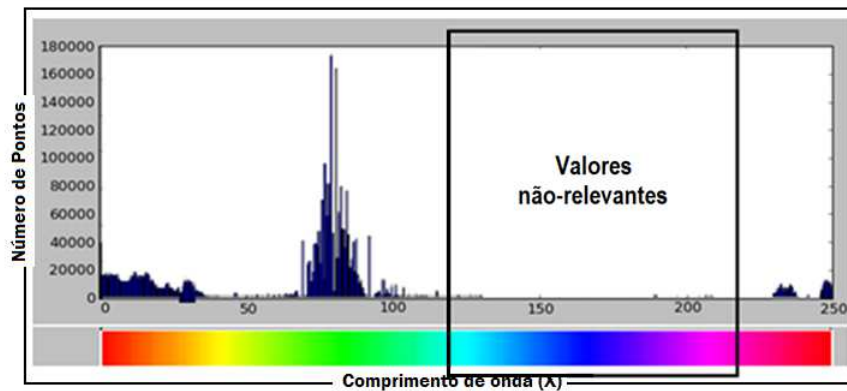
Para o caso de manga *Tommy*, Os matizes azul e ciano puderam obviamente ser descartados, uma vez que eles não são verificados em qualquer etapa no processo de pós-colheita dessa fruta.

Como a representação da imagem nesse descritor é um vetor, os elementos cujos valores são próximos dos matizes não incidentes foram expurgados, como é mostrado na Figura 3.1-10, o que resultou em um histograma reduzido, como mostrado na Figura 3.1-11.

<sup>19</sup> Em informática, a taxa de transferência é a quantidade de trabalho que um computador pode fazer em um determinado período de tempo




**Figura 3.1-9:** Histograma da imagem de um objeto. Fonte: Produzido pelo autor.



**Figura 3.1-10:** Faixa do espectro cujos valores não são relevantes. Fonte: Produzido pelo autor.

A não linearidade do eixo horizontal (salto nos valores do eixo considerando o intervalo eliminado) não afeta a representação e não traz nenhum problema para o cálculo do histograma.



**Figura 3.1-11:** Histograma resultante da eliminação das cores próximas ao azul e ciano. Fonte: Produzido pelo autor.


Observando a Figura 3.1-10, é possível observar a irrelevância dos matizes azul e ciano na distribuição de cor de uma manga *Tommy Atkins*. Portanto, é possível reduzir uma quantidade considerável de tempo de processamento, visando à melhoria do desempenho do sistema de análise de imagem. Para isso, descarta-se todos os pontos da imagem cuja componente H tenha valor superior a 20% do valor puro dessas cores.

### 3.1.1.7. Pertinência de uma amostra a um padrão

Um padrão de classificação pode definir, entre outras coisas, uma escala de cores para as superfícies das frutas. Para verificar a pertinência de uma manga a um nível de um determinado padrão, torna-se inicialmente necessário especificar o padrão; isso é feito de maneira bastante objetiva, descrevendo os percentuais de cores do padrão e associando o valor do nível para cada percentual de cores. Considerando os vários padrões definidos na seção (2.4.4), pode ser verificado que os níveis são definidos pelo percentual de cobertura de três cores, comuns à manga *Tommy Atkins*: Verde, Vermelho e Amarelo.

**Tabela 3.1-1:** Valor angular das cores Vermelho, Amarelo e Verde no Modelo HSL. Fonte: Produzido pelo autor.

Ângulo	Cor
330°	Magenta-Vermelho
360° / 0°	Vermelho
30°	Vermelho- Amarelo
60°	Amarelo
90°	Amarelo-Verde
120°	Verde
150°	Verde-Ciano



A avaliação consistirá na aplicação de um algoritmo de decisão.

O algoritmo do programa que permite informar ao sistema o padrão a ser utilizado é apresentado no Fluxograma IV do Apêndice II.

Percebe-se que a classificação através da informação do padrão a ser obedecido, não é diretamente estabelecida, pois deve ser levado em consideração o fato de que as imagens das frutas não apresentam cores puras apenas, mas uma grande quantidade de cores diferentes. A predominância de um determinado espectro de cor é o que deve ser considerado. Assim, não é possível descartar todas as cores não presentes no padrão, pois algumas dessas cores representam uma composição com uma das cores lá definidas; outras cores, como já foi visto, podem ser descartadas. A Tabela 3.1-1 mostra que entre duas cores diferentes, existem nuances que combinam essas cores.

### 3.1.1.8. Decisão na avaliação pela cor

A decisão é a resposta do sistema à apresentação de uma fruta na entrada do sistema. Para ser efetivo, o sistema deve classificar as frutas de acordo com o padrão indicado para o

procedimento; aqui deve ser lembrado que o sistema admite o uso de vários padrões (não simultâneos).

O padrão construído por especificação direta ou a partir de exemplos pode ter sua descrição insuficiente para especificar completamente as características desejadas (incompletude do modelo); como exemplo desse problema, uma fruta pode apresentar características muito próximas ao padrão e mesmo assim ser rejeitada. Assim, para evitar a rejeição indiscriminada de amostras de frutas, dois mecanismos de validação foram criados:

#### **3.1.1.8.1. Decisão pela congruência das componentes HSL:**

Esse mecanismo permite que o sistema aprenda as características das frutas que devem ser rejeitadas: a ideia é construir uma representação intensional (seção 2.3.5) dos pontos da imagem das mangas que pertencem a um determinado padrão, de maneira que essa descrição possa vir a ser comparada a pontos de uma instância representados em extensão.


Isso representa, em outras palavras, a construção de um modelo mínimo para cada componente HSL da imagem, onde cada elemento desse modelo é formado a partir de informações fornecidas pelas próprias imagens durante o treinamento, formando assim intervalos de valores onde se encontram instâncias dos valores do mundo real para o objeto.

O conhecimento aprendido pelo sistema repousa então nesses intervalos e na correlação entre eles e o padrão que representam.

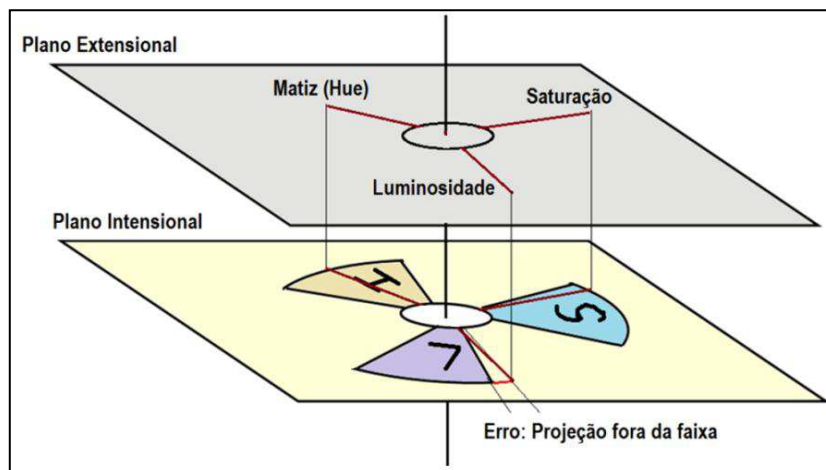
Assim, modelos podem ser criados para representar, de maneira genérica, objetos que são instâncias positivas (de acordo com o padrão), ou negativas (fora do padrão); existindo ainda espaços entre esses modelos para instâncias que não se enquadram em nenhum desses dois conjuntos.

Uma questão importante sobre a aprendizagem, é a maneira de como o sistema decidirá sobre dados de amostras ainda não informados; o que exige um mecanismo de validação. Como decidir sobre uma amostra cuja distribuição de cores não está dentro de qualquer nível de um padrão? Esta é uma das questões fundamentais da aprendizagem, que foi tratada neste trabalho, por meio de heurísticas de tratamento de ruído, implementando-se a medida de “distância” entre os modelos diferentes para a decisão.





**Figura 3.1-12:** Abstração dos planos de representação em Extensão e em Intensão. Fonte: Produzido pelo autor.




**Figura 3.1-13:** Inconsistência da componente L com o padrão. Fonte: Produzido pelo autor.

A Figura 3.1-12 apresenta uma abstração desenvolvida para modelar o sistema: A representação de um ponto da imagem (a); A faixa de valores possível para cada componente do ponto (b) e a projeção dos valores reais do ponto, obtido pelo sistema de captura de imagens, sobre o plano intensional. Neste exemplo, os valores obtidos dos pontos de uma imagem são projetados a partir da sua descrição extensional (seção 2.3.5) dentro da faixa de valores admissíveis para as componentes H, S e L da descrição intensional.

A Figura 3.1-13 apresenta a ocorrência de pontos de uma imagem fora do padrão; uma discrepância pode ser notada na componente L, que está fora da faixa de valores admissíveis

para o padrão. Para casos como esse, o sistema utiliza um teste adicional: a comparação com uma faixa de valores de exclusão, definida pela assimilação de exemplos negativos (fora do padrão) de frutas em relação ao padrão, como mostra a Figura 3.1-14. Neste caso, a fruta deve ser rejeitada.

Quando as frutas apresentarem valores fora do padrão, conjuntamente para as três componentes HSL, elas não poderão ser instanciadas nos conjuntos intensionais positivos ou negativos, devem ser rejeitadas, por estarem absolutamente fora do padrão; essa condição designa o que se costuma denominar *aberrações* ou *monstros* em sistemas de classificação baseados em conhecimento.




**Figura 3.1-14:** Ponto na faixa de valores de exemplos negativos. Fonte: Produzido pelo autor.

Ainda com referência à Figura 3.1-13, pode ser observado que as faixas de valores das instâncias positivas e negativas admitem intervalos entre seus limites; ou seja, existe uma gama de valores que não pertencem nem à faixa que define uma fruta *positiva* (pertencente ao padrão), nem à faixa que define a fruta como “negativa” (não pertencem ao padrão). Com isso, há uma folga para decisão, que pode ser definida pelo cálculo da distância entre os valores da instância e os valores dos limites dessas duas faixas.

Embora o método aqui descrito possa funcionar perfeitamente com o módulo de treinamento sendo realizado apenas com a apresentação de instâncias positivas, ele se torna mais confiável com a apresentação de instâncias negativas. Sistemas desenvolvidos com a inclusão de exemplos negativos são mais robustos, no sentido que podem justificar a classificação de um objeto como válido, mas não podem fazer isso para objetos não válidos, que são excluídos por não portarem atributos positivos, e não por portarem atributos negativos.

### 3.1.1.8.2. Decisão com base nos valores médios das componentes HSL:

Esse método de decisão emprega um fator que expressa a distância máxima entre as características da manga e as estabelecidas pelo padrão (erro) para a decisão; essa abordagem foi inicialmente concebida para os casos em que se deseja um controle maior em relação à variação cromática das frutas. Neste método, a expressão intensional dos pontos da fruta representa a média dos valores das componentes HSL dos pontos da imagem; logo, não há no plano intensional, um intervalo para filtrar os valores das componentes HSL projetados do plano extensional, mas apenas um valor para cada componente. Sendo assim, a distância entre os valores HSL dos pontos da instância extensional, são calculados e comparados com um valor de limiar associado a cada componente ( $\phi_h$ ,  $\phi_s$  e  $\phi_l$ ), definidos pelo usuário. O gráfico da Figura 3.1-15 apresenta uma abstração da aplicação desse método.



**Figura 3.1-15:** Instância atinge valor da faixa de valores de exemplos negativos. Fonte: Produzido pelo autor.

O mecanismo de decisão é indicado a partir do procedimento de “CONSULTA”. Apesar de possuírem exatamente a mesma função, podem apresentar respostas diferentes, dependendo de seus valores.

Uma vez definido, um padrão pode ser utilizado para classificar outros frutos, através da comparação com as imagens do mesmo. Isso é feito da seguinte maneira: Inicialmente, é extraído o histograma médio das imagens, de maneira que se obtenha  $n$  histogramas médios; um para cada nível do padrão. Os algoritmos envolvidos nessa tarefa são apresentados no Apêndice II, Fluxogramas V, VI e VIII:

O passo seguinte é realizar a comparação da imagem capturada da fruta a classificar e a comparação do seu histograma com os histogramas médios encontrados no passo anterior. Inicialmente, as imagens dos lados da fruta são capturadas na câmara de aquisição de imagens

e seus respectivos histogramas são gerados e somados; a soma se dá componente a componente. O resultado da soma é então comparado a cada um dos histogramas médios extraídos dos diferentes níveis do padrão. Esta comparação é determinada através do cálculo da distância entre os valores de cada componente de H, S e L, e a função que minimiza a distância é definida pelo cálculo do erro médio quadrático, que deve ser encontrado para cada componente do espaço de cor, através das seguintes expressões:

Erro médio quadrático da componente H

$$D_{ImH,MH} = \sqrt{\frac{1}{n} \sum_{j=0}^{155} [imH(j) - MH(j)]^2} \quad (\text{Eq. 3.1-7})$$

Erro médio quadrático da componente S

$$D_{ImS,MS} = \sqrt{\frac{1}{256} \sum_{j=0}^{255} [imS(j) - MS(j)]^2} \quad (\text{Eq. 3.1-8})$$

Erro médio quadrático da componente L

$$D_{ImL,ML} = \sqrt{\frac{1}{256} \sum_{j=0}^{255} [imL(j) - ML(j)]^2} \quad (\text{Eq. 3.1-9})$$

Deve ser observado em (a), que  $n$  é o número de elementos da componente MATIZ, que sofre a redução da representação da componente H; no caso da manga *Tommy Atkins*,  $n = 156$  (Equação 3-1.7). As demais componentes não são reduzidas, evidentemente.

O algoritmo identifica a classe, ou seja, o nível do padrão que mais se aproxima das frutas a classificar (Apêndice II, Fluxograma IX). O número de níveis é uma característica do padrão e a aproximação de uma fruta a um desses níveis é feita através do cálculo da distância entre a imagem dessa fruta e a representação generalizada dos níveis do padrão, onde a fruta é associada ao nível mais próximo. Isso funciona bem para os níveis intermediários, mas a imagem pode apresentar características muito abaixo do nível inicial ou muito abaixo do nível final. Para evitar esse erro, o método estabelece um operador de pertinência  $\phi$ , definido em  $[0,1]$ , que permitirá estabelecer uma medida de similaridade. Com isso, ao se especificar  $\phi =$

0,95, por exemplo, o sistema recusará qualquer distância superior a 5%; ou seja, para que uma fruta tenha seu nível identificado no padrão, além de ter suas cores próximas às cores do nível, determinado pela distância mínima, a diferença entre as cores não poderá exceder esse limiar.

O procedimento computacional para encontrar a distância mínima entre a imagem e os  $n$  níveis do padrão, além de verificar a similaridade ( $\phi$ ), está descrito no Apêndice II, Fluxograma IX.

Em resumo, o Cálculo da distância para os valores médios das componentes HSL admite um fator de aproximação que é definido empiricamente pelo usuário e pode ser ajustado, dependendo da resposta do sistema. Já o mecanismo de avaliação da congruência com a faixa de valores das componentes HSL do conjunto de exemplos positivos e negativos do padrão, é completamente autônomo, e só pode ser alterado pelo usuário pela revisão do conhecimento; ou seja, pela apresentação de novos exemplares positivos e negativos.

### **3.1.1.9. Especificação do sistema de aprendizagem**

O presente método utiliza a aprendizagem de máquina construída sob dois paradigmas da aprendizagem de máquina (seção 2.3.5): No primeiro caso, a fonte é o instrutor; esse é o caso do ensino direto ou edição da base de conhecimento. No segundo caso, a fonte provém de exemplos positivos e negativos (seção 2.3.5).

O conjunto de objetos (mangas) ser avaliado permite a modificação do sistema de seleção, configurando a aprendizagem como dinâmica (seção 2.3.5). Assim, admite que a base de conhecimento seja ajustada com a experiência, ou seja, a apresentação sucessiva de novas características é absorvida pelo sistema; portanto, a aprendizagem é incremental (seção 2.3.5).

Como o conjunto de entrada pode apresentar distorções que não estão caracterizadas na base de conhecimento, a aprendizagem admite classificar objetos com a presença de ruídos de atributos e até mesmo, ruídos de classe (seção 2.3.5).

Para realizar a classificação de mangas utilizando como critério a cor da superfície, o sistema utiliza padrões de referência; esses padrões permitem ao agente classificador, realizar uma comparação para identificar as mangas submetidas à entrada, segundo critérios por eles estabelecidos.

Os padrões podem ser definidos a partir de dois métodos de aprendizagem distintos:

### **3.1.1.9.1. Aprendizagem por instrução direta**

Para definir um padrão por instrução direta, um critério de classificação deve ser inicialmente estabelecido fora do sistema, de maneira que seja possível para um humano, identificar visualmente um fruto em conformidade com desse critério.

O usuário deve apenas informar ao sistema, o nome do padrão, o número de níveis e para cada um desses níveis, informar as cores e os respectivos percentuais de cobertura.

O algoritmo funcional do método que realiza a consulta para o padrão definido por instrução direta é mostrado no Fluxograma III do Apêndice II.

Os algoritmos computacionais desenvolvidos para implementar esse método são mostrados no Apêndice II - Fluxogramas VI e VII.

### **3.1.1.9.2. Aprendizagem a partir de exemplos**

O critério para definir a aprendizagem por exemplos (seção 2.3.5) deve estabelecer inicialmente o número de níveis; em seguida é necessários submeter exemplares de frutos pertencentes a cada um dos níveis ao sistema. Um diretório será criado, com a criação de  $n$  subdiretórios, onde  $n$  é o número de níveis do padrão.

O algoritmo funcional desse método de definição de padrões é mostrado no Fluxograma I do Apêndice II; já o algoritmo computacional encontra-se no Fluxograma VIII.

### **3.1.1.9.3. Construção da base de conhecimento**

A base de conhecimento (ou *Knowledge Base - KB*) é construída a partir das informações sobre as cores extraídas das imagens das mangas; ou seja, é baseado em objetos. Trata-se de uma tabela de valores onde as relações entre os dados e operações sobre os mesmos estão distribuídas nos diversos módulos do sistema.

A relação de identificadores que pertencem à estrutura de dados da base de conhecimento é apresentada no Quadro 3.1-1; esta estrutura suporta  $k+1$  padrões diferentes; para cada padrão,  $n$  níveis podem ser definidos; para cada nível, são definidos os valores mínimo, máximo e médio das componentes *HSL*, formados pelas amostras *positivas* e *negativas*.

Os identificadores da base de conhecimento para instrução direta são apresentados no Quadro 3-1.2:

**Quadro 3.1-1** - Relação dos identificadores da base de conhecimento. Fonte: Produzido pelo autor.

Identificador	Descrição
Standard[k]	Nome do Padrão[k]; com $k \geq 0$ .
n_Inst[k]	Número de instâncias componentes do padrão k.
n_level[k]	Número de níveis do padrão k.
Min_H_k_i_n_p	Valor mínimo da componente H[i]; com $i=[0..155]$ , para o padrão k, nível n; Inst. positiva.
Max_H_k_i_n_p	Valor máximo da componente H[i]; com $i=[0..155]$ , para o padrão k, nível n; Inst. positiva.
Med_H_k_i_n_p	Valor médio da componente H[i]; com $i=[0..155]$ , para o padrão k, nível n; Inst. positiva.
Min_H_k_i_n_n	Valor mínimo da componente H[i]; com $i=[0..155]$ , para o padrão k, nível n; Inst. negativa.
Max_H_k_i_n_n	Valor máximo da componente H[i]; com $i=[0..155]$ , para o padrão k, nível n; Inst. negativa.
Med_H_k_i_n_n	Valor médio da componente H[i]; com $i=[0..155]$ , para o padrão k, nível n; Inst. negativa.
Min_S_k_i_n_p	Valor mínimo da componente S[i]; com $i=[0..255]$ , para o padrão k, nível n; Inst. positiva.
Max_S_k_i_n_p	Valor máximo da componente S[i]; com $i=[0..255]$ , para o padrão k, nível n; Inst. positiva.
Med_S_k_i_n_p	Valor médio da componente S[i]; com $i=[0..255]$ , para o padrão k, nível n; Inst. positiva.
Min_S_k_i_n_n	Valor mínimo da componente S[i]; com $i=[0..255]$ , para o padrão k, nível n; Inst. negativa.
Max_S_k_i_n_n	Valor máximo da componente S[i]; com $i=[0..255]$ , para o padrão k, nível n; Inst. negativa.
Med_S_k_i_n_n	Valor médio da componente S[i]; com $i=[0..255]$ , para o padrão k, nível n; Inst. negativa.
Min_L_k_i_n_p	Valor mínimo da componente L[i]; com $i=[0..155]$ , para o padrão k, nível n; Inst. positiva.
Max_L_k_i_n_p	Valor máximo da componente L[i]; com $i=[0..155]$ , para o padrão k, nível n; Inst. positiva.
Med_L_k_i_n_p	Valor médio da componente L[i]; com $i=[0..155]$ , para o padrão k, nível n; Inst. positiva.
Min_L_k_i_n_n	Valor mínimo da componente L[i]; com $i=[0..155]$ , para o padrão k, nível n; Inst. negativa.
Max_L_k_i_n_n	Valor máximo da componente L[i]; com $i=[0..155]$ , para o padrão k, nível n; Inst. negativa.
Med_L_k_i_n_n	Valor médio da componente L[i]; com $i=[0,..,155]$ , para o padrão k, nível n; Inst. negativa.

**Quadro 3.1-2:** Relação dos identificadores para instrução direta. Fonte: Produzido pelo autor.

Identificador	Descrição
Standard[k]	Nome do k-ésimo Padrão, com $k \geq 0$
n_levels[k]	Número de níveis do padrão k
num_color[k]	Número de cores do padrão k
n_color[k,i]	Nome da i-ésima cor do padrão k; $i = \{0..num\_color-1\}$
Perc_color[k,i,p,j]	Tabela que agrega o padrão k, da cor i, o percentual de cor p no nível j.

### **3.1.2. Método para detecção de manchas pretas**

Muitas das várias doenças e pragas que atingem a manga possuem uma característica importante comum, que é a presença de manchas negras na sua superfície (seção 2.1.8). Considerando esse aspecto, a identificação de manchas negras sobre a superfície da manga, independente da causa das mesmas, se torna uma tarefa relevante para assegurar a qualidade em um sistema automático de classificação.

Todas as normas referentes a padrões de qualidade de manga para os mercados internacionais, como a FFV-45, da Comissão Econômica para a Europa da ONU, incluindo a instrução normativa Nº 38 de 19 de dezembro de 2012, do Ministério da Agricultura, Pecuária e Abastecimento do Brasil, estabelecem padrões mínimos que os frutos para consumo *in natura* devem respeitar. Essas normas estabelecem que a presença de manchas negras nas superfícies das frutas é um fator que degrada substancialmente a qualidade; isso é corroborado na publicação técnica sobre pós-colheita de mangas para exportação do EMBRAPA/CNPq (FILGUEIRAS, 2000), e em vários outros artigos científicos nacionais e internacionais.


Um preceito bastante difundido para a compra de mangas é o de evitar as frutas que apresentam manchas escuras, muito embora a presença de algumas dessas manchas não afetem a polpa da fruta, apenas seu aspecto visual externo. As frutas com manchas negras, expostas numa prateleira, são evitadas pelos consumidores, tornando esse um fator decisivo associado à qualidade da fruta para comercialização.

Manchas negras na superfície podem indicar a ocorrência de doenças, pragas ou amaduracimento demasiado da fruta; geralmente, a presença dessas manchas em abundância em uma manga madura, pode indicar alterações da polpa logo abaixo.

#### **3.1.2.1. Definição do método para detecção de manchas negras**

A detecção de manchas negras nas superfícies das mangas foi implementada neste trabalho a partir da detecção de pontos com níveis de saturação muito baixos. Esses pontos possuem ainda valores mínimos das componentes S e L para uma determinada matiz H, não sendo portanto confundidos e contabilizados com aqueles que formam o fundo da imagem. Observe na Figura 3.1-16, que a saturação S da componente Matiz (H) das cores verde, vermelho e amarelo (puras), possui uma faixa de valores que tornam a percepção dessas cores bem próxima à do preto, mais precisamente os valores entre 0 e 25% (efeito color fade); esse efeito sofre variações ainda mais abruptas quando se varia a componente Luminosidade (L).





**Figura 3.1-16:** Efeito “fade” pela redução do valor S. Fonte: Montagem do autor.

Com isso, uma rotina foi criada para detectar qualquer ponto coberto por uma cor típica do padrão da manga, com valores de S e L inferiores a um determinado limiar, inicialmente estabelecido em 20%. Esses valores podem ser alterados, para determinar outros tipos de distorções na combinação HSL na área da fruta, para detectar alterações indesejáveis nas cores das frutas, chegando inclusive a determinar ocorrências de manchas esbranquiçadas, onde valores altos da luminosidade (L) tornam a sensação da cor próxima ao branco, independente do matiz (H). O Algoritmo que realiza a detecção da mancha escura e calcula o seu percentual, está incluído no Apêndice II deste trabalho, Fluxograma XII.

### 3.1.3. Método “Fuzzy” para estimação da maturidade

A eficiência de processos adequados e confiáveis para classificação de frutos é de grande importância para o aumento da produtividade da indústria agrícola; esses processos são de importância vital para melhorar a qualidade e conseqüentemente, favorecer o comércio e a exportação.

A manga é um dos produtos mais importantes do mercado internacional de frutas frescas; há demandas para esse produto tanto no mercado interno quanto no externo. Entretanto, o processo de classificação de mangas é realizado por seres humanos, sendo considerado ineficiente, por ser trabalhoso, tedioso e propenso a erros.

A estimação da maturidade de mangas é um dos principais requisitos associados à comercialização dessa fruta, devido principalmente à rápida taxa de amadurecimento em prateleira dessa fruta (seção 2.1.2).

A determinação do estágio de maturação de mangas pode ser realizada considerando uma função cujo domínio é a distribuição de cores na superfície da fruta, tendo como imagem um termo que o designa em linguagem natural, como “verde”, “maduro”, “muito maduro”, etc. A lógica fuzzy proporciona meios de utilizar essa informação imprecisa em sistemas

automáticos de classificação, permitindo não apenas acelerar o tempo do processo, mas também estabelecer uma comunicação com a máquina de forma mais natural.

### **3.1.3.1. Seleção de frutos pela maturidade a partir da cor da superfície**

Para realizar a seleção de mangas em termos de sua maturidade, utilizando como critério a cor da superfície (seção 2.1.3), torna-se necessário adotar um padrão de referência (MALEVSKI *et al.*, 1977); esse padrão poderá ser definido por órgãos que atuam no mercado ou mesmo pelo próprio produtor/distribuidor, quando se deseja estabelecer um procedimento particular mais específico.

O padrão permitirá ao agente selecionador, realizar uma comparação para identificar a manga segundo critérios pré-estabelecidos.

Uma vez que seja estabelecido o padrão, existirá o risco de erros humanos ocorrerem na seleção, porquanto a percepção de diferenças em escala de cores não é uma tarefa trivial, principalmente sem a utilização de aparelhos de mensuração adequados.

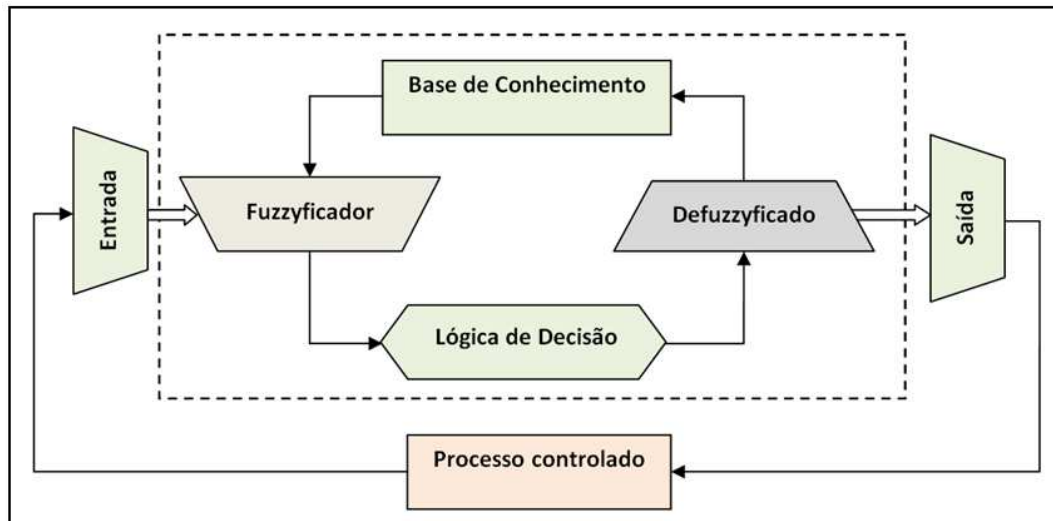
No caso da manga *Tommy Atkins*, assim como em outras variedades, a cor de sua superfície varia de acordo com a sua fase de desenvolvimento (seção 2.1.1), porém, dada a profusão de cores variadas, não é fácil estabelecer tal correlação; talvez por esse motivo, sejam tão poucos os padrões estabelecidos como referência para indicar o estágio de maturação dessa variedade (2.2.2).

### **3.1.3.2. O sistema Fuzzy para decisão sobre a maturidade**

Um **sistema fuzzy** para decisão é composto pelos seguintes elementos (ALAVI, 2012):

- Uma coleção de variáveis de entrada, onde cada uma delas representa uma coleção de conjuntos;
- Uma coleção de conjuntos para a variável de saída;
- Uma coleção de regras que associam as entradas à saída;

A Figura 3.1-17 apresenta o esquema geral de um **sistema de controle fuzzy** operando em um processo designado para selecionar mangas em função da sua maturidade.



**Figura 3.1-17:** Sistema fuzzy para controle de um processo Fonte: Produção do autor.

Um conjunto de regras lógicas define o algoritmo de controle fuzzy, incorporando o conhecimento humano, que é abstrato, subjetivo e muitas vezes adstrito de múltiplas interpretações. A lógica permite definir uma estratégia de controle.

O diagrama do sistema fuzzy apresentado possui os seguintes componentes:

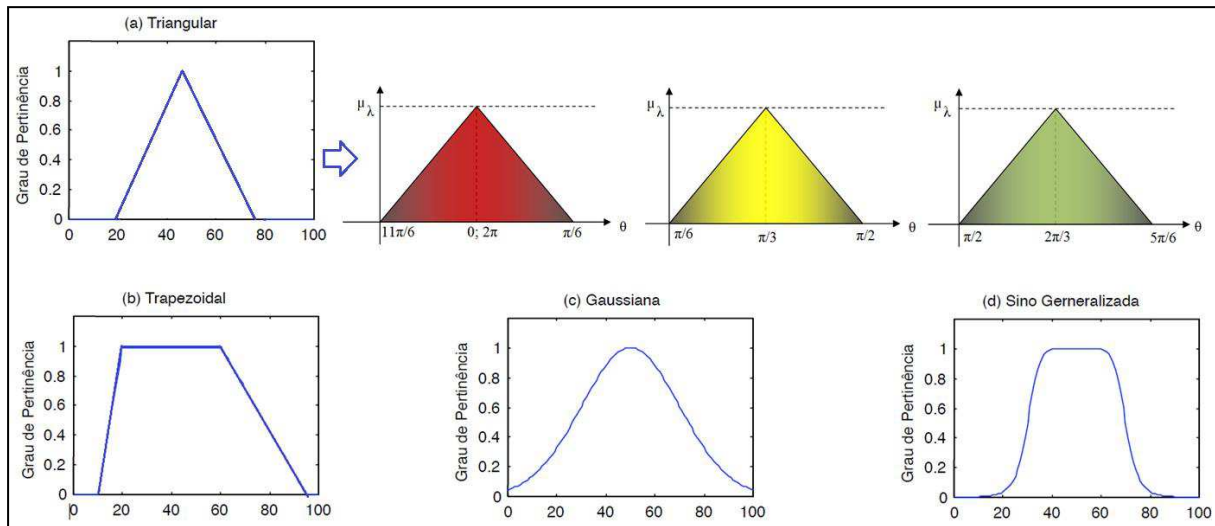
- **Entrada:** Local onde os dados numéricos nos quais o sistema irá se basear para tomar as decisões são coletados.
- **Fuzzificador:** Parte do sistema que transforma dados numéricos em informações nebulosas (fuzzy).
- **Base de conhecimento:** Local onde residem as regras a serem aplicadas para a decisão.
- **Analizador lógico:** Toma as decisões, integrado por um motor de inferência e algumas funções de aglutinação fuzzy;
- **Defuzzificador:** Faz o papel inverso ao fuzzificador, transformando a saída fuzzy do sistema em uma informação numérica.
- **Saída:** Emite a resposta do sistema.

### 3.1.3.3. Fuzzificação de variáveis, funções de pertinência e lógica de decisão

As funções de pertinência definem o grau de pertinência ( $\mu$ ) de um determinado valor para cada termo linguístico, definindo as curvas de possibilidades. A maioria das aplicações

utiliza funções de pertinência padrão (*Standard Membership Functions - Standart-MBFs*).

A Figura 3.1-18 apresenta algumas das principais funções aplicáveis para fuzzificadores.



**Figura 3.1-18:** Funções "fuzzy" de pertinência típicas. Fonte: Produção do autor.

A representação de cores em gráficos fuzzy emprega normalmente funções senoidais como a Gaussiana, apresentada na Figura 3.1-18(c), mas no caso deste trabalho, foram utilizadas formas triangulares, como mostra a Figura 3.1-18(a), já que as cores do sistema HSL podem ser representadas por um gráfico valorado no intervalo  $[0,1]$ , onde o valor "1" representaria o matiz puro da cor, ou seja, o ângulo no círculo de cores onde o matiz atinge seu valor máximo (seção 2.2.5); por exemplo,  $0^\circ$  ou  $360^\circ$  para a cor vermelha ( $0-2\pi$ ). A partir desse ponto, e em direções opostas, o matiz perde sua tonalidade progressivamente, até chegar a um ponto onde seu valor é nulo, o que seria representado pelo "0".

A informação sobre a *maturidade* é suficientemente representada por uma função trapezoidal como mostra a Figura 3.1-18(b), já que as condições podem ser consideradas constantes sobre algum intervalo de tempo.

Os nomes das funções fuzzy seguem as formas dos respectivos gráficos; As funções de pertinência são normalizadas no intervalo  $[0,1]$ ; com isso, seu máximo é sempre "1" (100% de pertinência) e o seu mínimo é "0" (indica a não pertinência ao grupo).

O uso de funções-padrão apresenta inúmeras vantagens em relação ao uso de outras curvas, pois são simples, porém completas; representam bem a realidade e são em termos computacionais, de fácil implementação.

Outros tipos de funções de pertinência podem ser empregados, mas são invariavelmente mais pesados, por exigirem maior *throughput*; além disso, podem não seguir um dos princípios básicos inerentes à lógica fuzzy: funcionar de maneira a imitar o modo como o ser humano raciocina ou assimila informação.

Neste trabalho, a pertinência a cada um dos grupos definidos no padrão é estabelecida por uma função fuzzy que estabelece uma relação entre descrições da sensação de cor transmitida pela superfície da manga *Tommy Atkins* e o seu respectivo estágio de maturidade. Inicialmente, essas indicações devem ser expressas em um formato fuzzy; ou seja, devem ser “fuzzificadas”.

A fuzzificação nada mais é que a transformação de dados de entrada (distribuição de cores) para um conjunto fuzzy correspondente. Antes dos dados serem fuzzificados, eles devem ser normalizados para que se enquadrem nos limites adequados do universo de discurso da entrada do sistema.

Uma das entradas do processo resulta de medidas de parâmetros, neste caso, os dados sobre a cobertura cromática da manga. Tais medidas geram dados do tipo analógicos, que são convertidos para uma representação digital adequada, através de uma conversão D/A (Digital para Analógico), para que possam ser manipulados pelo sistema. Essa conversão, bem como todo o mecanismo de aquisição de dados de imagens e a quantificação das suas cores são realizadas pelo mesmo sistema descrito na seção (3.1.1).

Em sistemas de controle, a saída do processo é realimentada para o controlador fuzzy, que já manipula a informação convertida para a representação digital. No caso do sistema de classificação, a saída gerada pode ser encaminhada a outro sistema, como o de empacotamento, por exemplo. A única informação a ser enviada da saída para a entrada é um sinal de “flag”, indicando que uma nova manga pode ser analisada.

As imagens das mangas e as informações sobre maturação possuem precisão e resolução específicas; daí a necessidade de se estabelecer uma normalização desses valores. Deve ser salientado que normalizações mal elaboradas podem ser responsáveis pela introdução de erros sistemáticos nos dados de entrada.

O processo de Fuzzificação pode seguir três estratégias básicas:

- Dados de entrada quaisquer são convertidos em uma função singular fuzzy em um universo apropriado de discurso. Precisamente, a função singular fuzzy é um valor comum e conseqüentemente nenhum processo de Fuzzificação é introduzido neste caso.
- Dados de entrada quaisquer são convertidos em um vetor fuzzy baseado em conhecimento fornecido por algum especialista ou diretamente por instrumentos de medida, conversão *ND* e normalização. Este é o caso da fuzzificação da distribuição de cores capturadas por um sistema da visão computacional.
- Dados de entrada são distribuídos de maneira aleatória e então convertidos em um vetor fuzzy arbitrário. Porém, a distribuição do vetor fuzzy pode ser determinada pelos parâmetros da distribuição disponível para o processo de medida subjacente. Essa abordagem é raramente utilizada.

As cores podem ser utilizadas para categorizar a manga em grupos distintos. O Quadro 3.1-3 apresenta cinco grupos associados a uma variável fuzzy descrita em linguagem natural. O número de grupos foi definido a partir de termos geralmente utilizados em linguagem natural para especificação do estágio de maturidade. A tese subjacente é que existe um conjunto de cores cujos percentuais de cobertura sobre a superfície de uma manga são relacionados à esta Tabela. Outros valores binários são introduzidos nessa Tabela para caracterizar comercialmente o nível de maturidade.

Diferentemente dos padrões já apresentados, é estabelecida neste trabalho uma referência ao estágio de maturidade avançada da manga. Tal inclusão é justificada pela possibilidade de uma fruta apresentar estado de maturidade além do ideal; ou seja, a fruta já se encontra no estado de *senescência*. Pode-se denominar este conjunto de valores-padrão TAFC (*Tommy Atkins Fuzzy Classifier*).

**Quadro 3.1-3** - Variáveis fuzzy associadas ao padrão TAFC. Fonte: Produção do Autor.

Escala	Descrição	Descartável	Comestível
1	manga verde	não	não
2	manga meio madura	não	sim
3	manga madura	não	sim
4	manga muito madura	não	sim
5	manga senescente/deteriorada	sim	não

A fuzzificação da cor (entrada) é feita nesse caso, pela definição da pertinência como uma função da quantidade de pixels presentes na imagem capturada da manga, nas faixas de comprimento de onda da luz para as cores verde, vermelha e amarela ( $\lambda$ ). A cor é uma


variável linguística. Já a instância de uma cor, ou seja, um valor de cor específico é um valor linguístico.

Um valor linguístico  $\lambda_x$ , é fuzzificado utilizando funções de pertinência para mapeá-lo no intervalo [0,1]; isso já é realizado pelo sistema desenvolvido na seção 2, que foi utilizado para obter os valores informados nesta análise.

A Figura 3.1-18 apresenta as funções de pertinência para as cores verde, vermelho e amarelo. Este gráfico fuzzy foi construído de maneira a interpretar qualquer possível valor de  $\lambda$ ; nele existe, evidentemente, um conjunto infinito de combinações de percentuais complementares de cores entre cada par de valores de  $\lambda$ . Procura-se neste trabalho, classificar mangas considerando apenas um subconjunto particular de cores. Os percentuais  $\lambda$  considerados representam a área da manga coberta por cada cor, em todas as possíveis combinações.

A distribuição dos valores dos comprimentos de onda como mostrado na Figura 3.1-19 não é de fácil implementação. O modelo RGB não indicaria dois pontos de cores distintos, pois um único ponto nesse modelo é composto por parcelas das três cores componentes.

No caso do modelo HSL, um ponto define uma cor única; portanto não seria possível especificar duas cores num só ponto. Entretanto, o gráfico transmite a abstração de uma combinação disjunta de cores, e seu resultado pode ser obtido diretamente a partir do histograma pelo fuzzificador do fluxograma VI do Apêndice II.



**Figura 3.1-19** - Função fuzzy para representação de cores. Fonte: Produção do Autor.

### 3.1.3.4. Regras fuzzy para decisão

O conhecimento específico do problema de classificação da maturidade, segundo o padrão proposto, pode ser formalizado na forma de *Regras Fuzzy*. Variáveis linguísticas

podem ser utilizadas num sistema baseado em regras do tipo *SE-ENTÃO*, para permitir a construção de sistemas de tomada de decisão. Essas regras são compostas por duas partes; uma denominada “antecedente”, que expressa a condição a ser verificada para a aplicação da segunda parte, denominada “consequente”, que expressa a ação a ser realizada caso a sua antecedente seja verdadeira.

Geralmente, as regras de inferência fuzzy representam uma generalização em algum nível, da regra lógica advinda do cálculo proposicional denominada “*Modus Ponens*”, que longe de ser uma “lei” da lógica, é na verdade um dos mecanismos mais universalmente aceitos para a construção de deduções. Essa regra estabelece o seguinte:

$$\frac{P \rightarrow Q, P}{\therefore Q}$$

Ou seja, se é verdade que uma determinada afirmação (*P*) implica (ou resulta) em uma outra afirmação (*Q*), então na ocorrência de *P*, deduz-se *Q*. A inferência fuzzy expressa uma relação *R* entre dois conjuntos *A* e *B*, a partir da generalização da regra *Modus Ponens*, da seguinte maneira:

$$R: A \rightarrow B$$

Ou seja, se *A* é verdade, então *B* também é verdade.

As regras fuzzy definem o conhecimento envolvido, que pode ser obtido heurísticamente, por experiência ou qualquer outro meio, humano ou artificial; para o caso da manga *Tommy Atkins*, foi estabelecido heurísticamente, e está representado pelas regras mostradas no Quadro 3.1-4.

**Quadro 3.1-4:** Regras fuzzy que relacionam as cores ao estágio de maturação. Fonte: Produção do Autor.

Regra	Antecedente	Consequente
R <sub>1</sub>	Se a cor for verde	(Manga está verde) ∨ (Manga está meio madura)
R <sub>2</sub>	Se a cor for vermelha	(Manga está meio madura) ∨ (Manga está madura)
R <sub>3</sub>	Se a cor for amarela	(Manga está muito madura) ∨ (Manga está senescente)

Essas regras representam o nosso conhecimento sobre o problema, adquirido por experiência; elas representam um formalismo para um processo de pensamento.

A informação sobre a maturidade da fruta é também inserida no sistema; A Figura 3.1-20 mostra as funções de pertinência que serão utilizadas neste trabalho para essa variável fuzzy.



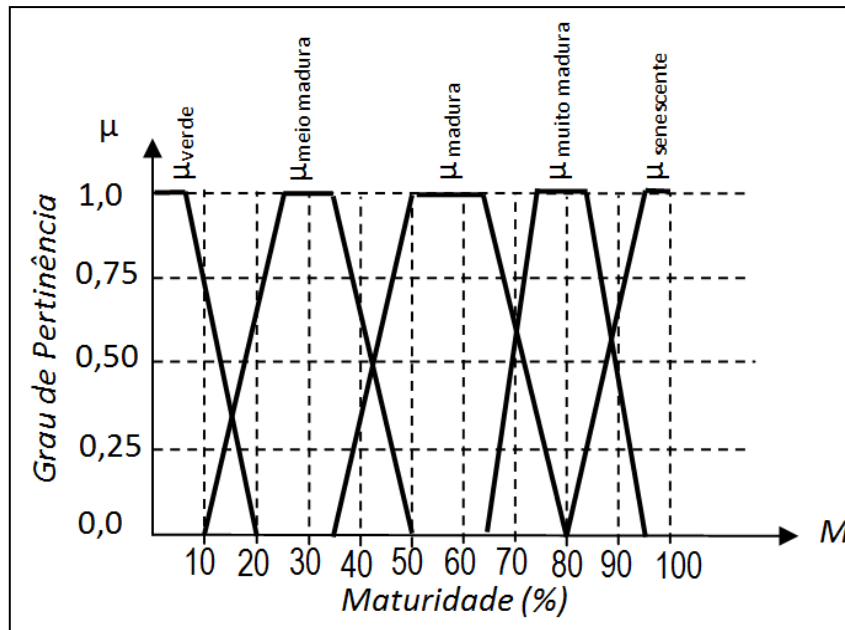


Figura 3.1-20: Funções fuzzy para o maturidade. Fonte: Produção do Autor.

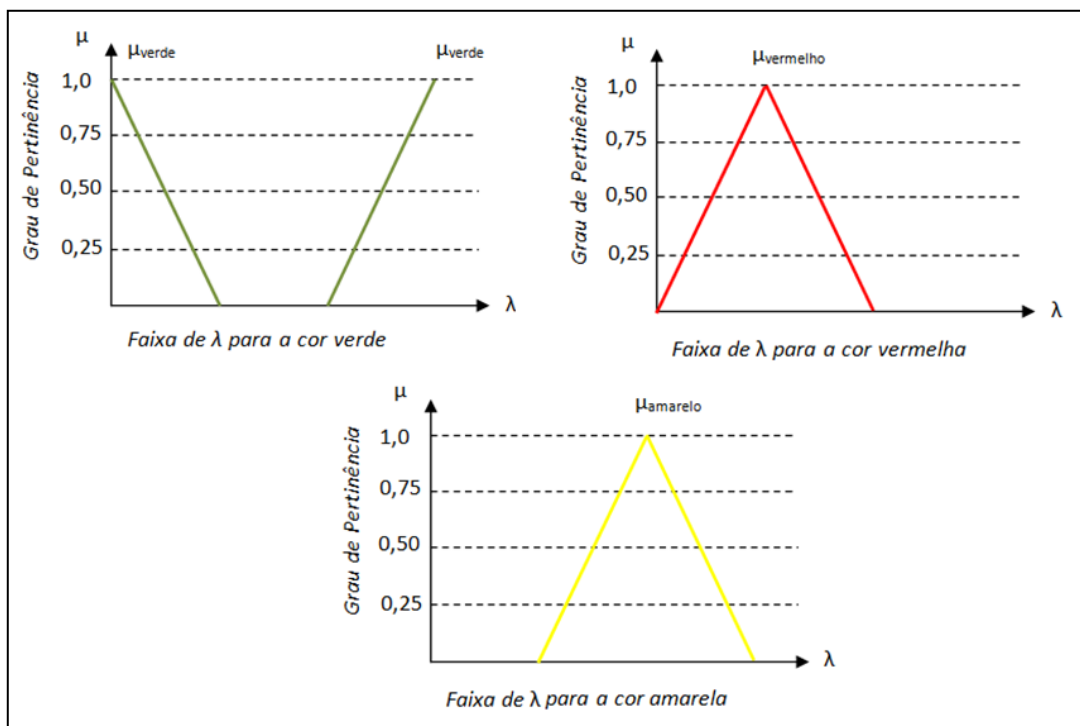


Figura 3.1-21: Funções fuzzy individuais para as cores. Fonte: Produção do Autor.

As Figuras 3.1-20 e 3.1-21, juntamente com a base de regras (Quadro 3.1-4), contêm todas as informações necessárias para relacionar os dados de entrada com os de saída.

O gráfico da Figura 3.1-20 pode ser desmembrado para cada cor, como mostram os gráficos da Figura 3.1-21.

O gráfico da Figura 3.1-20 também pode ser desmembrado para os diversos estádios de maturidade, como mostra os gráficos da Figura 3.1-22.

O próximo passo do procedimento consiste em correlacionar as informações de entrada (cores) com a base de conhecimento (regra SE-ENTÃO), para gerar o resultado de saída. Esse processo representa a inferência sobre o conhecimento expresso nas regras.

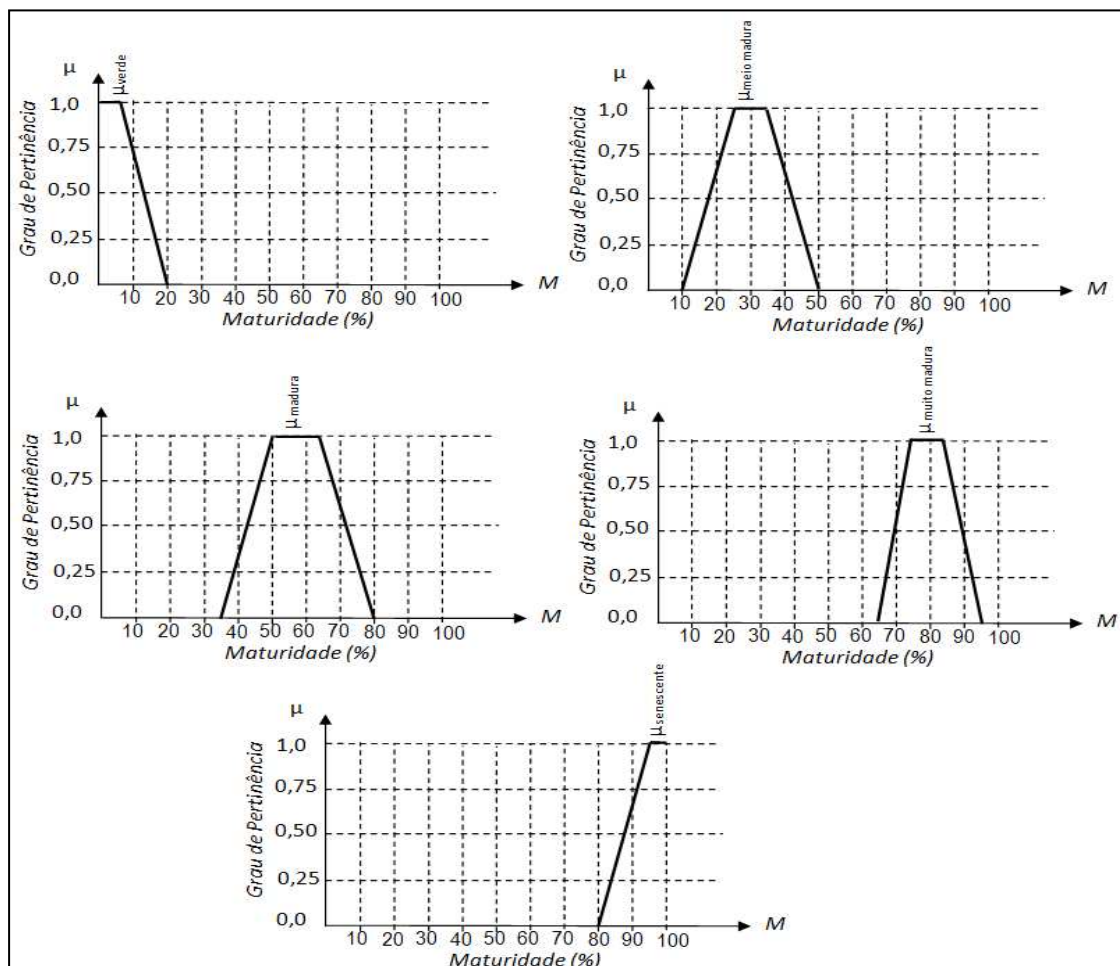


Figura 3.1-22 - Estádios de Maturidade fuzzificados. Fonte: Produção do Autor.

Existem várias técnicas inferenciais aplicáveis sobre conjuntos fuzzy; uma das mais simples e mais empregadas é a estratégia de Mandami (MANDANI, 1974), exemplificada na Figura 3.1-23. Essa abordagem realiza operações Mín e Máx, que representam as operações de interseção e união sobre os conjuntos, e é aplicável a sistemas de decisão sobre maturidade de frutos (ADHIMANTORO e GAOL, 2014).

