

CLAUDIO DENIS

**METODOLOGIA DE SELEÇÃO DE TOMATES PARA  
PROCESSAMENTO INDUSTRIAL POR MEIO DA  
VISÃO COMPUTACIONAL E REDES NEURAI**

São Caetano do Sul  
2009

# **Livros Grátis**

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

CLAUDIO DENIS

**METODOLOGIA DE SELEÇÃO DE TOMATES PARA  
PROCESSAMENTO INDUSTRIAL POR MEIO DA  
VISÃO COMPUTACIONAL E REDES NEURAI**

Dissertação apresentada à Escola de Engenharia  
Mauá do centro Universitário do Instituto Mauá de  
Tecnologia para obtenção do título de Mestre em  
Engenharia de Processos Químicos e Bioquímicos

Linha de Pesquisa: Análise e Otimização de  
Processos Industriais

Orientador: Prof. Dr. Wânderson de Oliveira Assis

São Caetano do Sul  
2009

Denis, Claudio

Metodologia de seleção de tomates para processamento industrial por meio da Visão Computacional e Redes Neurais / Cláudio Denis – São Caetano do Sul, SP: CEUN-EEM, 2009. 103 p.

Dissertação (mestrado) Escola de Engenharia Mauá do Centro Universitário do Instituto Mauá de Tecnologia, São Caetano do Sul, SP, 2009.

Orientador: Prof. Dr. Wânderson de Oliveira Assis

1.Redes Neurais 2.Visão Computacional 3. Processamento de Imagem. Cláudio Denis I. Instituto Mauá de Tecnologia Centro Universitário. Escola de Engenharia Mauá II. Título

*Os melhores momentos são proporcionados por amigos que sempre apoiaram de maneira fundamental para a realização deste trabalho. Dedico a todas as pessoas que colaboraram nesta caminhada.*

## **Agradecimentos**

Ao Professor Dr. Wânderson Oliveira Assis pelo apoio, paciência, incentivo e orientação acompanhando-me em todos os passos deste trabalho.

Ao Professor Dr. Péricles Brasiliense Fusco pela amizade, lições de vida, apoio em todas as horas.

Aos professores da banca por aceitarem a tarefa de avaliar o trabalho e apresentar suas valiosas contribuições.

À Fundação Salvador Arena, Faculdade de Tecnologia Termomecânica pelo apoio para a realização deste trabalho.

À Escola de Engenharia Mauá pelo curso e uso de laboratórios e ajuda do Corpo Técnico-Administrativo.

Ao Professor Sérgio Martins pela grande ajuda na revisão dos trabalhos.

À amiga Luciana pela ajuda constante e incentivos.

A minha esposa Luzia e meus filhos queridos pelo carinho, ajuda constante e compreensão.

À minha mãe que sempre ocupou lugar de destaque em minha vida.

A Deus que criou tudo que existe na Natureza.

## RESUMO

O presente trabalho propõe uma metodologia para a classificação de tomates baseada em visão computacional, com ênfase para o tratamento do padrão de cor, abordando métodos que trabalham com a segmentação de imagens coloridas através do processo de classificação de cores, isto é, a segmentação de imagens baseada no atributo da cor dos pixels. O objetivo é fazer esta classificação tão próxima à humana quanto possível, que seja robusta à variação de grandezas tais como iluminação ou brilho da cor. A classificação de tomates realizadas por humanos é baseada em normas brasileiras do “Centro de Qualidade de Horticultura do CEAGESP-S.P.” (HORTIBRASIL, 2006). Nesta norma o amadurecimento do tomate é caracterizado por três sub-grupos: Pintando, Colorido e Maduro. O tomate maduro pode ter as cores: vermelho, rosado, laranja e amarelo. O tomate vermelho é usado no processamento industrial para diversos produtos tais como: molho, polpa de tomate, *ketchup* dentre outros; por este motivo ele será o ponto central deste trabalho. A abordagem apresenta a classificação de tomates para processamento industrial e os da norma citada, também classifica o tomate com base nas suas dimensões e formato. O sistema utilizado é composto por: uma câmera do tipo *Webcam*, que transmite a imagem para o computador, e um programa desenvolvido especialmente para esta finalidade em linguagem orientada a objetos, a imagem é capturada e colocada em um quadro. O programa aplica uma varredura neste quadro gerando os dados de cores RGB dos pixels e dados do tamanho do tomate. No passo seguinte do mesmo software, os dados de cores são tratados e enviados para um classificador formado por rede neural artificial. A rede neural utilizada é a *MLP-Multilayer Perceptron* que é responsável pela geração dos pesos e polarizações que permitirão efetuar a classificação do tomate. Aplicando este sistema de classificação em um ambiente que apresenta variações de luminosidade é observado que este tem um bom rendimento e atende à proposta deste trabalho por meio de componentes de baixo custo.

**Palavras-chaves:** Redes Neurais, visão Computacional, processamento de imagem, classificação de tomates.

## ABSTRACT

The present work approaches a methodology of sorting tomatoes based on computational vision, working with segmentation of coloured images through the process of color classification, i.e., the segmentation of images based on the color attribute of pixels. The objective is to make a color classification as close as possible of human classification. We look for a robust classification with respect to the variation of illumination and color brightness. The sorting tomatoes carry out by humans is based on the standards made by specialized institutions in the case of Brazil use standard of "Quality Center of Horticulture of CEAGESP-S.P." (HORTIBRASIL, 2006). At this standard the ripening tomatoes is characterized by three subgroups: painting, color and ripe. The ripe fruit could have the colors: red, a rosy, orange and yellow. The red tomatoes are used for industrial processing for make several types of products such as: tomato sauce, tomato pulp, ketchup etc; for this reason it will be the core of this work. The solution also allows classification the tomato based on their format and dimensions. This solution is based on a system composed by a Webcam for simultaneously classify the tomatoes based on shape and color, that transmit the image to the computer and on the program that was specially developed for this in a object oriented language oriented to object. This image is captured in a frame and the program scans the frame generating the RGB color data of pixels. On the next step this data are treated and send to an Artificial Neural Network (ANN) classifier. The ANN used is a Multilayer Perceptron (MLP) that it is responsible for the generation of weights and bias allowing the tomato classification. This system is applied in the environment with light variations and it has a good performance to attend the proposal of this work with low cost components.

**Keywords:** Neural Networks, Computational Vision, Image Processing, Tomato's Classification.



## LISTA DE ILUSTRAÇÕES

FIGURA 2.1 - CARACTERÍSTICAS EXTERNAS DO TOMATE.....	4
FIGURA 2.2 - CARACTERÍSTICAS INTERNAS DO TOMATE.....	5
FIGURA 2.3 - CARACTERÍSTICAS INTERNAS DO TOMATE.....	6
FIGURA 2.4 - FORMATO DE TOMATES.....	6
FIGURA 2.5 - COLORAÇÃO DE TOMATES.....	7
FIGURA 2.6 - AMADURECIMENTO DO TOMATE.....	8
FIGURA 2.7 - OS PRINCIPAIS DEFEITOS GRAVES DO TOMATE.....	9
FIGURA 2.8 - DEFEITOS LEVES DO TOMATE.....	10
FIGURA 2.9 - ESTEIRA PARA SELEÇÃO MANUAL DE TOMATES.....	11
FIGURA 3.1 - O OLHO HUMANO.....	14
FIGURA 3.2 - CONES E BASTONETES E SUAS RESPOSTAS AO ESPECTRO.....	15
FIGURA 3.3 - FUNÇÃO DE LUMINOSIDADE.....	16
FIGURA 3.4 - O PLANO DE MAXWELL E O SPECTRUM LOCUS.....	19
FIGURA 3.5 - DIAGRAMA DE CROMATICIDADE r-g.....	21
FIGURA 3.6 - SISTEMA RGB DO MONITOR.....	22
FIGURA 3.7 - 1931 CIE – DIAGRAMA DE CROMATICIDADE.....	24
FIGURA 3.8 - 1931 CIE – DIAGRAMA DE CROMATICIDADE REPRES. DE CORES...24	24
FIGURA 3.9 - DIAGRAMA DE CROMATICIDADE CIE-XYZ.....	25
FIGURA 3.10 - NÍVEIS DE LUMINOSIDADE DE CIE-L*a*b*.....	26
FIGURA 4.1 - A GEOMETRIA DA REFLECTÂNCIA.....	27
FIGURA 4.2 - DIAGRAMA DO TRIÂNGULO DE CROMATICIDADE PARA O RGB...32	32
FIGURA 4.3 - UMA RETA E SUA REPRESENTAÇÃO NO DOMÍNIO DISCRETO.....	33
FIGURA 4.4 - CONTORNOS EQUIDISTANTES PARA DIFERENTES MÉTRICAS.....	34
FIGURA 4.5 - DETERMINAÇÃO DE LIMIAR PARA HISTOGRAMA.....	35
FIGURA 4.6 - OS LIMIARES APLICADOS A UM ESPAÇO 3D DE CORES.....	36
FIGURA 4.7 - IMAGENS DE UM TOMATE ANTES E APÓS A FILTRAGEM.....	38
FIGURA 5.1 - O NEURÔNIO BIOLÓGICO.....	43
FIGURA 5.2 - BOMBA DE SÓDIO E POTÁSSIO.....	43
FIGURA 5.3 - DISPARO DE UM NEURÔNIO.....	44

FIGURA 5.4 - MODELO NÃO-LINEAR DE UM NEURÔNIO.....	45
FIGURA 5.5 - A REDE NEURAL MULTICAMADA.....	48
FIGURA 6.1 - SISTEMA COM ILUMINAÇÃO DO OBJETO E CÂMERA WEBCAM.....	52
FIGURA 6.2 - TELA DE ENTRADA - SELEÇÃO DE CAMERA...;;.....	53
FIGURA 6.3 - SELEÇÃO DE CAMERA OU ARQUIVO.....	53
FIGURA 6.4 - IMAGEM CAPTURADA PELA CÂMERA.....	54
FIGURA 6.5 - IMAGEM CAPTURADA E CONCLUSÃO DA ANÁLISE.....	54
FIGURA 6.6 - VISUALIZAÇÃO DE IMAGEM FILTRADA.....	55
FIGURA 6.7 - RESULTADOS DA ANÁLISE DA IMAGEM.....	55
FIGURA 6.8 - RESULTADOS DA CLASSIFICAÇÃO DA NEURAL .....	57
FIGURA 6.9 - LAYOUT GERAL DO CLASSIFICADOR DE TOMATES.....	58
FIGURA 6.10 - GRÁFICO DE 50 PIXELS DO EXEMPLAR PINTANDO.....	60
FIGURA 6.11 - GRÁFICO DE 50 PIXELS DO EXEMPLAR COLORIDO.....	61
FIGURA 6.12 - GRÁFICO DE 50 PIXELS DO EXEMPLAR MADURO.....	62
FIGURA 6.13 - REDE NEURAL MLP DESENVOLVIDA.....	64
FIGURA 6.14 - CONSTRUÇÃO DA REDE NO MATLAB®.....	65
FIGURA 6.15 - DESEMPENHO DA REDE APÓS TREINAMENTO.....	66
FIGURA 6.16 - RESULTADOS DO TREINAMENTO – PINTANDO 500 LUX.....	67
FIGURA 6.17 - RESULTADOS DO TREINAMENTO – PINTANDO 1000 LUX.....	67
FIGURA 6.18 - RESULTADOS DO TREINAMENTO – COLORIDO 500 LUX.....	68
FIGURA 6.19 - RESULTADOS DO TREINAMENTO – COLORIDO 1000 LUX.....	68
FIGURA 6.20 - RESULTADOS DO TREINAMENTO – MADURO 500 LUX.....	69
FIGURA 6.21 - RESULTADOS DO TREINAMENTO – MADURO 1000 LUX.....	69
FIGURA 6.22 - RESULTADOS OBTIDOS PELA REDE NEURAL PINTANDO.....	71
FIGURA 6.23 - RESULTADOS OBTIDOS PELA REDE NEURAL COLORIDO.....	71
FIGURA 6.24 - RESULTADOS OBTIDOS PELA REDE NEURAL MADURO.....	72
FIGURA 6.25 - RESULTADOS NO SISTEMA PRÁTICO PINTANDO 700 LUX.....	73
FIGURA 6.26 - RESULTADOS NO SISTEMA PRÁTICO COLORIDO 700 LUX.....	73
FIGURA 6.27 - RESULTADOS NO SISTEMA PRÁTICO MADURO 700 LUX.....	74
FIGURA 6.28 – EXEMPLO DE IMAGENS DE UM TOMATE SANTA CRUZ.....	75
FIGURA A.1 - ENTRADA DO TOMATE PARA O PROCESSO DE SELEÇÃO.....	84
FIGURA A.2 - SAÍDA DA SECAGEM EM DIREÇÃO AO CLASSIFICADOR.....	85
FIGURA A.3 - CLASSIFICADOR COMPUTADORIZADO E AS BAIAS DE SELEÇÃO.....	86

FIGURA A.4 - BAIAS DE SELEÇÃO DE TOMATES.....87

## LISTA DE TABELAS

TABELA 3.1 - LUZES MONOCROMÁTICAS.....	13
TABELA 3.2 - GRANDEZAS RADIOMÉTRICAS.....	16
TABELA 3.3 - GRANDEZAS RADIOMÉTRICAS E FOTOMÉTRICAS.....	17
TABELA 3.4 - COMPRIMENTOS DE ONDAS DAS CORES.....	21
TABELA 3.5 - AS MEDIDAS DE DISTÂNCIA EM UMA IMAGEM DIGITAL.....	33
TABELA 4.1 - FUNÇÕES DE ATIVAÇÃO DE UM NEURÔNIO.....	45
TABELA 6.1 - REPRESENTAÇÃO DA UTILIZAÇÃO DA CONTAGEM $n_c$ .....	57
TABELA 6.2 - PARÂMETROS RGB DOS EXEMPLARES P,C E M.....	59
TABELA A.3.1 – PRINCIPAIS CARACTERÍSTICAS DA REDE 1.....	98

# SUMÁRIO

<b>1 INTRODUÇÃO.....</b>	<b>1</b>
<b>2 TOMATE.....</b>	<b>3</b>
2.1 CARACTERÍSTICAS DO TOMATE.....	4
2.2 CLASSIFICAÇÃO DE TOMATES.....	5
2.3 DEFEITOS NOS TOMATES: DEFEITOS GRAVES E DEFEITOS LEVES.....	8
2.4 PROCESSO DE FABRICAÇÃO DO EXTRATO DE TOMATE.....	11
<b>3 LUZ, CORES E VISÃO.....</b>	<b>12</b>
3.1 DEFINIÇÕES E DEPENDÊNCIAS .....	13
3.2 O SISTEMA VISUAL HUMANO .....	14
3.3 GRANDEZAS FOTOMÉTRICAS .....	15
3.4 REPRESENTAÇÃO DE CORES.....	17
3.4.1 Medidas perceptíveis .....	17
3.4.2 Medidas físicas.....	18
3.5 Padronizações de Cores .....	20
3.6 CIE-RGB.....	21
3.7 Sistema CIE-XYZ.....	23
3.8 Sistema CIE-La*b*.....	25
<b>4. IMAGEM, SELEÇÃO DE CORES E FILTRAGEM.....</b>	<b>27</b>
4.1 Física de formação da imagem.....	27
4.2 Modelagem matemática da imagem.....	28
4.3 Imagem Digital.....	29
4.4 Amostragem e quantização.....	29
4.4.1 Dispositivos de aquisição.....	30
4.4.2 Dispositivos de representação.....	31
4.4.3 Geometria e conectividade.....	33
4.5 Segmentação.....	34

4.5.1 Métodos para segmentação.....	34
4.5.2 A Imposição de limiares.....	35
4.5.3 Algoritmos baseados em vizinhança.....	36
4.5.4 A Classificação de pixels.....	37
4.5.5. Filtro de Sobel.....	38
<b>5 REDES NEURAIS ARTIFICIAIS.....</b>	<b>39</b>
5.1 Histórico.....	40
5.2 O Neurônio.....	42
5.2.1 O Neurônio biológico e sua ativação.....	42
5.2.2 A modelagem matemática.....	44
5.3 Os tipos de RNAs.....	45
5.3.1 A estrutura das redes.....	46
5.3.2 O treinamento das redes.....	46
5.4 O PERCEPTRON MULTICAMADA (MLP).....	47
5.4.1 Introdução.....	47
5.4.2 Arquitetura do MLP.....	47
5.4.3 Treinamento: a retropropagação do erro.....	49
5.4.3.1 O princípio de Hebb.....	49
5.4.3.2 A regra de Widrow.....	50
5.4.3.3 A retropropagação do erro.....	51
<b>6 SISTEMA DE CLASSIFICAÇÃO DE TOMATES.....</b>	<b>52</b>
6.1 Análise das medições em RGB.....	57
6.2 Treinamento e obtenção de resultados na rede.....	63
<b>7 CONCLUSÕES E COMENTÁRIOS FINAIS.....</b>	<b>76</b>
<b>8 REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>78</b>
<b>9 GLOSSÁRIO.....</b>	<b>82</b>
APÊNDICE A1 INSTALAÇÕES DE UMA EMPRESA DE CLASSIFICAÇÃO.....	84

APÊNDICE A2 – Análise das Medições em RGB - Resultados complementares.....	88
APÊNDICE A3 - Tabela de Resultados da Rede Neural – Treinamento e Simulação.....	95

# 1 INTRODUÇÃO

Mesmo depois da automação de muitos setores industriais, a inspeção de tomates é ainda realizada por humanos com melhor qualidade do que por meios artificiais (SEBRAE, 2006). Grande parte das abordagens automáticas para esta tarefa concentra-se na análise de algum tipo de imagem digital do espectro visível ou não visível, tais como os raios X, para avaliar tais frutos (USÓ et al, 2006). A análise de imagens do espectro visível, de particular interesse neste trabalho, pode então ser entendida como a automação do processo de inspeção visual realizado por especialistas humanos utilizando técnicas da visão computacional (USÓ et al, 2006).

As inspeções de tomates realizadas por humanos usualmente tomam como base padronizações realizadas por instituições especializadas. Para o caso específico do tomate no Brasil, uma das escassas referências é o Centro de Qualidade em Horticultura (CEAGESP, 2006), que se tornou padrão brasileiro e propõe a classificação de tomates baseada em padrões de cor e qualidade, o que também é proposto nas normas do departamento de agricultura dos Estados Unidos, conforme a norma 51.3310 (ANON, 1993) revista em Janeiro de 1997 para classificação de tomates para processamento. Contudo, freqüentemente a linguagem utilizada pelas instituições em suas padronizações não é própria para a automação, isto é, não apresenta descrição formal dos padrões. Um sistema autônomo eficiente para a classificação de frutas deve estar apto a realizar sua tarefa com base nestas descrições de alto nível.

Alguns trabalhos têm sido propostos (DESMUKH, 2005), (USÓ et al, 2006) utilizando técnicas de processamento de imagens digitais para a análise da forma e tamanho de frutos e para a detecção de defeitos. Para o problema do reconhecimento de padrões no domínio da agricultura, algumas abordagens utilizam métodos estatísticos, redes neurais artificiais (LOURO, 2006), (SIMÕES & COSTA, 2003) e análise de características. Embora diversos trabalhos tenham sido propostos nesse sentido, particularmente a classificação de frutas baseada no parâmetro cor permanece ainda como um problema aberto.

O presente trabalho propõe uma metodologia para a classificação de tomates para processamento industrial baseada em informações visuais, com ênfase no tratamento do



padrão de cor. Pretende-se obter um sistema utilizando redes neurais que permita a classificação eficiente e robusta à variação da luminosidade típica no ambiente industrial (GARCIA JUNIOR, 2002) que pode variar de 500 lux a 1000 lux. A abordagem permite também a seleção do tomate pelo tamanho e formato usando algoritmo de processamento de imagem baseado no filtro de Sobel (GONZALEZ&WOODS, 2003).

A proposta é trabalhar com um sistema que atenda aos requisitos citados, com custo reduzido e que tenha as seguintes características:

i) obtenção de um sistema de classificação de tomates que permita o reconhecimento durante a passagem e a parada do tomate em frente à câmera que captura a imagem;

ii) a imagem capturada pela câmera é enquadrada no software de análise de imagens, e quando solicitado a imagem é analisada apresentando como resultado a determinação dos valores de cor (RGB/Lab\*);

iii) os valores médios obtidos são utilizados como entradas no software de rede neural (MLP) que oferece na saída a classificação da cor do tomate independente da variação de luminosidade;

iv) o software de análise de imagens também fornece o formato e as dimensões do tomate.

A escolha do tema deste trabalho se deve a indicação de orientações do SEBRAE para a montagem de uma empresa para processamento industrial de tomates (SEBRAE, 2006). Atualmente existem, além do SEBRAE, outras empresas que executam o processo de seleção, como ilustrado no Apêndice A1. Nestas, o tomate passa por uma pré-lavagem, é transportado em uma esteira, e em seguida é classificado manualmente por operários. Esta classificação manual poderia ser automatizada, e esta possibilidade é a principal motivação para este trabalho.

A abordagem do trabalho é descrita da seguinte forma: o capítulo 2 apresenta o tomate, suas principais características e classificação; o capítulo 3 apresenta os fundamentos da luz, cores e da visão humana, a imagem digital, a segmentação e a filtragem das imagens, o capítulo 4 disserta sobre a formação da imagem e o processamento da imagem utilizando conceitos como segmentação, filtragem, etc; o capítulo 5 descreve os fundamentos das redes neurais e suas aplicações; o capítulo 6 apresenta o classificador por meio de redes neurais e sua aplicação neste trabalho; e finalmente o capítulo 7 apresenta as considerações finais, conclusões e sugestões para continuidade do trabalho.

## 2 TOMATE

O tomateiro, originário das regiões costeiras voltadas ao Pacífico da América do Sul, é uma das principais hortaliças de importância econômica e alimentar do Brasil. Esta cultura está concentrada no Sudeste brasileiro em se tratando de tomate cultivado sob o sistema estaqueado (FERNANDES, CARDOSO & MARTINELLI, 2003). No Estado de São Paulo existem também culturas extensivas de tomate rasteiro para indústria e mercado. No Nordeste, os plantios para indústria são expressivos, tendendo a crescer nas margens do Rio São Francisco. Também está sendo difundida com sucesso no cerrado, no estado de Goiás (CASTELLANE, 1988). O tomate é o fruto pertencente à espécie *Lycopersicum Esculentum Mill* e a origem do seu nome é proveniente da língua náuatle (língua nativa da parte central do México) que o define como *tomatl* (FERNANDES, CARDOSO & MARTINELLI, 2003).

A cadeia de produção envolvendo a cultura do tomateiro representa para o Brasil um setor de grande interesse socioeconômico. De acordo com a FAO- *Food and Agriculture Organization* em 2005 o Brasil produziu 3,3 milhões de toneladas numa área de 562 mil hectares. O cultivo do tomate destinado ao consumo “in natura”, ou seja, para comercialização em feiras livres, supermercados, varejões etc., é realizado por meio de culturas “estaqueadas” ou “tutoradas”. Já o tomate que é destinado a indústria para utilização de polpa apresenta crescimento determinado e rasteiro (FERNANDES, CARDOSO & MARTINELLI, 2003).

O tomate é um alimento altamente nutritivo e sadio, sendo fonte de diversas vitaminas e sais minerais, e apresentando excelente palatabilidade. Seu baixo valor energético torna-o recomendável para aqueles que estão em dieta ou que precisam de um alimento de fácil digestão. O fruto do tomate é a parte comestível e ele pode ser consumido cru ou cozido. A partir da polpa são feitos o extrato, o purê, o *catchup*, os molhos para as massas, sucos e até doces (FERNANDES, CARDOSO & MARTINELLI, 2003).

## 2.1 CARACTERÍSTICAS DO TOMATE

O tomate apresenta em sua morfologia as seguintes características externas, conforme figura 2.1:

- componentes externos: Pedúnculo, Sépala, Ápice e Região estilar;
- seção longitudinal que se refere ao comprimento; e
- seção transversal que se refere ao diâmetro equatorial.

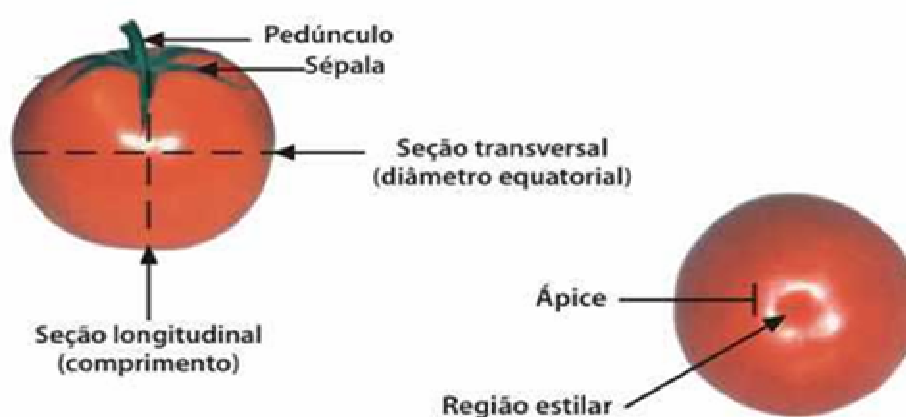


Figura 2.1 – Características externas do tomate (CEAGESP,2006)

O tomate apresenta as seguintes características internas que são mostradas nas figuras 2.2 e 2.3:

### Seção longitudinal de um tomate de 2 lóculos (biloculado).





Figura 2.2 – Características internas do tomate (CEAGESP,2006)

Seção longitudinal de tomate biloculado.

Seção transversal de um tomate de 3 lóculos (multiloculado)



O pericarpo compreende a casca (epicarpo), as paredes internas (mesocarpo e endocarpo) e o septo.  
O córtex é a parte do mesocarpo mais próxima ao epicarpo.  
A polpa é o pericarpo sem o epicarpo.

Figura 2.3 – Características internas do tomate (CEAGESP,2006)

Seção longitudinal de tomate multiloculado.

## 2.2 CLASSIFICAÇÃO DE TOMATES

*Classificar* quer dizer separar o produto por variedade, tamanho, cor e qualidade de maneira que o fruto tenha aparência uniforme. Utilizar a classificação do tomate é unificar a linguagem do mercado, isto é, usar os mesmos padrões para determinar a qualidade do produto.

O tomate é classificado por: Grupos (formatos: I, II, III, IV e V); Cores (Vermelho, Rosado, Laranja e Amarelo; subgrupos: I – Pintando; II – Colorido; III – Maduro ); Classes (0, 40, 50, 60, 70, 80, 90 e 100). A classificação do tomate deve ser feita de forma que se consiga a homogeneidade de formato, cor e classe e a caracterização da qualidade.

O tamanho do tomate é determinado pelo diâmetro equatorial do fruto. Assim, o tomate será classificado em oito classes: 0 para diâmetro menor que 40 mm; 40 para diâmetro maior ou igual a 40 mm até 50 mm; 50 para diâmetro maior ou igual a 50 mm até 60 mm; 60 para diâmetro maior ou igual a 60 mm até 70 mm; 70 para diâmetro maior ou igual a 70 mm até 80 mm; 80 para diâmetro maior ou igual a 80 mm até 90 mm; 90 para diâmetro maior ou igual a 90 mm até 100 mm; 100 para diâmetro maior que 100 mm (CEAGESP, 2006).

A classificação por grupo é utilizada para caracterizar os grupos de cultivares conforme figura 2.4. No tomate são utilizados o formato do fruto, a coloração do fruto maduro e a durabilidade do fruto, que é uma informação opcional. Os grupos de formato I, II, III e IV são determinados pela relação entre o comprimento e o diâmetro equatorial do fruto. O grupo V, pelo diâmetro equatorial.

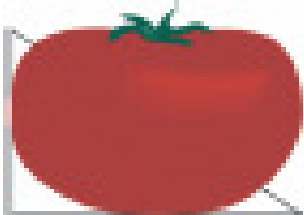
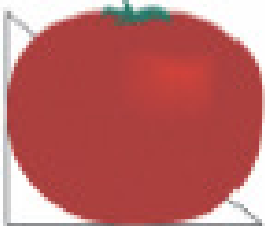
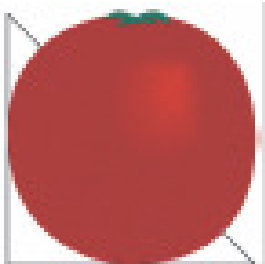
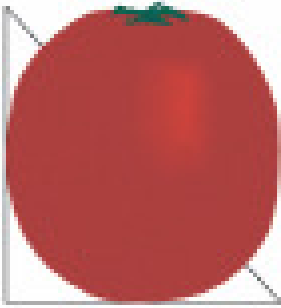

Caqui	Saladete
	
I – Menor que 0,90	II – Entre 0,90 e 1,00
Santa Cruz	Italiano
	
III – Entre 1,00 e 1,15	IV – Maior que 1,15
Cereja	Cálculo do Formato (F)
 <p data-bbox="225 1861 778 1895">V – Diâmetro equatorial menor que 39mm</p>	<p data-bbox="804 1491 1358 1563">Formato do fruto = Comprimento dividido pelo diâmetro equatorial</p>

Figura.2.4 – Formato de tomates (CEAGESP,2006)

A cor do tomate varia em função do seu estágio de maturação, sendo ele classificado por este quesito em Vermelho, Rosado, Laranja e Amarelo como mostrado na figura 2.5.



Figura 2.5 – Coloração do tomate maduro (CEAGESP,2006)

O padrão brasileiro de classificação de tomates segundo o Centro de Qualidade em Horticultura (CEAGESP, 2006), adotado neste trabalho, propõe a classificação das frutas segundo dois aspectos distintos: cor e qualidade. O parâmetro qualidade é observado segundo a ocorrência de defeitos de ordem mecânica, patológica, presença e intensidade de manchas e podridão. Já pelo parâmetro cor varia em função do seu estágio de maturação, sendo ele classificado por este quesito em Vermelho, Rosado, Laranja e Amarelo mostrado na figura 2.5. O amadurecimento do tomate determina a mudança de coloração da sua casca e caracteriza três subgrupos: I – Pintando; II – Colorido; III – Maduro, conforme mostra a figura 2.6.

Existem dois tipos de tomates vermelhos um usado para saladas e culinária e outro para processamento industrial (CICA-KNORR, 2006). Neste trabalho propõe-se uma metodologia para a classificação de tomates para processamento industrial com ênfase para o tratamento do padrão de cor conforme a norma apresentada e a informação industrial (SEBRAE, 2006) utilizar-se-á cor Maduro Vermelho.



Figura 2.6 – Amadurecimento do tomate (CEAGESP, 2006)

### 2.3 DEFEITOS NOS TOMATES: DEFEITOS GRAVES E DEFEITOS LEVES

Os defeitos graves podem ser, conforme mostrado na figura 2.7:

- podridão - dano patológico e/ou fisiológico que implique em qualquer grau de decomposição, desintegração ou fermentação dos tecidos;
- passado - fruto que apresenta um avançado estágio de maturação e senescência, caracterizados principalmente pela perda de firmeza;
- queimado - fruto que apresenta zona de cor marrom, provocada pela ação do sol atingindo a polpa;
- dano por geada - fruto que apresenta perda de consistência e zonas necrosadas provocadas pela ação da geada. podridão apical - dano fisiológico caracterizado por necrose seca na região apical do fruto, associada diretamente à deficiência de Cálcio no solo da plantação;
- dano profundo - lesão de origem mecânica, fisiológica ou causada por pragas com profundidade maior que 1,5mm (CASTELLANE, 1988).




Figura 2.7: Os principais defeitos graves do tomate (CEAGESP, 2006)

Os defeitos leves são aqueles que depreciam a aparência do produto e podem ser: conforme mostrado na figura 2.8:

- a) dano superficial - lesão de origem mecânica, fisiológica ou causada por pragas com profundidade menor que 1,5mm;
- b) mancha - alteração na coloração normal do fruto, qualquer que seja sua origem. Considera-se defeito quando a parte afetada superar 10% (dez por cento) da superfície do fruto;
- c) ocado - fruto que apresenta vazios, em função do mal desenvolvimento do conteúdo locular;
- d) deformado - alteração da forma característica da variedade ou cultivar;
- e) imaturo - fruto que não alcançou o estágio de maturação ideal ou comercial, ou seja, quando ainda não é visível o início de amarelecimento na região apical do fruto.



Os danos causados por pragas-chave da cultura do tomateiro podem ser divididos em insetos transmissores de doenças e traças e brocas dos frutos. Os efeitos destas pragas podem ser reduzidos pela aplicação de manejo integrado de pragas conforme (FERNANDES, CARDOSO & MARTINELLI, 2003).

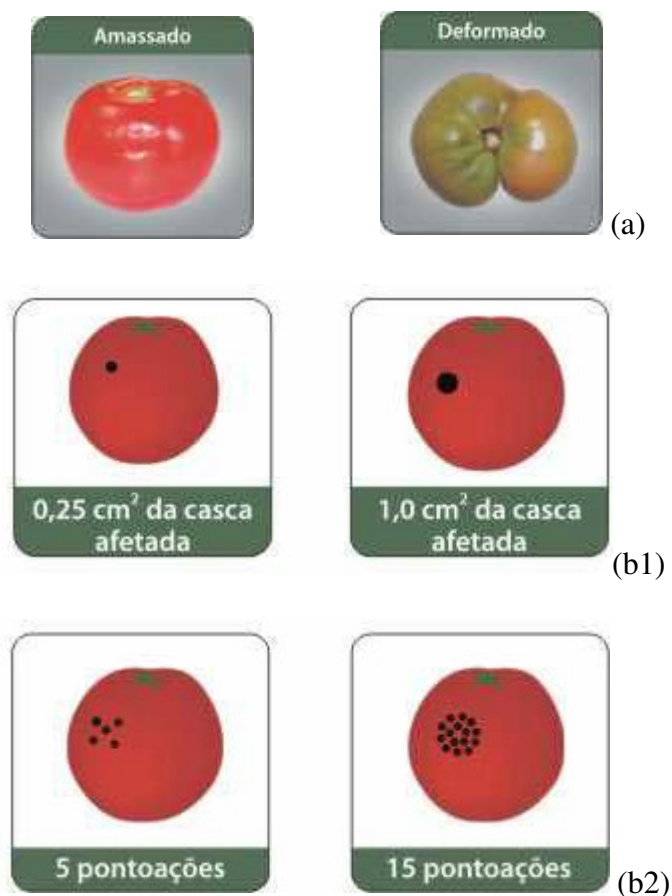


Figura 2.8- Defeitos leves do tomate (CEAGESP,2006)

O defeito leve formado por mancha pode ser distinguido por dois tipos conforme figura 2.8:

b1) mancha profunda: no nível 1 a área total está entre 0,25cm<sup>2</sup> e 1,0cm<sup>2</sup> e no nível 2 a área total é menor que 1,0cm<sup>2</sup>; e b2) mancha difusa; nível 1, entre 5 e 15 pontos e nível 2, mais que 15 pontos.

As pesquisas relacionadas aos aspectos principais de plantação, formação e aplicações são bastante relevantes. Os aspectos relacionados ao processo de seleção dos frutos são também importantes e precisam ser aperfeiçoados, visando substituir a seleção manual que é lenta e até certo ponto ineficiente (SILVA&GIORDANO, 2000).

## 2.4 PROCESSO DE FABRICAÇÃO DO EXTRATO DE TOMATE

As técnicas de transformação do tomate no processo de industrialização utilizam-se de poucas etapas de fabricação. O tomate é uma fruta que tem um período de vida curto e após a sua colheita torna-se necessária a sua rápida utilização, transformando-o em produtos tais como: Extratos, Sucos, Purê, Molhos, etc (SILVA&GIORDANO, 2000).

Os tomates destinados a produção de extrato de tomate, devem se apresentar com boa cor e firmes, em ponto de maturação adequado, isto é, nem verdes e nem excessivamente maduros, livres de materiais estranhos o que deverá assegurar um produto final de boa qualidade (SEBRAE, 2006). Os tomates ao entrarem nas linhas de processamento, sofrem inicialmente uma lavagem com água potável e clorada. Após a operação de lavagem, os tomates serão escolhidos por uma seleção manual feita por meio de uma esteira provida de roletes rotativos que faz com que os tomates girem e facilitem assim o processo de seleção; neste processo são retirados os tomates inadequados tais como: verdes, desintegrados, descoloridos, etc. A figura 2.9 mostra o processo de seleção por meio de esteiras. Após a fase de seleção, os tomates irão passar por outras fases que são: trituração, despulpamento e refinação, concentração e por último a pasteurização (SEBRAE, 2006).



Figura 2.9 - Esteira para seleção manual de tomates (SEBRAE, 2006).

### 3 LUZ, CORES E VISÃO

As ondas eletromagnéticas se propagam no vácuo com a velocidade da luz dada por  $c = 3 \times 10^8$  m/s. Sabendo-se a frequência de uma onda eletromagnética ( $f$ ), no vácuo, pode-se determinar o comprimento de onda ( $\lambda$ ) desta radiação por meio da equação:

$$\lambda = \frac{c}{f} \text{ [nm]} \quad (3.1)$$

Luz é uma radiação visível que pode ser definida como sendo uma radiação eletromagnética, capaz de produzir uma sensação visual e que está compreendida em uma faixa de comprimentos de onda ( $\lambda$ ) limitados entre 380 e 780 nanômetros (GARCIA JUNIOR, 1996). O espectro de luz visível nesta faixa de comprimentos de ondas pode assumir diversas cores, desde o violeta até o vermelho.

A visão está envolvida na percepção da cor. Uma pessoa pode conseguir enxergar na luz fraca, entretanto pode ter dificuldade de distinguir as cores. Somente quando mais luz estiver presente a cor poderá ser distinguida. A variação da intensidade de luz é necessária para a percepção da cor, deve ser considerada também a maneira pela qual o cérebro responde ao estímulo visual. A cor verde tem um significado diferente para um residente de uma floresta tropical e para um habitante do deserto. Da mesma forma, um objeto pode parecer vermelho para um observador e laranja para outro. Claramente, a percepção da cor envolve a percepção física, fisiologia e psicologia.

Um objeto aparece colorido porque o meio está interagindo com a luz. A análise desta interação e os fatores que a determinam estão ligados à preocupação da física da cor.

A fisiologia da cor envolve as respostas dos olhos e do cérebro à luz e os dados sensórios que ela produz. A psicologia da cor é invocada quando a mente processa os dados do campo visual, comparando-os com a informação armazenada na memória, e as interpreta como cor.

### 3.1 DEFINIÇÕES E DEPENDÊNCIAS

O modelo da quantização admite que a energia da onda de luz está presente em pacotes de energia, os fótons. Conforme a teoria de Einstein (SERWAY, 1996), a energia de um fóton é proporcional à frequência da onda eletromagnética:  $E=h.f$ , onde  $h=6,63 \times 10^{-34} \text{J.s}$  é a constante de Planck. Este fóton tem características ondulatórias, pois a sua energia é determinada pela frequência (SERWAY, 1996). Uma vez que todas as ondas eletromagnéticas se propagam no vácuo com a velocidade  $c$ , a frequência  $f$  e o comprimento de onda  $\lambda$  estão relacionados pela expressão (3.1)

O olho humano é um mecanismo neurobiológico de recepção da luz. Ele excita-se com radiações eletromagnéticas entre 380nm a 780nm, do espectro de *luz visível*. A luz, por sua vez, possui uma composição que depende de propriedades da radiância (ou irradiância) de um corpo.

A radiação composta por um único comprimento de onda (ou de uma faixa bem estreita) é classificada como *luz monocromática* (ou espectral). As luzes monocromáticas captadas pelo olho humano são mostradas na tabela 3.1. As demais cores podem ser produzidas pela somatória de ondas com diferentes comprimentos, não se tratando, portanto, de luzes monocromáticas - exceção ao preto (ausência de cor).

<b>Comprimento de onda (<math>\lambda</math>)</b>	<b>Cor</b>
780 a 605 nm	Vermelha
605 a 590 nm	Laranja
590 a 560 nm	Amarela
560 a 500 nm	Verde
500 a 470 nm	Ciano
470 a 430 nm	Azul
430 a 380 nm	Violeta

As células sensíveis do olho podem detectar quase todas as graduações de cores quando luzes monocromáticas, apenas das cores vermelha, verde e azul, são misturadas apropriadamente em diferentes combinações (GUYTON & HALL, 1997). A passagem da informação visual pelo sistema nervoso central (SNC) faz com que uma função de ordem cognitiva passe a atuar sobre a amostragem da onda eletromagnética realizada pelo sistema visual. "É a presença ou ausência da luz que nos dá a sensação de cor. A luz é um fenômeno

físico, mas a cor depende da interação da luz com o sistema visual, sendo, portanto, um fenômeno psicofísico" (GOMES & VELHO, 1998).

As ondas eletromagnéticas monocromáticas visíveis e as ondas produzidas pelas somatórias destas produzem o espectro de cores. A percepção dos limites destas cores não é estabelecida com exatidão, pois, envolvem-se noções psicológicas e exemplos prévios de cada indivíduo na rotulação de cor das diferentes ondas visíveis, o que pode ser considerado como *classificação* das cores. Assim, podemos entender que, uma vez observada pelos mecanismos sensórios visuais, a forma de onda é classificada pelo cérebro segundo algum critério de ordem *psicológica*, ou subjetiva.

Para a proposição de modelagens matemáticas para tal classificação, então, faz-se necessário um maior domínio dos conceitos físicos de uma cor e sua amostragem pelo sistema visual humano.

### 3.2 O SISTEMA VISUAL HUMANO

O sistema visual humano é um mecanismo neurobiológico natural de interface com o ambiente. Ele é óticamente equivalente a uma câmera fotográfica dotada de capacidade de focalização e com abertura controlável. Tal estrutura tem por finalidade levar as imagens externas às regiões da retina fazendo uso de uma seqüência de movimentos biológicos.

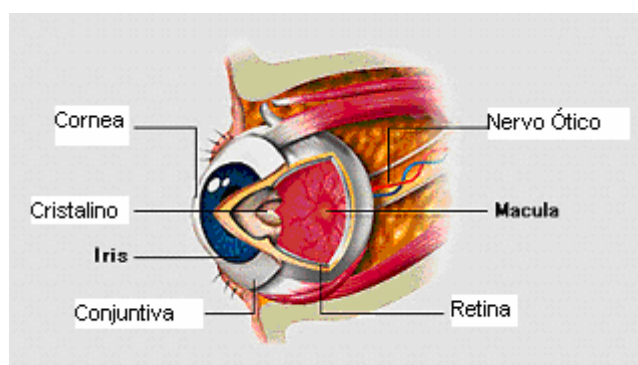


Figura: 3.1 Olho Humano (GUYTON & HALL, 1997)

A luz que entra no olho (figura 3.1) é focalizada pelo sistema córnea-cristalino no fundo da superfície do globo ocular, a retina. A superfície da retina é constituída por milhões de estruturas sensíveis, os *bastonetes* e os *cones* (figura 3.2). Quando estas estruturas são estimuladas pela luz, estes receptores enviam para o cérebro impulsos, através do nervo ótico,

e percebe-se então uma imagem (SERWAY, 1996). Os cones são as estruturas responsáveis pela visão colorida, e os bastonetes são responsáveis pela acuidade visual, isto é, pela resolução espacial da imagem. Nos cones podem ser encontrados fotopigmentos que respondem aos espectros de luz definidos em três comprimentos de onda distintos: 445, 535 e 570 nanômetro, que correspondem respectivamente às cores azul, verde e regiões do vermelho. Embora os cones sejam encontrados em toda a retina, esta possui uma região espacialmente alinhada com o globo ocular que é rica em cones os quais respondem a grandes níveis de iluminação (GUYTON & HALL, 1997).

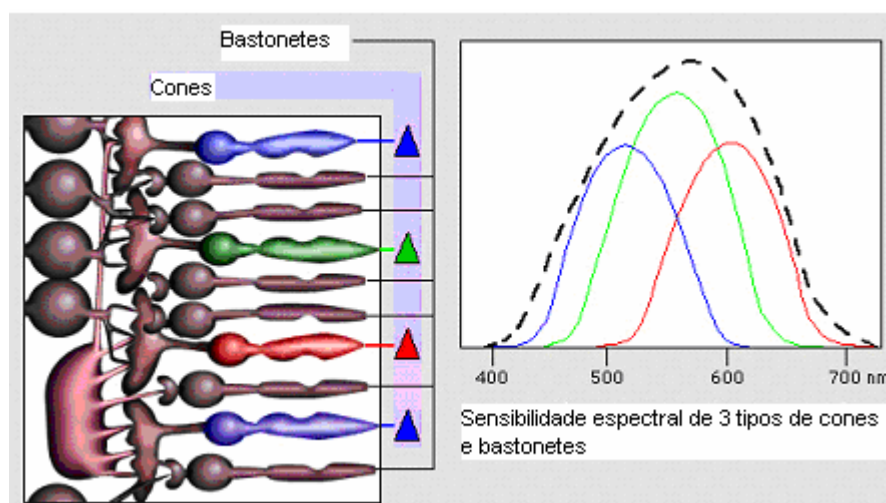


Figura 3.2: Cones e bastonetes e suas respostas ao espectro (GUYTON & HALL, 1997)

As cores e sua interpretação envolvem duas propriedades do mecanismo ocular: a) a adaptatividade ao brilho e discriminação, e b) a adaptatividade à cor. Na adaptatividade ao brilho descrita por GONZALEZ & WOODS, 2003, as superfícies com brilho médio do campo visual total apresentam-se como brilhantes, e aquelas abaixo da média apresentam-se escuras. Na adaptatividade à cor o processo é similar.

### 3.3 GRANDEZAS FOTOMÉTRICAS

Uma radiação eletromagnética genérica pode ser quantificada fazendo-se uso de um conjunto de grandezas, denominadas *radiométricas*. No domínio dos trabalhos com cores, uma onda é referenciada em termos de sua potência (ou fluxo de energia), que é uma medida da intensidade da onda em questão. Na tabela 3.2, seguem-se algumas medidas usuais.

Embora tais grandezas possam ser utilizadas genericamente com qualquer radiação, estas não são particularmente adotadas onde existe interação humana. Isso decorre do fato do

olho humano não possui igual sensibilidade a todos os diferentes comprimentos de onda das radiações. A curva apresentada na figura 3.3 é denominada *função de luminosidade para o observador padrão*. Esta curva estabelece a luminosidade relativa ( $V_\lambda$ ), que é a sensação de brilho para os diferentes comprimentos de onda vistos por um indivíduo considerado normal.

Tabela 3.2 - As grandezas radiométricas, suas unidades usuais e definições.		
Grandeza	Unidade	Descrição
<b>Unidades Básicas:</b>		
Energia	J	Quantidade de radiação da onda.
Potência	W	Fluxo de energia por unidade de tempo (J/s)
<b>Superfícies Emissivas:</b>		
Emitância (ou excitância)	W/m <sup>2</sup>	Fluxo de energia emitida por unidade tempo e por unidade de área.
Energia Radiante	W/rad	Fluxo de energia emitida por unidade tempo em uma dada direção.
Radiância	W/m <sup>2</sup> srad	Fluxo de energia emitida por tempo por área em uma dada direção.
<b>Superfícies reflexivas:</b>		
Irradiância	W/m <sup>2</sup>	Fluxo de energia refletida de um ponto da superfície por unidade de área.

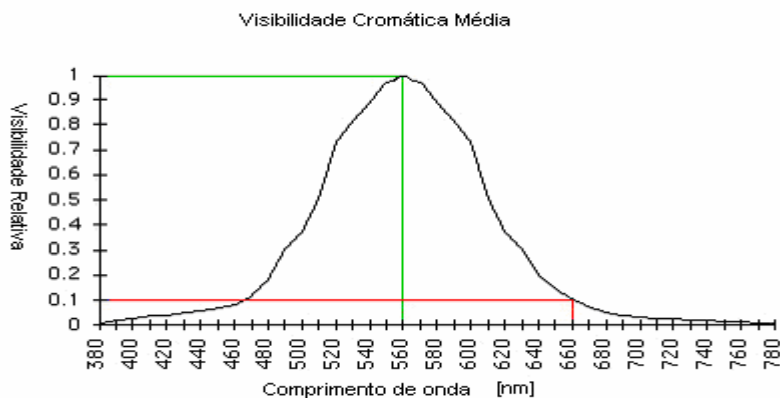


Figura 3.3 - Função de luminosidade ( $V_\lambda$ ) de um observador padrão aos diferentes comprimentos de luz visível (BALLARD & BROWN, 1982).

Uma vez observada tal curva, pode-se perceber que o comprimento de onda que corresponde aproximadamente à cor verde-amarelada (555 nm) é fortemente captado pelo olho humano, enquanto cores como o vermelho e o azul sofrem atenuações. Assim, torna-se claro que as unidades *radiométricas* anteriormente adotadas não terão validade no trato de sistemas de radiação visível observados pelo olho humano. Nesse sentido, estabeleceram-se novas unidades de quantificação, denominadas *fotométricas*.

Tais grandezas fazem uso das medidas anteriormente apresentadas, com uma adequação à curva do observador padrão. Assim, tomando-se por exemplo uma cena que recebe uma certa iluminação do ambiente, é possível demonstrar (GOMES & VELHO, 1998)

que, para a interpretação humana da irradiância de um ponto, denominada iluminância, para uma radiação distribuída continuamente pelo espectro de frequência:

$$L = 683 \cdot \int_{A_1}^{A_2} V_A I_A dA \tag{3.2}$$

- onde: L é a iluminância;  
 I<sub>A</sub> é a irradiância da superfície;  
 V<sub>A</sub> é a função da sensibilidade do observador padrão;  
 A<sub>1</sub> é o menor comprimento de onda do espectro incidente;  
 A<sub>2</sub> é o maior comprimento de onda do espectro incidente;  
 683 constante;

Utilizando-se a mesma metodologia para os demais conceitos apresentados na tabela 3.2, é possível estabelecer uma correlação entre grandezas fotométricas e grandezas radiométricas, que é mostrada na tabela 3.3.

Características Radiométricas		Características Fotométricas	
Grandeza	Unidade	Grandeza	Unidade
Fluxo de Energia	Watt	Fluxo luminoso	Lm (Lúmen)
Emitância radiante	W/m <sup>2</sup>	Emitância luminosa	Lm/m <sup>2</sup> (Lux)
Irradiância	W/m <sup>2</sup>	Iluminância	Lm/m <sup>2</sup> (Lux)
Intensidade radiante	W/srad	Intensidade luminosa	Lm/srad (Candela)
Radiância	W/m <sup>2</sup> srad	Luminância	Lm/m <sup>2</sup> srad

### 3.4 REPRESENTAÇÃO DE CORES

A representação de cores tornou-se necessária para o ser humano manipular as cores. A cor é uma atribuição subjetiva, pois depende da visão, luz e interpretação individual. O entendimento da cor envolve fisiologia, física e psicologia, o que torna difícil a tarefa de definir grandezas que a represente. Dessa forma, as cores têm sido descritas na literatura (GOMES & VELHO, 1998) de duas formas distintas: **a)** com *medidas perceptíveis*, que descrevem as cores de forma geral; e **b)** com *medidas físicas*, que são medidas científicas que buscam embasar sua representação com a ciência chamada de colorimetria.

#### 3.4.1 Medidas perceptíveis

As medidas perceptíveis procuram descrever atributos genéricos relativos à forma da onda em questão. Há três tipos de descritores perceptuais da sensação de luz. São eles:



luminância, saturação e tonalidade ou HSI (*hue, saturation, intensity*) (GONZALEZ & WOODS, 2003).

A luminância é uma medida do nível da quantidade de energia emitida por uma fonte de luz que é percebida por um observador. Na prática, esta grandeza está ligada ao conceito genericamente conhecido como "brilho" da cor (GONZALEZ & WOODS, 2003).

A saturação refere-se ao grau de pureza de uma cor, ou seja, alguma graduação que represente uma cor qualquer como uma grandeza entre uma onda monocromática (espectro de frequência com um único fasor na frequência da onda) e a luz branca (que contém todas as cores). Assim, as cores monocromáticas têm saturação máxima, e a luz branca, mínima (zero).

A tonalidade da cor é um atributo que distingue a luz vermelha da luz verde ou amarela por meio de comparação (subjetiva) entre a cor em observação e exemplos previamente conhecidos. De maneira genérica, trata-se da identificação da cor (ou comprimento de onda) dominante, isto é, a determinação de uma luz monocromática que corresponda (aproximadamente) à cor observada (GOMES & VELHO, 1998).

As grandezas tonalidade e saturação juntas correspondem à grandeza conhecida como *crominância*. A crominância pode ser definida como a parte da cor que é invariante ao brilho. É importante se destacar que a grandeza conhecida como "brilho" é de caráter cognitivo e, portanto, não possui definição uniforme na literatura. Admite-se que "*o brilho é um descritor subjetivo e é praticamente impossível de ser medido*". Assume-se que o brilho é uma grandeza que está ligada a luminância de objetos emissivos. Contudo, há uma concordância em se tratar de uma grandeza subjetiva, que está ligada de alguma forma ao conceito de luminância da imagem. Adota-se este conceito como designado à palavra "brilho", utilizando-a tanto para objetos emissivos quanto para reflexivos (GOMES & VELHO, 1998).

### **3.4.2 Medidas físicas**

Todas as cores visíveis podem ser obtidas pela soma de ondas monocromáticas do espectro. Assim, uma notação intuitiva para representação de cores está ligada à somatória dessas ondas elementares (espectrais) para a produção das ondas desejadas (RESNICK & HALLIDAY, 1996).

No entanto, essa notação incorre em somatórias de quantidades variáveis de comprimentos de onda. Seria desejável, então, alguma notação onde o número de componentes fosse fixo. Poder-se-ia pensar na representação de ondas como funções de

algumas ondas monocromáticas adotadas *a priori*; no entanto, tal reconstrução não é fisicamente possível, já que sabidamente a superposição de ondas com frequências diferentes sempre produz uma onda complexa (não-senoidal) (RESNICK & HALLIDAY, 1991). Em outras palavras, a somatória de duas ondas puras sempre produz uma onda (no caso, uma cor) menos saturada que uma onda monocromática, não sendo, portanto, possível reproduzir desta forma a maioria das ondas monocromáticas e as cores que são combinações destas.

Contudo, a reconstrução física da onda não é a única forma de se transmitir a sensação de cor. Sucessivos estudos de Isaac Newton (1666), H. Grassman (1853) e Maxwell (1860) provaram que, para conseguir a *equivalência de uma cor*, é condição necessária e suficiente proceder à soma de três ondas de comprimentos distintos, tais que duas delas não produzam a terceira. Desta forma, a equivalência de uma cor fica associada à reprodução dos estímulos observados nos cones da visão humana (BALLARD & BROWN, 1982).

Assim, desenvolveu-se o paradigma da *representação tricromática*. Nesse sistema, as ondas primárias estão representadas nos três eixos ortogonais de um sistema de coordenadas, onde as demais cores podem ser representadas como uma combinação das três cores dos eixos. Considera-se um espaço tridimensional cujos eixos são três cores arbitrárias tomadas como referência X, Y e Z. Denomina-se *plano de crominância* (ou *plano de Maxwell*) o plano de equação  $X+Y+Z=1$ , conforme o apresentado na figura 3.4.

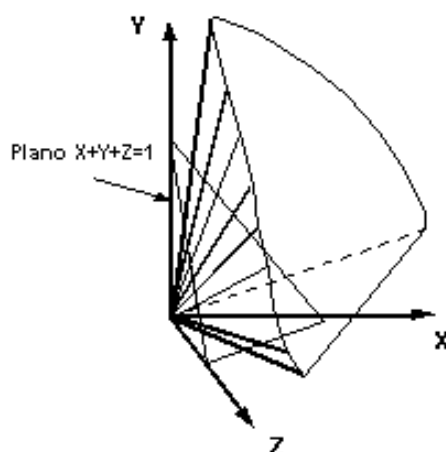


Figura 3.4 - O plano de Maxwell e o *spectrum locus* (BALLARD & BROWN, 1982)

A grande particularidade do plano de Maxwell é a possibilidade de representação de qualquer cor C do espaço de cores visíveis com uma projeção C' sobre ele (usualmente

conhecida como cromaticidade) e uma grandeza escalar (C-C') representativa da intensidade luminosa da cor. Em outros termos, o plano de Maxwell é um plano *padrão* de representação de cores.

As cores espectrais podem ser representadas em função das cores escolhidas como eixos do sistema e estarão representadas no plano de Maxwell por pontos em uma curva denominada *spectrum locus* (local do espectro), que usualmente se apresenta em forma de uma ferradura. Internas à curva, apresentar-se-ão as possíveis combinações das ondas monocromáticas, resultando em um conjunto de todas as cores possíveis, menos a variação de luminosidade, ou seja, em termos de cromaticidade (BALLARD & BROWN, 1982).

Uma outra particularidade do plano de Maxwell é a redundância de uma variável. Seja uma cor C com coordenadas (C1, C2, C3) expressa nesse sistema. As coordenadas do ponto C' (C'1, C'2, C'3) - projeção do ponto C sobre o plano de Maxwell - podem ser expressas por:

$$C'1 = \frac{C1}{\{C1+C2+C3\}} : C'2 = \frac{C2}{\{C1+C2+C3\}} : C'3 = \frac{C3}{\{C1+C2+C3\}} \quad (3.3)$$

Uma vez que o ponto C' encontra-se sobre o plano de Maxwell, uma de suas componentes pode ser expressa em termos das outras duas. Por exemplo:

$$C'3 = 1 - C'1 - C'2 \quad (3.4)$$

Nesse sentido, usualmente, adota-se em (BALLARD & BROWN, 1982) a projeção do triângulo de Maxwell e do *spectrum locus* sobre algum dos planos laterais (usualmente o r-g), gráfico que é denominado *diagrama de cromaticidade*. É importante observar que a posição do triângulo de Maxwell e o seu formato projetado (e, portanto, o formato do *spectrum locus*) dependerão da escolha das cores representadas nos eixos ortogonais.

Uma vez que a escolha das cores dos eixos não é uma tarefa trivial, diversos padrões foram propostos, sendo os principais apresentados nas seções seguintes.

### 3.5 PADRONIZAÇÕES DE CORES

O órgão padronizador internacional na área de colorimetria é o CIE – Comissão Internacional de Iluminação (*Commission Internationale de l'Eclairage*). A maioria de suas padronizações foi estabelecida na década de 30 e permanece até hoje, tais como RGB, XYZ e YUV. Contudo, alguns outros padrões estabeleceram-se mundialmente no trabalho com cores, mesmo sem as padronizações do CIE, caso do HSI, adotando até mesmo outras formas de representação que não a tricromática (GOMES & VELHO, 1998).

### 3.6 CIE-RGB

Uma vez que o sistema visual humano possui células capazes de detectar comprimentos de onda de três tamanhos distintos: vermelho, verde e azul, nas faixas alta, média e baixa do espectro, respectivamente, é imediata a utilização de comprimentos de onda em faixas similares para a composição de representação tripla. Embora com o passar dos anos os comprimentos de onda adotados tenham-se alterado consideravelmente desde a proposição inicial de Maxwell (1860), atualmente definem-se os comprimentos de onda para o sistema RGB como os mostrados na tabela 3.4. Observa-se que não se tratam rigorosamente dos mesmos comprimentos de onda observados pelos cones humanos respectivamente 570, 535 e 445 nm.

Comprimento de onda ( $\lambda$ )	Cor
700 nm	Vermelho
546 nm	Verde
435,8 nm	Azul




Figura 3.5 – Definição das cores primárias pelo *diagrama de cromaticidade r-g* do sistema RGB

A projeção radial do sólido de cor no plano de Maxwell da figura 3.4 é chamada de diagrama de cromaticidade, a projeção do conjunto obtido em um dos planos coordenados, que no caso do sistema CIE-RGB é o plano r-g mostrado na figura 3.5.

Em um sistema descrito apenas em termos de três cores, a determinação da luminância deste não mais requer uma integração de todo o espectro de cores sobre a curva do observador padrão, mas sim, a observação das potências aparentes relativas a esses três comprimentos de onda. Então, em termos de sua variação de luminância, é possível demonstrar (GOMES & VELHO, 1998) que o sistema CIE-RGB - para as cores primárias adotadas - pode ser descrito como:

$$Y = 0,299R + 0,587G + 0,114B \quad (3.5)$$

A variação da luminosidade do sistema RGB dá-se no sentido do plano desenhado pela equação, não coincidindo, portanto, com nenhum dos eixos do sistema.

O sistema RGB pode ser aplicado em dispositivos de computação gráfica, dentre eles está o sistema de cor do monitor do tipo CRT (Tubo de raios catódicos), onde as cores RGB são definidas pelo tipo de fósforo utilizado. Este espaço de cor forma um subconjunto limitado pelo espaço gerado por elas, formando um cubo apresentado na figura 3.6. Nos pontos extremos dos eixos deste cubo aplica-se o triângulo de Maxwell.




Figura 3.6 – Sistema RGB do monitor (GOMES & VELHO, 1998)

Os modelos de especificação de cor baseados no espaço vetorial, como o modelo RGB, apesar de práticos do ponto de vista computacional, são inadequados do ponto de vista de comunicação com o usuário e com relação à especificação simples e intuitiva de uma determinada cor. Uma dificuldade de se especificar cor no sistema RGB ocorre quando se deseja determinar uma cor de tonalidade e luminância conhecidas e precisamos apenas dosar a saturação, diminuindo ou aumentando a quantidade de branco na cor. Para realizar essa

mudança devemos alterar três componentes de cor e essa alteração não tem qualquer relação intuitiva com os parâmetros percentuais de tonalidades, luminância e saturação (GOMES & VELHO, 1998).

Nesse ambiente, observa-se alguns pontos importantes da representação RGB:

- a) nem todas as cores do espectro visível estão representadas no espaço positivo do sistema, ou seja, algumas cores podem requerer quantidades negativas de alguma cor primária (como pode ser visto na figura 3.7);
- b) grandezas fotométricas de interesse como a luminância não são de obtenção imediata, necessitando do cálculo da combinação linear ou da integração sobre a curva do observador padrão;
- c) a figura resultante não faz uma utilização ótima do espaço, acarretando perda de precisão e homogeneidade na distinção de cores.