A função MIN transporta para a saída, o menor valor observado nas variáveis; as várias saídas minimizadas são então submetidas à função MAX, que gera o conjunto de valores equivalente à união dos conjuntos minimizados da saída. Como se manipula informações

fuzzy, os resultados das inferências também serão fuzzy, de forma que funções de pertinência também devem ser definidas para os resultados.

A técnica de Mamdani assemelha-se à heurística de decisão MAXMIN, onde num sistema de escolhas, o melhor dos piores resultados é escolhido. É um critério de decisão conservador, mas coerente.

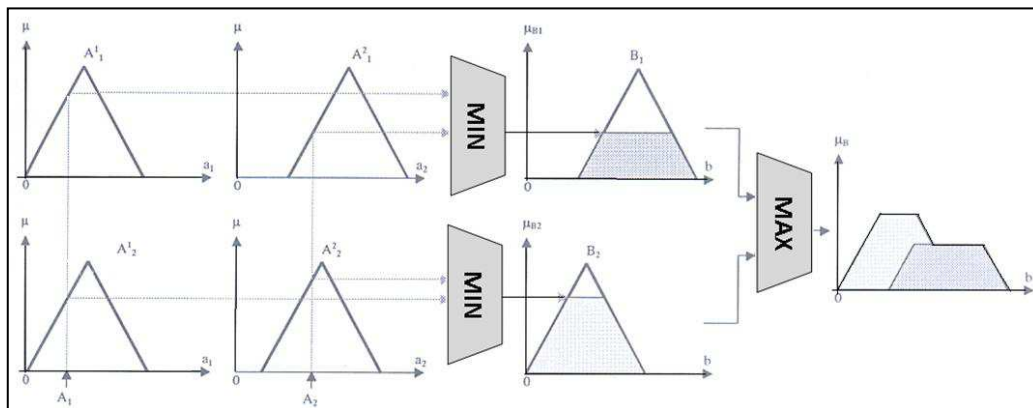


Figura 3.1-23: Estratégia de Mamdani. Fonte: Adaptação do Autor a partir de MAMDANI (1974).

Seja a seguinte expressão: *vermelho E maduro*; ela representa uma operação de interseção E (ou AND, como é comumente usada na notação da lógica booleana) entre duas variáveis independentes da entrada do nosso sistema.

Para avaliar essa expressão, torna-se necessário fazer uma composição dos planos Cartesianos das duas variáveis, produzindo uma saída bidimensional.

As regras a serem inferenciadas são então expressas pelas seguintes expressões:

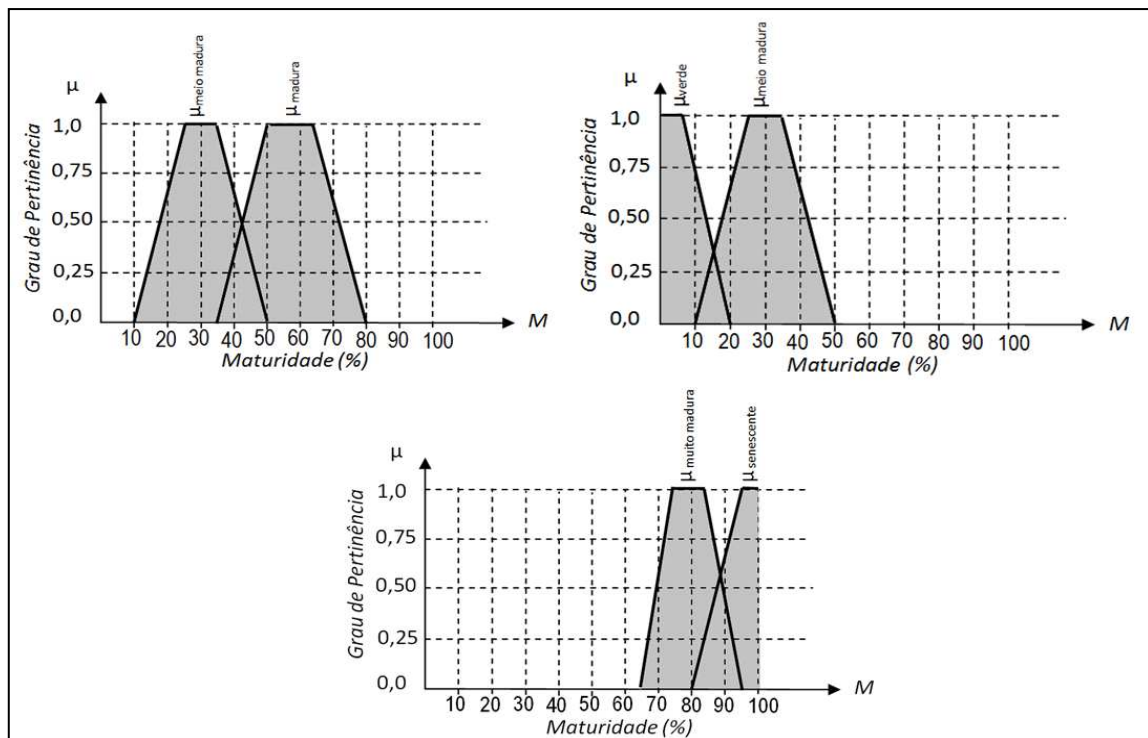
$$\mu_{R1}(\lambda, m) = \text{Mín}\{\mu_{\text{verde}}(\lambda), (\mu_{\text{verde}}(m) \text{ OU } \mu_{\text{meio-maduro}}(m))\}.$$

$$\mu_{R2}(\lambda, m) = \text{Mín}\{\mu_{\text{vermelho}}(\lambda), (\mu_{\text{meio-maduro}}(m) \text{ OU } \mu_{\text{maduro}}(m))\}.$$

$$\mu_{R3}(\lambda, m) = \text{Mín}\{\mu_{\text{amarelo}}(\lambda), (\mu_{\text{maduro}}(m) \text{ OU } \mu_{\text{senescente}}(m))\}.$$

Nas equações acima, o subíndice R se refere às regras da base de conhecimento que envolve essas funções.

Como a função Maturidade possui entradas compostas (definidas pelas regras), uma associação dos estádios de maturação deve ser realizada através da operação União, como mostra os gráficos da Figura 3.1-24.



**Figura 3.1-24:** Funções fuzzy individuais para os estádios de Maturidade. Fonte: Produção do Autor.

Assim como a combinação das funções fuzzy de cor ( $\lambda$ ) e estado de maturidade (M), pode-se combinar todo o conjunto de possibilidades  $\lambda \times M$ , gerando um *sólido de decisão*.

### 3.1.3.5. Defuzzificação

A defuzzificação é o processo que promove a conversão do resultado obtido pela inferência realizada sobre o conjunto fuzzy em um valor numérico escalar (*crispy value*). Isso se torna necessário porque embora o valor resultante da inferência possa ser compreendido em linguagem natural ou mesmo facilmente interpretado em um gráfico, ele consiste evidentemente de um valor numérico. Sendo assim, as variáveis linguísticas produzidas pela inferência devem ser “defuzzificadas”.

Em outras palavras, o processo de defuzzificação “decifra” o significado de um resultado expresso de maneira vaga.

Existem várias maneiras de defuzzificar um sistema; WEBER (2003) descreve aqueles que seriam os seis métodos que se mostram práticos e efetivos; são eles:

- **COA** – Centre of Area, que retorna a informação do nível de confiança em função do centro da área da figura geométrica;
- **COG** – Centre of Gravity, que utiliza o centro de massa da figura (CG);

- **HD** – Height Defuzzification, que considera apenas a média das alturas das figuras que compõem o plano;
- **COLA** – Centre of Largest Area, que considera apenas a figura de maior área e o seu centro geométrico;
- **MOM** – Mean of Maxima, que utiliza a heurísticas de escolher o ponto mais alto no plano, independente das áreas das figuras, como o resultado mais plausível;
- **COM** – Centre of Maximum, que busca um ponto de equilíbrio entre os pontos de máximo de cada figura inscrita no plano.

Para escolher o mecanismo mais adequado, foi considerado que as áreas das figuras que compõem o gráfico seriam incluídas no cálculo, assim como as alturas; isso porque a área está vinculada à distribuição da cor sobre a manga, e a altura representa a relevância da cor para a maturidade; assim, foi empregado o mecanismo COG.


O gráfico a ser defuzzificado é formado a partir dos planos  $\mu(\lambda_{cor}, M)$ , aplicando sobre eles a função  $MAX(\mu[\lambda, m])$  do algoritmo Mamdani. Para facilitar o cálculo dos centros de massa, o eixo das abcissas (M) é inicialmente deslocado, tornando o seu ponto médio o eixo das ordenadas; ou seja, a base da figura fica centrada sobre o ponto (0,0). Além disso, o eixo das ordenadas é redimensionado valores percentuais [0-100] ao invés de [0-1], para coincidir com o intervalo de maturidade.

O Centro de Gravidade (CG) do gráfico é aquele pelo qual passa a resultante das forças de gravidade que atuam em cada elemento de sua massa. Na física, é o ponto de equilíbrio do corpo, como se toda sua massa estivesse concentrada naquele ponto. O CG pode ser entendido ainda como um ponto sobre o qual é nulo o somatório dos momentos dos pesos das partículas que constituem o sólido (ou sistema).

Considerando uma região plana, as funções fuzzy podem ser divididas em subgráficos mais simples, como triângulos e retângulos. Assim, torna-se mais fácil calcular o centro de gravidade (CG) do sistema, encontrando os CGs das figuras que o compõem. O algoritmo para o cálculo do centro de gravidade pode ser descrito da seguinte forma:

1. Inicialmente, divide-se o sistema gráfico composto em elementos cujas geometrias permitam que os cálculos locais dos centros de gravidade dos mesmos sejam obtidos através de equações conhecidas, como as da Figura 3.1-25.
2. Escolhe-se um sistema de referências para descrever as coordenadas daqueles elementos. É importante lembrar que os pesos daqueles elementos são conhecidos.

3. Multiplica-se seus pesos por suas respectivas coordenadas (x,y) em relação ao referencial gráfico escolhido anteriormente;
4. Soma-se os resultados obtidos da multiplicação anterior;
5. Soma-se os pesos dos elementos que compõem o sistema (ou corpo);
6. Divide-se valor obtido no passo 3 pelo valor obtido no passo 4 e obtém-se a coordenada do Centro de Gravidade do sistema em questão.
7. O valor resultante é o centro de massa da figura e representa o valor numérico representado pela variável fuzzy.



**Figura 3.1-25:** Centros de gravidades de superfícies planas retangulares e triangulares. Fonte: Produção do Autor.

## 3.2. Métodos de análise pela forma

### 3.2.1. Método de estimação de propriedades físicas

A manga da variedade *Tommy Atkins* (seção 2.1) produzida no Brasil é um dos mais importantes itens de exportação do país para o mercado mundial de frutas frescas onde a Europa aparece como o seu principal cliente. Apesar da pouca expressão da manga no mercado internacional de frutas e da existência de fatores limitantes ao comércio, o país vem apresentando uma taxa de crescimento médio anual das exportações desse produto duas vezes maior que a média mundial (CORREIA e ARAÚJO, 2010). Dentre os fatores limitantes, aquele que representa um dos principais gargalos para exportação da manga é o processo de seleção e classificação dessa fruta dentro de critérios estabelecidos por padrões internacionais. Isso está associado, em grande parte, à falta de tecnologias apropriadas (seção 2.1), aliada às enormes dificuldades operacionais que demandam muita mão de obra.

Os processos de seleção e classificação incluem processos quantitativos (como as estimativas de massa e volume) e qualitativos (como a análise de forma e de cores). Esses processos merecem atenção especial, pois categorizam os frutos dentro dos padrões exigidos pelo mercado (seção 2.1.4). O produtor brasileiro de frutas está se esforçando para se adequar às exigências de qualidade impostas pelo mercado internacional.

A busca por métodos não destrutivos para a estimação de propriedades físicas de produtos agrícolas é de grande interesse da comunidade científica internacional, já que a automação desses processos agrega valor econômico, melhora a qualidade e reduz custos com mão de obra (RENGANATHAN e SUDHAKARA, 2002).

A uniformidade do aspecto da manga (forma), assim como da sua massa, são atributos obrigatórios para a exportação, não apenas por facilitar o manuseio e transporte, mas sobretudo para satisfazer as preferências do consumidor (SPREER, 2011).

Neste trabalho é desenvolvido um método para estimação da massa e do volume da manga *Tommy Atkins*, através de um método não invasivo, empregando análise de imagens (seção 2.2.9) e aprendizagem de máquina (seção 2.3.5), para permitir uma interface mais amigável para o procedimento de configuração do sistema.

Outra abordagem desse método permite a identificação da forma da manga, além da identificação da orientação do fruto em relação do pedúnculo, que possibilita sua utilização por um sistema automático para embalagem.

Um sistema de hardware e software para efetuar a mensuração das frutas em esteiras transportadoras sem intervenção humana pode ser construído a partir dos métodos apresentados neste trabalho.

Para estimar a massa e o volume da manga, torna-se inicialmente necessário, adotar um modelo geométrico aproximado:

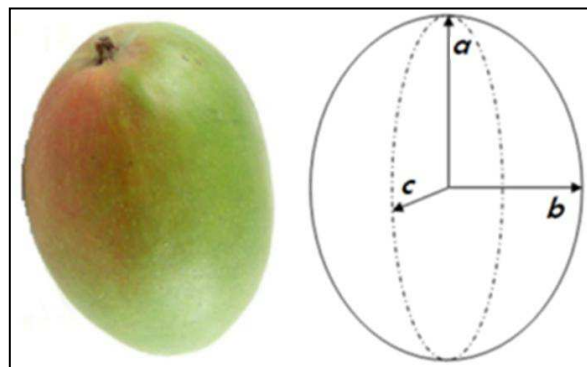
### **3.2.1.1. Forma aproximada da manga**

O conceito de eixos de frutas e sementes pode ser encontrado em MOHSENIN (1978). Sempre que existe uma figura geométrica conhecida, que se assemelhe à forma de um fruto ou semente, os valores aproximados de volume, área e outras informações podem ser calculados, desde que os comprimentos dos eixos sejam fornecidos. No caso da manga, por exemplo, tres eixos são considerados:

- O **eixo maior** ou **principal**; relativo ao comprimento da fruta;

- O **eixo intermediário** ou **secundário**, transversal ao principal, relativo à largura da fruta;
- O **eixo menor** ou **terciário**, perpendicular ao principal e ao transversal, relativo à profundidade da fruta.

No caso da manga *Tommy Atkins*, a forma geométrica da qual ela mais se aproxima é a “Esferóide Prolato”, que pode ser definida como uma superfície de revolução obtida pela rotação de uma elipse em torno do seu eixo maior. Essa figura geométrica caracteriza-se por ter o seu eixo polar maior do que o eixo equatorial ( $a > b$  e  $a > c$ ), com os eixos  $b$  e  $c$  de mesmo tamanho (Figura 3.2-1).



**Figura 3.2-1:** Forma aproximada da manga *Tommy Atkins*: Esferóide Prolato. Fonte: Montagem do autor.

Não é difícil, na prática, observar que há uma diferença entre o modelo geométrico e a forma real da fruta. Para realizar esse trabalho, torna-se necessário obter dados precisos, analisando imagens das mangas, a fim de estimar os valores dos eixos e criar um modelo mais próximo da realidade possível.

Os parâmetros de interesse relacionados com o modelo na Figura 3.2-1 são:

- **Eixo Primário** (ou máximo) =  $a$  (neste trabalho, o eixo principal será denotado  $p$ ).
- **Eixo Secundário** (ou mínimo) =  $b$  ou  $c$  (neste trabalho, esses eixos serão denotados  $a$  e  $b$ , respectivamente).
- **Volume**, que é obtido pela fórmula da Equação 3.2-1:

$$V = \frac{4}{3}\pi b^2 a. \quad (\text{Eq. 3.2-1})$$



### 3.2.1.2. Descrição do método

O método proposto combina duas tecnologias: um **sistema analisador de imagem** (seção 2.2.9) e um **sistema de aprendizagem de máquina** (seção 2.3.5); isso para permitir uma maneira fácil e prática de configuração e atualização das informações no classificador, onde exemplos positivos de "manga pertencente à classe X" e exemplos negativos da classe "manga não pertencente à classe X" são aprendidos.

O sistema de análise de imagens deve ser capaz de extrair informações como os diâmetros principal, secundário e terciário das frutas.

A Figura 3.2-2 apresenta o Fluxograma funcional do método desenvolvido; inicialmente, uma imagem é carregada a partir de um arquivo PNG (seção 2.2.7); logo em seguida, é realizado o processo de detecção das bordas da fruta na imagem, onde os pontos encontrados são armazenados em um vetor. Observa-se que apenas a componente que identifica a o matiz (H) é considerada.

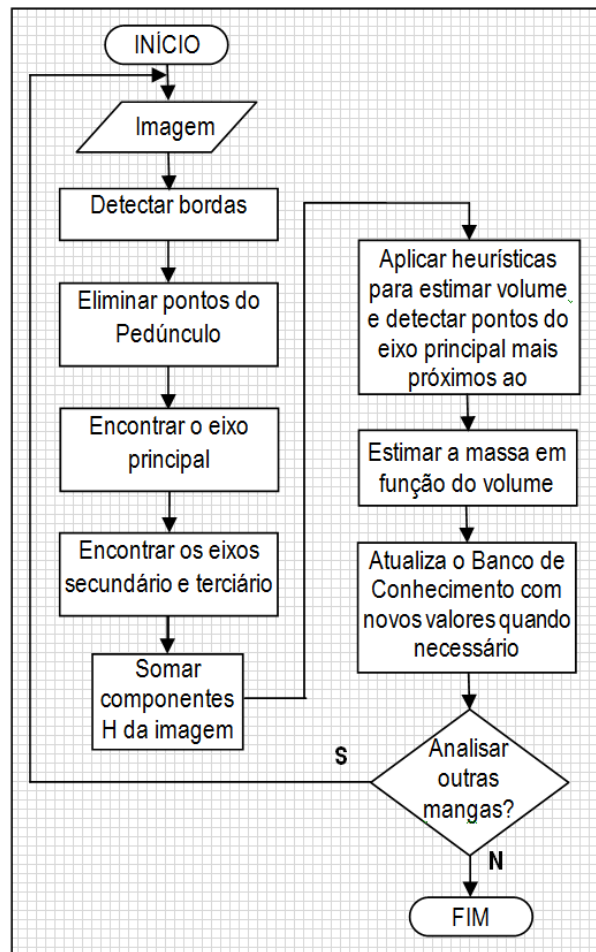


Figura 3.2-2: Fluxograma funcional do método. Fonte: Produção do autor

O passo seguinte é suavizar as curvas definidas pelos pontos no vetor, com o objetivo de excluir o pedúnculo dos pontos que formam o perímetro da fruta na imagem, substituindo essas coordenadas por valores nulos. Em seguida, os eixos principal, secundário e terciário são calculados por fórmulas matemáticas aplicadas sobre o vetor de pontos; finalmente, algumas heurísticas são aplicadas para estimar as propriedades físicas do fruto (seção 2.1.4).

Cada vez que uma nova imagem é apresentada ao sistema, o módulo de aprendizagem de máquina é acionado para representá-la (aprender suas características), podendo adicionar essa nova informação à base de conhecimento, caso esteja no modo incremental de aprendizagem. O processo se repete até que não exista mais nenhuma manga a ser processada.

### **3.2.1.2.1. Processamento e análise de imagens**

Uma câmera digital média resolução (5Mpixels) foi utilizada para capturar as imagens da manga; para esse procedimento, a fruta deve estar na sua posição de repouso natural, a uma distância focal fixa, sobre um fundo azul opaco em condições de iluminação bem estabelecidas. Esse ambiente reduz uma grande quantidade de pré-processamento. Nesse caso, o equipamento especificado na seção (3.1.) foi utilizado.

Um algoritmo de detecção de bordas foi desenvolvido para obter a linha perimetral da manga; como a cor azul normalmente não ocorre nessa fruta, torna-se mais fácil detectar as suas fronteiras, bastando para isso, a identificação de qualquer ponto com o matiz diferente.

A representação consiste em armazenar o conjunto resultante dessa segmentação em um formato adequado, mantendo a integridade da informação de interesse.

### **3.2.1.2.2. Resolução da imagem para a análise da manga**

A resolução específica suficiente para a análise da imagem é uma função da informação que deve ser extraída para a estimação das dimensões do fruto; por esse motivo, torna-se necessário definir inicialmente o tamanho da área mínima de interesse.

Se o objetivo é medir os eixos de uma manga, uma área quadrada definida com arestas de 1mm deve ser suficiente, especialmente para a cultivar *Tommy Atkins*, que tem grandes dimensões; qualquer detalhe inscrito numa área de tamanho menor que essa pode ser considerado negligenciável.

### **3.2.1.2.3. Área de interesse e região interpretável**

Um conceito importante no processamento de imagem é a área (ou região) de interesse, que é definida como a região em que o problema a resolver reside, e consequentemente, onde

o processamento estará concentrado. Áreas de interesse são em geral, limitadas por pontos, cuja determinação é uma tarefa essencial para a definição, especificação e tratamento do problema.

Para analisar uma imagem digital, é necessário conhecer a sua resolução. Geralmente, considera-se que a maior resolução disponível é sempre a melhor aplicável, mas no caso de análise de imagem por sistemas de visão computacional, isso nem sempre é verdade, uma vez que:

- A resolução da imagem (seção 2.2.6) é diretamente proporcional ao custo do espaço (memória) e tempo (transformação).
- Resolução deve ser suficiente para capturar as características do objeto de forma a atender a percepção do analista; uma resolução muito baixa provoca distorções no objeto capturado, o que poderia levar a interpretações equivocadas.
- Do ponto de vista deste trabalho, o aumento da resolução de uma imagem além de um certo ponto, não produz qualquer ganho de informação, mas certamente, induz alguns custos adicionais para seu manuseio.

Com o objetivo de ajustar a diferença entre as resoluções de imagens digitais e a capacidade de percepção humana associada à especificidade do problema, pode ser definido o conceito de "região interpretável" como uma área minimamente suficiente para representar um acontecimento detectável na imagem.

Uma imagem de 12 x 8 polegadas capturada por uma câmara digital de 5Mpixels tem 5242880 pontos distribuídos em uma área de 96 polegadas quadradas, a resolução aproximada chega a 54.613 pontos por polegada quadrada, ou seja, uma região interpretável de 1 mm<sup>2</sup> nessa resolução, representa uma matriz de aproximadamente 233 pixels, o que corresponde a uma enorme redução da quantidade de pontos a analisar. Assim, câmaras de maior ou menor resolução podem ser utilizadas.

O primeiro passo para realizar a análise de uma imagem, é reduzir a sua resolução até atingir a da região interpretável; isso implica numa grande redução do conjunto de pontos que forma a imagem; no caso descrito acima, essa redução é da ordem de aproximadamente 233 para 1.


Em resumo, a construção de uma região interpretável de 1mm<sup>2</sup>, realizada a partir de operações aritméticas básicas sobre apenas cinco pontos discretos, reduz substancialmente o

número de operações necessárias e computacionalmente custosas, como é o caso do procedimento de segmentação da imagem para a detecção de bordas do objeto de análise.

Um dispositivo de configuração permite a edição do valor da resolução, que ser alterado pelo usuário sempre que se faça necessário. Assim, torna-se possível redefinir a dimensão dessa matriz conforme a conveniência do usuário, lembrando que quanto menor sua área, maior será o *throughput* do sistema.

#### 3.2.1.2.4. A detecção de bordas por descontinuidade da cor

O modelo de cor utilizado no método é o HSL, e o seu componente H, que corresponde ao matiz, que nos dá a percepção da cor, é o único parâmetro de interesse neste trabalho. Assim, para eliminar *throughput* desnecessário, e como o valor das componentes S e L são descartados, apenas o histograma da componente H será utilizado.



**Figura 3.2-3:** Pontos de definição da região Interpretável. Fonte: Produção do autor

Uma área de  $1\text{mm}^2$  de uma imagem com uma resolução de 5Mbytes possui aproximadamente 233 pixels. Considerando o pixel central e os pixels colocados nos vértices dessa matriz, como mostra a Figura 3.2-3, foi desenvolvido um programa de computador para representar imagens utilizando essa estrutura reduzida como a unidade de digitalização.

Deve ser notada neste ponto a diferença entre o procedimento de reduzir a resolução de uma imagem, que equivale a diminuir o número de pixels que a representa, com conseqüente perda de qualidade advinda da redução da nitidez de detalhes, porém mantendo a equivalência do aspecto visual, por critérios de proporcionalidade. No modelo de representação proposto neste trabalho, existe uma redução do número de elementos que compõe a imagem, pela identificação semântica de áreas de pequenas dimensões, onde um único ponto torna-se o

representante de uma região, em função de algumas heurísticas. Esses pontos são agrupados em conjuntos segundo sua classe.

Para a identificação dos pontos que representam regiões de interesse, a matriz da imagem é iterativamente varrida para a construção da representação reduzida. Em cada interação, os pontos que definem uma região interpretável são extraídos da matriz da imagem e analisados; o componente matiz (H) de cada um desses pontos são usados para determinar a característica da região da imagem sob análise, retornando três possíveis valores, obtidos através das regras heurísticas definidas a seguir, que empregam a função computacional H(coordenada do ponto), que retorna o valor do matiz de um ponto qualquer da imagem.

Uma vez definido o tamanho da aresta da região interpretável, a imagem é varrida inteiramente, a partir do ponto inicial (linha = 1, coluna = 1), para calcular o valor dos vértices e do ponto central (pontos *a*, *b*, *c*, *d*, *e*). Assim, tem-se:

$$a = (\text{linha}, \text{coluna});$$

$$b = (\text{linha}, \text{coluna} + \text{aresta});$$

$$c = (\text{linha} + \text{aresta}, \text{coluna} + \text{aresta});$$

$$d = (\text{linha} + \text{aresta}, \text{coluna});$$

$$e = ((\text{linha} + \text{aresta})/2, (\text{coluna} + \text{aresta})/2);$$

A cada conjunto de pontos encontrados, a seguinte função lógica é avaliada, onde apenas o ponto central (*e*) é armazenado em um dos conjuntos, através da função **F** (Consequente).

$$SE (H(e) <> azul) E (H(a) = azul OU H(b) = azul OU H(c) = azul OU H(d) = azul) F BORDER$$

$$SE (H(a) <> azul E H(b) <> azul E H(c) <> azul E H(d) <> azul) F INNER$$

$$SE (H(a) = azul E H(b) = azul E H(c) = azul E H(d) = azul) F BACKGROUND$$

Assim, após digitalizar uma região interpretável, um dos seguintes vetores é atualizado:

$$a\_border [s, (l, c)]; \quad (\text{Vetor que armazena os pontos do perímetro da manga})$$

$$a\_inner [s, (l, c)], \text{ ou} \quad (\text{Vetor que armazena os pontos do interior da manga})$$

$$a\_background [s, (l, c)]. \quad (\text{Vetor que armazena o plano de fundo da imagem})$$

Onde *s* é o índice do vetor e (*l*, *c*) são as coordenadas do ponto central. As seguintes relações entre esses conjuntos ou vetores são obtidas quando uma imagem é totalmente digitalizada:

$$BORDER \subset INNER \leftrightarrow a\_border [] \subset a\_inner [].$$

$$INNER \not\subset BORDER \leftrightarrow a\_inner[] \not\subset a\_border[].$$

$$BACKGROUND \cap BORDER \cap INNER = \emptyset \leftrightarrow a\_border[] \cap a\_inner[] \cap a\_background[] = \emptyset.$$

Sempre que os pontos que representam o pedúnculo aparecem no conjunto *BORDER*, eles devem ser excluídos, ou haverá risco do cálculo do eixo principal incluir um ponto pertencente ao pedúnculo, induzindo um erro que pode ser grave. Um algoritmo computacional para tratar desse problema de forma adequada foi desenvolvido:

Inicialmente, o conjunto *BORDER* é dividido em dois sub-conjuntos, B1 e B2, definidos da seguinte maneira:

$$\forall p(x_i, y_i) \in BORDER \exists p(x_i, y_j) \mid y_j \leq y_i \vdash p(x_i, y_i) \in B1;$$

$$\forall p(x_i, y_i) \in BORDER \exists p(x_i, y_j) \mid y_j > y_i \vdash p(x_i, y_i) \in B2;$$

Ou seja, para um valor de  $x_i$  no eixo das abcissas, poderá existir até dois valores  $y_i$  e  $y_j$  no eixo das ordenadas, com  $j \neq i$ , de maneira que os pontos  $(x_i, y_i)$  e  $(x_i, y_j)$  pertencerão a B1 e B2, se  $y_j \leq y_i$  e  $y_j > y_i$ , respectivamente. Assim, B1 e B2 armazenarão os pontos superiores e inferiores do perímetro da manga, mantendo a contiguidade dos pontos adjacentes.

O passo seguinte é o de dividir B1 em  $n$  segmentos com o mesmo comprimento  $l$ , *SEGL*, cada um deles constituídos por uma série de pontos de tamanho determinado  $n$ , dado pela Equação (3.2-2).

$$n = \frac{Dim(B1)}{l} \quad (\text{Eq. 3.2-2})$$

*Dim(B1)* é o número de pontos no conjunto B1, e  $l$  é um parâmetro de entrada, fornecido pelo usuário, que não pode ser menor do que o diâmetro máximo do pedúnculo (em milímetros).

Se houverem pontos remanescentes, ou seja, o conjunto B1 não é múltiplo de  $l$ , então um novo segmento *SEGL*[ $n+1$ ] é criado com esses pontos, e é completado pela inclusão dos últimos pontos do segmento anterior *SEGL*[ $n$ ]. A repetição de pontos do segmento anterior não altera o resultado da avaliação, o único problema é que esses pontos serão analisados duas vezes.

Para cada elemento na matriz *SEGL*:

$a$  - o primeiro ponto no segmento  $\overline{AB}$ ;

$b$  - o último ponto no segmento  $\overline{AB}$ ;

$m$  - um ponto em  $\overline{AB}$ ;  $m \in SEG1$ ,  $m \neq a$ ,  $m \neq b$ .

Calcular:

$$d = \text{MAX}[\delta_{am} + \delta_{mb} - \delta_{ab}], \tag{Eq. 3.2-3}$$

onde:

$\delta_{ab}$  = distância entre os pontos  $a$  e  $b$ ;

$\delta_{am}$  = distância entre os pontos  $a$  e  $m$ ;

$\delta_{mb}$  = distância entre os pontos  $m$  e  $b$ .

$d$  que é obtido pela Equação (3.2-3), traz a informação sobre a possibilidade do segmento  $\overline{AB}$  conter uma quina (ou canto); quanto mais alto o valor de  $d$ , maior a chance do segmento conter uma quina.




Figura 3.2-4: Detecção de quinas em um segmento. Fonte: Produção do autor

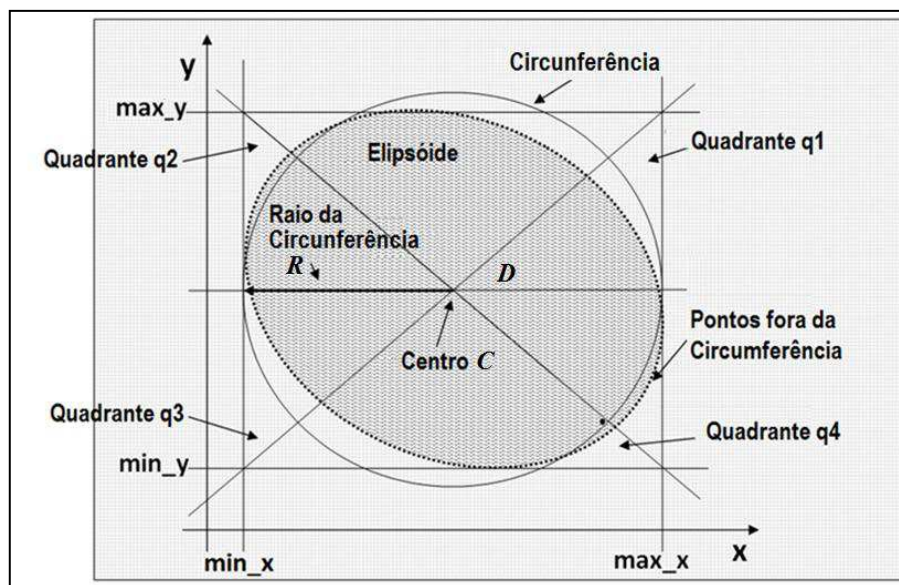
É possível detectar os segmentos portadores de quinas em  $SEG1$ , através dos seguintes passos:

- Encontrar elementos  $SEG1$ , onde  $d \geq l/4$ ; marcado os mesmos como portadores de quinas. Este filtro segrega todos os segmentos que contêm pelo menos um ponto fora da curva esperada para um segmento  $SEG1$ , como mostra a (Figura 3.2-4).
- Todo o procedimento para encontrar os segmentos portadores de quinas em  $B1$ , devem ser realizados sobre  $B2$ .
- Uma vez que foram identificados segmentos os portadores de quinas, seus pontos devem ser excluídos de  $\{B1 \cap B2\}$ .
- Testes de execução indicam que este método não é preciso se o pedúnculo for mais longo que  $2 * l$ . Por isso, o pedúnculo não deve ultrapassar 2 cm de comprimento.

### 3.2.1.2.5. Estimação da distância máxima entre pontos de uma elipsóide

Para calcular a distância máxima entre dois pontos do conjunto BORDER, foi desenvolvido um algoritmo que leva em conta a especificidade da forma elipsóide, definida pelos pontos desse conjunto.

Assim, o algoritmo se presta a encontrar o eixo principal de figuras geométricas onde os eixos principal e secundários possuem comprimentos diferentes; ele explora a busca qualificada sobre os pontos que se encontram na região da superfície (conjunto BORDER), nas extremidades do eixo principal da figura geométrica.



**Figura 3.2-5:** Conjunto BORDER inscrito em um Retângulo. Fonte: Produção do autor

O procedimento é iniciado com a varredura sobre os pontos do conjunto BORDER para encontrar os valores de máximo e de mínimo em relação aos eixos X, Y; ou seja, as coordenadas cujos valores são os mais próximos ou mais distantes do eixo das abscissas e do eixo das ordenadas do plano cartesiano representado pela matriz de pontos do conjunto. Evidentemente, pode existir mais que um ponto de máximo ou de mínimo com mesmo valor. Esses pontos definem uma região retangular cujas linhas são paralelas aos eixos Cartesianos, onde todos os pontos do conjunto BORDER residem em seu interior.

O ponto central é definido com facilidade pelo cálculo do valor médio dos pontos de máximo e de mínimo, assim como o maior segmento deste retângulo  $D$ , que é paralelo a um dos eixos e ortogonal ao outro. Considerando o ponto central encontrado, é traçada uma circunferência cujo raio  $R$ , que é a metade do segmento  $D$ ; Dependendo da distribuição dos



pontos dentro do retângulo, alguns deles podem aparecer fora da borda da circunferência (Figura 3.2-5).

Todos os pontos dentro do círculo devem ser descartados para o cálculo do eixo principal, uma vez que pelo menos dois pontos de distância máxima (PDM) entre o perímetro do círculo e a linha do retângulo existem. Isto é feito simplesmente pela filtragem de todos os pontos cuja distância ao centro da circunferência é menor que  $R$ . Assim, os PDMs estarão localizados na região entre as bordas do perímetro da circunferência e da linha do retângulo. Esse método está representado no Fluxograma funcional da Figura 3.2-6.

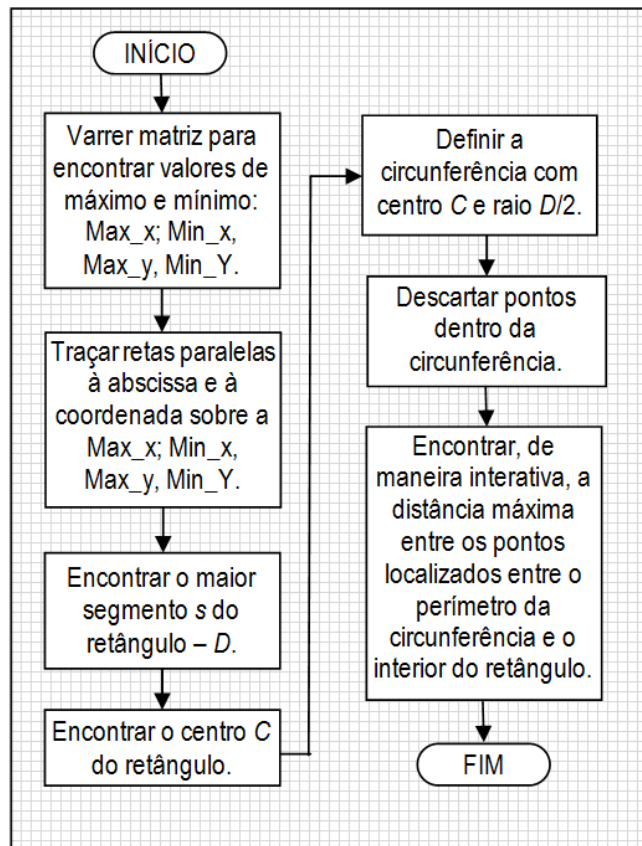


Figura 3.2-6: Fluxograma funcional para encontrar o eixo principal. Fonte: Produção do autor

De modo a melhorar a eficiência do algoritmo, a seguinte heurística é aplicada:

Seja o conjunto de quadrantes  $\{q1, q2, q3, q4\}$ ; um ponto  $p$  num quadrante tem a função de pertinência definida por:

$$p \in q1 \Leftrightarrow x \geq 0, y \geq 0;$$

$$p \in q3 \Leftrightarrow x \leq 0, y \leq 0;$$

$$p \in q2 \Leftrightarrow x \geq 0, y \leq 0;$$

$$p \in q4 \Leftrightarrow x \leq 0, y \geq 0.$$

A estratégia é pesquisar iterativamente os PDMs inicialmente entre quadrantes opostos, já que os pontos de quadrantes adjacentes não pertencerão ambos ao eixo principal.

No caso, os quadrantes a serem inicialmente analisados seriam:  $q1 \succ q3$  e  $q2 \succ q4$ <sup>20</sup>.

A eficiência máxima do algoritmo será notada quando eventualmente, o eixo principal da manga estiver alinhado paralelamente ao eixo X ou ao eixo Y. Em uma esteira com forma em "V", objetos oblongos como a manga tendem a assumir esta posição. Por isso, esse método torna-se bastante interessante para esse trabalho, pois a intenção é analisar a fruta pré-orientada, repousando sobre seu eixo principal por artifícios mecânicos, o que sugere o desenvolvimento do protótipo de um sistema de automação baseado neste método.

Um programa de computador foi implementado para extrair os pontos pertencentes ao contorno da imagem, considerando cada ponto segundo o conceito de "Região Interpretável".

Uma vez que os PDMs são encontrados, o eixo principal é determinado e o próximo passo é o de encontrar os eixos secundário e terciário da seguinte forma:

- Encontra-se a equação da reta para o eixo principal, na forma  $(y = ax + b)$ ;
- Divide-se o conjunto BORDER conjunto em dois grupos: *UPPER* (pontos acima ou à esquerda do eixo principal) e *LOWER* (pontos abaixo ou à direita do eixo principal). A relação que define esses conjuntos é bastante simples: um ponto  $p(x, y)$  está acima da reta  $y = ax + b$ , se tiver coordenadas satisfazendo a desigualdade  $y > ax + b$ , e abaixo da linha se  $y < ax + b$ .
- Encontra-se o ponto PDML de distância máxima do eixo principal para os conjuntos laterais (superior e inferior) B1 e B2, utilizando a equação de distância do ponto para a reta.
- Dado um PDML em *UPPER* (ou *LOWER*) com coordenadas  $(x_0, y_0)$ , o ponto mais próximo do eixo principal, com coordenadas  $(x_1, y_1)$ , é dado por:

$$x_1 = \frac{b(bx_0 - ay_0) - ac}{a^2 + b^2} \tag{Eq. 3.2-4}$$

$$y_1 = \frac{a(-bx_0 + ay_0) - bc}{a^2 + b^2} \tag{Eq. 3.2-5}$$

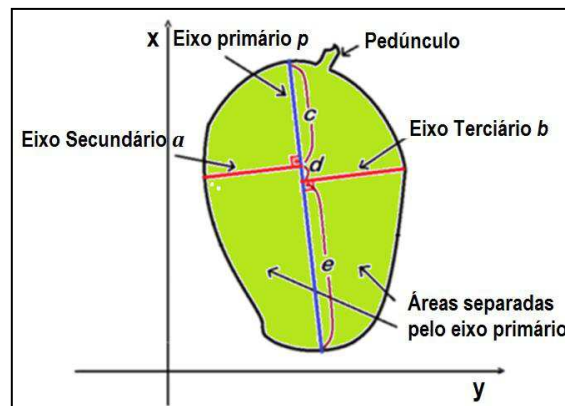
Os PDML encontrados em *UPPER* e *LOWER* são atribuídos às variáveis  $a$  (eixo secundário) e  $b$  (eixo terciário).

---

<sup>20</sup> O símbolo  $\succ$  entre os quadrantes indica que eles são opostos.

### 3.2.1.2.6. Análise geométrica da manga

As medições manuais dos eixos diâmetros da manga não são, como foi mostrado, simples e precisas; sua utilização na indústria torna-se inviável na prática, devido às limitações de tempo e precisão dessa operação.



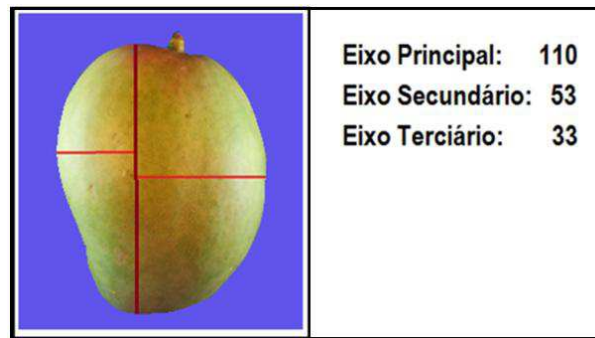
**Figura 3.2-7:** Eixo principal divide a manga em regiões geometricamente distintas. Fonte: Produção do autor.

A análise do formato geométrico da manga *Tommy Atkins*, permitiu o desenvolvimento de um novo método de medição automático, utilizando técnicas de processamento de imagens que permitem a identificação de diferentes padrões geométricos, proporcionando melhor estimativa de volume e massa. É possível também inferir outras informações relevantes, como a posição do pedúnculo em relação ao eixo principal. Essa informação pode ser útil em processos de embalagem, para estabelecer o correto alinhamento da fruta nas caixas.

Ao analisar a geometria da manga na posição de repouso (Figura 3.2-7), é possível deduzir os seguintes fatos:

- O eixo maior  $p$  divide a manga em duas partes com aspectos geométricos distintos, e muito raramente, passa através do pedúnculo, mas por um dos ombros da fruta.
- O comprimento do pedúnculo deve ser desconsiderado na análise, por induzir erros drásticos na estimativa do volume.
- Os segmentos de reta secundários e terciários, muitas vezes possuem comprimentos diferentes, quase nunca são coincidentes sobre uma mesma linha.
- Os pontos onde os segmentos de reta secundário e terciário tocam o eixo principal dividem esse eixo em três novos segmentos de reta: um entre esses pontos ( $d$ ) e os outros dois, entre cada ponto e o perímetro da manga ( $c$  e  $e$ ).

- A disposição desses eixos permite estimar o formato da fruta; os eixos secundários e terciários encontram-se mais próximos da região dos ombros da manga e portanto, mais próximos ao pedúnculo, o que torna possível inferir sua posição relativa. A Figura 3.2-8 apresenta uma estimativa da medida desses eixos realizada pelo sistema. Pode ser facilmente deduzido que mesmo se a imagem analisada fosse a do lado inverso da manga, as medidas permaneceriam iguais, ainda que as variáveis que indicam os eixos secundários e terciários fossem trocadas.



**Figura 3.2-8:** Medições extraídas de um exemplar da mangas *Tommy Atkins*. Fonte: Produção do autor

A partir dessas observações, é possível estimar o volume de mangas considerando os três segmentos de reta: o eixo principal, o eixo secundário e o terciário. A idéia é calcular dois volumes, diferenciados pelos valores dos eixos secundário e terciário; em seguida, os respectivos resultados são unificados.

Considerando o fator entre o segmento de reta  $c$  da Figura 3.2-7;  $\theta = a / c$  é estimado em aproximadamente 0,9 para mangas *Tommy Atkins*, com base em testes experimentais realizados em laboratório. Assim, o volume pode ser calculado através de adaptações da fórmula de volume dada na Equação 3.2-6 :

$$V_{P1} = \frac{4}{3}\pi a^2 p \quad (\text{Eq. 3.2-6})$$

$$V_{P2} = \frac{4}{3}\pi * a * a\theta * p \quad (\text{Eq. 3.2-7})$$

$$V_{P3} = \frac{4}{3}\pi * a * ac_1 * p * \theta + \frac{4}{3}\pi * b * bc_2 * p * \theta \quad (\text{Eq. 3.2-8})$$

Sendo  $c_1 = a / (a+b)$ , e  $c_2 = b / (a + b)$  são os coeficientes de proporcionalidade para os eixos secundários e terciários. A fórmula original para o volume de um esferóide prolato é a

Equação 3.2-6; a Equação 3.2-7 leva  $\theta$  em conta, e finalmente, a fórmula da Equação 3.2-8, que é empregada neste trabalho, emprega os valores de  $\theta$ ,  $c1$  e  $c2$ , além dos raios  $a$  e  $b$  individualmente.

A massa dessa manga pode ser estimada de maneira muito precisa quando o volume é conhecido, pois a sua densidade, a relação volume/massa é muito próxima de 1, principalmente nos estágios iniciais de maturidade, onde o erro médio calculado em testes de laboratório é de aproximadamente 0,001%, como será mostrado mais adiante.

### **3.2.2. Método para estimação da orientação do pedúnculo**

A soma dos segmentos de reta  $c$  e  $c+d$  é sempre menor do que a soma dos segmentos  $e$  e  $e+d$ ; com esta observação, a posição do pedúnculo pode ser facilmente indicada em relação ao eixo principal, retornando coordenar o ponto final da extremidade principal mais próxima do pedúnculo.

### **3.2.3. Método inteligente de seleção de mangas pela forma**

#### **3.2.3.1. O processo de classificação**

A classificação no presente trabalho é simplesmente a associação de um objeto (instância) de uma categoria pré-definida (classe). Os objetos a serem classificados são mangas da variedade *Tommy Atkins* e as categorias são tantas quantas os dados permitam inferir. Esta tarefa é inteiramente definida pelo usuário.

O uso da abordagem da aprendizagem de máquina (ML) neste trabalho justifica-se pelas seguintes vantagens:

- A classe pode ser definida de acordo com as necessidades do usuário ou suas preferências;
- É muitas vezes mais precisa do que as regras baseadas em dados adicionadas por humanos;
- Uma vez que o sistema é treinado, a classificação é feita automaticamente, com pouca ou nenhuma intervenção humana.
- O processo de classificação é muito consistente.
- A tarefa de configuração do sistema torna-se extremamente facilitada.

Um dos principais problemas na classificação das mangas (ou qualquer outro objeto) é definir quais os elementos que devem ser considerados na análise; essa tarefa denomina-se

"definição do objeto de interesse". Um especialista é quase sempre solicitado para sugerir quais atributos ou características mais relevantes ou informativos para formar esse conjunto de dados. Não é uma tarefa fácil; a inserção de dados redundantes no conjunto de dados, certamente representará despesas de espaço/ tempo; por outro lado, a supressão de um único parâmetro pode tornar a tarefa de classificação impossível (ZHANG e PIERCE, 2013). A seleção de Instâncias nesses conjuntos de dados é de fato um problema de otimização, onde há uma tentativa minimizar o erro e o tamanho da amostra (MOTODA *et al.*, 2010). Os dados utilizados para classificar as mangas neste projeto são as medidas dos eixos obtidos pelo analisador de imagem das mangas. O conhecimento a ser aprendido é construído de forma iterativa a partir da associação de amostras de entrada e uma associação com a classe adequada. As decisões sobre os casos são feitas através de um conjunto de regras baseadas em heurísticas, inscritas em uma árvore de decisão.

### 3.2.3.2. Construção do sistema de aprendizagem de propriedades físicas

As Classes que devem ser identificadas são as principais informações do sistema; para definir uma classe, o usuário deve inicialmente associar um nome à mesma maneira a identificá-la univocamente; em seguida, deve selecionar conjuntos de amostras tanto para os casos positivos (dentro do padrão), quanto para os casos negativos (fora do padrão).

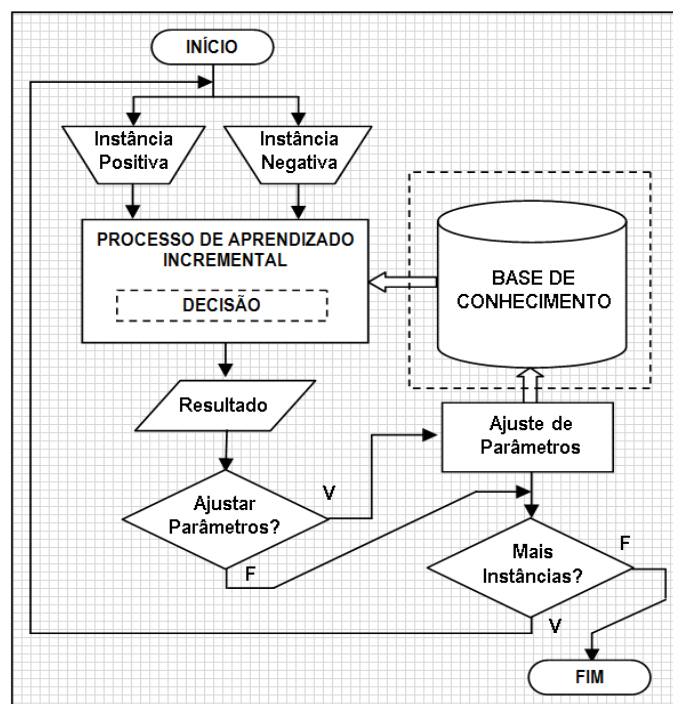


Figura 3.2-9: Fluxograma funcional do modo de TREINAMENTO. Fonte: Produção do autor

Deve ser observado que as amostras negativas não são imprescindíveis, mas aumentam sobremaneira a precisão do sistema.

Evidentemente, pode haver mais do que uma classe coexistente no sistema, desde que seus nomes e atributos sejam diferentes. O sistema é capaz de lidar com uma grande quantidade de classes, uma vez que suas definições podem ser definidas a partir das informações obtidas a partir do analisador de imagens.

Existem dois modos de operação: o *modo de treinamento* e o *modo de seleção* ou *uso*; os Fluxogramas operacionais são mostrados nas Figuras 3.2-9 e 3.2-10.

No modo de treinamento, os dados de cada amostra são adquiridos e inseridos na estrutura apresentada nos Quadros 3.2-1 e 3.2-2, juntamente com o nome de classe e a avaliação indicada para o tipo da amostra - o valor deve ser "positivo" ou "negativo".

Cada nova instância apresentada à máquina na forma de uma imagem é analisada pelo sistema de análise de imagem e os valores medidos são associados a um nome de classe. No caso da manga *Tommy Atkins*, uma entrada típica para uma amostra é apresentado na Tabela 3.2-1. O sistema recolhe esses dados e calcula os valores apresentados na Tabela 3.2-2, mantendo uma informação generalizada sobre os casos anteriores.

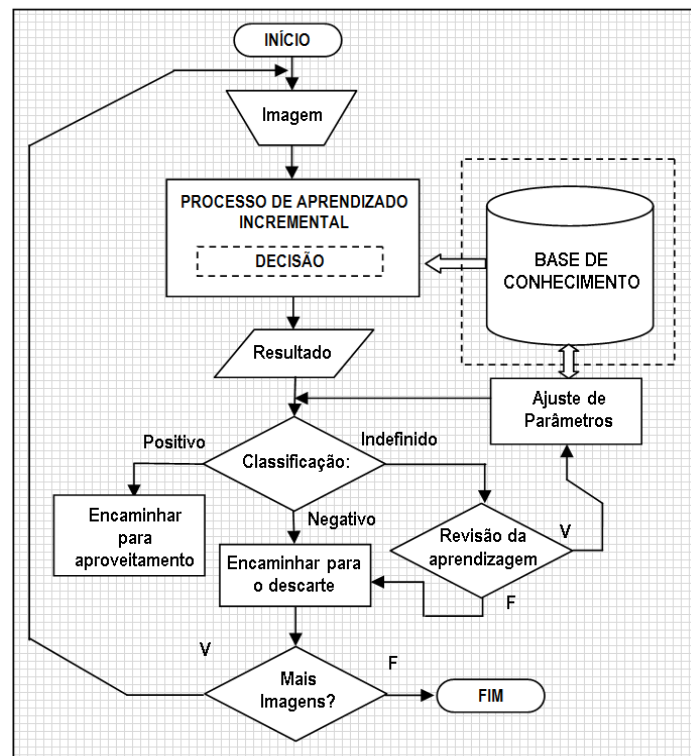


Figura 3.2-10: Fluxograma funcional do modo SELEÇÃO. Fonte: Produção do autor

Apesar de apenas uma pequena quantidade de informação ser adquirida de cada vez; um grupo maior de informações que são úteis para decidir sobre cada nova instância é criada, como mostrado nos Quadros 3.2-1 e 3.2-2; os valores de dados adquiridos a partir de cada nova imagem são atribuídos às variáveis das Tabelas 3.2-1 e 3.2-2, e mantidos no sistema para calcular todos os outros valores, vindo a serem descartados no final de cada análise.

**Quadro 3.2-1:** Dados da Base de Conhecimento para instâncias POSITIVAS

<b>Base de Conhecimento acumulado para instâncias POSITIVAS</b>	
<i>Class</i>	Classe associada aos valores
<i>Lpmin</i>	Comprimento Mínimo do Eixo Principal
<i>Lpmax</i>	Comprimento Máximo do Eixo Principal
<i>Lamin</i>	Comprimento Mínimo do Eixo Secundário
<i>Lamax</i>	Comprimento Máximo do Eixo Terciário
<i>Lcmin</i>	Comprimento Mínimo do Segmento <i>c</i>
<i>Lcmax</i>	Comprimento Máximo do Segmento <i>c</i>
<i>MinR(pa)</i>	Razão Mínima entre os eixos Principal e Secundário
<i>MaxR(pa)</i>	Razão Máxima entre os eixos Principal e Secundário
<i>MinR(pb)</i>	Razão Mínima entre os eixos Principal e Terciário
<i>MaxR(pb)</i>	Razão Máxima entre os eixos Principal e Terciário
<i>MinR(ab)</i>	Razão Mínima entre os eixos Secundário e Terciário
<i>MaxR(ab)</i>	Razão Máxima entre os eixos Secundário e Terciário
<i>ML(p)</i>	Comprimento Médio do Eixo Principal
<i>ML(a)</i>	Comprimento Médio do Eixo Secundário
<i>ML(b)</i>	Comprimento Médio do Eixo Terciário
<i>ML(c)</i>	Comprimento Médio do Segmento <i>c</i>
<i>ML(d)</i>	Comprimento Médio do Segmento <i>d</i>
<i>ML(e)</i>	Comprimento Médio do Segmento <i>e</i>
<i>SigL(p)</i>	Desvio Padrão do Eixo Principal
<i>SigL(a)</i>	Desvio Padrão do Eixo Secundário
<i>SigL(b)</i>	Desvio Padrão do Eixo Terciário
<i>SigL(c)</i>	Desvio Padrão do <i>c</i> Segmento
<i>SigL(d)</i>	Desvio Padrão do <i>d</i> Segmento
<i>SigL(e)</i>	Desvio Padrão do <i>e</i> Segmento

**Quadro 3.2-2:** Dados da Base de Conhecimento para instâncias NEGATIVAS.

<b>Base de Conhecimento acumulado para instâncias NEGATIVAS</b>	
<i>NClass</i>	Classe associada aos valores
<i>NLpmin</i>	Comprimento Mínimo do Eixo Principal
<i>NLpmax</i>	Comprimento Máximo do Eixo Principal
<i>NLamin</i>	Comprimento Mínimo do Eixo Secundário
<i>NLamax</i>	Comprimento Máximo do Eixo Terciário
<i>NLcmin</i>	Comprimento Mínimo do Segmento <i>c</i>
<i>NLcmax</i>	Comprimento Máximo do Segmento <i>c</i>
<i>NMinR(pa)</i>	Razão Mínima entre os eixos Principal e Secundário
<i>NMaxR(pa)</i>	Razão Máxima entre os eixos Principal e Secundário
<i>NMinR(pb)</i>	Razão Mínima entre os eixos Principal e Terciário



## Continuação

Quadro 3.2-2: Dados da Base de Conhecimento para instâncias NEGATIVAS.

$NMaxR(pb)$	Razão Máxima entre os eixos Principal e Terciário
$NMinR(ab)$	Razão Mínima entre os eixos Secundário e Terciário
$NMaxR(ab)$	Razão Máxima entre os eixos Secundário e Terciário
$NML(p)$	Comprimento Médio do Eixo Principal
$NML(a)$	Comprimento Médio do Eixo Secundário
$NML(b)$	Comprimento Médio do Eixo Terciário
$NML(c)$	Comprimento Médio do Segmento $c$
$NML(d)$	Comprimento Médio do Segmento $d$
$NML(e)$	Comprimento Médio do Segmento $e$
$NSigL(p)$	Desvio Padrão do Eixo Principal
$NSigL(a)$	Desvio Padrão do Eixo Secundário
$NSigL(b)$	Desvio Padrão do Eixo Terciário
$NSigL(c)$	Desvio Padrão do $c$ Segmento
$NSigL(d)$	Desvio Padrão do $d$ Segmento
$NSigL(e)$	Desvio Padrão do $e$ Segmento

Tabela 3.2-1 - Informações extraídas de cada instância.

Dados adquiridos a partir de cada instância								
Número de pontos no conjunto BORDER	Comprimento do eixo principal	Comprimento do eixo secundário	Comprimento do eixo terciário	Comprimento do segmento $c$	Comprimento do segmento $d$	Comprimento do segmento $e$	Nome da Classe atribuído à instância	Avaliação da Instância (positiva/negativa)
$Npb$	$L(p)$	$L(a)$	$L(b)$	$L(c)$	$L(d)$	$L(e)$	$Class$	$IEval$
564	12,3	5,9	3,6	5,1	0,9	6,3	Tommy	Positive

Tabela 3.2-2: Informações derivadas dos dados lidos das instâncias.

Dados calculados a partir da informação de entrada						
Número de casos apresentados até o momento	Razão entre os eixos primário e secundário	Razão entre os eixos primário e terciário	Razão entre os eixos secundário e terciário	Numero de amostras positivas apresentadas no treinamento	Numero de amostras negativas apresentadas no treinamento	Número de instâncias não identificadas → Retreinamento
$nInst$	$R(pa)\%$	$R(pb)\%$	$R(ab)\%$	$Npe$	$Nne$	$Nui$
1	48,78	28,45	58,33	1	0	0

### **3.2.3.3. Funcionamento do mecanismo de estimação de propriedades físicas**

Depois de alimentar o sistema com o conjunto de treinamento, este então é capaz de classificar outras instâncias utilizando o modo de seleção. Uma vez que uma nova manga é apresentada à entrada do sistema na forma de uma imagem, os dados da Tabela 3.2-1 são extraídos e registrados. Estes valores são então comparados com os dados generalizados apresentados na Tabela 3.2-2, que são compilados a partir de informações provenientes tanto do conjunto de treinamento, como do uso normal no modo de seleção. O sistema não mantém registros de todos os dados que recolhe, mas atualiza apenas informações estatísticas derivadas a partir desses dados, a fim de usar como filtro para a classificação sobre os novos casos que lhe são apresentados. Essa estrutura é chamada de Base de Conhecimento (KB) e é de fato um filtro, ou "objeto generalizante", que mantém uma representação intensional das classes que o sistema classifica.

A informação para a formação do objeto generalizante é aprendida pelo sistema no modo de treinamento; esse modo de operação produz as configurações do filtro que a máquina utilizará para classificar outros casos que serão apresentados no modo de operação normal (modo de seleção). Quanto maior o conjunto de treinamento, maior será o ajuste sobre o filtro do sistema.

### **3.2.3.4. Instâncias portadoras de ruído**

Quando uma instância que contém ruído é apresentada para a máquina no modo de seleção, será dificilmente selecionada como um exemplo positivo; nesse caso, o sistema ativa o filtro da amostra negativa, que pode selecioná-la como um "exemplo negativo" se for reconhecido como tal.

Podem existir casos em que uma imagem de entrada nem é reconhecida como exemplo positivo, nem como exemplo negativo. Para chegar a uma decisão, o sistema calcula a distância entre os dados de entrada da instância e os valores positivos e negativos da base de conhecimento (filtros). A entrada é então atribuída o valor do tipo mais próximo ao filtro. Dificilmente haverá um impasse, mas se as distâncias forem iguais, a decisão seguirá um viés pessimista, e a amostra será considerada negativa. Observe-se que em qualquer caso, a base de conhecimento absorverá a informação, utilizando-a para casos similares no futuro.

### **3.2.3.5. Mecanismo de decisão**

A decisão é baseada na avaliação lógica sobre os valores de entrada e do filtro de generalização; uma árvore de decisão parcial é mostrado na Figura 3.2-11, mostrando as

etapas de decisão para selecionar uma instância de entrada com valores "positivos" para uma classe chamada "Tommy".

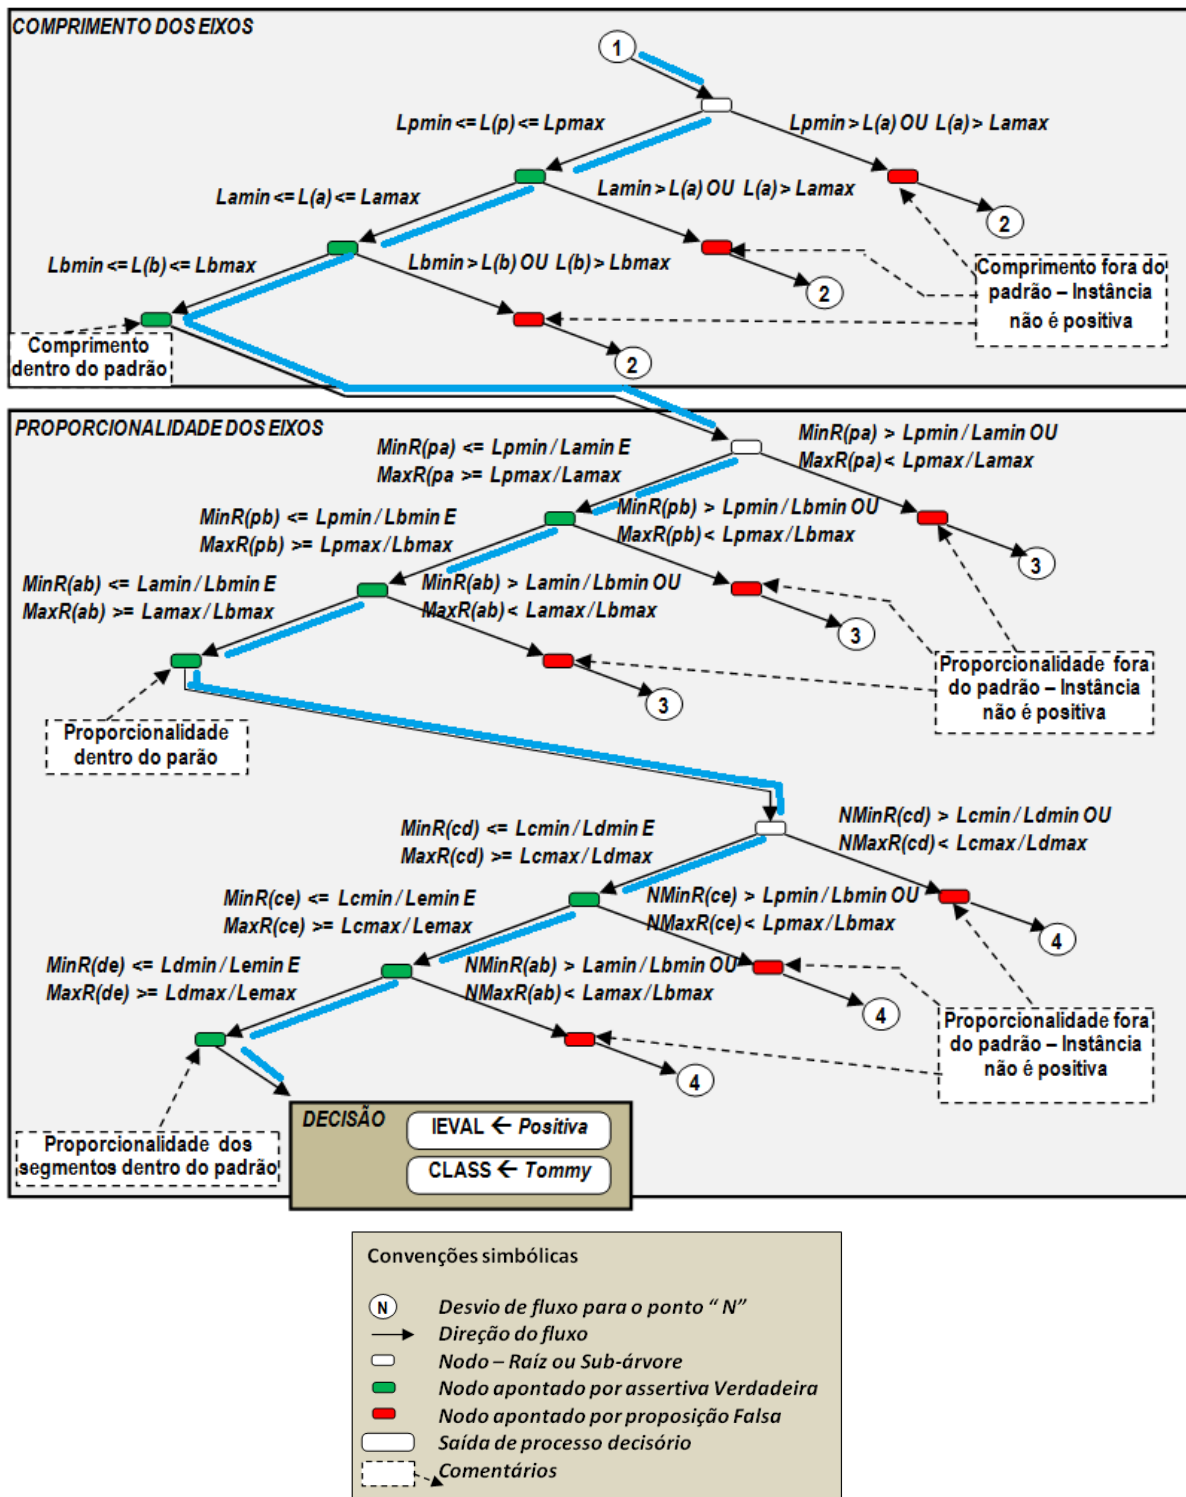


Figura 3.2-11: Ramificação da árvore de decisão para uma instância POSITIVA. Fonte: Produção do Autor.

Se qualquer um dos parâmetros de entrada do exemplo não se encaixa nos valores estabelecido pelo filtro de generalização, como no caso onde os nodos apontadores desviam o

fluxo para 2, 3 e 4, uma alteração no fluxo de decisão lógica é feita para um nó remoto adequado, onde a ocorrência é verificada se é ou não negativa (Figura 3.2-12).

Se todos os parâmetros estiverem dentro dos valores do filtro de classe generalizado, a instância é considerada positiva, e o nome associado à classe é herdado pela instância, ou seja, o objeto sob análise é associado pelo sistema a um exemplo positivo.

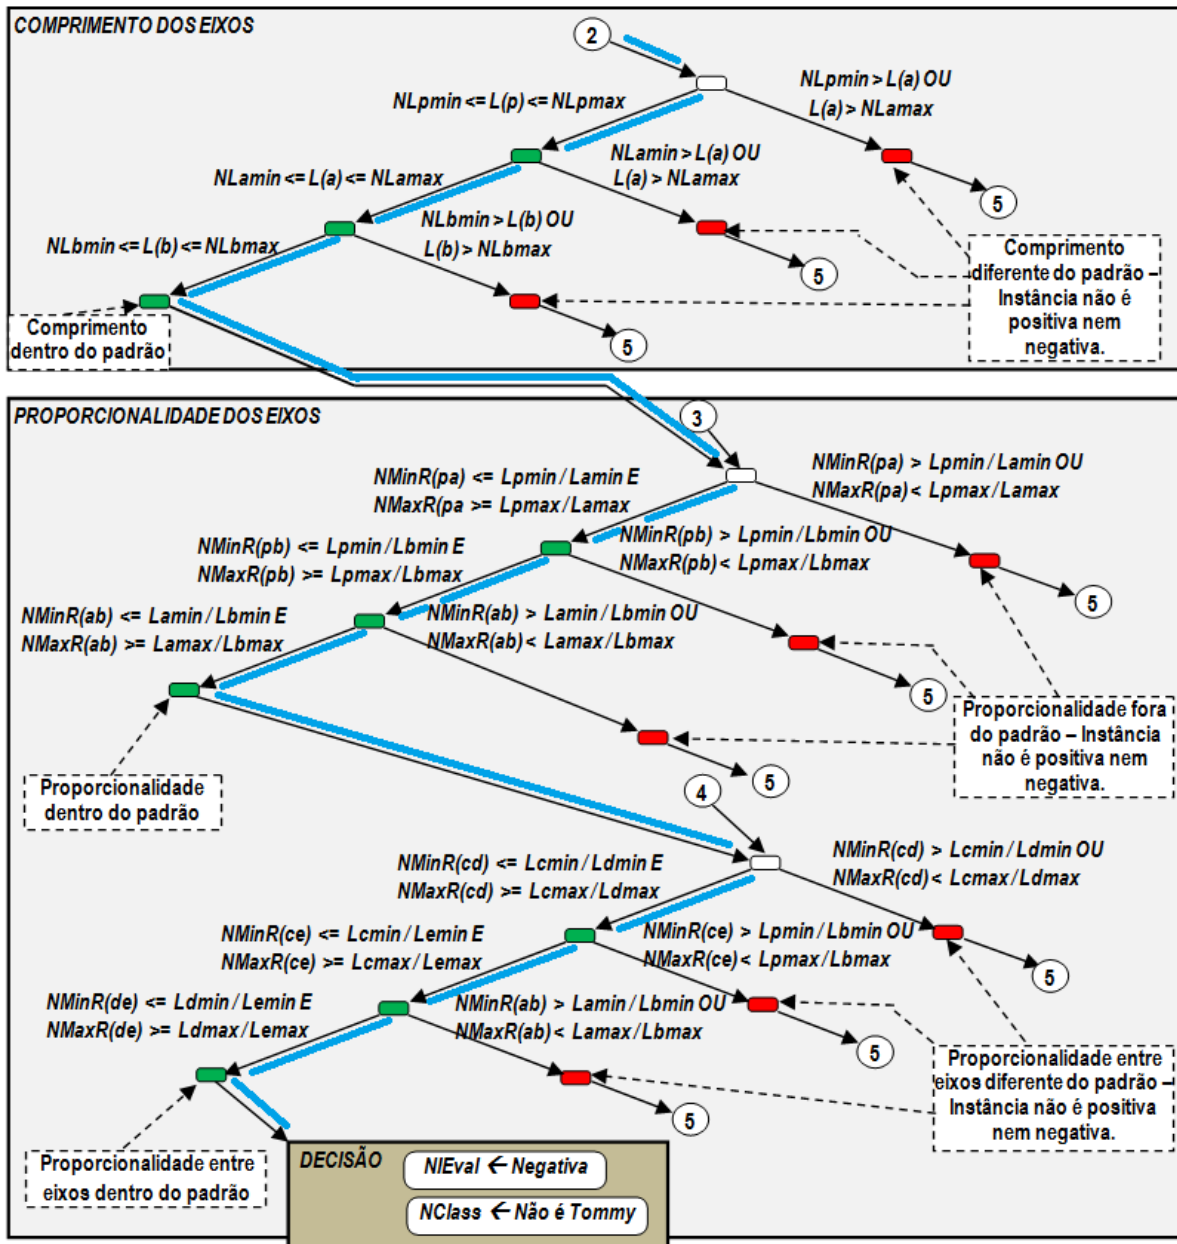


Figura 3.2-12: Ramificação da árvore com decisão para uma instância NEGATIVA. Fonte: Produção do Autor.

Quando o sistema de análise deve avaliar um exemplo negativo; todos os parâmetros devem atender aos valores de filtro de classe negativa generalizado para que o exemplo seja considerado negativo.

Se apenas uma parte dos filtros não indicarem que os valores da instância são de um exemplo positivo, a instância não poderá ser classificada como negativa e descartada de imediato.

Assim, pode haver casos em que a instância não é imediatamente classificada como positiva, nem como negativa. Em muitos sistemas de aprendizagem isso ocorre frequentemente, principalmente em universos de análise não lineares, caóticos ou nebulosos. Nem sempre é possível estabelecer um bom filtro a priori; nesses casos, heurísticas apropriadas devem ser desenvolvidas para completar a decisão sem que a classificação seja descaracterizada. Tais heurísticas envolvem quase invariavelmente, o emprego de faixas de tolerâncias.

Sempre que uma instância não pode ser interpretado como positiva ou negativa, então é uma instância portadora de ruído, e o sistema deve decidir calculando a distância do erro dos filtros positivos e negativos (como nos pontos onde as setas desviam para 5). Nesse caso, os valores aproximados do exemplo de entrada e o filtro de classe podem ser encontrados da seguinte forma:


Dos dados apresentados no Quadro 3.2-1, obtem-se:

$$\varepsilon(p)^+ = ML(p) * (1 + SigL(p)), e$$

$$\varepsilon(p)^- = NML(p) * (1 + NSigL(p)).$$


$$\varphi^+ = |ML(p) - \varepsilon(p)^+|, e$$

$$\varphi^- = |NML(p) - \varepsilon(p)^-|$$



**Figura 3.2-13:** Proximidade entre a instância e os modelos positivos e negativos. Fonte: Produção do Autor.

Os erros de distância mínima para valores médios da classe de valores positivos e negativos, e  $\varphi^+ + \varphi^-$ , respectivamente, podem ser utilizados para decidir sobre os valores da instância de entrada, como mostrado na Figura 3.2-13.



**Figura 3.2-14:** Avaliação da proximidade utilizando o desvio padrão. Fonte: Produção do Autor.

Deve ser notado que o sistema assume que se distâncias de valores positivos e negativos de classe são iguais, a instância é considerada positiva (viés otimista). Se não houver nenhuma informação exemplo negativo sobre a base de conhecimento, em seguida, o filtro utiliza o desvio padrão para a emissão de uma decisão (Figura 3.2-14).

## 4. RESULTADOS E DISCUSSÕES

### 4.1. Métodos de avaliação pela cor

#### 4.1.1. Resultados dos métodos de avaliação pela cor

##### 4.1.1.1. Resultados do método de classificação com aprendizagem por instrução direta

O método para criação de um padrão através da simples informação do número de níveis e dos intervalos referentes a cada nível foi inicialmente testado.

A hipótese consistia basicamente em verificar se a classificação de um lote de mangas realizada pelo sistema automático seria similar à classificação realizada por um especialista humano sobre o mesmo lote, de maneira que a máquina pudesse realizar essa tarefa em substituição à mão de obra humana.

O experimento consistiu em instruir o sistema de aprendizagem com um padrão de cores e em seguida, submeter um lote de mangas para a classificação pelo sistema e simultaneamente, para a classificação de uma pessoa com experiência nesse tipo de procedimento. A comparação entre esses dois resultados, representaria a correlação entre os agentes classificadores (máquina x homem).

Para avaliação do funcionamento do sistema de aprendizagem por instrução direta, foram adquiridas quatro caixas de mangas *Tommy Atkins* no mercado central de Campina Grande-PB, que somavam no total, 209 unidades. As mangas eram provenientes de Petrolina-PE e se encontravam em diferentes estádios de maturação; apenas 170 mangas desse lote foram selecionadas para o experimento, já que se apresentavam mais homogêneas e sem danos físicos.



**Figura 4.1-1:** Procedimento de lavagem e acondicionamento das frutas. Fonte: Fotos do autor.

As amostras foram lavadas em água corrente e enxugadas, discretamente enumeradas e acondicionadas em uma prateleira de alvenaria, forrada com isopor (Figura 4.1-1), em temperatura ambiente, que teve variação diária dentro do intervalo de 20°C a 29°C. O experimento foi realizado nas instalações do Laboratório de Propriedades Físicas do LAPPA/DEAG/UFMG.

Não se podia estabelecer a priori o número mínimo de amostras suficiente para o treinamento, pois esse valor não pode ser objetivamente definido, por ser de natureza qualitativa, podendo variar muito em função da homogeneidade da variedade da fruta. Para não estabelecer um número arbitrário, foi empregada a heurística de consultar dados de trabalhos científicos similares, como os descritos na seção (2.4), onde foi verificado que a média de amostras utilizadas não ultrapassava 100 unidades; foi então empregado um critério superlativo, decidindo-se por utilizar um número maior de amostras. Assim, o sistema foi configurado para reconhecer o padrão definido pela escala MILLER apresentada na seção (2.4.4), e definido o número de 170 mangas para a análise do sistema.



**Figura 4.1-2:** Algumas das sequencias típicas de imagens capturadas. Fonte: Fotos do autor.

Durante vários dias e com o auxílio da câmara de aquisição de imagens, os dois lados de cada manga foram capturados em intervalos de 72 horas, com a fruta em posição de repouso. O final desse procedimento ocorreu quando as frutas já estavam extremamente maduras, o que ocorreu duas semanas após o início. Cinco sequencias foram registradas, totalizando 1700 imagens (Figura 4.1-2). Em cada intervalo, o sistema armazenava as imagens das frutas nos



cinco diretórios que representavam os níveis da escala; a estrutura dos diretórios armazenam os arquivos considerando a informação “sequência”, associada à data do experimento, podendo cada diretório armazenar várias imagens referentes a um mesmo nível, obtidas em dias diferentes.

Um especialista em fruticultura com larga experiência em classificação de frutas, pertencente ao quadro da Empresa Estadual de Pesquisa Agropecuária da Paraíba SA - EMEPA<sup>21</sup> foi o responsável pela “análise humana” do experimento.

A análise pelo especialista foi realizada em três momentos: no 1º, no 7º e no 14º dia da análise; os resultados respectivos são mostrados nas Tabelas 4.1-1, 4.1-2 e 4.1-3, e incluem a informação do erro das especificações dos níveis entre os classificadores nesses dias. Eles mostram que o classificador automático obteve um desempenho bastante coerente e confiável para essa tarefa. Os erros entre os classificadores podem ter ocorrido em virtude do erro humano, apesar do extenuo e minucioso trabalho do avaliador, pois a tarefa de atribuir percentuais de cores sobre a superfície das mangas não é fácil e exige do classificador humano um longo período de treinamento. Segundo o próprio avaliador, o maior número de ocorrências de erros na análise intermediária se deu porque as cores estavam bem mais dispersas, e a avaliação de cores nessas condições se torna mais difícil; as Tabelas referentes ao início e final da avaliação, fortalecem essa afirmação, pois as cores nesses estágios estavam mais homogêneas, resultando menores erros.

**Tabela 4.1-1:** Resultados das classificações no primeiro dia da avaliação.

Dia 1				
Nível	Avaliação AUTOMÁTICA	Avaliação HUMANA	Erros por nível (Abs)	Erros por nível (%)
	Nº de Mangas classificadas	Nº de Mangas classificadas		
1	89	89	0	0,00
2	39	35	4	2,35
3	28	33	5	2,94
4	11	10	1	0,59
5	3	3	0	0,00

A aferição dos percentuais de cores distribuídas na superfície de uma fruta, como a manga, não é uma tarefa trivial para humanos, pois essa distribuição não ocorre discretamente, mas de forma contínua. Assim, existem áreas onde gradientes de cores como verde e vermelho ou verde e amarelo ocorrem, e o olho treinado deve ser capaz de identificar

<sup>21</sup> Edivaldo Galdino Ferreira - Eng. Agrônomo, M.Sc., Pesquisador da Emepa-PB.

qual cor é mais representativa naquela área e em que proporção. A análise é geralmente realizada em quadrantes pré-definidos da superfície da fruta, recebendo cada um deles, uma estimativa do percentual de uma das cores presentes, sendo esses valores totalizados para cada fruta ao final.

**Tabela 4.1-2:** Resultados das classificações no sétimo dia da avaliação.

Dia 7				
Nível	Avaliação AUTOMÁTICA	Avaliação HUMANA	Erros por nível (Abs)	Erros por nível (%)
	Nº de Mangas classificadas	Nº de Mangas classificadas		
1	6	9	3	1,76
2	18	20	2	1,18
3	38	28	10	5,88
4	51	59	8	4,71
5	57	54	3	1,76

**Tabela 4.1-3:** Resultados das classificações no décimo quarto dia da avaliação.

Dia 14				
Nível	Avaliação AUTOMÁTICA	Avaliação HUMANA	Erros por nível (Abs)	Erros por nível (%)
	Nº de Mangas classificadas	Nº de Mangas classificadas		
1	4	4	0	0,00
2	12	15	3	1,76
3	10	11	1	0,59
4	32	27	5	2,94
5	112	113	1	0,59

Os resultados mostram que as classificações nos estádios de amadurecimento inicial e final das mangas, foram mais próximas; na Tabela 4.1-3, por exemplo, nota-se que no 14º dia, a maioria das mangas estava classificada no nível 5; isso porque a maior parte de sua área estava com a cor amarela, que é característica do estágio de amadurecimento. Foi observado que quatro mangas permaneceram verdes, provavelmente devido ao fenômeno de encruamento<sup>22</sup>.

No final, foi observada uma pequena diferença entre a classificação do sistema e a classificação humana, com erro médio da classificação por nível em torno de 1,9%. O erro máximo foi verificado nas classificações realizadas no 7º dia (Tabela 4.1-2), com um erro médio da classificação por nível de 3,06%.

<sup>22</sup> Relativo a um amadurecimento anormal da fruta.

#### 4.1.1.2. Resultados do método de classificação com aprendizagem a partir de exemplos

A segunda hipótese consistia em verificar a capacidade da construção de um padrão a partir de exemplos, e a consequente avaliação da consistência do padrão assim definido, quando submetido à classificação de novas amostras. Em tese, o sistema deveria identificar qualquer nova fruta a ele apresentada, associando à mesma um nível do padrão, de maneira que sua distribuição de cores fosse similar às das demais imagens no nível.

Para a construção do novo padrão, foram utilizadas as mesmas imagens coletadas das 170 amostras do experimento anterior.

O novo padrão foi definido com cinco níveis e as amostras de cada nível foram determinadas a partir do experimento anterior (seção 3.1.1). Assim, bastou que o sistema fosse instruído através do modo “Aprendizagem”, para analisar as fotos armazenadas no diretório já criado, para montar sua base de conhecimento, com base nas componentes do modelo HSL das imagens.

Os valores das componentes HSL do lote avaliado foram somados e suas médias obtidas para cada nível; os valores médios calculados pelo sistema para a componente H nas cores verde, vermelho e amarelo são apresentados na Tabela 4.1-4.

**Tabela 4.1-4:** Percentuais de cobertura do Matiz (H) aprendidos após o treinamento.

Nível	Cor (%)		
	Vermelho	Verde	Amarelo
1	5,02	92,01	2,97
2	4,89	76,41	18,7
3	6,16	31,86	61,98
4	4,12	9,52	86,36
5	3,98	2,36	93,66

Para verificar a consistência dos resultados da aprendizagem, outras 60 mangas foram adquiridas em outro fornecedor: um comerciante do CEASA/EMPASA de Campina Grande – PB. As mangas também eram provenientes de Petrolina-PE e se encontravam com dois a três dias de colhidas, em diferentes estádios de maturação. As mangas foram submetidas ao procedimento de lavagem e acondicionamento, de maneira similar ao procedimento anterior; em seguida, submetidas à análise do sistema no modo “Consulta”, durante o mesmo intervalo de tempo (14 dias), com imagens coletadas a cada 72 horas, sob condições climáticas similares ao experimento anterior: temperatura variando no intervalo de 21°C a 30°C. As imagens colhidas no modo consulta não foram armazenadas pelo sistema.

**Tabela 4.1-5:** Variação da cobertura do Matiz (H) em função do tempo

Nível	Cor (%)		
	Vermelho	Verde	Amarelo
1	7,33	90,33	2,34
2	7,33	82,25	10,42
3	7,33	28,9	63,77
4	6,25	4,66	89,09
5	4,66	3,12	92,22

Os percentuais obtidos para o novo conjunto de entrada (mangas que não pertenciam ao conjunto de treinamento) são mostrados na Tabela 4.1-5; comparando os resultados com os valores obtidos com o da Tabela 4.1-4, foi calculada a distância (erro), que também é mostrada na Tabela 4.1-6.

O Erro médio de acerto por nível calculado é de aproximadamente 2,6%; esse resultado indica que o sistema foi capaz de criar uma representação genérica para um conjunto amostra, e que essa representação foi suficiente para classificar novos elementos dentro dos níveis criados, com margem de erro aceitáveis. Uma avaliação da taxa de erros em classificação de frutas pela cor, dos métodos descritos na seção (2.6), indica que o percentual de acerto de sistema desse tipo varia muito, entre 75% e 95%, dependendo da fruta e do método utilizado.

Considerando que os erros verificados podem estar associados ao número de amostras que constituiu o treinamento inicial do sistema, a hipótese que a performance do sistema venha a melhorar com o aumento do número de amostras no conjunto de treinamento, pode ser considerada.

**Tabela 4.1-6:** Diferença entre os percentuais do padrão e das amostras (erro)

Nível	Cor (%)			Erro médio por nível (%)
	Vermelho	Verde	Amarelo	
1	-2,31	1,68	0,63	1,54
2	-2,44	-5,84	8,28	5,52
3	-2,13	4,86	-2,73	1,97
4	-1,17	2,96	-1,79	3,24
5	-0,68	-0,76	1,44	0,96

Alem do Matiz (H), as componentes S e L também são calculadas e consideradas para a alocação nos níveis, mas seus valores só podem ser interpretados visualmente, e com o auxílio de um sólido HLS; os dados médios desses valores são apresentados em seus valores normalizados entre [0,1] (Tabela 4.1-7), e também em seus valores reais, extraídos do sistema (Tabela 4.1-8).

**Tabela 4.1-7:** Valores médios dos componentes HSL do padrão.

Nível	Vermelho			Verde			Amarelo		
	H (â)	S (%)	L (%)	H (â)	S (%)	L (%)	H (â)	S (%)	L (%)
1	354	86,11	48,41	145	83,11	35,01	62	91,11	63,39
2	354	81,14	52,68	145	83,01	44,74	61	90,64	61,94
3	357	67,22	57,31	141	82,13	52,09	61	87,22	61,03
4	1	63,13	59,12	139	78,79	62,54	60	86,45	58,64
5	1	59,05	61,02	139	76,05	68,07	60	84,05	56,42

**Tabela 4.1-8:** Valores médios normalizados dos componentes HSL do padrão.

Nível	Vermelho (%)			Verde (%)			Amarelo (%)		
	H	S	L	H	S	L	H	S	L
1	0,98	0,86	0,48	0,40	0,83	0,35	0,17	0,91	0,63
2	0,98	0,81	0,53	0,40	0,83	0,45	0,17	0,91	0,62
3	0,99	0,67	0,57	0,39	0,82	0,52	0,17	0,87	0,61
4	0,00	0,63	0,59	0,39	0,79	0,63	0,17	0,86	0,59
5	0,00	0,59	0,61	0,39	0,76	0,68	0,17	0,84	0,56

#### 4.1.1.3. Resultados do método detector de manchas negras

Para verificar a precisão do método de estimação da área por pigmentação escura, foi necessário inicialmente, escolher uma fruta atingida e calcular o tamanho da área atingida. A determinação precisa desse valor pode ser precisamente calculada nem mesmo por um especialista humano, devido a diversos fatores, mas boas aproximações podem ser realizadas através do procedimento descrito em Mohsenin (1978), que utiliza um ampliador fotográfico para aumentar a escala da imagem da semente e facilitar o cálculo da área da mesma, considerando o multiplicador da escala em questão. Isso foi possível com a utilização de um projetor digital, que possibilitou a ampliação da imagem em 20 vezes, possibilitando a estimação da área afetada com maior precisão.

Para verificar o funcionamento do detector de manchas negras, imagens dos dois lados de uma única manga foram submetidas para análise (Figura 4.1-3).

O procedimento consistiu em sobrepor a imagem ampliada de mangas atingidas, com uma grade formada por quadrados de tamanho fixo (Figura 4.1-4); em seguida, deve ser contado o número de quadrados que formam a área da manga  $\Delta m$  e o número de quadrados atingidos pela mancha negra  $\Delta n$ .

Como cada quadro a ser analisado pode conter diferentes quantidades de tons de cinza, uma escala similar à apresentada na definição de pixels (seção 2.2.6) é empregada.

O somatório da área atingida  $\Delta_n$  é dado pela equação 4.1-1 e o percentual da área atingida  $A_n$  é calculado pela equação 4.1-2:


$$\Delta_n = \sum_{i=1}^n \sum_{j=1}^m N_{i,j} \quad (\text{Eq. 4.1-1})$$

Onde  $i,j$  são os índices da matriz de quadrados, cuja dimensão é  $m \times n$ ; e  $N_{ij}$  é o percentual de cinza presente em um quadrado específico.

$$A_n = \frac{\Delta_n}{\Delta_m} * 100 \quad (\text{Eq. 4.1-2})$$



**Figura 4.1-3:** Manga atingidas por manchas negras. Fonte: Fotos do autor.



**Figura 4.1-4:** Grade sobre a manga para contagem dos pontos negros. Fonte: Produção do autor.

A análise por um observador humano é de difícil interpretação, pois as manchas são bastante difusas e a fronteira entre duas cores não é bem definida. Todas as manchas apresentavam tonalidades escuras, variando da cor ferrugem ao cinza escuro ou preto. Quanto maior a área a ser analisada, maior é o grau de dificuldade para uma estimativa precisa do percentual da superfície atingido.

O cálculo manual da área da superfície da manga atingida por manchas negras, para as imagens da Figura 4.1-3, obtido de maneira manual exaustiva, resultou em 4,75%.

Como não havia nenhuma correlação estabelecida entre os diferentes valores de cobertura de manchas negras obtidos pelas possíveis variações das componentes S e L e os valores obtidos pelo método manual (humano), foi inicialmente realizada uma simulação com o objetivo de “calibrar” os valores desses componentes. A partir das imagens dos lados da manga (Figura 4.1-3), variou-se os valores das componentes entre dois valores limiares:

- O valor inicial (15%) para as duas componentes corresponderiam à impressão (humana) da cor preta; obviamente, valores menores não alterariam essa impressão;
- O valor final (25%) para as duas componentes corresponderiam perfeita percepção (humana) do matiz subjacente, ou seja, a cor já seria percebida.

Variando e combinando os valores das S e L componentes em cinco pontos percentuais, foram obtidos os valores da Tabela 4.1-9. A resposta do sistema para esses valores, indicando a área atingida pela mancha negra estão apresentados na mesma tabela.

**Tabela 4.1-9:** Percentual da área atingida em função dos valores das componentes SL.

#	Limiar (%)		Área atingida (%)
	S	L	
1	15	15	3,27
2	20	15	3,41
3	15	20	3,72
4	20	20	3,85
5	25	20	4,12
6	20	25	4,23
7	25	25	4,37

Como resultado final, o sistema obteve resultados bem próximos ao calculado manualmente (4,75%) para os valores das componentes S e L estabelecidos em 25% (entrada #7 na Tabela 4.1-9); o erro calculado entre o homem e a máquina, foi de aproximadamente 0,38%.


Estabelecendo os valores das componentes S e L em 25%, e realizando os procedimentos de avaliação manual e também pelo sistema sobre um novo lote contendo 10 novas amostras, foram obtidos os valores apresentados na Tabela 4.1-10.

Os resultados expressos na Tabela 4.1-10 indicam uma boa aproximação entre as análises humana e de máquina, onde o valor médio calculado para as diferenças entre as estimativas ficou em 0,84%, ou seja, a precisão chegou a superar 99%.

**Tabela 4.1-10:** Avaliação Homem x Máquina para análise de pontos pretos.

#	Área atingida (%)		Diferença (%)
	Humano	Sistema	
1	3,25	3,93	0,68
2	7,50	8,68	1,18
3	6,25	7,74	1,49
4	8,75	10,14	1,39
5	4,75	5,23	0,48
6	0,25	1,11	0,86
7	3,75	3,92	0,17
8	4,50	5,17	0,67
9	6,75	7,21	0,46
10	9,25	10,27	1,02

Para ilustrar a dificuldade associada à estimação humana, a aplicação do método descrito para a aferição manual da cobertura de pontos pretos para as 10 amostras indicadas nesta tabela, foi realizada em cerca de duas horas.

**Figura 4.1-5:** Influência das componentes S e L para o vermelho no intervalo 15-25%. Fonte: Produção do autor.

O gráfico da Figura 4.1-5 apresenta a variação da cor vermelha pura, com Matiz (H) em 0°/360° e valores limiars baixos, definidos entre 15% e 25% tanto para a saturação (S) quanto para a Luminosidade (L); pode ser nitidamente observado, apesar de qualquer perda de precisão advinda do mecanismo de apresentação (impressora ou vídeo), que a componente



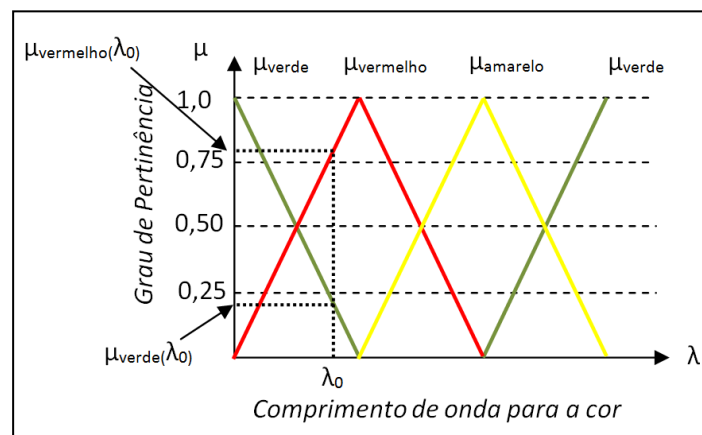
de luminosidade influencia o efeito fade (escurecimento) de maneira bem mais abrupta que a saturação. Isso acontece para qualquer cor representada pelo modelo HSL. Observa-se nessa figura, que a coluna 2, formada por segmentos estratificados da coluna 1 para valores iguais da componente L e dispostos em sequência, apresentam-se mais homogêneos que os relacionados a um mesmo valor da componente S na coluna 1.

#### 4.1.1.4. Resultados do método para estimação de maturidade utilizando fuzzy

Para avaliar o estimador, considere as variáveis fuzzy de entrada para cores e maturidade e as respectivas regras de inferência, como descritas na seção (4.1.3).

##### 4.1.1.4.1. Interpretação gráfica da aplicação das regras

A Figura 4.1-6 apresenta uma entrada específica para a variável Cor, obtida pelo sistema descrito na seção (4.1.3) para as imagens *ImA-Seq3* e *ImB-Seq3*, indicadas na Figura 4.1-8; a Tabela 4.1-11 apresenta os mesmos valores, em termos de percentual de cobertura da cor sobre a superfície.



**Figura 4.1-6:** Interpretação de um valor de entrada específico ( $\lambda_0$ ). Fonte: Produção do Autor.

Aqui deve ser feita uma observação. A especificação de um comprimento de onda específico só se apresenta da forma mostrada na Figura 4.1-6.

Quando uma das cores não se faz presente na superfície da fruta, isso não representa na verdade um problema, pois o que se deseja é obter os valores  $\mu$  de cada uma das cores, o que é feito pelo fuzzificador, que é implementado no sistema pelo algoritmo do fluxograma VI do Apêndice II.




Figura 4.1-7: Distribuição por igual das cores. Fonte: Produção do Autor.

Com isso, o valor do comprimento de onda pode ser expresso por uma composição dos valores dos comprimentos de onda das cores Vermelho, Amarelo e Verde; ou seja:

$$\lambda_0 = \lambda(\text{Vermelho}) \circ \lambda(\text{Amarelo}) \circ \lambda(\text{Verde}) . \quad (\text{Eq. 4.1-3})$$

Caso o sistema capturasse as cores, e por coincidência, o percentual de cobertura de cada cor fosse igual ao das demais, o gráfico que expressaria esta condição seria como mostra a Figura 4.1-7.




Figura 4.1-8: Imagens selecionadas para avaliação. Fonte: Produção do Autor.

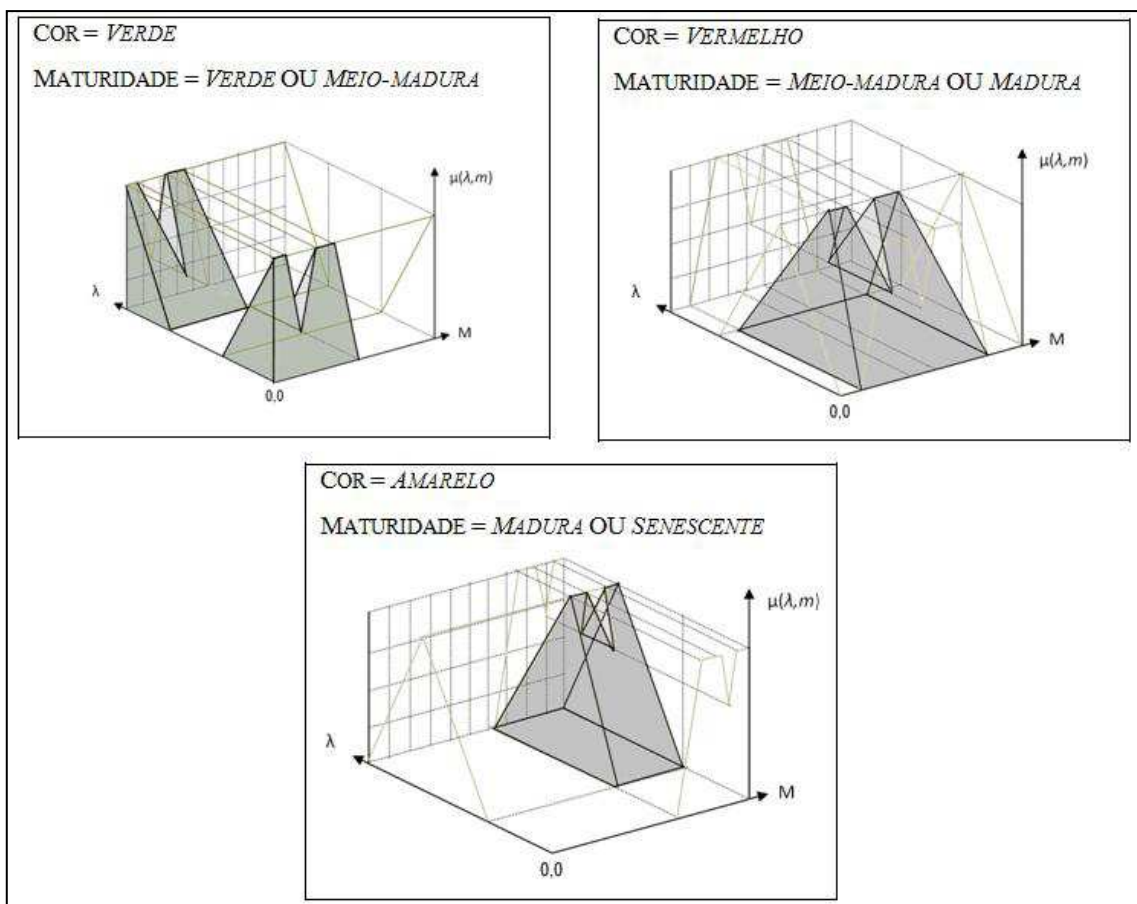
O que se deseja fazer agora é inferir do sistema o resultado para esses valores de entrada. Deseja-se obter a saída resultante de uma entrada específica. Seja  $\lambda_x$ , como mostra o gráfico da Figura 4.1-9; para este valor específico de combinação de cores, o grau de pertinência para cada cor componente é simplesmente um valor escalar; ou seja,  $\mu_{\text{cor}}(\lambda_x)$ . Assim, teremos os valores  $\mu_{\text{verde}}(\lambda_x)$ ,  $\mu_{\text{vermelho}}(\lambda_x)$  e  $\mu_{\text{amarelo}}(\lambda_x)$  para as cores verde, vermelho e amarelo,

respectivamente. Os valores escalares obtidos pelo sistema para as imagens dos lados da manga indicada na Figura 4.1-8 (Seq. 3), estão indicados na Tabela 4.1-11:

**Tabela 4.1.11:** Percentual de cores da imagem retornada pelo sistema

#	Grau de Pertinência de $\lambda$	%
1	cor vermelho [ $\mu_{\text{vermelho}}(\lambda_x)$ ]	79,5
2	cor verde [ $\mu_{\text{verde}}(\lambda_x)$ ]	20,5
3	cor amarela [ $\mu_{\text{amarelo}}(\lambda_x)$ ]	0,0

Como as funções Cor e Maturidade se relacionam nas duas dimensões para um valor de entrada específico. Deve ser procedida a operação E entre essas duas funções, de acordo com as regras indicadas. Os gráficos 3-D compostos para as regras são mostrados na Figura 4.1-9.



**Figura 4.1-9:** Combinação de Funções fuzzy Cor x Estádio de Maturidade. Fonte: Produção do Autor.

A interpretação das regras pode ser melhor compreendida a partir da análise dos gráficos resultantes do produto Cartesiano *Cor x Maturidade*, como foi visto; porém, para a entrada especificada na Tabela 4.1-11, os sólidos geométricos são cortados na altura  $\mu_{\text{cor}}$ , resultando nos aspectos mostrados na Figura 4.1-10 (lado esquerdo). Observe que para um valor de

entrada específico, a linha traçada pelo valor a partir do eixo  $\lambda(\text{cor})$ , representa um plano que corta o espaço tridimensional, produzindo um plano para cada cor.

Observando a Figura 4.1-10, tem-se que  $\lambda_0$  corta os sólidos sobre as cores verde e vermelha apenas em uma reta paralela ao eixo da Maturidade. Com isso, o resultado não está no interior de um sólido, mas num plano, que é obtido a partir do corte realizado sobre essa reta. Nesse caso, o valor da entrada associado à cor amarela é nulo, ou seja,  $\mu(\lambda_0) = 0$  para essa cor.