### 3.7 Sistema CIE-XYZ

O sistema RGB apresentava dois problemas principais: representação de valores negativos dificultando o cálculo da cor dentro de um sistema de coordenadas; e não era possível representar as cores num sistema de coordenadas de 3 dimensões. O modelo XYZ usa primárias imaginárias X, Y e Z para descrever o espaço de cores; pode-se definir um gráfico de representação para que as grandezas fotométricas sejam encontradas mais facilmente, porém representando as cores que não estão definidas dentro do espectro visível. A partir dos valores definidos pelas letras X, Y e Z, são definidas as coordenadas dentro do sistema RGB que levam a uma equação matemática associada às letras. A representação desse sistema de cores é mostrado nas figuras 3.7 e 3.8; o formato de uma figura encontra-se inserido dentro de um triângulo representando as três primárias do sistema RGB, onde todas as cores visíveis são representadas com coordenadas positivas. Os espaços dentro da figura são locais de cores sem luminosidade e isto foi colocado ao longo de X para Z no sistema XYZ. Toda luminosidade é expressa em Y, o local de referência Y foi escolhido para enquadrar o domínio das cores reais. O ponto de energia branco (w) foi escolhido para ter coordenadas de cromaticidade iguais (0.33, 0.33) como mostram as figuras 3.7, 3.8 e 3.9. Coordenadas de cromaticidade representa a relativa contribuição das três primárias, a soma das coordenadas é igual a 1.0. Entretanto, z pode ser calculada pelo conhecimento das coordenadas x e y para:

$$X + Y + Z = 1$$

(3.6)

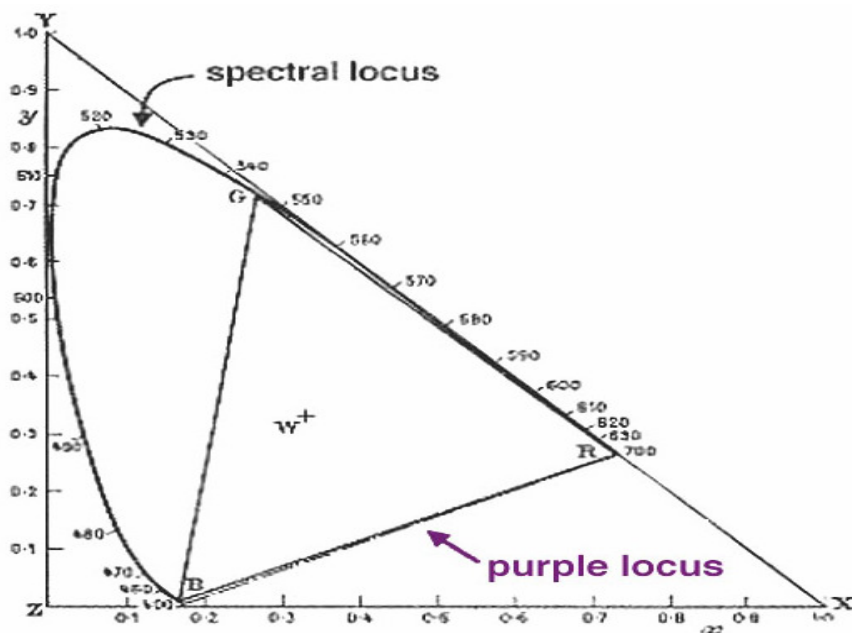


Figura 3.7 – 1931 CIE - diagrama de cromaticidade (CIE, 2006)

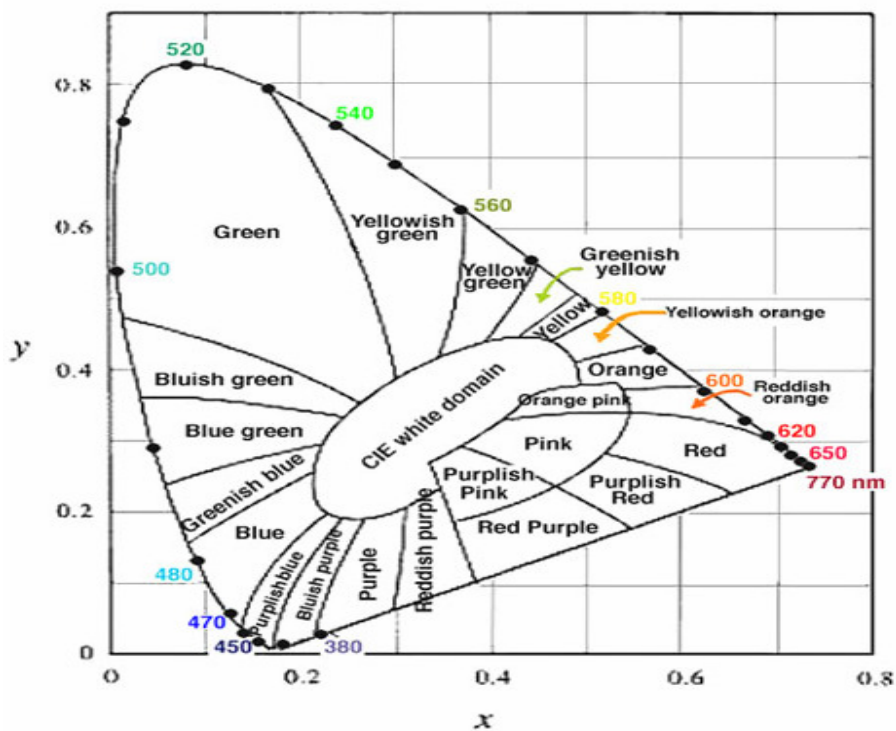


Figura 3.8- 1931 CIE diagrama de cromaticidade com representação aproximada das cores (CIE, 2006)




Figura 3.9 - Diagrama de cromaticidade do sistema CIE-XYZ (CIE, 2006)

A mudança de coordenadas entre os sistemas CIE-RGB e CIE-XYZ é dada por:

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0.049 & 0.31 & 0.20 \\ 0.17 & 0.81 & 0.01 \\ 0.00 & 0.01 & 0.99 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (3.7)$$

Usando essa transformação de mudança de base (3.7), podemos calcular grandezas colorimétricas do sistema CIE-XYZ a partir do sistema CIE-RGB.

### 3.8 Sistema CIE L\*a\*b\*

**CIE L\*a\*b\*(ou CIE LAB)** é o modelo de cor mais completo usado convencionalmente para descrever todas as cores visíveis pelo olho humano. O asterisco após o L, a e b são parte do nome completo L\*, a\* e b\*. Os três parâmetros representam respectivamente L\* luminosidade da cor (L\* = 0 representa o preto e L\* =100 representa o branco) conforme figura 3.10, o a\* está posicionado entre magenta e verde e b\* está posicionado entre amarelo e azul.



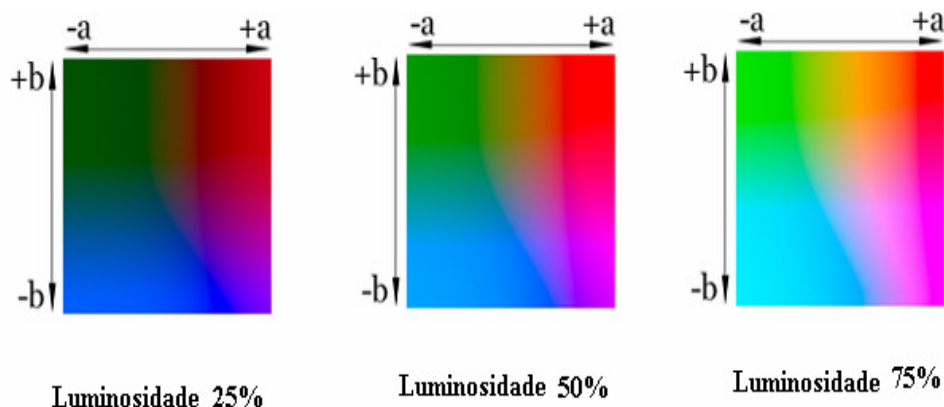


Figura 3.10 – Níveis de luminosidade  $L^*$  para CIE  $L^*a^*b^*$

O modelo de cor Lab tem sido criado para servir como um dispositivo independente, modelo absoluto para ser usado como referência e imprescindível para perceber as representações visuais do *gamut* cheio de cores (*gamut* de um dispositivo ou processo é a porção visível do espaço de cores que pode ser representada, detectada ou reproduzida). Este modelo não tem precisão, mas ajuda no entendimento do conceito, é tridimensional e pode ser representado em um espaço tridimensional. Uma característica útil dele é que o primeiro parâmetro é extremamente intuitivo: mudar este valor é como mudar o ajuste de luminosidade da TV. Entretanto, somente umas poucas representações de algumas "fatias" do horizontal no modelo é suficiente para conceitualmente visualizar o *gamut* completo, assumindo que a luminância pode ser representada no eixo vertical.

CIE 1976  $L^*a^*b^*$  foi baseado diretamente no CIE 1931 XYZ espaço de cores como uma tentativa de linearizar a perceptividade das diferenças de cores, usando a diferença métrica de cores descrita pela elipse de MacAdam (CIE, 2006). A relação não linear para  $L^*$ ,  $a^*$  e  $b^*$  é intencional para imitar a resposta logarítmica do olho.

## 4 IMAGEM, SELEÇÃO DE CORES E FILTRAGEM

A formação de uma imagem ocorre quando um sensor registra a radiação que interagiu com objetos físicos (BALLARD & BROWN, 1982) e para entendê-la são necessários alguns conceitos, tais como:

- a) a física da formação da imagem;
- b) a modelagem matemática de uma imagem;
- c) a modelagem matemática de uma imagem discreta.

### 4.1 FÍSICA DE FORMAÇÃO DA IMAGEM

A física da formação da imagem envolve o comportamento de uma imagem no sistema visual do observador, em que os sistemas físicos podem ser descritos pela matemática.

Os objetos são classificados como *emissivos* ou *radiantes em relação à emissão de luz* ou como *reflexivos* ou *irradiantes em relação à reflexão de luz*. Assim, ocorre em uma fonte de luz distante incidindo sobre uma pequena parte de uma superfície, como o disposto na figura 4.1. Denomina-se *reflectância* da superfície, a fração de um dado fluxo de energia incidente, refletido em uma certa direção.

A *função de reflectância* é uma medida de como se comporta a energia emanada de um ponto, com relação ao fluxo incidente. Usualmente, esta é uma função dos três ângulos ( $i$ ,  $e$ ,  $g$ , da figura 4.1), com o ângulo incidente  $i$  formado pelo vetor de iluminação e o vetor normal da superfície, ângulo de emissão  $e$  formado pelo vetor normal  $N$  e vetor de observação  $O$ , e o ângulo de observação  $g$ , pelo vetor de iluminação e vetor de luz refletida (vetor de observação), onde:  $O$  é igual a observador;  $N$  é igual a vetor normal.




Figura 4.1 - A geometria da reflectância

Os diversos tipos de superfícies terão, portanto, diferentes complexidades de função de reflectância. Superfícies puramente foscas terão o mesmo brilho em todas as direções. Superfícies *especulares* puramente reflexivas terão reflexão na direção em que o ângulo de observação for igual ao ângulo de incidência, no plano formado pelos vetores envolvidos. Em termos formais a radiância (L) de um ponto será dada por (BALLARD&BROWN, 1982) :

$$L = \frac{d^2\Phi}{dA \cos \theta dw} \quad [\text{watts}/(\text{metro}^2 \text{ estereoradiano})] \quad (4.1)$$

onde:  $\left\{ \begin{array}{l} L \text{ é a radiância da imagem} \\ \Phi \text{ é o fluxo de energia luminosa} \\ \theta \text{ é o ângulo entre a superfície normal e a direção de emissão} \end{array} \right.$

A intensidade de luz refletida por um ponto L(p) é, portanto, uma função do fluxo de luz incidente sobre tal elemento de área E(p) e da função de reflectância da superfície (r). Ocorre que, em sistemas reais, a luz incidente é extremamente difícil de ser modelada.

## 4.2 MODELAGEM MATEMÁTICA DA IMAGEM

Da modelagem matemática do mundo físico é sabido que a luz refletida de um ponto de uma superfície pode ser descrita como uma função da luz nele incidente e da reflectância desse ponto. Pretende-se agora estabelecer como tal função compõe o que venha a ser uma imagem.

Define-se como *função imagem* a abstração fundamental de uma imagem, ou seja, sua representação matemática. Em geral, esta função de intensidade luminosa bidimensional  $f(x,y)$  (GONZALEZ & WOODS, 2003) em que o valor ou amplitude de  $f$  é definido sobre um ponto genérico  $p(x,y)$  dá a intensidade (brilho) da imagem naquele ponto e é dada por:

$$I(p) = f(x, y) \quad (4.2)$$

onde  $\left\{ \begin{array}{l} I(p) \text{ é a função imagem para o ponto } p; \\ (x,y) \text{ é a coordenada espacial do ponto } p; \\ f(.) \text{ é a função que mapeia o ponto } p \text{ no universo de cor.} \end{array} \right.$

A função imagem é caracterizada por dois componentes: a quantidade de luz incidindo na cena observada também chamada iluminação, e a quantidade de luz refletida pelos objetos da cena, também chamada reflectância; portanto:  $f(x,y) = i(x,y) \cdot r(x,y)$  (GONZALEZ & WOODS, 2003).

Em termos de mapeamento monoespectral, podemos assumir que  $f(\cdot)$  representa a função do ponto mapeando-o em um universo de tons de cinza, ou seja, trata-se do mapeamento das intensidades luminosas  $L(p)$  vistas por um observador.

### 4.3 IMAGEM DIGITAL

Um caso particular da *função imagem* é a *função imagem digital*. Os argumentos e o valor da função são sempre inteiros. Para se obter a conversão da representação da imagem, a partir de uma função contínua para a discreta, utiliza-se a ferramenta conhecida como função delta. Tal função é aplicada sobre um ponto  $p$  e pode ser definida como:

$$\int \delta(x) dx = 1 \quad (4.3)$$

onde:  $\delta(x) = 0$  quando  $x \neq 0$ ; não definido quando  $x = 0$ .

Com a aplicação desta ferramenta matemática nas dimensões usuais, a multiplicação da imagem bidimensional pela função  $\delta(x)$ , pode-se obter um conjunto de amostras, gerando uma imagem discreta (BALLARD & BROWN, 1982).

A modelagem do mundo físico através de uma imagem discreta, possibilita uma forma finita de representação de grandezas contínuas. Contudo, devido ao processo de digitalização, diversos problemas são introduzidos no universo de mapeamento mundo-imagem, tais como amostragem, quantização, conceito de distância entre pontos etc. Uma imagem multiespectral especial é uma imagem colorida na qual,  $f$  (é um vetor  $(f_1 \dots f_n)$ ) de uma imagem colorida, que pode ser representada por:  $f(x) = \{f_{\text{red}}(x), f_{\text{blue}}(x), f_{\text{green}}(x)\}$ .

### 4.4 AMOSTRAGEM E QUANTIZAÇÃO

Para ser conveniente ao processamento computacional, uma função imagem precisa ser digitalizada espacialmente e em amplitude (GONZALEZ & WOODS, 2003). A primeira chama-se *amostragem*, que é a discretização do domínio da imagem, usualmente a digitalização das coordenadas espaciais da imagem; e a segunda chama-se *quantização*, que é a digitalização das amplitudes da função imagem.

A *amostragem* da imagem envolve o *intervalo espacial de amostragem* e o *padrão espacial dos pontos de amostragem* (BALLARD & BROWN, 1982). No primeiro tópico, usualmente o problema pode ser reduzido a uma curva de resolução da imagem *versus* custo

computacional. Evidentemente, busca-se utilizar imagens que preservem a fidelidade da visão humana, com a menor resolução espacial possível. Os intervalos de amostragem excessivamente grandes comprometerão o resultado final da imagem observada, levando ao problema computacional da subamostragem da imagem contínua, fazendo com que uma superfície suave, tipicamente, apareça “rugosa” (BALLARD & BROWN, 1982).

De forma a adotar um critério para o problema da amostragem, faz-se uso do *teorema da amostragem* que, em sua essência, define como deve ser uma amostragem mínima para garantir a representatividade da imagem. Em muitos casos tal problema leva à utilização de amostragens não-homogêneas no campo visual, similar ao encontrado na região da fóvea, na retina.

O *padrão espacial dos pontos de amostragem* é obtido com a menor unidade de partição da imagem, o *pixel*, que significa a composição de *picture element*. O pixel faz parte de um *padrão espacial* no qual o plano da imagem é definido. Este padrão define um conjunto finito de células sobre as quais o nível de cor é constante.

Embora o formato mais comum do padrão seja o retangular, outros padrões podem ser assumidos, tais como triangular ou hexagonal. Já a *quantização* envolve a problemática de se saber com quantos níveis de intensidade uma dada imagem será mapeada.

A discretização impõe um compromisso entre a eficiência computacional dos sistemas e a visualização das imagens. No domínio dos trabalhos com cores, uma baixa quantização implica a perda de informações importantes do mundo físico.

#### **4.4.1 Dispositivos de aquisição**

Segundo GONZALEZ & WOODS (2003), dois elementos são necessários e indispensáveis na *aquisição* de imagens digitais por qualquer dispositivo: **a)** um elemento físico que seja sensível às diferentes bandas de comprimento de onda eletromagnética (tipicamente da luz visível, mas, genericamente, de qualquer faixa de onda), responsável pela amostragem do universo e a conversão dessas amostragens em impulsos elétricos; e **b)** um dispositivo digitalizador, responsável pela conversão do impulso elétrico para quantificações digitais.

Os processos pelos quais as intensidades são capturadas, entretanto, podem variar consideravelmente. Em sistemas de *raios-x*, por exemplo, entre um canhão emissor de raios e um conjunto de receptores sensíveis a tal raio, interpõe-se um alvo, constituído de material capaz de absorver parcialmente os raios-x. Nos receptores, obter-se-á um mapeamento da

absorção dos raios pelo alvo. Tal sistema é um exemplo típico de elementos sensíveis a ondas não-visíveis.

A *câmera de vídeo* é um dispositivo que gera amostras da luz visível tipicamente fazendo uso de elementos sensíveis a particulares comprimentos de onda. Tal dispositivo possibilita a utilização de diversas tecnologias. Um tipo que abrange praticamente a totalidade das câmeras atuais faz uso da tecnologia conhecida como CCD, baseada em dispositivos de carga acoplada.

O CCD (*charge-coupled device*, dispositivo de carga acoplada) utiliza-se de uma coleção de elementos denominados fotossensíveis, que produzem uma tensão de saída na forma de cargas armazenadas, proporcional à intensidade de algum comprimento de onda incidente. Trata-se de elementos com grande resolução e alta velocidade de aquisição (da ordem de 1/10.000 s) (GONZALEZ & WOODS, 2003).

É possível dispor os fotossensores de duas maneiras: **a)** em linha, ou **b)** em matrizes de área. A arquitetura com captura em linha utiliza apenas uma linha de *fotossítios* de tais elementos e produz uma imagem bidimensional pela variação da posição relativa entre a cena e o detetor. Normalmente os *scanners* (digitalizadores de imagem) utilizam-se desta tecnologia. Na segunda arquitetura (em bloco ou matricial), toda uma matriz desses componentes é utilizada. As câmeras de vídeo fazem uso dessa arquitetura.

Embora os elementos fotossensíveis tenham grande velocidade de aquisição de dados, a manipulação desses sinais analógicos convertidos digitalmente até sua emissão na forma de um sinal de vídeo fazem com que tais dispositivos funcionem com uma varredura repetida trinta vezes por segundo.

As câmeras possuem suas curvas específicas de sensibilidade. Idealmente, uma câmera que mostre o ambiente e o retorne em coordenadas RGB deverá possuir elementos sensíveis aos comprimentos de onda definidos pelo sistema CIE-RGB. Esta sensibilidade não é idêntica fisicamente para todos os dispositivos. Isso significa que, para cada câmera, o cálculo da luminância será particular e observado sobre suas próprias cores primárias.

#### **4.4.2. Dispositivos de representação**

Tradicionalmente, os monitores de TV ou vídeo constituem a principal classe de dispositivos representadores de imagem e, portanto, de cores. O sistema de vídeo é

constituído de quatro componentes: **a)** um monitor; **b)** um controlador de vídeo; **c)** uma memória de exibição e **d)** um conversor digital-analógico.

O *monitor de vídeo* consiste de um tubo de raios catódicos, uma tela e um canhão que produz um feixe de elétrons. Em pontos da tela ou; mais precisamente; a cada pixel encontram-se camadas de fósforo, que, ao serem atingidos pelo feixe de elétrons, passam a emanar radiação eletromagnética visível por algum tempo. Usualmente, utilizam-se fósforos com as radiações correspondentes aos níveis vermelho, verde e azul (RGB). O *controlador de vídeo* é o dispositivo que tem por finalidade controlar o movimento do feixe de elétrons sobre a tela, produzindo uma varredura nela. O padrão de varredura é variável, dependendo do dispositivo (GOMES & VELHO, 1998). A *memória de exibição* armazena dados da imagem digital que, através do *conversor digital-analógico*, são convertidos em tensões a serem aplicadas ao canhão de elétrons.

Devido às limitações físicas dos dispositivos de emissão, tais como os fósforos coloridos (que não são capazes de representar todas as cores do espectro visível), um monitor de vídeo terá seu espaço de cores limitado, ou seja: "(...) o sólido de cor desse sistema será um subconjunto limitado do espaço gerado pelas cores primárias R, G e B. Isso porque cada cor primária do espaço de cor do monitor assume um valor de intensidade máxima". (GOMES & VELHO, 1998)

Dessa forma, cada monitor terá o seu próprio espaço RGB que, por sua vez, será um novo subconjunto do sistema RGB padronizado pelo CIE. Graficamente, então, esse espaço pode ser expresso por um triângulo sobre o espaço de cromaticidade (figura 4.2).




Figura 4.2 - Diagrama representativo do triângulo de cromaticidade para o RGB de dois monitores distintos (GOMES & VELHO, 1998).

### 4.4.3. Geometria e conectividade

O processo de amostragem e representação de grandezas no mundo físico por meio de valores inteiros, invariavelmente, impõe alguma perda de informação. Essa problemática é particularmente visível quando tratamos do problema da subamostragem, já abordado. Todavia, por maior que seja a resolução da amostragem espacial, sempre existirá algum nível de subamostragem em uma imagem digital, implicando em perda da informação geométrica do universo da amostragem, já que esta é representada, em última instância, por *pixels*, ou seja, entidades discretas. Tal fato é representado pela figura 4.3. Uma das implicações deste problema, conhecido como "*paradoxo da conectividade*" (BALLARD & BROWN, 1982) diz respeito ao problema estrutural da adoção da vizinhança de um ponto. A distância entre dois pontos de uma imagem é de grande relevância para muitos algoritmos de visão computacional. As medidas mais comuns para essa grandeza para dois pontos  $x(x_1, y_1)$  e  $y(x_2, y_2)$  são apresentadas na tabela 4.1. Tais distâncias podem ser visualizadas na figura 4.4. Definidos tais padrões, a adoção de um deles (ou de outros) permanece a cargo do algoritmo envolvido, isto é, do padrão que maximiza sua performance.




Figura 4.3 - Uma reta (grandeza contínua) e sua representação em um domínio discreto

Tabela 4.1 - As várias medidas de distância entre pontos em uma imagem digital.	
Nomenclatura	Distância
Euclidiana	$De\{x,y\} = \sqrt{\{x_1 - x_2\}^2 + \{y_1 - y_2\}^2}$
Quarteirão (ou D4)	$Dcb\{x,y\} =  x_1 - x_2  +  y_1 - y_2 $
Tabuleiro de Xadrez (ou D8)	$Dch\{x,y\} = \text{Max} \{ \{ x_1 - x_2 ,  y_1 - y_2 \} \}$






Figura 4.4 - Contornos equidistantes para diferentes métricas:  
 (a) Euclidiana (com aproximação para inteiro de número decimal);  
 (b) D4; (c) D8.

## 4.5 SEGMENTAÇÃO

A idéia da segmentação tem origem nos seres humanos que desenvolvem agrupamento visual baseado em características como proximidade, similaridade e continuidade. Na visão computacional, este processo é denominado segmentação, pelo qual entende-se a extração de parâmetros que permitam associar regiões da imagem com objetos na cena. Nesse sentido, busca-se dividir a imagem digital em regiões disjuntas, tais que um *pixel* pertença apenas a uma das regiões (GONZALEZ & WOODS, 2003).

No processamento de imagens, o primeiro passo para a análise de imagens é a segmentação. A segmentação divide uma imagem de entrada em partes ou objetos constituintes. A saída do estágio de segmentação trabalha com os dados em forma de pixels (*raw pixels data*), correspondendo tanto à fronteira de uma região como a todos os pontos da mesma (GONZALEZ & WOODS, 2003).

### 4.5.1. Métodos para segmentação

Os algoritmos de segmentação para imagens monocromáticas são baseados em duas propriedades: a) descontinuidade e b) similaridade (GONZALEZ & WOODS, 2003).

Na *segmentação baseada na descontinuidade*, a partição é embasada em alterações bruscas nos níveis da função imagem. Tais descontinuidades em uma imagem digital são decorrentes de diversas situações na cena tais como: descontinuidade da normal das superfícies, descontinuidade em profundidade, descontinuidade na refletância da superfície e descontinuidade de iluminação. As principais áreas de interesse são a detecção de pontos isolados e a detecção de limiares e bordas na imagem.

Esta informação é relevante para a segmentação de imagens. Para tanto, trabalha-se com a detecção de pontos, linhas e bordas. Na prática, a descontinuidade é obtida por meio da

varredura da imagem por uma máscara. Os operadores que, atuando sobre as imagens digitais, visam determinar as descontinuidades nelas presentes realizando operações entre pixels, tais como diferença e derivada, fornecem as bordas de uma imagem e estas são seguidas por detecção de fronteiras.

Já a *segmentação baseada em similaridade* busca agrupar regiões com características semelhantes. Dentre as possíveis características utilizáveis, encontram-se a textura e as cores.

A segmentação por similaridade utiliza-se de abordagens tradicionais que fazem uso de cores e dividem-se em dois grupos: a) as que fazem uso da informação topológica da imagem, tais como o crescimento de região e a divisão e agrupamento de região (*split and merging*) e b) as que não fazem uso da informação topológica, como é o caso da imposição de limiares e procura de bordas (*edge finding*) (GONZALEZ & WOODS, 2003).

#### 4.5.2. A imposição de limiares

A técnica da imposição de limiares (*thresholds*) (MARQUES & VIEIRA, 1999) foi primeiramente adotada para a segmentação de imagens em tons de cinza e, posteriormente, generalizada para imagens multicromáticas. Tradicionalmente, faz uso da representação da imagem em um espaço de cores e da similaridade entre os valores dos pixels para agrupamento.

Tratando-se de imagens monocromáticas, por esta abordagem, um *pixel*  $p(x,y)$  em uma imagem  $f(x,y)$  seria classificado como pertencente a uma região:

R1, caso  $f(x,y) < T$  e R2, caso contrário

onde:  $T$  é o *threshold* (ou limiar) para a classificação.

Tradicionalmente, a aplicação dos limiares está ligada a um estudo do histograma da imagem, e a determinação de um nível capaz de separar duas regiões, conforme a figura 4.5.

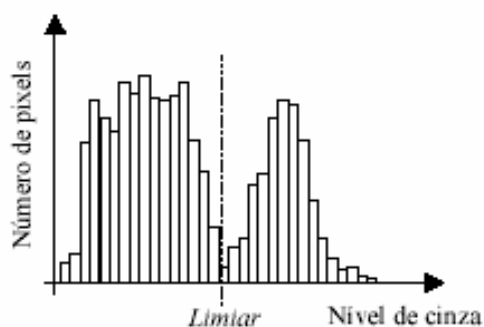


Figura 4.5 - Determinação de limiar para histograma em tons de cinza (BALLARD & BROWN, 1982)

Para as imagens coloridas, o paradigma da imposição de limiares evoluiu para um espaço multidimensional. Dada a representação das cores de *pixels* de uma imagem em algum espaço tridimensional, "espera-se determinar parâmetros de cores para os limiares que possam processar a segmentação" (BALLARD & BROWN, 1982). Nesse sentido, como pode ser visto na figura 4.6, para pertencer a um grupo R, a representação da cor de um *pixel* precisa estar dentro dos limites das três faixas das primárias de cores (A, B e C).




Figura 4.6 - Os limiares aplicados a um espaço tridimensional de cores (BALLARD & BROWN, 1982)

O método dos limiares é considerado de grande utilização em situações simples, mas bastante primitivo (BALLARD & BROWN, 1982). Normalmente, *pixels* bem divididos de um histograma, ou espaço de cores, podem não estar conectados espacialmente. Outras situações como a presença de ruído ou mesmo fundos de imagem que apresentam tonalidades variáveis podem incorrer em segmentações inapropriadas.

Duas observações são, portanto, importantes no contexto dos trabalhos com *limiares* aplicado ao reconhecimento de cores:

- a) nenhuma consideração sobre a localização espacial do *pixel* e topologia da imagem é utilizada em sua classificação, apenas o espaço de cores é analisado;
- b) nem sempre existe um limiar ótimo para segmentar regiões.

As limitações restringem fortemente a utilização do método.

### 4.5.3. Algoritmos baseados em vizinhança

Um dos algoritmos que proporciona a segmentação pela análise da vizinhança é o *crescimento de região*. Trata-se de um processo pelo qual *pixels* com características

semelhantes em uma vizinhança são agregados em regiões maiores, sucessivamente, partindo-se de um conjunto de pontos denominado a "semente" da região (GONZALEZ & WOODS, 2003). Propõe-se que, para a segmentação de imagens monocromáticas por este processo, a propriedade  $P$ , que é utilizada para classificar um *pixel* em uma dada região, seja o valor absoluto da diferença entre o nível de cinza de um pixel e o nível de cinza do pixel tomado como semente. Em outras palavras, todo *pixel* de uma vizinhança que possuir uma diferença menor que um limite  $T$  do *pixel* semente, será enquadrado na região deste *pixel*. De maneira análoga, para imagens coloridas, podemos utilizar um limiar tricromático. Observe-se que, embora faça uso da imposição de limiares, este método leva em consideração a informação da vizinhança do ponto, o que é desconsiderado pelo método anterior.

Um método alternativo ao anterior é o da *divisão e agrupamento de regiões* (BALLARD & BROWN, 1982). A alternativa apresentada é inicialmente subdividir uma imagem em um conjunto arbitrário de regiões, e, então, proceder à sua análise, dividindo-as novamente em partes menores, caso não atendam a determinados critérios, ou agrupando-as com regiões vizinhas.

#### **4.5.4. A classificação de pixels**

Tanto os algoritmos baseados em análise de descontinuidades quanto os que efetuam o agrupamento de regiões freqüentemente utilizam-se da comparação de níveis de intensidade luminosa dos pixels da imagem para a tomada de decisões e da imposição de limiares. Contudo, tratando-se de imagens segmentadas por cores, nem sempre a diferença entre o valor luminoso de dois pontos é suficiente para proceder segmentações, visto que as noções cognitivas de cor não são homoganeamente distribuídas pelo espectro de cores. Tratando-se do paradigma da imposição de limiares, isto implica que as regiões representativas de cada cor pertencente ao espectro de cores não são necessariamente separáveis por sólidos de tamanhos iguais no espaço tricromático de cores e, mais que isso, não são necessariamente separáveis por sólidos regulares.