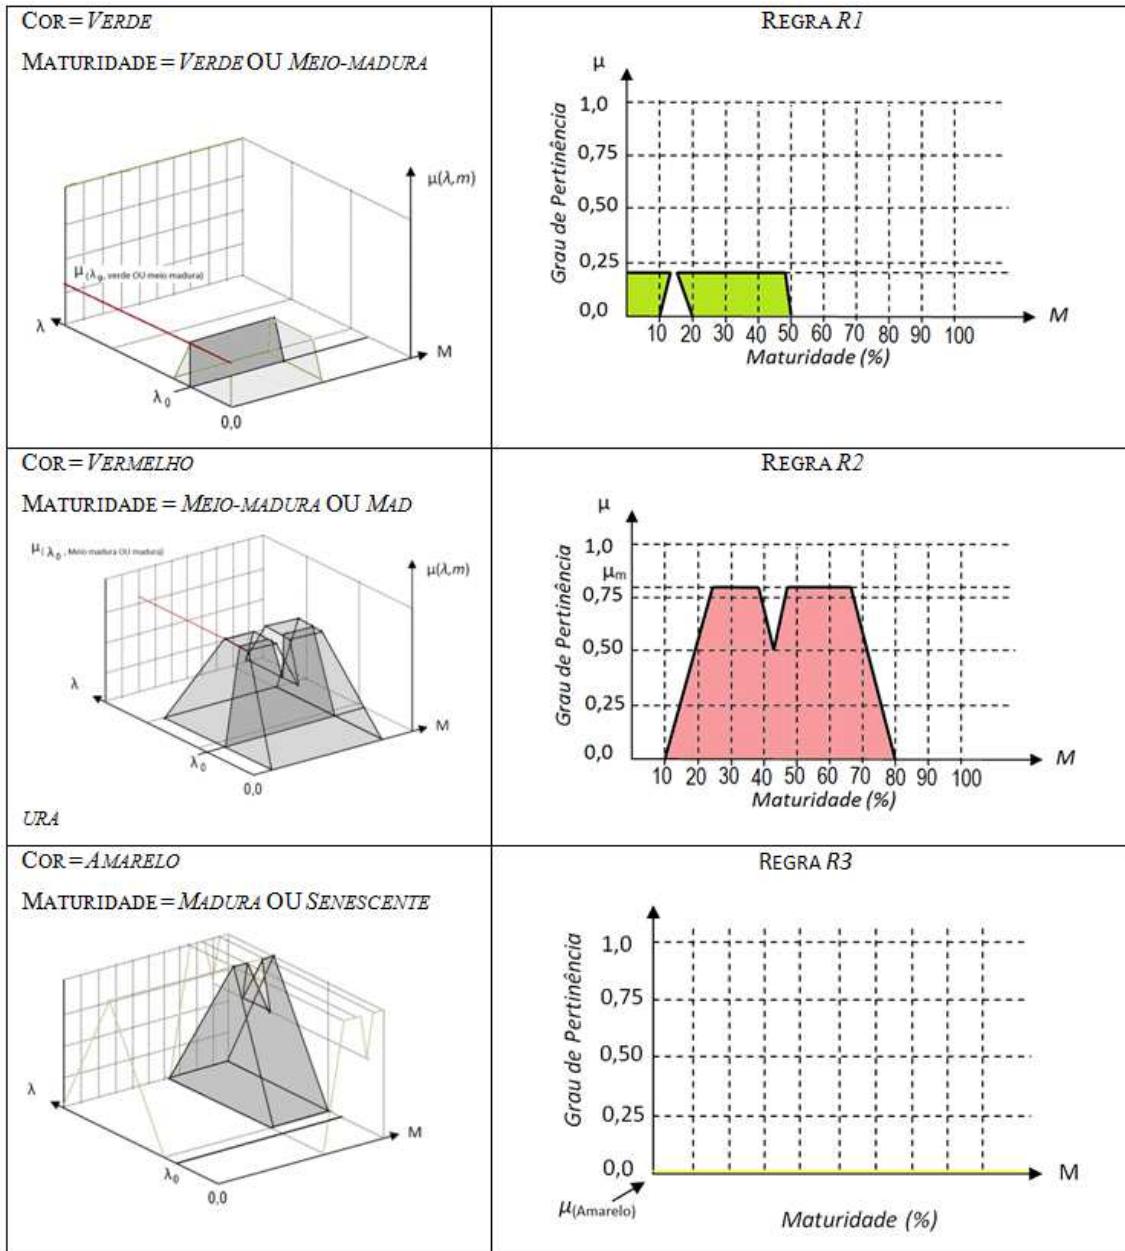


Figura 4.1-10: Planos definidos por uma combinação de cores específica. Fonte: Produção do Autor.

Embora uma resposta do sistema já tenha sido emitida através desses planos, sua representação está muito longe do que se espera de um sistema capaz de manipular

informações próximas à linguagem natural; portanto, resta agora, realizar o processo inverso da fuzzificação, para obter uma saída expressa em termos de um valor numérico, que representa a estimacão da maturidade da manga sob análise.

As geometrias dos corpos que representam os valores fuzzy resultantes podem ter seus centros de massa facilmente encontrados. A Figura 4.1-11 apresenta as fórmulas empregadas nos cálculos das coordenadas x e y do centro de massa das figuras geométricas encontradas na representação fuzzy do conhecimento envolvido neste trabalho.




Figura 4.1-11: Composição dos planos de saída (MAX(μ[λ,m])). Fonte: Produção do Autor.

Deseja-se calcular o valor μ(M) para a entrada λ<sub>x</sub>; os centros de massa das figuras que compõem o gráfico da Figura 4.1-11, bem como suas respectivas áreas são mostrados na Tabela 4.1-12. Os valores são computados pelas seguintes fórmulas:

$$P_i(x) = \text{Área}_i * x_i \tag{Eq. 4.1-4}$$

$$P_i(y) = \text{Área}_i * y \tag{Eq. 4.1-5}$$

$$X_{cg} = \frac{\sum_{i=1}^n \text{Área}_i * x_i}{\sum_{i=1}^n \text{Área}_i} \tag{Eq. 4.1-6}$$

$$Y_{cg} = \frac{\sum_{i=1}^n \text{Área}_i * y_i}{\sum_{i=1}^n \text{Área}_i} \tag{Eq. 4.1-7}$$

Tabela 4.1.12: Defuzzificação por COG

Peça	Área <sub>i</sub>	x <sub>i</sub>	y <sub>i</sub>	P <sub>i</sub> (x)	P <sub>i</sub> (y)
1	205,00	-35,00	13,60	-7175,00	2788,00
2	41,00	-28,67	13,60	-1175,47	557,60
3	596,25	-20,00	26,50	-11925,00	15800,63
4	1351,50	-9,50	39,75	-12839,25	53722,13
5	323,75	0,00	35,00	0,00	11331,25
6	323,75	5,00	46,00	1618,75	14892,50
7	1431,00	17,00	39,75	24327,00	56882,25
8	556,50	34,60	26,50	19254,90	14747,25
<b>SOMA</b>	<b>4828,75</b>	<b>-36,57</b>	<b>240,70</b>	<b>12085,93</b>	<b>170721,60</b>
<b>Valores calculados para X<sub>G</sub> e Y<sub>G</sub>:</b>					
<b>X<sub>cg</sub> = 2,50291069</b>			<b>Y<sub>cg</sub> = 0,353552369</b>		

Os valores calculados de X<sub>cg</sub> e Y<sub>cg</sub>, representam as coordenadas sobre o gráfico onde reside o seu centro de gravidade. Deslocando o gráfico e reajustando os valores, obtém-se:

$$X_{cg} = 43,503$$




Figura 4.1-12: Resultado escalar (crispy) para a maturidade para a entrada λ<sub>0</sub>. Fonte: Produção do Autor.

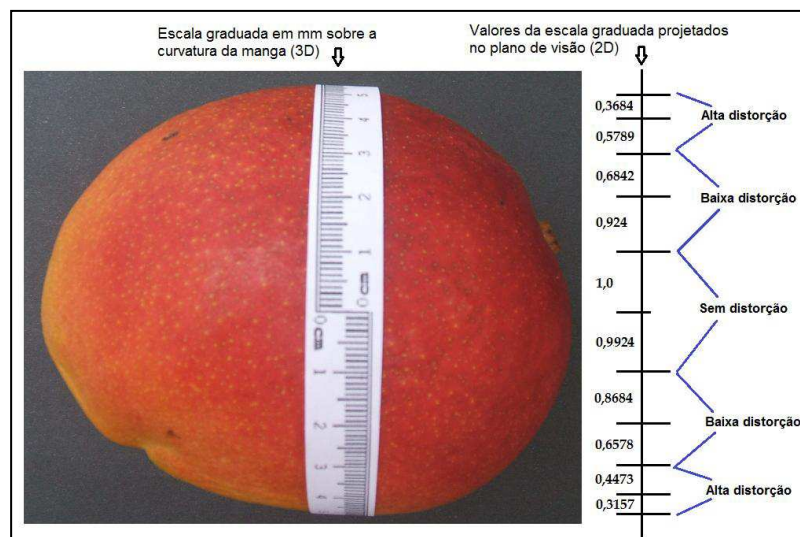
Assim, para o método COG, o valor estimado para o percentual de maturidade para a entrada de cores λ<sub>0</sub>, é dado por X<sub>cg</sub>; assim, m<sub>0</sub> = 42,029 %. Este valor escalar está indicado no gráfico da Figura 4.1-12.

Assim, o sistema estimou que a manga analisada está próxima à metade da sua vida pós-colheita.

## 4.1.2. Discussões sobre os métodos de avaliação pela cor

### 4.1.2.1. Discussão sobre os sistemas inteligentes de classificação pela cor

O sistema de classificação inteligente aqui apresentado passou por várias etapas em seu desenvolvimento; observações coletadas nessas etapas resultaram na adoção de alguns critérios para sua implementação. De início, a questão da aquisição de dados (captura das imagens), se apresentou um desafio quase intransponível; isso porque a manga é um objeto tridimensional, enquanto que a sua imagem nos métodos de representação computacionais, era um arcabouço bidimensional. Com isso, vários problemas emergiram, pois havia perdas de informação e/ou de tempo computacional nas soluções procuradas.




**Figura 4.1-13:** Problema de conversão 3D para 2D. Fonte: Produção do Autor.

Analisando a Figura 4.1-13, observa-se um dos principais problemas de conversão entre o espaço 3D, que é o nosso plano de realidade, e espaço 2D, que é o plano da imagem: a existência da “distorção espacial”, que é a redução da área real pelo efeito da esfericidade da manga. Note que a escala tem seus marcadores comprimidos próximo à linha perimetral. Com isso surge outro problema: a distorção advinda da *saturação cromática*, cujo efeito torna as cores mais escuras nas bordas que no centro. Assim, o problema de associar a cor a uma porção da área da superfície se apresenta de maneira integrada ao de representar a área real da fruta.

Uma das mais atraentes soluções matemáticas estudadas foi o emprego da “projeção transversa de Mercator” de 1569 (Figura 4.1-14), que é uma projeção cilíndrica de uma esfera em um plano bidimensional (ARENAS-RIOS, 2012).

A Transversa de Mercator foi concebida com o objetivo de traçar o sistema de coordenadas terrestres com um nível de distorção matematicamente controlado; ainda hoje, essa projeção é adotada pela Agência de Mapeamento de Defesa Americana (DMA), que instituiu o sistema UTM<sup>23</sup> (SOUZA e GARNES, 2012).



**Figura 4.1-14:** Projeção Transversa de Mercator (ARENAS-RÍOS, 2012). Fonte: Produção do Autor.

Apesar de interessante, verificou-se que essa solução e várias outras similares, aumentavam consideravelmente o esforço computacional, sem que as distorções da transformação 3D-2D fossem eliminadas.

O uso de espelhos se mostrava similar ao emprego de várias câmeras em praticamente todos os aspectos. Basta imaginar um espelho refletindo um dos lados da manga, de maneira que ele permitisse a captura da imagem lateral da fruta; de início, ambas as imagens seriam portadoras do mesmo problema inicial, e certamente haveria uma área comum às duas imagens, dando margem a um novo problema, que é a eliminação das áreas sobrepostas.

Uma solução heurística foi encontrada com a adoção do modelo de cores HSL, pois ele separa as componentes da cor, independente do brilho ou luminosidade; assim, a área da fruta próxima às bordas, atingidas pelo efeito da esfericidade, seria bastante minorado, já que a cor seria perfeitamente capturada, o que mudaria seria sua luminosidade.

Quanto à questão da representação da área, a heurística adotada foi a de que os modelos criados pelo sistema propagariam o erro de maneira linear, distorcendo uma parte da superfície, em todas as imagens. Ora, uma vez que a captura da imagem torna esse aspecto invariável, a classificação pode ocorrer sem maiores problemas, já que o erro fica adstrito à representação, como um ruído causado pelo dispositivo de entrada. Evidentemente, duas

<sup>23</sup> *Universal Transversa de Mercator*



imagens do mesmo objeto transportariam o mesmo ruído, obtendo o mesmo conceito na classificação.

A grande maioria dos sistemas de classificação pesquisados neste trabalho empregava uma ou duas câmaras para captura de imagens, sem fazer qualquer uso de métodos de planificação de imagens.

A proposta para o desenvolvimento deste trabalho foi concluída após extensiva análise de trabalhos anteriores. A meta era não apenas oferecer um mecanismo alternativo diferente dos já existentes, mas algo que se apresentasse inovador em alguns aspectos e pudesse ser aplicado em um sistema eletromecânico para propósitos práticos a baixo custo.

Este trabalho encontra algumas similaridades parciais com os levantados pela pesquisa. Um dos sistemas com melhor performance dentre os pesquisados foi desenvolvido por BERMUDEZ *et al.* (2012) utiliza um modelo diferente do HSL para representar a cor; Apesar disso, chega a uma margem de acerto de 96,4% em relação à análise de especialistas humanos; praticamente o mesmo valor aqui obtido. Uma diferença fundamental é que não está associado qualquer mecanismo de aprendizagem de máquina, constituindo-se numa ferramenta não evolutiva.

Já o trabalho de ATENCIO *et al.* (2009), que resultou em uma performance ainda superior, encontra maiores similaridades, já que emprega o mesmo modelo de cores (HSL), porém, sem fazer uso da componente L (Luminosidade). Comparando a classificação do sistema com a de um especialista, o resultado foi um índice de acerto de 99%, para um total de 40 amostras, obtidos em uma só análise.

Neste trabalho, a comparação das informações obtidas pelo sistema comparadas ao especialista humano, foi realizada com 170 amostras, com imagens colhidas em diferentes fases da maturação, com uma taxa de erro de 1,76% no início e no final da análise. As análises intermediárias envolveram diferenças maiores, com o erro chegando a 3,05%. No primeiro dia de comparação, a avaliação do sistema e a do analista humano coincidiram para um total de 93 amostras.

A taxa de acerto dos sistemas de avaliação de cor apresentados na revisão da literatura, apresenta uma grande variação na taxa de erro, com uma média de acerto pouco superior a 90%.

Como pode ser observado nos trabalhos apresentados, a maioria dos sistemas de análise de imagens utiliza redes neurais (seção 2.3.7) para gerar e armazenar o conhecimento, que

fica adstrito aos pesos dessas estruturas, cujos valores não podem ser facilmente traduzidos para uma forma que possa ser interpretado semanticamente; ou seja, aquele valor só faz sentido para a rede neural. Na proposta alternativa desse trabalho, os dados são representados em Tabelas que representam o conhecimento acumulado, e os valores podem ser interpretados pelo especialista do domínio de conhecimento, que poderá desenvolver inferências a partir dessa informação. Assim, o método proposto pode ser facilmente modificado para fornecer explicações sobre suas decisões, ou seja, pode explicar porque aceitaria ou rejeitaria uma amostra.

O sistema desenvolvido possui as seguintes características:

- Assim como a grande maioria dos métodos estudados, ele não é destrutivo; ou seja, as frutas não são danificadas para a análise.
- Capaz de classificar padrões de vários níveis de distribuição de cores.
- Utiliza histogramas para representar a informação, que apesar de ser reconhecidamente uma estrutura que exige grande esforço computacional, compensa essa perda ao abstrair completamente a posição da fruta no processo de captura de dados da imagem, evitando assim o pré-processamento para a avaliação de cores.
- Utiliza um ambiente controlado para aquisição de imagens, com foco fixo, fundo homogêneo e alinhamento mecânico do objeto.
- Um aspecto que não foi notado nos trabalhos analisados é a filtragem de parte do espectro de cores da imagem para a geração dos histogramas, o que diminui em grande escala, o *throughput*.
- Emprega o paradigma de aprendizagem de máquina a partir de exemplos, criando generalizações de objetos para os níveis dos padrões. Isso facilita enormemente o uso do sistema classificador por parte do especialista, que transfere seu conhecimento para o banco de conhecimento do sistema de forma objetiva e amigável, permitindo a construção de padrões através da técnica de aprendizagem por exemplos; a aprendizagem se dá através da simples apresentação de objetos (mangas) a uma câmera digital, além da informação do nível da classe ou padrão ao qual o objeto pertence.

- A aprendizagem do sistema pode ser evolutiva por opção do usuário; ou seja, melhora com a experiência. Com isso a taxa de erro está sempre sendo diminuída, ainda que não se possa afirmar se chegará à perfeição, ou seja, poderá classificar sem erros.
- O sistema é capaz de decidir sobre frutas cujas descrições não foram transferidas pelo especialista, empregando aproximações, como por exemplo, a utilização do erro quadrático médio como medida de distância ou peso da função de aprendizagem (seção 1.3.8).
- Para aproximar o sistema de visão computacional da humana, permitindo que não houvesse grandes discrepâncias entre as decisões de um especialista e as do sistema proposto, foi adotado o modelo de cores HSL, que é o mais próximo do mecanismo de interpretação de cores humana dentre os que já foram desenvolvidos como recursos computacionais.
- O sistema de representação de cores HSL contorna o problema da interpretação das cores em superfícies esféricas.
- Evita a indecisão, através da utilização em cascata da análise das componentes HSL.
- Pode ser aplicado a vários outros tipos de frutas, podendo ser necessária a alteração do filtro de cores do histograma e da quantidade de imagens a serem analisadas por fruta.
- Pode ser adaptado para selecionar mangas em uma esteira eletromecânica com um dispositivo de chaveamento por seleção, implementando o módulo de decisão.
- É de baixo custo; seus componentes principais são um computador e uma câmera digital.
- O sistema foi codificado na linguagem Python, mas uma versão em C++ já está sendo feita para com o propósito de aumentar a velocidade e viabilizar a construção de dispositivos de automação industrial embarcados.

#### **4.1.2.2. Discussão sobre o detector de manchas negras**

Não foi possível encontrar na revisão bibliográfica realizada neste trabalho, um método que implementasse essa função com o método aqui desenvolvido para avaliação de mangas;

outros métodos foram pesquisados, e os que mais se aproximaram desse objetivo eram quase invariavelmente, orientados à detecção da antracnose (seção 2.1.9), como o de TÉLIZ-ORTÍZ *et al.*, (2003). Outros trabalhos pesquisados forneciam soluções para detecção da moscas-da-fruta (seção 3.3.1), e outros foram desenvolvidos para avaliação de folhas, o que torna esses trabalhos mais seletivos e, portanto, diferentes do que foi desenvolvido neste trabalho.

Em SPÓSITO *et al.* (2004), encontra-se a proposição de uma escala para determinação da severidade de pontos pretos em cítricos. A escala é dividida em seis pontos para a faixa de cobertura de pontos pretos {1,1; 4,5; 15,0; 31,0; 53,0 e 68,0%}. Porém, toda a avaliação foi feita por analistas humanos, não foi utilizado nenhum procedimento automático por imagens.

O método proposto por BULANON *et al.* (2013), que emprega análise de imagens espectrais para detectar pontos pretos em cítricos, chega a um nível de acerto em torno de 96%, mas seu desempenho é calculado em relação a outros métodos computacionais, baseados em Redes Neurais e não a especialistas humanos.

O método desenvolvido em HAFF *et al.* (2013), implementa um algoritmo baseado em análise de limiares, semelhantes ao desenvolvido neste trabalho, mas utiliza uma função estatística denominada “distância de *Mahanlanobis*” para realçar os pontos de interesse e uma outra função denominada “suavização Gaussiana” que realiza a convolução das imagens normais e realçadas, para contar pontos de interesse. No caso, o sistema proposto permitia a detecção de pontos originados pela presença de larvas da mosca-da-fruta em mangas, com um índice de acerto de 94%.

Em NANDI *et al.* (2014a), é utilizado o modelo de cores RGB, realizando a contagem de pixels pretos na imagem da manga, a partir de uma comparação dos valores das componentes RGB, onde de acordo com observações realizadas em diversos experimentos, os valores da Componente B são altos e os das componentes R e G são baixos para pixels mais escuros. Os valores baixos de R e G e os valores altos de B são contabilizados e somados a partir de valores de referência pré-estabelecidos (*thresholds*) e comparados à soma de todos os pixels da imagem, obtendo-se o percentual da superfície da fruta atingido pelas manchas negras. O seu índice de acerto foi estimado em 90%.

#### **4.1.2.3. Discussão sobre o estimador de maturidade fuzzy**

Este trabalho apresentou uma nova abordagem para a manipulação das informações dos sistemas desenvolvidos na seção (4.1.1), onde a lógica fuzzy foi aplicada para avaliação de uma informação descrita de maneira bastante subjetiva: a maturidade da manga *Tommy*

*Atkins*. Aqui não foi analisada qualquer correlação entre a distribuição de cores e nível de maturidade detectada por um sistema de aprendizagem, mas foi empregada uma heurística humana, que não exige uma formalização numérica mais elaborada, representada na forma de regras do tipo Se-Então, cuja validade é fruto da percepção histórica, que permite sua real aplicação (*Rules of Thumb*).

Embora não tenha sido possível encontrar trabalhos que utilizassem as mesmas variáveis linguísticas para o produto analisado, foi possível perceber a aplicabilidade do sistema, podendo ser induzida a sua funcionalidade pelo experimento realizado. Porém, muitos trabalhos recentes demonstram a viabilidade do uso de lógica fuzzy para estimação de maturidade.

O trabalho de DADWAL E BANGA (2012) traz uma abordagem semelhante, mas utiliza o padrão de cores RGB, e apresenta sua aplicação em maçãs, com a observação que a distribuição de cores da fruta implica em resultados inesperados.

Já o trabalho recente de NANDI *et. al.* (2014), apresenta um algoritmo baseado em regras fuzzy que é utilizado para classificar a fruta de cinco variedades de mangas (“*Kumrapali*”, “*Amrapali*”, “*Sori*”, “*Langra*” e “*Himsagar*”) em quatro graus de qualidade: pobre, média, boa e muito boa, com base na sua maturidade estimada, e tamanho, utilizando imagens RGB e funções do MATLAB® para estabelecer uma função fuzzy de Mistura Gaussiana, que é uma soma ponderada das densidades dos componentes da cor. Nesse caso, foi estabelecida uma relação dos resultados obtidos pelo sistema ao de analistas humanos, ambos com nível de acerto entre 88,6% e 91,2%. As regras utilizadas eram do tipo:

- **Se o nível de maturidade é cru e tamanho é pequeno, então qualidade é ruim;**
- **Se o nível de maturidade é maduro e tamanho é grande, então qualidade é muito boa.**

Regras que relacionam cores com a maturidade não são informadas no sistema.

## **4.2. Métodos de avaliação pela forma**

### **4.2.1. Resultados dos métodos de avaliação pela forma**

Para estimar a massa da manga a partir das informações do volume foi inicialmente necessário verificar a correlação entre o volume real (medido) e a massa real da fruta fresca. Isso porque o sistema de estimação de massa e volume a partir das imagens não é capaz de

inferir o valor da massa, que é uma grandeza física inerente ao material e imperceptível pelos sistemas de visão. Nesses casos, a massa é calculada em termos de sua correlação com o volume, que pode ser estimado visualmente.

Para isso, três caixas de mangas *Tommy Atkins*, totalizando 156 unidades foram obtidas no mercado central da cidade de Campina Grande, no Estado da Paraíba. As mangas com danos mecânicos foram descartadas e no final, 145 restaram, das quais 100 unidades foram separadas para o experimento e o restante foi utilizado em procedimentos destrutivos, para avaliar o percentual de massa útil (polpa da fruta) em relação à sua massa total.


Todos os procedimentos de mensuração foram realizados nas instalações do Laboratório de Propriedades Físicas do LAPPA/DEAG/UFCG.

As mangas apresentavam diferentes estádios de maturação, mas não muito distantes entre si; foi estimado a partir de informações do vendedor, que as mangas teriam sido colhidas há cerca de dois dias em média.

O lote se apresentava aparentemente bastante uniforme, por isso, ainda no instante da compra, foi solicitada do vendedor a inclusão de algumas unidades que apresentassem alguma diferença em relação ao tamanho médio do lote, de maneira que algumas apresentassem sensíveis diferenças no seu volume e massa aparente. Essa medida visou observar o comportamento dos valores estimados a partir de bases mais heterogêneas.

Ao chegar ao LAPPA, todas as mangas foram inicialmente lavadas e acondicionadas em estantes; cada uma delas foi enumerada com a utilização de uma caneta do tipo “marcador permanente” para retroprojeter.

Após o procedimento de identificação, todas as mangas foram pesadas com o auxílio de uma balança eletrônica; os resultados foram expressos em gramas (*g*), e tomados numa altitude de aproximadamente 540 m em relação ao nível do mar, sendo anotados em seguida; seus respectivos volumes foram determinados por meio do método de Arquimedes, analisando a quantidade de água deslocada pelo fruto inserido em um Becker graduado 0-4000 ml cheio de água; os resultados foram expressos em centímetros cúbicos ( $cm^3$ ) e anotados. Esses procedimentos foram realizados a partir da chegada do lote (1º dia do experimento), e repetidamente, durante duas semanas, com intervalos de 60 horas.




**Figura 4.2-1:** Curva da perda de massa das mangas no intervalo de 15 dias. Fonte: Produção do Autor.


O gráfico da Figura 4.2-1 apresenta a queda da massa das frutas em função do tempo de armazenamento em estante, causado pela perda de água; pode ser observado que as mangas numeradas de 1a 100 apresentam uma queda uniforme, independente da sua massa inicial.

As mínimas variações das inclinações verificadas para diferentes mangas no gráfico podem ser associadas às diferenças do estágio de maturação inicial do procedimento para cada uma delas, além de outros fatores como diferentes espessuras da superfície.

Foram tomadas precauções para manter todas as mangas em condições de mesma temperatura, umidade relativa e espaço de armazenamento isolado da iluminação solar direta, para que esses fatores não viessem a produzir efeitos térmicos diferenciados entre as amostras.



(a)



(b)

**Figura 4.2-2:** Correlação entre a massa fresca e volume da manga *Tommy Atkins*.

Ao final do período de coleta de dados, os coeficientes de correlação e equação de regressão linear foram determinados para os dados do início (a) e do final (b) desse



procedimento, utilizando a função FIT de ajuste de curvas do programa Wolfram Mathematica<sup>24</sup>. Os resultados foram expressos no gráfico da Figura 4.2-2.

Observando a Figura 4.2-2 (a), uma grande aproximação entre a massa e o volume pode ser notada, com os pontos se concentrando muito próximos à linha de regressão ajustada; a correlação entre esses valores é muito alta, próximo a 100%. Na Figura 4.2-2(b), pode também ser notado que embora os valores tenham sido reduzidos devido à perda de água nos frutos, tanto na massa e quanto no volume, a correlação permaneceu sem alteração muito significativa, com baixa dispersão.

#### **4.2.1.1. Correlação entre massa e volume**

Com base nesses resultados, deduz-se que a massa fresca da manga pode ser estimada com boa precisão a partir de seu volume. Esta afirmação extraída do experimento é também confirmada por outros trabalhos, como em MORAIS *et al.* (2004) e FILGUEIRAS *et al.* (2002) que chegam a valores quase idênticos aos que aqui foram obtidos.

Pode ser concluído, a partir desse experimento, que para a manga *Tommy Atkins*, a correlação massa x volume é mais alta nos estádios iniciais da maturação, e que a partir das informações do volume dessa fruta, sua massa pode ser estimado com boa aproximação.

#### **4.2.1.2. Estimação do volume**

O método de estimação do volume das mangas aqui apresentado foi definido heurísticamente, após o estudo de vários trabalhos similares durante a revisão bibliográfica (seção 2.5), sendo vislumbrado inicialmente após a análise dos métodos descritos em ATENCIO *et al.* (2009) e BERMÚDEZ *et al.* (2012); a verificação que a imagem da manga poderia ser dividida em duas figuras de diferentes áreas a partir do seu eixo principal, e que o cálculo do volume poderia ser melhor estimado considerando essa diferença, não foi extraída de nenhum desses trabalhos, sendo fruto de simples dedução pela análise da geometria da fruta.

O método foi testado sobre o mesmo conjunto de 100 mangas selecionado para o procedimento de aprendizagem por exemplos (seção 2.3.5); durante o procedimento de coleta de dados (massa e volume), foi realizado em paralelo um processo para a captura de imagens das mangas, como também a medição manual dos eixos das mesmas, que foi realizada com o

---

<sup>24</sup> Wolfram Research Trademark - Champaign – IL.

auxílio de um paquímetro digital; cada medição foi realizada três vezes para cada eixo, sendo escolhido sempre o maior valor.

As imagens foram então submetidas à avaliação do sistema. Os valores retornados na primeira avaliação são mostrados na Tabela 4.2-1, que apresenta os valores reais medidos em laboratório e ainda os valores emitidos pela saída do sistema.

A Tabela 4.2-1 está dividida em duas partes principais: As medições manuais, dadas em milímetros (mm) e as medições obtidas pelo sistema de análise de imagens, também dadas em milímetros, empregadas nas fórmulas V-P1, V-P2 e V-P3 (desenvolvida neste trabalho), para derivar os valores estimados para o volume, que é dado em centímetros cúbicos (cm<sup>3</sup>). Ainda está incluído o erro (%) calculado para cada uma das estimativas de volume geradas por essas fórmulas, em relação aos volumes obtidos manualmente.

Pode ser inicialmente notada uma notável discrepância entre os valores obtidos manualmente, que constituem os valores de referência para as estimativas descritas nas fórmulas, e os volumes calculados para o esferóide prolato (V-P1) estão associados aos maiores erros. Isso reflete uma característica da manga *Tommy Atkins*: a sensível variação entre as dimensões de um fruto para outro.

**Tabela 4.2-1:** Medições manuais, estimativas e resposta do sistema.

#	Medições manuais					Fórmula V-P1				Fórmula V-P2		Fórmula V-P3								CPP	
	p (mm)	b (mm)	c (mm)	Massa (g)	Volume (cm <sup>3</sup> )	p/2 (mm)	a (mm)	Volume (cm <sup>3</sup> )	Erro	Volume (cm <sup>3</sup> )	Erro	p (mm)	p/2 (mm)	a (mm)	b (mm)	c (mm)	d (mm)	e (mm)	Volume (cm <sup>3</sup> )		Erro
1	146,37	119,74	107,57	765,54	767,84	73,2	59,9	1098,8	43,11%	987,1	28,56%	146,0	73,0	62,0	57,0	66,0	4,0	76,0	792,1	3,16%	[258,272]
2	137,34	117,07	110,72	759,28	761,55	68,7	58,5	985,6	29,42%	932,1	22,40%	137,0	68,0	65,0	54,0	62,0	3,0	72,0	782,4	2,74%	[239,250]
3	144,97	109,08	98,07	758,30	760,56	72,5	54,5	903,2	18,75%	812,0	6,76%	145,0	72,0	61,0	50,0	61,0	5,0	79,0	727,0	4,41%	[242,245]
4	136,02	106,65	100,94	752,10	754,33	68,0	53,3	810,1	7,39%	766,7	1,64%	138,0	69,0	63,0	45,0	58,0	5,0	75,0	725,7	3,79%	[245,251]
5	135,90	123,31	106,08	697,70	699,64	68,0	61,7	1082,0	54,65%	930,8	33,04%	130,0	65,0	62,0	61,0	54,0	4,0	72,0	729,2	4,22%	[269,257]
6	134,60	112,33	96,71	691,10	693,01	67,3	56,2	889,3	28,32%	765,6	10,48%	134,0	67,0	63,0	49,0	57,0	3,0	74,0	713,2	2,91%	[252,239]
7	138,20	112,61	103,07	665,39	667,16	69,1	56,3	917,6	37,54%	839,9	25,89%	136,0	68,0	60,0	52,0	57,0	2,0	77,0	675,4	1,24%	[268,256]
8	136,88	102,58	93,97	659,10	660,84	68,4	51,3	754,2	14,12%	690,9	4,54%	137,0	68,0	59,0	44,0	57,0	4,0	76,0	630,4	4,60%	[254,253]
9	132,08	110,80	103,65	650,35	652,04	66,0	55,4	849,0	30,21%	794,2	21,81%	132,0	66,0	62,0	49,0	54,0	3,0	75,0	682,6	4,68%	[244,258]
10	130,53	115,10	107,08	644,50	646,16	65,3	57,6	905,4	40,13%	842,4	30,36%	130,0	65,0	60,0	52,0	60,0	4,0	66,0	645,6	0,08%	[254,256]
11	130,81	100,93	94,50	644,20	645,86	65,4	50,5	697,7	8,03%	653,3	1,15%	130,0	65,0	61,0	40,0	54,0	5,0	71,0	638,0	1,21%	[249,258]
12	132,97	115,37	102,58	644,09	645,75	66,5	57,7	926,7	43,51%	824,0	27,60%	133,0	66,0	61,0	51,0	56,0	6,0	71,0	670,0	3,76%	[256,252]
13	129,28	104,85	97,62	638,40	640,03	64,6	52,4	744,2	16,27%	692,8	8,25%	130,0	65,0	61,0	44,0	61,0	3,0	66,0	641,5	0,24%	[258,249]
14	131,70	105,10	93,52	638,00	639,63	65,9	52,6	761,7	19,09%	677,8	5,97%	132,0	66,0	60,0	45,0	55,0	4,0	73,0	633,3	0,99%	[270,256]
15	134,10	113,64	101,22	627,64	629,21	67,1	56,8	906,8	44,11%	807,7	28,36%	134,0	67,0	59,0	52,0	56,0	1,0	77,0	647,3	2,88%	[259,243]
16	133,36	109,16	105,39	622,39	623,93	66,7	54,6	832,1	33,36%	803,3	28,75%	133,0	66,0	60,0	49,0	55,0	2,0	76,0	644,1	3,24%	[256,260]
17	132,81	103,52	92,28	621,70	623,24	66,4	51,8	745,2	19,57%	664,3	6,59%	133,0	66,0	61,0	42,0	55,0	1,0	77,0	649,0	4,13%	[259,262]
18	133,85	107,71	100,95	619,46	620,99	66,9	53,9	813,1	30,93%	762,0	22,71%	134,0	67,0	59,0	49,0	58,0	3,0	73,0	635,1	2,27%	[253,250]
19	132,08	99,44	96,08	616,50	618,01	66,0	49,7	683,8	10,65%	660,7	6,91%	132,0	66,0	60,0	39,0	62,0	4,0	66,0	626,7	1,41%	[265,261]
20	134,22	109,09	100,53	614,01	615,51	67,1	54,5	836,3	35,88%	770,7	25,22%	134,0	67,0	60,0	49,0	60,0	3,0	71,0	653,9	6,23%	[257,253]
21	132,57	98,12	92,04	613,60	615,10	66,3	49,1	668,3	8,65%	626,9	1,91%	133,0	66,0	60,0	38,0	55,0	4,0	74,0	626,8	1,90%	[257,275]
22	129,06	114,89	101,25	613,30	614,80	64,5	57,4	892,0	45,09%	786,1	27,86%	129,0	64,0	60,0	53,0	61,0	5,0	63,0	640,0	4,10%	[235,251]
23	132,93	99,38	91,65	608,20	609,67	66,5	49,7	687,4	12,75%	633,9	3,98%	133,0	66,0	59,0	41,0	55,0	6,0	72,0	607,5	0,36%	[255,262]
24	130,51	109,62	101,58	607,75	609,22	65,3	54,8	821,1	34,79%	760,9	24,90%	130,0	65,0	61,0	47,0	58,0	3,0	69,0	647,5	6,29%	[239,253]
25	127,82	104,66	92,31	607,50	608,96	63,9	52,3	733,1	20,38%	646,6	6,18%	128,0	64,0	58,0	48,0	54,0	3,0	71,0	585,7	3,82%	[255,258]

Continuação...

Tabela 4.2-1: Medições manuais, estimativas e resposta do sistema.

#	Medições manuais					Fórmula V-P1				Fórmula V-P2		Fórmula V-P3								CPP	
	<i>p</i> (mm)	<i>b</i> (mm)	<i>c</i> (mm)	Massa (g)	Volume (cm <sup>3</sup> )	<i>p</i> /2 (mm)	<i>a</i> (mm)	Volume (cm <sup>3</sup> )	Erro	Volume (cm <sup>3</sup> )	Erro	<i>p</i> (mm)	<i>p</i> / 2 (mm)	<i>a</i> (mm)	<i>b</i> (mm)	<i>c</i> (mm)	<i>d</i> (mm)	<i>e</i> (mm)	Volume (cm <sup>3</sup> )		Erro
26	136,39	110,33	99,69	603,61	605,05	68,2	55,2	869,3	43,67%	785,5	29,82%	137,0	68,0	57,0	51,0	61,0	4,0	72,0	616,7	1,92%	[271,253]
27	129,26	99,86	92,61	602,00	603,44	64,6	49,9	674,9	11,84%	625,9	3,72%	130,0	65,0	59,0	41,0	63,0	2,0	65,0	598,3	0,86%	[243,243]
28	135,08	100,51	90,89	597,90	599,31	67,5	50,3	714,5	19,22%	646,1	7,81%	135,0	67,0	56,0	45,0	57,0	3,0	75,0	567,4	5,33%	[265,261]
29	137,11	105,92	103,53	594,52	595,92	68,6	53,0	805,4	35,16%	787,2	32,11%	137,0	68,0	57,0	48,0	58,0	5,0	74,0	604,0	1,36%	[259,271]
30	125,14	113,62	100,92	591,60	592,98	62,6	56,8	845,9	42,65%	751,3	26,70%	125,0	62,0	58,0	57,0	54,0	4,0	67,0	608,3	2,58%	[244,257]
31	135,80	96,49	94,39	588,90	590,27	67,9	48,2	662,0	12,15%	647,6	9,71%	136,0	68,0	58,0	39,0	59,0	4,0	73,0	603,8	2,30%	[267,259]
32	123,94	103,50	92,01	586,00	587,35	62,0	51,8	695,2	18,36%	618,0	5,22%	124,0	62,0	59,0	44,0	51,0	4,0	69,0	574,8	2,14%	[252,253]
33	133,88	113,78	104,20	585,54	586,89	66,9	56,9	907,5	54,63%	831,1	41,61%	134,0	67,0	54,0	60,0	56,0	6,0	72,0	618,1	5,32%	[271,259]
34	127,62	109,30	101,27	584,63	585,97	63,8	54,7	798,3	36,23%	739,6	26,22%	128,0	64,0	58,0	51,0	55,0	5,0	68,0	597,1	1,89%	[256,239]
35	132,60	103,65	95,00	580,00	581,32	66,3	51,8	745,9	28,31%	683,7	17,60%	133,0	66,0	58,0	45,0	58,0	5,0	70,0	595,1	2,38%	[239,257]
36	126,40	99,57	92,33	579,10	580,41	63,2	49,8	656,1	13,05%	608,4	4,83%	127,0	63,0	57,0	43,0	53,0	2,0	72,0	546,1	5,92%	[269,2580]
37	123,00	108,90	104,30	577,87	579,18	61,5	54,5	763,8	31,87%	731,5	26,30%	123,0	61,0	61,0	48,0	54,0	2,0	67,0	610,1	5,34%	[259,250]
38	121,82	99,20	95,09	572,40	573,68	60,9	49,6	627,7	9,41%	601,7	4,88%	123,0	61,0	58,0	44,0	57,0	3,0	63,0	547,9	4,49%	[265,261]
39	118,12	110,43	103,52	558,58	559,79	59,1	55,2	754,2	34,73%	707,0	26,30%	118,0	59,0	59,0	48,0	50,0	4,0	64,0	556,2	0,63%	[273,263]
40	118,62	109,31	102,64	558,08	559,28	59,3	54,7	742,1	32,69%	696,8	24,60%	119,0	59,0	61,0	46,0	51,0	1,0	67,0	585,6	4,71%	[259,256]
41	122,63	107,64	99,14	557,27	558,47	61,3	53,8	743,9	33,21%	685,2	22,69%	122,0	61,0	60,0	47,0	51,0	2,0	69,0	589,7	5,60%	[241,256]
42	116,99	100,60	94,38	553,30	554,48	58,5	50,3	619,9	11,80%	581,6	4,89%	118,0	59,0	58,0	43,0	51,0	2,0	65,0	528,2	4,74%	[273,264]
43	117,48	99,58	93,58	552,80	553,97	58,7	49,8	610,0	10,11%	573,2	3,47%	117,0	58,0	58,0	45,0	49,0	4,0	64,0	523,0	5,59%	[269,270]
44	121,45	98,06	90,39	552,00	553,17	60,7	49,0	611,5	10,54%	563,6	1,89%	121,0	60,0	58,0	41,0	52,0	3,0	66,0	534,4	3,40%	[245,254]
45	122,25	113,90	97,04	546,87	548,01	61,1	57,0	830,4	51,53%	707,5	29,10%	122,0	61,0	58,0	51,0	51,0	5,0	66,0	569,1	3,84%	[275,268]
46	121,08	103,76	88,47	541,70	542,82	60,5	51,9	682,5	25,74%	582,0	7,21%	121,0	60,0	59,0	45,0	52,0	4,0	65,0	558,2	2,83%	[248,263]
47	121,46	108,24	96,75	537,48	538,57	60,7	54,1	745,1	38,34%	666,0	23,66%	121,0	60,0	58,0	47,0	50,0	3,0	68,0	546,1	1,40%	[264,268]
48	121,18	106,93	97,60	534,76	535,84	60,6	53,5	725,5	35,39%	662,2	23,58%	120,0	60,0	58,0	48,0	53,0	4,0	63,0	549,1	2,47%	[267,266]
49	120,30	98,60	88,21	532,40	533,47	60,2	49,3	612,4	14,79%	547,8	2,70%	121,0	60,0	56,0	43,0	50,0	5,0	66,0	503,4	5,63%	[258,251]
50	118,79	105,63	99,27	531,43	532,49	59,4	52,8	694,0	30,33%	652,2	22,48%	119,0	59,0	59,0	47,0	49,0	4,0	66,0	553,5	3,95%	[262,273]
51	120,02	97,41	88,98	529,70	530,75	60,0	48,7	596,3	12,35%	544,7	2,63%	120,0	60,0	56,0	42,0	52,0	5,0	63,0	501,5	5,51%	[249,245]
52	126,48	104,86	97,16	528,40	529,45	63,2	52,4	728,2	37,54%	674,7	27,44%	127,0	63,0	55,0	48,0	55,0	4,0	68,0	527,1	0,45%	[255,259]
53	117,65	96,22	90,50	526,40	527,43	58,8	48,1	570,3	8,13%	536,4	1,70%	118,0	59,0	56,0	41,0	51,0	3,0	64,0	491,6	6,80%	[265,261]
54	122,79	107,25	96,93	525,97	527,00	61,4	53,6	739,5	40,33%	668,4	26,82%	123,0	61,0	58,0	47,0	54,0	2,0	67,0	555,2	5,36%	[261,256]
55	122,17	106,06	103,62	523,65	524,67	61,1	53,0	719,6	37,15%	703,0	33,99%	122,0	61,0	57,0	46,0	53,0	4,0	65,0	535,7	2,11%	[259,248]
56	125,27	95,52	88,58	523,40	524,42	62,6	47,8	598,5	14,12%	555,0	5,83%	126,0	63,0	54,0	41,0	55,0	5,0	66,0	490,6	6,45%	[259,252]
57	132,21	102,28	97,87	522,04	523,05	66,1	51,1	724,2	38,45%	693,0	32,48%	132,0	66,0	56,0	46,0	58,0	4,0	70,0	561,9	7,44%	[265,261]
58	121,61	97,70	88,37	521,00	522,01	60,8	48,9	607,8	16,43%	549,8	5,32%	122,0	61,0	55,0	42,0	53,0	3,0	66,0	493,2	5,51%	[261,253]
59	121,00	96,62	94,47	518,70	519,69	60,5	48,3	591,5	13,81%	578,3	11,27%	121,0	60,0	55,0	41,0	53,0	3,0	65,0	483,4	6,99%	[265,258]
60	130,94	93,17	89,23	517,10	518,09	65,5	46,6	595,1	14,87%	570,0	10,02%	131,0	65,0	53,0	41,0	57,0	2,0	72,0	489,2	5,58%	[249,257]
61	120,31	109,36	98,02	516,99	517,97	60,2	54,7	753,4	45,45%	675,3	30,37%	121,0	60,0	57,0	48,0	53,0	3,0	65,0	533,0	2,89%	[266,257]
62	120,58	106,47	96,53	515,88	516,86	60,3	53,2	715,7	38,47%	648,9	25,54%	120,0	60,0	58,0	46,0	52,0	5,0	63,0	543,4	5,14%	[270,259]
63	121,43	107,73	96,66	515,58	516,56	60,7	53,9	737,9	42,85%	662,1	28,17%	121,0	60,0	57,0	48,0	53,0	3,0	65,0	533,0	3,18%	[268,263]
64	119,16	99,62	89,36	512,10	513,06	59,6	49,8	619,2	20,69%	555,4	8,26%	120,0	60,0	56,0	43,0	52,0	4,0	64,0	503,4	1,88%	[249,255]
65	119,42	96,99	88,01	511,00	511,95	59,7	48,5	588,2	14,89%	533,7	4,26%	119,0	59,0	55,0	42,0	52,0	4,0	63,0	477,1	6,81%	[269,259]
66	120,27	98,14	88,12	510,70	511,65	60,1	49,1	606,5	18,54%	544,6	6,44%	120,0	60,0	57,0	46,0	52,0	3,0	65,0	526,9	2,99%	[256,258]
67	118,30	102,77	96,07	505,58	506,50	59,2	51,4	654,2	29,16%	611,6	20,74%	119,0	59,0	58,0	45,0	52,0	4,0	63,0	532,0	5,04%	[262,255]
68	114,08	104,32	98,52	501,75	502,65	57,0	52,2	650,0	29,32%	613,9	22,13%	114,0	57,0	59,0	45,0	50,0	3,0	61,0	530,3	5,49%	[252,239]
69	117,17	93,62	87,59	500,80	501,70	58,6	46,8	537,7	7,18%	503,1	0,28%	117,0	58,0	55,0	41,0	51,0	3,0	63,0	467,2	6,87%	[258,255]
70	112,99	95,03	89,82	497,00	497,88	56,5	47,5	534,3	7,31%	505,0	1,43%	113,0	56,0	56,0	47,0	49,0	3,0	61,0	479,7	3,66%	[270,265]
71	116,39	104,12	95,37	491,55	492,40	58,2	52,1	660,7	34,17%	605,1	22,90%	116,0	58,0	58,0	44,0	48,0	2,0	66,0	521,0	5,80%	[269,258]
72	119,93	102,18	95,49	489,43	490,27	60,0	51,1	655,6	33,73%	612,7	24,97%	120,0	60,0	56,0	46,0	50,0	0,0	70,0	510,9	4,20%	[257,253]
73	124,64	102,39	92,42	488,92	489,76	62,3	51,2	684,2	39,70%	617,6	26,10%	125,0	62,0	54,0	47,0	52,0	2,0	71,0	499,6	2,00%	[268,265]
74	115,27	94,85	86,95	486,90	487,73	57,6	47,4	543,0	11,33%	497,8	2,06%	115,0	57,0	55,0	45,0	48,0	3,0	64,0	467,7	4,11%	[259,250]
75	118,78	93,08	87,06	484,80	485,61	59,4	46,5	538,8	10,96%	504,0	3,78%	119,0	59,0	53,0	45,0	49,0	3,0	67,0	454,9	6,32%	[254,254]

## Continuação...

Tabela 4.2-1: Medições manuais, estimativas e resposta do sistema.

#	Medições manuais					Fórmula V-P1				Fórmula V-P2		Fórmula V-P3								CPP	
	p (mm)	b (mm)	c (mm)	Massa (g)	Volume (cm <sup>3</sup> )	p/2 (mm)	a (mm)	Volume (cm <sup>3</sup> )	Erro	Volume (cm <sup>3</sup> )	Erro	p (mm)	p/2 (mm)	a (mm)	b (mm)	c (mm)	d (mm)	e (mm)	Volume (cm <sup>3</sup> )		Erro
76	123,45	93,27	84,26	484,30	485,11	61,7	46,6	562,3	15,91%	508,0	4,72%	124,0	62,0	53,0	41,0	52,0	4,0	68,0	466,6	3,82%	[252,259]
77	113,41	110,35	93,76	481,66	482,46	56,7	55,2	723,1	49,88%	614,4	27,34%	113,0	56,0	56,0	50,0	47,0	2,0	64,0	489,8	1,52%	[266,270]
78	112,32	100,52	85,48	477,10	477,87	56,2	50,3	594,2	24,35%	505,3	5,75%	112,0	56,0	58,0	42,0	47,0	3,0	62,0	499,9	4,61%	[259,271]
79	122,80	102,47	92,99	473,58	474,33	61,4	51,2	675,1	42,33%	612,7	29,17%	123,0	61,0	54,0	45,0	51,0	3,0	69,0	484,8	2,21%	[259,250]
80	115,56	103,08	93,63	473,28	474,03	57,8	51,5	642,9	35,63%	584,0	23,19%	116,0	58,0	54,0	48,0	48,0	2,0	66,0	470,9	0,66%	[272,259]
81	122,58	101,25	92,94	471,46	472,20	61,3	50,6	658,0	39,34%	604,0	27,90%	123,0	61,0	55,0	43,0	51,0	2,0	70,0	495,4	4,90%	[259,265]
82	121,62	93,35	84,78	469,10	469,83	60,8	46,7	554,9	18,11%	504,0	7,27%	122,0	61,0	54,0	39,0	51,0	1,0	70,0	471,9	0,44%	[250,252]
83	114,45	93,90	85,36	468,80	469,53	57,2	47,0	528,4	12,53%	480,3	2,30%	115,0	57,0	54,0	40,0	48,0	0,0	67,0	442,3	5,81%	[259,271]
84	121,40	92,23	84,73	467,00	467,72	60,7	46,1	540,7	15,60%	496,7	6,20%	122,0	61,0	53,0	39,0	51,0	3,0	68,0	455,5	2,60%	[259,257]
85	122,60	102,12	89,42	460,66	461,35	61,3	51,1	669,4	45,11%	586,2	27,06%	123,0	61,0	54,0	41,0	53,0	4,0	66,0	475,0	2,96%	[258,257]
86	121,42	93,03	81,52	456,30	456,96	60,7	46,5	550,2	20,41%	482,1	5,51%	122,0	61,0	54,0	39,0	54,0	3,0	65,0	471,9	3,26%	[271,255]
87	113,67	103,42	93,02	455,00	455,66	56,8	51,7	636,6	39,71%	572,6	25,66%	114,0	57,0	55,0	46,0	51,0	2,0	61,0	470,5	3,25%	[259,271]
88	112,58	94,21	84,81	450,70	451,33	56,3	47,1	523,2	15,92%	471,0	4,35%	112,0	56,0	55,0	40,0	50,0	2,0	60,0	449,7	0,36%	[262,256]
89	113,43	104,03	93,13	448,95	449,57	56,7	52,0	642,8	42,97%	575,4	27,99%	113,0	56,0	52,0	52,0	52,0	1,0	60,0	446,0	0,80%	[258,263]
90	112,34	94,77	84,91	444,70	445,30	56,2	47,4	528,3	18,64%	473,3	6,29%	112,3	56,0	55,0	41,0	51,0	3,0	58,3	451,1	1,31%	[265,258]
91	121,24	102,68	91,72	444,60	445,20	60,6	51,3	669,3	50,34%	597,9	34,29%	121,0	60,0	52,0	49,0	55,0	4,0	62,0	463,1	4,02%	[267,263]
92	111,46	101,35	93,12	442,18	442,77	55,7	50,7	599,5	35,39%	550,8	24,40%	111,0	55,0	56,0	45,0	51,0	2,0	58,0	465,8	5,19%	[248,270]
93	120,08	93,54	83,62	440,40	440,98	60,0	46,8	550,1	24,75%	491,8	11,52%	120,0	60,0	54,0	39,0	54,0	4,0	62,0	464,1	5,25%	[252,239]
94	110,39	92,33	84,90	438,00	438,57	55,2	46,2	492,7	12,35%	453,1	3,31%	110,0	55,0	54,0	38,0	50,0	3,0	57,0	424,4	3,22%	[254,250]
95	109,49	101,21	90,29	431,78	432,31	54,7	50,6	587,2	35,84%	523,9	21,18%	110,0	55,0	54,0	47,0	51,0	2,0	57,0	443,2	2,51%	[270,267]
96	108,44	92,20	82,32	427,70	428,21	54,2	46,1	482,7	12,72%	430,9	0,64%	109,0	54,0	55,0	38,0	49,0	2,0	58,0	431,8	0,83%	[249,255]
97	115,34	98,03	92,49	426,13	426,63	57,7	49,0	580,4	36,03%	547,6	28,34%	115,0	57,0	51,0	47,0	48,0	1,0	66,0	418,9	1,81%	[254,259]
98	118,84	99,65	89,11	424,41	424,90	59,4	49,8	617,9	45,42%	552,5	30,04%	119,0	59,0	50,0	50,0	51,0	0,0	68,0	434,4	2,24%	[259,269]
99	114,23	89,30	84,32	422,10	422,58	57,1	44,7	477,0	12,87%	450,4	6,57%	114,0	57,0	53,0	37,0	52,0	2,0	60,0	423,5	0,21%	[257,255]
100	117,70	90,78	81,24	420,40	420,87	58,9	45,4	507,9	20,67%	454,5	7,99%	117,0	58,0	52,0	39,0	56,0	3,0	58,0	418,0	0,68%	[267,259]

A Tabela 4.2-2 apresenta os valores finais dos parâmetros e finalmente, a Tabela 4.2-3 apresenta os erros médios entre os valores medidos e os valores obtidos a partir do presente método.

Tabela 4.2-2: Valores históricos extraídos do sistema.

Dimensões (mm)	p/2	b	c	d	e
Mínimo	54,5	37,0	47,0	0,0	57,0
Máximo	73,0	61,0	66,0	6,0	79,0
Média	61,8	45,6	53,6	3,2	67,3
Desvio padrão	3,8	4,8	3,9	1,3	5,0

Tabela 4.2-3: Valores das médias calculada para o volume.

Erro	V_P1	V_P2	VP_3
Erro médio	27,12%	16,25%	3,44%
Desvio padrão	0,13	0,11	0,019

## 4.2.1.3. Outros dados fornecidos pelo sistema

Pode-se definir uma relação de rendimento entre os componentes da manga, que é uma medida de interesse para o processo pós-colheita. A relação entre a massa da polpa e a massa da manga (Tabela 4.2-4) é um indicativo interessante para a escolha de variedades que permitam maior produção de polpa por unidade de massa, por exemplo.

Essa informação é da maior importância, pois além da estimativa contábil da massa da polpa durante o processo de seleção, a informação da massa dos resíduos do processamento da manga se torna interessante ao considerar que esses materiais se apresentam hoje como potenciais fontes de antioxidantes, sendo de interesse da indústria de alimentos, onde são utilizados em substituição aos antioxidantes sintéticos. Outra aplicação interessante desses produtos é na elaboração de alimentos funcionais ou de fitoterápicos (RIBEIRO *et al.*, 2006).

**Tabela 4.2-4:** Aproveitamento da manga *Tommy Atkins*.

#	Massa da Manga (G)	Massas das partes (g)			Perda no processo destrutivo		Massa das partes (%)		
		Casca	Polpa	Caroço	(g)	%	Casca	Polpa	Caroço
1,00	750,93	103,67	565,89	72,59	-8,78	-0,01	0,14	0,75	0,10
2,00	748,13	95,42	555,34	89,36	-8,01	-0,01	0,13	0,74	0,12
3,00	718,64	94,48	532,67	84,74	-6,74	-0,01	0,13	0,74	0,12
4,00	674,42	93,48	493,24	81,59	-6,11	-0,01	0,14	0,73	0,12
5,00	573,02	88,93	403,77	74,78	-5,54	-0,01	0,16	0,70	0,13
6,00	583,59	88,73	427,12	62,46	-5,28	-0,01	0,15	0,73	0,11
7,00	396,18	68,84	269,97	49,29	-8,07	-0,02	0,17	0,68	0,12
8,00	397,34	69,84	269,97	51,54	-5,98	-0,02	0,18	0,68	0,13
9,00	742,17	100,83	559,70	71,68	-9,97	-0,01	0,14	0,75	0,10
10,00	748,01	99,00	559,02	88,24	-1,75	0,00	0,13	0,75	0,12
11,00	710,53	92,75	526,11	83,75	-7,92	-0,01	0,13	0,74	0,12
12,00	669,91	93,88	488,93	79,91	-7,19	-0,01	0,14	0,73	0,12
13,00	570,03	92,53	393,85	76,18	-7,48	-0,01	0,16	0,69	0,13
14,00	267,59	87,50	110,52	61,73	-7,84	-0,03	0,33	0,41	0,23
15,00	393,33	69,84	267,25	48,67	-7,57	-0,02	0,18	0,68	0,12
16,00	393,21	71,11	266,21	50,85	-5,05	-0,01	0,18	0,68	0,13
17,00	733,17	100,91	552,20	70,88	-9,18	-0,01	0,14	0,75	0,10
18,00	728,45	94,89	540,20	86,60	-6,76	-0,01	0,13	0,74	0,12
19,00	703,91	92,77	520,29	82,73	-8,13	-0,01	0,13	0,74	0,12
20,00	661,65	92,60	483,81	78,99	-6,25	-0,01	0,14	0,73	0,12
21,00	562,45	90,76	390,08	75,45	-6,16	-0,01	0,16	0,69	0,13
22,00	264,74	86,25	109,40	60,90	-8,20	-0,03	0,33	0,41	0,23
23,00	386,36	68,22	263,76	48,49	-5,89	-0,02	0,18	0,68	0,13
24,00	575,67	90,59	400,66	77,80	-6,62	-0,01	0,16	0,70	0,14
25,00	588,81	87,99	431,86	63,10	-5,86	-0,01	0,15	0,73	0,11
26,00	404,36	71,39	277,67	50,49	-4,82	-0,01	0,18	0,69	0,12
27,00	402,75	70,52	271,92	52,14	-8,16	-0,02	0,18	0,68	0,13
28,00	745,57	101,22	563,48	73,45	-7,42	-0,01	0,14	0,76	0,10
29,00	747,88	98,10	551,41	88,90	-9,47	-0,01	0,13	0,74	0,12
30,00	715,50	92,57	528,44	86,86	-7,62	-0,01	0,13	0,74	0,12
Média	<b>585,28</b>	<b>88,32</b>	<b>419,16</b>	<b>70,80</b>	<b>-6,99</b>	<b>-0,01</b>	<b>0,16</b>	<b>0,70</b>	<b>0,13</b>

Durante a fase de coleta de dados para os procedimentos do método de estimação de propriedades físicas, um lote de trinta mangas, separados do lote original do experimento da seção (3.2.3) para a aferição da massa das mangas e de suas partes constituintes: a superfície, a polpa e o caroço. A aferição desses valores torna esse procedimento destrutivo, já que essas partes devem ser pesadas separadamente.

O procedimento foi realizado uma única vez, quando o lote se encontrava com seis dias de armazenamento em estante. Embora a pesagem tenha sido realizada com o máximo de cuidado, perdas são verificadas durante o processo, principalmente pela aderência do sumo da fruta às mãos e aos equipamentos utilizados na pesagem (facas, containers, etc).

Os resultados obtidos na estimação da massa das partes da manga foram comparados ao levantamento realizado por COSTA *et al.* (2002), onde foi analisada a relação de massa entre as partes constituintes de 14 diferentes variedades de mangas provenientes do banco de germoplasmas da Embrapa Semi-Árido, instalado no Campo Experimental de Mandacaru, em Juazeiro, BA. A Tabela 4.2-5 foi extraída dessa pesquisa.

**Tabela 4.2-5:** Aproveitamento da manga *Tommy Atkins*. Fonte: Extraído de COSTA *et al.* (2002).

Variedade	PMF (g)	CF (cm)	LF (cm)	%CASCA	%CAROÇO	%POLPA
Maçã	206,8	6,6	7,8	12,4	13,4	74,1
Palmer	600,0	12,6	8,7	13,3	9,6	77,1
Zill	274,5	9,6	6,8	11,5	11,3	77,2
Kensington	354,3	9,8	8,4	12,3	14,0	73,7
Manzanillo	681,1	9,4	8,3	11,8	8,8	79,4
Black Java	386,1	7,7	7,4	10,4	9,4	80,2
Kent	657,2	11,7	10,2	9,6	11,5	78,8
Keitt	610,0	13,0	9,6	13,7	15,8	70,5
<b>T. Atkins</b>	<b>484,7</b>	<b>10,6</b>	<b>9,3</b>	<b>14,4</b>	<b>13,1</b>	<b>72,5</b>
Ametista	465,4	9,1	9,5	9,2	10,3	80,5
Momi-k	433,0	12,3	8,7	11,7	9,5	78,8
Smith	483,4	13,0	8,5	11,0	10,1	78,9
Ruby	249,6	10,1	6,7	12,8	16,4	70,8
Espada Ouro	307,0	10,3	6,8	11,5	13,1	75,4
Média	442,4	10,4	8,3	11,8	11,9	76,3
Mínimo	206,8	6,6	6,7	9,2	8,8	70,5
Máximo	681,1	13,0	10,2	14,4	16,4	80,5
Desvio Padrão	154,5	1,9	1,1	1,5	2,5	3,4

A Tabela 4.2-6 apresenta a correlação estabelecida entre os valores mensurados em Laboratório através da análise de 30 mangas (Tabela 4.2-4) e a aproximação com os valores obtidos em um experimento similar realizado por COSTA *et al.* (2002), apresentados em destaque na Tabela 4.2-5, com boa aproximação.

**Tabela 4.2-6:** Diferença dos percentuais de massa da manga *Tommy Atkins*.

Fonte de dados	Percentuais calculados		
	Casca	Polpa	Caroço
Tabela 5.2.8 <sup>25</sup>	16,0	70,0	13,0
Tabela 5.1.9	14,4	72,5	13,1
Diferença numérica	1,6	-2,5	-0,1

A Tabela 4.2-7 apresenta a estimaco da massa da polpa e dos resduos da manga para o experimento, realizada pelo sistema, com suas totalizaoes.

**Tabela 4.2-7:** Estimaco da massa das partes componentes da manga.

Valores Estimados				
#	Volume	Casca	Polpa	Caroço
1	792,1	126,73	554,45	102,97
2	782,4	125,19	547,69	101,71
3	727,0	116,32	508,89	94,51
4	725,7	116,11	508,00	94,34
5	729,2	116,67	510,42	94,79
6	713,2	114,10	499,21	92,71
7	675,4	108,07	472,80	87,81
8	630,4	100,87	441,29	81,95
9	682,6	109,21	477,80	88,73
10	645,6	103,30	451,94	83,93
11	638,0	102,09	446,63	82,95
12	670,0	107,20	469,01	87,10
13	641,5	102,65	449,08	83,40
14	633,3	101,33	443,32	82,33
15	647,3	103,57	453,13	84,15
16	644,1	103,06	450,89	83,74
17	649,0	103,84	454,29	84,37
18	635,1	101,62	444,57	82,56
19	626,7	100,28	438,71	81,47
20	653,9	104,62	457,71	85,00
21	626,8	100,28	438,74	81,48
22	640,0	102,40	448,00	83,20
23	607,5	97,20	425,23	78,97
24	647,5	103,60	453,26	84,18
25	585,7	93,71	409,99	76,14
26	616,7	98,67	431,69	80,17
27	598,3	95,72	418,79	77,77
28	567,4	90,78	397,16	73,76
29	604,0	96,64	422,81	78,52
30	608,3	97,33	425,80	79,08

<sup>25</sup> Os valores no integram 100% devido a ocorrncia de perdas que totalizaram em mdia 1%.

Continuação...

Tabela 4.2-7: Estimação da massa das partes componentes da manga.

Valores Estimados				
#	Volume	Casca	Polpa	Caroco
31	603,8	96,61	422,68	78,50
32	574,8	91,97	402,36	74,72
33	618,1	98,89	432,66	80,35
34	597,1	95,53	417,94	77,62
35	595,1	95,22	416,60	77,37
36	546,1	87,37	382,24	70,99
37	610,1	97,62	427,08	79,32
38	547,9	87,67	383,54	71,23
39	556,2	89,00	389,37	72,31
40	585,6	93,70	409,95	76,13
41	589,7	94,36	412,82	76,67
42	528,2	84,51	369,72	68,66
43	523,0	83,68	366,11	67,99
44	534,4	85,50	374,06	69,47
45	569,1	91,05	398,34	73,98
46	558,2	89,31	390,72	72,56
47	546,1	87,38	382,29	71,00
48	549,1	87,86	384,37	71,38
49	503,4	80,55	352,40	65,45
50	553,5	88,56	387,45	71,96
51	501,5	80,24	351,07	65,20
52	527,1	84,33	368,96	68,52
53	491,6	78,65	344,11	63,91
54	555,2	88,84	388,66	72,18
55	535,7	85,71	375,00	69,64
56	490,6	78,49	343,41	63,78
57	561,9	89,91	393,36	73,05
58	493,2	78,92	345,27	64,12
59	483,4	77,34	338,35	62,84
60	489,2	78,27	342,41	63,59
61	533,0	85,27	373,07	69,28
62	543,4	86,95	380,41	70,65
63	533,0	85,27	373,07	69,28
64	503,4	80,55	352,40	65,45
65	477,1	76,33	333,95	62,02
66	526,9	84,31	368,85	68,50
67	532,0	85,12	372,42	69,16
68	530,3	84,84	371,18	68,93
69	467,2	74,76	327,07	60,74
70	479,7	76,74	335,76	62,36



Continuação...

Tabela 4.2-7: Estimação da massa das partes componentes da manga.

Valores Estimados				
#	Volume	Casca	Polpa	Caroço
71	521,0	83,36	364,68	67,73
72	510,9	81,74	357,60	66,41
73	499,6	79,93	349,69	64,94
74	467,7	74,83	327,36	60,80
75	454,9	72,78	318,43	59,14
76	466,6	74,65	326,61	60,66
77	489,8	78,37	342,86	63,67
78	499,9	79,98	349,92	64,99
79	484,8	77,57	339,38	63,03
80	470,9	75,34	329,63	61,22
81	495,4	79,26	346,75	64,40
82	471,9	75,50	330,31	61,34
83	442,3	70,76	309,58	57,49
84	455,5	72,89	318,88	59,22
85	475,0	76,00	332,51	61,75
86	471,9	75,50	330,31	61,34
87	470,5	75,27	329,32	61,16
88	449,7	71,96	314,81	58,46
89	446,0	71,36	312,19	57,98
90	451,1	72,18	315,79	58,65
91	463,1	74,10	324,17	60,20
92	465,8	74,52	326,03	60,55
93	464,1	74,26	324,90	60,34
94	424,4	67,91	297,11	55,18
95	443,2	70,90	310,21	57,61
96	431,8	69,08	302,23	56,13
97	418,9	67,03	293,24	54,46
98	434,4	69,51	304,10	56,48
99	423,5	67,76	296,44	55,05
100	418,0	66,88	292,62	54,34

#### **4.2.2. Discussão sobre os métodos de avaliação pela forma**

A avaliação da manga Tommy Atkins pela forma foi realizada neste trabalho através da implementação de métodos que permitem a estimação do volume, e em função desse parâmetro, a massa da fruta, que pode ainda ser extratificada em termos de seus componentes: a casca, a polpa e o caroço.

Os mecanismos de análise de imagens foram emprestados dos desenvolvidos para a análise da cor. Pode ser verificado nesse estudo, que os problemas referentes ao efeito “fade” e outros, não representaram nenhum obstáculo na interpretação dos dados de interesse.

A resolução dos equipamentos empregados na análise de cores é muitas vezes superior àquela que é suficiente para estimar o volume, por exemplo. Por esse motivo, a utilização de vídeo pode ser empregada sem maiores problemas, com consequente aumento na velocidade e diminuição da memória de trabalho.

Os algoritmos para o cálculo do volume representaram uma das partes mais interessantes da abordagem, onde podemos concluir, com base inclusive nos trabalhos apresentados na revisão da literatura, que devido à diversidade geométrica particular de cada fruta, torna-se necessário desenvolver modelos individuais para estimação, inclusive para uma mesma espécie de produto agrícola, que pode apresentar diferenças entre suas diversas cultivares.

Considerando o modelo geométrico utilizado, foi possível desenvolver um método para a indicação da orientação do eixo principal em relação ao pedúnculo da manga; essa informação se torna útil num sistema de embalagens, onde a manga pode ser alocada num receptáculo com orientação uniforme, não apenas em relação ao pedúnculo, mas também em relação à sua base dorsal.

Embora não tenha sido desenvolvido neste trabalho, as alturas dos ombros da manga podem ser estimadas; isso constitui num novo parâmetro para a estimação da maturidade da fruta no pomar, podendo ser um indicador para o ponto de colheita da fruta.

No decorrer dos estudos que substanciaram este trabalho, vários métodos foram desenvolvidos para a estimação do volume, onde apenas aquele que apresentou maior aproximação foi implementado. É fato notório a dificuldade existente na estimação do volume da manga Tommy Atkins, dada à sua excentricidade característica, mas a abordagem de considerar os diferentes volumes de cada lado da fruta se mostrou muito eficiente, com boa aproximação das análises realizadas em laboratório.

## 5. CONCLUSÕES E TRABALHOS FUTUROS

### 5.1. Conclusões

#### 5.1.1. Avaliação pela cor

A ampla disponibilidade de dispositivos para captura de imagens digitais tem lançado novos desafios para a área de processamento de imagem, sobretudo nos processos de detecção de objetos e padrões; isso tem permitido a expansão da investigação científica e o desenvolvimento de diversas aplicações, como os sistemas de classificação automatizada, classificação de produtos, diagnóstico de doenças em animais e plantas, etc.

Ao final deste trabalho, foi possível deduzir de maneira conclusiva, que a construção de um sistema automático para classificar mangas e outras frutas pela análise das cores das suas superfícies, tarefa que é reconhecidamente extenuante e repetitiva quando realizada por humanos, é viável; isso porque o sistema substitui a atividade humana penosa por atividades mais elevadas, como a de supervisão, além da tecnologia utilizada ser implementada com baixo custo, proporcionando a melhoria do processo pós-colheita da manga *Tommy Atkins* e de outros frutos, que porventura venham a ser inseridos no sistema.

Os resultados advindos dos sistemas desenvolvidos neste trabalho mostram que para os lotes de manga *Tommy Atkins* analisados, a classificação segundo padrões de cores obteve um ótimo desempenho, com taxas de acerto equivalente ao especialista humano e superior aos métodos apresentados na revisão da literatura.

O mecanismo de avaliação desenvolvido é de natureza indutiva, ou seja, aprende com sua própria experiência; logo, espera-se que a resposta do sistema seja melhorada à medida em que seja utilizado.

Manchas ou pontos pretos sobre a superfície da manga e de outras frutas representam uma grande preocupação para a indústria e para o comércio desses produtos; várias pesquisas estão sendo desenvolvidas utilizando os mais diversos métodos não destrutivos para a sua detecção.

A estimação da área afetada por manchas negras pôde ser realizada através do mecanismo desenvolvido neste trabalho, por meio de um método simples, que emprega a limiarização das componentes Saturação e Luminosidade do modelo de cor HSL, independente do Matiz, para contabilizar pixels cujos níveis dessas componentes estejam abaixo dos limiares que permitem a percepção da cor.

A ocorrência de um evento específico cuja repercussão se apresenta como pontos pretos não pode ser identificada, pois o sistema apenas calcula a área da superfície que possui pontos pretos, não sendo capaz de inferir sobre possíveis relações causa-efeito.

A precisão obtida pelo de detecção de manchas negras em relação aos resultados obtidos pelo agente humano foi aproximada ao máximo, a partir de um único exemplo, fornecendo a configuração inicial para os valores dos limiares de S e L; aplicado de maneira indutiva para novas amostras, foi verificado que a precisão alcançou um patamar muito alto, superior a 99%. Isso demonstra a viabilidade do emprego do sistema.

Os sistemas baseados em lógica *fuzzy* são já reconhecidos como importantes ferramentas para o tratamento de incertezas, pois conseguem representar e manipular a subjetividade dos fenômenos do mundo real com boa aproximação da interpretação natural humana.

Este trabalho inclui um mecanismo baseado em regras *fuzzy* construídas a partir de heurísticas compiladas de vários trabalhos científicos sobre a correlação entre as cores da superfície da manga *Tommy Atkins* e do seu estágio de maturidade, que implementa um mecanismo de decisão sobre uma variável adstrita de grande imprecisão: a maturidade da manga; com base nas cores da sua superfície, a partir de regras heurísticamente definidas, o mecanismo é capaz de estimar o grau de pertinência da fruta a um determinado estado de maturidade, expresso por uma variável linguística.

Os resultados obtidos asseguram que o mecanismo pode ser utilizado em um sistema de seleção automático, sendo que a sua confiabilidade está diretamente vinculada às regras heurísticas definidas; sendo assim, este sistema pode ser definido como um SBR – Sistema Baseado em Regras (seção 2.3.3); uma vez que as regras sejam suficientes para estabelecer uma saída correta relação entre entrada e saída, o sistema funcionará de acordo. Sistemas construídos com variáveis desse tipo são especialmente interessantes porque permitem uma adaptação objetiva aos mais diversos jargões ou especificidades linguísticas, humanizando de certa maneira, a interface com o usuário.

### **5.1.2. Avaliação pela forma**

Foi apresentado neste trabalho, um método não destrutivo que utiliza imagens para avaliar automaticamente a manga *Tommy Atkins*, estimando alguns dos seus mais importantes parâmetros físicos, com base na abordagem de aprendizagem de máquina. Um conjunto de programas de computador (sistema) foi desenvolvido para calcular os valores dos eixos principais e secundários dessas mangas, estimando seus volumes e suas massas, que são

parâmetros relevantes para os processos de seleção. O método se mostrou viável, com a fórmula desenvolvida para estimação do volume, vindo a apresentar boas aproximações dos valores reais, comparável e em alguns casos superior aos métodos mais eficientes até então desenvolvidos para esse fim. Outro resultado emitido pelo sistema é a estimação da massa da polpa da manga e de seus resíduos, além da informação da orientação do pedúnculo em relação ao eixo principal da fruta, que pode ser aplicada em processos de embalagem da manga em um recipiente do tipo de caixa, adaptada para receber as mangas alinhadas de maneira uniforme. Uma máquina para classificar mangas automaticamente, utilizando este método, já está sendo construída; com algumas pequenas extensões, poderá ser possível estender este método para avaliar outras frutas.

## **5.2. Trabalhos futuros**

### **5.2.1. Avaliação pela cor**

Os resultados obtidos neste trabalho são suficientes para instigar a construção um sistema de automação industrial dotado de esteiras para classificar mangas pela cor, empregando seus mecanismos de decisão.

Uma evolução interessante para este trabalho seria o desenvolvimento de um sistema de comunicação entre os bancos de conhecimentos das máquinas remotamente localizadas, de maneira que esses pudessem trocar experiências, formando uma sociedade de agentes classificadores.

Outro trabalho possível seria a utilização de imagens de baixa resolução, que como foi visto, pode ser suficiente para a decisão. Com o uso de dispositivos de vídeo de rádio frequência (RF), seria possível não apenas reduzir ainda mais os custos de construção de um equipamento de avaliação, mas também aumentar sua velocidade de operação.

Além disso, existe a possibilidade de a utilização do sistema desenvolvido para avaliação de outras frutas, iniciando por outras cultivares da manga e seguindo para classificar outras drupas.

O mecanismo para detecção de manchas negras pode evoluir para identificar alguns eventos associados aos parâmetros da cor detectada; por exemplo, o ataque do patógeno *Alternaria alternata* está associada à presença da cor marrom, como pode ser visto em BATISTA (2010); danos físicos como machucões podem escurecem a cor da região atingida.

Assim, um sistema de identificação de agentes específicos que atacam a manga e outros frutos, é um projeto a ser desenvolvido.

Finalmente, os resultados obtidos pelo sistema de estimação de maturidade por lógica fuzzy sugerem a exploração de novos projetos baseados no uso de sistemas de visão associados a sistemas de decisão baseados nessa lógica. A construção um “*Backlog*” de fuzzificadores e defuzzificadores adequados às várias espécies e variedades de frutas é sem dúvida uma ideia promissora.

### **5.2.2. Avaliação pela forma**

A manga Tommy Atkins é reconhecidamente uma fruta de formas irregulares, quando comparadas a outras mangas; mesmo assim, a avaliação da geometria desta fruta permitiu a estimação de seus principais atributos físicos a partir de imagens com uma boa aproximação. Uma *backlog* de informações sobre a geometria de outros frutos poderia ser adaptado ao método aqui desenvolvido para avaliação pela forma, permitindo que o referido sistema viesse a ser empregado na avaliação de outras frutas.

Uma ideia desenvolvida durante a avaliação da geometria da manga e que pode derivar um trabalho que venha a estender o método aqui implementado, é o desenvolvimento de uma linguagem para descrição geométrica (LDG) de frutos e outros produtos agrícolas, ou mesmo a construção de uma sublinguagem ou biblioteca de funções para uma LDG já existente para suportar esta aplicação.

## 6. BIBLIOGRAFIA

ABBOTT, J. A.: Quality measurement of fruits and vegetables. **Postharvest Biology and Technology**, v. 15, p. 207-225, 1999.

ABDULLAH, M. Z.; MOHAMAD-SALEH, J.; FATHINUL-SYAHIR, A. S.; MOHD-AZEMI, B. M. N.: Discrimination and classification of fresh-cut starfruits (averrhoa carambola l.) using automated machine vision system. **Journal of Food Engineering**, v. 76, p.506-523, 2006.

ADHIMANTORO, S.; GAOL, F. L: Application of ultrasonic and fuzzy logic to determine fruit maturity level. **International Journal of Control and Automation** v.7, n.1, p. 27-38, 2014.

AGUDELO-LAVERDE, L. M.; SCHEBOR, C.; BUERA, M. D. P.: Water content effect on the chromatic attributes of dehydrated strawberries during storage, as evaluated by image analysis, **Food Science and Technology**, London, v. 55, n. 2, p. 157-152, 2013.

ALAVI, N.: Date grading using rule-based fuzzy inference system. **Journal of Agricultural Technology**, v.8, n.4, p. 1243–1254, 2012.

ALMEIDA, D. **Maturação e data de colheita - Curso de tecnologia pós-colheita e processamento mínimo de produtos hortofrutícolas**. Instituto Superior de Agronomia – Lisboa, 2007. Disponível na URL: <<http://estudos.universia.net/portugal /curso/uti-tecnologia-pos-colheita-processamento-minimo-produtos-hortofruticolos-qualidade-seguranca>>. Acesso em janeiro de 2013.

AMORIM, T. B. F. Colheita e pós-colheita: manejo e conservação da manga. In: SÃO JOSÉ, A. R. (Org.). O agronegócio manga: produção e mercado. **Anais do I Simpósio Latino Americano sobre Produção de Manga**, (1999), Vitória da Conquista: UESB/DFZ, 2002. p. 346-356.

AOCS - AMERICAN OIL CHEMISTS SOCIETY. **Official methods and recommended practices of the American oil Chemists Society**. 5.ed. Champaign, IL: AOCS, v. I, 1997.

ARCE-LOPERA, C.; MASUDA, T.; KIMURA, A.; WADA, Y.; OKAJIMA, K. Luminance distribution as a determinant for visual freshness perception: evidence from image analysis of a cabbage leaf. **Food Quality and Preference**, v. 27, n. 2, p. 202-207, 2012.

ARENAS-RÍOS, M. **Estudo Cartografia geotécnica e visões fractais da geometria do relevo**. 2012. Dissertação (Mestrado em Engenharia Civil e Ambiental), Publicação G.DM-001A/90, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF.

ARIANA, D.; GUYER, D.; SHRESTHA, B. Integrating multispectral reflectance and fluorescence imaging for defect detection on apples. **Computers and Electronics in Agriculture**, vl. 50, n. 2, p. 148-161, 2006a.

ARIANA, D.; LU, R.; GUYER, D. Near-infrared hyperspectral reflectance imaging for detection of bruises on pickling cucumbers. **Computers and Electronics in Agriculture**, v. 53, n. 2, p. 60-70, 2006b.

ASSIS, J. S., FETT, M. S., LIMA, M. A. C., CANTILLANO, R. F. F, SELF, G. **Elaboração e difusão das normas da produção integrada da manga no Brasil: Colheita e pós-colheita**. EMBRAPA Semi-Árido, 2008.

ATENCIO, P.; SÁNCHEZ, T. Z.; BRANCH, J. W.: **Automatic visual model for classification and measurement of the quality of fruit: Case *Mangifera indica* L.** Dyna, Nro. 160, p. 317-326. Medellín, Colombia, 2009.

AWAD, M.: **Fisiologia pós-colheita de frutos**. São Paulo: Ed. Nobel, 1993.

AWETA EQUIPMENT, **Acoustic Firmness Sorter (AFS)**. Italy. Disponível na URL: <http://www.aweta.nl/index.php>. Acessado em março de 2013.

BAPTISTA, E.: Resolução de imagens digitais - Coluna Fique Ligado, **Revista Zoom Magazine** - Views Imagem & Comunicação Ltda - 2012. Disponível em: [http://www.fazendovideo.com.br/vtart\\_024.asp](http://www.fazendovideo.com.br/vtart_024.asp). Acesso em: outubro de 2013.

BARBOSA, F. R.; MOREIRA, A. N.; HAJI, F. N. P.; ALENCAR, J. A. **Monitoramento de pragas na cultura da mangueira**. Petrolina: Embrapa Semiárido, 2001.

BARBOSA, F. R.; PARANHOS, B. A. J. Artrópodes-praga associados à cultura da mangueira no Brasil e seu controle. In: MENEZES, E. A.; BARBOSA, F. R. **Pragas da**



**mangueira: monitoramento, nível de ação e controle.** Petrolina: Embrapa Semi Árido, 2005.

BARBOSA, F. R: Manejo integrado de pragas da mangueira. SEMINÁRIO DE MANGAS DO VALE DO SÃO FRANCISCO, 1. Embrapa Semi-Árido. Petrolina. **Anais di I Simpósio de Manga do Vale do São francisco.** Disponível na URL: <http://www.agencia.cnptia.embrapa.br/recursos/OPB136ID-KknonkV9xQ.pdf>; Acesso em janeiro de 2013.

BARNES, M.; DUCKETT, T.; CIELNIAK, G.; STROUD, G.; HARPER, G. Visual detection of Blemishes in potatoes using minimalist boosted classifiers. **Journal of Food Engineering**, v. 98, p. 339-346, 2010.

BATISTA, D. C.: **Cultivo da mangueira - Doenças.** Embrapa Semiárido - Sistemas de Produção, 2 - 2ª edição. Versão Eletrônica, Ago/2010. Disponível em: [http://sistemasdeproducao.cnptia.embrapa.br/FontesHTML/Manga/CultivodaMangueira\\_2ed/doencas.htm](http://sistemasdeproducao.cnptia.embrapa.br/FontesHTML/Manga/CultivodaMangueira_2ed/doencas.htm). Acesso em: março de 2014.

BEHLING, E. B.; SENDÃO, M. C.; FRANCESCATO, H. D. C.; ANTUNES, L. M. G.; BIANCHI, M. L. P.: Flavonoid quercetin: general aspects and biological actions. **Revista Alimentação e Nutrição**, Araraquara, v. 15, n.3, 2004.

BELLMAN, R. **An introduction to artificial intelligence - Can computers think?** Boyd & Fraser Ed. San Francisco – CA, 1978.

BENDER, R. J., BRECHT J. K.; BALDWIN, E.A.; MALUDO, T. M. M. Aroma volatiles of mature-green and tree-ripe ‘Tommy Atkins’ mangoes after controlled atmosphere vs. air storage. **HortScience Magazine**, v. 35, p.684-686, 2000.

BENDER, T. C.: **Classificação e recuperação de imagens por cor utilizando técnicas de inteligência artificial.** 2003. Dissertação (Mestrado em Computação) – UNISINOS, Departamento de Computação, São Leopoldo.

BENEDETTI, S.; BURATTI, S.; SPINARDI, A.; MANNINO, S.; MIGNANI, E. Electronic nose as a non-destructive tool to characterize peach cultivars and to monitor their ripening stage during shelf-life. **Postharv. Biol. and Tech. Magazine**, v.47, p. 299-305. 2008.

BERMÚDEZ, A. M.; PADILLA, D. B.; TORRES, G. S. Image analysis for automatic feature estimation of the *Mangifera indica* fruit. **Ingenueria y Desarrollo**. Universidad del Norte Magdalena. v.31, n. 1, p. 84-104, 2012.

BIALE, J.B.; YOUNG, R. E.: Growth, maturation and senescence in fruits. **Science**. Washington, v. 146. n. 36-46, 1964.

BLASCO, J.; ALEIXOS, N.; CUBERO, S.; JUSTE, F. GÓMEZ-SANCHIS, J.; ALEGRE, V.; MOLTÓ, E. Computer vision developments for the automatic inspection of fresh and processed fruits. **Bornimer Agrartechnische Berichte**, Heft 69, Leibniz-Institut für Agrartechnik Potsdam-Bornim, 2009.

BLASCO, J.; ALEIXOS, N.; GOMEZ, J.; MOLTO, E. Citrus sorting by identification of the most common defects using multispectral computer vision. **Journal of Food Engineering**, Essex, v. 83, n. 3, p. 384-393, 2007b.

BLASCO, J.; ALEIXOS, N.; MOLTO, E. Computer vision detection of peel defects in citrus by means of a region oriented segmentation algorithm. **Journal of Food Engineering**, Essex, v. 81, n. 3, p. 535-543, 2007a..

BORGES, F. F.: **Fusão de sensores de baixo custo aplicada à seleção e classificação automatizada de mangas para exportação**. 2011. Tese (Doutorado em Engenharia de Processos). Universidade Federal de Campina Grande, Campina Grande.

BRANQUINHO, J.; MURCHO, D. E.; GOMES, N. G. **Enciclopédia de termos lógico-filosóficos**, São Paulo: Ed. Martins Fontes, 2006.

BREZMES, J.; LLOBET, E.; VILANOVA, X.; ORTS, J.; SAIZ, G.; CORREIG, X. Correlation between electronic nose signals and fruit quality indicators on shelf-life measurements with Pink Lady apples. **Sensors and Actuators B: Chemical**. Elsevier, v. 80, p. 41-50, 2001.

BROISLER, P. P.: **Simulação do transporte de mangas irradiadas para exportação**. Dissertação (Mestrado em Aplicações de Tecnologia Nuclear) IPEN – USP, 2007.

BROSNAN, T.; SUN, D.W.: Improving quality inspection of food products by computer vision - A review. **Journal of Food Engineering**. v. 61, p. 3-16, 2004.

BULANON, D. M.; BURKS, T. F.; KIM, D. G.; RITENOUR, M. A. Citrus black spot detection using hyperspectral image analysis. **Agric. Eng. Int. CIGR Journal**, v.15, n.3, p. 171–180. Issued in 09/ 2013. Disponível em: <http://www.cigrjournal.org>; Acesso em: 12/2014.

BUSSAB, W. O. – **Análise de Variância e de Regressão**. Atual Editora, São Paulo, 1988.

CALBO, ADONAI G.; MORETTI, CELSO L.; HENZ, GILMAR P.: Respiração de Frutas e Hortaliças – **EMBRAPA – Comunicado Técnico # 46** - Novembro, Brasília, DF, 2007.

CAMBRIDGE: perception of color. Portal **Cambridge in Colour**. Disponível na URL: <http://www.cambridgeincolour.com/pt-br/tutorials/color-perception.htm>. Acesso em fevereiro de 2013.

CARBONELL, J. G.: Introduction: Paradigms for Machine Learning. Artificial Intelligence. **Special Volume on Machine Learning**. Ed. Carbonell, J.G. Vol 40 N° 1-3, North-Holland. 1989.

CARVALHO, A. A.: **Fundamentação Teórica para Processamento Digital de Imagens**. Monografia do Bach. em Eng. da Computação -Departamento de Ciência da Computação - Universidade Federal de Lavras - Lavras - MG, 2003.

CDME/UFF – O Sistema RGB e o Cubo de Cores: Matemática Números e Operações. **A formação das cores**. Universidade Federal Fluminense. Disponível na URL: [http://www.uff.br/cdme/matrix/matrix-html/matrix\\_color\\_cube/matrix\\_color\\_cube\\_br.html](http://www.uff.br/cdme/matrix/matrix-html/matrix_color_cube/matrix_color_cube_br.html). Acesso em novembro de 2012.

CEPSRM – UFRS - **Página Dinâmica para Aprendizado do Sensoriamento Remoto**. Disponível na URL: <http://www6.ufrgs.br/engcart/PDASR/formcor.html>. Acesso em agosto de 2013.

CHAN, L. M.; TAN, R.; THIO, G.: Design of visual-based color classification system. **Research Papers JASA 2** - 2007, p. 30-33. Disponível na URL: [http://www.researchgate.net/publication/228747127\\_Design\\_of\\_Visual-based\\_Color\\_Classification\\_System](http://www.researchgate.net/publication/228747127_Design_of_Visual-based_Color_Classification_System). Acesso em 12/2014.

CHAN, T.; F. SHEN: **Image Processing and Analysis: Variational, PDE, Wavelet, and Stochastic Methods**, Ed. SIAM, 2005

CHARNIAK E, MCDERMOTT D.: **Introduction to Artificial Intelligence**. Addison-Wesley Publishers, Reading, Massachussets, 1985.

CHEN, P.: Application of elastic theory to high-speed impact sensing of fruits. **Proceedings of the 3<sup>rd</sup> IFAC/CIGR Workshop on Control Applications in Post-Harvest and Processing Technology**. Tokyo, Japan, 2001.

CHITARRA, M. I. F.; CHITARRA, A. B. **Pós-colheita de frutas e hortaliças: fisiologia e manuseio**. 2<sup>a</sup> ed. rev. e ampl. Lavras: UFLA, 2005.

CIE: **Technical Guides on Color Models**. (1976), Disponível na URL: [http://dba.med.sc.edu/price/irf/Adobe\\_tg/models/cielab.html](http://dba.med.sc.edu/price/irf/Adobe_tg/models/cielab.html), Acesso em julho de 2012.

CORREIA, R. C.; ARAUJO, J. L.: **Cultivo da Mangueira: Mercado**. 2<sup>a</sup> edição. Versão Eletrônica, Ago/2010. Disponível na URL: [http://sistemasdeproducao.cnptia.embrapa.br/FontesTML/Manga/CultivodaMangueira\\_2ed/mercado.htm](http://sistemasdeproducao.cnptia.embrapa.br/FontesTML/Manga/CultivodaMangueira_2ed/mercado.htm). Acesso em Maio de 2013.

COSTA, C.; MENESATTI, P.; PAGLIA, G.; PALLOTTINO, F.; AGUZZI, J.; RIMATORI, V.; RUSSO, G.; RECUPERO, S.; RECUPERO, G.: Quantitative evaluation of Tarocco sweet orange fruit shape using optoelectronic elliptic Fourier based analysis. **Postharvest Biology and Technology**, v. 54, n. 1, p. 38-47, 2009.

COSTA, J.C; PAIVA, L.E.; ALMEIDA; A. S.; SOUZA, S. O.: Comparação entre Variedades de Mangueira em Relação a Características do Fruto nas Condições do Submédio do São Francisco. **Anais do VXII Congresso Brasileiro de Friticultura**, Belém – PA. 2002.

COX, E.; **The fuzzy systems handbook: a practitioner's guide to building, using, and maintaining fuzzy systems** . New York: AP Professional, 1994.

CUNHA, A. G.: **Dicionário Etimológico da Língua Portuguesa** - 4<sup>a</sup> Ed. Faperj, 2010

DADWAL, M.; BANGA, V. K.: Estimate Ripeness Level of fruits Using RGB Color Space and Fuzzy Logic Technique. **International Journal of Engineering and Advanced Technology (IJEAT)** ISSN: 2249 – 8958, v.2, Issue-1, October 2012.

DANGELO, J. G.; FATTINI, C. A.: **Anatomia Humana Sistêmica e Segmentar**, 3<sup>a</sup> edição. Editora Atheneu, Rio de Janeiro, 2011.

DAVIES, E. R.: **Machine Vision : Theory, Algorithms, Practicalities**. Morgan Kaufmann Ed., 2005.

E-FÍSICA – O olho humano. **Portal de Ensino de física on-line**. CEPA – Centro de Ensinos e Pesquisa aplicada – Departamento de física - USP. Disponível na URL: <http://efisica.if.usp.br/optica/basico/visao/olho/>. Acesso em dezembro de 2013.

EISBERG, R.; RESNICK, R.. **Física Quântica – Átomos, Moléculas, Sólidos, Núcleos e Partículas**. Editora Campus, Rio de Janeiro, 1979.

ELMASRY, G.; WANG, N.; VIGNEAULT, C.; QIAO, J.; ELSAYED, A.: Early detection of apple bruises on different background colors using hyperspectral imaging. **LWT Food Science and Technology**, London, v. 41, n. 2, p. 337-345, 2008

ELMASRY, G.; WANG, N.; VIGNEAULT, C.: Detecting chilling injury in Red delicious apple using hyperspectral imaging and neural networks - **Postharvest Biology and Technology**, Elsevier, v. 52 n. 1, p. 1-8, 2009.

EMMCH – **Enciclopédia Multimídia do Corpo Humano – Órgãos dos sentidos**, Fascículo XI. Editora Planeta De Agostini, São Paulo, 2005.

FILGUEIRAS, H. A. C.; MORAIS, P. L. D. de; ARAÚJO, E. C. E. A.; VASCONCELOS, L. F. L.; PEREIRA, M. E. C.; ALVES, R. E. Maturation of Tommy Atkins mango grown in Piauí, Brasil. In: **proceedings of the International Mango Symposium**, 7., 2002, Recife-PE, 2002. p. 311.

FILGUEIRAS, H. A. C. Manga - Pós-Colheita; Embrapa agroindústria Tropical (Fortaleza, CE), Embrapa **Comunicação para Transferência de Tecnologia**. Brasília, 2000.

GARCÍA-RAMOS, F. J.; VALERO, C.; HOMER, I.; ORTIZ-CAÑAVATE, J.; RUIZ-ALTISENT, M.: Non-destructive fruit firmness sensors: a review. **Spanish Journal of Agricultural Research**, v. 3,(1), p. 61-73, 2005.

GARDNER, H.: **Creating Minds: An Anatomy of Creativity as Seen Through the Lives of Freud, Einstein, Picasso, Stravinsky, Eliot, Graham, and Gandhi**. Basic Books Ed., New York, 1993.

GARDNER, J.; P. N. BARTLETT.: **Electronic Noses: Principles and Applications**. USA: Oxford University Press, 1999.

GAUSS, C. F.: **Disquisitiones generales circa superficies curvas**. Publicado em 1827. Livro eletrônico Disponível na URL: [http://gdz.sub.uni-goettingen.de/no\\_cache/dms/load/img/?IDDOC=139389](http://gdz.sub.uni-goettingen.de/no_cache/dms/load/img/?IDDOC=139389) Acesso: Outubro de 2013.

GELADI, P.; GRAHN, H.: **Multivariate Image Analysis**: First Edition. New York: Ltd, John Wiley & Sons, 1996.

GILL, J.; SANDHU, P. S.; SINGH, T: A Review of Automatic Fruit Classification using Soft Computing Techniques. **International Journal of Computer Science and Electronics Engineering (IJCSEE)** v. 2, Issue 2, 2014.

GINSBERG, M. L.: **Essentials of artificial intelligence**. San Mateo: Morgan Kaufmann Publishers. San Mateo, CA. 1993.

GODINHO, R.D. : Como foi inventada a fotografia?, **Revista Mundo Estranho**, Canal de Tecnologia da Abril Cultural, Edição 15. URL: <http://mundoestranho.oabril.com.br/materia/como-foi-inventada-a-fotografia>. Acesso em outubro de 2013.

GOMEZ, A.H., G.X. HU, J. WANG, AND A.G. PEREIRA. Evaluation of tomato maturity by electronic nose. **Computers and Electronics in Agriculture**. 54, 2006.

GOMEZ, A.H., J. WANG, AND A.G. PEREIRA. 2007. Mandarin ripeness monitoring and quality attribute evaluation using an electronic nose technique. **Proceedings of the ASABE - American Society of Agricultural and Biological Engineers**, St. Joseph, Michigan, 2007.

GÓMEZ-SANCHIS, J.; GOMEZ-CHOVA, L.; ALEIXOS, N.; CAMPS-VALLS, G.; MONTESINOS, C.; MOLTO, E.; BLASCO, J.: Hyperspectral system for early detection of rottenness caused by *Penicillium digitatum* in mandarins. **Journal of Food Engineering**, v. 89, n. 1, p. 80-86, 2008a.

GÓMEZ-SANCHIS, J.; MOLTÓ, E.; CAMPS-VALLS, G.; GÓMEZ-CHOVA, L.; ALEIXOS, N.; BLASCO, J.: Automatic correction of the effects of the light source on spherical objects. An application to the analysis of hyperspectral images of citrus fruits. **Journal of Food Engineering**, v. 85, n. 2, p. 191-200, 2008b.

GONZALES, R. C.; WOODS, R. E.: **Processamento Digital de Imagens – 3ª Edição**. Pearson Prentice Hall, São Paulo-SP. 2010.

GOULD, S. J.: **The Mismeasure of Men**.- Penguin Books Ed. London, 1983.

GOWEN, A.; TAGHIZADEH, M.; O'DONNELL, C.: Identification of mushrooms subjected to freeze damage using hyperspectral imaging. **Journal of Food Engineering**, Essex, v. 93, n. 1, p. 7-12, 2009.

GREEFA, **IDF firmness module**. (Manual Técnico do fabricante). GREEFA Grading Technology, Tricht, N. L. 2008. Disponível na URL: <http://www.greefa.nl>. Acesso em janeiro 2013.

GROSS, J.: **Pigments in Fruits**. London: Academic Press. 1987.

GTZ - **DEUTSCHE GESELLSCHAFT FÜR TECHNISCHE ZUSAMMENARBEIT**  
Manual de exportacion frutas tropicales y hortalizas, Eschborn, 1992.

GUILLERMIN, P.; BERTRAND, D.; CHEVALLIER, S.; KOHLER, A.: Characterisation of Fruits by Multivariate Image Analysis. UFoST World Congress, **Proceedings of the 13th World Congress of Food Science & Technology iufost** (2006) . Disponível na URL: <http://iufost.edpsciences.org/articles/iufost/pdf/2006/01/iufost06000745.pdf>, Acesso em dezembro de 2013.

HAFF, R. P.; SARANWONG, S.; THANAPASEC, W.; JANHIRANC, A.; KASEMSUMRANC, S.; KAWANO, S.: Automatic image analysis and spot classification for detection of fruit fly infestation in hyperspectral images of mangoes. **Postharvest Biology and Technology** 86 (2013), p. 23–28. Disponível na URL: <http://naldc.nal.usda.gov/naldc/download.xhtml?id=57098&content=PDF> Acesso em 12/2014.

HAUGELAND, J.: **Mind Design II: Philosophy, Psychology, Artificial Intelligence** - Cambridge, Massachussets, MIT Press, 1997.

HAUPT, R. L.; HAUPT, S. E.: **Practical Genetic Algorithms**. 2nd Edition, New York: Wiley & Sons -Interscience, 2004.

HAYKIN S. **Redes neurais: princípios e prática**. Trad. Paulo Martins Engel. - 2.ed. - Porto Alegre: Bookman, 2001.

HOUAISS, A.: **Dicionário Houaiss da Língua Portuguesa**. Rio de Janeiro Instituto Antônio Houaiss. Ed. Objetiva, 2001.

ICONTEC: **Colombian technical Standard NTC 5139, Frutas frescas. Mangos criollos. Especificaciones**, ICONTEC, Bogotá D.C, 2002.

IQBAL, S. M.; GANESAN, D.; RAO, S.: Mechanical system for on-line fruit sorting and grading using machine vision technology. **Journal of the Instrumentation Society of India**, N. 34, v. 3, p. 153-162, Madras, India, 2012

JACOBI, K.K.; MACRAE, E.A.; HETHERINGTON, S.E.: Early detection of abnormal skin ripening characteristics of 'Kensington' mango (*Mangifera indica* Linn). **Scientific Horticulture**, n. 72, p. 215–225., 1998.

KADER, A. A.: **Postharvest technology of horticultural crops**. 5th ed. Berkeley: University of California, 1992.

KANG, S.; TRUJILLO, F.: Colour vision system evaluation of bicolour fruit: a case study with 'B74' mango. **Postharvest Biology and Technology**, Amsterdam, v. 49, n. 1, p. 77-85, 2008.

KAPACH, K.; MAIRON, E. B. R.; EDAN, Y.; BEN-SHAHAR, O.: Computer vision for fruit harvesting robots: state of art and challenges ahead. **International journal of computer vision and robotics**, n.12, v. 3, 2012.

KAUFMAN, D.: **O que são Caratenóides?** Disponível na URL: <http://dinakaufman.com/artigos/o-que-sao-carotenoides/> Acesso em fevereiro de 2013.

KIMARI, H.: Doenças da mangueira *Mangifera indica* L. **Manual de fitopatologia: doenças das plantas cultivadas**. São Paulo, Ceres, v. 2, 1980.

KLIR, G. J.; YUAN, B. **Fuzzy Sets and Fuzzy Logic: Theory and Applications** . New Jersey: Prentice Hall PTR, 1995.

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

KONZEN, P.H.A.; FURTADO, J.C.; CARVALHO, C.W.; FERRÃO, M.F.; MOLZ, R.F.; BASSANI, I.A.; HÜNING, S.L. Otimização de métodos de controle de qualidade de fármacos usando algoritmos genéticos e busca tabulada. **Pesquisa Operacional**, v. 23, Nº. 1, Rio de Janeiro, 2003.

KOVÁCS, Z. L.: **Redes Neurais Artificiais – Fundamentos e Aplicações**. (Ed.4), São Paulo, 2006.



KUBRUSLY, C. A.: O que é Fotografia, **Coleção Primeiros Passos**, São Paulo: Brasiliense, 1982

KURTZWEIL R.: **The age of intelligent Machines**. The MIT Press - Cambridge, Massachussets, 1990.

LEFCOUT, A.; KIM, M.: Technique for normalizing intensity histograms of images when the approximate size of the target is known: detection of feces on apples using fluorescence imaging. **Computers and Electronics in Agriculture**, v. 50, n. 2, p. 135-147, 2006.

LEFCOUT, A.; KIM, M.; CHEN Y-R.; KANG B.: Systematic approach for using hyperspectral imaging data to develop multispectral imagining systems: Detection of feces on apples. **Computers and Electronics in Agriculture**, v. 54, n. 1, p. 22-35, 2006.