Um algoritmo de segmentação mais cuidadoso com esse conceito deveria estar apto a realizar a classificação de cores antes da fase de segmentação propriamente dita.

Uma vez realizada tal análise, a imagem classificada poderia ser submetida aos algoritmos acima descritos. Tal camada, que é descrita aqui como um pré-processamento,

pode também ser vista como uma classe de segmentação, em situações onde apenas a informação de cores é suficiente para a segmentação.

O método da imposição de limiares pode ser considerado um método de classificação, já que subdivide o espaço de entrada em regiões discretas que podem ser interpretadas como classes. A fim de obter melhores classificações, ferramentas mais elaboradas podem ser utilizadas, em especial, ferramentas do âmbito da inteligência artificial, onde o problema de classificação é de grande relevância. Uma abordagem natural e com grande habilidade de generalização é a das *redes neurais artificiais* (RNAs), a qual será utilizada neste trabalho no processo de classificação após a segmentação tradicional.

#### 4.5.5. Filtro de Sobel

A filtragem do sinal é um conceito relacionado ao processamento de imagem que pode ser utilizado para definir a classificação baseada no tamanho dos elementos.

O filtro de Sobel é uma operação tipicamente utilizada em processamento de imagem, especialmente em algoritmos desenvolvidos para fazer a detecção de contornos (KIMMEL, SHAKED & ELAD, 2005). Em termos técnicos, o filtro é um operador que calcula pelo método das diferenças finitas uma aproximação do gradiente da intensidade de cor dos pixels na imagem. Os cálculos de obtenção do filtro de Sobel estão em GONZALEZ & WOODS, 2003. O filtro de Sobel calcula o gradiente em cada ponto da imagem, definindo a direção de mudança do claro para escuro e a quantidade de variação naquela direção. Então, utilizando esta técnica, pode-se determinar a variação da luminosidade em cada seção, mais suave ou mais abrupta. Com isto, é possível estimar a presença de pontos de transição claro-escuro e sua direção, e a partir daí detectar o contorno dos objetos da imagem.

A Figura 4.7 mostra um exemplo de aplicação do filtro de Sobel na detecção do contorno a partir de uma imagem de tomate. A partir desta imagem filtrada pode-se desenvolver um algoritmo para definir o tamanho do tomate.




Figura 4.7 – Imagens de um tomate antes e após a filtragem

## 5 REDES NEURAIIS ARTIFICIAIS

Diversos pesquisadores, nos últimos anos, têm utilizado a modelagem das RNAs em sistemas de visão computacional (GONZALEZ & WOODS, 2003). Sua capacidade de responder a situações previamente treinadas e de generalizar para situações não presentes em seu universo de treinamento têm estimulado as pesquisas na área. Mais que isso, algumas das novas classes de redes neurais apresentam respostas que se assemelham fortemente às de células encontradas no sistema de visão humana, abrindo um novo leque no trabalho com imagens por esse paradigma. Outros pesquisadores têm se dedicado ao uso das RNAs na simulação de movimentos oculares. Uma visão geral da problemática que envolve a modelagem por RNAs para interpretação de imagens pode ser encontrado em (BARNARD & CASANET, 1991).

A proposição da segmentação por cores, como a separação de coleções de pontos em um espaço  $n$ -dimensional, leva a um caso típico de utilização das redes neurais artificiais (BARNARD & CASANET, 1991).

Neste capítulo serão abordados os principais aspectos relacionados às redes neurais apresentando: a) um panorama histórico da técnica; b) os aspectos biológicos; c) a modelagem matemática do neurônio; e d) a arquitetura de RNA que será usada como classificador nesse trabalho.

Destaca-se que, devido à grande diversidade de arquiteturas encontradas na literatura, apenas as de maior importância ou de alguma forma relevantes ao trabalho proposto serão abordadas, em especial, o *perceptron* multicamada. A escolha pela utilização das redes *perceptron* multicamada deve-se à existência de vasta bibliografia referente ao assunto, bem como vários softwares já testados que poderão ser utilizados na comprovação dos dados resultantes do software proposto neste trabalho. Um panorama geral de outras arquiteturas pode ser encontrado em algumas referências bibliográficas da área (CABRAL, 1999).

## 5.1 HISTÓRICO

No ano de 1894, o espanhol Ramòn y Cajal, em sua publicação "A Retina dos Vertebrados" (*Die Retine der Wirbeltiere*), identificava anatomicamente uma célula nervosa. Quase meio século depois, Warren McCulloch e Walter Pitts em 1943, publicaram o artigo "Um Cálculo Lógico das Idéias Provenientes da Atividade Nervosa" (*A Logical Calculus of the Ideas Immanent in Nervous Activity*), levando ao surgimento das "redes neurais artificiais". Especulava-se, então, sobre ser booleana a natureza da inteligência. Contribuindo ainda mais para tal especulação, os mesmos autores implementaram um *discriminador linear* extremamente simples, capaz de separar duas coleções de entradas booleanas que fossem linearmente separáveis, em duas coleções, tomando como critério seus valores de saída, ou seja, tal discriminador era capaz de implementar as funções booleanas básicas AND, OR e NOT. Era o primeiro modelo matemático e computacional para o neurônio biológico.

O passo seguinte no desenvolvimento das RNAs foi dado por Frank Rosenblatt em 1962, que construiu uma rede com os discriminadores lineares de McCulloch e Pitts dispostos em camadas, batizada de *perceptron*. Necessitava-se, entretanto, de uma forma de treinar esta rede, que apresentava um número muito maior de pesos sinápticos. O aprendizado nas redes neurais nasceu dos estudos de Hebb (1949), biólogo, que estudava o comportamento de animais, propôs que o aprendizado em um sistema neural complexo poderia ser expresso na forma da alteração dos pesos sinápticos *locais* em função dos erros detectáveis *in loco*. Nesse momento histórico, a teoria das RNAs já se tornava estabelecida como área de pesquisa científica.

Frank Rosenblatt em 1962 empregou o princípio de Hebb em um discriminador linear, enunciando a "lei do aprendizado do *perceptron*" e elaborou uma modelagem que permitia que os estímulos da rede pudessem assumir valores contínuos, embora o neurônio utilizado ainda tivesse a função de ativação não-linear de McCulloch. Contudo, Rosenblatt não conseguiu estender tal lei ou sua prova para redes, o que era o grande limitador da utilização prática da modelagem até então.

Paralelamente a Rosenblatt, Widrow (1962) desenvolveu um modelo neural linear, batizado ADALINE (*Adaptive Linear Element*). O grande valor desse modelo foi a proposta de Widrow para a aproximação linear através do cálculo do gradiente de uma função do mínimo quadrado médio (LMS), que, em sua homenagem, foi batizada "regra Delta de

Widrow”. Posteriormente, esse método foi generalizado para uma rede neural multidimensional, que, por se tratar de múltiplas ADALINES, ficou conhecida como MADALINE (MEHROTA et al, 1997).

Seguiu-se durante a década de 70 uma fase de pouca produção de pesquisas na área. Minsky e Pappert em 1969 demonstravam as limitações das teorias desenvolvidas. As redes de uma camada falhavam na tarefa de resolver problemas extremamente simples, como a operação XOR “ou exclusivo” (HAYKIN, 2004).

Embora em menor escala de produção destacam-se, nesse período, o trabalho de Teuvo Kohonen em 1972 desenvolvendo os mapas auto-organizados ("*self-organized maps*"), uma nova classe de redes neurais que não necessita de supervisão para o aprendizado, e o trabalho de James Anderson em 1972, desenvolvendo as memórias associativas. Na década de 80 ocorreu um novo impulso nas pesquisas em redes neurais. O desenvolvimento das memórias associativas de Hopfield em 1982 inaugura essa fase (HAYKIN, 2004).

Tratava-se de uma rede neural capaz de associar modelos apresentados a ela a modelos presentes em uma memória prévia. Alguns anos depois, Rummelhart, Hinton e Williams (RUMMELHART et al, 1986) desenvolveram o algoritmo que ficou conhecido como a “*retropropagação do erro*” (*error backpropagation*), basicamente uma generalização da regra Delta de Widrow para uma rede ADALINE que tinha uma função de ativação *semilinear*. O resultado obtido foi o de uma rede com grande poder de generalização quando treinada adequadamente, que poderia aproximar qualquer função contínua. Este trabalho é considerado pela comunidade mundial como o grande impulsionador da teoria das RNAs (HAYKIN, 2004).

No início da década de 80, graças ao aparecimento de computadores mais rápidos e baratos e ao elevado número de trabalhos, as RNAs deram o seu grande salto (MEHROTA et al, 1997).

Seu domínio de aplicações atingiu a engenharia, física e psicologia. As conferências multiplicaram-se enormemente e um sem número de publicações tornou-se disponível em todo o mundo. As aplicações vislumbradas anteriormente como o reconhecimento da fala e da visão, voltavam à tona (HAYKIN, 2004).

Em 1980, K. Fukushima, dos laboratórios NHK em Tóquio, desenvolveu uma série de redes neurais especializadas no reconhecimento visual de caracteres. As primeiras tentativas com a teoria dos “*self-organized networks*”, em uma rede batizada *neocognitron*, apresentou os problemas, hoje clássicos, de falhas no reconhecimento de caracteres distorcidos



rotacionalmente ou em localizações espaciais diversas. Persistia ainda a questão do número de neurônios e camadas necessárias para uma dada implementação. Hecht-Nielsen (1990), baseado nos trabalhos do russo Kolmogorov, e Girosi e Poggio (1990) mostraram que qualquer função contínua pode ser aproximada com uma dada precisão, estabelecida *a priori*, por uma rede com uma única camada oculta (MEHROTA et al, 1997).

Com base nesse estudo, Park e Sandberg (1991) desenvolveram uma nova classe de redes neurais, conhecidas como “redes de base radial”. Trata-se de uma rede dotada de “campos receptivos” para seus neurônios, encontrando semelhança em neurônios biológicos tipicamente encontrados em áreas relativas à interpretação da visão e audição (HAYKIN, 2004).

Nestes últimos anos, a diversidade de arquiteturas das RNAs cresceu enormemente, expandindo suas aplicações na mesma proporção e impondo novos domínios à teoria. Podemos destacar sua aplicação em processamento de sinais, quer seja processamento de dados, voz ou imagens, reconhecimentos de padrões diversos, sistemas de controles e qualquer outro sistema onde a modelagem seja difícil (HAYKIN, 2004).

## 5.2 O NEURÔNIO

### 5.2.1 O Neurônio biológico e sua ativação

A teoria denominada *conexionista* recebe inspiração da maneira como o cérebro humano funciona, tendo como unidade básica de processamento uma entidade, de *hardware* ou *software*, inspirada no funcionamento do neurônio biológico.

Com o avanço dos estudos fisiológicos do sistema nervoso iniciado no século XIX, o neurônio foi reconhecido como o dispositivo elementar do processamento cerebral, e este passou a ser alvo de extensivos estudos, culminando nos dias atuais em que seu funcionamento é conhecido com alguma profundidade (GUYTON & HALL, 1997).

A anatomia da célula nervosa (figura 5.1) caracteriza-se pela presença de um corpo celular (*soma*), responsável pelos processos metabólicos da célula, e pelas projeções deste corpo (*dendritos* e *axônio*) (GUYTON & HALL, 1997). Tal célula destaca-se pela capacidade de transmissão de impulsos elétricos, possível graças às propriedades peculiares de sua membrana celular.

As entradas neurais provêm das conexões sinápticas, efetuadas pelas ramificações dos dendritos de um neurônio em contato com os axônios de outros neurônios. O neurônio, após

receber tais entradas, aqui referidas como impulsos nervosos, processadas de alguma forma, produz uma saída em seu axônio.

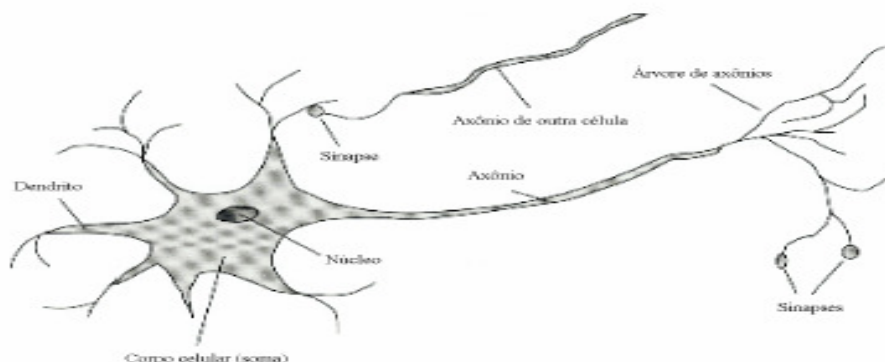


Figura 5.1 - O neurônio biológico (LOESCH & SARI, 1996)

O impulso nervoso propaga-se, segundo o processo biológico conhecido como a “bomba de sódio e potássio”, que pode ser visto na figura 5.2. A difusão de íons pela membrana possibilita que esta apresente uma polarização entre suas regiões interna e externa da ordem de alguns milivolts. Nesses termos, caracterizamos o impulso nervoso como sendo a propagação de uma despolarização, durante algum tempo, ao longo da membrana.




Figura 5.2 - Bomba de sódio e potássio: a propagação do impulso elétrico em um neurônio

A formação do potencial elétrico em um neurônio foi alvo de estudo de diversos pesquisadores, dentre os quais se destacam Hodgking e Huxley (1952), agraciados com o Prêmio Nobel de Fisiologia em 1963 pelo estudo da despolarização de uma membrana *in vitro* (LOESCH & SARI, 1996).

Kovács (2006) apresenta resumidamente a formação de tal potencial em um neurônio. Segundo ele, este ocorre sempre que a membrana recebe estímulos suficientes para cruzar um *limiar de disparo*. Ao receber tal estímulo, a célula se excitará por alguns microssegundos ( $T_n$ ), emitindo nesse período forte descarga; depois entrará em um período de *refração absoluta*

( $T_R$ ), em que a célula não produzirá novo disparo, chegando a um período de *refração relativa* ( $T_r$ ), em que um novo disparo será produzido somente sob uma excitação bastante maior que o valor do limiar de disparo e finalmente retornará ao seu estado de repouso. Um potencial de ação pode ser visto na figura 5.3 (KOVÁCS, 2006).




Figura 5.3 - Disparo de um neurônio (KOVÁCS, 2006).

### 5.2.2 A modelagem matemática

O neurônio pode ser entendido como um dispositivo que tem muitas entradas e apenas uma saída. Nesse sentido, Rummelhart, Hinton e Willians (RUMMELHART et al, 1986) propuseram um modelo não-linear para o neurônio biológico, que é amplamente aceito pela comunidade científica (figura 5.4).

Esse modelo é basicamente um *perceptron* de Rosenblatt, com uma função de ativação semilinear. O *perceptron* modela um neurônio processando uma soma ponderada de suas entradas e submetendo o resultado a uma camada de processamento de limiares  $g(.)$  (figura 5.4). No caso dos *perceptrons*, essa camada consiste basicamente de uma função degrau, mapeando as saídas nos níveis binários 0 ou 1, naturalmente uma função altamente não-linear. Rummelhart, Hinton e Willians propuseram a utilização de funções semilineares visto que, no desenvolvimento de seu método de aprendizado, fazem uso da derivada da função adotada. Esta alteração permite o treinamento dos neurônios e torna uma rede neural, como será visto adiante, capaz de mapear qualquer função contínua (LOESCH & SARI, 1996).




Figura 5.4 – Modelo não-linear de um neurônio

onde:

- X é o vetor de entrada do neurônio  $k$ ;
- $x_i$  é a excitação de entrada na sinapse  $i$ ;
- $y_k$  é a resposta (ou saída) do neurônio  $k$ ;
- $w_{ki}$  é o peso sináptico da entrada  $i$  do neurônio  $k$ ;
- $w_{k0}$  é o peso sináptico da entrada de polarização do neurônio  $k$ ;
- $g(.)$  é a função de ativação do neurônio.

Os principais tipos de função de ativação juntamente com as suas respectivas derivadas são mostrados na tabela 5.1.

Tipo da função	Equação	Derivada
Reta	$g(v) = \alpha v$	$g'(v) = \alpha$
Degrau	$g(v) = h(v)$	-
Sigmóide	$G(v) = (1 + \exp(\beta v))^{-1}$	$g'(v) = \beta \cdot (1 - g(v)) \cdot g(v)$
Tangente Hiperbólica	$g(v) = (1 - \exp(-2v)) / (1 + \exp(2v))$	$g'(v) = \beta \cdot (1 - g(v))^2$

onde:

- $g(.)$  é a função de ativação;
- $g'(.)$  é a derivada da função de ativação;
- $h(.)$  é a função degrau unitário;
- $\alpha$  e  $\beta$  são constantes.

### 5.3 OS TIPOS DE RNAs

A abordagem conexionista das RNAs abre um amplo leque de formas de conexão entre as unidades de processamento, isto é, os neurônios. Isso abrange o número de camadas presentes na rede, a forma de conexão entre tais unidades, a forma de treinamento, as funções de ativação presentes em cada camada etc.

Os pesquisadores utilizam a notação arquitetura na denominação de todo um conjunto de características de uma rede, englobando sua forma de treinamento, finalidade etc. Há dois critérios básicos para a classificação das RNAs (HAYKIN, 2004):

- a) quanto à estrutura;
- b) quanto à forma de treinamento.

### 5.3.1 A estrutura das redes

Com relação às estruturas, uma rede neural pode ser definida por duas maneiras distintas que serão detalhadas a seguir (HAYKIN, 2004).

**Redes *Feedforward*:** A propagação do processamento neural é feita em camadas sucessivas, ou seja, neurônios dispostos em camadas terão seus sinais propagados seqüencialmente da primeira à última camada, de forma unidirecional. O exemplo típico desse tipo de rede seria o *perceptron* multicamadas (MLP) (HAYKIN, 2004).

**Redes “Recorrentes”:** As saídas de um, ou de todos os neurônios, podem ser realimentadas a neurônios de camadas precedentes (geralmente da primeira). Esse tipo de rede é classificado como memória dinâmica. O exemplo típico dessa rede é a rede de Hopfield (HAYKIN, 2004).

### 5.3.2 O treinamento das redes

A forma de treinamento diz respeito a como são atualizados os valores dos pesos sinápticos durante o aprendizado da rede. Nesse contexto, podemos descrever:

1. Redes com pesos fixos;
2. Redes com treinamento não-supervisionado;
3. Redes com treinamento supervisionado;
4. Redes com aprendizado por reforço.

Nas redes com pesos fixos, os pesos de alguns (ou de todos) neurônios são fixados em um dado valor, ou fixados ao peso (variável) de outro neurônio. Esse tipo de rede é tipicamente aplicado a soluções de problemas particulares e tem aplicação tradicionalmente ligada à invariância espacial. Considera-se, por exemplo, uma imagem de entrada que deva ser classificada por uma RNA independentemente de sua rotação sobre seu centro, pode ser adotada uma rede onde os pesos dos neurônios equidistantes do centro mantivessem um mesmo peso sináptico (HAYKIN, 2004).

Nas redes com treinamento não supervisionado não existe a apresentação de mapeamentos entrada-saída à rede; caberá exclusivamente a ela a tarefa de realizar a classificação, com base na informação de número de classes e topologia da rede (HAYKIN, 2004). É o caso das redes auto-organizadas de Kohonen.

Nas redes com treinamento supervisionado, tipicamente, uma seqüência de padrões de entrada associados a padrões de saída é apresentada à rede. Esta utiliza as comparações entre

a sua classificação para o padrão de entrada e a classificação correta dos exemplos para recalibrar seus pesos. Enquadram-se nesse contexto a maioria das redes utilizadas, como o *perceptron* multicamada (MLP) (HAYKIN, 2004).

O aprendizado por reforço refere-se à utilização de alguma função heurística, definida *a priori*, que descreva o quão boa é a resposta da rede a uma dada entrada, e da busca da maximização de tal função. Em outras palavras, não é fornecido à rede o mapeamento direto entrada-saída, mas sim, uma recompensa, ou penalização, decorrente da saída gerada pela rede à entrada apresentada. Tal reforço é utilizado na recalibração dos pesos da rede (HAYKIN, 2004).

## 5.4 O PERCEPTRON MULTICAMADA (MLP)

### 5.4.1 Introdução

O *perceptron* foi desenvolvido por Rosenblatt em 1962. Tratava-se de uma rede baseada no discriminador linear de McCulloch (1943), que utilizava o princípio do aprendizado de Hebb (1949) para aprender através de exemplos. Widrow (1962), simultaneamente a Rosenblatt, aprimorou um sistema de treinamento que fazia uso do erro quadrático, embora ainda o tenha aplicado a sistemas lineares. Rummelhart, Hinton e Williams (RUMMELHART et al, 1986), anos mais tarde, desenvolveram um princípio de aprendizado para redes com funções de ativação semilineares baseadas nas redes desenvolvidas por Widrow, que foi denominado *error backpropagation*, ou a retropropagação do erro, que propiciou a arquitetura e o treinamento do *Multilayer perceptron* (MLP) ou *perceptron* multicamada.

### 5.4.2 Arquitetura do MLP

O MLP é uma rede com a topologia apresentada na figura 5.5. Os MLPs podem ser entendidos como uma coleção de neurônios estruturalmente idênticos arranjados de maneira que a saída de cada neurônio em uma camada alimente a entrada de cada neurônio da camada seguinte. Os dados são apresentados no formato de vetores de padrões de entrada para a camada A, onde  $N_A$  representa o número de neurônios desta camada, frequentemente  $N_A = n$  que corresponde à dimensionalidade dos vetores padrões de entrada  $x$ . O número de neurônios da camada de saída (Q) é  $N_Q = m$ , o número de classes de padrões que a rede foi treinada para

reconhecer. A rede neural reconhece um vetor de padrões  $x$  como pertencente a classe  $\omega_m$  se a  $m$ -ésima saída da rede é “alta”, enquanto as outras são “baixas” (GONZALEZ & WOODS, 2003). A função de ativação do tipo pode ser do tipo “sigmóide”. No treinamento por retropropagação é requerida a diferenciabilidade ao longo de todos os caminhos da rede neural. As camadas estão dispostas de A a Q conforme a figura 5.5 sendo a camada A a *camada de entrada*, primeira camada da rede, Q a *camada de saída*, última camada da rede e *camadas ocultas*, todas as demais de B a P. A função de ativação sigmóide apresentada na equação (5.1) tem a requerida diferenciabilidade:

$$h_j(I_j) = \frac{1}{1 + \exp[-(I_j + \theta_j) / \theta_o]} \quad (5.1)$$

em que  $I_j$ ,  $j=1,2,\dots, N_j$ , representa a entrada do elemento de ativação de cada neurônio na camada J da rede  $\theta_j$  é uma compensação,  $\theta_o$  controla a forma da função sigmóide. A equação 5.1 fornece os limites de resposta para as respostas “alta” e “baixa” de cada neurônio. Para qualquer valor de  $I_j$  maior que  $\theta_j$  o sistema responde “alta” e para qualquer valor de  $I_j$  menor que  $\theta_j$  responde “baixa”. A função sigmóide é sempre positiva (0 a 1) ou 0.05 para “baixa” e 0.95 para “alta” (GONZALEZ&WOODS, 2003).

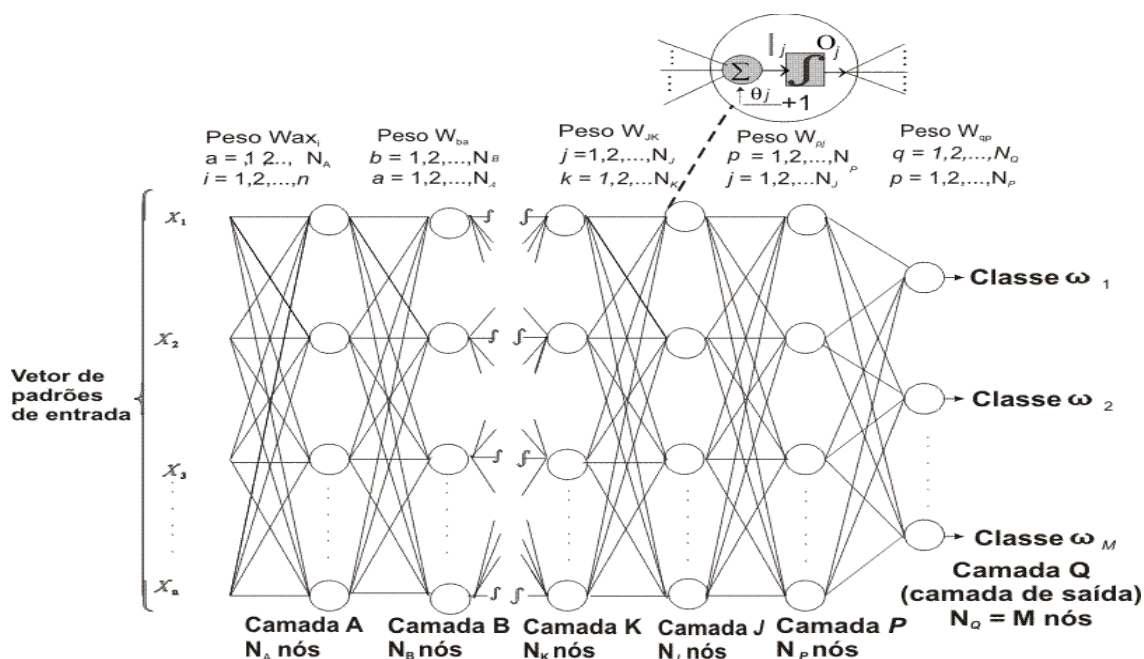


Figura 5.5 – A rede neural multicamada. O detalhe mostra a estrutura básica de cada neurônio. A compensação  $\theta_j$  é tratada como outro peso (GONZALEZ&WOODS, 2003).

### 5.4.3 Treinamento: a retropropagação do erro

Segundo Kovács (1996)"(...) a retropropagação do erro é o mais poderoso procedimento que se conhece até hoje para o treinamento de redes neurais". Uma vez que a retropropagação do erro foi uma generalização do trabalho de Widrow para funções de ativação não-lineares, e que este, por sua vez, foi uma evolução do trabalho de Hebb.

#### 5.4.3.1 O princípio de Hebb

Seja um discriminador linear que utiliza a função de ativação do tipo degrau unitário. Hebb propôs, em 1949, um princípio pelo qual o aprendizado de um sistema poderia ser reduzido a um processo puramente local, ou seja, a atualização de um peso sináptico é vista como uma função apenas das entradas daquela sinapse e da saída atual do neurônio.

Seja o sinal de erro sobre um neurônio  $N$  definido como:

$$e_N\{n\} = y_N^d\{n\} - y_N\{n\} \quad (5.2)$$

onde:  $e_N(n)$  é o sinal de erro na iteração  $n$ ;  
 $y_N^d(n)$  é a saída desejada do neurônio  $N$  na iteração  $n$ ;  
 $y_N(n)$  é a saída efetiva do neurônio  $N$  na iteração  $n$ .

O aprendizado do neurônio  $N$ , então, é dado por:

$$w_i[n+1] = w_i[n] + \Delta w_i \quad (5.3)$$

sendo:  $\Delta w_i(n+1) = \zeta \cdot e_N(n) \cdot x_i(n) \quad (5.4)$

onde:  $n$  é a iteração;  
 $w_i$  é o  $i$ -ésimo peso sináptico do neurônio  $N$ ;  
 $\zeta$  é uma constante que representa o passo do aprendizado;  
 $e_N(n)$  é o erro associado ao neurônio  $N$  na iteração  $n$ ;  
 $x_i$  é o valor do  $i$ -ésimo elemento do vetor de entrada do neurônio  $N$ .

A alteração do peso de uma sinapse de um neurônio fica condicionada apenas à proporção do erro do neurônio relativo à própria sinapse. Contudo, o equacionamento de Hebb apresenta alguns pontos de relevância:

- a) somente é válido para o discriminador linear (contínuo ou discreto);
- b) somente é válido para um único discriminador linear, visto que Roseblatt não conseguiu estender tal princípio para redes.

Assim, embora o equacionamento de Hebb tenha apresentado os princípios básicos do aprendizado, fazia-se necessária alguma ferramenta mais poderosa para o treinamento de redes de *perceptrons*.



### 5.4.3.2 A regra de Widrow

Seja um conjunto de M exemplos, de mapeamentos entrada-saída, apresentados a um neurônio N. Define-se o erro quadrático aplicado sobre tal conjunto como sendo:

$$E = \sum_{m=1}^M \{ y_m - y_m^d \}^2 \quad (5.5)$$

onde:  $\left\{ \begin{array}{l} E \text{ é o erro quadrático;} \\ y_m^d \text{ é a saída desejada para o exemplo } m; \\ y_m \text{ é a saída efetiva para o exemplo } m; \\ M \text{ é o número de exemplos.} \end{array} \right.$

O gráfico da função apresenta-se como uma curva convexa, que, portanto, possui um ponto de mínimo global (LUDWIG & MONTGOMERY, 2007). Utilizando-se tal equacionamento, o problema do aprendizado de redes pode ser reduzido a um problema de obtenção do ponto de mínimo da curva de erro quadrático (KOVÁCS, 2006). A obtenção deste ponto para um conjunto de mapeamentos passa a ser vista como a determinação de um conjunto ótimo de pesos W. Assim, é possível expressar a saída  $y_m$  da rede como a função:

$$y_m = f \{ w ; X \} \quad (5.6)$$

onde:  $\left\{ \begin{array}{l} y_m \text{ é a saída efetiva da rede para o exemplo } m; \\ W \text{ é um conjunto de pesos sinápticos para o neurônio } N; \\ X \text{ é a entrada para o exemplo } m; \\ f(.) \text{ é uma função linear de ativação do neurônio } N. \end{array} \right.$

Widrow mostrou (para a rede ADALINE) que, partindo de um ponto arbitrário, pode-se caminhar pela superfície da curva  $E(w)$  em direção ao ponto de mínimo global, atualizando o conjunto de pesos sinápticos constantemente. Este princípio, denominado "regra delta de Widrow" é dado por:

$$w_N(n+1) = w_N(n) - \zeta \frac{d}{dt} . E(w_N(n)) \quad (5.7)$$

onde:  $\left\{ \begin{array}{l} n \text{ é a iteração;} \\ w_N(n) \text{ é o conjunto de pesos sinápticos do neurônio } N \text{ na iteração } n; \\ \zeta \text{ é o passo que se dará na direção contrária ao gradiente;} \\ E(w_N(n)) \text{ é o erro quadrático em função dos pesos sinápticos do neurônio } N \text{ na iteração } n; \\ d./dt \text{ é a derivada do argumento com relação ao tempo.} \end{array} \right.$

Uma importante observação sobre a regra delta de Widrow é que esta permite generalização para múltiplos ADALINE, tornando possível treinar toda uma rede MADALINE. Contudo, tal regra não faz qualquer menção à utilização de funções de ativação diferentes das lineares, semilineares ou não-lineares, o que torna necessária a definição de uma nova ferramenta.

### 5.4.3.3 A retropropagação do erro

O algoritmo de aprendizado da retropropagação do erro corresponde à generalização do algoritmo de Widrow para funções de ativação semilineares. Dessa maneira, redefine-se o erro quadrático sobre um neurônio N como:

$$E(W) = \sum_{m=1}^M \{g(W \cdot X_m) - y_m^d\}^2 \quad (5.8)$$

onde:

- W é o vetor de pesos sinápticos para o neurônio N;
- E(w) é o erro quadrático em função dos pesos sinápticos;
- M é o número de exemplos;
- X<sub>m</sub> é o vetor de entrada para o neurônio N para o exemplo m;
- Y<sub>m</sub><sup>d</sup> é a saída desejada para o exemplo m;
- g(.) é a função de ativação semilinear.

É possível mostrar (KOVÁCS, 1996) que tal função de erro quadrático leva a uma atualização de pesos sinápticos para um neurônio N expressa por:

$$w_N(n+1) = w(n) - \zeta (y_m^d - y_m) \frac{dg(v)}{dv} \cdot x_i \quad (5.9)$$

onde:

- M é o número de exemplos;
- W(n) é o vetor de pesos sinápticos na iteração n;
- X<sub>m</sub> é o vetor de entradas do exemplo m fornecido ao neurônio N;
- y<sub>m</sub> é a saída para o exemplo m;
- y<sub>m</sub><sup>d</sup> é a saída desejada para o exemplo m;
- ζ é o passo de aprendizado;
- g(v) é a função de ativação semilinear do neurônio N.

A regra delta generalizada é aplicável a um neurônio isoladamente ou a um grupo de neurônios dispostos em camadas, como é o caso do Multilayer Perceptron (MLP) (KOVÁCS, 2006).

## 6 SISTEMA DE CLASSIFICAÇÃO DE TOMATES

O padrão brasileiro de classificação de tomates segundo o Centro de Qualidade em Horticultura (CEAGESP, 2006), conforme já apresentado anteriormente, propõe a classificação das frutas segundo dois aspectos distintos: cor e qualidade. O parâmetro qualidade é observado segundo a ocorrência de defeitos de ordem mecânica, patológica, presença e intensidade de manchas e podridão. Já pelo parâmetro cor varia em função do seu estágio de maturação, sendo ele classificado por este quesito em Vermelho, Rosado, Laranja e Amarelo. O amadurecimento do tomate determina a mudança de coloração da sua casca e caracteriza três subgrupos: I – Pintando; II – Colorido; III – Maduro.

Existem dois tipos de tomates vermelhos: um usado para saladas e culinária e outro para processamento industrial (CICA, KNORR 2006). Neste trabalho a seleção de tomates para processamento industrial (tomates da cor Vermelho) é feita por um sistema constituído de câmera tipo web-cam que é responsável por capturar a imagem e transmiti-la para o computador (figura 6.1). A resolução da câmera foi ajustada para 640x480pixels. Um programa foi desenvolvido em linguagem orientada a objeto, em Visual Basic<sup>®</sup> para capturar esta imagem e criar uma interface para o usuário.




Figura 6.1 Sistema com iluminação do objeto e câmera Webcam para aquisição de imagens

No processo de classificação de tomates, quando clicamos um botão o programa analisa a imagem, captura e efetua a filtragem usando filtro de Sobel. Na imagem filtrada um algoritmo detecta o contorno e conta o número de pixels na horizontal e na vertical. Estes

parâmetros são utilizados para determinar a classificação do tomate com base no seu formato, conforme ilustrado na Figura 2.4.

A Figura 6.2 ilustra a tela de inicialização do programa desenvolvido onde pode ser selecionada a câmera (webcam) que será utilizada. A captura da imagem pode ser efetuada diretamente de uma câmera ou de um arquivo (figura 6.3).




Figura 6.2 – Tela de entrada – Seleção de câmera

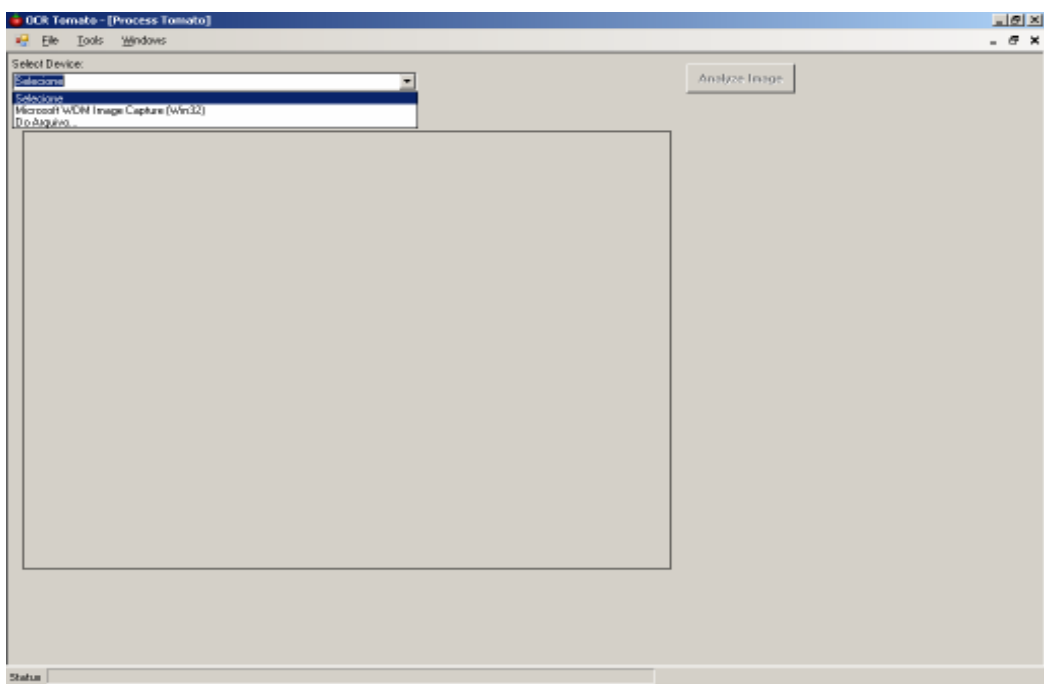


Figura 6.3 – Seleção de câmera ou arquivo

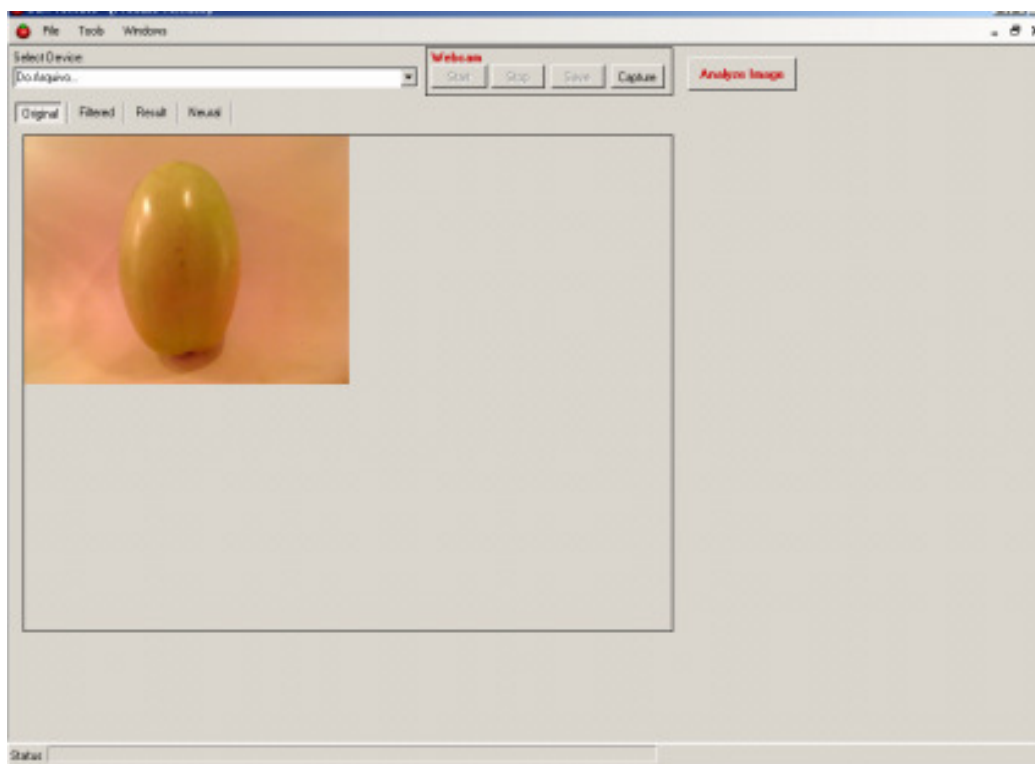


Figura 6.4 – Imagem capturada pela câmera

Após carregar uma imagem (Figura 6.4), clicando no botão “Analyze Image” o algoritmo efetua a análise da imagem até a sua conclusão conforme Figura 6.5.

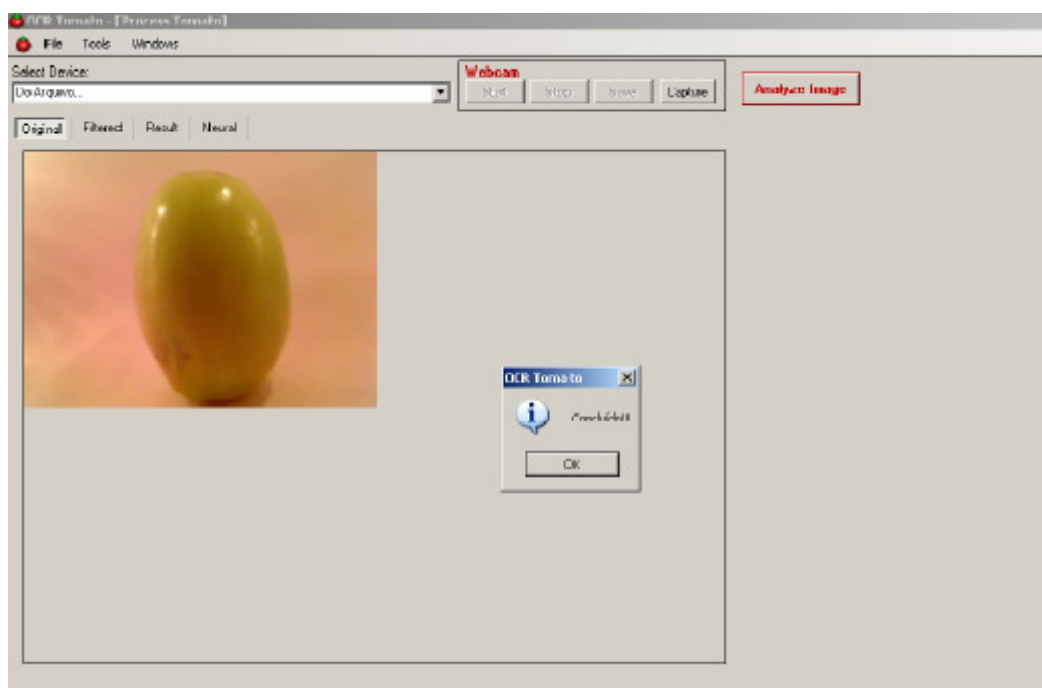


Figura 6.5 – Imagem capturada e conclusão da análise

Clicando no atalho “Filtered” mostra-se o resultado da imagem filtrada por filtro de Sobel (figura 6.6). Clicando em “Result” o algoritmo mostra o resultado da análise da imagem, como ilustrado na figura 6.7.



Figura 6.6 – Visualização de imagem filtrada

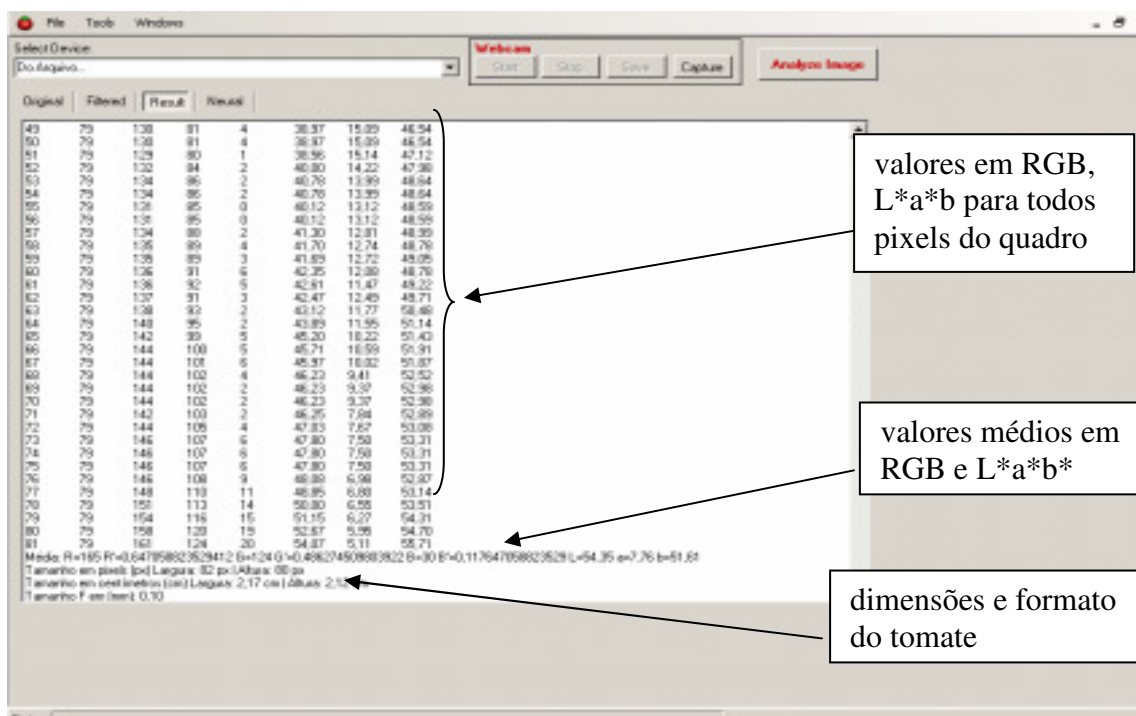


Figura 6.7 – Resultados da análise da imagem (Cor e Dimensões)

No exemplo ilustrado acima, há o tomate e o fundo da imagem. Na abordagem desenvolvida o programa é capaz de detectar o contorno do tomate e as suas dimensões pela aplicação do filtro Sobel e com base nos valores obtidos determinar a sua classificação por formato. A partir das informações obtidas pela filtragem, eliminam-se as linhas que contenham a informação do fundo da imagem que é da cor branco representado por: R(255), G(255), B(255); isto garante que, ao retornar à imagem colorida, o programa seja capaz de reduzi-la para limitar a região de medição dos valores de RGB para cada pixels, de forma a garantir que as medições vão incluir apenas pontos reais do tomate. A imagem cortada não é mostrada no programa.

Nos resultados finais da tabela obtida e mostrada na figura 6.7 contém os valores de cada pixel para RGB,  $L^*a^*b^*$ , na segunda linha o tamanho em pixels (Largura e Altura), na terceira linha os mesmos valores convertidos em cm, na última o formato do tomate conforme a norma do CEAGESP, definindo-se o seu grupo.

No exemplo ilustrado acima, há o tomate e o fundo da imagem. Na abordagem desenvolvida o programa é capaz de detectar o contorno do tomate e as suas dimensões e com base nos valores obtidos determinar a sua classificação. A partir das informações obtidas pela filtragem elimina-se as linhas que contenham a informação do fundo da imagem que é da cor branco representada por: R(255), G(255), B(255); isto garante que, ao retornar à imagem colorida, o programa seja capaz de reduzi-la para limitar a região de medição dos valores de RGB para cada pixels, de forma a garantir que as medições vão incluir apenas pontos reais do tomate. A imagem cortada não é mostrada no programa.

A partir dos valores médios de RGB obtêm-se também os correspondentes em  $L^*a^*b^*$ . Os valores de RGB médios obtidos são enviados para um classificador formado por uma rede neural artificial. A rede neural usada é uma MLP desenvolvida em Visual Basic<sup>®</sup>, mas treinada em MATLAB<sup>®</sup> utilizando a função *nntool*. A rede apresenta 3 entradas (R, G e B), uma camada escondida com 4 neurônios, e uma camada de saída com 3 neurônios. As saídas utilizadas são P (Pintando), C (Colorido) e M(Maduro). O algoritmo baseado em rede neural define, pelo máximo valor obtido nas saídas, qual a classificação para o tomate. A figura 6.8 mostra o desenvolvimento do algoritmo usando a rede neural no Visual Basic<sup>®</sup>. Na tela apresentam-se os valores utilizados para os *bias(viés)* e pesos sinápticos conforme resultados obtidos no treinamento. A letra P (“Pintando”) é o resultado da classificação da rede neural para o exemplo utilizado.

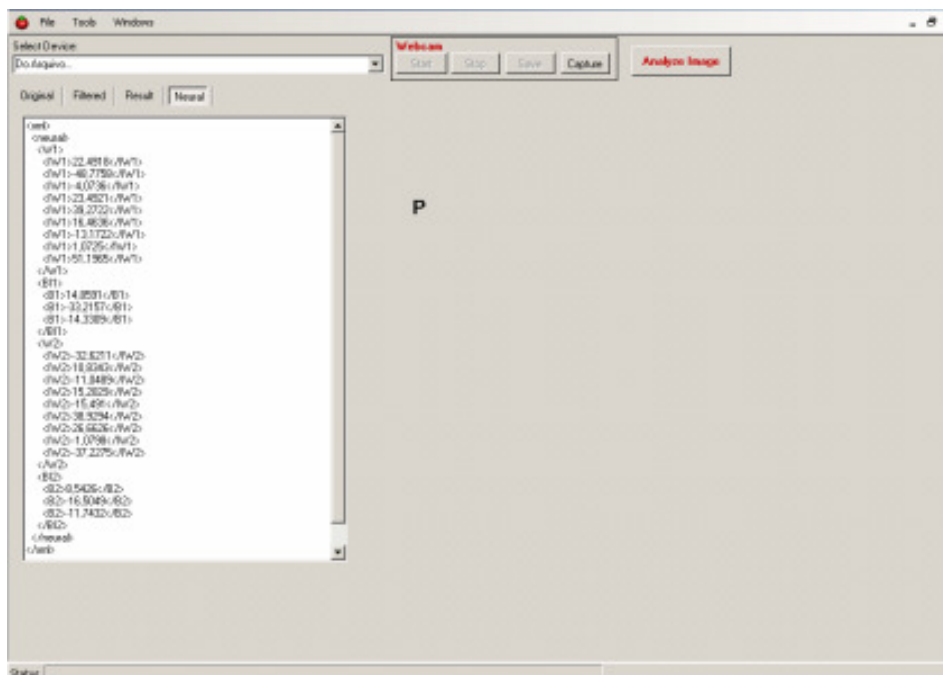


Figura 6.8 – Resultados da classificação da neural (Exemplar “Pintando” (P))

Um resumo da metodologia desenvolvida neste trabalho é apresentado na figura 6.9.

## 6.1 ANÁLISE DAS MEDIÇÕES EM RGB

Para se comprovar que a média do total dos pixels R,G e B da imagem completa é suficiente para representar o objeto da imagem, o tomate, tomaram-se três exemplares de cada categoria de tomate, um pintando, um colorido, um maduro e destes valores obtidos foram feitas contagens de quantos números pertenciam a condições tais como o exemplo mostrado na Tabela 6.1. Outros exemplares de cada tipo foram utilizados e todos estavam na range de porcentagem indicada na tabela 6.1, por isso, a demonstração destes três exemplares mostrou-se suficiente.

Tabela 6.1 - Representação da utilização da contagem $nc(x)R$ .		
Resultado do número de contagem (nc) da participação de R nas faixas e suas porcentagens do Exemplar Pintando		
$nc_j(x)$ ( representa o número de amostras x em que a condição j é atendida)	Condição/Valor de R ( $nc(x)_R < \text{valor de R}$ )	Porcentagem
0	$R \leq 100$	0%
7073	$100 \leq R \leq 150$	30,7%
15242	$150 \leq R \leq 200$	66,3%
665	$200 \leq R \leq 255$	3%
22980	$100 \leq R \leq 255$	100%



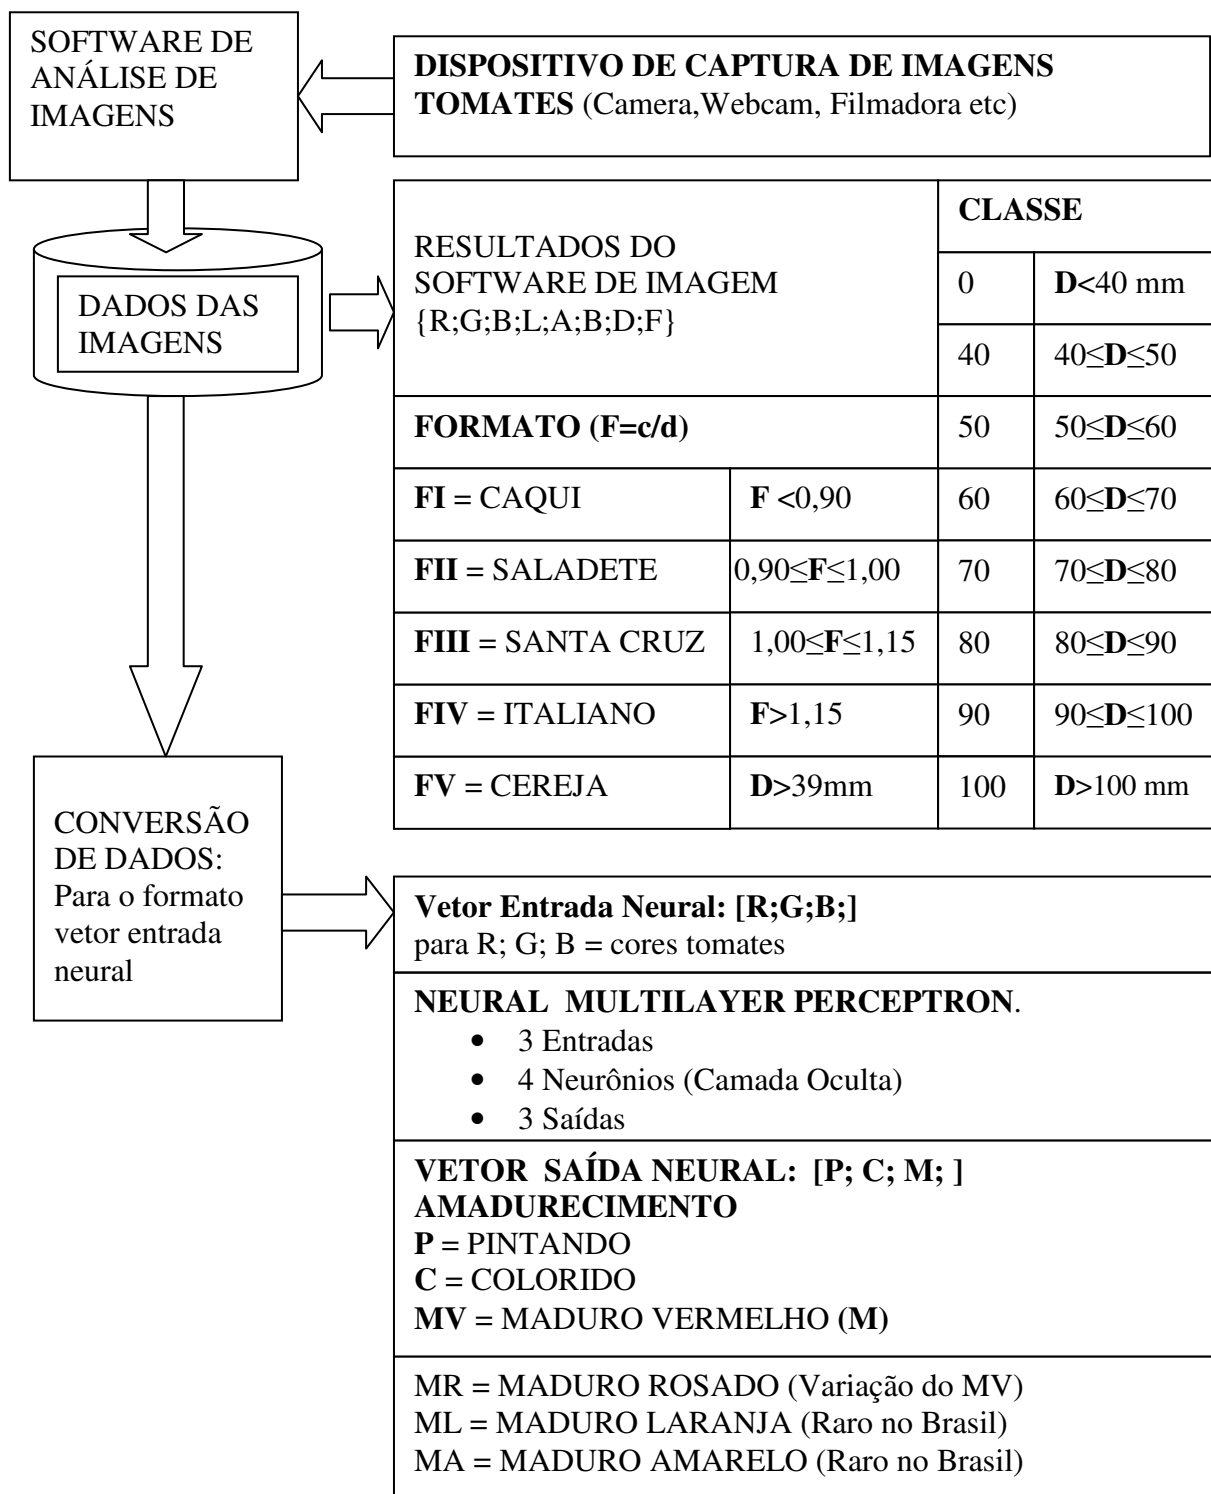


Figura 6.9 Layout geral do classificador de tomates

A utilização da contagem  $nc(x)_R$  para os exemplares Pintando, Colorido e Maduro, conforme as faixas de:  $nc(x)_R \leq 100$ ;  $100 \leq nc(x)_R \leq 150$ ;  $150 \leq nc(x)_R \leq 200$  e  $200 \leq nc(x)_R \leq 255$  mostradas na segunda coluna (R) da tabela 6.1. O procedimento é repetido para as colunas de G e B, obtendo assim a porcentagem da participação dos números nas faixas de  $nc(x)_j$  para  $j = R, G$  e  $B$ . Neste caso foram obtidos os resultados demonstrados nas tabelas do Apêndice A2 e por meio dos gráficos mostrados respectivamente nas figuras 6.10, 6.11 e 6.12 que apresentam os gráficos com as variações dos parâmetros RGB nos 50 pixels selecionados aleatoriamente das três amostras estudadas. Os gráficos apresentam uma grande variação dos valores destes parâmetros. Porém, quando o valor R é alto, os valores G e B tendem a acompanhá-lo, da mesma forma quando o R é baixo, G e B também o serão.

Analisando-se os gráficos e os dados dos exemplares Pintando, Colorido e Maduro apresentados no Apêndice A2, pode-se elaborar uma tabela de parâmetros RGB para cada classificação de tomate para as imagens coletadas (tabela 6.2):

Tabela 6.2 – Parâmetros RGB dos exemplares: Pintando, Colorido e Maduro			
Exemplar	Parâmetros RGB		
	R-G	G-B	B-R
Pintando			
$R^2$	0.8516	0.790	0.902
Colorido			
$R^2$	0.7227	0.4775	0.4472
Maduro			
$R^2$	0.9553	0.4226	0.9553

Este fenômeno dos parâmetros indica que a proporção relativa entre R, G e B é relativamente constante, apesar da grande variação nos valores absolutos. De fato, o índice de correlação da interpolação linear  $R^2$  entre R-G, G-B e B-R das amostras analisadas é alto, o que indica boa correlação linear conforme tabela 6.2. Portanto, a média dos valores obtidos após o tratamento da imagem está dentro da faixa de valores que apresentam maior porcentagem de  $nc(x)_j$ , o que comprova que a média representa o objeto em análise e poderá ser utilizada como dado de entrada da rede neural.

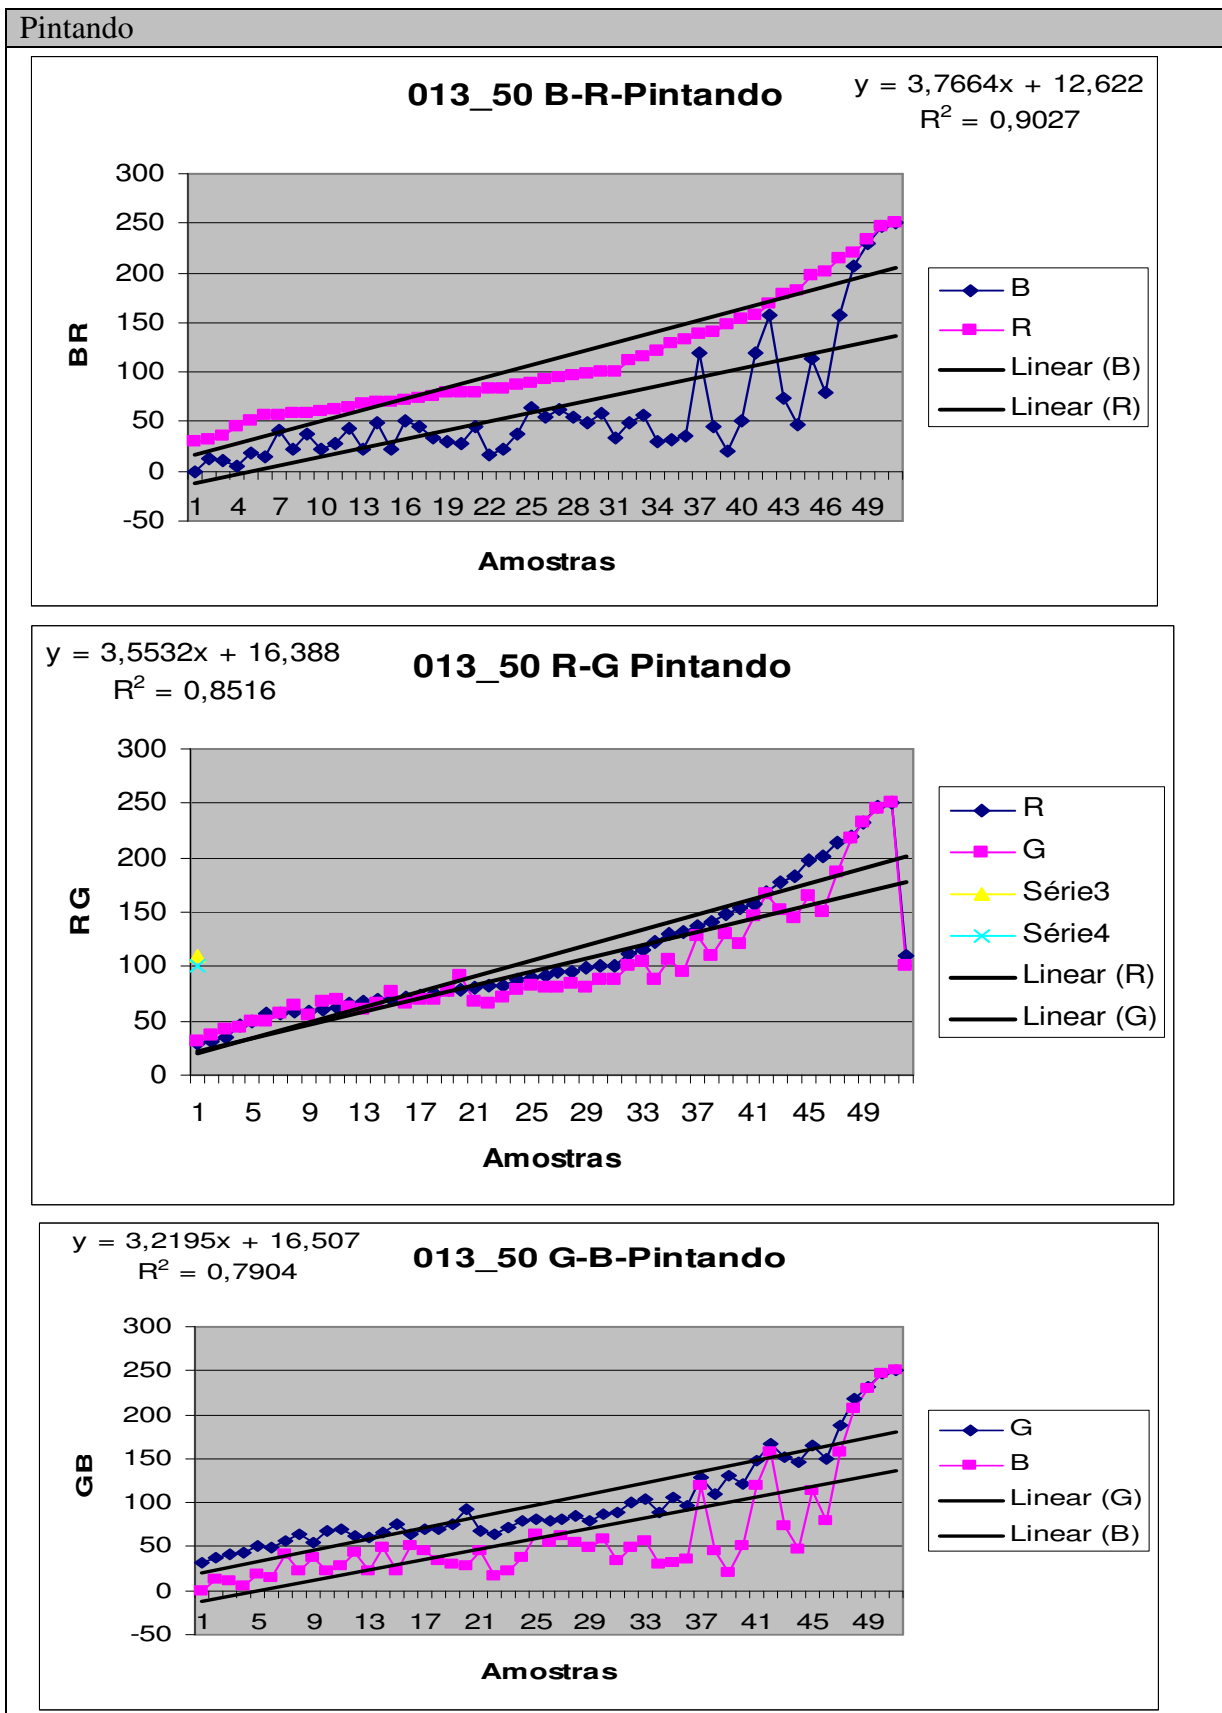


Figura 6.10 - Gráficos de 50 pixels do exemplar Pintando: (a) R-G;(b) G-B;(c) B-R.