LENAT, D. B. The role of heuristics in learning by discovery: Three case studies. In Michalsky, R. S., Carbonell, J. G., and Mitchell, T. M., editors, in **Machine Learning, An Artificial Intelligence Approach**, Morgan Kauffman. 1983

LI, Z.; WANG, N.; RAGHAVAN, V.; VIGNEAULT, C.: Ripeness and rot evaluation of 'Tommy Atkins' mango fruit through volatiles detection. **Journal of Food Engineering** 91 (2009) p. 319–324. Disponível na URL: [www.elsevier.com/locate/jfoodeng](http://www.elsevier.com/locate/jfoodeng); Acesso em julho de 2013.

LIQUIÈRE, M.; SALLANTIN, J., INNE (Induction in Networks): A structural learning algorithm for noisy exemples. **Proceedings of the Fourth European Working Session on Learning**, Montpellier - 1989, Pitman, Morgan Kaufmann Publishers Inc., Londres, 1990

LLEÓ, L.; BARREIRO, P.; RUIZ-ALTISENT, M.; HERRERO, A.: Multispectral images of peach related to firmness and maturity at harvest. **Journal of Food Engineering**, v. 93, n. 2, p. 229-235, 2009

LLOBET, E.; HINES, E. L; GARDNER, J. W; FRANCO, S.: Non-destructive banana ripeness determination using a neural network-based electronic nose. **Measurements Science Technology** n.10, 1999.

LOPES, L. F. D. **Análise de componentes principais à confiabilidade de sistemas complexos**. 2001. Tese (Doutorado Engenharia de Produção) – Universidade Federal Santa Catarina, 2001.

LOPES, P. R. C; MOREIRA, A N.; HAJI, F.N.P.; SILVA, A.S. Produção integrada de manga. **Anais do III SBPIF Seminário Brasileiro de Produção Integrada de Frutas**, 2001, Bento Gonçalves, RS.: Embrapa Uva e Vinho, 2001.

LOPEZ-GARCIA, F.; ANDREU-GARCIA, A.; BLASCO, J.; ALEIXOS, N.; VALIENTE, J.: Automatic detection of skin defects in citrus fruits using a multivariate image analysis approach. **Computers and Electronics in Agriculture**, v. 71, n. 2, p. 189-197, 2010.

LUGER G. F.; STUBBLEFIELD, W. A.: **Artificial Intelligence: Structures and Strategies for Complex Problem Solving** - Benjamin Cummings Publishers, Redwood City, CA, 1993.

LUNADEI, L.; DIEZMA, B.; LLEÓ, L.; RUIZ-GARCIA, L.; CANTALAPIEDRA, M.; RUIZ, A. Monitoring of fresh-cut spinach leaves through a multispectral vision system. **Postharvest Biology and Technology**, Amsterdam, v. 63, n. 1, p. 74-84, 2012.

MAGNESS, F.R.; TAYLOR, G.F: **An improved type of pressure tester for determining fruit maturity**. U.S. Dept. of Agriculture, Circ. # 350, Washington, D.C., 1925.

MALEVSKI, Y.; L, GOMEZ-BRITO,; PELEG, M.; SILBERG, M.: External color as maturity index of mango. **Journal of Food Sci.** 42: p. 1316-1318, 1977.

MAMDANI, E. H.: Application of Fuzzy Algorithms for Control of Simple Dynamic Plant. **Proceedings of IEE Control and Science**, v. 121, No. 12, pags. 1585–1588, 1974.

MAZZA, G.; MINIATI, E.: **Anthocyanins in Fruits, Vegetables, and Grains**. CRC Press. Boca Raton, FL, USA , 1993.

McADAM, D. L.: **Color Measurement: Theme and Variations**. Springer-Verlag, Berlin, 1981.

McMINN, R. M. H.: **Atlas Colorido de Anatomia Humana**. São Paulo: Manole, 1990.

MEDINA, V. M.: **Fisiologia Pós-Colheita da Manga**; Embrapa CNPMF, Cruz das armas, BA – 1995.

MENDOZA, F., DEJMEK, P., AGUILERA, J. M.. Calibrated color measurements of agricultural foods using image analysis, **Journal of Postharvest Biology and Technology**, n. 41, p. 285-295, 2006.

MICHALSKY R. S., CARBONELL J. G., MITCHELL T.: **Machine Learning Vol II**. M. Kaufmann Publishers, Los Altos, CA. 1983(a).

MICHALSKY R. S., CARBONELL J. G., MITCHELL T.: **Machine Learning, Vol I**. M. Kaufmann Publishers, Los Altos, CA. 1983(b).

MICROSOFT: **Reference Raster Image Processor (RIP)** Tutorial, disponível na URL.: <http://msdn.microsoft.com/en-us/gg463352.aspx>. Acesso em junho de 2013.

MILLER, W.R.; MCDONALD, R.E: Quality Changes During Storage and Ripening of 'Tommy Atkins' Mangos Treated with Heated Forced Air: **Hortscience** 26(4), p.395-397. 1991.

MILONE, G.: **Estatística geral e aplicada**. São Paulo: Centage Learning, 2009.

MOHSENIN, N. N.: **Physical properties of plant and animal materials**. New York, NY. Gordon and Breach Pub. Inc. 1978.

MONTEIRO, R. C.; MOUND, L. A.; ZUCCHI, R. A.: Espécies de Frankliniella (Thysanoptera: Thripidae) de importância agrícola no Brasil. **Neotropical Entomology**, v. 30, Nº 1, 2001.

MORAIS, P. L. D.; FILGUEIRAS, A. H. C.; PINHO, J. L. M.; ALVES, R. E.: Correlação entre variáveis de crescimento do fruto da mangueira 'Tommy Atkins'. **Ciência e Agrotecnologia**, Lavras, v. 28, n. 4, 2004. Disponível na URL: <[http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S1413-0542004000400003&lng=en&nrm=iso](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1413-0542004000400003&lng=en&nrm=iso)>. Acesso em: Março de 2013.

MOROVIC, J.; LUO, M. R.: Calculating medium and image gamut boundaries for gamut mapping. In **Color: Research and applications journal**, v. 25, Wiley on-line library, 2000.

MOTODA, H; LIU, H; SETIONO, R; ZHAO, Z.: Feature Selection: An Ever Evolving Frontier in Data Mining. **JMLR: Workshop and Conference Proceedings 10: 4-13 Proceedings of the Fourth Workshop on Feature Selection in Data Mining**, 2010. Disponível na URL: <http://jmlr.org/proceedings/papers/v10/liu10b/liu10b.pdf>; Acesso em junho de 2013.

NANDI, C. S.; TUDU, B.; KOLEY, C.: Machine Vision Based Techniques for Automatic Mango Fruit Sorting and Grading Based on Maturity Level and Size. **Sensing Technology**:

**Current Status and Future Trends II**, n. 27 A. MASON et al. (eds.), Smart Sensors, Measurement and Instrumentation 8, Springer International Publishing Switzerland , 2014a.

NANDI, C. S.; TUDU, B; KOLEY, C.: Computer Vision Based Mango Fruit Grading System. **International conference on Innovative Engineering Technologies (ICIET'2014)**, Bangkok, 2014b.

NETO, F. P. L.: **Manga: Características da planta**. Artigo disponível na URL: [http://www.agencia.cnptia.embrapa.br/Agencia22/AG01/arvore/AG01\\_17\\_24112005115221.html](http://www.agencia.cnptia.embrapa.br/Agencia22/AG01/arvore/AG01_17_24112005115221.html). Acesso em fevereiro de 2012.

NOVO, E. M. L. M.: **Sensoriamento Remoto: Princípios e Aplicações**. Editora Edgar Blücher Ltda. São José dos Campos, 1989.

OBENLAND, D.; NEIPP, P.: Chlorophyll fluorescence imaging allows early detection and localization of lemon rind injury following hot water treatment. **Hortscience**, v. 40, n. 6, pgs 1821-1823, 2005.

OLIVEIRA, J. E. M.; PARANHOS, B. A. J.; MOREIRA, A. N.: Cultivo da Mangueira - Pragas. **Embrapa Semiárido - Sistemas de Produção, 2 - 2ª edição**. Versão Eletrônica, Ago/2010. Disponível na URL: [http://sistemasdeproducao.cnptia.embrapa.br/FontesHTML/Manga/CultivodaMangueira\\_2ed/pragas.htm](http://sistemasdeproducao.cnptia.embrapa.br/FontesHTML/Manga/CultivodaMangueira_2ed/pragas.htm), Acesso em março de 2014.

OLSEN, E. V.; SOROKULOVA, I. B.; PETRENKO, V. A.; CHEN, I. H.; BARBAREE, J. M.; VODYANOY, V. J.: **Biosensor Bioelectronics**, n. 21, 2006.

PALTRINIERI, G.; FIGUEROLA, F.; ROJAS, L.: **Technical manual on small-scale processing of fruits and vegetables**. Food and Agriculture Organization of the United Nations (FAO). Santiago, Chile, 1997.

PAN: **Portal do Agronegócio**. Disponível na URL: <http://www.portaldoagronegocio.com.br/conteudo.php?id=88322>. Acessado em Março de 2013.

PATTERSON, T.: The electronic nose knows: handheld technology measures grape maturity. **Wines & Vines**, n.88, 2007.

PEDRESCHI, F., LEÓN, J., MERY, D., & MOYANO, P. Implementation of a computer vision system to measure the color of potato chips. **Food Research International**, n. 39, p. 1092–1098, 2006.

PEDRINI, H.; SCHWARTZ WR.: **Análise de Imagens Digitais: Princípios, Algoritmos e Aplicações**. Thompson Learning Eds., São Paulo, 2008

PEREIRA, M. H. R.: **Estudos de história da cultura grega**. Lisboa: Publicação da Fundação Calouste Gulbenkian, 1971.

PLA, F.; SANCHEZ, J. S.; SANCHIZ, J. M.: Online machine vision system for fast fruit color sorting using low-cost architecture. **Proceedings of the SPIE'99 - Machine Vision Systems for Inspection and Metrology VIII**, 244, 1999.

PLATÃO: **A República**. Tradução de Enrico Corvisieri. Editora Nova Cultural Ltda, Rio de Janeiro, 2000.

PSF – **Biologia dos frutos**. (autores diversos) Portal do São Francisco / Colégio S. Francisco. Artigo em Hipertexto. Disponível na URL: <http://www.portalsaofrancisco.com.br/alfa/fruto/index.php>. Acesso em março de 2012.

QIN, J.; BURKS, T.; RITENOUR, M.; BONN, W.: Detection of citrus canker using hyperspectral reflectance imaging with spectral information divergence. **Journal of Food Engineering**, v. 93, n. 2, p. 183-191, 2009.

QUEVEDO, R.; MENDOZAB, F.; AGUILERAB, J. M.; CHANONAC, J.; GUTIÉRREZ-LÓPEZ, G.: Determination of senescent spotting in banana (*Musa cavendish*) using fractal texture Fourier image. **Journal of Food Engineering**, v. 84, n. 4, p. 509-515, 2008.

RASHIDI M.; SEYFI, K.: Classification of fruit shape in Cantaloupe using the analysis of geometrical attributes. **World Journal of Agricultural Sciences**, n.3, v. 6, p. 735-740, 2007.

REID, M. S.: Maturation and maturity indices. In: **Postharvest technology of horticultural crops**. ANR Publication Univ. of California, Oakland, CA, USA, 2002-

RENGANATHAN, S.; SUDHAKARA P. R.: New Approaches for Size Determination of Apple Fruits for Automatic Sorting and Grading: **Iranian Journal of Electrical and Computer Engineering**, v. 1, No. 2, 2002. Disponível na URL: [http://198.55.49.74/en/VEWSSID/J\\_pdf/89020020206.pdf](http://198.55.49.74/en/VEWSSID/J_pdf/89020020206.pdf). Acesso em Janeiro de 2013.

RIBEIRO, S. M. R.; QUEIROZ, J. H.; RIBEIRO, M. E. L. Q.; SILVA, S. R. S.: Potencial Antioxidante dos Resíduos da Industrialização da Manga (*Mangifera indica*, L), variedade Ubá. **Anais da 29ª Reunião Anual da Sociedade Brasileira de Química**. Maio de 2006 –

águas de Lindóia-SP. Disponível na URL: <https://sec.sbu.org.br/cd29ra/resumos/T0629-1.pdf>. Acesso em junho de 2014.

RICH E, KNIGHT K, FINLAY J.: **Machine Learning Review** by Dewan Shaju Khan made by reading through various AI books /other journals & computer magazines. 1997, URL: <http://www.scism.lsbu.ac.uk/inmandw/review/ml/review/rev7061.html>, Acesso em outubro de 2013.

RICH E, KNIGHT K: **Artificial Intelligence** - New York, NY: McGraw Hill 1991.

RIQUELME, M.T.; BARREIRO, P.; RUIZ-ALTISENT, M.; VALERO, C.: Olive classification according to external damage using image analysis. **Journal of Food Engineering**, v. 87, n. 3, p. 371-379. Elsevier, 2008. Disponível na URL: <http://www.sciencedirect.com/science/article/pii/S0260877407006413>. Acesso em junho de 2013.

RIYADI, S.; MUSTAFA, M. M.; HUSSAIN, A.; HAMZAH, A.: Papaya fruit grading based on size using image analysis. **Proceedings of the International Conference on Electrical Engineering and Informatics Institut Teknologi**. Bandung, Indonesia, 2007.

RUEDA, L.; MERY, D.; KITTLER, J. : Progress in Pattern Recognition, Image Analysis and Applications, **Proceedings of the 2th Iberoamerican Congress on Pattern Recognition, CIARP 2007**, Valpariso, Chile, 2007.

RUSSEL, S; NORVIG, P.: **Inteligência Artificial: A Modern Approach**. Ed. Campus-Elsevier. Rio de Janeiro, 2004.

SADRNIA, H.; RAJABIPOUR, A.; JAFARY, A.; JAVADI, A.; MOSTOFI, Y.: Classification and analysis of fruit shapes in long type watermelon using image processing. **International Journal of Agriculture and Biology**, n. 9, 2007.

SALDAÑA, E.; SICHE, R.; LUJÁN, M.; QUEVEDO, R.: Review: computer vision applied to the inspection and quality control of fruits and vegetables. **Brazilian Journal of Food Technology**. v. 16, n. 4, Campinas, SP. 2013.

SALIM, S. N .M.; SHAKAFF, A. Y. M.; AHMED, M. N.; ADOM, A.H.; HUSINM, Z.: Development of electronic nose for fruits ripeness determination. **Proceedings 1<sup>st</sup> International Conference on Sensing Technology**, Palmerston North, New Zealand. 2005.

SANTOS, A. C. A : **Importância e métodos físicos de avaliação da qualidade da matéria prima** . LTPC - Laboratório de Tecnologia e Pós-colheita / Universidade de Évora. Disponível na URL: [http://www.google.com.br/url?sa=t&rct=j&q=&esrc=s&source=web&cd=1&ved=0CBwQFjAA&url=http%3A%2F%2Fwww.isa.utl.pt%2Ffiles%2Fpub%2Fensino%2Fformacao%2FTPC\\_Comunicacoes%2FDia01%2F08\\_Metodos\\_fisicos\\_Cristina\\_Santos.pdf&ei=YK3kU9SQI8zMsQTn2oKIDA&usg=AFQjCNHQ6vT5TnilCJaNwaemzd5M1EKNUw&bvm=bv.72676100,d.cWc](http://www.google.com.br/url?sa=t&rct=j&q=&esrc=s&source=web&cd=1&ved=0CBwQFjAA&url=http%3A%2F%2Fwww.isa.utl.pt%2Ffiles%2Fpub%2Fensino%2Fformacao%2FTPC_Comunicacoes%2FDia01%2F08_Metodos_fisicos_Cristina_Santos.pdf&ei=YK3kU9SQI8zMsQTn2oKIDA&usg=AFQjCNHQ6vT5TnilCJaNwaemzd5M1EKNUw&bvm=bv.72676100,d.cWc), 2012. Acesso em dezembro de 2013.

SCHALKOFF R. J. **Artificial Intelligence: An Engineering Approach**, McGraw-Hill editors, New York, NY, 1990

SENG, W. C.; MIRISA, S. H.: A New Method for Fruits Recognition System. **Proceedings of the International Conference on Electrical Engineering and Informatics, ICEEI '09**. v. 1, p. 130-134, 2009.

SHANNON, C. E.: **A Mathematical Theory of Communication**, Collected Papers, eds. N.J.A. Sloane e Aaron D. Wyner, IEEE Press, 1993.

SILVA, P. C. G.: **A exportação de frutas frescas no Chile e Brasil**. CNPTIA/EMBRAPA, Juazeiro – BA, 2013.

SIMÃO, S. **Estudo da planta e do fruto da Mangueira (Mangifera indica L. )**. Tese em Eng. Agrícola. Escola Superior de Agricultura "Luiz de Queiroz", Universidade de São Paulo Piracicaba, S.P., 1960.

SIMÕES, A. S.; COSTA, A. H. R.: Classificação de laranjas baseada em padrões visuais. **Anais do 6º Simpósio Brasileiro de Automação Inteligente - SBAI'2003**. Sociedade Brasileira de Automática - SBA. p. 77-81, Bauru, 2003.

SIMON, J. D.: **Computer Vision: Models, Learning, and Inference**. Cambridge University Press; 1 edition, 2012.

SINCLAIR, C. **Sinclair iQTM Firmness Tester Manual**. Fresno, CA, USA. Available at: <http://www.sinclair-intl.com>. Acesso em janeiro de 2013.

SINGH, A.: Approximation of fruit weight by using fruit dimensions in mango (*Mangifera indica* L.). **Progressive Horticulture**, v. 44, n. 1, 2012, Disponível na URL:

<http://www.indianjournals.com/ijor.aspx?target=ijor:pho&volume=44&issue=1&article=010>;  
Acesso em setembro de 2013.

SLAUGHTER D.C.: Nondestructive Maturity Assessment Methods for Mango: A Review of Literature and Identification of Future Research Needs. **Biological and Agricultural Engineering**. University of California, Davis, 2009.

SOUTO, R. P.: **Segmentação de imagem multiespectral utilizando-se o atributo matiz**. São José dos Campos: INPE, 2000. URL: [www.obt.inpe.br/pgsere/Souto-R-P-2000/publicacao.pdf](http://www.obt.inpe.br/pgsere/Souto-R-P-2000/publicacao.pdf). Acesso em dezembro de 2011.

SOUZA, W. C. O.; BARROS, P. N.; SILVA, E. C. V.; VILAR, F. C. R.; PEREZ, J. O.; GOMES, E. C. S.: **Caracterização das perdas de manga ‘Tommy Atkins’ no mercado atacadista de Juazeiro, BA.**, Inst. Federal. SERTÃO-PE, Campus Petrolina Zona Rural, Petrolina, PE, 2010.

SOUZA, W. O.; GARNÉS, S. J. A.: Análises de Projeções Cartográficas para grandes escalas. **Anais do IV Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação**. Recife – PE, p. 001-009, 2012.

SPOSITO, M. B.; AMORIM, L.; JUNIOR, J. B.; BASSANEZI, R. B.; AQUINO, R.:  
Elaboração e validação de escala diagramática para avaliação da severidade da mancha preta em frutos cítricos. **Fitopatologia brasileira**. v.29 no.1 Brasília Jan./Feb. 2004.

SPREER, W.; MÜLLER, J.: Estimating the mass of mango fruit (*Mangifera indica*, cv. Chok Anan) from its geometric dimensions by optical measurement. **Computers and Electronics in Agriculture**, v. 75, n. 1, p. 125–131, 2011.

STEFFENS, B.: Ibn al-Haytham: **First Scientist (Profiles in sciences)**. Morgan Reynolds Pub, Greensboro, North Carolina, USA, 2007.

TAVARES, S. C. C. H.; COSTA, V. S. O.; LOPES, L. M. M.: **Manejo da Mancha Angular (*Xanthomonas campestris* pv. *Mangiferae indica*) na Produção Integrada de Manga** – Manual de Instrução Técnicas da Embrapa Semi-Árido - CGPE 5302, Petrolina, 2005.

TÉLIZ-ORTÍZ, D.; MORA-AGUILERA, G.; ÁVILA-QUEZADA, G.: Systems for Measuring Severity of Anthracnose and Scab in Avocado Fruits. **Proceedings of the V World Avocado Congress (Actas V Congreso Mundial del Aguacate)**, p. 585-589. 2003.



TEOH, C. C.; SYAIFUDIN, A.R.M.: Use of image analysis for grading size of mango. **Acta Horticulturae**, v. 710, p. 485-490, 2006.

THOMPSON, P.; TROSCIANKO, T.: **Basic vision: an introduction to visual perception**, Rev. ed., Oxford University Press, 2011

TORRES, R.; FALCÃO, A.; DINSTEIN, I.: Content-Based Image Retrieval: Theory and Applications. **Revista de Informática Teórica e Aplicada**, v. 13, n. 2, 2006.

TUCKER, G. A. *Introduction*. In: SEYMOUR, G. B.; TAYLOR, J. E.; TUCKER, G. A. **Biochemistry of fruit ripening**. Chapman & Hall, Londres, 1993. p. 1-51.

UNAY, D.; GOSSELIN, B.: Stem and calyx recognition on ‘Jonagold’ apples by pattern recognition. **Journal of Food Engineering**, v. 78, n. 2, p. 597-605, 2007.

VILLEFANE, J.: **Introducción a la teoría da la imagem**, Madrid, Ed. Piramide, 1988

WALTER, E. H. M.: **Classificação de Frutas e Hortaliças – Solução técnica para um problema comercial**. CTAA/ EMBRAPA. Embrapa Agroindústria de Alimentos, Guaratiba, RJ, 2010.

WATADA, A. E.; HERNER, R. C.; KADER, A. A.; ROMANI, R. J.; STABY, G. L. Terminology for the description of developmental stages of horticultural crops. **HortScience** – American Society for Horticultural Science, Alexandria, Virginia, 1984.

WEBER, L; KLEIN, P. A. T. **Aplicação de lógica fuzzy em software e hardware**. Editora Ulbra. Canoas, 2003.

WINSTON P. H. **Artificial Intelligence**. Addison-Wesley Publishers, Reading, Massachussets, 1992.

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

XING, J.; JANCOSOK, P.; DE BAERDEMAEKER, J.: Stem-end/ calyx identification on apples using contour analysis in multispectral images. **Biosystems Engineering**, London, v. 96, n. 2, p. 231-237, 2007

ZHANG, Q.; PIERCE, F. J.: **Agricultural automation fundamentals and practice**. CRC Press/ Taylor & Francis group – Boca Raton, FL, 2013.

ZHAO, X.; BURKS, T.; QIN, J.; RITENOUR, M.: Digital microscopic imaging for citrus peel disease classification using color texture features. **Applied Engineering in Agriculture**, St. Joseph, v. 25, n. 5, p. 769-776, 2009.

## A MANGA “TOMMY ATKINS”

## Conteúdo

1. Classificação dos frutos.....	225
2. A mangueira .....	228
3. Aspectos biológicos.....	230
4. A cultivar “Tommy Atkins” .....	232
5. Características da manga <i>Tommy Atkins</i> .....	232
6. A manga no Brasil.....	234
7. Processos de Colheita da manga <i>Tommy Atkins</i> .....	235
8. Produção Integrada de Frutas .....	236
9. O Mercado Mundial de frutas .....	246
10. O Mercado Mundial de mangas .....	249
11. Bibliografia.....	251

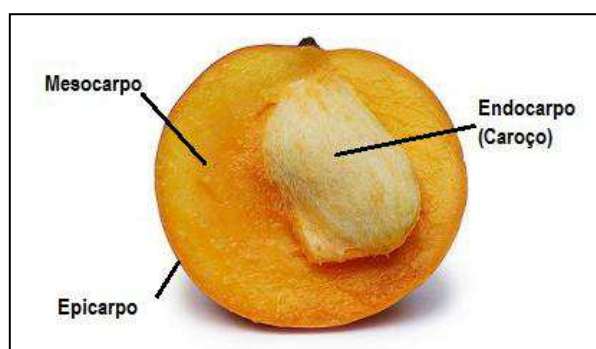
## 1. Classificação dos frutos

O fruto é o órgão das plantas resultante do desenvolvimento do ovário após a fecundação, até a maturidade; biologicamente, tem a função de proteger a semente (ou sementes), acomodando-a em um envelope adequado e assegurando a disseminação e a perpetuação das espécies. Em uma definição mais conservadora (clássica), é o ovário desenvolvido e com sementes maduras. Também pode ser conceituado como um órgão formado por um ou mais ovários desenvolvidos, aos quais podem se associar outras estruturas acessórias. A grande diversidade na organização das flores das angiospermas, especialmente a variação do número, arranjo, grau de fusão e estrutura dos pistilos que formam o gineceu, propicia uma ampla gama de variação no tamanho, forma, textura e anatomia dos frutos (RAVEN *et al*, 2001).

O fruto é constituído de duas partes fundamentais: o fruto propriamente dito, chamado de pericarpo, originado da parede do ovário, e a semente. Por sua vez, o pericarpo é subdividido em três camadas:

- a) **Epicarpo:** A casca do fruto, revestimento externo;
- b) **Mesocarpo:** parte intermediária do pericarpo, em geral, é a parte mais desenvolvida dos frutos carnosos e a parte mais comestível; polpa.

- c) **Endocarpo:** parte interior do pericarpo, que normalmente é pouco desenvolvida, reveste a semente e é de difícil separação desta.



**Figura API-1:** A manga e sua morfologia interna. Fonte: Montagem do autor a partir de foto encontrada em <http://www.fotosantesedepois.com/manga/>.

A morfologia do fruto manga é mostrada na Figura API-1; a parte comestível é a polpa, ou mesocarpo; o “caroço” da manga, que muitos associam à semente, é na realidade o endocarpo, uma camada que reveste a semente.

Os frutos podem ser classificados segundo vários critérios, e alguns deles são até denominados “pseudofrutos”, “falso fruto” ou “fruto acessório”, pois são desenvolvidos de um tecido vegetal adjacente à flor que sustenta o fruto, assemelhando-se em cor e consistência a um fruto verdadeiro, que é desenvolvido no ovário. Pseudofrutos são popularmente conceituados como frutos. Um resumo de algumas classificações por diferentes critérios é apresentado no Quadro API-1; a partir dela, é possível classificar a manga como um fruto carnoso de clima tropical, fresco, climatérico, simples, indeiscente, do tipo drupa.

**Quadro API-1:** Classificação de frutas. Fonte: Adaptação do autor

Parâmetro	Classe	Descrição	Exemplos
Procedência	Regiões Temperadas	Fruto proveniente de regiões com clima temperado.	Pera, maçã, damasco, pêssego, ameixa, azeitona, figo.
	Regiões Subtropicais	Fruto proveniente de regiões com clima subtropical.	Abacate, laranja, limão, lima, tangerina, figo, kiwi, azeitona e romã.
	Regiões Tropicais	Fruto proveniente de regiões com clima tropical.	<b>Manga</b> , banana, mamão, abacaxi.
Teor de água	Secos	Possui baixo teor de água	Noz, castanha, amêndoa, avelã, pinhão.
	Frescos	Possui alto ou médio teor de água	<b>Manga</b> , Abacaxi, Melão

## Continuação

Quadro API-1: Classificação de frutas. Fonte: Adaptação do autor

Amadurecimento	Climatéricos	Têm a capacidade de amadurecer separados da planta, mesmo quando colhidos imaturos.	<b>Manga</b> , ameixa, banana, damasco, figo, kiwi, maçã, maracujá, pêssego, tomate e pera.
	Não-climatéricos	Só amadurecem na planta. A produção de etileno não aumenta durante o amadurecimento.	abacaxi, azeitona, cereja, laranja, limão, melancia, morango, uva.
Composição	Simples	Quando os carpelos são unidos entre si, ao menos nos primeiros estágios de desenvolvimento; são frutos oriundos do desenvolvimento do pedúnculo ou do receptáculo de uma única flor.	A maior parte dos frutos conhecidos apresentam-se desta forma, como limão, <b>manga</b> , maracujá, mamão, pepino, pera, e goiaba.
	Compostos	Os carpelos são separados desde a flor, e se desenvolvem de maneira independente (separadamente).	Abacaxi.
	Agregados	Provenientes de uma única flor, com gineceu pluridialicarpelar sincárpico ou apocárpico.	Morango.
	Esquizocarpos	Originários somente do ovário da flor, decompondo-se em mericarpos na sua maturidade.	Mamona.
Abertura	Deiscentes	que abrem-se na maturação, normalmente secos.	castanha e a maior parte das leguminosas.
	<b>Indeiscentes</b>	não se abrem espontaneamente. Podem ser secos, lenhosos, ou carnosos.	maçã, laranja, melão, <b>manga</b> .
Tipo	Fruto carnosos	apresenta pericarpo suculento.	<b>Manga</b> , mamão, abacate.
	Baga	O ovário unicarpelar ou multicarpelar com sementes livres.	Tomate, Limão, Abóbora, uva.
	Drupa	o ovário unicarpelar, com semente aderida ao endocarpo duro.	Pêssego, <b>Manga</b> , abacate, Azeitona, Ameixa.
	Pomo	é um pseudofruto composto por um ou mais carpelos.	Maçã, Pera, Marmelo.
	Folículo	abre-se através de uma única fenda longitudinal.	Esporinha.
	Capsula	fruto seco que se abre através de poros ou por fendas longitudinais.	Papoula, Algodão, Paineira, Mamona.
	Vagem	abre-se através de duas fendas longitudinais (leguminosas).	Soja, feijão, ervilha, Amendoim.

## Continuação

Quadro API-1: Classificação de frutas. Fonte: Adaptação do autor

	Aquênio	fruto seco indeiscente, o pericarpo seco está totalmente aderido a uma única semente, apenas em um ponto.	Girassol.
	Sâmara	fruto seco indeiscente, o pericarpo seco forma expansões aladas.	Típuna, Pau-d'álho.
	Síliqua	abre-se por quatro fendas longitudinais, deixando um septo mediano.	Couve, Repolho.
	Noz	um fruto seco com apenas uma semente (raramente duas) no qual a parede do ovário ou parte dela torna-se muito dura na maturidade, por exemplo.	Avelã.
	Grão ou Cariopse	fruto seco indeiscente, o pericarpo seco está totalmente aderido a uma única semente, porém difere dos Aquênios e caracteriza as gramíneas, por exemplo.	Milho, Arroz, Trigo, Aveia, Cevada.
		abre-se através de um septo transversal, peeparando-se uma espécie de "tampinha" conhecida por opérculo.	Jequitibá, Sapucaia, Eucalipto.
	Lomento	Derivado de ovário unicarpelar, fragmenta-se transversalmente em segmentos unisseminado; deiscente.	Carrapicho.
	Craspédio	Derivado de ovário unicarpelar, fragmenta-se transversalmente em segmentos; após a queda, uma armação formada pela nervura e sutura do carpelo permanece presa ao receptáculo; deiscente.	Sensitiva.

## 2. A mangueira

A mangueira é uma árvore nativa do sul do continente asiático, proveniente da região que compreende todo o leste da Índia e o Ceilão (Figura API-2); alguns autores afirmam que sua origem ocorreu na Birmânia e Bangladesh, na fronteira do leste da Índia, tendo se espalhado por outras regiões que vão desde a Índia, passando pela Malásia e chegando até as Filipinas e ilhas circunvizinhas. É provável que seu cultivo tenha sido originado na Índia, pela sua domesticação há cerca de 4 mil anos, oriunda de sementes de frutos de tamanho reduzido e com pouca polpa; a primeira difusão registrada a partir da região de origem foi feita pelo chinês *Hwen Tisang* que, visitando o Indústão no subcontinente indiano, entre os anos 622 e 645 a.C., levou a manga para outras nações (FILHO *et al.*, 2011).



**Figura API-2:** Região de provável origem da manga. Fonte: Montagem do autor

A mangueira é uma árvore pertencente ao ramo da família botânica anacardiáceas; o Quadro API-2 apresenta sua classificação científica. Trata-se de uma árvore frondosa, apresentando uma copa bastante enfolhada, geralmente simétrica. Sua forma é diversificada e muda em função da variedade, podendo ir de arredondada a piramidal, de baixa e densa a ereta e aberta. Seu sistema radicular é caracterizado por uma raiz do tipo pivotante, diferenciada pela sua espessura e seu comprimento maior que o das outras, tendo ainda raízes de superfície, que apresentam ramificações compostas por raízes finas e fibrosas (SIMÃO, 1960).

**Quadro API-2:** Classificação científica da mangueira. Fonte: Extraído de (EMBRAPA/CNPTIA, 2012).

Classificação científica	
Reino	<i>Plantae</i>
Filo	<i>Magnoliophyta</i>
Classe	<i>Magnoliopsida</i>
Ordem	<i>Sapindales</i>
Família	<i>Anacardiaceae</i>
Gênero	<i>Mangifera</i>

Trata-se de uma planta cujo porte varia de médio a grande (Figura API-3), em função de vários parâmetros, como a variedade, a fertilidade do solo, a idade e o porta-enxerto; de maneira geral, as plantas não enxertadas podem atingir algo entre 30 e 40 metros de altura, enquanto que nas culturas comerciais com plantas enxertadas, as plantas atingem entre 7 e 9 metros. O crescimento excessivo da copa é um problema para os produtores, pois as plantas altas, de maior porte dificultam sobremaneira o controle de pragas e de doenças, além das tarefas de colheita; por esse motivo, são feitas podas controladas de formação e de produção (EMBRAPA/CNPTIA, 2012).



**Figura API-3:** Mangueira gigante em Ghana, alcança 22 metros de altura. Fonte: [www.clarkefast.wordpress.com](http://www.clarkefast.wordpress.com).

As folhas da mangueira são grossas, com textura semelhante ao couro (coriáceas), possuindo forma de uma ponta de lança (lanceoladas), sua coloração é verde-escura na parte superior e verde-clara na parte inferior; a nervura principal e as secundárias são salientes e apresentam coloração amarelo-esverdeada. As dimensões das folhas variam normalmente de 15 a 40 centímetros de comprimento e de 1,5 a 4,0 centímetros de largura (EMBRAPA/CNPTIA, 2012).

### 3. Aspectos biológicos

A mangueira possui inflorescências do tipo panícula, de forma piramidal côncava; elas se desenvolvem a partir de gemas terminais de ramos maduros, e possui flores bem formadas, que são frequentemente masculinas. Além disso, é ramificada e apresenta um número extremamente variável de flores, que vão das centenas aos milhares. As flores são pequenas, e seus vertículos apresentam cinco folhas (pentâmeras). O ovário é súpero e o estigma é rudimentar. Aproximadamente 30% das primeiras flores abertas nas panículas são hermafroditas, e o restante delas é do gênero masculino (70%). Uma panícula pode comportar mais de 15.000 flores, mas apenas uma pequena porção delas chega resultar em frutos (EMBRAPA/CNPTIA, 2012).

A polinização da mangueira é feita geralmente por moscas e abelhas principalmente, no entanto, apesar da sua vigorosa inflorescência que abriga grande número de flores, o processo da fecundação não é tão eficiente, sendo afetado pelas condições climáticas, como mostra o Quadro API-3.



**Quadro API-3:** Fatores que influenciam o desenvolvimento da mangueira. Fonte: (SEAGRI, 2012).

<b>Fator</b>	<b>Restrição</b>
Pluviosidade	<ul style="list-style-type: none"> <li>• Vegeta e frutifica em regiões cujas chuvas anuais acumulem entre 450 mm. e 2.500 mm.;</li> <li>• Regiões com período chuvoso e seco bem consistente e bem definido são mais propícias;</li> <li>• Preferencialmente, o período de seco deve ser iniciado antes da floração, e o período chuvoso deve ser iniciado logo após a frutificação.</li> </ul>
Temperatura	<ul style="list-style-type: none"> <li>• A baixa temperatura durante a floração impede a abertura das flores;</li> <li>• A alta temperatura pode antecipar a colheita;</li> <li>• A alta temperatura é prejudicial se for acompanhada de ventos fortes e de baixa umidade relativa durante a frutificação;</li> <li>• Desenvolve-se bem e frutifica em regiões com temperaturas entre 21 e 27°C.</li> </ul>
Umidade relativa	<ul style="list-style-type: none"> <li>• Preferencialmente abaixo de 60%;</li> <li>• Alta umidade reduz a polinização;</li> <li>• Alta umidade induz proliferação de doenças que reduzem a produção dos frutos.</li> </ul>
Luz solar	<ul style="list-style-type: none"> <li>• Radiação solar incidente deve ser abundante para a floração e frutificação;</li> <li>• Demanda anual de Irradiação mínima é de 2.000 horas/luz/ano.</li> </ul>
Vento	<ul style="list-style-type: none"> <li>• Ventos moderados a fortes, associados à temperatura elevada e baixa umidade relativa causam queda de frutos;</li> <li>• Ventos fortes causam queda de flores e de frutos.</li> </ul>

A quantidade de frutos que vingam e amadurecem é muita pequena em relação à quantidade de flores produzidas. O período de queda dos frutos começa na primeira semana após a fecundação (SEAGRI, 2012).

Normalmente, a planta floresce e frutifica uma vez por ano, mas com a adoção de técnicas especiais como poda e aplicação de hormônios de crescimento, ou ainda efetuando uma combinação de estresse hídrico por um período de 30 a 70 dias com a aplicação foliar de nitrato de potássio ou cálcio, consegue-se provocar o florescimento e frutificação mais de uma vez ao ano e na época desejada.

A propagação pode ser feita por meio de sementes (plantios domésticos) e por enxertia (garfagem) em viveiro para plantios comerciais. Geralmente, prefere-se utilizar a enxertia, de uma variedade desejada em um porta-enxerto de outra variedade, porque nos pomares, à época da frutificação, o tamanho e a cor dos frutos ficam uniformes, o que é comercialmente muito interessante. Em plantas enxertadas, a frutificação pode ocorrer a partir do segundo ano e, comercialmente, no terceiro ou no quarto ano (EMBRAPA/CNPTIA, 2012).

#### 4. A cultivar “*Tommy Atkins*”

A árvore original da variedade *Tommy Atkins* desenvolveu-se a partir de sementes de origem desconhecida, plantadas no início da década de 1920, em um pomar do condado de *Broward*, ao norte de *Forte Lauderdale*, no estado da *Flórida*, *EUA*, na propriedade de *Thomas H. Atkins*. Especulava-se que as sementes fossem afiliadas à variedade *Haden*; esta possibilidade veio a ser confirmada em análises posteriores. O ano exato em que surgiu o primeiro fruto não é conhecido, mas foi provavelmente no início da década de 1940. A cor marcante dos frutos atraiu a atenção do Sr. *Atkins*, que acreditava ter um produto com potencial como uma variedade comercial (CAMPBELL, 1968).

Por volta de 1945, o Sr. *Atkins* decidiu enxertar algumas árvores e disponibilizá-las para venda. As primeiras árvores enxertadas só foram vendidas três anos mais tarde, em 1948. Os frutos foram submetidos ao comitê de variedade do Fórum *Flórida Mango* para avaliação. Registros existentes indicam que os frutos foram submetidos nos anos 1947, 1949, 1950 e 1951. O comitê ficou dividido, pois alguns não consideravam a manga *Tommy Atkins* digna de aceitação como uma variedade, pois a mesma havia recebido algumas avaliações ruins para alguns requisitos, dentre os quais, textura da carne e sabor, porém, para outros membros, o fruto atraiu a atenção favorável, particularmente devido à sua cor. Eles estavam interessados na produção comercial de mangas e viram nela um potencial de sucesso, principalmente porque o fruto era muito atraente, tinha porte avantajado, cor excelente, alta produtividade e resistência à antracnose.

Em 1950, um agricultor chamado *W.W. Carmichael* comprou uma árvore enxertada de *T.H. Atkins* e a em *Perrine*, na *Flórida*, e dela, enxertou outras árvores. Mais tarde, a família *Mitchell*, também de *Perrine*, comprou a árvore original de *Carmichael* e a mudou para o seu pomar. Eles começaram a enxertar árvores adicionais e estabeleceram pomares no final de 1950 e início de 1960. Em pouco tempo, o fruto estava alcançando aceitação no mercado e outros produtores iniciaram suas próprias plantações desta variedade. Nos anos seguintes, mais árvores desta variedade foram plantadas na *Flórida* do que de qualquer outra (CAMPBELL, 1968).

#### 5. Características da manga *Tommy Atkins*

As árvores *Tommy Atkins* são de crescimento vigoroso, possuindo dossel, denso e arredondado. A produção se inicia entre 3 e 4 anos após o plantio, e suportam bem às

intempéries climáticas, como ventos fortes, frio ou calor intenso. As árvores podem suportar entre 75 e 150 kg de frutas entre os 6 e 8 anos de idade; as árvores com mais de dez anos, chegam a suportar 300 kg (PSF, 2012).

O fruto é considerado de médio a grande porte, pesando de 450 a 700 g. É oval para forma oblonga com uma ponta arredondada (Figura API-4).

A superfície do fruto é lisa, e a pele é grossa e possui resistència à lesão mecânica superior grande maioria de variedades. O fruto também é resistente à infecção pelo fungo que causa a doença de antracnose e lhe proporciona um período mais longo de armazenamento.



**Figura API-4:** A manga *Tommy Atkins*. Fonte: Extraído de <http://www.losurdos.com.au>

A cor externa do fruto é extremamente atrativa. A cor de fundo é arroxado-púrpura quando verde e amarelo-alaranjado quando madura, com grandes manchas de um estonteante vermelho escuro brilhante. Em muitas frutas o blush vermelho cobre a maior parte da superfície, de modo que pouco da cor de fundo pode ser visto.

A carne é amarela, com intensidade que varia de claro a escuro. O sabor é bom, mas varia conforme as condições de solo e clima. A textura da carne é muito firme devido à presença de fibras fina. A polpa representa mais de 80% da massa do fruto. A semente pesa entre 28 e 42g e a polpa da fruta e é monoembriônica.

A cultivar *Tommy Atkins* é a mais importante dentre as variedades de manga no comércio global, tendo desde muito superado a Haden (GALAN, 1993).

Várias investigações de análise sensorial<sup>1</sup>, indicam que o a manga da variedade *Tommy Atkins* é a preferida quando comparada com Haden e a Espada. E essa variedade também apresentou os melhores resultados na avaliação da cor, sabor ácido e doce, aparência e ausência de fibras (CARDELLO, 1997).

## 6. A manga no Brasil

A manga foi introduzida no Brasil pelos portugueses, que a trouxeram de Goa na Índia, no século 16, no século XVI (PINTO *et al.*, 2012). Adaptou-se muito bem em várias regiões brasileiras, sendo muitas vezes confundida como fruteira nativa, tendo se tornado uma das principais frutíferas cultivadas no Nordeste brasileiro (Figura API-5) em virtude das condições climáticas favoráveis.



**Figura API-5:** Mangueira da variedade *Tommy Atkins* em Petrolina – PE. Fonte: Foto de Asit K. Ghosh; domínio público.

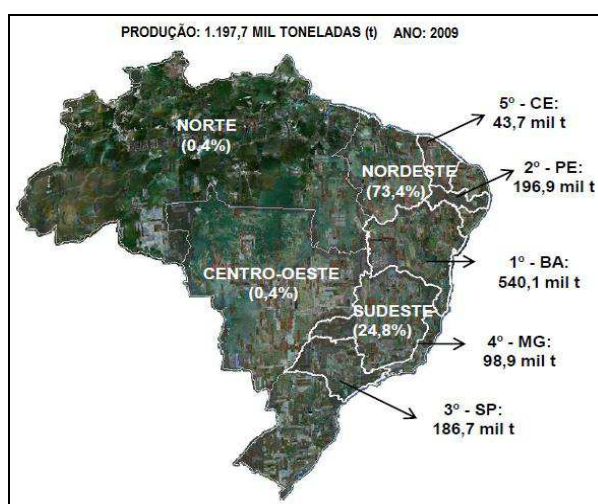
A introdução e a propagação por sementes originaram frutos de tipos diversificados, diferentes sabores e qualidades, que só foram estabelecidas como variedades muito depois. Bem mais recentemente, houve também a introdução, no país de variedades selecionadas em outros países, que permitiram alavancar a qualidade da cultura local. Para atender às exigências dos importadores, a produção e a pós-colheita de manga no Brasil sofreram grandes transformações que se refletiram no mercado interno, que é o grande consumidor da manga brasileira; assim, a necessidade da melhoria da qualidade da manga para atender o mercado externo, teve por desdobramento, a melhoria desse produto para o mercado interno (DONADIO, 1996).

---

<sup>1</sup> Os testes sensoriais fazem parte do controle da qualidade de um produto, por ser uma medida multidimensional integrada, que possui vantagem como, por exemplo, é possível determinar a aceitação de

Estima-se que existam em todo o mundo, cerca de 500 a 1000 variedades de manga. No Brasil, são cultivadas atualmente, diversas variedades, estando entre as principais: *Alfa*, *Bourbon*, *Coração de Boi*, *Espada*, *Haden*, *Keitt*, *Kent*, *Palmer*, *Rosa* e *Tommy Atkins*. Algumas nasceram e se desenvolveram no País; muito se deve ao trabalho da Empresa Brasileira de Pesquisa Agropecuária - EMBRAPA; outras variedades são de origem estrangeira, sendo a maior parte dessas, originárias dos Estados Unidos.

Os principais produtores da fruta no país eram, até o início da década passada, os Estados de São Paulo e de Minas Gerais, que, juntos, alcançavam cerca de 50 % da área planta da e 25 % do total da produção nacional.



**Figura API-6:** Produção de manga no Brasil Distribuição da produção por regiões. Fonte: Extraído de EMBRAPA/CNPTIA, 2012

Hoje, os estados campeões de produção são Bahia e Pernambuco. A região nordeste tornou-se responsável por praticamente 50% da produção nacional, bem como, por mais de 80% da produção direcionada à exportação (Figura API-6).

## 7. Processos de Colheita da manga *Tommy Atkins*

Os processos pós-colheita consideram principalmente, aspectos da fisiologia da manga, como respiração, transpiração, transformações químicas, distúrbios fisiológicos e doenças causadas por microrganismos que ocorrem durante o período de amadurecimento e senescência dos frutos; englobam ainda boas práticas de colheita e de manuseio pós-colheita, que são adotadas com a finalidade de manter a qualidade dos frutos por períodos prolongados.

## 8. Produção Integrada de Frutas

A Instrução Normativa (IN) Nº 20 de 27 de setembro de 2001, do Ministério da Agricultura, Pecuária e Abastecimento, define as diretrizes gerais e as normas técnicas para o processo PIF - Produção Integrada de Frutas. Foi esta IN que estabeleceu o marco legal para a regulamentação da PIF no Brasil, consagrando-o como um processo público de certificação brasileiro para o setor.

A Portaria nº 144 de 31 de julho de 2002 do Instituto de Metrologia, Normalização e Qualidade Industrial - INMETRO, estabelece que as frutas PIF orientadas para comercialização “in natura”, destinadas ao mercado nacional ou exportadas, poderão ser avaliadas no âmbito do SBAC - Sistema Brasileiro de Avaliação da Conformidade.

A adoção da Produção Integrada de Frutas - PIF (LOPES *et al.*, 2001) pelos produtores tornou-se uma exigência dos mercados importadores, principalmente da Comunidade Europeia, que adotou essa medida para garantir a qualidade desses produtos. Com isso, as práticas de colheita e de manuseio pós-colheita passaram a contemplar não apenas requisitos que garantam a qualidade da fruta, mas também aqueles que promovam a sustentabilidade ambiental, a segurança alimentar, a saúde e a segurança do trabalhador e a viabilidade econômica, assegurando seu controle e sua “rastreadibilidade”<sup>2</sup> (ANDRIGUETO E KOSOSKI, 2002).

O sistema de produção integrada está se constituindo num paradigma da produção agrícola em todo o mundo. É um conjunto de normas e procedimentos aplicáveis sobre práticas agrônômicas, cujos componentes são selecionados a partir de insumos disponíveis na região produtora, que numa visão global, asseguram a qualidade e a produtividade das culturas em condições de sustentabilidade.

Os métodos aplicados na produção são gerenciados considerando vários aspectos, que incluem as exigências dos consumidores, a disponibilidade de recursos na região, a viabilidade econômica da atividade e a proteção ao meio ambiente.

O modelo esquemático apresentado na Figura API-7 mostra os componentes da Produção Integrada de Frutas (PIF) utilizados na região do Submédio do Vale do São Francisco, em

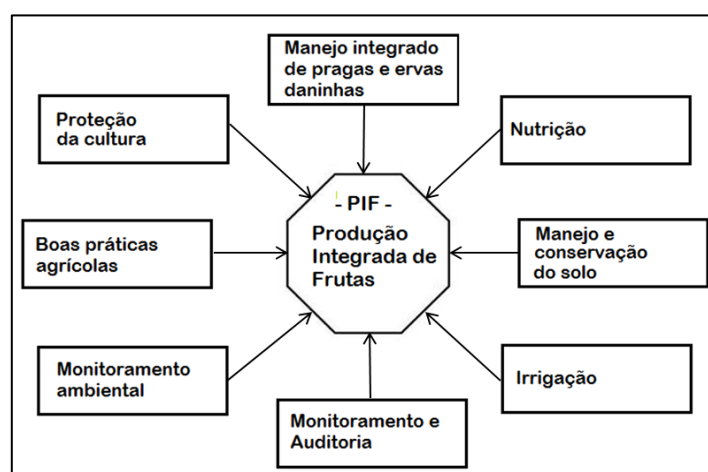
---

<sup>2</sup> “Rastreadibilidade” é a capacidade de traçar o histórico, a aplicação ou a localização de um item através de informações previamente registradas, de acordo com a norma ISO8402.

cujo programa está prevista ainda a criação de um selo de qualidade, certificando que as frutas foram produzidas dentro das normas exigidas (CPATSA, 2013).

São várias as vantagens econômicas advindas da PIF, como a minimização de custos de produção, redução do desperdício e de insumos agrícolas, além de proporcionar o consumo de produtos saudáveis e de qualidade certificada.

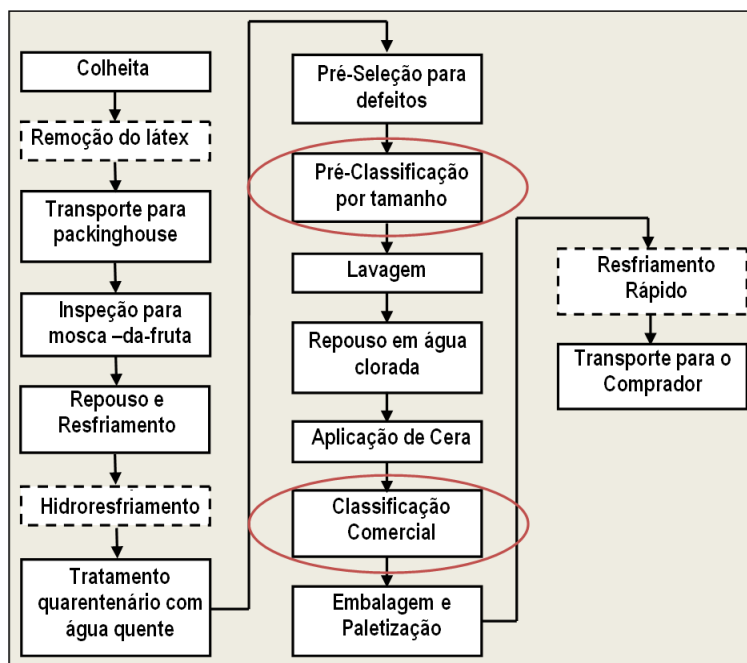
A PIF atinge todos os processos da produção, indo desde a seleção da semente até a prateleira, eliminando produtos de baixa qualidade e portadores de níveis de resíduos agrotóxicos nos produtos, que possam comprometer a integridade física do consumidor.