Figura 6.11 - Gráficos de 50 pixels do exemplar Colorido: (a) R-G;(b) G-B;(c) B-R.

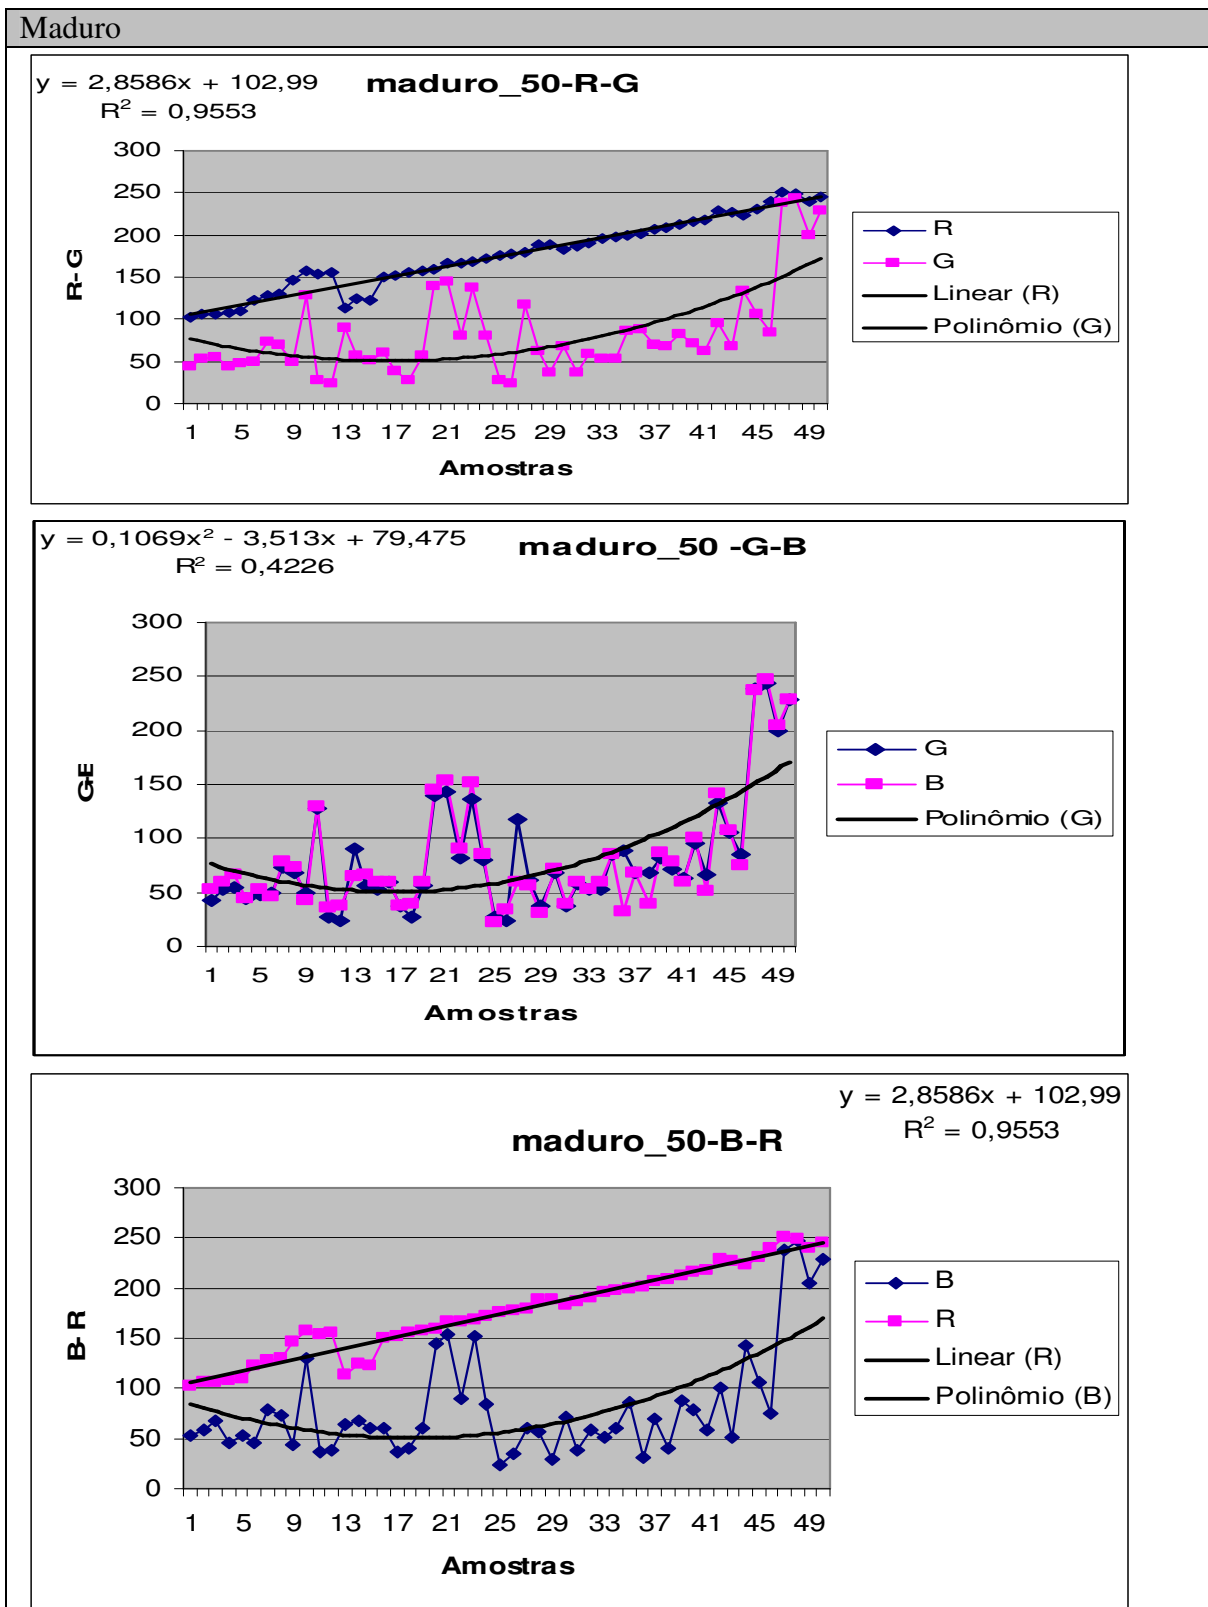


Figura 6.12 - Gráficos de 50 pixels do exemplar Maduro: (a) R-G;(b) G-B;(c) B-R.

## 6.2 TREINAMENTO E OBTENÇÃO DE RESULTADOS NA REDE

Conforme demonstrado anteriormente utilizando os passos demonstrados nas figuras 6.2 a 6.8 é possível obter a classificação por formato e por coloração. A rede neural utilizada é a MLP-*Multilayer Perceptron* que tem três entradas: R;G;B ou L, a, b, uma camada oculta com quatro neurônios e três saídas: P(“Pintando”), C(“Colorido”), M(“Maduro”) que apresentam a classificação do tomate como detalhado na figura 6.13. A escolha para quatro neurônios na camada oculta é devida aos resultados obtidos, foram feitos testes para cinco e dez neurônios e os resultados ficavam muito apurados e exibiam pequenas mudanças na variação dos valores dos dados apresentados.

As funções de ativação utilizadas, definidas após vários testes com funções tangente hiperbólica e sigmóide, foram as funções sigmóides que apresentaram melhores resultados. Assim, a partir da estrutura apresentada na figura 6.13, podemos montar o seguinte algoritmo para a rede neural, onde:  $n_j(i)$  indica a saída do neurônio (i) da camada (j) respectivamente para os quatro neurônios da camada oculta ( $j=1$  e  $i = 1, 2, 3$  e  $4$ ) e  $n_k(i)$  indica a saída do neurônio (k) da camada (j) respectivamente para os os três neurônios da saída ( $j=2$  e  $k = 1, 2$  e  $3$ ), antes da função de ativação;  $nb_j(i)$  e  $nb_j(k)$  indicam a saídas dos mesmos neurônios (i e k) nas camadas (j) após a função de ativação sigmoidal;  $E(m)$  indicam as entradas da rede ( $m=1, 2, 3$  e  $4$ ); os termos  $b_1(i)$  e  $b_2(k)$  indicam os *bias* (viés) dos neurônios e os parâmetros  $IW_1(i,m)$  e  $IW_2(k,i)$  indicam os pesos sinápticos para os neurônios (i) e (k) das camadas 1 e 2 respectivamente.

$$\begin{aligned} n_1(1) &= b_1(1) + IW_1(1,1)*E(1) + IW_1(1,2)*E(2) + IW_1(1,3)*E(3) \\ n_1(2) &= b_1(2) + IW_1(2,1)*E(1) + IW_1(2,2)*E(2) + IW_1(2,3)*E(3) \\ n_1(3) &= b_1(3) + IW_1(3,1)*E(1) + IW_1(3,2)*E(2) + IW_1(3,3)*E(3) \\ n_1(4) &= b_1(4) + IW_1(4,1)*E(1) + IW_1(4,2)*E(2) + IW_1(4,3)*E(3) \end{aligned} \quad (6.1)$$

$$\begin{aligned} nb_1(1) &= 1/(1+\exp(-n_1(1))) \\ nb_1(2) &= 1/(1+\exp(-n_1(2))) \\ nb_1(3) &= 1/(1+\exp(-n_1(3))) \\ nb_1(4) &= 1/(1+\exp(-n_1(4))) \end{aligned} \quad (6.2)$$

$$\begin{aligned} n_2(1) &= b_2(1) + IW_2(1,1)*nb_1(1) + IW_2(1,2)*nb_1(2) + IW_2(1,3)*nb_1(3) + IW_2(1,4)*nb_1(4) \\ n_2(2) &= b_2(2) + IW_2(2,1)*nb_1(1) + IW_2(2,2)*nb_1(2) + IW_2(2,3)*nb_1(3) + IW_2(2,4)*nb_1(4) \\ n_2(3) &= b_2(3) + IW_2(3,1)*nb_1(1) + IW_2(3,2)*nb_1(2) + IW_2(3,3)*nb_1(3) + IW_2(3,4)*nb_1(4) \end{aligned} \quad (6.3)$$

Os valores das saídas de cada neurônio podem ser obtidos pelos seguintes cálculos:

$$\begin{aligned}
 S1 &= 1/(1+\exp(-n2(1))) \\
 S2 &= 1/(1+\exp(-n2(2))) \\
 S3 &= 1/(1+\exp(-n2(3)))
 \end{aligned}
 \tag{6.4}$$

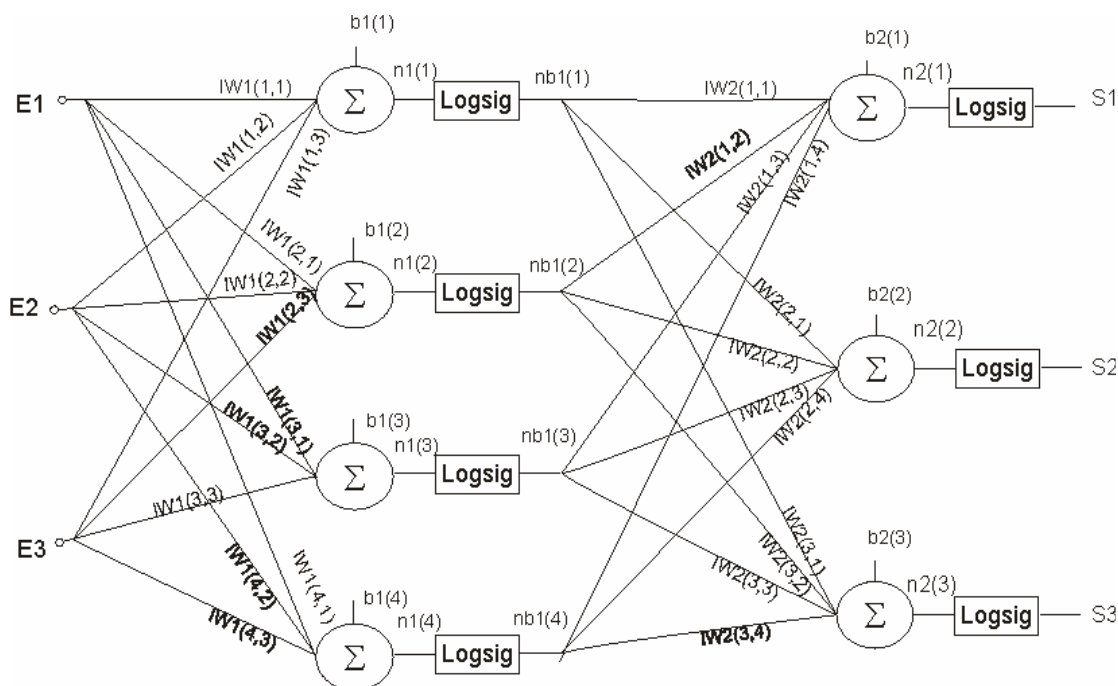


Figura 6.13 – Rede neural MLP desenvolvida

A necessidade da utilização da rede neural está ligada à variação de luminosidade no ambiente de captura da imagem, pois, o reconhecimento do tomate pela rede neural independe desta variação de luminosidade. Em um ambiente industrial a luminosidade típica é da ordem 500 a 1000lux, faixa que será utilizada neste trabalho, conforme normas da ABNT citadas em (GARCIA, 2002).

Para fazer o treinamento da rede foram utilizados dados de RGB de 180 tomates, sendo 30 Tomates “Pintando” a 500 lux, 30 Tomates “Pintando” a 1000 lux, 30 Tomates “Colorido”s a 500 lux, 30 Tomates “Coloridos” 1000 lux, 30 Tomates “Maduros” a 500 lux e finalmente 30 Tomates “Maduros” a 1000 lux. O vetor de dados de entrada, os *targets* adotados para as saídas da rede neural e os termos utilizados são apresentados no Apêndice A3.

No treinamento da rede construída em MATLAB<sup>®</sup> (figura 6.14) foram utilizados os seguintes parâmetros de configuração: steps = 1000; mu = 0.001; mu-dec = 0,1; mu-inc = 10; mu-max = 1000000000; show = 25; time = infinito. No treinamento a rede apresentou excelente convergência com erro quadrático de 0.0622581 após 10000 épocas, portanto com

erro tendendo para zero. O treinamento gerou o gráfico da figura 6.15 que exibe a resposta do desempenho da rede, mostrando que o erro MSE (Erro Médio Quadrático) diminui fortemente durante imediatamente após as primeiras 23 épocas, mas sendo o treinamento interrompido a partir deste ponto para evitar *overtraining*.

Os resultados após o treinamento com a rede obtida são o vetor com pesos neurais (pesos sinápticos) e polarizações *bias* conforme apresentado abaixo, que foram usados no programa desenvolvido em Visual Basic® para classificar os tomates.

$IW1(i,m)=[-96.6786 \ -121.8544 \ 253.5232; \ 152.77 \ -639.1494 \ 598.7545; \ -155.6476 \ -97.7333 \ 193.0715; \ -67.0508 \ -131.0674 \ 183.0207];$

$IW2(k,i)=[2353.4422 \ -224.842 \ 158.9038 \ -2503.6931; \ -5.0008 \ 178.673 \ 339.0306 \ 8.1298; \ -7212.3037 \ 41.6834 \ -558.0864 \ 7206.8051];$

$b1(i)=[61.8043; \ -1.9784; \ 71.2827; \ 50.5857]$

$b2(k)=[216.7093; \ -181.802; \ -35.706]$

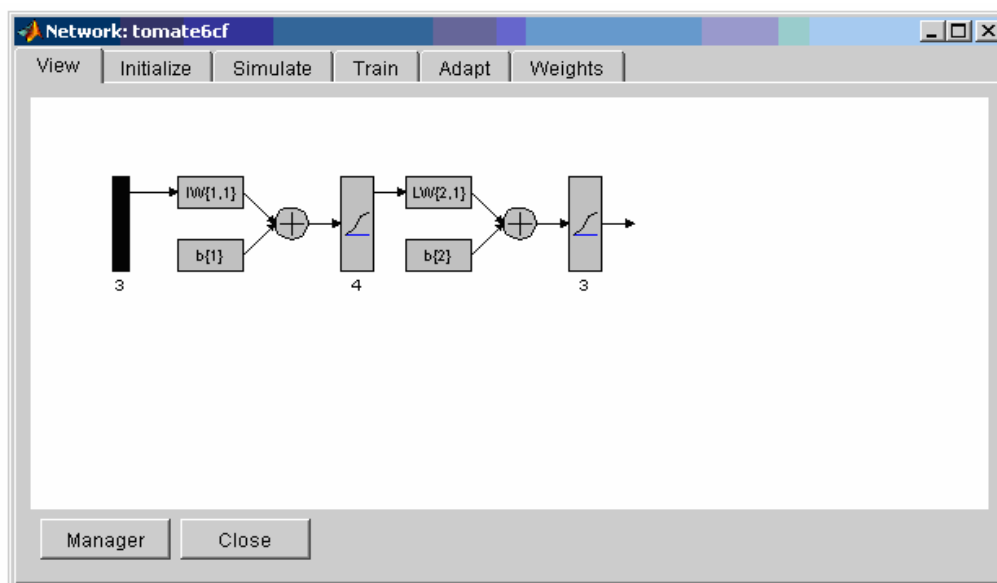


Figura 6.14- Construção da rede no MATLAB®






Figura 6.15 – Desempenho da rede após treinamento

Para treinar a rede foram utilizadas as entradas (6.5) na rede no MATLAB® em seu módulo *nnTool* e as saídas resultantes do treinamento são apresentadas no Apêndice A3 – Resultados do treinamento da rede neural. As figuras 6.16 a 6.21 mostram graficamente os resultados do treinamento. Os valores numéricos correspondentes estão no Apêndice A3.




Figura 6.16 – Resultados obtidos pela rede neural para 30 Tomates “Pintando” – 500 lux




Figura 6.17 – Resultados obtidos pela rede neural para 30 Tomates “Pintando” – 1000 lux

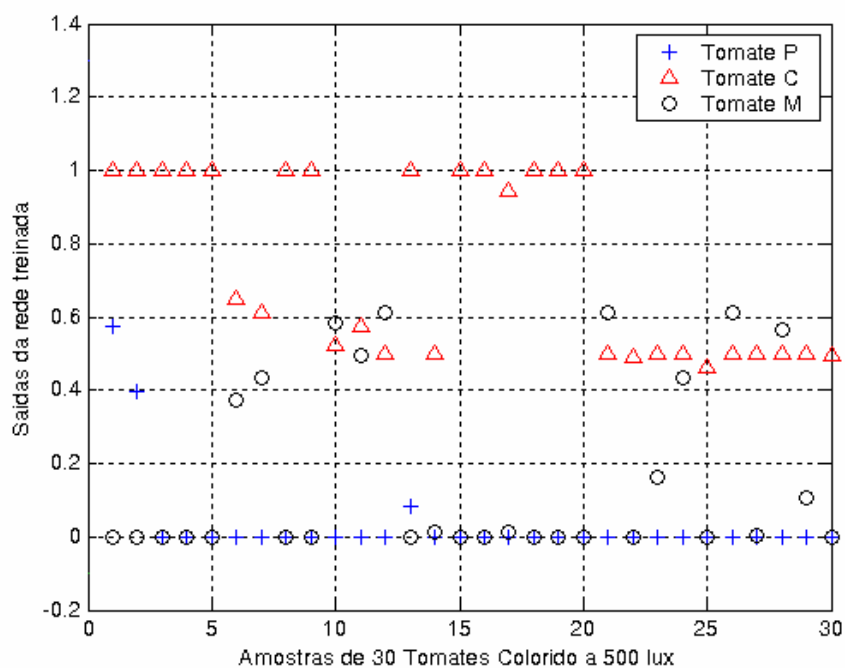


Figura 6.18 – Resultados obtidos pela rede neural para 30 Tomates “Coloridos” – 500 lux




Figura 6.19 – Resultados obtidos pela rede neural para 30 Tomates “Coloridos” – 1000 lux




Figura 6.20 – Resultados obtidos pela rede neural para 30 Tomates “Maduros” – 500 lux




Figura 6.21 – Resultados obtidos pela rede neural para 30 Tomates “Maduros” – 1000 lux

Os resultados obtidos no treinamento da rede para tomates “Pintando” (figuras 6.16 e 6.17) apresentaram-se com grande precisão, mostrando a eficiência da rede no reconhecimento desta coloração. Observa-se que, das 60 amostras analisadas, metade a 500

lux e a outra metade em 1000 lux, somente em 02 das amostras obteve-se valor para a saída S1 menor que 0,97. Ainda assim, em todos estes casos, os valores obtidos para a saída S1 eram muito maiores que os obtidos nas outras saídas, mostrando um índice de acerto de 100% na classificação.

Os resultados obtidos no treinamento da rede para tomates “Colorido” (figuras 6.18 e 6.19) não apresentaram a mesma precisão. Observou-se que das 60 amostras analisadas, também metade a 500 lux e a outra metade em 1000 lux, em 21 das amostras houve dificuldade no reconhecimento pois os resultados obtidos para as saídas S2 e S3 apresentaram resultados próximos (diferença entre eles menor que 0,2). Das 21 amostras que apresentaram valores próximos para S2 e S3, em 7 delas o máximo valor corresponde a S2, o que indica tomate “Colorido”. Percentualmente, estes resultados indicam um índice de acerto de 76,6%, mostrando uma precisão relativamente baixa na rede.

Os resultados obtidos no treinamento para tomates “Maduros” (figuras 6.20 e 6.21) mostram que das 60 amostras analisadas em 54 delas o máximo valor corresponde a S3, o que indica tomate “Maduro”. Percentualmente, isto equivale a um índice de acerto de 90,0%.

Analisando os resultados, de forma geral, podemos concluir que a rede apresenta dificuldade para identificar o tomate “Colorido” principalmente quando a coloração dos pixels do tomate está muito próxima de 90% da coloração final, ou seja, conforme ilustrado na figura 2.6, o tomate apesar de classificado com do grupo II (“Colorido”) tem uma coloração muito próxima à do grupo III (“maduro”). É importante salientar que esta dificuldade de identificação da seleção correta ocorre até mesmo na classificação pelos humanos; e por isto pode-se afirmar que a maioria dos erros obtidos na classificação automática podem também ocorrer caso a classificação fosse efetuada manualmente por humanos.

Dando continuidade ao processo de avaliação do desempenho da rede após o treinamento foram utilizadas imagens de tomates diferentes daquelas utilizadas no treinamento da rede. As novas entradas utilizadas correspondem a valores RGB para 30 imagens capturadas a 1000 lux, sendo 10 imagens de cada exemplar. Os valores obtidos no processamento de imagem e utilizados nas entradas da rede e os resultados obtidos pela rede com a aplicação das novas entradas são mostrados no Apêndice A3. Estes resultados são mostrados graficamente nas figuras 6.22 a 6.24.

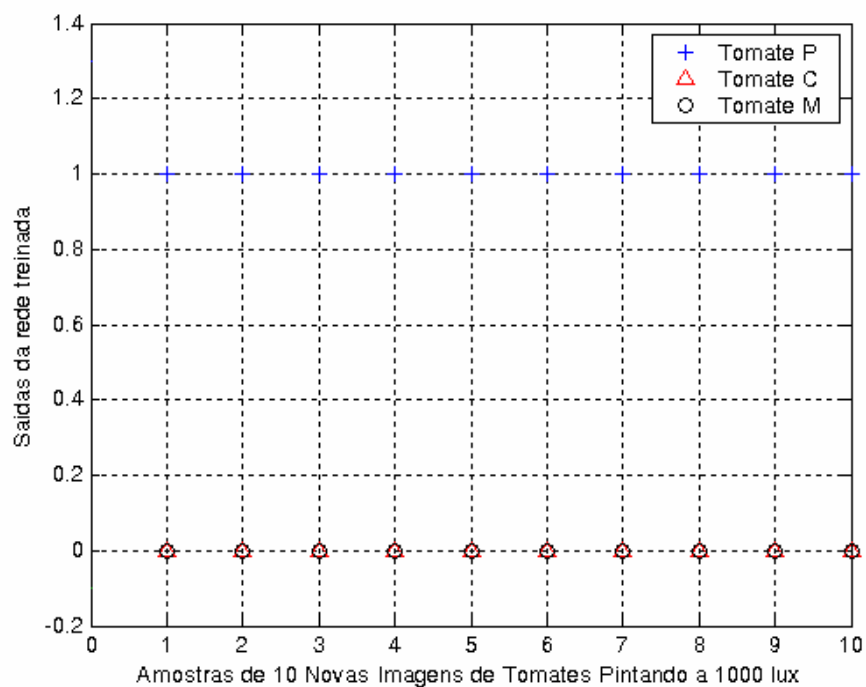


Figura 6.22 – Resultados obtidos pela rede neural para 10 Novas Imagens de Tomates “Pintando” – 1000 lux




Figura 6.23 – Resultados obtidos pela rede neural para 10 Novas Imagens de Tomates “Coloridos” – 1000 lux




Figura 6.24 – Resultados obtidos pela rede neural para 30 Novas Imagens de Tomates “Maduros” – 1000 lux

Analisando os resultados mostra-se que o índice de acertos para tomates “Pintando” foi de 100%, para tomates “Coloridos” de 90% e para tomates “Maduros” foi de apenas 60%. Novamente mostra-se a dificuldade para identificar tomates “Coloridos” ou “Maduros” cujo grau de coloração esteja próximo da região limitante, próxima de 90% da coloração final.

O Apêndice 3 mostra um resumo da tabela dos resultados apresentados que foram obtidos no treinamento e na simulação em MATLAB<sup>®</sup>.

Para finalizar, foram efetuados testes com o sistema prático desenvolvido de forma a verificar a eficiência da solução proposta para classificação de tomates. Para isto foram avaliadas amostras de 30 tomates “Pintando”, 30 tomates “Coloridos” e 30 tomates “Maduro”. Os resultados obtidos, apresentados na figuras 6.25 a 6.27 mostram a eficiência da proposta desenvolvida. Observa-se que houve um índice de acerto de 96,6% para “Pintando”, 93,3 % para tomates “Coloridos” e 100% para tomates “Maduro”. Os excelentes resultados obtidos, inclusive melhores que os obtidos por simulação, são resultados de um cuidadoso ajuste de posicionamento da câmera e luminosidade para obter a imagem com melhor precisão.




Figura 6.25 – Resultados obtidos no sistema prático para 10 imagens de Tomates “Pintando” – 700 lux




Figura 6.26 – Resultados obtidos no sistema prático para 10 imagens de Tomates “Coloridos” – 700 lux






Figura 6.27 – Resultados obtidos no sistema prático para 10 imagens de Tomates “Maduros” – 700 lux

Em relação ao processamento de imagem utilizando filtro de Sobel para determinação das dimensões do tomate, a abordagem apresenta boa precisão na classificação obtendo com relativa eficiência a classificação nas categorias I (Caqui), II (Italiano), III(Saladete), IV (Santa Cruz) e V (Cereja). Tomando-se dois exemplares de cada categoria, o índice de acerto foi de 70%. Os erros na classificação do tomate pelas dimensões ocorreram principalmente devido à presença de sombra na imagem captada pelo sistema. Isto pode ser observado, por exemplo, nos resultados apresentados na Figura 6.28 que mostra as imagens de um tomate Santa Cruz, obtidas pelo sistema de classificação, com e sem filtro de Sobel, e onde o tomate foi classificado Saladete devido à incorreta medição do diâmetro equatorial obtido a partir da sombra na base do tomate.




Figura 6.28 – Exemplo de imagens de um tomate Santa Cruz com e sem filtro de Sobel

Podemos concluir que, analisando os resultados obtidos, o sistema desenvolvido apresenta uma ótima solução para a automação do processo de classificação de tomates por forma e coloração, podendo obter-se resultados com relativa precisão.

## 7 CONCLUSÕES E COMENTÁRIOS FINAIS

A presente dissertação apresentou uma metodologia de seleção de tomates por meio do processamento de imagem e redes neurais, aplicou-se técnicas de segmentação de imagens coloridas por meio da segmentação de imagens baseada no atributo da cor dos pixels, além da filtragem por filtro de Sobel. O problema a ser tratado diz respeito à obtenção de uma classificação por coloração e formato tão próxima à humana quanto possível. Busca-se uma solução robusta à variação da luminosidade (ou o brilho da cor) e apresente também o tamanho do tomate e a sua classificação conforme a norma de classificação do CEAGESP. Tal problemática é encontrada em diversas situações práticas que sofram as influências do ambiente, tal como no processamento industrial do tomate que é o objeto deste trabalho e para resolver o problema de classificação por coloração apresentou-se um classificador que aplica redes neurais artificiais.

O sistema de classificação é formado por: uma câmera do tipo *webcam* que transmite a imagem para o computador e um programa desenvolvido especialmente para esta finalidade em linguagem orientada a objetos. No programa a imagem é capturada e uma varredura neste quadro produz os dados de cores RGB dos pixels. No passo seguinte estes dados são tratados, convertidos para o padrão CIE  $L^* a^* b^*$  e enviados para um classificador formado por rede neural artificial. A rede neural utilizada é a MLP-*Multilayer Perceptron* que tem três entradas: R;G;B ou  $L^*, a^*, b^*$ , uma camada oculta de neurônios e três saídas S1, S2 e S3, identificando respectivamente as classificações P(pintado), C(colorido) e M(Maduro).

Aplicando-se este sistema de classificação com a simulação de um ambiente industrial por meio de variações de luminosidade, observa-se que a rede neural apresenta um bom rendimento e bom índice de acerto, que se assemelha ao que poderia ser obtido na classificação manual e por inspeção visual humana. Adicionalmente a abordagem é relativamente simples, utilizando-se de componentes de baixo custo, que não excede US\$ 1000,00, viabilizando a sua utilização no desenvolvimento da aplicação.

O sistema leva menos que 2s para executar a análise completa de um tomate. Pensando numa aplicação industrial, a classificação poderia ser feita com os tomates enfileirados passando em uma esteira. Desta maneira o sistema poderia selecionar 30 tomates/minuto.

Mas, para isto acontecer seria necessário aplicar outras técnicas de segmentação e análise de imagens que não foram utilizadas neste sistema.

Melhorias na solução desenvolvida são muito bem-vindas podendo ocorrer por meio de outros trabalhos de continuidade, onde os principais aspectos que podem ser avaliados são:

- integração entre software e hardware de forma a permitir que os processos de captura de imagem, classificação do tomate e controle de dispositivos para fazer a triagem dos tomates, possam ser executados de forma totalmente automatizada;
- melhorar a estabilidade do filtro de imagens, para garantir uma melhor precisão na seleção do tomate por forma, mesmo quando há presença de sombras na imagem;
- avaliar outros tipos e configurações de redes visando melhorar a eficiência do sistema;
- aprimorar o sistema permitindo selecionar o tomate não somente pela cor e tamanho, mas também detectar defeitos no fruto de forma que aqueles muito danificados possam ser automaticamente descartados;
- avaliar a utilização em outros tipos de aplicações onde os conceitos de processamento de imagem possam ser vantajosos.

## 8 REFERÊNCIAS BIBLIOGRÁFICAS

- ANDERSON, J.A. *An introduction to Neural Networks*. London: The MIT Press, 1995.
- ANON. *United States Standards for Grade Evaluation of Tomatoes for Processing*. In Code of Federal Regulations, Title 7, Sections 51.3310-51.3327. The Office of the Federal Register, National Archives and Records, Washington, DC, 1993.
- BALLARD, D.; BROWN, C.; **Computer Vision**. New York: Prentice Hall, 1982.
- BARNARD, E.; CASANET, D.; **Invariance and neural nets**. IEEE Transactions on neural networks Vol.2, n.5, September, 1991.
- BLUM, A. *Neural networks in C++; an object framework for building connections systems*. New York: John Wiley & Sons, Inc., 1992.
- BO Li, HUOSHENG Hu, LIBOR Spacek. **An adaptive color segmentation algorithm for Sony lagged robots**. Proceedings of the 21<sup>st</sup> IASTED INTERNATIONAL CONFERENCE APPLIEDS INFORMATICS. February 10-13, 2003, Innsbruck, Austria.
- BRAGA, A. PÁDUA, CARVALHO, A.C.P. DE LEON, LUDERMIR, T.B. **Redes Neurais Artificiais – Teoria e Aplicações**. 2ed. Rio de Janeiro: LTC, 2007
- BUFFA, J.A.; WILSON, J.D.; **College Physics**. 5<sup>th</sup> ed. New Jersey. USA: Pearson Education, Inc., 2003.
- CABRAL, E.F. **Redes neurais artificiais - Um curso prático para engenheiros e cientistas**. São Paulo: Editora Suprema, 1999.1v.
- CASTELLANE, P.D..**Podridão apical em frutos de tomateiro**. Jaboticabal: Editora Funep, 1988.
- CASTLEMAN, K.R. *Digital image processing*. New Jersey: Prentice Hall, 1996.
- CEAGESP – CENTRO DE QUALIDADE EM HORTICULTURA *Classificação do tomate* São Paulo - ABH. Disponível em: <<http://www.hortibrasil.org.br/>> Acesso em: 10 jan. 2006.
- CICA-KNORR. **Importância dos tomates**. Disponível em: <<http://www.cica.com.br/Dicas/Dicas.aspx?idSubGrupo=5>> Acesso em: 18 abril 2006.

- CIE - COMMISSION INTERNATIONALE DE L'ECLAIRAGE. Disponível em: <http://www.cie.co.at/framepublications.html>>. Acesso em: 10 mar. 2006.
- CHEN, C. H., PAU, L.F. & WANG, P.S.P. *Handbook of pattern recognition & computer vision*. Singapore: World Scientific Publishing Co. Pte. Ltd., 1995.
- COSTA, A.R. et al. **GUARANÁ Robot-Soccer Team: Some Architectural Issues**. Anais do 4º Simpósio Brasileiro de Automação Inteligente, São Paulo, setembro, 1999.
- DESMUKH K.S; SHINDE G. N. **An adaptive color image segmentation**. In: Electronic Letters on and Image analysis - Computer Vision Center da Universidade Autônoma de Barcelona, Barcelona, Spain, 2005.
- DOHERTY, J.F; AL-SHAYKU, O. K.; **A discrete random transform method for invariant image analysis using artificial neural networks** *Artificial Neural Networks for speech and vision*. London: Chapman & Hall, 1993.
- FERNANDES, O. A.; CARDOSO, A. M.; MARTINELLI, S. **Manejo Integrado de pragas do tomate**. Jaboticabal: Editora Funep, 2003.
- GARCIA JUNIOR, ERVALDO. **Luminotécnica**. 2ªed. São Paulo: Editora Érica Ltda, 2002.
- GOMES, J.; VELHO, L.; **Computação Gráfica: Imagem**. Rio de Janeiro: Instituto de Matemática Pura e Aplicada - IMPA, 1998.
- GONZALEZ, R. C.; WOODS, R.E. **Processamento de Imagens Digitais**. São Paulo: Editora Edgard Blucher Ltda., 2003.
- GUYTON, A. C.; HALL, J. E. **Tratado de Fisiologia Médica**. 9ªed. Rio de Janeiro: Editora Koogan S.A., 1997.
- HAYKIN, Simon **Redes neurais: princípios e prática**. 2ª ed. Porto Alegre: Bookman, 2004.
- HORTIBRASIL - Instituto Brasileiro de Qualidade em Horticultura. Disponível em: <http://hortibrasil.org.br/classificacao/tomate/tomate.html> >Acesso em: 10 janeiro 2006.
- KIMMEL, R.; SHAKED, D; ELAD, M. **Irwin Sobel: Space-dependent Color Gamut Mapping: A Variational Approach**. IEEE Transactions on Image Processing, Vol. 14(6), p. 796-803, 2005.
- KONDO, N.; AHMAD, U.; MONTA, M.; MURASE, H. **Machine vision based quality evaluation of Iokan orange fruit using neural networks**. *Elsevier. Computers and electronics in agriculture*. Vol. 29, 2000.
- KOVÁCS, Z. L. **Redes neurais artificiais – Fundamentos e aplicações: um texto básico**. 4ª ed. São Paulo: Editora Livraria da Física, 2006.

- KOVÁCS, Z.L. **O cérebro e a sua mente - Uma introdução à neurociência computacional**  
São Paulo: Edição acadêmica, 1997.
- KOVÁCS, Z. L. **Redes neurais artificiais - Fundações e aplicações**. 2ª ed. São Paulo:  
Collegium cognitio, 1996.
- LITTMAN, E.; RITTER, H. **Adaptative color segmentation - A comparison of neural and  
statistical methods**. IEEE Transactions on Neural Networks. Vol. 8, N.1, January, 1997.
- LOESCH, C.; SARI, S.T. **Redes Neurais Artificiais: Fundamentos e Modelos**. Blumenau:  
Editora da FURB, 1996.
- LOURO, A. H. F.; MENDONÇA, M. M.; GONZAGA, A. **Classificação de Tomates  
utilizando Redes Neurais Artificiais**, In: ANAIS DO WVC'2006 - II WORKSHOP DE  
VISÃO COMPUTACIONAL, 16 a 18 de Outubro de 2006, São Carlos, SP, ISBN: 85-  
85205-65-2, p.239-244.
- LUDWIG JUNIOR, O.; COSTA, E. M. **Redes Neurais - Fundamentos e Aplicações com  
Programas em C**. Rio de Janeiro: Editora Ciência Moderna, 2007.
- MARQUES FILHO, O.; VIEIRA NETO, H. **Processamento Digital de Imagens**. São Paulo:  
Editora Brasport, 1999.
- MATSUMOTO, É.Y. **MATLAB 6.5: fundamentos de programação**. São Paulo: Érica, 2002.
- MAXWELL, T.; GILES, C. L. **Transformation invariance using high order correlation in  
neural net architectures**. IEEE International conference on system, man and cybernetics  
Atlanta, GA, 1998.
- MEHROTA, K.; MOHAN, C.K.; RANKA, S. **Elements of artificial networks**. London:  
The MIT Press, 1997.
- NALWA, V. S. **A guided tour of computer vision**. AT&T Publication, 1993.
- NEWTON LABS; **Cognachrome Vision User's Guide**. Newton Research Labs. Disponível:  
[http://www.newtonlabs.com/cognachrome/manual/cognachrome\\_toc.html#SEC4](http://www.newtonlabs.com/cognachrome/manual/cognachrome_toc.html#SEC4), 1998.
- NOVAKOVSKY, S. V. **Color television - A theory of color reproduction**. Moscow: MIR  
Publishers, 1975.
- OLLER, A.; ESTEVA, S.; FERNÁNDEZ, A.; ROSA, J. L. Soccer team based on agent  
oriented programming systems **Proceedings of Micro-Robot world cup soccer  
tournament**, Taejon, Korea, 1996.
- PAZOS, F. **Automação de sistemas e robótica**. Rio de Janeiro: Axcel Books do Brasil  
editora, 2002.

- PONS, C.F. **Identificação e controle de sistemas dinâmicos com redes neurais**. Dissertação de Mestrado. Escola Politécnica da USP. São Paulo, 1998
- RESNICK, R.; HALLIDAY, D.; J, W. **Fundamentos de Física, Ótica e Física Moderna**. 4ª ed. Rio de Janeiro: Livros técnicos e científicos, 1996. V4.
- RUMELHART, D.E.; McCLELLAND, J.L. **Parallel Distributed Processing: Explorations in the Microstructure of Cognition**. Cambridge, MIT Press, 1986.
- SEBRAE (Brasil). **Processos de Industrialização de derivados do tomate**. Disponível em: <http://br.geocities.com/abgalimtec/molhotomate.html>. >. Acesso em: 10 jan. 2006.
- SERWAY, A. R. **Física 3 para Cientistas e Engenheiros com Física Moderna**. 3ª ed. Rio de Janeiro: Livros Técnicos e Científicos, 1996. V3,
- SILVA, J. B. C; GIORDANO, L. B. **Tomate para processamento Industrial – Brasília**: Embrapa Comunicação para Transferência de Tecnologia, 2000.
- SIMÕES, A. S.; COSTA, A. H. R. **Classificação de Laranjas Baseada em Padrões Visuais**. In: Anais do 6º SBAI, 2003.
- USÓ, M. A.; PLA, F.; SEVILHA, P. G. **Multispectral image segmentation by energy minimization for fruit quality estimation**. Disponível em: <<http://www.vision.uji.es>> Acesso em: 29 janeiro 2006.



## 9 GLOSSÁRIO

**ABH - Associação Brasileira de Horticultura** - Entidade fundada em 1961 em Viçosa -MG como utilidade pública Federal com o objetivo de congregar pessoas interessadas em Olericultura. <http://www.abhorticultura.com.br/Historico/>

**CEAGESP** - Companhia de Entrepostos e Armazéns Gerais de São Paulo surgiu em maio de 1969, da fusão de duas empresas mantidas pelo Governo de São Paulo. Hoje, com redes de armazenagem e entrepostagem que asseguram grande parte do abastecimento do Estado. <http://www.ceagesp.gov.br/>

**CIE - Commission Internationale de l'Eclairage** – é uma organização devotada à cooperação internacional e troca de informações entre os países membro em todos os assuntos relacionados à ciência e a arte da iluminação. <http://www.cie.co.at/cie/>

**Gamut** – gamute de um dispositivo ou processo é a porção visível do espaço de cores que pode ser representada, detectada ou reproduzida.

**Náuatle - Nahuatl** é uma língua nativa do México também denominada língua mexicana, era falada pelos Astecas e os seus predecessores. acredita-se que o Nahuatl poderá ter sido uma das línguas faladas pelos Teotihuacan.

**Observador padrão** - observador padrão do CIE (D50 e D65) tem sua distribuição de energia entre 380nm e 730nm com intervalos de 10nm e, eles podem ser utilizados no Triestímulos e nos cálculos de XYZ os valores de xy.

**Purple locus** - Na representação do diagrama de cromaticidade, onde se encontra a linha reta deste contorno, encontramos a Linha Púrpura ou Linha *Magenta*, ao longo desta linha se encontram as cores púrpuras e *magentas* saturadas.

**Spectral lócus** - Na representação do diagrama de cromaticidade, encontra-se a figura na forma de ferradura, o contorno e a linha reta deste contorno, formando a linha espectral, representando as cores.

**Tomatl** - é o nome originário do tomate na língua náuatle

## APÊNDICE A1 – Instalações de Uma Empresa de Classificação de Tomates

Instalações de uma empresa que seleciona tomates no interior do estado de São Paulo. O sistema classifica tomates in natura (não especificamente utilizados para o processo industrial).



Figura A -1 - Entrada do tomate para o processo de seleção e classificação: Lavagem, Secagem e Classificação.



Figura A -2 – Saída da secagem em direção ao classificador



Figura A -3 - Classificador computadorizado e as baias de seleção.



Figura A - 4 - Baias de seleção dos tomates.

## APÊNDICE A2 – Análise das Medições em RGB – Resultados complementares

No capítulo 6 utilizou-se de três exemplares que são: um exemplar de tomate pintado, um exemplar de tomate colorido e um exemplar de tomate maduro, por meio de uma seleção aleatória de 50 pixels da formação R-G, G-B, B-R de cada exemplar de tomate foram obtidas as tabelas que são mostradas a seguir:

### a) Exemplar Pintando

A.1) Tabela do exemplar pintando do capítulo 8.1						
Exemplar Pintando (seleção aleatória de 50 pixels)						
	R	G	G	B	B	R
1	104	92	92	28	28	104
2	108	92	92	18	18	108
3	114	107	107	28	28	114
4	125	109	109	37	37	125
5	133	114	114	58	58	133
6	137	126	126	69	69	137
7	153	140	140	61	61	153
8	155	141	141	54	54	155
9	157	142	142	57	57	157
10	157	147	147	58	58	157
11	160	140	140	65	65	160
12	161	132	132	47	47	161
13	161	154	154	54	54	161
14	161	159	159	47	47	161
15	162	154	154	56	56	162
16	163	144	144	58	58	163
17	163	151	151	59	59	163
18	164	158	158	50	50	164
19	164	158	158	50	50	164
20	164	144	144	66	66	164
21	166	143	143	58	58	166
22	167	154	154	59	59	167
23	169	157	157	53	53	169
24	170	157	157	52	52	170
25	171	162	162	56	56	171
26	172	155	155	52	52	172
27	174	155	155	73	73	174
28	175	157	157	73	73	175
29	175	156	156	69	69	175

30	176	165	165	75	75	176
31	177	173	173	74	74	177
32	177	161	161	70	70	177
33	180	161	161	63	63	180
34	180	165	165	73	73	180
35	180	166	166	90	90	180
36	180	161	161	63	63	180
37	183	175	175	82	82	183
38	183	175	175	82	82	183
39	184	175	175	74	74	184
40	188	178	178	72	72	188
41	191	179	179	95	95	191
42	192	183	183	86	86	192
43	194	187	187	94	94	194
44	203	190	190	116	116	203
45	209	196	196	128	128	209
46	218	212	212	168	168	218
47	225	222	222	175	175	225
48	237	234	234	224	224	237
49	247	246	246	244	244	247
50	252	251	251	250	250	252

Valores médios e contagens de quantos números pertencem a cada condição.

Médias das componentes R-G, G-B e B-R do Exemplar Pintando.					
R	G	G	B	B	R
161,84	147,55	147,55	63,29	63,29	161,84

Tabela do Exemplar Pintando do capítulo 8.1 apresentando o (nc) da participação de R nas faixas e suas porcentagens (100 2)					
Classe	R (xi)	fi	fia	fr%	fra%
1	90;100	0	0	0	0
2	100;110	47	47	0,20	0,20
3	110;120	402	449	1,74	1,94
4	120;130	1248	1697	5,42	7,36
5	130;140	2108	3805	9,16	16,52
<b>6</b>	<b>140;150</b>	<b>3264</b>	<b>7069</b>	<b>14,18</b>	<b>30,70</b>
<b>7</b>	<b>150;160</b>	<b>4013</b>	<b>11082</b>	<b>17,43</b>	<b>48,13</b>
<b>8</b>	<b>160;170</b>	<b>3901</b>	<b>14983</b>	<b>16,95</b>	<b>65,08</b>
<b>9</b>	<b>170;180</b>	<b>3581</b>	<b>18564</b>	<b>15,56</b>	<b>80,64</b>
<b>10</b>	<b>180;190</b>	<b>2586</b>	<b>21150</b>	<b>11,25</b>	<b>91,89</b>
11	190;200	1156	22306	5,06	96,95
12	200;210	275	22581	1,20	98,15
13	210;220	140	22721	0,60	98,75
14	220;230	133	22854	0,57	99,32
15	230;240	65	22919	0,28	99,60
16	240;250	37	22956	0,16	99,76
17	250;260	56	23012	0,24	100
		23012		100	



Resultado do número de contagem (nc) da participação de R nas faixas e suas porcentagens do Exemplar Pintando (8.1) (pintando100luxadob002)		
nc(repr. nºde x R repete	Nc /Valor de R	porcentagem
0	$R \leq 100$	0%
<b>7073</b>	<b><math>100 \leq R \leq 150</math></b>	<b>30,7%</b>
<b>15242</b>	<b><math>150 \leq R \leq 200</math></b>	<b>66,3%</b>
665	$200 \leq R \leq 252$	3%
22980	$97 \leq R \leq 252$	100%

**b) Exemplar Colorido.**

Exemplar Colorido (seleção aleatória de 50 pixels)					
R	G	G	B	B	R
84	67	67	37	37	84
86	58	58	41	41	86
150	93	93	47	47	150
150	126	126	114	114	150
149	122	122	136	136	149
149	79	79	48	48	149
147	106	106	98	98	147
146	101	101	40	40	146
145	95	95	42	42	145
142	72	72	46	46	142
141	85	85	41	41	141
129	65	65	29	29	129
121	96	96	61	61	121
120	75	75	36	36	120
119	91	91	67	67	119
118	87	87	42	42	118
116	78	78	56	56	116
132	43	43	34	34	132
132	105	105	110	110	132
135	46	46	32	32	135
137	93	93	47	47	137
138	74	74	29	29	138
123	76	76	41	41	123
124	102	102	69	69	124
130	65	65	37	37	130
122	87	87	62	62	122
121	96	96	46	46	121
200	105	105	64	64	200
199	81	81	56	56	199
188	87	87	57	57	188
179	91	91	57	57	179
165	142	142	137	137	165
151	75	75	45	45	151
154	134	134	114	114	154
167	133	133	128	128	167
158	93	93	46	46	158

163	88	88	51	51	163
253	252	252	251	251	253
252	250	250	250	250	252
249	245	245	246	246	249
212	104	104	65	65	212
208	104	104	62	62	208
216	100	100	56	56	216
219	130	130	107	107	219
220	106	106	85	85	220
223	127	127	108	108	223
231	227	227	224	224	231
232	228	228	224	224	232
233	230	230	225	225	233
249	246	246	245	245	249
246	245	245	244	244	246
204	112	112	94	94	204

Valores médios e contagens de quantos números pertencem a cada condição.

Médias das componentes R-G, G-B e B-R do Exemplar Colorido					
R	G	G	B	B	R
166,86	115,73	115,73	90,94	90,94	166,86

Análise estatística dos valores de R da tabela do tomate colorido exposta no Apêndice 2 utilizando o resultado do número de contagem (nc) da participação de R nas faixas e suas porcentagens do Exemplar Colorido (8.1)(100luxadobe)					
Classe	R (xi)	fi	fia	fr%	fra%
1	80;90	46	46	0,24	0,24
2	90;100	386	432	0,42	0,66
3	100;110	1378	1810	6,04	6,7
4	110;120	2038	3848	8,88	15,58
5	120;130	1534	5382	6,73	22,31
6	130;140	1477	6859	6,52	28,83
7	140;150	1387	8246	6,28	35,11
8	150;160	1527	9773	6,72	41,83
<b>9</b>	<b>160;170</b>	<b>2087</b>	<b>11860</b>	<b>9,26</b>	<b>51,09</b>
<b>10</b>	<b>170;180</b>	<b>2266</b>	<b>14126</b>	<b>9,88</b>	<b>60,97</b>
<b>11</b>	<b>180;190</b>	<b>2157</b>	<b>16283</b>	<b>9,44</b>	<b>70,41</b>
<b>12</b>	<b>190;200</b>	<b>2198</b>	<b>18481</b>	<b>9,60</b>	<b>80,01</b>
<b>13</b>	<b>200;210</b>	<b>1955</b>	<b>20436</b>	<b>8,57</b>	<b>88,58</b>
<b>14</b>	<b>210;220</b>	<b>2019</b>	<b>22455</b>	<b>8,87</b>	<b>97,45</b>
15	220;230	402	22857	1,79	99,24
16	230;240	59	22916	0,35	99,59
17	240;250	46	22962	0,24	99,83
18	250;260	30	22992	0,17	100
		22992		100	

Resultado do número de contagem (nc) da participação de R nas faixas e suas porcentagens do Exemplar Colorido (8.1)		
nc ( representa o número de vezes que a condição é atendida)	Condição/Valor de R (nc< valor de R)	porcentagem
423	$R \leq 100$	2,00%
7819	$100 \leq R \leq 150$	34%
<b>10237</b>	<b><math>150 \leq R \leq 200</math></b>	<b>44,50%</b>
4513	$200 \leq R \leq 253$	19,60%
22992	$81 \leq R \leq 253$	100%

**c) Exemplar Maduro**

Exemplar Maduro (seleção aleatória de 50 pixels)					
R	G	G	B	B	R
103	43	43	53	53	103
106	53	53	59	59	106
107	55	55	67	67	107
108	44	44	45	45	108
109	48	48	53	53	109
123	49	49	46	46	123
128	73	73	79	79	128
130	69	69	74	74	130
147	50	50	43	43	147
157	128	128	130	130	157
154	27	27	36	36	154
155	24	24	38	38	155
114	90	90	64	64	114
124	56	56	67	67	124
123	52	52	60	60	123
150	60	60	60	60	150
152	38	38	37	37	152
155	27	27	40	40	155
157	56	56	60	60	157
160	139	139	145	145	160
166	144	144	154	154	166
167	81	81	90	90	167
169	137	137	152	152	169
172	80	80	85	85	172
175	27	27	23	23	175
178	24	24	34	34	178
179	117	117	60	60	179
189	62	62	56	56	189
188	37	37	30	30	188
183	68	68	71	71	183
186	37	37	39	39	186
191	58	58	59	59	191
195	53	53	52	52	195
198	53	53	60	60	198

200	86	86	86	86	200
201	88	88	32	32	201
207	69	69	69	69	207
209	68	68	40	40	209
213	82	82	87	87	213
216	71	71	78	78	216
218	63	63	59	59	218
229	96	96	101	101	229
227	67	67	51	51	227
223	133	133	142	142	223
230	106	106	107	107	230
239	85	85	75	75	239
251	238	238	237	237	251
248	244	244	247	247	248
240	200	200	204	204	240
245	229	229	229	229	245

Valores médios e contagens de quantos números pertencem a cada condição.

Médias das componentes R-G, G-B e B-R do Exemplar Maduro					
R	G	G	B	B	R
175,88	81,68	81,68	81,3	81,3	175,88

Resultado do número de contagem (nc) da participação de R nas faixas e suas porcentagens do Exemplar Maduro (8.1)					
Classe	R (xi)	fi	fia	fr%	fra%
1	90;100	3	3	0,106232	0,106232
2	100;110	59	62	2,089235	2,195467
3	110;120	126	188	4,461756	6,657224
4	120;130	160	348	5,665722	12,32295
5	130;140	133	481	4,709632	17,03258
6	140;150	143	624	5,063739	22,09632
7	150;160	160	784	5,665722	27,76204
8	160;170	157	941	5,559490	33,32153
<b>9</b>	<b>170;180</b>	<b>152</b>	<b>1093</b>	<b>5,382436</b>	<b>38,70397</b>
<b>10</b>	<b>180;190</b>	<b>163</b>	<b>1256</b>	<b>5,771955</b>	<b>44,47592</b>
<b>11</b>	<b>190;200</b>	<b>163</b>	<b>1419</b>	<b>5,771955</b>	<b>50,24788</b>
<b>12</b>	<b>200;210</b>	<b>276</b>	<b>1695</b>	<b>9,773371</b>	<b>60,02125</b>
<b>13</b>	<b>210;220</b>	<b>374</b>	<b>2069</b>	<b>13,24363</b>	<b>73,26487</b>
<b>14</b>	<b>220;230</b>	<b>485</b>	<b>2554</b>	<b>17,17422</b>	<b>90,43909</b>
15	230;240	215	2769	7,613314	98,05241
16	240;250	50	2819	1,770538	99,82295
17	250;260	5	2824	0,177054	100
		2824		100	

Resultado do número de contagem (nc) da participação de R nas faixas e suas porcentagens do Exemplar Maduro (8.1)		
nc ( representa o número de vezes que a condição é atendida)	Condição/Valor de R (nc< valor de R)	porcentagem
3	$R \leq 100$	0,1%
<b>879</b>	<b><math>100 \leq R \leq 170</math></b>	<b>33%</b>
<b>1298</b>	<b><math>180 \leq R \leq 230</math></b>	<b>51,7%</b>
270	$230 \leq R \leq 251$	1%
2824	$97 \leq R \leq 251$	100%

## APÊNDICE A3 – Dados e Tabela de Resultados da Rede Neural – Treinamento e Simulação

Para fazer o treinamento da rede foram utilizados dados de RGB de 180 tomates, sendo 30 Tomates “Pintando” a 500 lux, 30 Tomates “Pintando” a 1000 lux, 30 Tomates “Colorido”s a 500 lux, 30 Tomates “Coloridos” 1000 lux, 30 Tomates “Maduros” a 500 lux e finalmente 30 Tomates “Maduros” a 1000 lux.

O vetor de dados de entrada da rede neural utilizado o treinamento da rede neural no software Matlab® em seu módulo nntool é apresentado a seguir.