**Figura API-7:** Modelo esquemático do processo de manejo PIF. Fonte: Extraído de (CPATSA, 2013).

O objetivo da PIF não é o aumento da produtividade, mas assegurar a sustentabilidade dos níveis obtidos pela produção convencional, de uma forma mais saudável para o consumidor e para o meio ambiente, otimizando a qualidade do produto. Em alguns casos, a produtividade aumenta em decorrência do rigor exigido pelo sistema no acompanhamento das atividades de manejo e das tecnologias aplicadas.

Representações esquemáticas dos procedimentos descritos nesses trabalhos são apresentadas nas Figuras API-8 e API-9; alguns dos métodos desenvolvidos neste trabalho são aplicados nas tarefas em destaque.



**Figura API-8:** Métodos PIF da colheita ao transporte. Fonte: Adaptação do autor a partir de PIF/Mangas em [www.cpatas.embrapa.br:8080/pif/manga](http://www.cpatas.embrapa.br:8080/pif/manga).



**Figura API-9:** Métodos PIF da recepção à comercialização. Fonte: Adaptação do autor a partir de PIF/Mangas em [www.cpatas.embrapa.br:8080/pif/manga](http://www.cpatas.embrapa.br:8080/pif/manga).

A principal vantagem da adoção da PIF é a adequação às exigências do mercado internacional de frutas frescas, viabilizando sua abertura pelo fato do sistema transmitir maior credibilidade do aspecto “qualidade do produto”. Isso significa também uma vantagem competitiva no mercado interno, já que consumidor brasileiro está exigindo cada vez mais, produtos saudáveis, de melhor qualidade, cuja produção não agrida o meio ambiente.



Uma variação da PIF orientado para mangas, denominado PIM - Produção Integrada de Mangas (Quadro API-4), é encontrada em LOPES (2001); um trabalho denominado “Monitoramento e Avaliação da Cadeia de Suprimento da Manga para Melhorar a Qualidade da Manga”, financiado pela *National Mango Board* (NMB) dos Estados Unidos, culminou com o lançamento de um manual de melhores praticas de manejo para a colheita e manuseio das mangas comercializadas aquele país (NMB, 2011).

**Quadro API-4-** Detalhamento de procedimentos PIF para mangas. Fonte: Adaptação do autor a partir de PIF/Mangas em [www.cpsa.embrapa.br:8080/pif/manga](http://www.cpsa.embrapa.br:8080/pif/manga).

<b>Procedimentos PIF para manga</b>	
Colheita	<ul style="list-style-type: none"> <li>• A colheita das mangas que se encontram ao alcance das mãos, deve realizada com a utilização de uma tesoura de poda ou lâmina apropriada; o pedúnculo deve ser cortado com aproximadamente 1,5 cm de comprimento, para que sejam reduzidos ou evitados o vazamento do látex e a entrada de microrganismos no fruto. Quando as mangas estiverem longe do alcance das mãos, deve-se utilizar o colhedor de saco ou escadas.</li> <li>• As caixas de transporte devem estar sempre em bom estado de conservação; não podem possuir arestas cortantes ou pontiagudas; a superfície interna dos mesmos deve ser lisa e uniforme; esses contenedores precisam ser limpos e sanitizados com água clorada; devem ser frequentemente verificados para evitar unidades com defeitos que possam machucar as frutas; durante a colheita, devem ser enfileirados ao longo da linha de plantio, à sombra, afastado do contato com o solo por uma manta de plástico ou lona, que deve ser mantida sempre limpo e deve ser colocado sempre com o mesmo lado em contato com o solo. As frutas devem ser colhidas utilizando um instrumento de corte adequado e submetido a um processo de sanitização. Um espaço vazio entre os contentores empilhados deve ser deixado; frutas manchadas com látex devem ser encaminhadas separadamente das demais.</li> <li>• Para garantir a rastreabilidade do produto, cada lote de frutas deve ser identificado com uma etiqueta onde conste no mínimo: o produtor, a data de colheita, a variedade, o número do lote e o responsável pela colheita.</li> </ul>

## Continuação...

**Quadro API-4-** Detalhamento de procedimentos PIF para mangas. Fonte: Adaptação do autor a partir de PIF/Mangas em [www.cpatsa.embrapa.br:8080/pif/manga](http://www.cpatsa.embrapa.br:8080/pif/manga).

Remoção do Látex	<ul style="list-style-type: none"> <li>• A prática comum para exsudação do látex é cortar o pedúnculo na região em que há a imediata exsudação do látex e colocar a fruta com esta parte em contato com o solo até que não haja mais a saída desta substância. No sistema PIM isso não é permitido, empregando-se mesas de metal com tampo de tela de arame, onde as mangas são colocadas longe do solo e o látex escoar para o solo sem manchá-las. O tempo dessa operação é considerado longo, podendo chegar a mais de 30 minutos.</li> </ul>
Transporte para o armazém de embalagem	<ul style="list-style-type: none"> <li>• Inicialmente, os veículos de transporte devem estar sempre limpos para se evitar contaminações com terra, fertilizantes, sujeira, etc. Devem ter a capacidade de carga obedecida e suas carrocerias adequadas ao transporte da carga e grande capacidade de absorver impactos. Não se deve transportar frutas a granel ou utilizar veículos de tração animal.</li> <li>• O transporte para o armazém de embalagem (packinghouse) deve ser feito de maneira cuidadosa, para evitar danos mecânicos durante esse processo. A exposição ao sol da carga deve ser evitada ao máximo. Quanto mais rápido o transporte do campo para o galpão de embalagem, menor a possibilidade de perdas pela deterioração causada por altas temperaturas. No verão ou em dias de grande insolação, a carga deve ser coberta com lona clara, telas de sombreamento (sombrite 50%) ou tecido de algodão cru, de maneira a permitir uma ventilação adequada por entre a cobertura e as mangas.</li> <li>• O transporte de outras frutas da PIF conjuntamente com a manga pode ser realizado desde que os lotes sejam devidamente identificados, separados e livres do risco de contaminação.</li> </ul>
Inspeção para mosca-da-fruta	<ul style="list-style-type: none"> <li>• As moscas da fruta (<i>Diptera tephritidae</i>) são classificadas como “insetos de quarentena”. Assim, um lote de fruta exportado para a Europa, por exemplo, contendo uma única fruta infestada, pode ser totalmente rejeitado e destruído pelas autoridades fitossanitárias europeias.</li> <li>• São 12 as espécies de que atacam a manga; dentre essas, duas são consideradas como mais prejudiciais: a <i>Ceratitis cosyra</i> e a <i>Bactrocera invadens</i>.</li> </ul>

## Continuação...

**Quadro API-4-** Detalhamento de procedimentos PIF para mangas. Fonte: Adaptação do autor a partir de PIF/Mangas em [www.cpatsa.embrapa.br:8080/pif/manga](http://www.cpatsa.embrapa.br:8080/pif/manga).

Inspeção para mosca-da-fruta	<ul style="list-style-type: none"> <li>• O método considerado mais eficaz para interromper o ciclo de desenvolvimento da mosca-da-fruta é retirar toda a fruta caída no chão para evitar que os insetos adultos depositem nela seus ovos.</li> <li>• Durante a colheita, a seleção da fruta e a recepção no galpão de empacotamento, a fruta deve ser inspecionada e qualquer uma que apresente traços de ataque das moscas deve ser destruída.</li> <li>• Nenhuma fruta rejeitada na inspeção deve ser deixada próxima ao pomar ou aos lugares de processamento para evitar contaminação.</li> </ul>
Tratamento hidrotérmico quarentenário	<ul style="list-style-type: none"> <li>• No Brasil, desde a década de 90, o tratamento hidrotérmico vem sendo utilizado como método primário para a desinfestação pós-colheita de frutas atacadas pelas diversas espécies de moscas-das-frutas. Os métodos quarentenários variam de acordo com a espécie da mosca; alguns são definidos por órgãos regulamentadores sanitários, como o <i>APHIS</i> Departamento de Agricultura dos Estados Unidos - <i>USDA</i> (NASCIMENTO <i>et al.</i> 1992). Essa regulamentação exige tratamento com água quente a 46,1°C, com a duração da imersão variando de acordo com o formato e a massa da fruta.</li> <li>• Os produtores brasileiros adotam esse método, com imersão dos frutos em água aquecida a 46,1°C, pelo tempo de 75 minutos para frutos com massas até 425g e de 90 minutos para frutos de 426g até 650g (NASCIMENTO <i>et al.</i> 1992).</li> </ul>
Recepção dos lotes	<ul style="list-style-type: none"> <li>• Cada lote de frutas levado ao galpão deve ser univocamente identificado, com informações que permitam rastrear a sua procedência, manejo ante e pós-colheita, além da hora de chegada.</li> <li>• As mangas destinadas à exportação devem possuir o Certificado Fitossanitário de Origem (CFO).</li> <li>• A área de recepção das mangas deve ser protegida contra as intempéries climáticas e insetos</li> <li>• O layout da área de recepção deve ser organizado de maneira a permitir a livre movimentação das frutas entre as áreas de operacionais.</li> </ul>

## Continuação...

**Quadro API-4-** Detalhamento de procedimentos PIF para mangas. Fonte: Adaptação do autor a partir de PIF/Mangas em [www.cpatsa.embrapa.br:8080/pif/manga](http://www.cpatsa.embrapa.br:8080/pif/manga).

Recepção dos lotes	<ul style="list-style-type: none"> <li>• As mangas PIM podem ser mantidas juntamente com as de outro sistema de produção ou outros produtos agrícolas, desde que sejam devidamente identificadas, separadas e os procedimentos contra riscos de contaminação sejam realizados.</li> </ul>
Pré-resfriamento/ Hidroresfriamento	<ul style="list-style-type: none"> <li>• As mangas com temperaturas elevadas devem ser rapidamente refrigeradas, para evitar a perda de água e suas consequências, como o aumento na velocidade do amadurecimento, e a perda de massa. A aparência das frutas também pode ficar comprometida, assim como a firmeza das mesmas, que podem ser tornar flácidas e murchas.</li> <li>• Esse procedimento pode ser realizado em túneis de ventilação forçada, requerendo neste caso, aproximadamente, 4 a 6 horas para reduzir a temperatura dos frutos a 10°C. A umidade relativa do ar, durante o resfriamento, deve ser mantida na faixa compreendida entre 85-95%, para evitar perda de água.</li> <li>• A utilização de água gelada ou gelo pode substituir o ar forçado, desde que se alcance ao final, a temperatura de 10°C. O resfriamento excessivo deve ser evitado, pois pode comprometer a qualidade da fruta.</li> </ul>
Seleção	<ul style="list-style-type: none"> <li>• Alguns frutos colhidos não tem valor comercial por apresentarem um ou vários defeitos, como imaturidade, maturidade excessiva, deformações, tamanho inadequado, manchas, danos mecânicos ou defeitos nutricionais, etc. Esses frutos devem ser eliminados no processo de seleção.</li> <li>• Tipicamente, essa é uma tarefa para mão de obra humana; os selecionadores devem estar posicionados comodamente, concentrados na tarefa, com capacidade de decisão com relação aos critérios e padrões de qualidade exigidos.</li> <li>• A seleção por massa pode ser mecânica, em máquinas selecionadoras, ou mesmo manual.</li> </ul>
Classificação	<ul style="list-style-type: none"> <li>• Esta é uma operação distinta da seleção; basicamente, classificar é identificar as características da fruta que a enquadra em um determinado padrão.</li> </ul>

## Continuação...

**Quadro API-4-** Detalhamento de procedimentos PIF para mangas. Fonte: Adaptação do autor a partir de PIF/Mangas em [www.cpatsa.embrapa.br:8080/pif/manga](http://www.cpatsa.embrapa.br:8080/pif/manga).

	<ul style="list-style-type: none"> <li>No Brasil não há nenhuma norma ou regulamento técnico de padrões de identidade e qualidade para mangas; esses padrões são determinados pelos países importadores, que ditam a cultivar, o tamanho ou massa, o estágio de maturação e a qualidade das frutas desejadas.</li> </ul>
Lavagem	<ul style="list-style-type: none"> <li>As mangas devem ser descarregadas dentro de tanques com água, sem que haja uma queda abrupta e acentuada, para evitar choques entre as frutas.</li> <li>O tanque de lavagem deve ser dotado de mecanismos de agitação, filtragem e circulação da água para a melhor remoção das sujeiras da superfície da fruta.</li> <li>A água utilizada na lavagem deve ser tratada e potável, com adição de cloro na concentração de 100 ppm.</li> <li>Quando ocorre o uso de detergentes, não se faz necessário o uso de água clorada, já que os detergentes neutralizam a ação germicida do cloro.</li> </ul>
Aplicação de cera	<ul style="list-style-type: none"> <li>A aplicação de cera é um procedimento que permite a reposição do brilho natural do produto, reduzido pela lavagem, permite ainda a redução da perda de água e pode ser associada a fungicidas.</li> <li>A cera deve ser aplicada em camadas bastante superficiais.</li> <li>No caso da manga, a formulação mais usada no Brasil é uma emulsão aquosa alimentícia de cera de carnaúba; que deve ser aplicada em frutos já limpos e secos por meio de bicos de aspersão, na medida em que os frutos passam por esteira.</li> <li>A secagem da cera pode ser feita em túnel de ar forçado, aquecido a 45°C.</li> <li>Geralmente, o polimento com escovas de crina é requerido.</li> </ul>
Embalagem	<ul style="list-style-type: none"> <li>A embalagem do produto é um importante requisito do método PIF, já que é o processo que mantém a fruta em um ambiente por um longo tempo.</li> <li>As exigências básicas do material de embalagem para manga incluem especificações para a proteção contra danos mecânicos; dissipação dos produtos da respiração (ventilação) e da energia térmica; o dimensionamento às normas de manejo, tamanho, massa; facilidade de</li> </ul>

## Continuação...

**Quadro API-4-** Detalhamento de procedimentos PIF para mangas. Fonte: Adaptação do autor a partir de PIF/Mangas em [www.cpatsa.embrapa.br:8080/pif/manga](http://www.cpatsa.embrapa.br:8080/pif/manga).

Embalagem	<p>acesso ao produto; custo adequado ao valor do produto.</p> <ul style="list-style-type: none"> <li>• A embalagem deve fornecer espaço adequado e homogêneo ao conteúdo, conter frutos da mesma origem, variedade, qualidade e tamanho.</li> <li>• A parte externa (visível) da embalagem deve ser atraente e representar adequadamente de todo o conteúdo.</li> <li>• Na caixa devem vir descritos, no mesmo lado, por extenso e de forma legível, informações acerca da identificação comercial, natureza e origem do produto.</li> <li>• As embalagens variam de acordo com o destino dos produtos.</li> <li>• Existem normas, como a INC (Instrução Normativa Conjunta) SARC/ANVISA/INMETRO N° 009, que especifica os requisitos mínimos de embalagens adequadas para frutas, incluindo mangas.</li> </ul>
Paletização	<ul style="list-style-type: none"> <li>• Nesse processo, as caixas de mangas devem ser empilhadas; a altura da pilha não deve ultrapassar determinado limite.</li> <li>• A amarração dos paletes deve ser feita com fitas adequadas para arqueação</li> <li>• Recomenda-se o uso de cantoneiras para alinhamento.</li> </ul>
Transporte para o comprador	<ul style="list-style-type: none"> <li>• Os veículos destinados ao transporte devem possuir dispositivos que permitam manter as condições ideais para manutenção da qualidade das frutas.</li> <li>• As frutas destinadas à exportação devem ser acondicionadas em containers com capacidade de 20 paletes; o carregamento deve ser feito de forma rápida e em local construído especialmente para este fim.</li> <li>• A temperatura ideal para as frutas durante o transporte está entre 10°C e 13°C. A renovação do ar dentro dos containers é imprescindível.</li> <li>• As condições de higiene do transporte também são imprescindíveis, de maneira a garantir a sanidade e inocuidade do produto.</li> <li>• Produtos de outras variedades e até mesmo outros produtos agrícolas podem compartilhar o veículo transportador, desde que separados.</li> </ul>

## Continuação...

**Quadro API-4-** Detalhamento de procedimentos PIF para mangas. Fonte: Adaptação do autor a partir de PIF/Mangas em [www.cpatsa.embrapa.br:8080/pif/manga](http://www.cpatsa.embrapa.br:8080/pif/manga).

Descarregamento	<ul style="list-style-type: none"> <li>• Ao chegar ao varejista, os produtos devem ser descarregados de acordo com as exigências feitas no pedido de compra.</li> <li>• Vários fatores podem influenciar o horário para a entrega do produto; independente disso, o produto deve ser mantido em condições ideais de transporte até a entrega.</li> <li>• Algumas das recomendações para o descarregamento são: <ul style="list-style-type: none"> <li>– Minimizar o tempo durante o qual as portas do caminhão refrigerado ficam abertas.</li> <li>– Otimizar o roteiro de entregas de maneira a economizar tempo e combustível.</li> <li>– Utilizar pessoal treinado, consciente da sensibilidade dos produtos agrícolas que são manuseados.</li> </ul> </li> </ul>
Estocagem	<ul style="list-style-type: none"> <li>• Recomenda-se que os varejistas disponham de câmaras frias para a estocagem de produtos como a mangas.</li> <li>• Um bom controle de temperatura até o momento em que as mangas são expostas para a venda tem um efeito positivo sobre a vida de prateleira das frutas.</li> <li>• É desejável expor mangas que estejam prontas para ser consumidas, de modo a causar um grande impacto visual e exibir suas melhores características de cor, brilho, textura e odor.</li> <li>• As mangas devem ser expostas em uma área aberta da loja; sua exposição em locais fechados não é recomendada.</li> <li>• As mangas não devem ser exibidas empilhadas umas sobre as outras, pois as frutas maduras sofrem amassamentos.</li> </ul>

Alguns deles métodos são descritos e comentados no Quadro AP-4, onde algumas das exigências que garantem a qualidade do produto processado estão parcialmente indicadas; alguns detalhes foram deliberadamente omitidos devido à sua grande extensão. Essas informações foram compiladas a partir de (SISGRIST, 2012), (CPATSA, 2013), (ASSIS *et al.*, 2013), (BRASIL, 2001a) e (BRASIL, 2001b).

## 9. O Mercado Mundial de frutas

O Brasil é atualmente o terceiro maior produtor mundial de frutas, seguindo a China e a Índia, que se colocam nas primeiras posições. O país é responsável por cerca de 5% da produção mundial, com um total superior a 42 milhões de toneladas em 2010 (Tabela API-1), e essa produção vem se expandindo nos últimos anos, com saldos positivos crescentes e impacto favorável na sua economia (FERNANDES, 2011).

**Tabela API-1:** Produção brasileira de frutas em 2010. Fonte: IBGE/lbraf - \*Em mil frutos. Conversão: 1 fruto = 2,5 kg (Região Sul- Sudeste, exceto PR (1,6 kg) e SC (1,67 kg)), 2,1 kg (Região Centro-Oeste) e 1,8kg (para as demais regiões).

Fruta	Produção (t)	Área (há)
Laranja	18.101.708	834.270
Banana	6.962.792	494.460
Abacaxi*	2.963.632	60.016
Melancia	2.052.928	96.477
Coco-da-baía*	1.891.687	276.616
Mamão	1.871.295	34.717
Uva	1.351.160	81.275
Maçã	1.279.026	38.717
<b>Manga</b>	<b>1.188.911</b>	<b>76.568</b>
Tangerina	1.122.730	61.670
Limão	1.020.345	44.194
Maracujá	920.158	62.243
Melão	478.431	18.870
Goiaba	316.363	15.677
Pêssego	220.739	20.295
Caqui	164.495	8.652
Abacate	152.181	11.051
Figo	25.727	2.934
Pera	16.367	1.540
Marmelo	964	209
<b>Total</b>	<b>42.101.639</b>	<b>2.240.451</b>

O mercado de frutas frescas detém atualmente, algo em torno de 47% dessa produção, de maneira que as exportações brasileiras dessa commodity têm sido pauta de destaque nas discussões de alternativas na geração de divisas para o país no comércio internacional nos



últimos anos. Com relação às exportações de frutas, a os volumes foram de aproximadamente 760 mil toneladas em 2010 e 681 mil toneladas em 2011 (Tabela API-2).

Com mais de 30 polos produtivos distribuídos no país, o incremento anual desse segmento, atinge uma média de 2,5% ao ano desde o início dos anos 90; a mesma taxa vem sendo mantida no crescimento das exportações.

Atualmente, a manga ocupa a nona posição na relação das frutas mais produzidas pelo Brasil; o país está entre os maiores produtores de manga do mundo, com uma produção aproximada de 1,2 milhão de toneladas.

**Tabela API-2:** Exportações brasileiras de frutas frescas em kg. Fonte: Extraído de FERNANDES (2011).

<b>Fruta</b>	<b>2010</b>	<b>2011</b>	<b>Var. (%)</b>
Melão	177.828.525	169.575.730	-4,64
<b>Manga</b>	<b>124.694.284</b>	<b>126.430.774</b>	<b>1,39</b>
Banana	139.553.134	110.053.925	-21,14
Maçã	90.839.409	48.666.209	-46,43
Laranja	37.821.810	33.310.972	-11,93
Melancia	28.261.716	29.287.478	3,63
Mamão	27.057.332	28.822.524	6,52
Abacate	2.699.698	3.263.236	20,87
Abacaxi	1.889.842	2.238.300	18,44
Figo	1.446.458	1.455.787	0,64
Tangerina	1.977.479	921.432	-53,40
Outrasfrutas	815.879	672.898	-17,52
Coco	407.737	479.345	17,56
Goiaba	147.348	137.455	-6,71
Pomelo	67.335	44.415	-34,04
Outros cítricos	4.519	26.561	487,76
Pera	22.738	16.128	-29,07
Framboesa/Amora	10.866	9.714	-10,60
Airela/Mirtilo	2.383	3.432	44,02
Cereja	48	1.385	2785,42
Ameixa	354	1.063	200,28
Damasco	112	91	-18,75
Pêssego	174	0	-100,00
Morango	2.976	0	-100,00
Mangostão	2.208	0	-100,00
Kiwis	142	0	-100,00
<b>Total</b>	<b>759.420.595</b>	<b>681.268.286</b>	<b>-10,29</b>

O mercado interno absorve praticamente 90% dessa produção, ou seja, apenas 10% da produção nacional de mangas são exportadas.

Mesmo com a queda na produção de frutas em 2011, quando a produção foi 10,29% menor que a do ano anterior (Tabela API-3), o resultado foi positivo, devido a forte alta no

valor das transações, que aumentaram 3,94% em relação ao ano anterior (valor bem acima da média histórica).

Os números referentes à exportação de manga nos últimos anos são bastante interessantes e refletem o enorme potencial desse produto para a exportação (Tabela API-3).

Considerando as cinco frutas com maior volume de exportação no ano de 2011, a manga foi a única dentre essas que manteve o volume de exportações crescente, embora isso tenha representado um aumento de apenas 1,39% em relação ao volume exportado no ano anterior; porém, devido ao elevado preço desse produto no mercado, o valor obtido aumentou em aproximadamente 17,5%. Isso elege a manga como o principal produto exportado em 2011 (UNCTAD, 2014).

**Tabela API-3:** Exportações brasileiras de frutas frescas em valor (US\$). Fonte: Secex/Elaboração (FERNANDES, 2011).

Fruta	2010	2011	Var. (%)
Melão	121.969.814	128.353.767	5,23
<b>Manga</b>	<b>119.929.767</b>	<b>140.910.324</b>	<b>17,49</b>
Banana	45.398.163	39.247.836	-13,55
Limão	50.693.603	65.806.140	29,81
Uva	136.648.806	135.782.857	-0,63
Maçã	55.365.805	36.059.461	-34,87
Laranja	16.276.736	16.364.077	0,54
Melancia	12.356.105	13.877.107	12,31
Mamão	35.121.752	38.887.743	10,72
Abacate	3.126.434	6.199.802	98,30
Abacaxi	998.318	1.401.952	40,43
Figo	7.310.886	7.300.741	-0,14
Tangerina	1.850.034	849.005	-54,11
Outras frutas	1.931.663	1.777.444	-7,98
Coco	121.240	259.795	114,28
Goiaba	326.364	300.067	-8,06
Pomelo	67.335	44.415	-45,76
Outros cítricos	4.978	115.017	2.210,51
Pera	15.819	17.704	-11,92
Framboesa/Amora	78.874	65.711	-16,69
Airela/Mirtilo	22.239	33.764	51,82
Cereja	72	2.632	3555,56
Ameixa	1.116	3.176	184,59
Damasco	1.055	837	-20,66
Pêssego	174	0	-100,00
Morango	9.675	0	-100,00
Mangostão	9.737	0	-100,00
Kiwis	307	0	-100,00
<b>Total</b>	<b>609.612.136</b>	<b>633.639.942</b>	<b>3,94</b>

## 10. O Mercado Mundial de mangas

A produção mundial de manga dobrou em pouco mais de trinta anos, chegando a um montante de cerca de 35 milhões de toneladas em 2009. A sua região de origem, o continente asiático, é o maior produtor mundial, sendo responsável por aproximadamente 77% da produção global. Em seguida, vêm os continentes americanos, com 13% e africano, com 10%.

A Índia é o principal produtor mundial, com uma média de 15 milhões de toneladas (Mt); a China ocupa a segunda posição, com pouco mais de 4 milhões de toneladas. No continente americano, o México, com 1,5 Mt e o Brasil com 1,2 Mt, ocupam respectivamente as 5ª e 7ª posições no ranking mundial. O principal país produtor de manga Africano é a Nigéria com 790 000 toneladas, seguido por Egito, com 450 000 toneladas (FAO, 2013). Os principais países produtores de manga estão pelo ranking (2010) de produção listados na Tabela API-4.

**Tabela API-4:** Principais produtores mundiais de manga em 2010. Fonte: Extraído de FAO (2013) "STATISTICS".

País	Produção
Índia	16,337,400
China	4,351,593
Thalândia	2,550,600
Paquistão	1,784,300
México	1,632,650
Indonésia	1,313,540
Brasil	1,188,910
Bangladesh	1,047,850
Filipinas	823,576
Nigéria	790,200

**Tabela API-5:** Evolução das exportações mundiais da manga. Fonte: Extraído de ITC em [www.trademap.org](http://www.trademap.org).

Ano	Toneladas (t)	Valor em US\$ * 1000
2001	715,341	95,958
2002	720,098	103,174
2003	980,728	123,707
2004	1,023,909	190,580
2005	1,120,842	324,961
2006	1,174,986	444,921
2007	1,278,176	338,939
2008	1,086,857	330,816
2009	1,451,357	403,965
2010	1,144,296	489,670

Existem três principais eixos comerciais definidos nas seguintes regiões do planeta: A Ásia comercializa principalmente com o Oriente Médio, a África exporta mangas para os mercados europeu e a América Latina abastece os mercados americano e europeu. Os principais mercados importadores são os Estados Unidos, com cerca de 330 000 toneladas em 2010, e a Europa, com 225 000 toneladas no mesmo ano (NMB, 2013).

O mercado mundial de manga é caracterizado pela competitividade e dinamismo por parte dos produtores, e pelo alto nível de exigência em termos de regulamentações sanitárias e fitossanitárias, por parte dos compradores. Entre 2001 e 2010, esse mercado teve uma evolução superior a 60% (Tabela API-5).


Apesar do aparente vigor desses números, os índices de exportação de manga do Brasil são baixos se comparados aos de outros países (Tabela API-6).

Desde 2004, o volume exportado pelo Brasil para os Estados Unidos, vem diminuindo, chegando a uma redução em 2012 de cerca de 11% do montante exportado em 2001.

Os Países latino-americanos são particularmente responsáveis pelo dinamismo do mercado atual, tendo progressivamente aumentando a sua oferta e conseqüentemente, sua fatia neste mercado. Na primeira década de 2000, o volume de sua exportação aumentou em quase 40 % para os Estados Unidos e 100% para a Europa. De maneira inversa, os volumes exportados para a Europa têm aumentado substancialmente, com um aumento de quase 45% entre 2001 e 2010, como mostra a Tabela API-6 (CORREIA, 2013).

**Tabela API-6:** Exportação de manga para o mercado Europeu. Fonte: Extraído de CORREIA (2013).

Exportador	Exportação Anual em toneladas (t).						
	2000	2005	2006	2007	2008	2009	2010
Brasil	39,636	82,293	84,858	83,025	96,870	80,670	92,880
Peru	9,304	26,394	41,027	36,854	50,756	36,270	60,129
Costa do Marfim	10,306	9,856	14,428	14,706	11,250	11,680	11,129
Israel	8,454	12,916	11,349	15,006	12,743	12,998	10,679
Paquistão	7,094	12,307	10,120	13,225	12,941	12,916	10,595
México	3,648	565	1,764	2,680	1,674	1,596	4,938
Estados Unidos	10,314	6,894	5,971	7,404	7,516	5,535	4,744
Rep. Dominicana	583	1,591	1,618	2,767	4,307	4,186	4,302
Mali	1,141	2,560	3,477	4,317	4,902	3,480	3,672
Costa Rica	3,092	6,271	7,545	4,664	5,360	5,685	3,452
Burkina Faso	182	1,164	2,152	3,191	2,406	1,988	3,304
Índia	1,746	1,722	2,472	2,428	2,577	2,472	3,116
Senegal	618	3,011	7,088	4,702	6,034	6,240	2 656



**Figura API-10:** Maiores receitas com frutos exportados em 2010 X 2011. Fonte: Extraído de <http://mercadofoco.apexbrasil.com.br>.

A receita proveniente das exportações de frutas frescas em 2011 teve na manga seu principal componente, como mostra a Figura API-10.

## 11. Bibliografia

ANDRIGUETO, J. R.; KOSOSKI, A. R.: **Marco legal da produção integrada de frutas do Brasil**. Brasília: Ministério da Agricultura, Pecuária e Abastecimento (MAPA)/Secretaria de Apoio Rural e Cooperativismo, 2002.

BRASIL: Definições e conceitos para os efeitos da produção integrada de frutas. **Diário Oficial - República Federativa do Brasil**, Brasília, DF. N. 237, 13 dez. Seção 1, 2001(a).

BRASIL: Instruções e normas técnicas gerais para a produção integrada de frutas. **Diário Oficial - República Federativa do Brasil**, Brasília, DF. N. 197, 15 out. Seção 1, 2001(b).

CARDELLO, H. M. A. B.; MORAES, M. A. C.: Análise sensorial de manga (*Mangifera indica* L.), var. HADEN, em pedaços, processada e congelada. **Alimentos e Nutrição** Araraquara, Vol. 8, Nº 1, 1997.

CPATSA: PIF: **Produção Integrada de Frutas**; Embrapa/Cpatsa-Centro de Pesquisa Agropecuária Trópico Sem1-Árido. Disponível na URL: <http://www.cpatna>.

embrapa.br:8080/pif/ manga /apresentacao.htm. Acesso em dezembro de 2013.

DONADIO, L. C. Variedades de Mangueira. Em: SÃO JOSÉ, A. R.; SOUZA, I. V. B.; MARTINS FILHO, J.; MORAIS, O. M. **Manga: Tecnologia de Produção e Mercado**. Capítulo 4. Universidade Estadual do Sudoeste da Bahia. Vitória da Conquista - BA. 1996.

FAO: **Annual Report of the Food and Agriculture organization of The United Nations**. Disponível na URL: [http:// faostat.fao.org/site/567/default.aspx#ancor](http://faostat.fao.org/site/567/default.aspx#ancor). Acesso em outubro de 2013.

FERNANDES M. S.: **Brasil: terceiro maior produtor mundial de frutas**. 2011. Artigo em Hipertexto. Disponível na URL: [http://www.brazilexportmagazine.com.br/revista/rev387/files/22e23\\_p.pdf](http://www.brazilexportmagazine.com.br/revista/rev387/files/22e23_p.pdf). Acesso em dezembro de 2012

FILHO W. P. C., ALVES H. S., MAZZEI A. R.: **Mercado de Manga no Brasil: contexto mundial, variedades e estacionalidade**. Artigo em Hipertexto. Disponível na URL: [http://www.iea.sp.gov.br/ out/publicacoes/pdf/tec4-0504.pdf](http://www.iea.sp.gov.br/out/publicacoes/pdf/tec4-0504.pdf). Acesso em novembro de 2011.

GALAN, V. The situations of mango culture in the world. **Acta Horticultrure Magazine**, V. 241, 1993.

NASCIMENTO, A. S.; MALAVASI, A.; MORGANTE, J. S.; DUARTE, A. L. Hot-water immersion treatment for mangoes infested with *Anastrepha fraterculus*, *A. obliqua* and *Ceratitis capitata* (Diptera: Tephritidae) in Brazil. **Journal of Economic Entomology**, Lanham, v.85, n.2, 1992.

NMB – **Annual report of the National Mango Board** (USA): [www.mango.org](http://www.mango.org). Acesso em setembro de 2013.

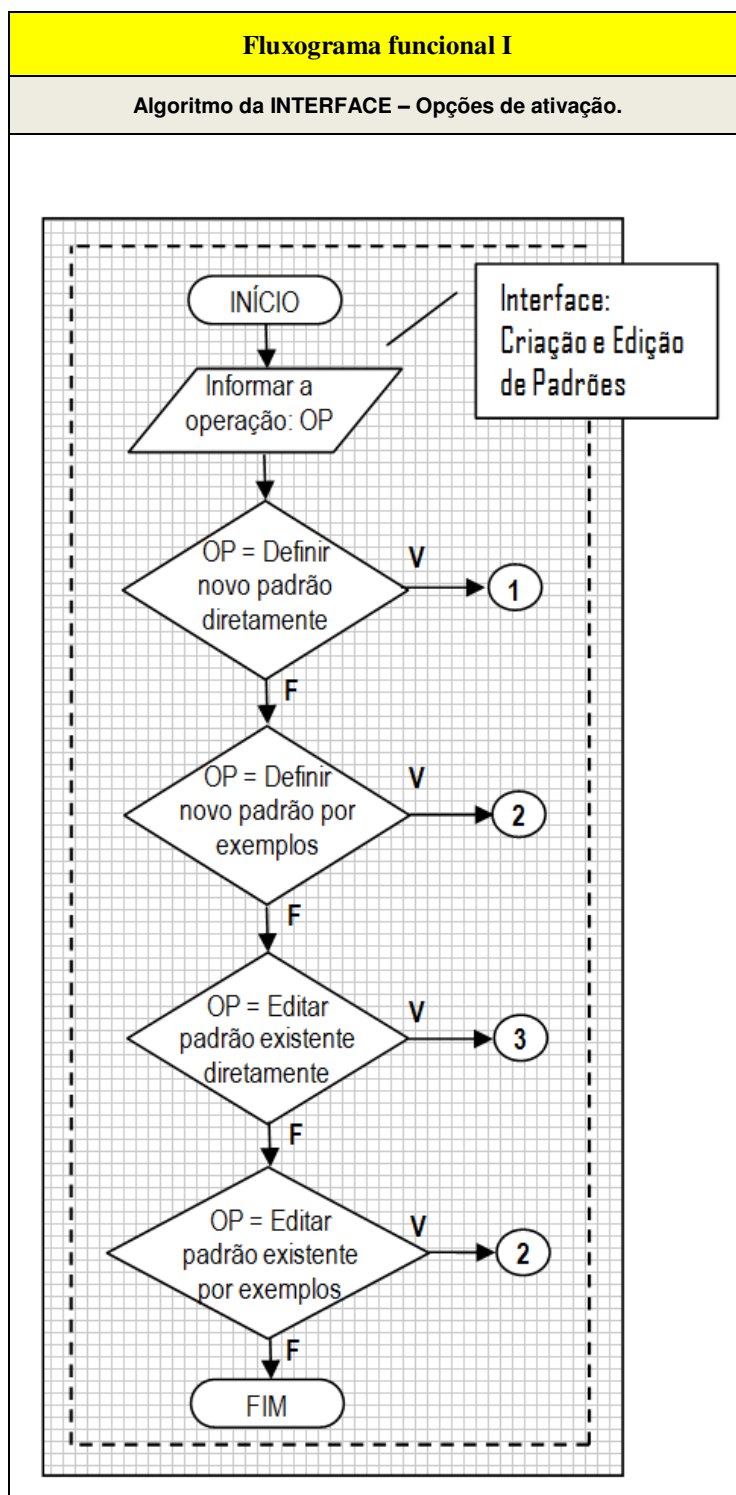
NMB - NATIONAL MANGO BOARD (USA): **Manual de Práticas para o Melhor Manejo Pós-Colheita da Manga**. Convênio SEBRAE/U. OF FLORIDA. Editor: Dr. Jeffrey K. Brecht, Universidade da Florida. National Mango Board 2011. Disponível na URL: [www.sebrae.com.br/setor/fruticultura](http://www.sebrae.com.br/setor/fruticultura) Acesso em janeiro de 2014.

RAVEN, P.; EVERT, R.; EICHHORN, S. **Biologia Vegetal**, 6ª edição, Editora Guanabara Koogan, Rio de Janeiro, 2001.

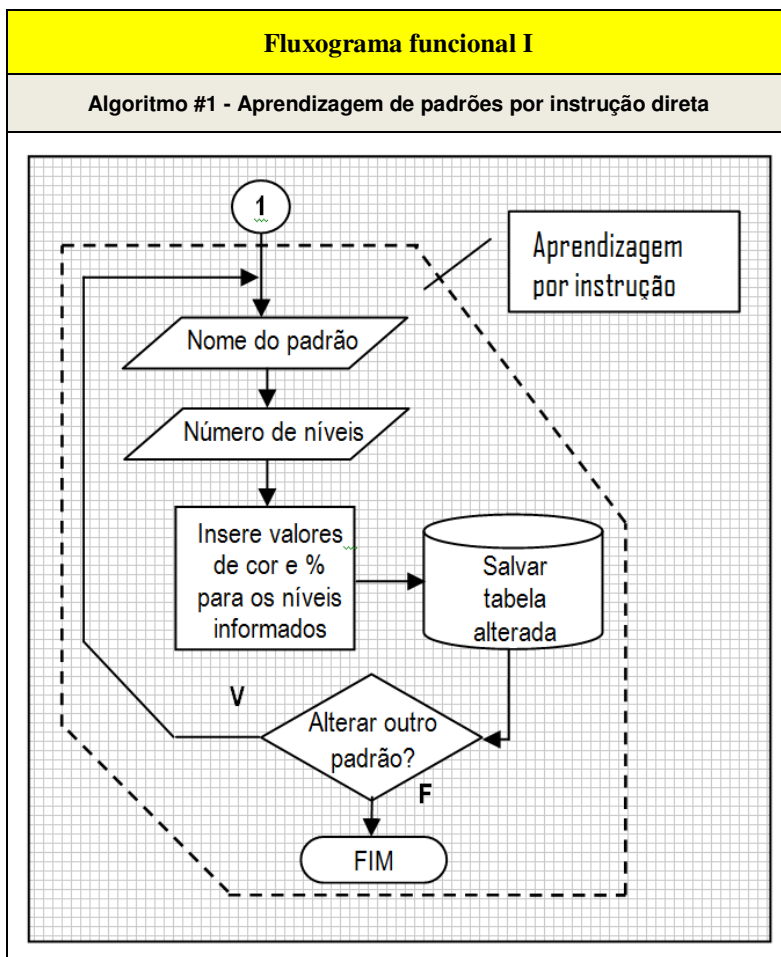
SEAGRI – **Informativo sobre a Manga - Cotações**. Portal da Secretaria de Agricultura do Estado da Bahia. Artigo em Hipertexto. Disponível na URL: <http://www.seagri.ba.gov.br/Manga.htm>. Acesso em janeiro de 2012.

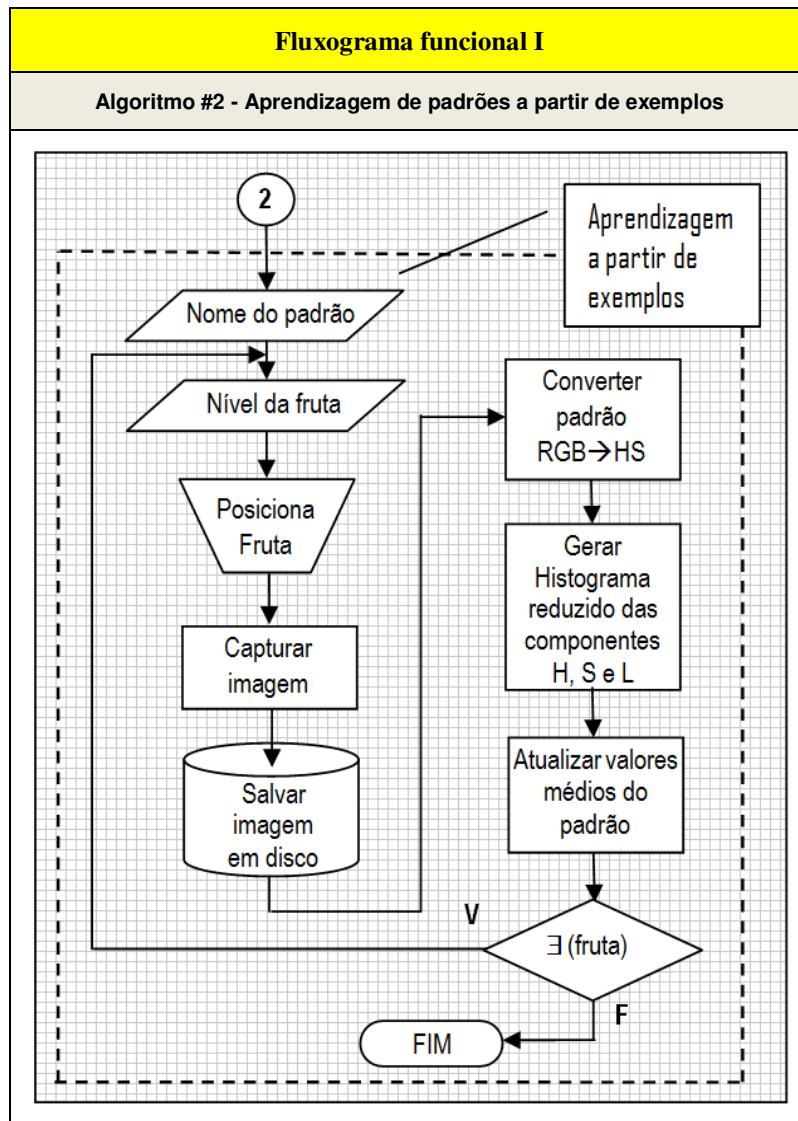
SISGRIST, J. M. M., **Tecnologia Pós-Colheita para a Comercialização de Manga In-Natura**. Instituto de Tecnologia de Alimentos – ITAL – Campinas, 2012. Disponível na URL: [http://www.nutricaoodeplantas.agr.br/site/ensino/pos/Palestras\\_William/Livromangapdf/16\\_tecnologia.pdf](http://www.nutricaoodeplantas.agr.br/site/ensino/pos/Palestras_William/Livromangapdf/16_tecnologia.pdf). Acesso em fevereiro de 2014.

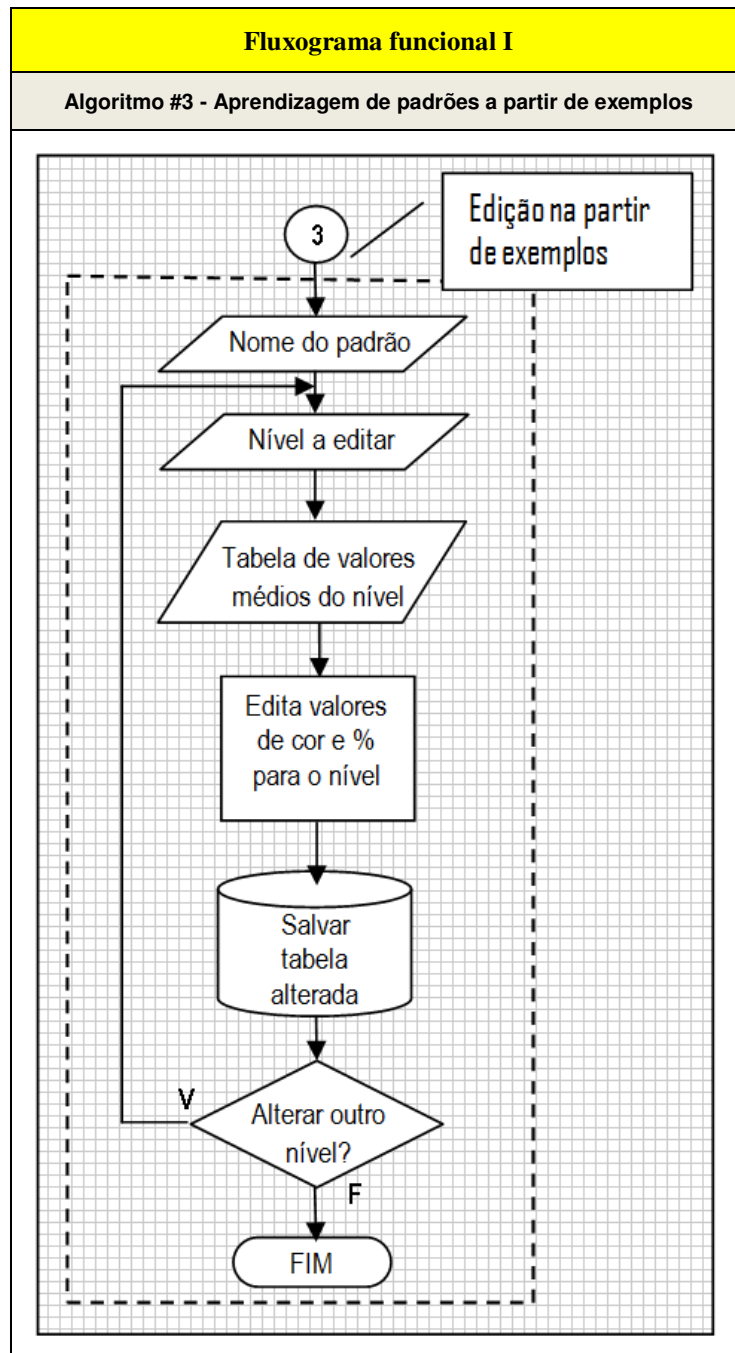
UNCTAD - **Annual Report of the United Nations Conference on Trade and Development**, Disponível na URL: <http://www.unctad.info/en/Infocomm/AACP-products/COMMODITY-PROFILE---Mango/>. Acesso em janeiro de 2014