EntradasTreinamento={ [0.694;0.556;0.258] [0.815;0.792;0.639] [0.663;0.631;0.302]  
[0.757;0.478;0.318] [0.631;0.616;0.286] [0.663;0.588;0.286] [0.722;0.557;0.278]  
[0.655;0.600;0.290] [0.667;0.584;0.325] [0.667;0.584;0.302] [0.520;0.411;0.079]  
[0.663;0.466;0.115] [0.652;0.349;0.099] [0.650;0.331;0.073] [0.700;0.328;0.092]  
[0.474;0.330;0.113] [0.748;0.333;0.235] [0.729;0.319;0.152] [0.798;0.285;0.221]  
[0.808;0.279;0.234] [0.473;0.393;0.047] [0.770;0.532;0.134] [0.717;0.415;0.111]  
[0.712;0.394;0.108] [0.782;0.363;0.122] [0.839;0.458;0.337] [0.858;0.486;0.301]  
[0.862;0.450;0.337] [0.870;0.498;0.352] [0.793;0.300;0.122] [0.663;0.588;0.384]  
[0.643;0.596;0.420] [0.604;0.612;0.420] [0.706;0.502;0.360] [0.624;0.643;0.416]  
[0.635;0.612;0.416] [0.675;0.588;0.400] [0.643;0.620;0.435] [0.620;0.592;0.388]  
[0.686;0.580;0.384] [0.608;0.604;0.396] [0.659;0.600;0.384] [0.651;0.616;0.435]  
[0.651;0.600;0.459] [0.584;0.608;0.337] [0.686;0.631;0.357] [0.659;0.608;0.349]  
[0.639;0.584;0.412] [0.686;0.514;0.478] [0.694;0.510;0.475] [0.839;0.458;0.337]  
[0.858;0.486;0.301] [0.862;0.450;0.337] [0.870;0.498;0.352] [0.825;0.524;0.324]  
[0.473;0.393;0.047] [0.770;0.532;0.134] [0.717;0.415;0.111] [0.712;0.394;0.108]  
[0.782;0.363;0.122] [0.686;0.514;0.478] [0.694;0.510;0.475] [0.698;0.475;0.447]  
[0.686;0.518;0.459] [0.675;0.525;0.451] [0.729;0.439;0.408] [0.706;0.447;0.392]  
[0.757;0.510;0.486] [0.757;0.510;0.482] [0.749;0.435;0.412] [0.737;0.463;0.423]  
[0.737;0.467;0.404] [0.678;0.561;0.482] [0.718;0.510;0.392] [0.690;0.478;0.420]  
[0.694;0.443;0.408] [0.733;0.486;0.443] [0.706;0.494;0.459] [0.682;0.455;0.404]  
[0.698;0.455;0.431] [0.886;0.368;0.380] [0.890;0.403;0.368] [0.898;0.384;0.372]  
[0.901;0.380;0.376] [0.905;0.380;0.349] [0.913;0.384;0.403] [0.913;0.396;0.380]  
[0.917;0.400;0.403] [0.917;0.415;0.400] [0.917;0.415;0.392] [0.718;0.427;0.435]  
[0.733;0.514;0.435] [0.776;0.557;0.510] [0.722;0.455;0.404] [0.761;0.427;0.369]  
[0.725;0.404;0.404] [0.729;0.439;0.388] [0.725;0.435;0.384] [0.722;0.447;0.388]  
[0.722;0.478;0.416] [0.737;0.361;0.322] [0.776;0.416;0.392] [0.714;0.416;0.388]  
[0.698;0.408;0.384] [0.780;0.420;0.400] [0.702;0.439;0.388] [0.725;0.525;0.486]  
[0.702;0.459;0.404] [0.702;0.459;0.404] [0.698;0.420;0.384] [0.737;0.463;0.423]  
[0.737;0.467;0.404] [0.678;0.561;0.482] [0.718;0.510;0.392] [0.690;0.478;0.420]  
[0.694;0.443;0.408] [0.733;0.486;0.443] [0.795;0.211;0.148] [0.886;0.264;0.253]  
[0.843;0.178;0.172] [0.757;0.482;0.408] [0.757;0.463;0.396] [0.718;0.427;0.369]

[0.718;0.533;0.431] [0.698;0.498;0.408] [0.722;0.451;0.412] [0.737;0.498;0.419]  
 [0.733;0.443;0.411] [0.745;0.450;0.419] [0.729;0.454;0.392] [0.741;0.474;0.431]  
 [0.737;0.454;0.396] [0.733;0.423;0.376] [0.752;0.411;0.388] [0.725;0.474;0.388]  
 [0.756;0.474;0.435] [0.764;0.427;0.376] [0.725;0.439;0.403] [0.745;0.486;0.435]  
 [0.721;0.376;0.321] [0.911;0.169;0.129] [0.897;0.199;0.160] [0.872;0.207;0.161]  
 [0.927;0.217;0.154] [0.902;0.211;0.148] [0.902;0.207;0.159] [0.884;0.194;0.142]  
 [0.919;0.186;0.153] [0.925;0.211;0.202] [0.924;0.171;0.142] [0.906;0.423;0.427]  
 [0.918;0.376;0.407] [0.890;0.407;0.356] [0.922;0.431;0.435] [0.922;0.443;0.447]  
 [0.890;0.415;0.419] [0.886;0.372;0.368] [0.902;0.396;0.392] [0.902;0.403;0.419]  
 [0.886;0.400;0.392] [0.911;0.169;0.129] [0.897;0.199;0.160] [0.872;0.207;0.161]  
 [0.927;0.217;0.154] [0.902;0.211;0.148] [0.902;0.207;0.159] [0.884;0.194;0.142]  
 [0.919;0.186;0.153] [0.925;0.211;0.202] [0.924;0.171;0.142] [0.911;0.169;0.129]  
 [0.897;0.199;0.160] [0.872;0.207;0.161] [0.927;0.217;0.154] [0.902;0.211;0.148]  
 [0.902;0.207;0.159] [0.884;0.194;0.142] [0.919;0.186;0.153] [0.925;0.211;0.202]  
 [0.924;0.171;0.142]}

(A3.1)

Para os valores de entrada apresentados em (A3.1) os resultados esperados e adotados na rede para fazer o treinamento (*targets*) são:

*Targets*={ [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0]  
 [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0]  
 [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0]  
 [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0]  
 [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0] [1;0;0]  
 [1;0;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0]  
 [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0]  
 [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0]  
 [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0]  
 [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0]  
 [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0] [0;1;0]  
 [0;1;0] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1]  
 [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1]  
 [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1]  
 [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1]  
 [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1] [0;0;1]  
 [0;0;1] }

(A3.2)

Parâmetros utilizados no módulo nntool do software MATLAB®

Para o treinamento da rede utilizada neste sistema listou-se os seguintes parâmetros:

Trainlm = treinamento por Levenberg-Marquardt

Learngdm = aprendizado por gradiente descendente e momentum

Layers = número de camadas da rede

steps = 10000; número de iterações

mu = 0.001; gradiente

mu-dec = 0,1; mu decremental

mu-inc = 10; mu incremental

mu-max = 1000000000; mu máximo

show = 25; o gráfico mostra em intervalos de 25 e 25

time = tempo de apresentação

MSE= Erro Médio Quadrático

Steps ou Epochs= épocas ou número de iterações

IW1 = vetor dos pesos sinápticos aplicados as entradas do primeiro layer

IW2 = vetor dos pesos sinápticos aplicados as entradas do segundo layer

B1= vetor de *bias*(viés) primeiro layer

B2 = vetor de *bias*(viés) segundo layer

### Resultados do treinamento da rede neural no MATLAB, *nntool*, utilizando as entradas (A3.1) e aparecem na tabela A3.1 na coluna outputs

Saídas para Tomate P(500lux):

```
{[1;1.105e-079; 9.4761e-018] [0.99992;1.5351e-058;2.2215e-014] [1;7.8883e-080; 7.3466e-229] [1; 5.7281e-067;0] [1;5.2981e-080;0] [1; 4.2381e-080;0] [1;1.0828e-079; 1.9206e-030] [1;3.21e-080; 0] [1;7.4656e-082;0] [1;1.0156e-081;0] [1; 1.1077e-079; 3.1121e-016] [1;1.1077e-079;3.1123e-016] [1;1.1077e-079; 3.1121e-016] [1; 1.1077e-079;3.1123e-016] [1;1.1077e-079;3.1123e-016] [1; 9.5209e-082;0] [1;0.011241;0] [1;2.2253e-077;4.5956e-016] [1;0.024074;0] [0.979;0.3712; 2.7052e-203] [1;1.1077e-079;3.1122e-016] [1;1.1077e-079;3.1123e-016] [1;1.1077e-079; 3.1123e-016] [1;1.1077e-079;3.1123e-016] [1;1.1077e-079;3.1123e-016] [1;0.00033995;0] [1; 3.8296e-063;1.1815e-065] [1;0.00032183;0] [1; 0.00029784;0] [1;6.6335e-032;4.3577e-005]}
```

Saídas para Tomate P(1000lux):

```
{[1;1.1976e-080;0] [1;5.972e-078; 1.9692e-025] [1;2.2334e-050; 2.5591e-068] [0.99974;8.9604e-029;3.2816e-114] [1;1.5543e-079;0] [1; 2.9055e-078; 5.0376e-079] [1;5.5184e-079;0] [1;1.1226e-077;6.3286e-029] [1;1.4476e-078;6.1515e-271] [1;5.2662e-081;0] [1;4.4422e-078;2.482e-150] [1; 2.0326e-081; 0] [1;4.7127e-078;2.0387e-028] [1;4.6698e-007; 6.0291e-136] [1;7.544e-082;0] [1;7.4619e-082;0] [1;7.4626e-082;0] [1; 7.6951e-078; 1.1381e-023] [0.57345;1;1.5004e-242] [0.39747;1;1.8286e-241] [1;0.00033995;0] [1; 3.8296e-063;1.1815e-065] [1;0.00032183;0] [1;0.00029784;0] [1;6.0071e-081;0] [1;1.1077e-079;3.1122e-016] [1;1.1077e-079; 3.1123e-016] [1;1.1077e-079; 3.1123e-016] [1;1.1077e-079;3.1123e-016] [1;1.1077e-079;3.1123e-016] }
```

Saídas para Tomate C(500lux):

```
{[0.57345;1;1.5004e-242] [0.39747;1;1.8286e-241] [1.2263e-005;1;7.5328e-225] [1.0065e-005;1;1.5073e-224] [7.8855e-009;1;1.2211e-213] [2.1846e-069; 0.64829; 0.37103] [2.0326e-069;0.61237;0.43183] [1.5702e-064;1; 5.1757e-018] [4.0635e-067; 0.99999; 6.3095e-009] [1.7086e-069; 0.52178; 0.58306] [1.8928e-069;0.5758; 0.49394] [1.648e-069;0.50132; 0.61386] [0.084859;1;1.7983e-238] [8.2822e-069; 0.49872;0.015035] [3.2667e-059; 1; 1.0867e-036] [2.9658e-054;1; 4.197e-054] [6.2024e-069; 0.94469;0.014882] [7.5653e-011;1;1.4934e-206] [3.7426e-055;1; 6.0288e-051] [2.6261e-014; 1; 2.1104e-194] [1.6557e-069;0.5; 0.61108] [8.0181e-065; 0.49124; 5.1325e-014] [3.4338e-069; 0.4994;0.16139] [2.1214e-069;0.4998; 0.43496] [1.9556e-049;0.46255;2.6225e-058] [1.6516e-069;0.5;0.61275] [1.557e-068;0.49818;0.0024747] [1.766e-069;0.49994;0.56615] [4.09e-069;0.49926;0.10422] [8.4849e-068;0.4968;1.8836e-005] }
```



Saídas para Tomate C(1000lux):

{[1.9161e-010;1;5.7114e-208] [1.6757e-069;0.50989;0.60001] [3.1922e-069; 0.80545; 0.13473] [1.7816e-069;0.5439;0.54701] [1.7016e-069;0.49998;0.5922] [2.2385e-066; 1;1.575e-011] [1.6512e-069;0.50323;0.61202] [1.6539e-069;0.5041;0.61067] [1.6556e-069;0.50439;0.60986] [1.7925e-069;0.54702;0.54172] [1.6517e-069;0.5;0.6127] [1.6409e-069;0.50005;0.61717] [2.9542e-069;0.77823; 0.16971] [1.5997e-066;1;5.1263e-011] [1.6407e-069;0.50008;0.61724] [2.454e-069; 0.70255;0.28168] [1.3561e-019;1;7.8147e-176] [5.7019e-069;0.93452;0.019896] [5.7019e-069;0.93452;0.019896] [1.4742e-068;0.99085;0.0007216] [1.8928e-069;0.5758;0.49394] [1.648e-069;0.50132;0.61386] [0.084859;1;1.7983e-238] [8.2822e-069; 0.49872;0.015035] [3.2667e-059;1;1.0867e-036] [2.9658e-054; 1;4.197e-054] [6.2024e-069;0.94469; 0.014882] [4.6914e-005;0.046354;0.0056518] [4.4028e-012;0.39409;9.0667e-166] [2.8461e-062;0.42243;0.0099407] }

Saídas para Tomate M (500lux):

{ [1.6905e-069;0.50001;0.59672] [1.6776e-069;0.5;0.60205] [1.6481e-069;0.50147; 0.61379] [1.7072e-069; 0.50735;0.58779] [1.8431e-069;0.55943;0.51803] [2.9e-069; 0.77133; 0.17908] [1.6579e-069;0.50115;0.60982] [1.9751e-069;0.59781;0.45671] [1.7555e-069;0.53615;0.5598] [1.6488e-069;0.50161;0.61348] [1.8548e-069;0.56519;0.51177] [1.6463e-069;0.50101;0.61469] [1.6442e-069;0.50082; 0.61559] [1.6446e-069;0.50139;0.61527] [1.7217e-069;0.50016;0.58398] [1.6832e-069;0.51375;0.59583] [1.6608e-069;0.5;0.60895] [2.0105e-069;0.6069; 0.44125] [1.7146e-069; 0.52356;0.58009] [1.6743e-069;0.5;0.6034] [0.00021854;0.041965; 0.99892] [5.9558e-006;0.042458;1] [1.8565e-007;0.043007;1] [0.00028854;0.041929;0.9976] [0.00027422;0.041936;0.99792] [0.00012846;0.042038; 0.99976] [0.00014419; 0.042021; 0.99967] [6.7473e-005;0.042121;0.99996] [2.1348e-011;0.057686;0.99846] [0.00010564;0.042061;0.99987] }

Saídas para Tomate M(1000lux):

{[1.6549e-069; 0.5;0.61141] [1.6429e-069;0.5;0.61637] [0.020857;0.37712;1.0562e-93] [1.6686e-069; 0.49999; 0.60573] [1.6554e-069;0.5;0.6112] [1.6478e-069; 0.5;0.61434] [1.8916e-069; 0.49989;0.5171] [1.849e-069;0.49991;0.53345] [1.6437e-069; 0.5; 0.61602] [1.7578e-069;0.49995;0.56945] [0.00021854; 0.041965;0.99892] [5.9558e-006;0.042458;1] [1.8565e-007;0.043007;1] [0.00028854;0.041929;0.9976] [0.00027422;0.041936;0.99792] [0.00012846; 0.042038;0.99976] [0.00014419;0.042021;0.99967] [6.7473e-005;0.042121;0.99996] [2.1348e-011; 0.057686;0.99846] [0.00010564;0.042061;0.99987] [0.00021854; 0.041965;0.99892] [5.9558e-006;0.042458;1] [1.8565e-007;0.043007;1] [0.00028854; 0.041929; 0.9976] [0.00027422;0.041936;0.99792] [0.00012846; 0.042038;0.99976] [0.00014419; 0.042021; 0.99967] [6.7473e-005;0.042121;0.99996] [2.1348e-011; 0.057686;0.99846] [0.00010564;0.042061;0.99987] }

Tabela A3.1 – Principais Características da rede 1

Atividade da rede Tomate1-3,4,3	Entradas	Target	Saída
Trainglm IW1= [-96.6786 - 121.8544 253.5232; 152.77 -639.1494 598.7545;-155.6476 - 97.7333 193.0715; - 67.0508 -131.0674 183.0207] IW2=[2353.4422 - 224.842 158.9038 - 2503.6931; -5.0008 178.673 339.0306 8.1298; -7212.3037 41.6834 - 558.0864 7206.8051] B1=[61.8043;- 1.9784;71.2827;50.58 57] B2=[216.7093;-	Data1= {[0.694;0.556;0.258] [0.815;0.792;0.639] [0.663;0.631;0.302] [0.757;0.478;0.318] [0.631;0.616;0.286] [0.663;0.588;0.286] [0.722;0.557;0.278] [0.655;0.600;0.290] [0.667;0.584;0.325] [0.667;0.584;0.302] [0.520;0.411;0.079] [0.663;0.466;0.115] [0.652;0.349;0.099] [0.650;0.331;0.073] [0.700;0.328;0.092] [0.474;0.330;0.113] [0.748;0.333;0.235] [0.729;0.319;0.152]	Data2= {[1;0;0] [1;0;0]	Outputs: {[1;1.105e-079; 9.4761e-018] [0.99992;1.5351e-058;2.2215e-014] [1;7.8883e-080; 7.3466e-229] [1; 5.7281e-067;0] [1;5.2981e-080;0] [1; 4.2381e-080;0] [1;1.0828e-079; 1.9206e-030] [1;3.21e-080; 0] [1;7.4656e-082;0] [1;1.0156e-081;0]  [1; 1.1077e-079; 3.1121e-016] [1;1.1077e-079;3.1123e-016] [1;1.1077e-079; 3.1121e-016] [1; 1.1077e-079;3.1123e-016] [1; 9.5209e-082;0] [1; 0.011241;0] [1;2.2253e-077;4.5956e-016] [1;0.024074;0] [0.979;0.3712; 2.7052e-203]  [1;1.1077e-079;3.1122e-016] [1;1.1077e-



<p>[0.706;0.494;0.459]          [0.682;0.455;0.404]          [0.698;0.455;0.431]          [0.886;0.368;0.380]          [0.890;0.403;0.368]          [0.898;0.384;0.372]          [0.901;0.380;0.376]          [0.905;0.380;0.349]          [0.913;0.384;0.403]          [0.913;0.396;0.380]          [0.917;0.400;0.403]          [0.917;0.415;0.400]          [0.917;0.415;0.392]          [0.718;0.427;0.435]          [0.733;0.514;0.435]          [0.776;0.557;0.510]          [0.722;0.455;0.404]          [0.761;0.427;0.369]          [0.725;0.404;0.404]          [0.729;0.439;0.388]          [0.725;0.435;0.384]          [0.722;0.447;0.388]          [0.722;0.478;0.416]          [0.737;0.361;0.322]          [0.776;0.416;0.392]          [0.714;0.416;0.388]          [0.698;0.408;0.384]          [0.780;0.420;0.400]          [0.702;0.439;0.388]          [0.725;0.525;0.486]          [0.702;0.459;0.404]          [0.702;0.459;0.404]          [0.698;0.420;0.384]          [0.737;0.463;0.423]          [0.737;0.467;0.404]          [0.678;0.561;0.482]          [0.718;0.510;0.392]          [0.690;0.478;0.420]          [0.694;0.443;0.408]          [0.733;0.486;0.443]          [0.795;0.211;0.148]          [0.886;0.264;0.253]          [0.843;0.178;0.172]          [0.757;0.482;0.408]          [0.757;0.463;0.396]          [0.718;0.427;0.369]          [0.718;0.533;0.431]          [0.698;0.498;0.408]          [0.722;0.451;0.412]          [0.737;0.498;0.419]          [0.733;0.443;0.411]          [0.745;0.450;0.419]          [0.729;0.454;0.392]          [0.741;0.474;0.431]          [0.737;0.454;0.396]          [0.733;0.423;0.376]          [0.752;0.411;0.388]          [0.725;0.474;0.388]          [0.756;0.474;0.435]</p>		<p>0.49124; 5.1325e-014] [3.4338e-069;          0.4994;0.16139] [2.1214e-069;0.4998;          0.43496] [1.9556e-049;0.46255;2.6225e-          058] [1.6516e-069;0.5;0.61275] [1.557e-          068;0.49818;0.0024747] [1.766e-          069;0.49994;0.56615] [4.09e-          069;0.49926;0.10422] [8.4849e-          068;0.4968;1.8836e-005]</p> <p>[1.9161e-010;1;5.7114e-208] [1.6757e-          069;0.50989;0.60001] [3.1922e-069;          0.80545;          0.13473] [1.7816e-069;0.5439;0.54701]          [1.7016e-069;0.49998;0.5922] [2.2385e-          066; 1;1.575e-011] [1.6512e-          069;0.50323;0.61202] [1.6539e-          069;0.5041;0.61067] [1.6556e-          069;0.50439;0.60986] [1.7925e-          069;0.54702;0.54172]</p> <p>[1.6517e-069;0.5;0.6127] [1.6409e-          069;0.50005;0.61717] [2.9542e-          069;0.77823; 0.16971] [1.5997e-          066;1;5.1263e-011] [1.6407e-          069;0.50008;0.61724] [2.454e-069;          0.70255;0.28168] [1.3561e-          019;1;7.8147e-176] [5.7019e-          069;0.93452;0.019896] [5.7019e-          069;0.93452;0.019896] [1.4742e-          068;0.99085;0.0007216]</p> <p>[1.8928e-069;0.5758;0.49394] [1.648e-          069;0.50132;0.61386]          [0.084859;1;1.7983e-238] [8.2822e-069;          0.49872;0.015035] [3.2667e-          059;1;1.0867e-036] [2.9658e-054;          1;4.197e-054] [6.2024e-069;0.94469;          0.014882] [4.6914e- 005;0.046354;          0.0056518] [4.4028e-012;0.39409;          9.0667e-166] [2.8461e- 062;0.42243;          0.0099407]</p> <p>[1.6905e-069;0.50001;0.59672] [1.6776e-          069;0.5;0.60205] [1.6481e-069;0.50147;          0.61379] [1.7072e-069; 0.50735;0.58779]          [1.8431e-069;0.55943;0.51803] [2.9e-069;          0.77133; 0.17908] [1.6579e-069;0.50115;          0.60982] [1.9751e-069;0.59781;0.45671]          [1.7555e-069;0.53615;0.5598] [1.6488e-          069;0.50161;0.61348]</p> <p>[1.8548e-069;0.56519;0.51177] [1.6463e-          069;0.50101;0.61469] [1.6442e-069;          0.50082; 0.61559] [1.6446e-069;0.50139;          0.61527] [1.7217e-069;0.50016;0.58398]          [1.6832e-069;0.51375;0.59583] [1.6608e-          069;0.5;0.60895] [2.0105e-069;0.6069;          0.44125] [1.7146e-069; 0.52356;0.58009]          [1.6743e-069;0.5;0.6034]</p>
--	--	---

	<p>[0.764;0.427;0.376]          [0.725;0.439;0.403]          [0.745;0.486;0.435]          [0.721;0.376;0.321]          [0.911;0.169;0.129]          [0.897;0.199;0.160]          [0.872;0.207;0.161]          [0.927;0.217;0.154]          [0.902;0.211;0.148]          [0.902;0.207;0.159]          [0.884;0.194;0.142]          [0.919;0.186;0.153]          [0.925;0.211;0.202]          [0.924;0.171;0.142]          [0.906;0.423;0.427]          [0.918;0.376;0.407]          [0.890;0.407;0.356]          [0.922;0.431;0.435]          [0.922;0.443;0.447]          [0.890;0.415;0.419]          [0.886;0.372;0.368]          [0.902;0.396;0.392]          [0.902;0.403;0.419]          [0.886;0.400;0.392]          [0.911;0.169;0.129]          [0.897;0.199;0.160]          [0.872;0.207;0.161]          [0.927;0.217;0.154]          [0.902;0.211;0.148]          [0.902;0.207;0.159]          [0.884;0.194;0.142]          [0.919;0.186;0.153]          [0.925;0.211;0.202]          [0.924;0.171;0.142]}</p>		<p>[0.00021854;0.041965; 0.99892] [5.9558e-006;0.042458;1] [1.8565e-007;0.043007;1]          [0.00028854;0.041929;0.9976]          [0.00027422; 0.041936; 0.99792]          [0.00012846; 0.042038; 0.99976]          [0.00014419; 0.042021; 0.99967]          [6.7473e-005;0.042121;0.99996] [2.1348e-011;0.057686;0.99846] [0.00010564; 0.042061;0.99987]           [1.6549e-069; 0.5; 0.61141] [1.6429e-069;0.5;0.61637] [0.020857;0.37712; 1.0562e-93] [1.6686e-069; 0.49999; 0.60573] [1.6554e-069;0.5;0.6112]          [1.6478e-069; 0.5;0.61434]          [1.8916e-069; 0.49989; 0.5171] [1.849e-069;0.49991;0.53345] [1.6437e-069; 0.5; 0.61602] [1.7578e-069;0.49995;0.56945]           [0.00021854; 0.041965;0.99892]          [5.9558e-006;0.042458;1] [1.8565e-007;0.043007;1] [0.00028854; 0.041929; 0.9976] [0.00027422;0.041936;0.99792]          [0.00012846; 0.042038;0.99976]          [0.00014419;0.042021;0.99967] [6.7473e-005;0.042121;0.99996] [2.1348e-011; 0.057686;0.99846] [0.00010564; 0.042061; 0.99987]           [0.00021854; 0.041965;0.99892] [5.9558e-006;0.042458;1] [1.8565e-007;0.043007;1]          [0.00028854; 0.041929; 0.9976]          [0.00027422;0.041936;0.99792]          [0.00012846; 0.042038;0.99976]          [0.00014419; 0.042021; 0.99967]          [6.7473e-005;0.042121;0.99996]          [2.1348e-011; 0.057686;0.99846]          [0.00010564;0.042061;0.99987]}</p>
<p>Simulate</p>	<p>Data3=          {[0.776;0.490;0.270]          [0.807;0.521;0.282]          [0.807;0.570;0.329]          [0.811;0.501;0.321]          [0.819;0.592;0.329]          [0.819;0.592;0.329]          [0.819;0.521;0.301]          [0.823;0.564;0.360]          [0.823;0.564;0.360]          [0.823;0.533;0.329]          [0.686;0.514;0.478]          [0.694;0.510;0.475]          [0.698;0.475;0.447]          [0.686;0.518;0.459]}</p>		<p>{[1;1.0471e-079;1.7375e-051] [1;1.1062e-079;4.3629e-017] [1;6.9148e-080;0] [1; 1.2531e-081;0] [1;1.0954e-079;3.2514e-023] [1; 1.0954e-079; 3.2514e-023] [1; 1.0513e-079;5.9542e-049] [1;7.7747e-082;0] [1;7.7747e-082;0] [1;3.9256e-081; 0]           [0.57345;1;1.5004e-242] [0.39747; 1;1.8286e-241] [1.2263e-005;1;7.5328e-225] [1.0065e-005;1;1.5073e-224]          [7.8855e-009;1;1.2211e-213] [2.1846e-069; 0.64829; 0.37103] [2.0326e-069; 0.61237; 0.43183] [1.5702e-064; 1; 5.1757e-018]</p>

	[0.675;0.525;0.451] [0.729;0.439;0.408] [0.706;0.447;0.392] [0.757;0.510;0.486] [0.757;0.510;0.482] [0.749;0.435;0.412] [0.900;0.174;0.156] [0.850;0.316;0.259] [0.757;0.482;0.408] [0.757;0.463;0.396] [0.718;0.427;0.369] [0.718;0.533;0.431] [0.698;0.498;0.408] [0.722;0.451;0.412] [0.737;0.498;0.419] [0.917;0.415;0.392]}		[4.0635e-067; 0.99999; 6.3095e-009] [1.7086e-069; 0.52178;0.58306]  [1.8198e-022;0.047875;1] [1;0.0073528;0] [1.6905e-069;0.50001;0.59672] [1.6776e-069;0.5;0.60205] [1.6481e-069;0.50147;0.61379] [1.7072e-069;0.50735;0.58779] [1.8431e-069;0.55943; 0.51803] [2.9e-069; 0.77133; 0.17908] [1.6579e-069; 0.50115; 0.60982] [8.4849e-068;0.4968;1.8836e-005]}
--	---	--	--

Os resultados de treinamento e testes da rede estão na tabela A3.1 e são mostrados graficamente nas figuras 6.22 a 6.24. Na tabela A3.1 os dados “Simulate” foram utilizados para avaliar a eficiência da rede.

### Teste da rede neural no sistema prático utilizando imagens a 700 lux

Entradas para Tomate P (700lux):

[0.537 0.505 0.113;0.721 0.270 0.184;0.613 0.541 0.150;0.545 0.466 0.117;0.592 0.498 0.176;0.784 0.250 0.258;0.705 0.333 0.160;0.749 0.345 0.278;0.780 0.207 0.262;0.607 0.525 0.231;0.658 0.388 0.211;0.717 0.258 0.250;0.749 0.243 0.215;0.749 0.192 0.247;0.737 0.231 0.262;0.541 0.443 0.180;0.552 0.454 0.160;0.576 0.454 0.149;0.745 0.235 0.184;0.725 0.325 0.184;0.745 0.352 0.235;0.682 0.568 0.392;0.709 0.600 0.431;0.650 0.564 0.360;0.701 0.576 0.423;0.650 0.549 0.380;0.721 0.611 0.454;0.678 0.560 0.423;0.654 0.627 0.333;0.650 0.603 0.329]

Saídas para Tomate P(700lux):

[1 0 0;1 1 0;1 3.9046e-008 0;0.97453 0 0.035021;1 0.00039247 0;1 1.1675e-006 0;1 0 2.8754e-009;1 0.00010202 0;1 3.6391e-009 0;1 2.4346e-009 0;0.99983 0 0.013176;1 0.00013188 0;1 7.4446e-083 0;1 2.8524e-019 0;1 1.4719e-009 0;0.54617 0 0.46056;0.54015 0 0.46099;0.54023 0 0.46087;0.57005 0 0.42137;0.54013 0 0.46101;0.54013 0 0.46101;0.54035 0 0.46072;0.55017 0 0.44772;0.55017 0 0.44772;0.54313 0 0.45703;1 0 4.0209e-024;0.54324 0 0.45689;1 0 2.2897e-032;0.96869 0 0.011054;0.54364 0 0.45635]

Entradas para Tomate C (700lux):

[0.701 0.600 0.592;0.752 0.640 0.623;0.639 0.517 0.525;0.725 0.635 0.627;0.870 0.776 0.788;0.839 0.694 0.713;0.823 0.690 0.709;0.854 0.752 0.686;0.894 0.717 0.752;0.827 0.643 0.662;0.804 0.682 0.627;0.752 0.643 0.639;0.745 0.639 0.580;0.905 0.807 0.819;0.956 0.866 0.823;0.725 0.564 0.576;0.972 0.929 0.925;0.968 0.933 0.921;0.870 0.792 0.698;0.929 0.784 0.780;0.768 0.556 0.603;0.607 0.521 0.470;0.709 0.482 0.396;0.733 0.490 0.400;0.725 0.470

0.384;0.709 0.482 0.364;0.709 0.513 0.364;0.713 0.443 0.360;0.752 0.564 0.462;0.741 0.439 0.352]

Saídas para Tomate C(700lux):

[0 1 0;0 1 0;0 1 0;0 1 0;1.4776e-055 1 0;0 0.99545 0.0066775;0 0.99898 0.00064405;0 1 4.6307e-038;0 1 9.9643e-037;0 1 1.5154e-012;0 7.2306e-033 1;0 0 1;0 1 0;0.0003309 0.99957 0;0 1 0;0 1 0;0 0.99246 0.0086049;0 1 0;2.1556e-279 1 0;0 1 0;0 0.99766 0.00055953;0 1 0;0 1 0;0 1 2.2467e-163;0.00010041 1 0;0 1 9.2373e-034;0 1 0;0 1 6.8359e-122;0 1 0;0 1 0]

Entradas para Tomate M (700lux):

[0.816 0.792 0.639;0.859 0.839 0.576;0.835 0.769 0.541;0.612 0.569 0.349;0.553 0.498 0.337;0.894 0.820 0.651;0.843 0.804 0.545;0.706 0.686 0.525;0.659 0.624 0.420;0.839 0.800 0.584;0.639 0.600 0.521;0.722 0.651 0.710;0.882 0.839 0.624;0.808 0.761 0.639;0.796 0.753 0.651;0.722 0.682 0.584;0.867 0.824 0.725;0.925 0.878 0.710;0.769 0.733 0.631;0.921 0.906 0.717;0.862 0.835 0.686;0.694 0.556 0.258;0.815 0.792 0.639;0.663 0.631 0.302;0.757 0.478 0.318;0.631 0.616 0.286;0.663 0.588 0.286;0.722 0.557 0.278;0.655 0.600 0.290;0.667 0.584 0.325]

Saídas para Tomate M(700lux):

[2.2204e-016 1.4433e-015 1;1.1102e-016 1.3323e-015 1;6.6613e-016 3.3307e-016 1;5.5511e-016 1.1102e-016 1;6.6613e-016 1.1102e-016 1;3.3307e-016 2.2204e-016 1;-4.4409e-016 1.1102e-015 1;3.3307e-016 0 1;0 8.8818e-016 1;5.5511e-016 1.1102e-016 1;0 0 1;0 0 1;0 0 1;0 0 0.99982;0 0 1;0 0.0043052 0.99495;0 0 1;0 4.6332e-007 1;0 0.0081049 0.9903;0 0 1;0 1.2835e-036 1;0 0 1;0 0 1;0 6.2216e-038 1;0 0 1;0 5.6921e-019 1;0 0 1;0 2.2226e-026 1;0 2.4012e-104 1;0 0 1]

# Livros Grátis

( <http://www.livrosgratis.com.br> )

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)  
[Baixar livros de Literatura de Cordel](#)  
[Baixar livros de Literatura Infantil](#)  
[Baixar livros de Matemática](#)  
[Baixar livros de Medicina](#)  
[Baixar livros de Medicina Veterinária](#)  
[Baixar livros de Meio Ambiente](#)  
[Baixar livros de Meteorologia](#)  
[Baixar Monografias e TCC](#)  
[Baixar livros Multidisciplinar](#)  
[Baixar livros de Música](#)  
[Baixar livros de Psicologia](#)  
[Baixar livros de Química](#)  
[Baixar livros de Saúde Coletiva](#)  
[Baixar livros de Serviço Social](#)  
[Baixar livros de Sociologia](#)  
[Baixar livros de Teologia](#)  
[Baixar livros de Trabalho](#)  
[Baixar livros de Turismo](#)