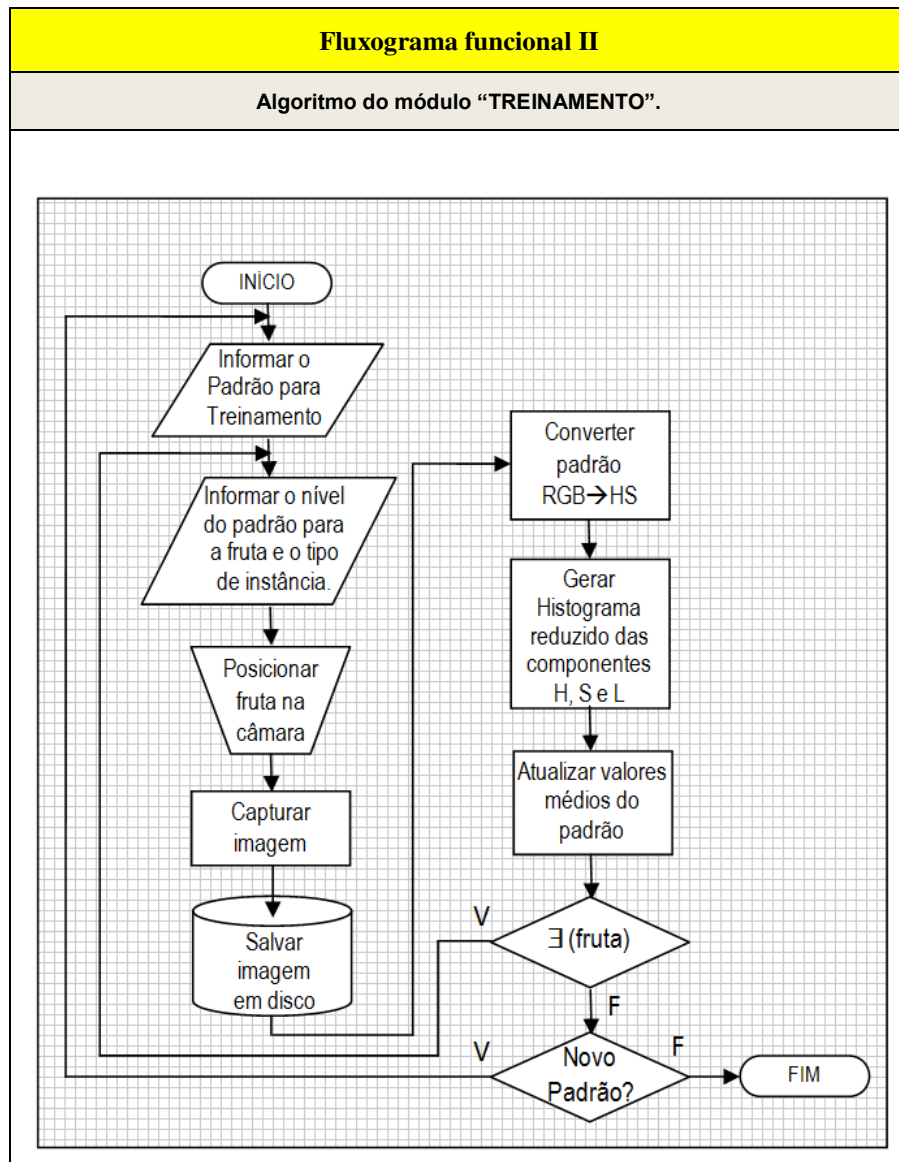


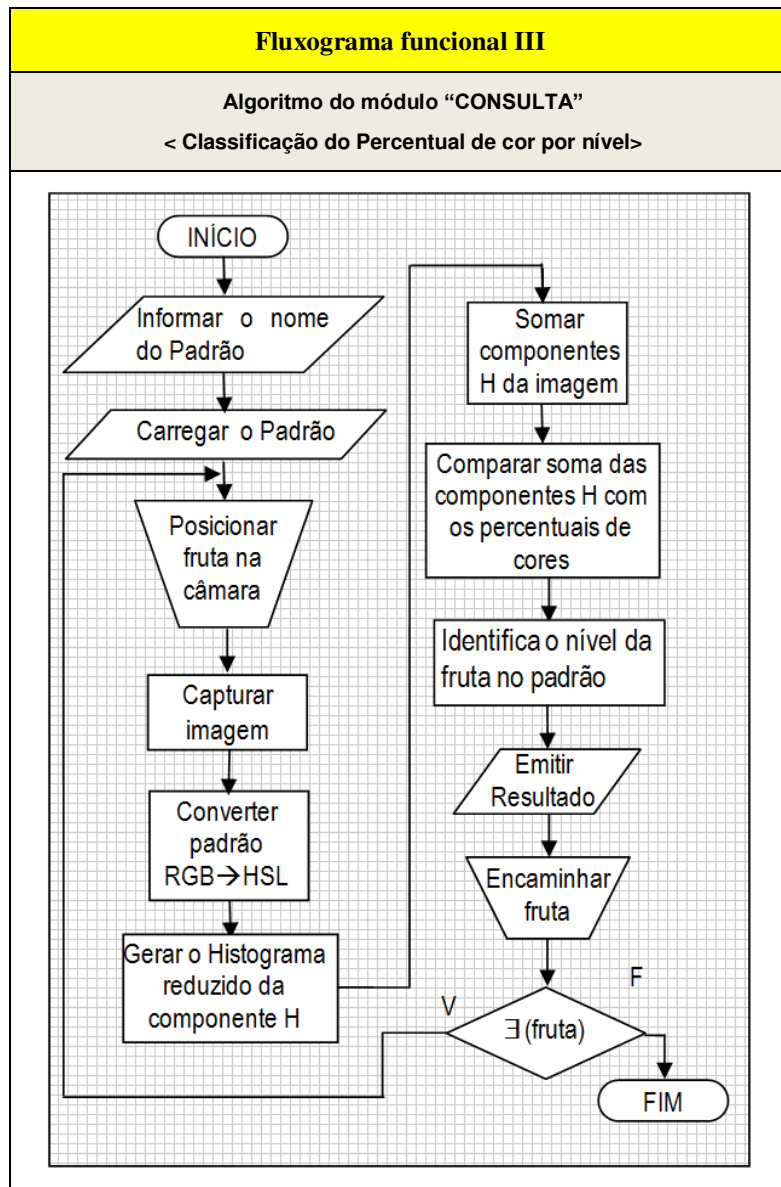


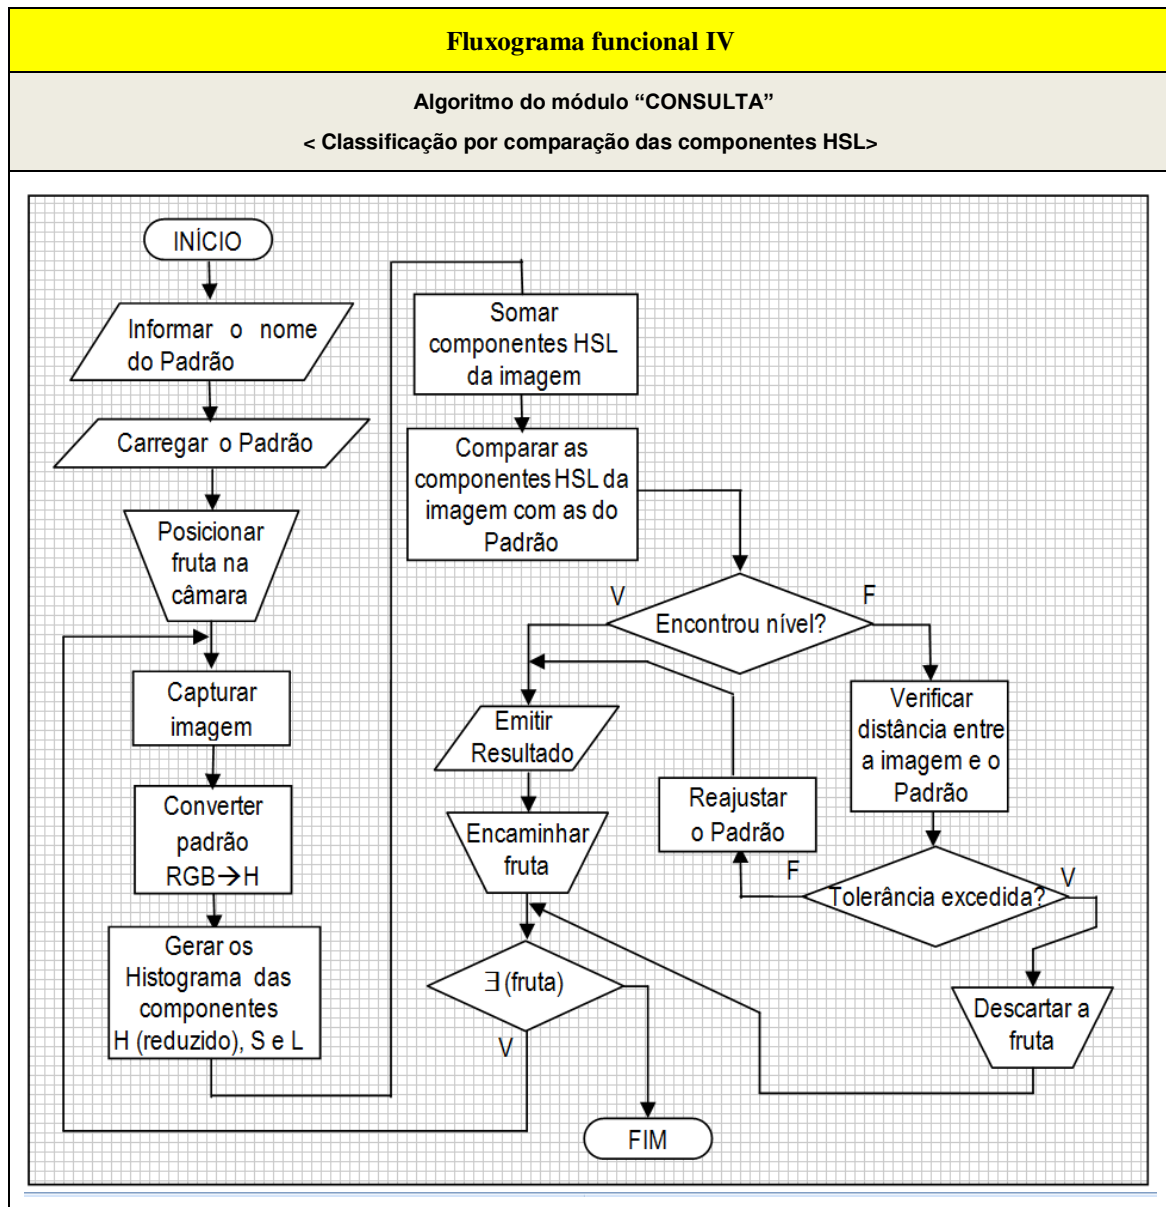


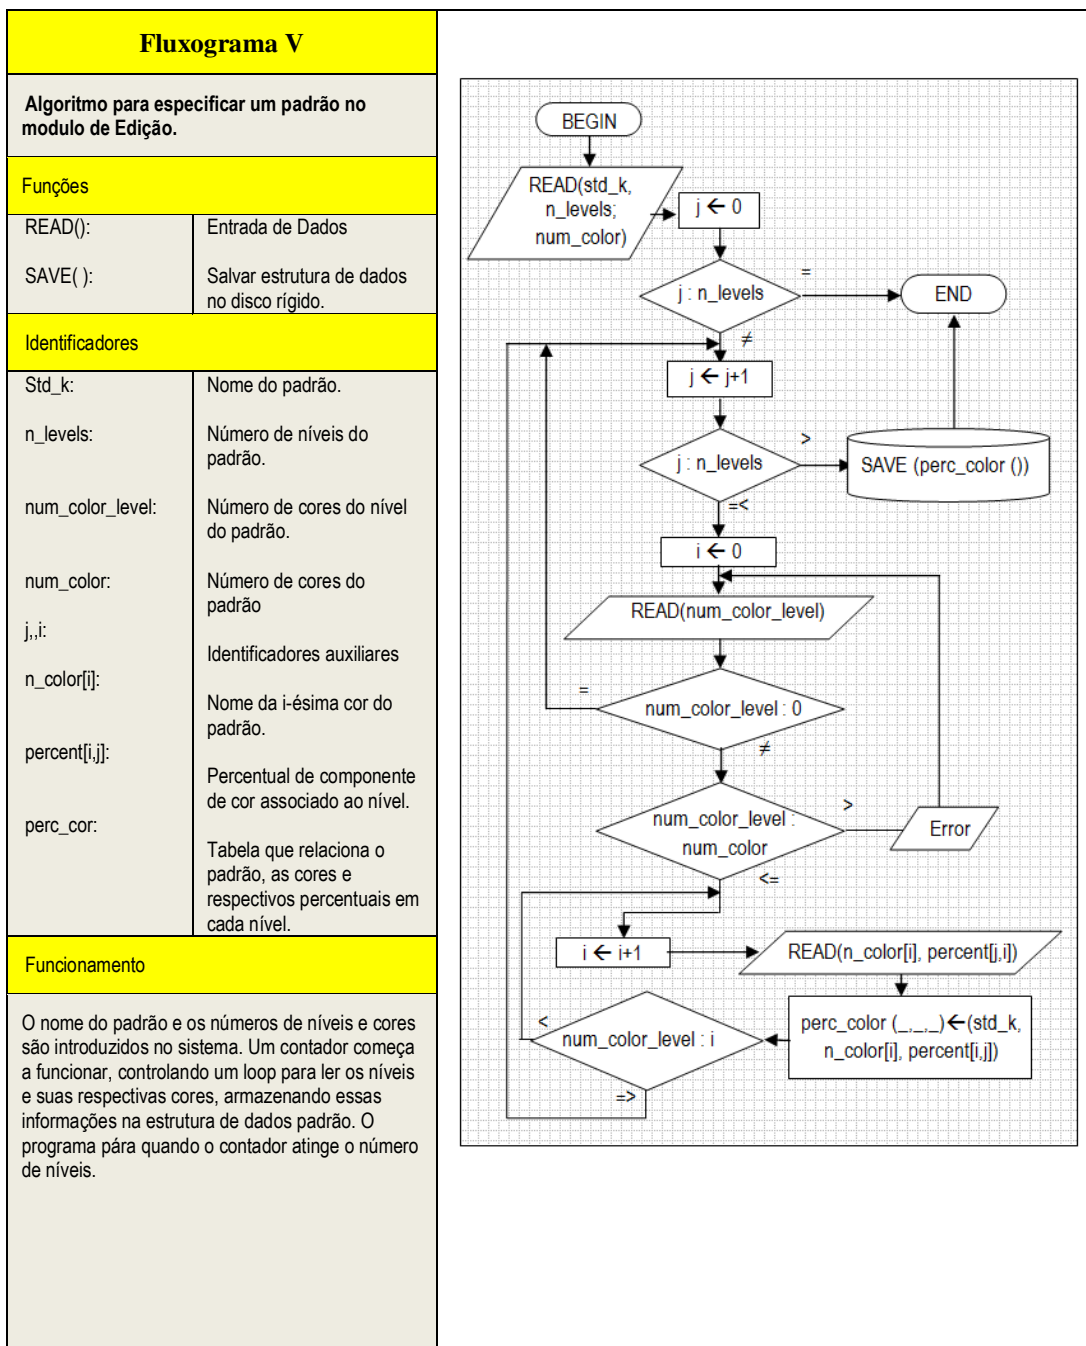


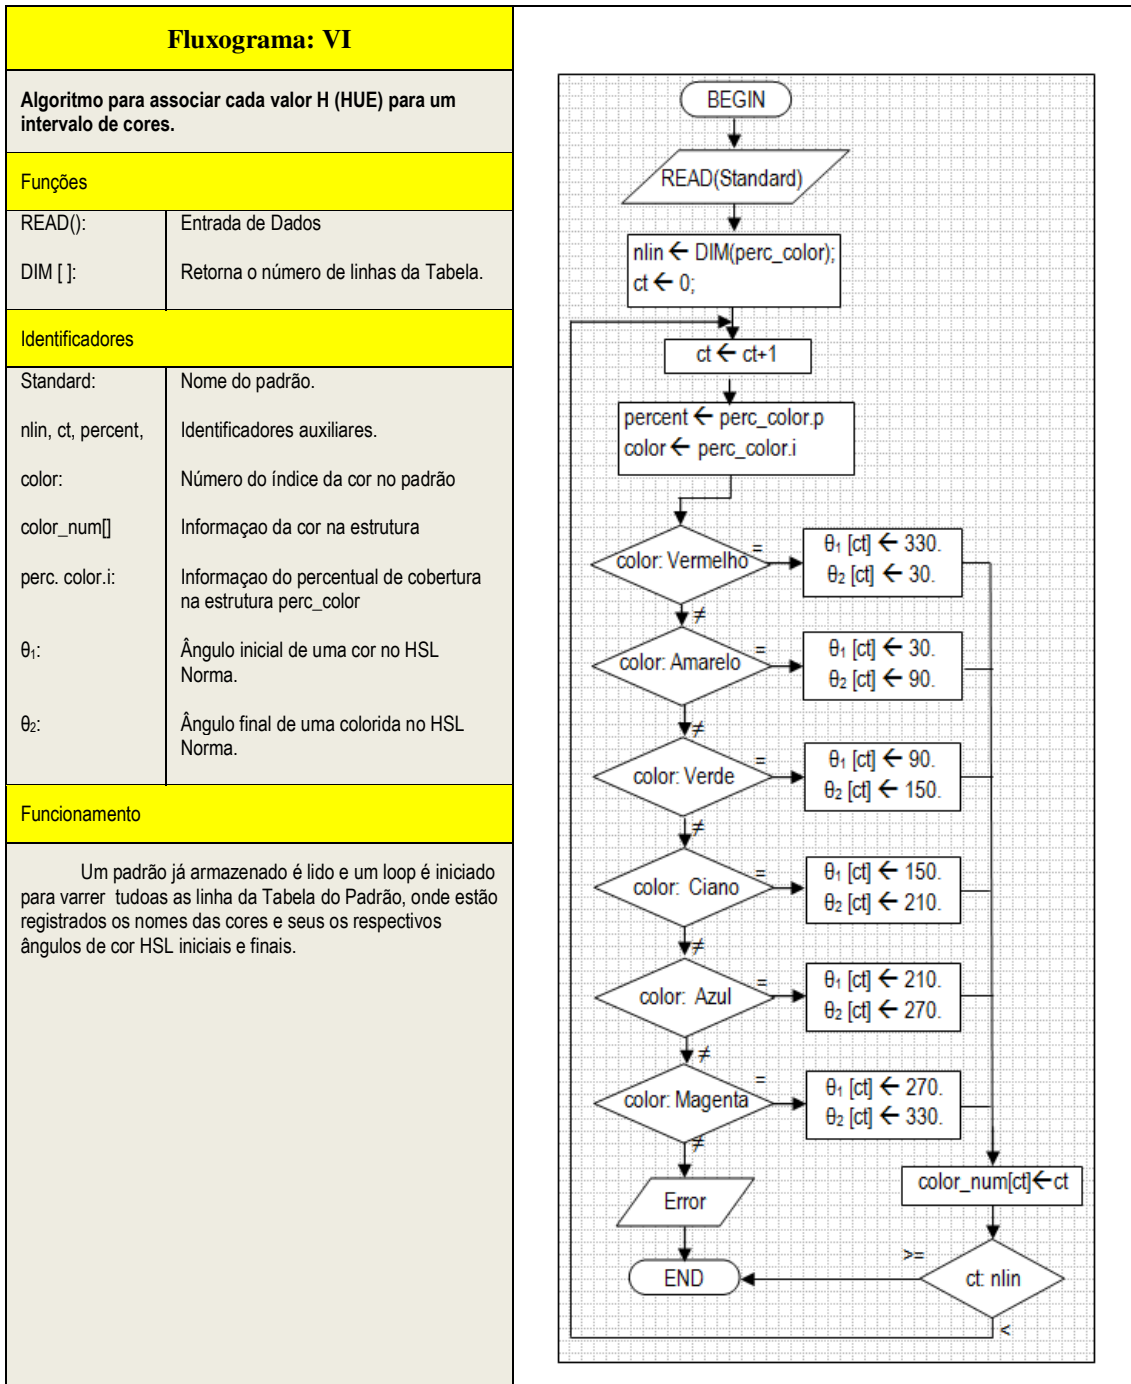














**Fluxograma VII**

**Algoritmo para identificar o nível do padrão de uma fruta por meio da análise do componente H (HUE).**

**Funções**

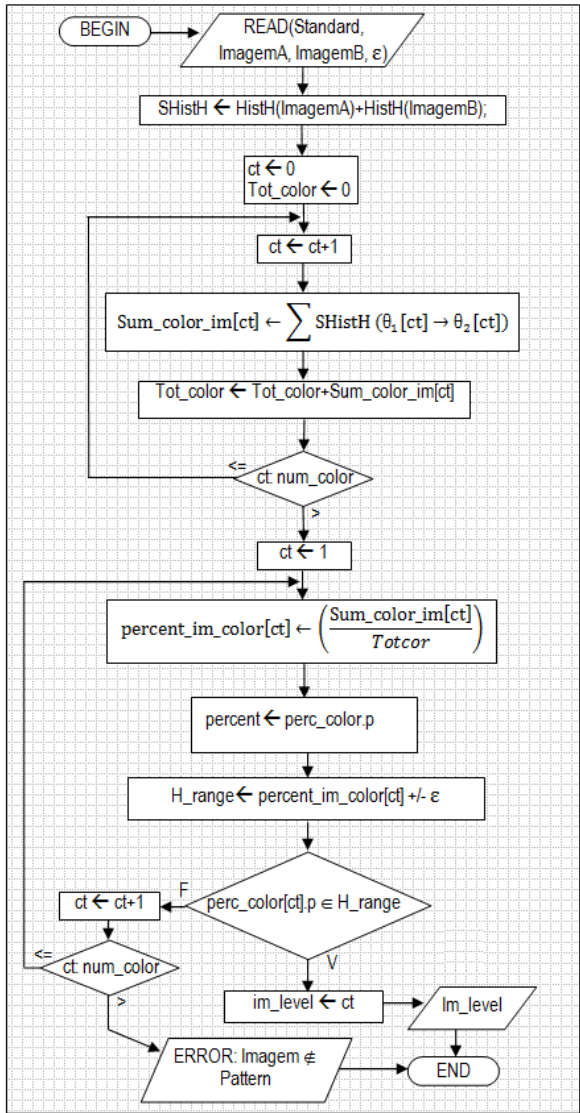
READ():	Entrada de Dados
HistH():	Retorna o Histograma H (matiz ou cor)
SHistH():	Soma os Histogramas H (matiz ou cor) das imagens das frutas.

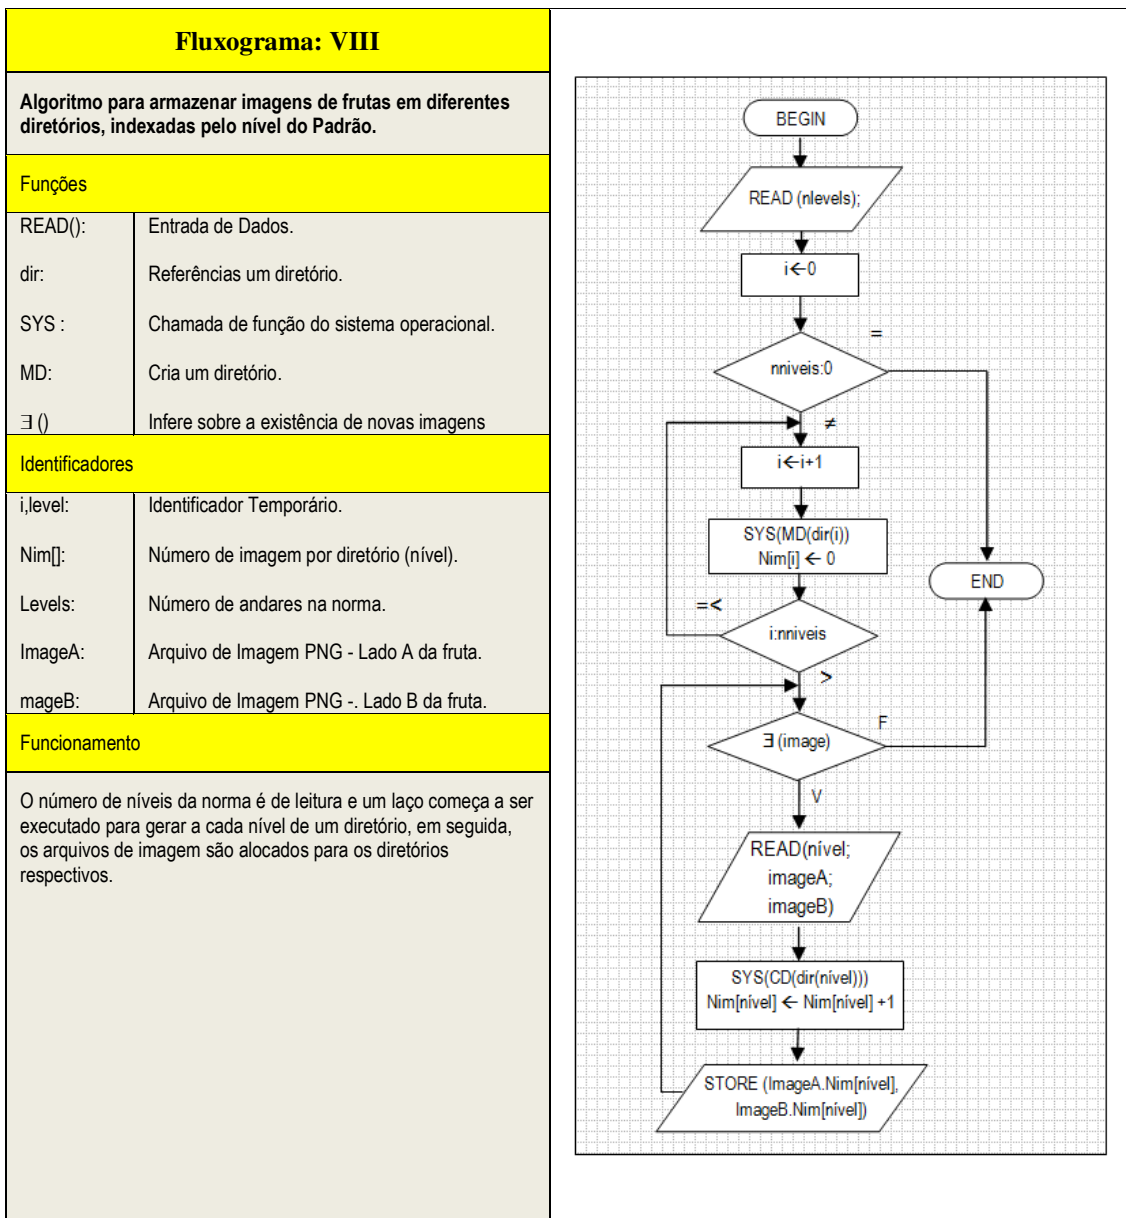
**Identificadores**

ImageA:	Arquivo de Imagem PNG - Lado A da fruta.
ImageB:	Arquivo de Imagem PNG - Lado B da fruta.
ct, percent:	Identificador Temporário.
Tot_color:	O valor total da soma do componente H (Cor ou matiz).
Sum_color_im[]:	Soma do componente H de uma imagem.
$\theta_1$ :	Ângulo inicial de uma cor no HSL Norma.
$\theta_2$ :	Ângulo final de uma colorida no HSL Norma.
perc_color.p	percentual de cor no nível.
Im_level:	Nível da fruta no padrão.
H_range:	Valor do intervalo de ângulos para uma cor no Padrão.
num_color:	Número de cores do padrão.
$\epsilon$	Distância máxima permitida – Erro máximo (%)

**Funcionamento**

Duas imagens são lidas (uma para cada lado da fruta em posição de repouso). Um loop digitaliza a imagem, somando os componentes de cor para cada cor no padrão. A porcentagem de cada cor é calculada e em seguida, comparada ao nível do padrão, para identificação do nível da fruta.





**Fluxograma IX**

**Cálculos dos Histogramas médios das componentes HSL para imagens contidas em diretórios associados aos níveis de um padrão.**

**Funções**

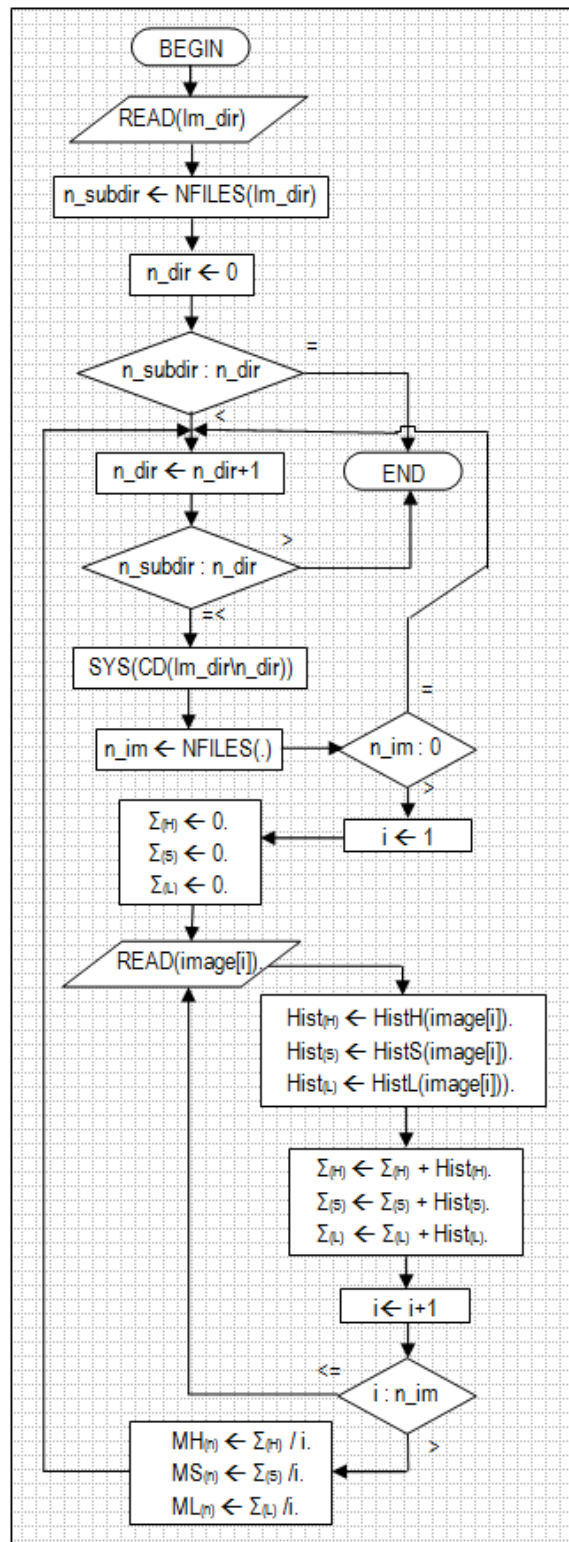
READ():	Entrada de Dados.
dir:	Referências um diretório.
SYS :	Chamada de função do sistema operacional.
MD:	Cria um diretório.
NFILES():	Retorna o número de arquivos em um diretório.
HistH():	Retorna o histograma do Matiz (Hue) de uma imagem.
HistS():	Retorna o histograma da Saturação de uma imagem.
HistL():	Retorna o histograma da Luminosidade de uma imagem.

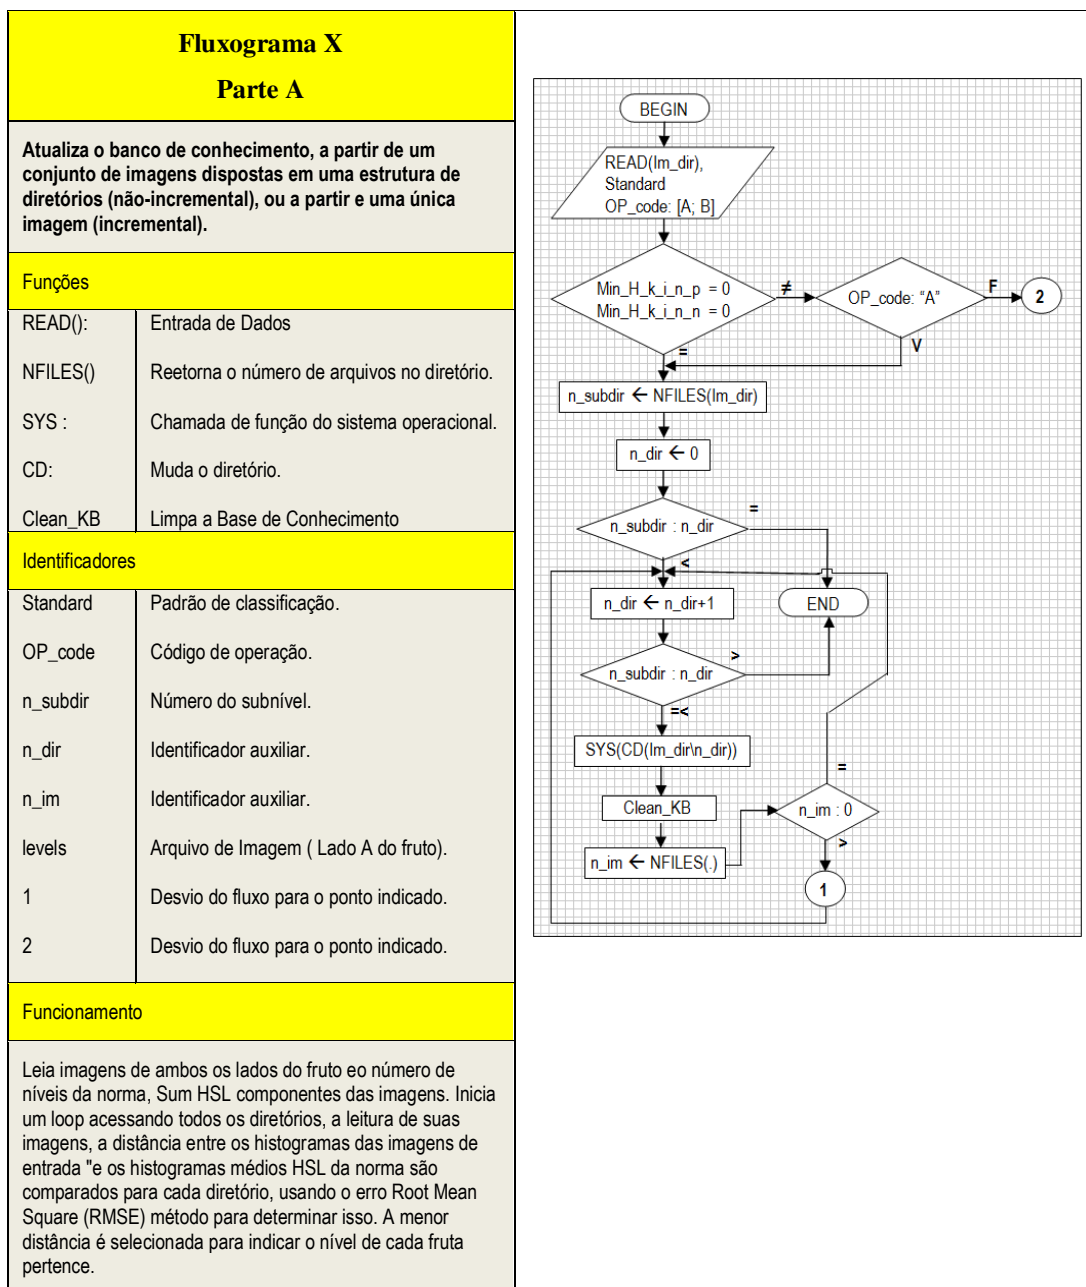
**Identificadores**

image:	Arquivo de Imagem.
n_subdir:	Número de arquivos em um diretório.
n_dir	Número de arquivos em um diretório.
n_im:	Número de arquivos de imagem
i :	Identificador auxiliar
Hist <sub>(H)</sub> :	Histograma do Matiz (Hue).
Hist <sub>(S)</sub> :	Histograma da Saturação.
Hist <sub>(L)</sub> :	Histograma da Luminosidade.
$\Sigma_{(H)}$ :	Soma dos histogramas de Matiz.
$\Sigma_{(S)}$ :	Soma dos histogramas de Saturação.
$\Sigma_{(L)}$ :	Soma dos histogramas de Luminosidade.
MH <sub>(n)</sub> :	A Histograma médio do Matiz.
MS <sub>(n)</sub> :	A Histograma médio da Saturação.
ML <sub>(n)</sub> :	A Histograma médio da Luminosidade.

**Funcionamento:**

Depois de ler o diretório onde se encontram as imagens de um padrão, os subdiretórios (Níveis do Padrão) são varridos dentro de um loop, para ler todas as imagens em cada diretório, calculando seus histogramas HSL e a média dos histogramas para o diretório. Todos os diretórios são visitados nesse processo; caso um diretório não possua imagens, ele lê as imagens do próximo diretório.

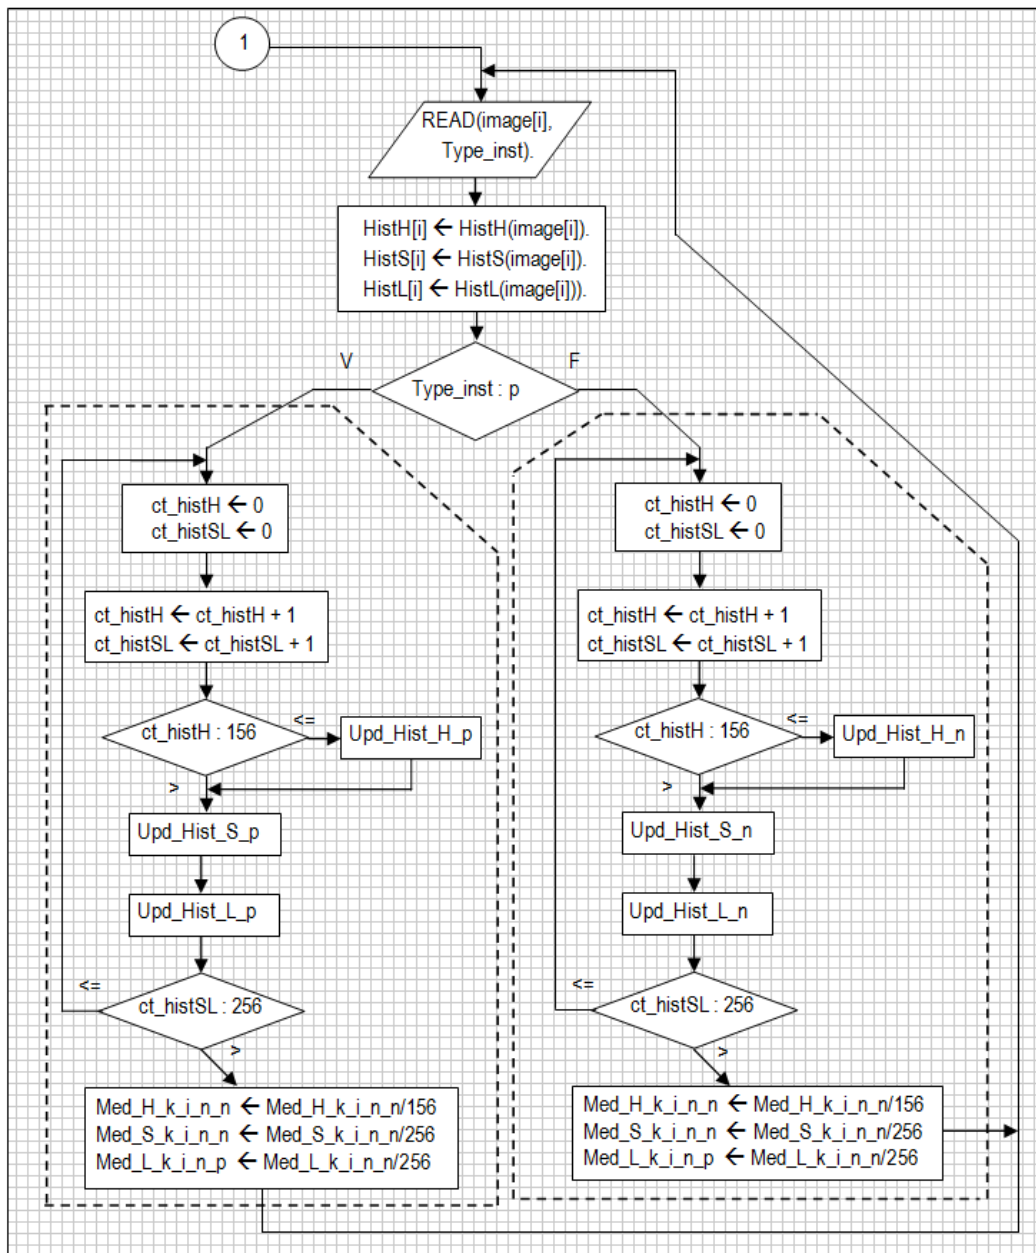




**Fluxograma X**

**Parte B**

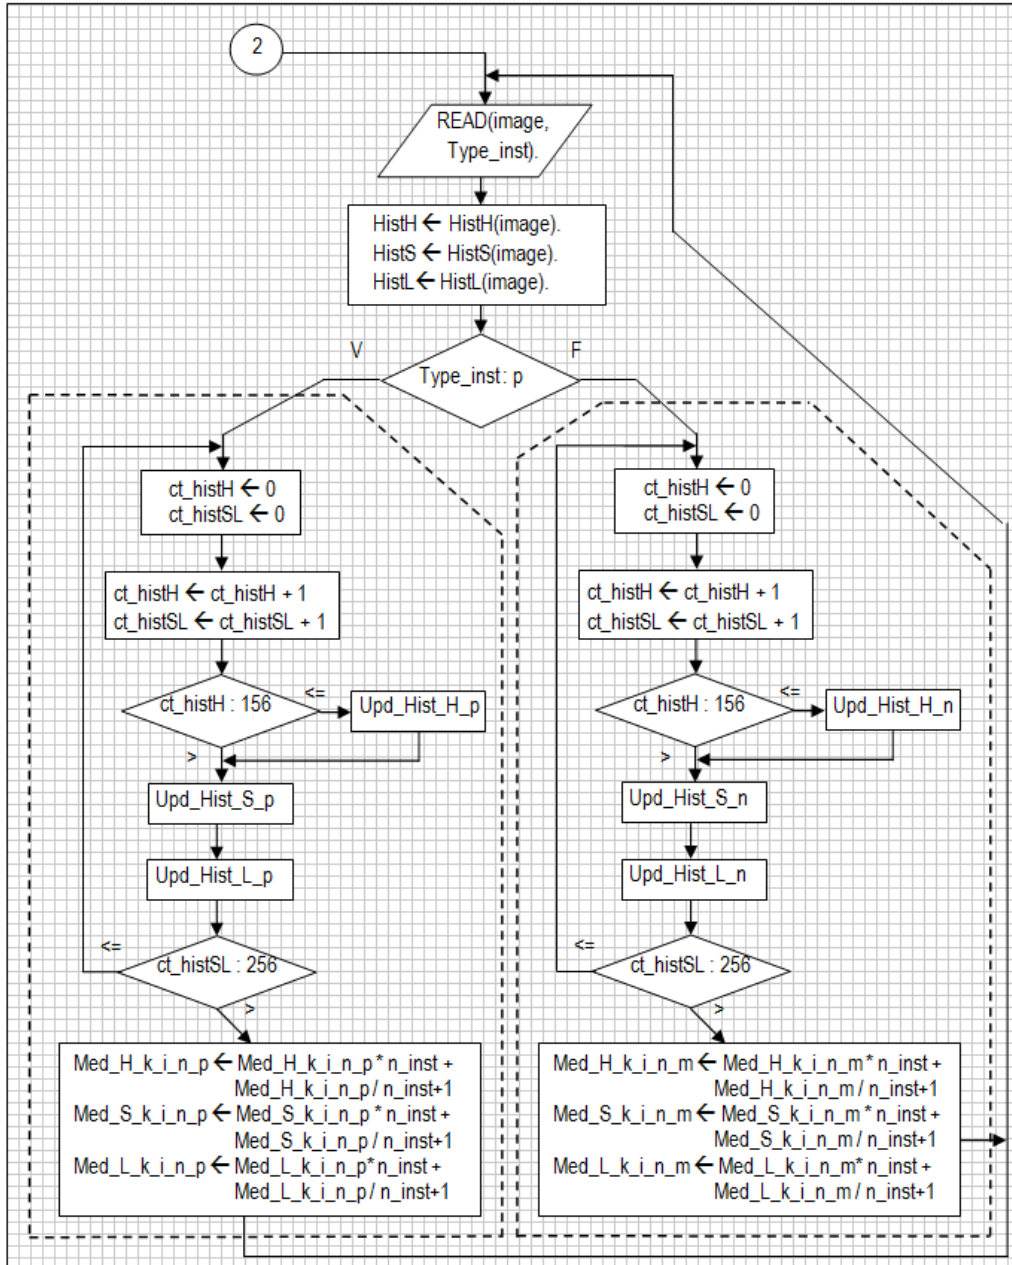
Varredura dos histogramas HSL e atualização dos valores da base de conhecimento para as instâncias positivas e negativas

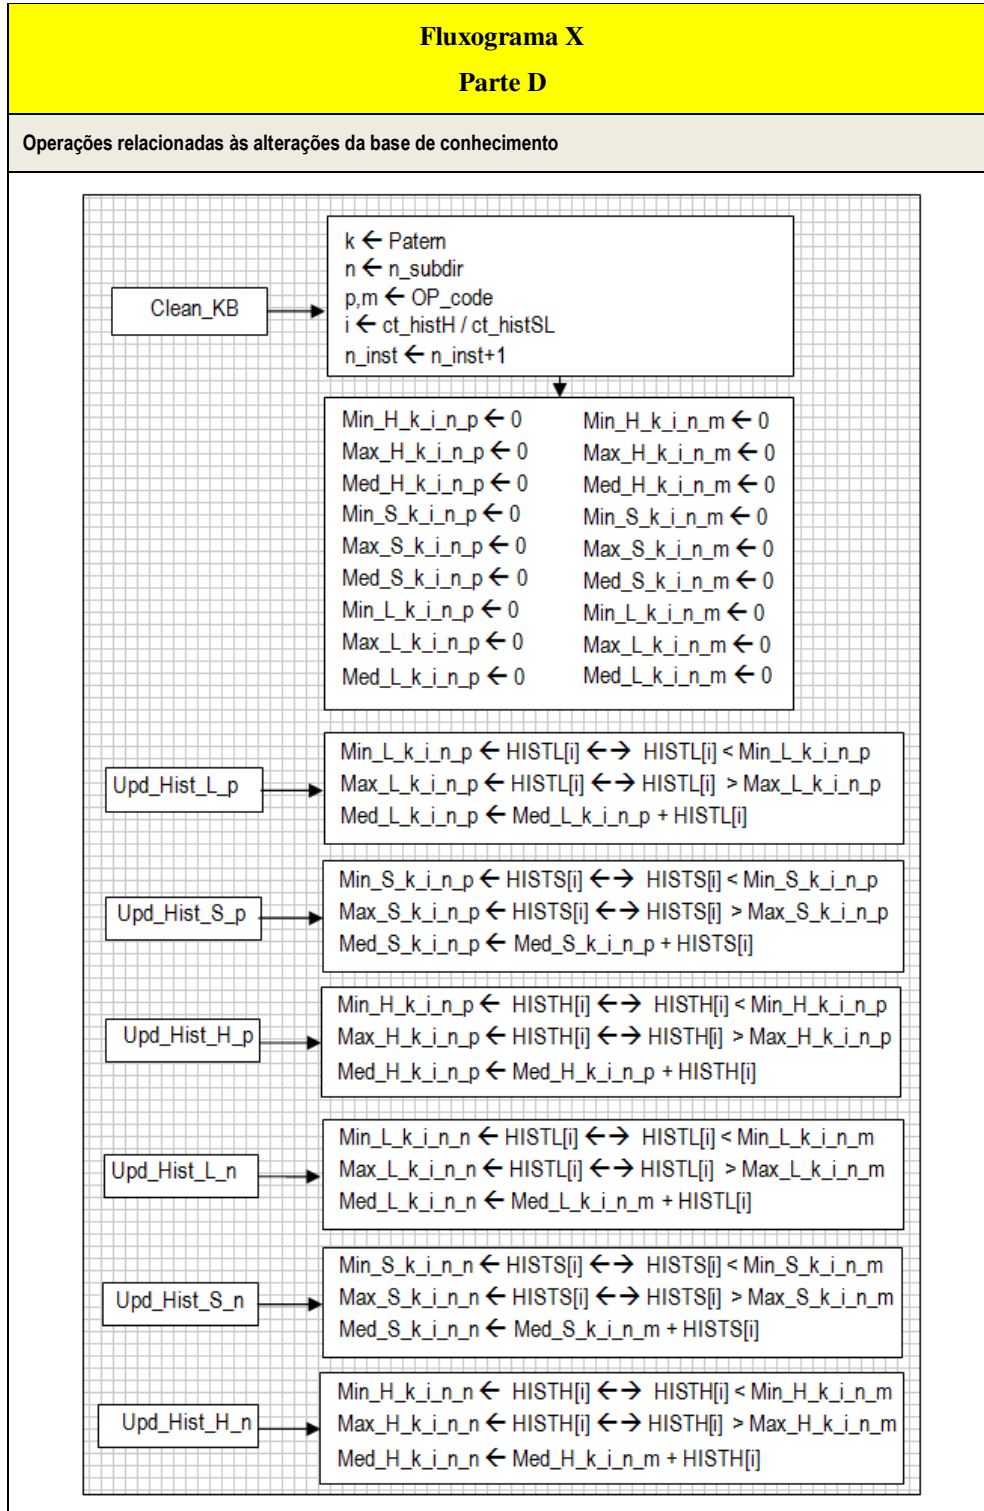


**Fluxograma X**

**Parte C**

Varredura dos histogramas HSL e atualização dos valores da base de conhecimento para uma instância positivas ou negativa





**Fluxograma XI**

Algoritmo para calcular a distância mínima entre a imagem e o padrão.

**Funções**

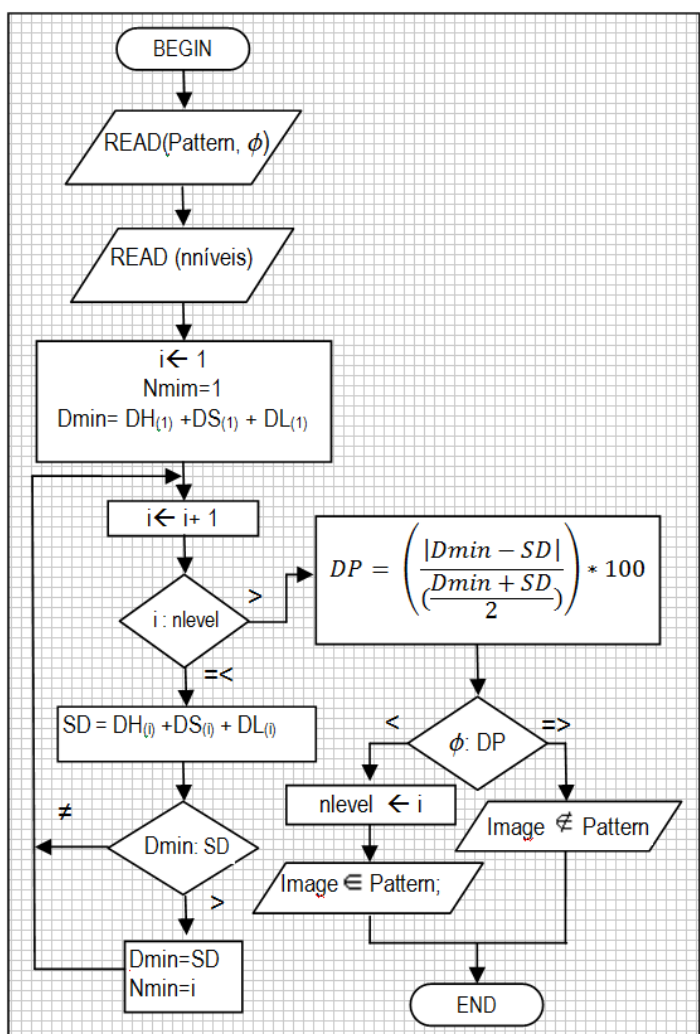
LÊ ()	Leitura dos níveis de um padrão
Grava() :	Salva (estrutura) em disco

**Variáveis**

$\phi$	Limiar de similaridade
Nmin	Nível de menor distância encontrado
Dmin	Distância mínima; somatório dos componentes HSL da imagem a ser analisada.
SD	Soma das distâncias encontradas para o nível.
DP	Diferença Percentual (imagem – nível)

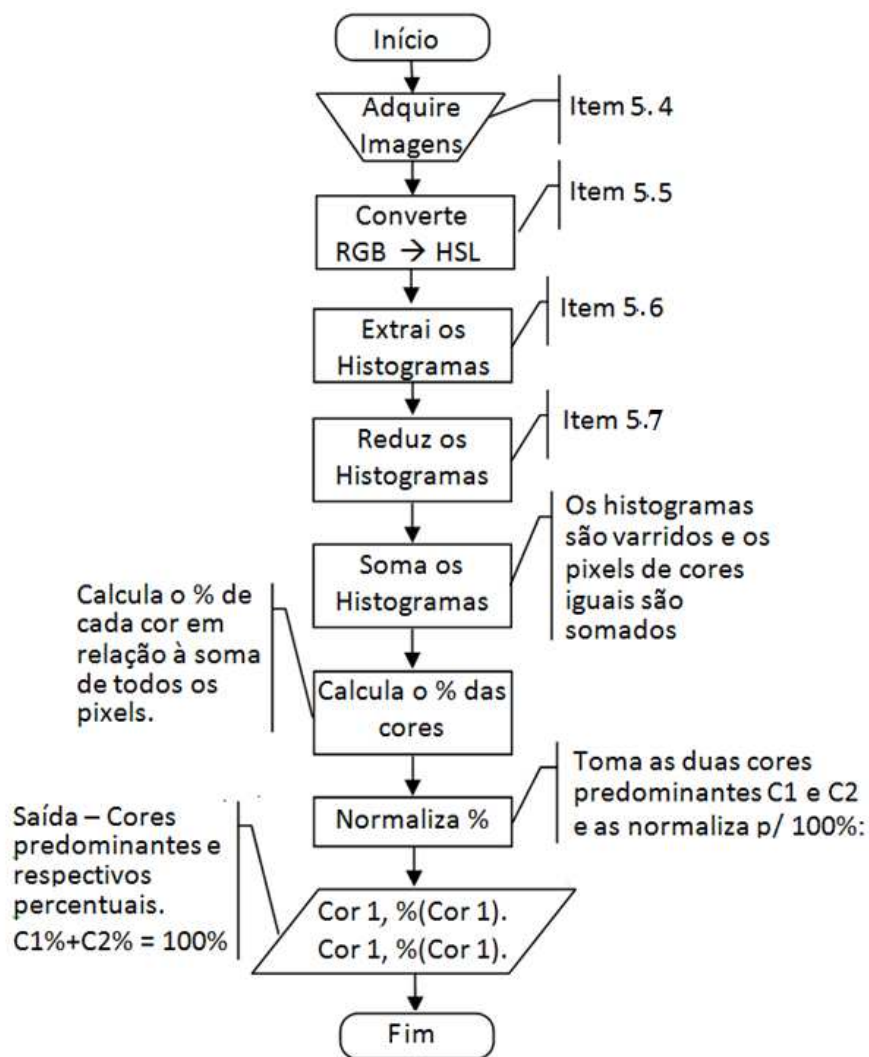
**Funcionamento**

Inicialmente, são lidos os níveis do padrão e  $\phi$ , de cores utilizadas e um nome para o padrão. Um contador é iniciado e um loop controlado por esse contador lê os valores das cores e respectivos percentuais para cada nível que o padrão estabelece. Quando o contador atingir um valor superior ao número de níveis do padrão, o algoritmo para.





**Fluxograma XII – Obtém o % das cores predominantes; permite extrair os níveis de cinza (S,L)**



**Algoritmo para detectar os pontos no contorno da manga - Fluxograma.**

Identificador	Significado
$l, c$	Dimensões $l$ - linha e $c$ -coluna da matriz principal (imagem)
$m(lm,cm)$	Matriz imagem – coordenadas $lm$ (linha); $cm$ (coluna)
$a,b,c,d$	Cores dos vértices da submatriz que forma o ponto interpretável
$rs$	Número de pixels da aresta da submatriz
$cpi$	Comprimento da aresta da submatriz em mm
$rm$	Resolução da Imagem (Matriz principal) em pixels por polegada quadrada (ppp).
$mpi(lmi,cmi)$	Matriz de pontos interpretáveis (linha da matriz interpretável, coluna da matriz interpretável)
$m$	Variável auxiliar para Cor
$i, j$	Variáveis auxiliares
Função	Descrição
$Imagem(m[lm,cm])$	Lê a imagem a partir de um arquivo binário e a armazena no vetor $m$
$Hue(lm, cm)$	Retorna a cor da coordenada $lm,cm$ da matriz (imagem).
$Predcor(a,b,c,d)$	Retorna a cor (HUE) predominante sobre os vértices $a,b,c$ e $d$ .

